ANALIZA PRINOSA I RIZIKA NA HRVATSKOM I NJEMAČKOM TRŽIŠTU KAPITALA PRIMJENOM MARKOWITZEVA MODELA

Torbarina, Lucija

Master's thesis / Diplomski rad

2018

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:124:647969

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

ANALIZA PRINOSA I RIZIKA NA HRVATSKOM I NJEMAČKOM TRŽIŠTU KAPITALA PRIMJENOM MARKOWITZEVA MODELA

Mentor:

prof. dr. sc. Zdravka Aljinović

Studentica:

Lucija Torbarina, 2161680

Split, kolovoz 2018.

SADRŽAJ

1. UVOD 1
1.1. Problem istraživanja 1
1.2. Predmet istraživanja 4
1.3. Svrha i ciljevi istraživanja 5
1.4. Istraživačke hipoteze 5
1.5. Metode istraživanja 6
1.6. Struktura istraživanja 6
1.7. Doprinos istraživanja 7
2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA 8
2.1. Definicije osnovnih pojmova 9
2.1.1. Prinos portfelja 9
2.1.2. Očekivana vrijednost i varijanca prinosa portfelja 11
2.2. Formulacija problema 12
2.3. Efikasna granica 13
2.4. Doprinosi i kritike MV modela 15
3. PREZENTACIJA HRTVATSKOG I NJEMAČKOG TRŽIŠTA KAPITALA 18
3.1. Hrvatsko tržište kapitala 18
3.1.1. Zagrebačka burza vrijednosnih papira 22
3.2. Njemačko tržište kapitala 28
3.2.1. Frankfurtska burza vrijednosnih papira 29
4. PRIMJENA MV MODELA NA HRVATSKOM TRŽIŠTU KAPITALA 35
4.1. Kriterij odabira dionica za analizu i formiranje početnog uzorka 35
5. PRIMJENA MV MODELA NA NJEMAČKOM TRŽIŠTU KAPITALA 45
5.1. Kriterij odabira dionica za analizu i formiranje početnog uzorka 45
5.2. Usporedba efikasnih granica hrvatskog i njemačkog tržišta kapitala 54
6. ZAKLJUČAK 55
LITERATURA 57
PRILOZI 60
POPIS SLIKA 71

POPIS TABLICA 72
POPIS GRAFIKONA 74
SAŽETAK.....75
SUMMARY 76

1. UVOD

1.1. Problem istraživanja

Svaki investitor teži pronalaženju optimalnog portfelja kako bi njegova investicija bila isplativa. Općenito, portfelj možemo definirati kao kombinaciju rizične imovine koja je u posjedu pojedinca ili tvrtke u cilju ostvarivanja prihoda. U financijskom smislu, portfelj definiramo kao skup vrijednosnih papira. Prilikom odabira vrijednosnica u portfelj analiziraju se dva važna parametra: rizik i prinos. Investitori se vode politikom uravnoteženja ta dva parametra unutar portfelja.
Da bi investitor bio siguran da vrijednosnica odgovara njegovim potrebama treba odlučiti kakav mu portfelj treba. Dobro isplanirani portfelj može mu pomoći da prevlada uspone i padove tržišta te prilagodi svoju izloženost riziku.[1]

Model koji se može primijeniti u navedenoj analizi je Markowitzev model optimizacije portfelja. Takav model predstavlja pouzdanu potporu pri kontinuiranom praćenju i predviđanju u procesu formiranja investicijskih portfelja, osobito uzevši u obzir očekivano povećanje stabilnosti na tržištu kapitala. Ovaj model za izbor optimalnog portfelja u uvjetima neizvjesnosti i rizika datira iz 1952. godine i njime je nobelovac Karry Max Markowitz postavio temelje moderne teorije portfelja. Cilj ovakvog modela je optimizacija odnosa očekivanog prinosa i pripadajućeg rizika. Ovaj pristup optimizaciji portfelja u skladu je s maksimom ″Nije dobro držati sva jaja u jednoj košari″. Markowitz razvija prvi matematički model koji će pokazati kako odabrati košare, tj. vrijednosnice. [2]

Također, ovakav pristup optimizaciji portfelja zahtijeva neke stroge pretpostavke, kao što je, primjerice, normalna distribucija prinosa. Prednosti ove distribucije su što se definira samo s dva parametra: varijancom i očekivanom vrijednosti i u tome što opisuje slučajne procese u prirodi. Istraživanja provedena na različitim tržištima kapitala pokazala su da pretpostavka o normalnoj distribuciji prinosa često nije zadovoljena u praksi.[3]

Tržišta kapitala u tranzicijskim zemljama mogu se okarakterizirati kao nerazvijena i od malog značaja za ekonomije u smislu prikupljanja kapitala za investicijske poduhvate i uloge u

[1] Maričić, Z., (2011.): Portfelj i izbor vrijednosnica, Praktični menadžment, Vol.2, No. 3, str. 88.
[2] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 1 .
[3] Marasović, B., (2006.): Model optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split, str. 30.

financijskom sustavu, posebno u usporedbi s onima u razvijenim ekonomijama. Nerazvijenost tržišta kapitala u tranzicijskim zemljama može se objasniti niskom razinom aktive institucionalnih investitora, nepovoljnim institucionalnim karakteristikama, propustima u provođenju privatizacijskih procesa, ali i nedovoljnim rastom ekonomija, niskom razinom štednje te niskom razinom ulagačke kulture i tradicije. [4]

Za razliku od teorijskih doprinosa i empirijskih istraživanja u razvijenim zemljama tržišne ekonomije, međusobna povezanost i interaktivnost tržišta kapitala i najznačajnijih ne bankovnih institucionalnih investitora u tranzicijskim zemljama poput Hrvatske, nije dovoljno istražena.

Analiza obuhvaća dvije države, Hrvatsku kao primjer tržišta u nastajanju ili tranzicijsko tržište, te Njemačku kao primjer razvijene zemlje s razvijenim tržištem kapitala. Osnovna ideja tržišta u nastajanju jest da takva tržišta prelaze iz slabo razvijenog statusa u grupu razvijenih zemalja. Karakteristike tržišta u nastajanju su nelikvidnost, slabi obujam trgovanja i prinosi koji nisu normalno distribuirani. Tržišta u nastajanju pružaju posebne izazove i raznolik raspon mogućnosti investitorima. [5] U svijetu se smatra da su ulaganja u ovakve zemlje jako rizična ali potencijalno veoma isplativa, te nude prednosti diversifikacije. Investitori su oprezni zbog nepredvidivih i brzih promjena političke situacije, zakona vezanih uz zaštitu vjerovnika i ulagača, te promjena u valutnim tečajevima. Ostali čimbenici bitni za inozemne investitore su: plitko i nelikvidno tržište, nepouzdanost informacija, korumpiranost i upitno funkcioniranje pravne države. [6]

Također, ovakva tržišta karakterizira i niska korelacija s prinosima na razvijenim tržištima i veća razina predvidljivosti u odnosu na razvijena tržišta kapitala, te rijetko i neusklađeno trgovanje. Tržišta kapitala u razvoju nerijetko zaostaju veličinom i institucionalnom izgrađenošću za razvijenim tržištima. [7]

Hrvatska, kao jedna od država s tržištem u nastajanju u procesu je prelaska iz zatvorenog u otvoreno tržišno gospodarstvo uz izgradnju odgovornosti unutar sustava. Hrvatsko tržište kapitala od iznimne je važnosti za gospodarstvo, njegov razvoj ide dobrim smjerom, ali malo

[4] Ćurak, M., Kundid, A., Visković, J.(2014.) : Financije nakon krize – forenzika, etika i održivost, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 63.
[5] Bekaert, G., Campbell, R. H. (2002.): Research in emerging markets finance: looking to the future, Emerging markets review, Vol. 3, No. 4, str. 2-13
[6] Žiković, S. (2005.): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet, Ljubljana, str. 22.
[7] Barbić, T. (2010.): Pregled razvoja hipoteze efikasnog tržišta, Privredna kretanja i ekonomska politika, Vol. 20, No. 124, str. 49.

sporijim tempom te mu je najveća prednost što je usklađeno s regulativom Europske unije. Najvažnija stavka je privlačenje što većeg broja ulagača i kompanija koje žele biti izlistani na burzi. [8]

Bruto domaći proizvod (BDP) je najučestaliji pokazatelj za mjerenje ekonomske aktivnosti zemlje. Prikazuje ukupnu vrijednost svih proizvedenih dobara i usluga u zemlji u određenom periodu, najčešće jedna godina. Kako bi se vidjela razlika razvijenosti Hrvatske i Njemačke, prikazani su osnovni pokazatelji razvijenosti za obe zemlje. Tako je BDP Hrvatske u 2017. godini iznosio 54.990 milijuna USD, a BDP per capita 13.237 USD. Također, jedan od važnih pokazatelja je i stopa nezaposlenosti koja je u ožujku 2018. godine iznosila 9,4%. [9]

Jedina hrvatska burza vrijednosnih papira je Zagrebačka burza (ZSE), koja je isto tako jedna od značajnijih burzi vrijednosnih papira u Jugoistočnoj Europi.[10] Danas je na burzu uvršteno više od 150 društava, a Burza upravlja Uređenim tržištem i Multilateralnom trgovinskom platformom. Tržišna kapitalizacija za ožujak 2018. godine iznosila je 238,8 milijardi kuna, od čega se 141,1 milijardi kuna odnosi na tržišnu kapitalizaciju dionica Zagrebačke burze. Za isto razdoblje na Burzi je bilo 137 uvrštenih dionica i 26 uvrštenih obveznica. Glavni indeks ZSE je CROBEX koji se sastoji od 25 dionica. Njegova vrijednost za navedeno razdoblje, ožujak 2018. godine iznosila je 1.804,97 bodova.[11]

S druge strane, postoje razvijena tržišta kapitala koja karakterizira visoka likvidnost koja omogućava izvršavanje transakcija značajnih količina uz vrlo mali utjecaj na cijenu. Kao primjer takvog tržišta kapitala, u obzir se uzima njemačko tržište kapitala. Njemačka je treće najveće gospodarstvo svijeta. Također, jedna je od razvijenih zemalja koja nije imala problema s nekretninskim balonima u kojoj je cijena stanova ista već duži period, s blagom tendencijom pada. Pretpostavka je da će događaji kao što su izbori za američkog predsjednika, točnije dolazak Donalda Trumpa na vlast i Brexit donijeti promjene i probleme na tržištima kapitala diljem svijeta. Unatoč takvim pretpostavkama, ta dva događaja nisu uspjeli uzdrmati njemačko tržište kapitala što ukazuje na njegovu jačinu i razvijenost.[12]

[8] Dostupno na: https://lider.media/aktualno/tvrtke-i-trzista/trziste-kapitala/sto-je-najveca-prednost-domaceg-trzista-kapitala/ (04.05.2018.)
[9] Dostupno na: https://countryeconomy.com/countries/compare/croatia/germany (04.05.2018.)
[10] Dostupno na: https://hr.wikipedia.org/wiki/Zagreba%C4%8Dka_burza (04.05.2018.)
[11] Dostupno na: http://zse.hr/default.aspx?id=121 (04.05.2018.)
[12] Nekretninski baloni bili su razlog neuspjeha. Uzrokovali su recesiju bilanci. Tijekom napuhavanja balona vrijednosti imovine u knjigama raste, no kada balon pukne, imovina se briše, dugovi ostaju i proglašava se bankrot poduzeća ali i država. Dostupno na: (https://lider.media/aktualno/tvrtke-i-trzista/trziste-kapitala/sto-je-najveca-prednost-domaceg-trzista-kapitala/)

U usporedbi sa brojkama zemlje kao što je Hrvatska, Njemačka ima puno veće pokazatelje kao što su BDP i BDP per capita. BDP u Njemačkoj za 2017. godinu iznosi 3.686.606 milijuna USD. BDP per capita je iznosio 44.674 USD za 2017. godinu. Također i ovdje se spominje stopa nezaposlenosti koja je u Njemačkoj u veljači 2018. godine iznosila 3,5% i može se vidjeti da je skoro za tri puta manja nego stopa nezaposlenosti u Hrvatskoj.[13]

U Njemačkoj vodeća burza za trgovanje vrijednosnim papirima je Frankfurt Stock Exchange (Borse Frankfurt) sa tržišnom kapitalizacijom od 1.77 bilijuna USD. Najpoznatija je i najznačajnija burza u Njemačkoj, te deseta burza vrijednosnih papira u svijetu. Frankfurtska burza ostvaruje više od 90% ukupnog prometa Njemačke burze. Na njoj kotiraju dionice iz više od 80 zemalja svijeta (kompanije iz Sjeverne Amerike, Europe, Azije, te manji udio kompanija uz Australije i Afrike). Glavni indeks ove burze je DAX koji se sastoji od njemačkih Blue chip dionica, tj. dionica 30 dioničkih društava iz Njemačke. Uz to što je najvažniji indeks na njemačkom tržištu dionica, DAX je jedan od glavnih europskih indeksa vezanih za burze vrijednosnih papira. Njegova vrijednost u svibnju 2018. godine iznosila je 12.732,99 bodova. Uz njega postoji još nekoliko indeksa: DAXplus, CDAX, DivDAX, MDAX, SDAX, TecDAX, VDAX te EuroStoxx 50. [14]

Usporedbom zemalja različite razvijenosti, u ovom slučaju Njemačke kao razvijene zemlje i Hrvatske kao zemlje u nastajanju ili tranzicijske zemlje, svakako se može vidjeti i razlika u njihovim tržištima kapitala. U ovom radu istražuje se koliko je hrvatsko tržište kapitala blizu ili daleko od njemačkog, uzimajući u obzir odnos rizika i prinosa. Odnosno pruža li hrvatsko tržište kapitala mogućnost veće zarade uz prihvaćanje većeg rizika?

1.2. Predmet istraživanja

Unutar ovog rada vrši se procjena efikasne granice na dva različita tržišta kapitala. Odnosno, uspoređuje se odnos rizika i prinosa ta dva tržišta kapitala primjenom Markowitzeva modela. U obzir se uzimaju dvije zemlje, Hrvatska, s tržištem kapitala u razvoju i Njemačka, s razvijenim tržištem kapitala.

U teorijskom dijelu se navode glavne značajke Markowitzeva modela, te značajke svakog od ova dva tržišta kapitala. U empirijskom dijelu se provodi sama procjena efikasne granice. Prilikom izračuna korištene su tjedne cijene dionica u razdoblju od dvije godine. Dionice korištene u analizi sastavni su dio glavnih indeksa ta dva tržišta kapitala, CROBEX u

[13] Dostupno na: https://countryeconomy.com/countries/compare/croatia/germany (26.04.2018.)
[14] Dostupno na: https://en.wikipedia.org/wiki/Frankfurt_Stock_Exchange (04.05.2018.)

Hrvatskoj i DAX u Njemačkoj. Zaključno s time, istražila se i jedna od pretpostavki ovakvog modela, a to je normalnost distribucije.

1.3. Svrha i ciljevi istraživanja

Glavni cilj ovog istraživanja je ukazati na to koliko je hrvatsko tržište kapitala blizu ili daleko od njemačkog tržišta kapitala, uzimajući u obzir odnos rizika i prinosa na dionice koje kotiraju na burzama. Vrlo zanimljivo s obzirom na činjenicu da se radi o dvije europske zemlje različite razvijenosti. Također, cilj i svrha jest usporedba ta dva različita tržišta uslijed globalnih poremećaja kao što su svjetske krize i trenutni poremećaji u svijetu, ali i lokalnih problema koji pogađaju pojedinu zemlju.

1.4. Istraživačke hipoteze

Temeljem definiranog problema istraživanja, te predmeta, svrhe i ciljeva istraživanja, postavlja se sama hipoteza istraživanja. Na temelju tako definirane hipoteze provodi se daljnje istraživanje i donose se određeni zaključci na kraju ovog rada.

- Moguće je ostvariti veći prinos uz veći rizik na hrvatskom tržištu kapitala u odnosu na njemačko razvijeno tržište kapitala

Uz ovu glavnu hipotezu, dodaje se pomoćna hipoteza, koja obuhvaća glavnu pretpostavku ovog MV modela.

- Prinosi dionica na njemačkom i hrvatskom tržištu kapitala su normalno distribuirani

1.5. Metode istraživanja

U sklopu ovog rada postoji teorijski i empirijski dio. Kako bi se ta dva dijela kvalitetno izradila i objasnila bit će potrebne određene metode istraživanja.
Tako je u teorijskom dijelu korišteno više različitih metoda. Metoda analize za raščlanjivanje složenih dijelova MV modela na jednostavnije kako bi se razumjela njegova suština. Putem metode sinteze objasnila se stvarnost spajanjem jednostavnih elemenata u složene. Temeljem pojedinačnih činjenica postigli su se zaključci uz korištenje metode indukcije. Kod usporedbe njemačkog i hrvatskog tržišta kapitala koristila se komparativna metoda, kojom se do zaključaka došlo proučavajući sličnosti i razlike. Za definiranje osnovnih pojmova , činjenica i procesa MV modela koristila se metoda deskripcije. Posljednja metoda u teorijskom dijelu je metoda kompilacije putem koje su se u obzir uzimali i tuđi stavovi i zaključci. U ovom dijelu rada, korištena je stručna literatura koja uključuje knjige, časopise te internetske izvore.

U empirijskom dijelu potrebna je matematička metoda za same izračune svih vrijednosti potrebnih za donošenje zaključaka, te statistička metoda za donošenje određenosti, pravilnosti i zakonitosti pojava. Također, u empirijskom dijelu za izračun efikasnih granica korišten je MS Excel, te za druge statističke zaključke, statistički program IBM SPSS.

1.6. Struktura istraživanja

Diplomski rad sastoji se od šest poglavlja, podijeljenih u dva dijela, teorijski i empirijski dio. Prvo poglavlje je Uvod, u kojem se definiraju problem, predmet istraživanja, svrha, ciljevi, postavljene hipoteze, korištene metode istraživanja, sama struktura te se navodi doprinos ovog istraživanja.

Poslije uvoda prelazi se na teorijski dio rada, u kojem se detaljno predstavlja sami pojam Markowitzeva modela, te njegove pretpostavke, ograničenja i kritike.

U trećem dijelu diplomskog rada izvršena je prezentacija i hrvatskog i njemačkog tržišta kapitala. Kratko se navode glavne karakteristike navedenih tržišta kapitala. Pri tome se misli prvenstveno na prezentaciju dviju burzi vrijednosnih papira te njihovih glavnih indeksa.

Nakon ovog teorijskog dijela, slijedi empirijski dio rada koji obuhvaća četvrto i peto poglavlje. U četvrtom poglavlju provedena je analiza prinosa i rizika na hrvatskom tržištu kapitala primjenom MV modela. A u petom poglavlju, analiza njemačkog tržišta kapitala. Nakon prikaza efikasnih granica za pojedino tržište kapitala, u sklopu petog poglavlja,

prikazana je i usporedba ta dva tržišta kapitala prikazom efikasnih granica oba tržišta kapitala na jednom grafikonu.

Zadnje, šesto poglavlje, odnosi se na zaključak cijelog rada, koji sadrži kratak osvrt na cijeli rad kao i odluku o prihvaćanju ili odbacivanju postavljene hipoteze na početku ovog rada, te kratko objašnjenje konačnog rezultata cijele analize.

1.7. Doprinos istraživanja

Doprinos ovog istraživanja je prikaz odnosa rizika i prinosa dva tržišta kapitala različitog stupnja razvijenosti, njemačko i hrvatsko tržište kapitala. Ovim radom daje se uvid u mogućnost ulaska ulagača na hrvatsko tržište kapitala s obzirom da postoji vjerojatnost ostvarivanja većih prinosa ali uz veći rizik. Također, može se koristiti kao dodatna literatura za daljnja istraživanja vezana za MV model i njegovu primjenu, koja je u prošlosti bila znatno manja.

2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA

Gotovo čitavo stoljeće mnogobrojna ekonomska istraživanja usredotočena su na rješavanje problema upravljanja rizikom i optimizacije portfelja. Pojmovi kao što su očekivani prinos i varijanca portfelja, predstavljaju kriterije na osnovu kojih se provodi optimizacija portfelja. Teorijske postavke moderne teorije portfelja iznesene su još pedesetih godina prošlog stoljeća, ali pravi procvat i široka primjena u praksi slijedi tek devedesetih godina prošlog stoljeća.[15]

Upravljanje portfeljima vrijednosnica jedno je od osnovnih područja modernih korporativnih financija. Svi subjekti na financijskim tržištima se u nekom trenutku susretnu sa viškom sredstava koja žele na neki način uložiti. Bez obzira želi li se uložiti u rizične dionice i derivative ili u vrlo siguran portfelj državnih obveznica i štednih depozita, Moderna teorija portfelja sa svojim glavnim reprezentantom – Markowitzevim modelom optimizacije portfelja, ima isti princip primjene, a to je pronaći optimalnu kombinaciju rizika i prinosa.[16]

U uvjetima intenziviranja razvitka tržišta kapitala, posebice u odnosu na srednje i istočno europsko okruženje te sadašnja i buduća EU udruživanja, potrebno je istražiti i primijeniti odgovarajuću modelsku potporu za analizu i predviđanje kretanja na tržištu kapitala. Nobelovac Harry Max Markowitz 1952. Godine postavlja temelje moderne teorije portfelja modelom za izbor optimalnog portfelja u uvjetima u neizvjesnosti i rizika. Cilj Markowitzevog upravljanja portfeljem nije maksimizacija očekivanog prinosa nego optimiranje odnosa očekivanog prinosa i pripadnog rizika. U skladu s maksimom ″Nije dobro držati sva jaja u jednoj košati″ Markowitz razvija prvi matematički model koji će pokazati kako odabrati košare, tj. vrijednosnice. Takav model visoko je vrednovan, što se očituje u činjenici da je za svoja dostignuća u razvoju moderne teorije portfelja Markowitz 1990. godine dobio Nobelovu nagradu iz ekonomije.[17]

Osnovna Markowitzeva ideja bila je naći ravnotežu između prihoda i rizika, te izabrati portfelj dionica koji donosi najveću moguću dobit uz najmanji mogući rizik. Portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda

[15] Aljinović, Z., Marasović, B., Šego, B., (2008.): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 121.
[16] Jerončić, M., Aljinović, Z. (2011.): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Ekonomski pregled, Vol. 62, No. 9-10, str. 584.
[17] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 1-2.

ima minimalni rizika, Markowitz naziva efikasnim portfeljem. Koristeći se ovim modelom, svaki ulagač iz skupa svih mogućih portfelja izabire onaj portfelj čiji odnos očekivanog prihoda (prinosa) i očekivanog rizika odgovara njegovoj ulagačkoj filozofiji.[18]

Osnovne pretpostavke Markowitzevog modela:[19]

- prinosi na dionice su distribuirani po normalnoj distribuciji,
- investitori žele maksimizirati svoju ekonomsku korisnost,
- investitori su racionalni i imaju averziju prema riziku,
- investitori su dobro obaviješteni o svim relevantnim činjenicama potrebnima za donošenje investicijske odluke,
- nema transakcijskih i poreznih troškova,
- vrijednosnice su savršeno djeljive.

Navedene pretpostavke temelj su ovog modela i svake analize koja se provodi MV modelom. Također, kasnije će se moći vidjeti da iz nekih od ovih pretpostavki zapravo proizlaze kritike MV modela.

2.1. Definicije osnovnih pojmova

2.1.1. Prinos portfelja[20]

Pretpostavimo da investitor može ulagati u n različitih vrijednosnih papira u trenutku t=0 i da ih posjeduje sve do trenutka t=T. pretpostavljamo nadalje da nema transakcijskih troškova i da su vrijednosnice savršeno djeljive. Cijene vrijednosnice u trenutku t=0 i trenutku t=T određuju prinos i-te vrijednosnice R_i, i$\epsilon\{1,2,\dots,n\}$, u trenutku t=T. Ako je u trenutku tϵ $\{0,T\}$ cijena vrijednosnog papira $P_i(0)$, odnosno $P_i(T)$, tada se složeni kontinuirani prinos pojedinog vrijednosnog papira računa izrazom:

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

[18] Aljinović, Z., Marasović, B., Šego, B., (2008.): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 137-138.
[19] Jerončić, M., Aljinović, Z. (2011.): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Ekonomski pregled, Vol. 62, No. 9-10, str. 584.
[20] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 2-6.

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.
Označimo nadalje π_i dio početnog uloga x investiranog u vrijednosnicu *i* u trenutku t=0, tj.

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

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

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

O izboru vektora portfelja π na početku promatranog razdoblja ovisit će ukupno prinos ili prinos portfelja u trenutku t=T:

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

gdje su $X^{\pi}(T) = \sum_{i=1}^{n} \psi_i P_i(T)$ ukupna novčana sredstva dobivena prodajom dionica u trenutku t=T.

Važno je napomenuti da ponekad udjeli π_i, $i \epsilon \{1,2,\ldots,n\}$, mogu poprimiti i negativne vrijednosti. To je u praksi poznato pod pojmom kratke prodaje (short sale). Kratka prodaja predstavlja jednu vrstu trgovine na financijskom tržištu. Mnogi investitori nadaju se da će se cijena dionica u budućnosti povećati i da će oni zaraditi na prodaji dionica u budućnosti. Kod kratke prodaje proces je obrnut. 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 manjoj cijeni.

2.1.2. Očekivana vrijednost i varijanca prinosa portfelja[21]

Budući da je cijena vrijednosnice $P_i(t)$ u nekom trenutku *t* u budućnosti slučajna varijabla, to je i prinos $R_i(t)$ vrijednosnice *i* u trenutku *t* slučajna varijabla.

Pretpostavka je da su distribucije prinosa portfelja i distribucije prinosa individualnih ulaganja približno normalne, što je i H. Markowitz predvidio u svojim istraživanjima. Normalnu je distribuciju moguće kompletno okarakterizirati poznavajući njenu aritmetičku sredinu i standardnu devijaciju, pa se sve 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(aX) = αE(X) , dobivamo izraz za očekivani prinos portfelja:

$$\mu_\pi = E(R_\pi) = E(\sum_{i=1}^{n} \pi_i R_i) = \sum_{i=1}^{n} \pi_i E(R_i) = \sum_{i=1}^{n} \pi_i \mu_i \qquad (6)$$

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).

Nadalje, rizik ulaganja u vrijednosni papir Markowitz kvantificira varijancom prinosa $Var(R_i)$.

Jedna od pretpostavki ovog modela je normalna distribucija prinosa dionica. Dionica čija vrijednost varira više u odnosu na očekivanu vrijednost je rizičnija, pa varijanca kao mjera varijabiliteta prinosa predstavlja prikladnu mjeru rizika.

Ako je $Var(R_i) = 0$, reći čemo da je vrijednosnica bezrizična (risk-free asset). U protivnom je rizična vrijednosnica.

[21] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 7-9.

Formula za izračun varijance dana je sljedećim izrazom:

$$Var(R^{\pi}) = \sum_{i=1}^{n} \sum_{i=1}^{n} \pi_i \sigma_{ij} \pi_j, \quad (7)$$

gdje je $\sigma_{ij} =$ Cov (R_i, Rj) = E(R_i R_j) – E (R_i) E(R_j), i,j ϵ $\{1,2, \dots, n\}$.

Budući da je

$$\sum_{i=1}^{n} \sum_{j=1}^{n} \pi_i \pi_j = 1, \quad (8)$$

možemo reći da jednakost (7) izražava Var (R^n) kao vagani prosjek n^2 varijanci i kovarijanci prinosa vrijednosnica u portfelju.

Za razliku od očekivane vrijednosti portfelja koja je linearna funkcija udjela investicija u portfelju, varijanca prinosa portfelja nije linearna funkcija udjela investicija , jer se moguće varijance prinosa oko očekivanih vrijednosti svake investicije ne moraju poklapati niti intenzitetom niti smjerom kretanja. Zbog toga varijanca prinosa ovisi o udjelima pojedinih vrijednosnica u portfelju, varijancama prinosa pojedinih vrijednosnih papira i korelacijama između prinosa pojedinih vrijednosnica.

2.2. Formulacija problema[22]

Za investitora pri izboru optimalnog portfelja najvažnije je postići što je moguće veći prinos. Osnovna ideja Markowitza bila je pronaći ravnotežu između rizika (varijance prinosa portfelja) i prinosa (očekivana vrijednost prinosa portfelja). Markowitzev model optimizacije portfelja formira se na način da ulagač zada donju granicu prinosa portfelja i tada se iz skupa mogućih portfelja izabere onaj koji ima minimalnu varijancu, odnosno minimalni rizik. Drugi pristup je da ulagač zada gornju granicu prihvatljivog rizika i onda se iz mogućeg skupa portfelja izabere onaj koji maksimizira prinos.

[22] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 13-16.

Matematički ova dva pristupa optimizacije izgledaju na sljedeći način:

1.

$$\underset{\pi \epsilon\, R^n}{Min}\ Var(R^{\pi})$$

$$\mathrm{E}\,(R^{\pi}) \geq c_1$$

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

2.

$$\underset{\pi \epsilon R^n}{Max}\ E\,(R^{\pi})$$

$$\mathrm{Var}\,(R^{\pi}) \leq c_2 \qquad (9)$$

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

Nepoznate varijable u ovom modelu su udjeli pojedinih dionica u portfelju π_i, $i \epsilon \{1,2,\dots,n\}$, odnosno vektor portfelja π kojemu su π_i komponente. Dakle, pitamo se 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 pojedince dionice u portfelju da bi prinos portfelja bio maksimalan, uz rizik ne veći od onog kojeg je ulagač unaprijed zadao (konstanta c_2).

Ograničenjima problema (I) i (II) moramo dodati i ograničenja nenegativnosti u slučaju zabrane kratke prodaje. Problem (I) je problem kvadratnog programiranja (fukncija cilja je kvadratna funkcija, a ograničenja su linearna). Problem (II) je problem linearnog programiranja s kvadratnim ograničenjem.

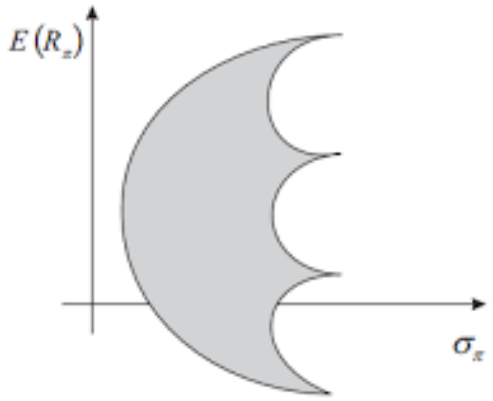
2.3. Efikasna granica[23]

Budući da je svaki portfelj po Markowitzu okarakteriziran svojim prinosom (očekivanim prinosom) i svojim rizikom (varijancom prinosa), može se prikazati točkom u koordinatnoj ravnini u kojoj apscisa predstavlja rizik, a ordinata stupanj očekivane stope prinosa.
Skup svih točaka pridruženih mogućim portfeljima od *n* vrijednosnica prikazan je na slici 1 i naziva se skup mogućih portfelja.

Skup mogućih portfelja ima sljedeća dva važna svojstva:

- ako imamo barem tri vrijednosnice (koje nisu savršeno korelirane i koje imaju različite prinose), skup mogućih portfelja je povezano skup
- skup mogućih portfelja je konveksan s lijeva.

[23] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 16-20.
Aljimović, Z. (2017.): Materijali s predavanja iz kolegija Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split

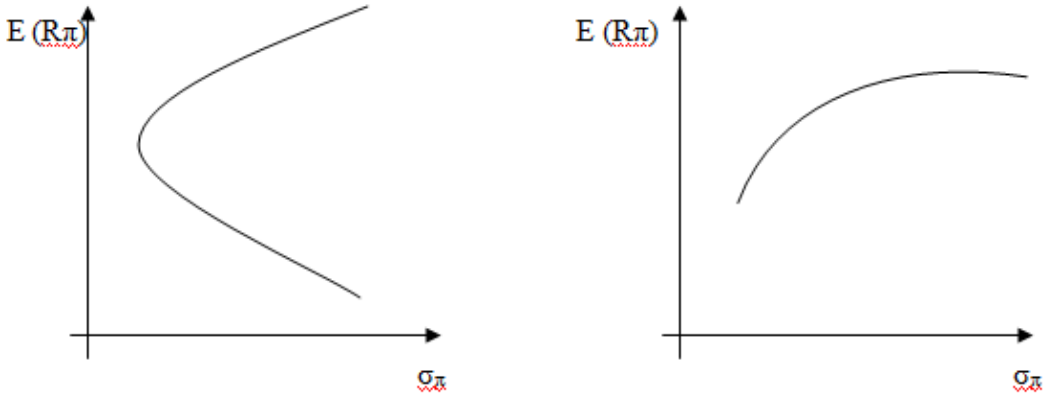


Slika 1: Skup mogućih portfelja

Izvor: Aljinović, Z., Marasović, B., Šego, B., (2008.): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 139.

Prema onome što prikazuje Slika 1, zaključuje se da svi oni portfelji koji se nalaze unutar prostora efikasne granice su mogući ali neefikasni portfelji. Svi oni portfelji koji se nalaze izvan prostora efikasne granice nisu mogući, te svi oni koji se nalaze na samoj efikasnoj granici su mogući i efikasni portfelji s različitim stopama očekivanog prinosa i rizika. Tako postoje portfelji na efikasnoj granici koji su efikasniji od drugih portfelja koji se također nalaze na efikasnoj granici. Razlika je u položaju, odnosno u stopama prinosa i rizika. Efikasan portfelj je onaj koji donosi najveću stopu prinosa, uz zadanu stopu rizika, odnosno portfelj koji za zadanu stopu prinosa ima minimalan rizik.

Dakle portfelj π^* je efikasan portfelj ako ne postoji nijedan drugi portfelj y za koji je $E(R_y) \geq E(R_{\pi^*})$ i $\sigma_y < \sigma_{\pi^*}$.



Slika 2: Skup minimalne varijance i efikasna granica

Izvor: Aljinović, Z., Marasović, B., Šego, B., (2008.): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 140.

Lijevi grafikon prikazan na slici 2 naziva se skup minimalne varijance (minimum- variance set). Njega 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 i to je prikazano na desnom grafikonu na slici 2.

Promatrajući sve moguće portfelje nad nekim konačnim skupom vrijednosnica, zanimaju nas baš efikasni portfelji koji su prethodno objašnjeni.

2.4. Doprinosi i kritike MV modela [24]

Pretpostavke Markowiitzevog modela optimizacije portfelja su sljedeće:

- funkcija korisnosti koja prezentira preferencije investitora je kvadratna funkcija
- prinosi su normalno distribuirani.

Ove pretpostavke bile su polazna točka mnogih kritika ovog modela. Normalna distribucija prinosa nikad nije dokazana. Većina empirijskih testova na tržištima kapitala imala je za rezultat asimetričnu i (ili) šiljastu distribuciju. Sljedeći razlog kritike ovog modela je potreba za izračunavanjem velikog broja standardnih devijacija i korelacija prinosa vrijednosnih papira koji su uzeti za analizu, što je ograničavalo njegovu praktičnu primjenu. Upravo zbog obujma i složenosti izračuna velikog broja parametra, u vrijeme nastanka MV model je bio

[24] Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 25-30.

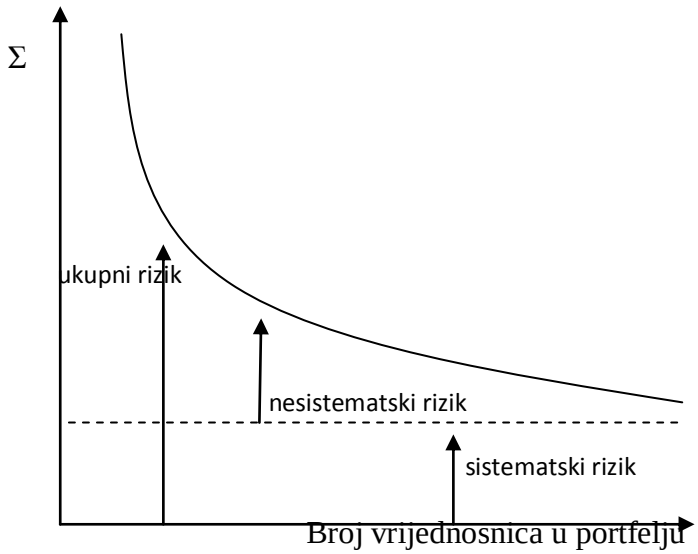
kritiziran i rijetko primjenjivan u praksi. Međutim, u novije vrijeme zahvaljujući brzim računalima i razvoju specijaliziranih softvera problem optimizacije portfelja može se riješiti brzo i efikasno primjenom MV modela. Bitno je naglasiti da će rezultati biti pouzdani i reprezentativni jedino u slučaju kada su ispunjene pretpostavke modela.

Primjena ovog modela u Hrvatskoj gotovo je zanemariva i to iz barem dva razloga. Prvi razlog je u činjenici da je zbog velikog broja matematičkih operacija gotovo nemoguće provesti izračun bez upotrebe računala, a drugi razlog je taj što stručnjaci koji se bave problemima financijskog modeliranja nisu dovoljno upoznati s mogućnostima recentnih programskih paketa razvijanih specijalno za potrebe financijskog modeliranja.

Unatoč svim kritikama, doprinos ovog modela je velik jer on predstavlja početak rađanja ekonomije tržišta kapitala. Sam doprinos leži u činjenici da sve do 1952. godine nije postojao odgovor na pitanje: *Kako izabrati dionice koje će sačinjavati portfelj?* Također, Markowitz je pokazao da se povećanjem broja dionica u portfelju rizik smanjuje. Taj zaključak je poznat kao diversifikacija rizika.

Ukupan rizik se sastoji od:

- sistematskog rizika koji je opći rizik na tržištu i proizlazi iz promjena u svjetskoj i nacionalnoj ekonomiji i ne može se ukloniti boljom diversifikacijom portfelja
- nesistematskog rizika, koji je uzrokovan promjenama u uspješnosti poslovanja pojedinih poduzeća i on se može ukloniti diversifikacijom



Slika 3: Sistematski i nesistematski rizik u odnosu na ukupni rizik

Izvor: Tomić – Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 29.

Zbog svojih dobrih svojstava MV model ostaje bazični model optimizacije portfelja i većina novih modela koji ga slijede temelje se na njemu. Dobro razumijevanje ovog modela omogućuje financijskom menadžeru da razvija nove modele optimizacije portfelja koji će se temeljiti na vlastitim opažanjima, ali i na specifičnostima tržišta na kojem djeluje.

3. PREZENTACIJA HRTVATSKOG I NJEMAČKOG TRŽIŠTA KAPITALA

3.1. Hrvatsko tržište kapitala

Tržište kapitala je dio financijskog tržišta, a obuhvaća trgovinu financijskim instrumentima na uređenom tržištu i izvan njega. Najčešće se na tržištu kapitala trguje dionicima i obveznicama s rokom dospijeća dužim od godine dana. Dionice su vlasnički vrijednosni papiri, koji predstavljaju udio u vlasništvu dioničkog društva. Obveznice su dužnički vrijednosni papiri, koji predstavljaju dugovanje (države ili tvrtke) određenog novčanog iznosa uvećanog za kamatu. Vrijednosni papiri mogu biti kratkoročni i dugoročni ovisno o tome je li dospijeće duga kraće ili duže od godinu dana. Kad govorimo o tržištu kapitala ključna je transparentnost, koja podrazumijeva da su podaci potrebni za donošenje utemeljene investicijske odluke dostupni svima na jednak način. Ono je institucionalno uređeno i određeno zakonodavnom i pravnom regulativom u cilju uspostavljanja efikasnog, sigurnog i likvidnog tržišta.[25]

Tržište kapitala u Republici Hrvatskoj, kao i djelokrug i nadležnost Hanfe (Hrvatska agencija za nadzor financijskih usluga) u tom području, uređeni su Zakonom o tržištu kapitala i Zakonom o preuzimanju dioničkih društava. Zakon o tržištu kapitala uređuje sljedeća područja: pružanje investicijskih usluga i obavljanje investicijskih aktivnosti i s tim povezanih pomoćnih usluga; osnivanje, poslovanje, nadzor i prestanak postojanja investicijskog društva; fond za zaštitu ulagatelja; osnivanje, poslovanje, nadzor i prestanak postojanja tržišnog operatera; pravila trgovanja na uređenom tržištu i multilateralnoj trgovinskoj platformi (MTP-u); ponudu vrijednosnih papira javnosti i uvrštenje vrijednosnih papira na uređeno tržište; objavljivanje informacija o izdavateljima vrijednosnih papira uvrštenih na uređeno tržište; zabranu zlouporabe tržišta; osnivanje, poslovanje, nadzor i prestanak postojanja operatera sustava poravnanja i/ili namire; pohranu financijskih instrumenata i poravnanje i namiru poslova s financijskim instrumentima. Dok Zakon o preuzimanju dioničkih društava uređuje: uvjete za davanje ponude za preuzimanje ciljnih društava; postupak preuzimanja; prava i obveze sudionika u postupku preuzimanja te nadzor postupka preuzimanja ciljnih društava.[26]

[25] Dostupno na: https://www.hanfa.hr/ (12.06.2018.)
[26] Dostupno na: https://www.hanfa.hr/trziste-kapitala/ (12.06.2018.)

Sudionici tržišta kapitala u Republici Hrvatskoj su ulagatelji u financijske instrumente, posrednici (investicijska društva, kreditne institucije i ostali), izdavatelji vrijednosnih papira i ostalih financijskih instrumenata, Zagrebačka burza d.d. Zagreb (tržišni operater i operater MTP-a), Središnje klirinško depozitarno društvo d.d. Zagreb (operater središnjeg depozitorija nematerijaliziranih vrijednosnih papira i operater središnjeg registra ostalih nematerijaliziranih financijskih instrumenata, operater sustava poravnanja i namire nematerijaliziranih vrijednosnih papira te operater Fonda za zaštitu ulagatelja).[27]

Hrvatsko tržište kapitala u prošlosti je doživjelo znatne promjene. Spajanje Zagrebačke i Varaždinske burze, tehnološke promjene u smislu uvođenja novog sustava trgovanja, povećana uloga i opseg djelovanja nadzorne agencije, sedam uspješnih IPO-ova u 2007. godini veliki su pomaci u razvoju tržišta kapitala male tranzicijske zemlje. Unatoč pozitivnim pomacima, prepreka daljnjem razvoju i dalje je ostala relativno visoka nelikvidnost tržišta. Ona se očituje u nedostatku stabilnih i visokih dnevnih prometa, visokoj volatilnosti cijena dionica, postojanju brojnih izrazito nelikvidnih dionica te mogućnosti utjecaja na cijenu pri velikim transakcijama. [28]

Hrvatsko tržište kapitala je jedan duži period nakon svog osnivanja bilo slabo razvijeno. Možemo reći da je postojalo samo na papiru i u zakonima, a da nije ispunjavalo svoje osnovne funkcije kao što su[29]:

- pribavljanje kapitala potrebnog za financiranje poslovanja i ekspanzije poduzeća;
- tržišno vrjednovanje poduzeća;
- mobiliziranje decentralizirane štednje u privredne svrhe;
- povećanje stupnja mobilnosti investicija (omogućuje investitorima održavanje potrebne razine likvidnosti kupnjom i prodajom vrijednosnih papira).

Drugim riječima, nisu stvoreni uvjeti za povezivanje ponude i potražnje vrijednosnih papira. Razlozi tome su bili i na strani ponude (nedovoljan broj dionica zanimljivih kupcima) i na strani potražnje (pomanjkanje investitora). Osnovni uzrok neatraktivnosti dionica u kontekstu portfolio analize je bila netransparentnost poslovanja poduzeća, mali broj dionica i njihova nelikvidnost. Nelikvidnost se očituje u broju dana ne trgovanja koji je za većinu dionica bio

[27] Dostupno na: https://www.hanfa.hr/trziste-kapitala/ (12.06.2018.)
[28] Benić, V.,Franić, I. (2008.): Komparativna analiza likvidnosti tržišta kapitala Hrvatske i zemalja regije, str. 482.
[29] Jakšić, S., (2007.): Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 5, No. 1, str. 332.

jako velik. Uključivanjem takvih dionica nije se mogla postići zadovoljavajuća diversifikacija rizika portfelja te su se takve dionice u pravilu kupovale u spekulativne svrhe. Prijelomna točka je bilo donošenje Zakona o tržištu vrijednosnih papira koji je stupio na snagu 25. srpnja 2002. godine. Stroge odredbe toga zakona su "prisilile" velik broj poduzeća ustrojenih kao dionička društva da "iziđu" (going-public) na burzu, tj. da ispune uvjete za kotiranje u nekoj od kotacija burze. Sama po sebi ova odredba, tj. sama činjenica da poduzeće kotira na burzi ne bi mnogo značila za razvoj tržišta kapitala. Međutim, kotiranje na burzi obvezuje dionička društva na ispunjavanje određenih uvjeta, kao što su periodično objavljivanje financijskih izvještaja kao osnove razumijevanja sigurnosti i uspješnosti poslovanja poduzeća, što bi trebali biti glavni čimbenici odluke investitora o kupnji ili prodaji dionica. Prema tome, povećanje ponude vrijednosnih papira kao i poboljšana transparentnost njihovih izdavatelja u kombinaciji s liberalizacijom (izmjena Zakona o deviznom poslovanju) i ulaskom jakih institucionalnih investitora (banke, investicijski fondovi, mirovinski fondovi, osiguravajuća društva…), tj. porastom potražnje za vrijednosnim papirima dalo je snažan zamah razvoju hrvatskog tržišta kapitala u vidu značajnog porasta prometa, tržišne kapitalizacije, broja transakcija, burzovnih indeksa i cijene dionica na burzama.[30]

Hrvatsko tržište kapitala bilježi vrlo brzi rast prije početka gospodarske krize, ali i manjak dubine i likvidnosti. Vlasnički vrijednosni papiri bili su ključni pokretač brzog rasta tržišta kapitala. Tržišna kapitalizacija se više nego utrostručila u razdoblju od 2001., dosegavši 133 posto BDP-a na kraju rujna 2007., dok je ukupni koeficijent prometa iznosio prosječno 8,1 posto kapitalizacije, odnosno bio je među najmanjima u regiji. Za vrijeme krize 2008. godine, Hrvatsko tržište kapitala biva zahvaćeno također velikom krizom, negativnim trendovima, posljedično financijskim negativnim rezultatima i mnogi, poglavito privatni predstavnici nemaju mogućnosti uskladiti se sa svim zahtjevima koje je donijela nova legislativa.[31]

Nakon te gospodarske krize, jedan od većih događaja koji je ostavio trag na hrvatskom tržištu kapitala je slučaj Agrokora. Ukratko, to je događaj koji je uzdrmao cijelu ekonomiju države, a time i samo tržište kapitala. Problemi unutar koncerna Agrokor utjecali su na nagli pad cijena dionica kako koncerna tako i na ukupnu vrijednost indeksa Crobex. U jednom trenu, dionice Agrokora bile su potpuno potopljene, posebice dionice poduzeća Ledo d.d. Ovaj događaj je pravi primjer kako svaka promjena u državi bitno utječe na rad burze i cijene ostalih dionica

[30] Jakšić, S., (2007.): Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 5, No. 1, str. 332-333.
[31] Caruana, J., Deppler, M., (2008.): Procjena stabilnosti financijskog sustava- ažurirana verzija, Sektor na monetarnu politiku i tržišta kapitala i Sektor za Europu, Međunarodni monetarni fond, Republika Hrvatska

na tržištu kapitala. Takve promjene dolaze više do izražaja na tržištima kapitala koja su još u nastajanju kao što je i hrvatsko tržište kapitala. Analizirajući početak 2018. godine, ZSE otvorila je u crvenom i uz skromne volumene trgovanja.

Kao tranzicijsko tržište, zemlja započinje program gospodarske reforme koji će je dovesti do jačih i odgovornijih ekonomskih performansi, kao što su transparentnost i efikasnost tržišta kapitala. Vrijednosti dionica su bile podcijenjene za vrijeme procesa privatizacije, također nitko nije bio upoznat o trgovanju na burzama. Mnogi od dioničara nisu znali procijeniti vrijednost papira koji su dobili tijekom procesa privatizacije, pa su ih prodavali po niskim cijenama. Investitori koji su počeli kupovati vrijednosnice znali su pravu vrijednost tih novo kreiranih dionica i tako su stvorili velike kapitalne dobitke. Naučeni iskustvom što se dogodilo u Hrvatskoj, dioničari su započeli širenje trgovanja na ostalim tranzicijskim burzama gdje su dionice još bile podcijenjene.[32]

Hrvatska kao država s tržištem u nastajanju je u prošlosti imala problema s razvitkom financijskog tržišta. Razlozi tome su loše provedena privatizacija, petogodišnji građanski rat 90-ih godina. Kao što je već spomenuto glavna karakteristika ovakvih tržišta jest manjak likvidnosti i premoć banaka nad svim ostalim financijskim institucijama. Također, ulaganje u ovakva tržišta jako je rizično, ali potencijalno isplativo. Zbog toga ovakva tržišta su na jedan način primamljiva investitorima koji su skloni nepredvidivim i brzim promjenama.[33]

Što se tiče novijih kretanja na hrvatskom tržištu kapitala, u siječnju se najviše trgovalo dionicama Zagrebačke banke, Valamara i Atlantske plovidbe, dok je u veljači najveća potražnja bila za Valamarom, Hrvatskim Telekomom i Adris Grupom. Iako je Zagrebačka burza najavila nastavak trgovanja dionicama iz sastava Agrokor, te se tim dionicama trebalo početi trgovati 2.3.2018, HANFA je naložila Zagrebačkoj burzi da privremeno i bez odgode na uređenom tržištu obustavi trgovanje dionicama izdavatelja iz grupe Agrokor (Belje d.d., Jamnica d.d., Ledo d.d., PIK-Vinkovci d.d., Tisak d.d., Vupik d.d., Zvijezda d.d. i Žitnjak d.d.).[34]

Burza vrijednosnih papira vrsta je burze koja brokerima i trgovcima dionicama, obveznicama i ostalim vrijednosnim papirima omogućuje trgovanje. Osim toga, pruža i pogodnosti za izdavanje i otkup ostalih financijskih instrumenata te sklapanje raznih financijskih poslova

[32] Zagreb International Review of Economics & Business, Vol. 20, No. 2, pp (2017.), str. 11.-12.
[33] Žiković, S. (2005.): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet, Ljubljana
[34] Dostupno na: http://www.zse.hr/ (12.06.2018.)

koji donose razne prinose. Da bi se nekim vrijednosnim papirom na burzi moglo trgovati, on ondje mora kotirati. Uobičajeno je da na burzama postoji jedinstveno mjesto gdje su prikazani vrijednosni papiri koji kotiraju, iako se trgovanje danas odvija elektroničkim putem i nije važna geografska lokacija na kojoj se kupac ili prodavatelj nalaze. Trgovina se može odvijati samo između članova burze. Trgovanje vrijednosnih papira u Hrvatskoj odvija se na Zagrebačkoj burzi, koja je ujedno i jedina burza vrijednosnih papira u Hrvatskoj.[35]

3.1.1. Zagrebačka burza vrijednosnih papira[36]

Zagrebačka burza utemeljena je 1907. u sklopu Trgovačkog doma (današnje Gospodarske komore i kao takva funkcionirala je do 1911. godine. Zagrebačka burza ponovno je otvorena 1919. pod nazivom Zagrebačka burza za robu i vrednote, uživajući povjerenje klijenata iz inozemstva, posebice Beča i Praga, te su se brojne novčane transakcije odvijale upravo preko nje, čineći osnovu snažnog zagrebačkog bankarstva i novčarstva onoga vremena. Godine 1945., dolaskom socijalističkog režima na vlast, Zagrebačka burza ponovno je zatvorena.

Obnova burze u Hrvatskoj uslijedila je tek 1991. godine, kada je 25 banaka i 2 osiguravajuća društva utemeljilo Zagrebačku burzu kao centralno mjesto trgovine vrijednosnim papirima u Republici Hrvatskoj. U samim počecima trgovalo se na velikim dražbama koje su organizirane u sjedištu Burze na Ksaveru i na kojima su svi brokeri bili fizički prisutni. Godine 1994. uveden je elektronički trgovinski sustav koji omogućava da brokeri članovi Burze budu telekomunikacijski povezani i trguju na Burzi ne napuštajući svoje urede diljem Hrvatske. U prvih pet godina nakon uvođenja elektroničkog sustava trgovanja, dakle od 1995. godine pa do 2000. godine, vrijednost tržišta Zagrebačke burze narasla je gotovo 10 puta. Danas je na Zagrebačku burzu uvršteno više od 150 društava, a Burza upravlja dvama tržištima: Uređenim tržištem i Multilateralnom trgovinskom platformom.
Uređeno tržište trgovinski je segment kojim upravlja Zagrebačka burza i na kojem je moguće trgovanje uvrštenim instrumentima.

[35] Dostupno na: https://hr.wikipedia.org/wiki/Burza_vrijednosnih_papira (14.06.2018.)
[36] Dostupno na: http://www.zse.hr/ (14.06.2018.)
Dostupno na: https://hr.wikipedia.org/wiki/Zagreba%C4%8Dka_burza (14.06.2018.)

Podijeljeno je na sljedeće segmente:

- vodeće tržište koje je najzahtjevniji tržišni segment u smislu zahtjeva koje postavlja pred izdavatelja, osobito glede transparentnosti,
- redovito tržište koje obvezuje izdavatelja na dostavu samo minimalnih informacija propisanih Zakonom o tržištu kapitala
- službeno tržište

S druge strane CE Enter tržište je multilateralna trgovinska platforma kojom upravlja Zagrebačka burza d.d. i sastoji se od sljedećih tržišnih segmenata: CE Enter – Alter, CE Enter – Fortis, CE Enter – X.

Od 2010. godine Zagrebačka burza uvela je neke značajne novitete na domaće tržište kapitala:

- pokrenuta je specijalistička trgovina (market making),
- započelo je trgovanje strukturiranim proizvodima,
- Burza je počela upravljati Multilateralnom trgovinskom platformom,
- uvedeno je osam novih indeksa,
- započelo je i izdavanje LEI oznaka.

Zajedno s Bugarskom i Makedonskom burzom, Zagrebačka burza 2014. godine osnovala je društvo SEE LINK, s ciljem stvaranja regionalne infrastrukture za trgovanje dionicama uvrštenima na ta tri tržišta. SEE LINK platforma postala je operativna u prvom kvartalu 2016.godine.

Na samome kraju 2015. godine, Zagrebačka burza uspješno je završila proces preuzimanja Ljubljanske burze od CEE Stock Exchange Group. Uzimajući u obzir sličnosti slovenskog i hrvatskog tržišta kapitala gledajući stupanj razvoja, strukturu i potencijal, očekuju se brojni pozitivni učinci i sinergije ove akvizicije za oba tržišta.

Već 25 godina Zagrebačka burza predvodi trendove u razvoju regionalnog tržišta kapitala, omogućujući transparentnu, sigurnu, učinkovitu i održivu trgovinu vrijednosnicama te održavajući najveću razinu kvalitete usluga tržišta kapitala kako bi se zadovoljile potrebe dioničara, ulagača, izdavatelja, članova i svih zainteresiranih strana.

Zagrebačka burza jedino je uređeno tržište u Republici Hrvatskoj. Na njoj danas kotira oko 300 različitih vrijednosnih papira, od čega su oko 230 dionice dok ostalo čine obveznice, komercijalni papiri, prava i certifikati. Trgovanje se u potpunosti odvija elektroničkim putem svakim radnim danom od 09:00 do 16:30 sati. Dionice s najvećom tržišnom kapitalizacijom na Zagrebačkoj burzi su INA d.d., HT d.d., Privredna banka Zagreb d.d., te Janaf d.d. Ukupna tržišna kapitalizacija u ožujku 2018. godine iznosila je 238,8 milijardi kuna, od čega se 141,1 milijardi kuna odnosi na tržišnu kapitalizaciju dionica Zagrebačke burze, a 97,7 milijardi kuna na tržišnu kapitalizaciju obveznica. Rezultati trgovine i dnevne cijene dionica dostupni su svim zainteresiranima putem dnevnog tiska, specijaliziranih kuća za distribuciju financijskih informacija kao i na Burzinim internetskim stranicama te pomoću ZSE Monitora.

Tablica 1: Tržišna kapitalizacija Zagrebačke burze za razdoblje 2013.-2017. godine u milijardi kuna

RAZDOBLJE	DIONICE	OBVEZNICE	UKUPNO
2013. godina	113,4	64,3	177,7
2014. godina	121,2	75,3	197,1
2015. godina	122,9	79,0	203,6
2016. godina	143,2	89,2	232,4
2017. godina	144,0	93,4	237,4

Izvor: http://www.zse.hr/

Tablica 1 prikazuje tržišnu kapitalizaciju Zagrebačke burze u razdoblju od pet godina. Tržišna kapitalizacija dobije se množeći zaključnu cijenu i broj izdanih dionica. Može se vidjeti da je tržišna kapitalizacija od 2013. godine do 2017. godine imala lagani uspon. Također, tržišna kapitalizacija dionica na Zagrebačkoj burzi veća je nego li tržišna kapitalizacija obveznica. Razlog tomu je što na Zagrebačkoj burzi kotira veći broj dionica nego obveznica.

Na Zagrebačku burzu mogu se uvrstiti financijski instrumenti koji ispunjavaju sljedeće uvjete:

- izdavatelj mora biti uredno registriran prema propisima RH,
- ispuniti obvezu objave prospekta,
- financijski instrumenti moraju biti slobodno prenosivi,
- financijski instrumenti kojima se može trgovati fer, uredno i djelotvorno,
- mora biti osigurana učinkovita namira transakcija.

Tablica 2: Broj uvrštenih vrijednosnica na Zagrebačkoj burzi

RAZDOBLJE	DIONICE	OBVEZNICE
2013. godina	131	45
2014. godina	160	39
2015. godina	152	38
2016. godina	147	36
2017. godina	144	33

Izvor: http://www.zse.hr/

Prema tablici 2 može se vidjeti broj uvrštenih vrijednosnica u razdoblju od pet godina. Ovdje se potvrđuje prethodno spomenuta činjenica da na Zagrebačkoj burzi kotira mnogo veći broj dionica nego li obveznica.

Tablica 3: Promet na Zagrebačkoj burzi u milijunima kuna

RAZDOBLJE	DIONICE	OBVEZNICE	UKUPNO
2013. godina	3.004,24	574,02	3.587,25
2014. godina	2.851,47	715,80	3.656,09
2015. godina	2.747,40	502,86	3.329,52
2016. godina	3.118,92	693,58	3.864,41
2017. godina	3.210,93	448,78	3.659,71

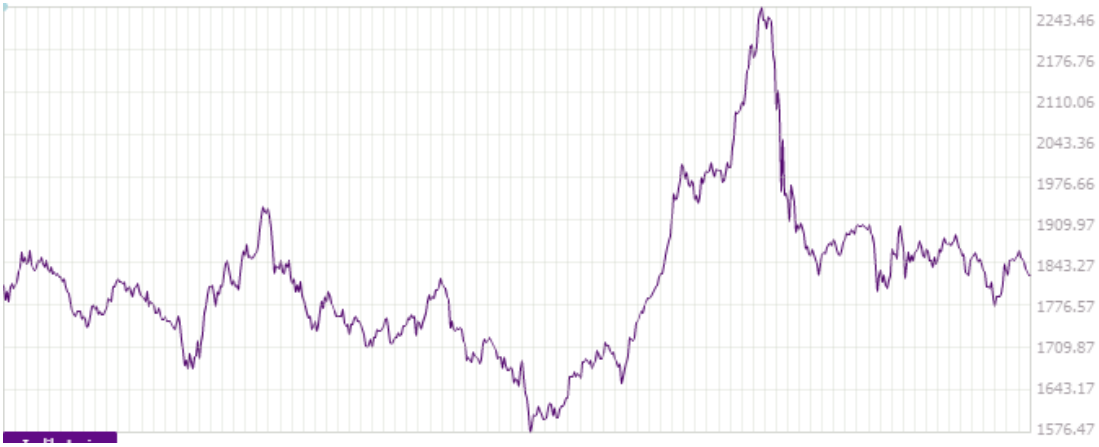
Izvor: http://www.zse.hr/

Tablica 3 prikazuje pojedinačno promet vrijednosnica (dionica i obveznica) te ukupan promet na Zagrebačkoj burzi u razdoblju od pet godina. Može se i ovdje vidjeti prednost prometa dionica u odnosu na promet obveznica. Ukupan promet vrijednosnica u promatranom razdoblju varira iz godine u godinu.

Na Zagrebačkoj burzi postoje dvije vrste indeksa, dionički i obvezнički. Dionički su indeski CROBEX, CROBEX10, CROBEXindustrija, CROBEXkonstrukt, CROBEXnutris, CROBEXplus, CROBEX TR, CROBEXtransport i CROBEXturist, dok su obvezнički indeksi CROBIS i CROBIStr.

CROBEX je dionički i službeni indeks Zagrebačke burze. Bazni datum, odnosno početak objavljivanja ovog indeksa je 01.07.1997. godine. Njegova bazna vrijednosti iznosi 1000,00. Sastoji se od 25 dionica, a maksimalna težina pojedine sastavnice mora biti 10%. Indeks se

računa kao omjer free float tržišne kapitalizacije i free float tržišne kapitalizacije na bazni datum. Free float tržišna kapitalizacija dionice računa se kao umnožak broja izdanih dionica, free float faktora i zadnje cijene dionice. Revizija CROBEX-a obavlja se polugodišnje, treći petak u ožujku i rujnu. Uvjet za uključenje dionica u sastav ovog indeksa je 80% dana trgovanja.



Slika 4: Vrijednost CROBEX-a za razdoblje od pet godina (17.06.2013.- 15.06.2018.)

Izvor: http://www.zse.hr/

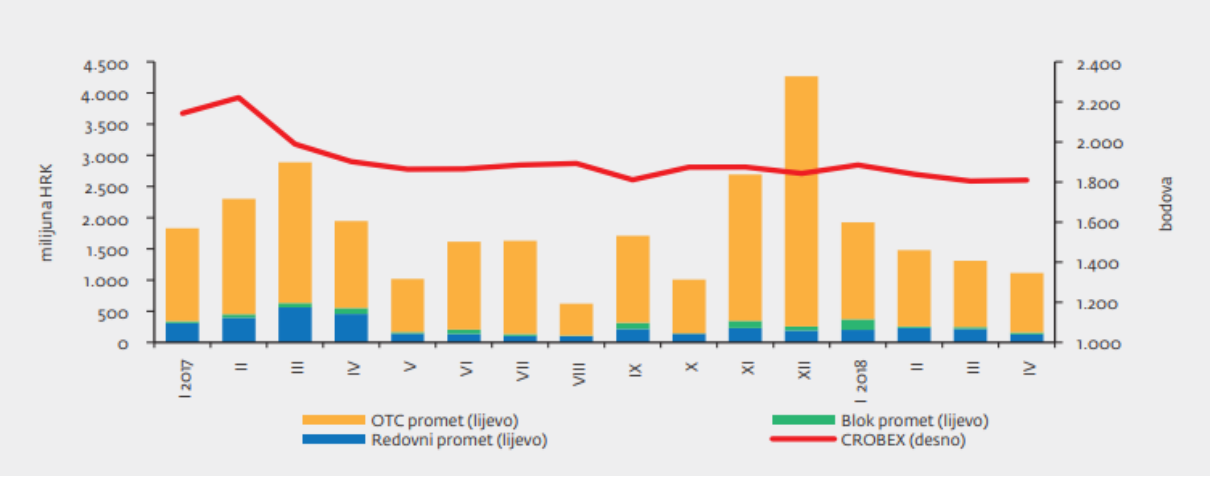
Na slici 4 prikazano je dnevno kretanje vrijednosti dioničkog indeksa CROBEX za razdoblje od pet godina. U promatranom razdoblju postoje stalne oscilacije vrijednosti CROBEX-a. Mogu se izdvojiti jedino dva veća rasta vrijednosti i to u razdoblju od 30.06.2016. godine do 26.09.2016. godine, te u razdoblju od 29.12.2016. do 6.02.2017. godine. Nakon toga, dolazi do strmovitog pada vrijednosti CROBEX-a. Takav pad dogodio se u samo mjesec dana i to u ožujku 2017. godine.

Tablica 4: Zaključna cijena CROBEX-a i stanje prometa dionica u sastavu indeksa

Datum	Zadnja	Promet dionica u sastavu indeksa	Datum	Zadnja	Promet dionica u sastavu indeksa
15.6.2018	1.821,36	3.806.493,36	29.5.2018	1.850,63	1.965.581,30
14.6.2018	1.825,51	2.505.912,11	28.5.2018	1.855,58	2.332.942,70
13.6.2018	1.821,17	3.659.366,70	25.5.2018	1.860,12	4.772.965,39
12.6.2018	1.824,88	4.212.383,85	24.5.2018	1.848,73	1.576.635,35
11.6.2018	1.827,25	4.412.142,94	23.5.2018	1.851,38	5.508.423,55
8.6.2018	1.831,45	1.613.181,85	22.5.2018	1.859,77	3.235.111,96
7.6.2018	1.830,83	14.462.381,53	21.5.2018	1.849,34	4.765.702,20
6.6.2018	1.829,77	9.172.511,85	18.5.2018	1.855,19	4.393.171,80
5.6.2018	1.842,85	4.303.614,20	17.5.2018	1.845,70	4.280.122,64
4.6.2018	1.838,84	2.426.297,55	16.5.2018	1.844,19	5.879.493,87
1.6.2018	1.846,38	7.367.377,65	15.5.2018	1.846,43	3.784.724,60
30.5.2018	1.854,02	4.659.564,48			

Izvor: http://www.zse.hr/

Tablica 4 prikazuje zaključne cijene indeksa i promet dionica koje se nalaze u sastavu indeksa na dnevnoj bazi u razdoblju od mjesec dana. Prema zaključnoj cijeni može se zaključiti kako nije bilo prevelikih oscilacija u promatranom razdoblju. S druge strane, promet dionica koje su u sastavu indeksa mijenjao se iz dana u dan. Najveći promet bio je 07.06.2018. godine i iznosio je 14.462.381,53 kn.



Slika 5: Promet na Zagrebačkoj burzi

Izvor: Hrvatska gospodarska komora, dostupno na: https://hgk.hr/

Slika 5 prikazuje promet (redovni, OTC i blok promet) na Zagrebačkoj burzi u razdoblju od siječnja 2017. godine do travnja 2018. godine, također prikazuje i kretanje indeksa CROBEX u navedenom razdoblju. Na Zagrebačkoj burzi nastavljeno je sada već dugotrajno razdoblje

niskog prometa i potisnutih cijena dionica. Tako je u travnju, u odnosu na ožujak, promet unutar knjige ponuda smanjen za 40,5%, pri čemu je promet dionicama bio 25,0%, a promet obveznicama 64,0% niži. Uz rast blok-prometa dionicama za 12,5%, u konačnici je sveukupni promet bio 34,3% niži nego u ožujku. Na kraju travnja Crobex se ipak vratio iznad psihološke granice od 1.800 bodova na 1.809,6 bodova, što je 0,3% više nego na kraju prethodnog mjeseca.

3.2. Njemačko tržište kapitala[37]

Njemačka je razvijena europska zemlja koja stalno raste. Njezina razvijenost može se vidjeti i u pokazateljima koji su već spomenuti u samom uvodu ovog rada. Također, jedna je od najrazvijenijih država svijeta i jedna od osnivačkih članica Europske Unije. Članica je i Ujedinjenih naroda, NATO-a, skupine G4, G7 i G8. S približno 82 milijuna stanovnika, druga je europska zemlja po broju stanovnika, a najveća u EU-u, te ima najsnažnije europsko gospodarstvo.[38]

Njemački financijski sustav temeljen na bankama oslanja se na proizvode posredovane bankom a ne toliko na procese tržišta kapitala. Štoviše, jedan od stupova u sustavu s tri stupa, štedionice, javno je kontroliran, a drugi stup, zadružne banke, ima poseban statut. Oba stupa nisu izložena kontroli tržišta kapitala kroz uobičajenu prijetnju promjene vlasništva. U financiranju tvrtki bankovni krediti su daleko važniji, povezani tržišnim proizvodima, tj. kapitalu i obveznicama, nego u SAD-u i UK-u. Štoviše, banke su dosad imale dominantan položaj u korporativnoj kontroli kroz svoje fondove i njihove glasove u nadzornom odboru u njemačkom dvoslojnom sustavu korporativnog upravljanja. Ovaj sustav natječe se s anglosaksonskim modelom korporativnog upravljanja. S obzirom da su banke pod pritiskom promjena međunarodnih uvjeta, sustav još mora dokazati njegovu održivost.

Njemački financijski sustav je bankocentričan. Banke imaju vodeću ulogu u mobiliziranju štednje, dodjeljivanju kapitala, nadzoru nad investicijskim odlukama korporativnih menadžera. Oni djeluju kao posrednici između kućanstava i poduzeća u prikupljanju depozita od kućanstva i pružanju kredita poduzećima.

Mjerenjem veličine burze relativnom tržišnom kapitalizacijom tj. omjerom vrijednosti svih izlistanih dionica na burzi i bruto domaćeg proizvoda zemlje domaćina, Njemačka tržišna

[37] Horst, S. (2004): Germany's Capital Market and Corporate Governance, Kiel Working Paper, No. 1206. Kiel Institute for World Economics

[38] Dostupno na: https://hr.wikipedia.org/wiki/Njema%C4%8Dka (23.06.2018.)

kapitalizacija od 40% BDP - a (u svibnju 2003.) je niska u odnosu na međunarodne standarde. Tako je uspoređujući neke zemlje, Njemačka imala približno jednak postotak kao i Italija (48), ali niži nego u Francuskoj (106), Ujedinjenom Kraljevstvu (128) i Sjedinjenim Državama (140). Bez obzira na rast tržišta dionica, sva tekuća ulaganja u vrijednosne papire osim dionica bila su veća u razdoblju od 1998. do 2000. nego li ulaganja u dionice. Za razliku od toga, udjeli dionica su veći. Dionice su važnije za tvrtke nego li za kućanstva i čine više od 50% imovine u bilanci poduzeća (2000.), ali značajno niže nego u eurozoni (71 posto).

3.2.1. Frankfurtska burza vrijednosnih papira[39]

Njemačka burza ima organizirano tržište vrijednosnica još od 1585. godine. Unatoč tome na što samo ime upućuje, ona je više od toga. Koristeći visoko razvijenu tehnologiju, Njemačka burza obavlja usluge tržišta vrijednosnih papira na međunarodnoj razini. Pokriva veliki raspon proizvoda i usluga koje su dio ovakvog poslovanja: trgovanje dionicama i derivatima, rješavanje naloga, vlasništvo nad vrijednosnim papirima i prikupljanje tržišnih podataka.
Zajedno sa svojim podružnicama Europske burze energije, Deutsche Börse Group Eurex jedna je od vodećih svjetskih tržišta organizirana za trgovanje opcijama i futuresima. Također, Njemačka burza razvija i provodi vlastiti sistem trgovanja i nadgleda svjetsku mrežu sudionika.

Grupa Deutsche Börse obuhvaća Deutsche Börse AG i svoje podružnice. Investitori mogu izabrati između tri područja za iznošenje svojih naloga: Xetra, Börse Frankfurt i Tradegate. Godine 1993. Frankfurtska burza vrijednosnih papira postaje dijelom Deutsche Börse AG, novom velikom organizacijom za pružanje financijskih usluga. U novom razdoblju, točnije svibnju 2011. godine u potpunosti je ukinut klasični način trgovanja te je uvedeno elektroničko trgovanje. Deutsche Börse generira oko 98% trgovanja njemačkim dionicama na uređenom tržištu Frankfurtske burze. S time je Frankfurt stock exchange daleko najveći dio njemačke burze i generira najviše prometa - zbog čega se cijene trgovačkih mjesta Xetra i Börse Frankfurt smatraju "referentnim cijenama".

Trgovanje se sada u potpunosti odvija elektroničkim putem, uz asistenciju računalnog sustava Xetra. Xetra® je vodeće trgovačko mjesto za trgovanje njemačkim dionicama i fondovima (ETF).

[39] Dostupno na: http://deutsche-boerse.com/dbg-en/about-us/deutsche-boerse-group (23.06.2018.)

Za institucionalne i privatne investitore, Frankfurtska burza je korisni dodatak potpuno elektronskoj platformi Xetra, gdje se trguje manje likvidnim dionicama i obveznicama. Na Frankfurtskoj burzi se može trgovati svakim radnim danom od 8:00 do 20:00 sati, koristeći širok raspon različitih naloga i usporedno s time primati kvalitetno jamstvo prilikom izvršenja narudžbi.

Na Frankfurtskoj burzi trguje se s više od 1.5 milijuna financijskih instrumenata, što je više nego na bilo kojem drugom europskom financijskom centru. Oba područja trgovanja, Xetra i Frankfurtska burza nude optimalno izvršenje narudžbe, s najvećom razinom transparentnosti i likvidnosti. Tako se na Frankfurtskoj burzi nalazi više od 10 000 dionica različitih kompanija. Što se tiče obveznica, ova burza ima najveću ponudu obveznica u Europi, među njima korporativne obveznice, sve više i strane obveznica te veliki raspon njemačkih velikih hipotekarnih obveznica. Osim obveznica i dionica, na ovoj burzi se trguje i mješovitim fondovima, certifikatima i varantima i dr.

Tablica 5: Tržišna kapitalizacija Njemačke burze izražena u mil. €

Razdoblje	Tržišna kapitalizacija
Prosinac 2015.	1.570.300,61
Prosinac 2016.	1.630.412,75
Prosinac 2017.	1.888.277,18

Izvor: izračun autora prema podacima FESE[40]

Tablica 5 prikazuje tržišnu kapitalizaciju Njemačke burze za razdoblje od tri godine. U usporedbi s prethodno navedenom tržišnom kapitalizacijom Zagrebačke burze, može se vidjeti kako je tržišna kapitalizacija njemačkog tržišta kapitala mnogo veća nego li je to slučaj na hrvatskom tržištu kapitala. Razlozi su ti što se ovdje radi o razvijenom tržištu kapitala, s puno većim obujmom trgovanja na burzi vrijednosnih papira, o čemu govore prethodno navedene činjenice i podaci. Može se vidjeti kako tržišna kapitalizacija kroz razdoblje od tri godine ima stalni uspon, te je svake godine veća od one u prethodnoj godini.

[40] Dostupno na: http://www.fese.eu/statistics-market-research/historical-data (25.06.2018.)

Tablica 6: Broj domaćih i stranih poduzeća čije su dionice uvrštene na Njemačkoj burzi

Razdoblje	Domaća poduzeća	Strana poduzeća
Prosinac 2015.	555	64
Prosinac 2016.	531	61
Prosinac 2017.	450	49

Izvor: izračun autora prema podacima FESE[41]

Prema tablici 6 može se zaključiti kako na Njemačkoj burzi dominiraju domaća poduzeća, odnosno dionice domaćih poduzeća. Također, postoje i strana poduzeća, čiji je udio znatno manji. Ovdje se također može vidjeti znatna razlika između Hrvatske i Njemačke. Na Njemačkoj burzi ima skoro pet puta više uvrštenih dionica nego na Zagrebačkoj burzi, što još jednom ukazuje na veličinu i značenje ove burze i njemačkog tržišta kapitala.

Kao što je već navedeno, glavni indeksi na ovoj burzi su: DAX, DAXplus, CDAX, DivDAX, MDAX, SDAX, TecDAX, VDAX te EuroStoxx 50.

DAX je prvi put izdan 01. srpnja 1988. S početnom vrijednosti indeksa od 1.163 boda. Prati izvođenje 30 najvećih i najlikvidnijih poduzeća na Njemačkom tržištu kapitala, što predstavlja oko 80% ukupne tržišne kapitalizacije izlistanih njemačkih dioničarskih društava. Indeks je proizvod i figurativna oznaka tvrtke Deutsche Börse AG. DAX se računa kao indeks cijena i uspješnosti. Za indeks uspješnosti, dividende se izračunavaju kao reinvestirane, a za indeks cijena, dividende se ne uzimaju u obzir. Dana 13. listopada 2008. godine, DAX postiže najveći dnevni dobitak na 11,40%. Volkswagen, kao sastavni dio ovog indeksa, postaje najvrjednija svjetska kompanija u listopadu 2008. godine porastom cijene dionice preko 1.000€. Značajnost i veličinu ovog indeksa dokazuje postizanje tržišne kapitalizacija DAX-a od 1.181.238,25 bilijuna € u svibnju 2018. godine. DAX danas ima položaj jednog od najvažnijih dioničkih indeksa na svjetskoj razini. Proteklih trideset godina vrijednost DAX-a je porasla za više od deset puta. Ulagači koji su pristupili pri najvećoj razini u 1988. godini imali bi prosječni godišnji prinos od 7,5%. Prema tome, početno ulaganje u iznosu od 1.000 eura, danas se vrednuje u iznosu od 8.754,96 eura.[42]

DAX je najvažniji njemački indeks, a istodobno i slika za njemačke Bluechip dionice. To su dionice osobito visoke vrijednosti, čije tvrtke imaju veliko priznanje. Na trgovačkom mjestu

[41] Dostupno na: http://www.fese.eu/statistics-market-research/historical-data (25.06.2018.)
[42] Dostupno na: http://deutsche-boerse.com/dbg-en/about-us/30-years-dax/dax-facts (03.07.2018.)

XETRA investitori mogu trgovati s 1.000 njemačkih dionica i 11.000 međunarodnih dionica.[43]

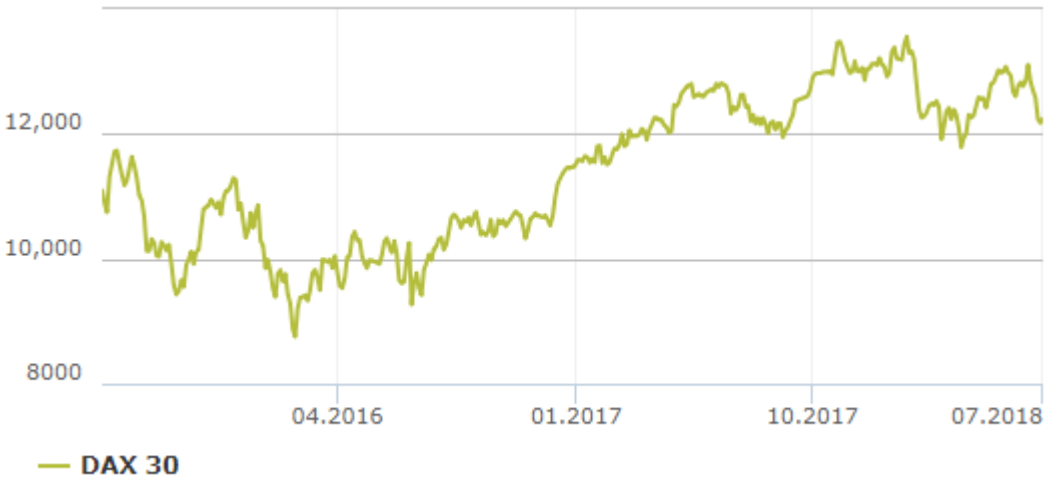
Name	Turnover	Last Price
Daimler	336,34 Mio.	55.58
Siemens	247,87 Mio.	112.58
Allianz	234,19 Mio.	174.38
Bayer	230,40 Mio.	94.92
Volkswagen (VW) vz	228,92 Mio.	141.10
SAP	204,44 Mio.	98.30
BASF	172,30 Mio.	81.27
adidas	162,84 Mio.	183.55

Slika 6: Promet i zaključna cijena najaktivnijih dionica u sastavu indeksa DAX na dan 02.07.2018. godine

Izvor: http://en.boerse-frankfurt.de/equities (02.07.2018.)

Na slici 6 prikazane su najaktivnije dionice u sastavu indeksa DAX, te njihov promet i zaključne cijene na određen dan, tj. 02.07.2018. Razlog zašto se te dionice smatraju najaktivnijim može se vidjeti u iznosima koji se odnose na promet tih dionica iskazan u milijunima € i to u jednom danu.

[43] Dostupno na: http://en.boerse-frankfurt.de/equities (02.07.2018.)



Slika 7: Kretanje indeksa DAX u razdoblju od tri godine (02.07.2015.-02.07.2018.)

Izvor: http://en.boerse-frankfurt.de/index/DAX (02.07.2018.)

Indeks DAX u ovom razdoblju od tri godine ima različita kretanja, tj. postoje oscilacije ali malog su značaja. Gledajući cijelo kretanje indeksa, može se reći da ima tendenciju rasta, posebno u 2017. godini.

Tablica 7: Zaključna cijena indeksa DAX

Datum	Zaključna cijena	Datum	Zaključna cijena
15.6.2018	13.010,55	30.5.2018.	12.783,76
14.6.2018	13.107,10	29.5.2018	12.666,51
13.6.2018	12.890,58	28.5.2018	12.863,46
12.6.2018	12.842,30	25.5.2018	12.938,01
11.6.2018	12.842,91	24.5.2018	12.855,09
8.6.2018	12.766,55	23.5.2018	12.976,84
7.6.2018	12.811,05	22.5.2018	13.169,92
6.6.2018	12,830,07	18.5.2018	13.077,72
5.6.2018	12.787,13	17.5.2018	13.114,61
4.6.2018	12.770,75	16.5.2018	12.996,33
1.6.2018	12.724,27	15.5.2018	12.970,04
31.5.2018	12.604,89		

Izvor: izračun autora prema podacima s Internet stranice nacionalne burze: http://en.boerse-frankfurt.de/

Također, promatrajući i analizirajući i ovu tablicu, u odnosu na navedene podatke vezane za Zagrebačku burzu u prethodnom poglavlju, ponovno se može vidjeti ta razlika između razvijenog tržišta i tržišta u nastajanju. U tablici 7 prikazane su zaključne cijene indeksa DAX u razdoblju od jednog mjeseca, kao što su bile prikazane zaključne cijene CROBEX-a u prethodnom poglavlju. Vrijednosti ovog indeksa daleko premašuju vrijednosti CROBEX-a i to za više od sedam puta u nekim slučajevima.

Prema prethodno navedenim podacima tržišta kapitala pojedine zemlje odnosno, Njemačke i Hrvatske, te njihovih glavnih burzi vrijednosnih papira, može se uočiti razlika u njihovoj razvijenosti i veličini. Dvije zemlje s različitim stupnjem razvijenosti razlikuju se u svakom pogledu. U sljedećim poglavljima provedena je financijska analiza pojedinih tržišta kapitala kojom se pobliže objašnjava odnos rizika i prinosa na svakom od navedenih tržišta kapitala.

4. PRIMJENA MV MODELA NA HRVATSKOM TRŽIŠTU KAPITALA

4.1. Kriterij odabira dionica za analizu i formiranje početnog uzorka

Prilikom odabira dionica za analizu putem MV modela poštuju se sljedeći kriteriji:

- dionice moraju biti uvrštene na Zagrebačkoj burzi;
- odabrane dionice moraju biti dio glavnog indeksa Zagrebačke burze, CROBEX-a;
- temeljem prethodnog kriterija, dionice moraju ispunjavati i određene kriterije kako bi bile dio CROBEX-a;
- dovoljno velika tržišna kapitalizacija;
- dovoljno velika vremenska serija, odnosno naglasak je na likvidnim dionicama.

Uvjeti koji moraju biti zadovoljeni kako bi dionica bila dio glavnog indeksa, CROBEX-a su sljedeći[44]:

- dionice uvrštene na uređeno tržište kojima se trgovalo više od 80% ukupnog broja trgovinskih dana u šestomjesečnom razdoblju koje prethodi reviziji
- rang dionice koji se određuje temeljem udjela u free float tržišnoj kapitalizaciji i udjela u prometu ostvarenom unutar knjige ponuda u šestomjesečnom razdoblju koje prethodi
- u sastavu indeksa može biti najmanje 15 dionica, a najviše 25 dionica s najvišim rangom

U nastavku ovog rada, u analizu je uključeno deset dionica koje su dio indeksa CROBEX. Točnije, odabrane dionice su sastavnice CROBEX-a 10 u kojeg ulaze dionice s najvećom free float tržišnom kapitalizacijom i prometom, a ujedno su i dio CROBEX-a.

[44] Dostupno na: http://www.zse.hr/ (04.07.2018.)

Simbol	Izdavatelj	Broj dionica	Free float faktor	Težinski faktor	Zadnja cijena	Tržišna kapitalizacija	Težina
ADPL	AD Plastik d.d.	4.199.584	0,70	1,00000000	197,00	579.122.633,60	3,54%
ADRS2	Adris grupa d.d.	6.784.100	1,00	1,00000000	417,00	2.828.969.700,00	17,28%
ARNT	Arena Hospitality Group d.d.	5.128.721	0,50	1,00000000	412,00	1.056.516.526,00	6,46%
ATGR	Atlantic Grupa d.d.	3.334.300	0,45	1,00000000	980,00	1.470.426.300,00	8,98%
ATPL	Atlantska plovidba d.d.	1.395.520	0,75	1,00000000	460,00	481.454.400,00	2,94%
ERNT	ERICSSON NIKOLA TESLA d.d.	1.331.650	0,55	1,00000000	1.025,00	750.717.687,50	4,59%
HT	HT d.d.	81.670.064	0,45	0,55810760	149,00	3.064.360.251,02	18,72%
KOEI	Končar - Elektroindustrija d.d.	2.572.119	1,00	1,00000000	650,00	1.671.877.350,00	10,21%
PODR	Podravka d.d.	7.120.003	0,85	1,00000000	319,00	1.930.588.813,45	11,80%
RIVP	VALAMAR RIVIERA d.d.	126.027.542	0,50	1,00000000	40,20	2.533.153.594,20	15,48%

Slika 8: Sastav CROBEX10

Izvor: http://www.zse.hr/ (04.07.2018.)

Slika 8 prikazuje dionice su obuhvaćene analizom putem Markowitzeva modela. To su redom dionice sljedećih poduzeća: AD Plastik d.d., Adris grupa d.d., Arena Hospitality Group d.d., Atlantic Grupa d.d., Atlanska plovidba d.d., Ericsson Nikola Tesla d.d., HT d.d., Končar – Elektroindustrija d.d., Podravka d.d. i Valamar Riviera d.d. Radi bolje pokrivenosti i različitosti prilikom analize, sve ove dionice dolaze iz različitih sektora. Tako su pokriveni sljedeći sektori u hrvatskom gospodarstvu: telekomunikacije (HT); proizvodnja prehrambenih proizvoda, pića i duhanskih proizvoda (PODR); proizvodnja računala te elektroničkih i optičkih proizvoda (ERNT); proizvodnja električne opreme (KOEI); proizvodnja transportne opreme (ADPL); trgovina na veliko i na malo; popravak motornih vozila i motocikala (ATGR); prijevoz i skladištenje (ATPL); djelatnost pružanja smještaja te pripreme i usluživanja hrane (ARNT i RIVP) te pravne, računovodstvene, upravljačke, arhitektonske djelatnosti i inženjerstvo te tehničko ispitivanje i analiza (ADRS2).

U nastavku su prikazane zaključne tjedne cijene odabranih dionica u razdoblju od dvije godine, odnosno od 3.lipnja 2016. godine do 29. lipnja 2018. godine. Svi podaci korišteni u daljnjoj analizi nalaze se na internet stranicama Zagrebačke burze.

Tablica 8: Zaključne tjedne cijene odabranih dionica hrvatskog tržišta kapitala

Datum	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
3.6.2016.	114,62	387,50	325,00	815,25	129,06	1.012,35	141,17	686,13	341,71	24,01
10.6.2016.	111,25	399,20	325,00	818,49	130,65	1.004,35	140,72	670,00	343,00	23,98
17.6.2016.	112,95	387,53	336,00	815,41	136,31	1.008,01	140,82	667,07	339,56	23,98
24.6.2016.	109,08	387,73	345,00	793,83	132,19	1.001,02	139,26	650,00	325,18	23,93
1.7.2016.	112,33	377,95	346,99	814,74	136,68	1.004,95	141,63	636,85	330,22	24,77
8.7.2016.	122,54	381,82	359,00	814,37	146,68	1.020,40	142,76	675,00	342,80	25,05
15.7.2016.	119,66	383,87	360,00	824,09	174,42	1.006,38	142,79	662,68	333,99	24,76
22.7.2016.	114,52	393,46	399,92	818,85	195,00	1.003,96	142,85	675,77	335,71	25,45
29.7.2016.	111,65	408,49	401,00	816,14	181,16	1.009,09	143,18	663,00	359,00	26,66
5.8.2016.	112,52	402,19	398,99	814,20	172,15	1.010,47	142,45	656,87	356,00	26,88
12.8.2016.	115,36	401,22	390,50	814,03	184,14	1.016,31	142,24	658,06	359,76	27,22
19.8.2016.	118,01	404,26	389,24	816,58	185,00	1.016,91	143,43	657,90	360,35	29,33
26.8.2016.	119,00	406,95	408,00	819,16	182,37	1.030,85	145,53	669,89	365,79	29,00
2.9.2016.	123,83	405,46	392,20	821,98	173,31	1.095,75	154,59	674,90	356,97	28,78
9.9.2016.	128,17	415,90	415,00	844,11	193,60	1.127,12	156,19	673,00	360,34	28,85
16.9.2016.	126,42	417,93	427,00	847,00	176,11	1.163,74	161,10	662,23	361,06	30,32
23.9.2016.	131,19	435,66	429,99	871,03	193,57	1.138,20	164,87	673,67	383,84	32,84
30.9.2016.	136,88	436,19	435,00	868,62	180,03	1.142,00	163,60	676,38	379,00	34,15
7.10.2016.	140,01	480,19	429,00	879,01	196,71	1.149,09	165,17	690,27	381,00	34,48
14.10.2016.	140,04	459,15	435,00	869,94	240,84	1.149,67	161,81	682,76	374,20	35,00
21.10.2016.	140,01	449,74	422,00	866,03	281,90	1.152,58	159,93	683,20	371,60	32,98
28.10.2016.	139,86	450,00	426,00	865,04	295,17	1.144,50	164,23	678,75	369,60	32,55
…										
2.2.2018.	182,50	430,00	452,00	950,00	660,00	1.230,00	165,00	705,00	269,00	43,00
9.2.2018.	187,00	441,00	442,00	935,00	640,00	1.220,00	167,00	705,00	261,00	41,90
16.2.2018.	190,50	428,00	443,00	940,00	626,00	1.210,00	165,00	710,00	264,00	41,40
23.2.2018.	192,50	427,00	435,00	890,00	640,00	1.170,00	163,00	700,00	253,00	40,80
2.3.2018.	191,50	418,00	440,00	970,00	620,00	1.155,00	163,00	695,00	265,00	42,30
9.3.2018.	195,00	434,00	439,00	960,00	644,00	1.170,00	162,50	700,00	264,00	41,70
16.3.2018.	195,00	435,00	425,00	970,00	628,00	1.165,00	165,50	660,00	263,00	42,10
23.3.2018.	192,00	440,00	430,00	965,00	570,00	1.170,00	163,50	680,00	261,00	40,90
30.3.2018.	186,00	424,00	425,00	970,00	568,00	1.165,00	164,00	655,00	260,00	40,10
6.4.2018	189,00	432,00	426,00	955,00	514,00	1.160,00	161,50	660,00	260,00	40,60
13.4.2018.	181,50	421,00	429,00	935,00	516,00	1.165,00	161,50	645,00	261,00	39,80
20.4.2018.	180,00	420,00	417,00	940,00	562,00	1.145,00	160,00	670,00	270,00	39,40
27.4.2018.	190,00	418,00	420,00	945,00	536,00	1.055,00	163,00	665,00	290,00	40,00
4.5.2018.	189,50	429,00	424,00	960,00	520,00	1.055,00	165,50	695,00	302,00	42,80
11.5.2018.	193,00	437,00	423,00	945,00	518,00	1.075,00	156,50	700,00	315,00	42,50
18.5.2018.	198,50	451,00	430,00	965,00	499,00	1.080,00	159,00	685,00	315,00	42,10
25.5.2018.	197,00	450,00	428,00	1.040,00	468,00	1.100,00	157,00	670,00	315,00	41,50
1.6.2018.	197,00	427,00	421,00	1.040,00	494,00	1.100,00	154,00	675,00	313,00	41,60

8.6.2018.	191,50	429,00	424,00	1.010,00	485,00	1.085,00	153,00	660,00	315,00	41,50
15.6.2018.	191,00	428,00	422,00	1.040,00	470,00	1.070,00	148,00	665,00	312,00	41,50
22.6.2018.	198,00	432,00	426,00	1.050,00	468,00	1.085,00	150,00	670,00	318,00	41,50
29.6.2018.	196,50	424,00	424,00	975,00	475,00	1.045,00	151,00	665,00	322,00	40,50

Izvor: http://www.zse.hr/

Temeljem zaključnih tjednih cijena, u nastavku su izračunati tjedni prinosi odabranih dionica. Izračun se temelji prema ranije spomenutoj formuli za izračun kontinuiranog prinosa te podacima koji su dostupni na Internet stranicama Zagrebačke burze.

Tablica 9: Tjedni prinosi odabranih dionica hrvatskog tržišta kapitala

Datum	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
10.6.2016.	-2,98%	2,97%	0,00%	0,40%	1,22%	-0,79%	-0,32%	-2,38%	0,38%	-0,13%
17.6.2016.	1,52%	-2,97%	3,33%	-0,38%	4,24%	0,36%	0,07%	-0,44%	-1,01%	0,00%
24.6.2016.	-3,49%	0,05%	2,64%	-2,68%	-3,07%	-0,70%	-1,11%	-2,59%	-4,33%	-0,21%
1.7.2016.	2,94%	-2,55%	0,58%	2,60%	3,34%	0,39%	1,69%	-2,04%	1,54%	3,45%
8.7.2016.	8,70%	1,02%	3,40%	-0,05%	7,06%	1,53%	0,79%	5,82%	3,74%	1,12%
15.7.2016.	-2,38%	0,54%	0,28%	1,19%	17,32%	-1,38%	0,02%	-1,84%	-2,60%	-1,16%
22.7.2016.	-4,39%	2,47%	10,52%	-0,64%	11,15%	-0,24%	0,04%	1,96%	0,51%	2,75%
29.7.2016.	-2,54%	3,75%	0,27%	-0,33%	-7,36%	0,51%	0,23%	-1,91%	6,71%	4,64%
5.8.2016.	0,78%	-1,55%	-0,50%	-0,24%	-5,10%	0,14%	-0,51%	-0,93%	-0,84%	0,82%
12.8.2016.	2,49%	-0,24%	-2,15%	-0,02%	6,73%	0,58%	-0,15%	0,18%	1,05%	1,26%
19.8.2016.	2,27%	0,75%	-0,32%	0,31%	0,47%	0,06%	0,83%	-0,02%	0,16%	7,47%
26.8.2016.	0,84%	0,66%	4,71%	0,32%	-1,43%	1,36%	1,45%	1,81%	1,50%	-1,13%
2.9.2016.	3,98%	-0,37%	-3,95%	0,34%	-5,10%	6,11%	6,04%	0,75%	-2,44%	-0,76%
9.9.2016.	3,44%	2,54%	5,65%	2,66%	11,07%	2,82%	1,03%	-0,28%	0,94%	0,24%
16.9.2016.	-1,37%	0,49%	2,85%	0,34%	-9,47%	3,20%	3,10%	-1,61%	0,20%	4,97%
23.9.2016.	3,70%	4,15%	0,70%	2,80%	9,45%	-2,22%	2,31%	1,71%	6,12%	7,98%
30.9.2016.	4,25%	0,12%	1,16%	-0,28%	-7,25%	0,33%	-0,77%	0,40%	-1,27%	3,91%
7.10.2016.	2,26%	9,61%	-1,39%	1,19%	8,86%	0,62%	0,96%	2,03%	0,53%	0,96%
14.10.2016.	0,02%	-4,48%	1,39%	-1,04%	20,24%	0,05%	-2,06%	-1,09%	-1,80%	1,50%
21.10.2016.	-0,02%	-2,07%	-3,03%	-0,45%	15,74%	0,25%	-1,17%	0,06%	-0,70%	-5,94%
28.10.2016.	-0,11%	0,06%	0,94%	-0,11%	4,60%	-0,70%	2,65%	-0,65%	-0,54%	-1,31%
…										
2.2.2018.	-3,76%	0,23%	1,11%	4,30%	-0,30%	2,05%	0,00%	0,71%	-0,37%	0,47%
9.2.2018.	2,44%	2,53%	-2,24%	-1,59%	-3,08%	-0,82%	1,20%	0,00%	-3,02%	-2,59%
16.2.2018.	1,85%	-2,99%	0,23%	0,53%	-2,21%	-0,82%	-1,20%	0,71%	1,14%	-1,20%
23.2.2018.	1,04%	-0,23%	-1,82%	-5,47%	2,21%	-3,36%	-1,22%	-1,42%	-4,26%	-1,46%
2.3.2018.	-0,52%	-2,13%	1,14%	8,61%	-3,17%	-1,29%	0,00%	-0,72%	4,63%	3,61%
9.3.2018.	1,81%	3,76%	-0,23%	-1,04%	3,80%	1,29%	-0,31%	0,72%	-0,38%	-1,43%
16.3.2018.	0,00%	0,23%	-3,24%	1,04%	-2,52%	-0,43%	1,83%	-5,88%	-0,38%	0,95%
23.3.2018.	-1,55%	1,14%	1,17%	-0,52%	-9,69%	0,43%	-1,22%	2,99%	-0,76%	-2,89%
30.3.2018.	-3,17%	-3,70%	-1,17%	0,52%	-0,35%	-0,43%	0,31%	-3,75%	-0,38%	-1,98%

6.4.2018	1,60%	1,87%	0,24%	-1,56%	-9,99%	-0,43%	-1,54%	0,76%	0,00%	1,24%
13.4.2018.	-4,05%	-2,58%	0,70%	-2,12%	0,39%	0,43%	0,00%	-2,30%	0,38%	-1,99%
20.4.2018.	-0,83%	-0,24%	-2,84%	0,53%	8,54%	-1,73%	-0,93%	3,80%	3,39%	-1,01%
27.4.2018.	5,41%	-0,48%	0,72%	0,53%	-4,74%	-8,19%	1,86%	-0,75%	7,15%	1,51%
4.5.2018.	-0,26%	2,60%	0,95%	1,57%	-3,03%	0,00%	1,52%	4,41%	4,05%	6,77%
11.5.2018.	1,83%	1,85%	-0,24%	-1,57%	-0,39%	1,88%	-5,59%	0,72%	4,21%	-0,70%
18.5.2018.	2,81%	3,15%	1,64%	2,09%	-3,74%	0,46%	1,58%	-2,17%	0,00%	-0,95%
25.5.2018.	-0,76%	-0,22%	-0,47%	7,48%	-6,41%	1,83%	-1,27%	-2,21%	0,00%	-1,44%
1.6.2018.	0,00%	-5,25%	-1,65%	0,00%	5,41%	0,00%	-1,93%	0,74%	-0,64%	0,24%
8.6.2016.	-2,83%	0,47%	0,71%	-2,93%	-1,84%	-1,37%	-0,65%	-2,25%	0,64%	-0,24%
15.6.2018.	-0,26%	-0,23%	-0,47%	2,93%	-3,14%	-1,39%	-3,32%	0,75%	-0,96%	0,00%
22.6.2018.	3,60%	0,93%	0,94%	0,96%	-0,43%	1,39%	1,34%	0,75%	1,90%	0,00%
29.6.2018.	-0,76%	-1,87%	-0,47%	-7,41%	1,48%	-3,76%	0,66%	-0,75%	1,25%	-2,44%

Izvor: izračun autora

Nadalje, na temelju izračunatih prinosa, izračunati su očekivani tjedni prinos i rizik mjeren varijancom i standardnom devijacijom.

Tablica 10: Očekivani tjedni prinos i rizik odabranih dionica na hrvatskom tržištu kapitala

	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
E (R)	0,50%	0,08%	0,25%	0,17%	1,21%	0,03%	0,06%	-0,03%	-0,06%	0,48%
σ^2	0,000551	0,000537	0,000895	0,00082	0,003771	0,000617	0,000309	0,000514	0,000679	0,000681
σ	2,35%	2,32%	2,99%	2,86%	6,14%	2,48%	1,76%	2,27%	2,61%	2,61%

Izvor: izračun autora

Podaci u tablici 10 izračunati su u programu Excel pomoću određenih funkcija. Tako je očekivani prinos izračunat funkcijom „average“, varijanca funkcijom „varp“, a standardna devijacija funkcijom „stdevp“. Prema izračunu i dobivenih rezultata, može se vidjeti kako je u promatranom razdoblju dionica poduzeća Atlantska plovidba d.d. (ATPL) s najvećim postotkom očekivanog prinosa i to 1,21%. S druge strane, dionica s najmanjim očekivanim prinosom (-0,06%) je dionica poduzeća Podravka d.d. (PODR).

Uspoređujući rizik odabranih dionica mjeren varijancom i standardnom devijacijom, dionica s najvećim rizikom je dionica poduzeća Atlantska plovidba d.d. (ATPL), a dionica s najmanjim koeficijentom rizika je dionica poduzeća Hrvatski telekom d.d. (HT).

Ovakav rezultat potvrđuje činjenicu da uz ostvarenje većeg prinosa na ulaganje, investitor trpi i veći rizik.

Sljedeći korak u analizi je izračun matrice varijanci i kovarijanci, koja je potrebna za izračun efikasne granice. Za potrebe izračuna matrice varijanci i kovarijanci potrebno je izračunati matricu A. Elementi matrice A dobiju na način da se od tjednog prinosa pojedine dionice za svako razdoblje oduzme očekivani prinos te dionice. Nakon izračuna matrice A, slijedi izračun matrice varijanci i kovarijanci formulom:

$$S = \frac{1}{M} A' * A, \tag{10}$$

gdje je A' oznaka za transponiranu matricu A.

Tablica 11: Matrica varijanci i kovarijanci na hrvatskom tržištu kapitala

	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
ADPL	0,000551	0,000129	-0,000028	0,000012	0,000132	0,000094	0,000053	0,000197	0,000184	0,000094
ADRS2	0,000129	0,000537	0,000127	0,000170	-0,000084	0,000173	0,000106	0,000131	0,000201	0,000188
ARNT	-0,000028	0,000127	0,000895	0,000039	0,000018	0,000164	-0,000052	0,000024	0,000151	0,000247
ATGR	0,000012	0,000170	0,000039	0,000820	-0,000163	0,000141	0,000089	0,000034	0,000195	0,000144
ATPL	0,000132	-0,000084	0,000018	-0,000163	0,003771	-0,000096	-0,000123	0,000177	0,000014	0,000012
ERNT	0,000094	0,000173	0,000164	0,000141	-0,000096	0,000617	0,000095	0,000133	0,000117	0,000138
HT	0,000053	0,000106	-0,000052	0,000089	-0,000123	0,000095	0,000309	0,000040	0,000063	0,000101
KOEI	0,000197	0,000131	0,000024	0,000034	0,000177	0,000133	0,000040	0,000514	0,000222	0,000100
PODR	0,000184	0,000201	0,000151	0,000195	0,000014	0,000117	0,000063	0,000222	0,000679	0,000284
RIVP	0,000094	0,000188	0,000247	0,000144	0,000012	0,000138	0,000101	0,000100	0,000284	0,000681

Izvor: izračun autora

Tablica 11 prikazuje matricu varijanci i kovarijanci za odabrane dionice. Na glavnoj dijagonali nalaze se varijance za svaku dionicu koje zapravo odgovaraju vrijednostima varijanci u prethodnoj tablici. Temeljem tih varijanci procjenjuje se rizičnost odabranih dionica. Kao što je već spomenuto, dionica s najmanjom varijancom od 0,00309 je HT, a s najvećom varijancom od 0,003771 je ATPL.

Nakon svih koraka u analizi, slijedi izračun efikasne granice. Prije samog prikaza efikasne granice na grafikonu, potrebno je pronaći portfelje na efikasnoj granici kroz *solver* u programskom paketu *Microsoft Excel-a* i to u slučaju kada kratka prodaja nije dozvoljena. U tom slučaju, uz standardna ograničenja prilikom formulacije problema, uvodi se dodatno ograničenje tzv. uvjet nenegativnosti. Tim uvjetom udjeli odabranih dionica ne smiju biti negativni.

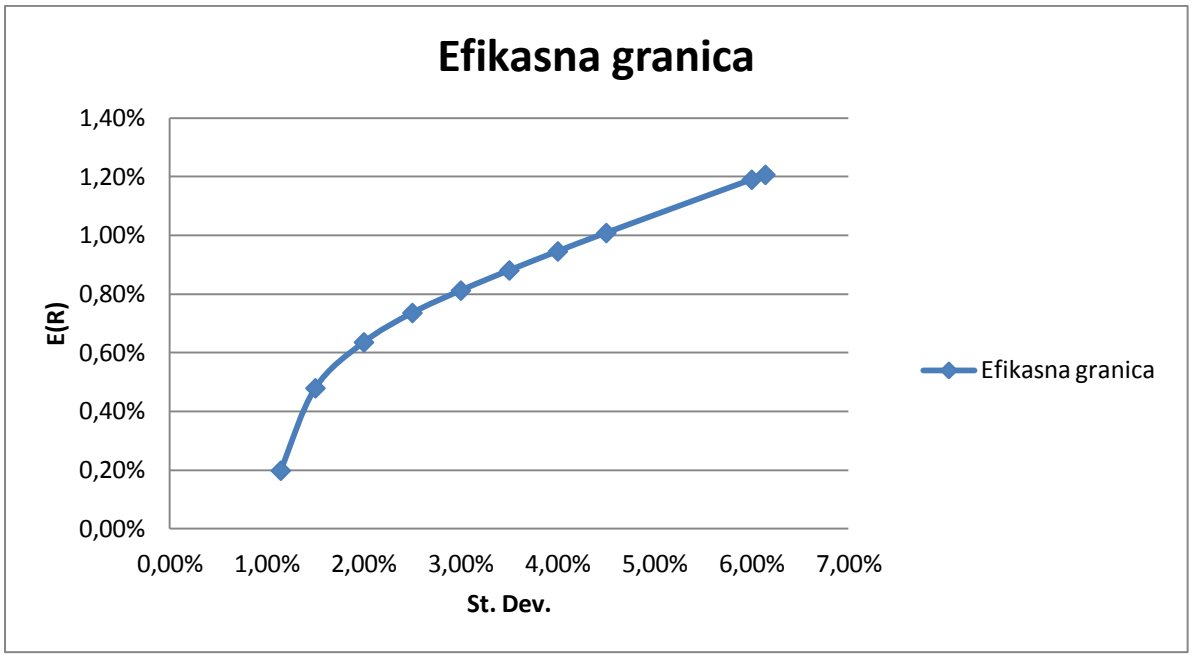
Tablica 12: Portfelji na efikasnoj granici kada kratka prodaja nije dozvoljena na hrvatskom tržištu kapitala

E (R)	σ	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
0,20%	1,14%	0,136558	0,030497	0,149216	0,098093	0,041282	0,040941	0,370469	0,125474	0	0,007470
0,48%	1,50%	0,347376	0	0,103658	0,091092	0,12954	0	0,119546	0	0	0,208789
0,64%	2,00%	0,424446	0	0,015011	0,011859	0,210876	0	0	0	0	0,337808
0,74%	2,50%	0,355477	0	0	0	0,340745	0	0	0	0	0,303778
0,81%	3,00%	0,291516	0	0	0	0,447563	0	0	0	0	0,260922
0,88%	3,50%	0,232622	0	0	0	0,543812	0	0	0	0	0,223566
0,95%	4,00%	0,175717	0	0	0	0,634915	0	0	0	0	0,189368
1,01%	4,50%	0,124962	0	0	0	0,722921	0	0	0	0	0,152117
1,19%	6,00%	0	0	0	0	0,976955	0	0	0	0	0,023045
1,21%	6,14%	0	0	0	0	1	0	0	0	0	0

Izvor: izračun autora

U tablici 12 prikazano je 10 portfelja koji se nalaze na efikasnoj granici, odnosno prikazani su udjeli odabranih dionica pri zadanim različitim razinama rizika mjeren standardnom devijacijom. Razina rizika kreće se od 1,14% do 6,14% kada se sav novac ulaže u jednu dionicu, ATPL (Atlantska plovidba d.d.). Očekivani prinos svakog portfelja raste s razine 0,20% na razinu 1,21% s porastom razine rizika, što nije slučaj sa stupanjem diverzificiranosti portfelja koji se smanjuje. Stoga, na nižim razinama rizika portfelj se sastoji od većeg broja dionica, a kako se rizik povećava, u portfelju se nalazi sve manje dionica, što potvrđuje činjenicu da diversifikacija portfelja dovodi do smanjenja rizika.

Temeljem svih dobivenih rezultata u ovoj analizi, slijedi prikaz efikasne granice.



Grafikon 1: Efikasna granica portfelja na hrvatskom tržištu kapitala

Izvor: izračun autora

Kao što je već spomenuto, efikasna granica je dio skupa minimalne varijance koji prikazuje portfelje koji za zadanu razinu standardne devijacije imaju maksimalan prinos. Također, efikasan portfelj je svaki onaj portfelj koji leži upravo na toj efikasnoj granici.

Grafikon 1 prikazuje efikasnu granicu koja se sastoji od deset efikasnih portfelja. Početna točka je ona pri razini rizika od 1,14 % i očekivanim prinosom od 0,20 % za portfelj koji se sastoji od 13,65% dionica AD Plastika d.d., 3,04% dionica Adris Grupe 2, 14,92% dionica Arena Hospitality Group d.d., 9,81% dionica Atlantic Grupe, 4,13% dionica Atlantske plovidbe, 4,09% dionica Ericsson-a, 37,05% dionica Hrvatskog Telekoma, 12,54% dionica Končara, 0% dionica Podravke i 0,75% dionica Valamar Riviere. Maksimalni očekivani prinos je 1,21% pri razini rizika od 6,14%, što ujedno predstavlja i posljednju točku na ovom grafikonu. Portfelj se pri takvim razinama rizika i očekivanog prinosa sastoji samo od jedne dionice i to dionica poduzeća Atlantska plovidba d.d. Sve to ukazuje na to da prilikom porasta razine rizika dolazi do smanjenja stupnja diversificiranosti portfelja jer se sav novac ulaže u dionice jednog poduzeća. Također, prema grafikonu, može se vidjeti da prilikom porasta rizika na njegovim nižim razinama, dolazi do većeg povećanja očekivanog prinosa i obratno,

prilikom porasta rizika na njegovim višim razinama, dolazi do manjeg povećanja očekivanog prinosa na ulaganje u odabranu dionicu.

Cijela ova analiza vodilja je investitoru kroz njegovo ulaganje u dionice, ali isto tako cijeli mehanizam ulaganja zapravo ovisi o averziji investitora prema riziku i njegovoj funkciji korisnosti. Zbog te različitosti između investitora, odabrani efikasni portfelji mogu se razlikovati od investitora do investitora.

U svrhu objašnjenja i donošenja zaključka vezano za dodatnu hipotezu ovo rada, u posljednjem koraku ove analize proveden je Kolmogorov – Smirnov test za normalnu distribuciju uz pomoć programa IBM SPSS Statistics 23. Testiranje hipoteze da distribucija ima određeni oblik može se izvršiti pomoću Hi- kvadrat testa, ali i pomoću Kolmogorov – Smirnov testa (KS test). Uzevši u obzir KS test, može se izvršiti testiranje jednolike, biomne, Poissonove i normalne distribucije. U ovom radu postavljena je hipoteza za testiranje normalne distribucije prinosa na tržištu kapitala. Ovaj test se temelji na najvećoj apsolutnoj razlici (ili diferenciji) D između empirijskih (iz uzorka) kumulativnih frekvencija i očekivanih kumulativnih frekvencija. Kao rezultat testiranja dobije se empirijska signifikantnost. Ako je ona veća od 5%, prihvaća se pretpostavka da zadana empirijska frekvencijska distribucija ima u ovom slučaju normalni oblik.[45]

Tablica 13: Kolmogorov – Smirnov test za normalnu distribuciju za hrvatsko tržište kapitala

One-Sample Kolmogorov-Smirnov Test

		ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
N		108	108	108	108	108	108	108	108	108	108
Normal Parameters[a,b]	Mean	,004987	,000831	,002463	,001656	,012061	,000292	,000620	-,000292	-,000550	,004842
	Std. Deviation	,0235892	,0232861	,0300515	,0287651	,0616908	,0249645	,0176514	,0227754	,0261789	,0262190
Most Extreme Differences	Absolute	,058	,047	,109	,135	,075	,100	,073	,105	,125	,113
	Positive	,058	,047	,109	,135	,075	,073	,062	,105	,125	,113
	Negative	-,041	-,047	-,078	-,125	-,045	-,100	-,073	-,049	-,096	-,100
Test Statistic		,058	,047	,109	,135	,075	,100	,073	,105	,125	,113
Asymp. Sig. (2-tailed)		,200[c,d]	,200[c,d]	,003[c]	,000[c]	,174[c]	,010[c]	,200[c,d]	,005[c]	,000[c]	,002[c]

Izvor: izračun autora

Tablica 13 prikazuje rezultate Kolmogorov – Smirnov testa za normalnu distribuciju za odabrane dionice hrvatskog tržišta kapitala. Na temelju dobivenih rezultata može se zaključiti da su empirijske signifikantnosti dionica ADPL, ADRS2, ATPL i HT veće od 5% pa se za te

[45] Pivac, S.(2010.): Statističke metode (predavanja, diplomski studij, kolegij ″Statističke metode¨), e-nastavni materijal, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 166.-167.

dionice može reći kako njihovi prinosi imaju normalan oblik. S druge strane, prinosi dionica ARNT, ATGR, ERNT, KOEI, PODR i RIVP nemaju normalan oblik distribucije. Stoga, može se donijeti zaključak, kako se na primjeru hrvatskog tržišta kapitala djelomično prihvaća pomoćna hipoteza ovog rada koja govori o normalnosti distribucije prinosa. Zbog ovako dobivenih rezultata, može se podcijeniti rizik pa se svi rezultati u obzir uzimaju s rezervom.

5. PRIMJENA MV MODELA NA NJEMAČKOM TRŽIŠTU KAPITALA

5.1. Kriterij odabira dionica za analizu i formiranje početnog uzorka

U ovom poglavlju prezentirana je analiza njemačkog tržišta kapitala na isti način kao što je to učinjeno za Hrvatsku. Za analizu primjenom MV modela, uzete su u obzir dionice u sastavu DAX-a. Kriteriji za odabir podudaraju se s korištenim kriterijima prilikom odabira dionica na hrvatskom tržištu kapitala. Kao dodatan kriterij, odabrane dionice su jedne od najaktivnijih dionica u sastavu indeksa DAX.

Name ▾ WKN / ISIN	stock exchange	bid	ask	Volume	Last Price	+/-%	DatumZeit
Bayer BAY001 / DE000BAY0017	Frankfurt	92.42	92.88	177,312	92.66	0,66 0,72	23.07.2018 06:00:31
Deutsche Lufthansa AG (spons. ADRs) 910979 / US2515613048	Frankfurt	20.80	21.00	3,244	20.80	-0,60 -2,80	23.07.2018 10:04:51
BASF BASF11 / DE000BASF111	Frankfurt	82.30	82.50	407,341	82.50	-0,33 -0,40	23.07.2018 06:33:20
adidas AG A1EWWW / DE000A1EWWW0	Frankfurt	189.70	189.85	265,779	189.40	-0,15 -0,08	23.07.2018 05:51:43
Daimler AG 710000 / DE0007100000	Frankfurt	57.61	57.75	294,039	57.60	0,37 0,65	23.07.2018 07:43:44
SAP SE 716460 / DE0007164600	Frankfurt	99.65	99.74	570,093	99.71	0,01 0,01	23.07.2018 07:42:08
Siemens AG 723610 / DE0007236101	Frankfurt	116.94	117.22	151,840	116.86	-0,08 -0,07	23.07.2018 06:38:11
Allianz 840400 / DE0008404005	Frankfurt	183.02	183.38	430,351	182.86	1,80 0,99	23.07.2018 07:28:58
Deutsche Telekom AG 555750 / DE0005557508	Frankfurt	13.66	13.72	603,021	13.71	-0,10 -0,69	23.07.2018 07:57:50
Volkswagen (VW) St. 766400 / DE0007664005	Frankfurt	142.80	144.70	17,402	144.70	3,10 2,19	23.07.2018 05:52:39

Slika 9: Odabrane dionice njemačkog tržišta kapitala

Izvor: http://en.boerse-frankfurt.de/ (23.07.2018.)

Slika 9 prikazuje dionice koje su uzete u obzir prilikom analize prinosa i rizika na njemačkom tržištu kapitala. Odabrane dionice su predstavnice različitih sektora i djelatnosti. Bayer je njemački biotehnološki i farmaceutski gigant, zapošljava oko 115.000 ljudi i ostvaruje godišnju dobit od 4,5 milijarde eura. Deutsche Lufthansa je njemačka nacionalna zrakoplovna kompanija i ujedno i najveći europski putnički zračni prijevoznik. Njemačka tvrtka BASF trenutno je najveća svjetska kemijska kompanija po prihodima i tržišnoj kapitalizaciji. Na

početku se bavila proizvodnjom katranskih bojila, ali je ubrzo započela proizvodnju tekstilnih bojila na bazi indiga. Sljedeća tvrtka čija je dionica uzeta u obzir za analizu je Adidas AG. Adidas AG je njemačka tvornica za proizvodnju sportske opreme. Trenutno je najjača tvornica sportske opreme u Europi, a druga u svijetu. Daimler je njemački automobilski proizvođač nastao udruživanjem Daimler - Benza i Chryslera 2008. godine. Nadalje, SAP AG je jedna od najvećih svjetskih proizvođača softwarea i najveća u Europi opreme. Siemens AG je svjetska konglomeracija najpoznatija po kućanskim aparatima i telekomunikacijskim uređajima, te u novije vrijeme i po lokomotivama o motornim vlakovima. S područja financija tu je najveća njemačka financijska tvrtka Allianz. Osnovna djelatnost Allianza su osiguranje i upravljanje imovinom. Deutsche Telekom je njemački pružatelj telefonskih i telekomunikacijskih usluga te dio međunarodne mreže T-Mobile. Na kraju, Volkswagen je njemački proizvođač automobila koji je na svjetskoj razini treći proizvođač automobila. [46]

U nastavku slijedi analiza njemačkog tržišta kapitala primjenom Markowitzev-og modela, također koristeći tjedne zaključne cijene u razdoblju od 03. lipnja 2016. godine, do 29. lipnja 2018. godine, kao i kod analize hrvatskog tržišta kapitala.

Tablica 14: Tjedne zaključne cijene odabranih dionica na njemačkom tržištu kapitala

Datum	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswagen
3.6.2016.	142,84	116,70	68,50	87,87	59,37	12,50	15,17	71,48	95,40	131,00
10.6.2016.	134,73	118,41	67,60	86,50	57,18	11,45	14,25	69,34	92,95	125,60
17.6.2016.	130,64	117,60	67,50	87,18	56,18	11,32	13,81	67,90	92,27	119,80
24.6.2016.	126,75	119,80	66,70	86,48	55,04	11,00	13,53	67,14	90,00	115,35
1.7.2016.	127,34	127,89	69,30	89,16	54,88	10,61	14,70	67,60	91,79	114,00
8.7.2016.	122,87	125,98	67,20	89,26	54,00	10,77	14,33	69,15	89,33	109,69
15.7.2016.	127,75	131,57	71,70	92,36	58,30	11,19	14,91	71,17	94,09	116,00
22.7.2016.	125,53	137,34	71,51	90,64	59,32	10,40	14,80	76,97	94,79	120,67
29.7.2016.	128,50	146,86	69,83	94,72	60,73	10,57	14,66	78,10	96,80	125,60
5.8.2016.	126,25	146,80	69,40	94,18	61,00	10,40	14,96	77,58	102,07	123,15
12.8.2016.	134,33	155,15	72,68	96,20	62,63	10,90	15,11	78,40	107,20	124,80
19.8.2016.	129,66	156,51	71,96	94,87	61,32	10,30	14,66	77,95	106,55	119,30
26.8.2016.	128,52	152,58	71,98	94,33	61,26	10,28	14,45	77,51	107,15	122,95
2.9.2016.	135,25	144,76	72,98	93,31	62,73	10,49	14,53	80,29	108,16	124,40
9.9.2016.	136,23	144,75	72,27	93,54	63,10	11,01	14,28	78,71	104,50	124,19
16.9.2016.	129,98	149,36	70,62	89,26	60,57	10,32	14,00	77,89	104,01	118,58

[46] Dostupno na: https://hr.wikipedia.org/wiki/DAX (24.07.2018.)

23.9.2016.	136,01	154,62	73,47	89,97	63,48	10,29	14,69	81,51	105,90	119,10
30.9.2016.	132,22	154,80	75,80	87,92	62,62	10,00	14,44	81,33	104,40	116,84
7.10.2016.	135,78	155,05	78,05	88,48	63,97	9,24	13,90	80,10	104,69	118,05
14.10.2016.	137,98	156,98	78,85	88,97	64,26	10,28	13,89	79,06	105,20	120,50
21.10.2016.	139,78	156,90	79,52	88,74	64,72	11,17	14,03	81,61	106,47	123,30
28.10.2016.	141,44	149,25	80,20	89,13	65,10	11,59	14,35	80,43	103,36	125,35
…										
2.2.2018.	200,00	179,90	90,65	100,77	71,35	27,60	13,85	87,89	115,02	172,56
9.2.2018.	182,92	174,80	84,20	93,37	69,51	25,60	12,87	81,78	105,30	160,90
16.2.2018.	190,98	180,80	87,14	97,44	72,50	26,60	13,18	84,80	111,40	167,60
23.2.2018.	191,70	181,90	88,13	96,71	71,33	27,40	13,42	84,85	110,96	163,50
2.3.2018.	184,44	173,75	83,32	91,97	67,86	26,40	12,95	82,70	103,70	154,90
9.3.2018.	189,92	174,01	85,13	96,36	67,86	26,00	13,26	88,65	105,92	157,20
16.3.2018.	190,00	195,25	84,89	94,62	69,30	27,40	13,48	87,74	107,44	163,46
23.3.2018.	180,04	195,15	80,79	88,78	65,74	25,40	12,97	83,54	101,38	153,32
30.3.2018.	184,58	196,50	82,11	90,78	69,07	25,80	13,31	85,09	103,80	161,70
6.4.2018	186,34	203,40	83,99	92,12	65,53	26,40	13,47	86,50	104,18	165,02
13.4.2018.	189,00	210,90	84,01	97,33	65,56	26,20	13,96	87,89	104,94	177,38
20.4.2018.	193,26	212,20	86,69	97,19	65,04	26,80	14,11	86,48	108,18	171,46
27.4.2018.	195,00	205,80	86,25	97,23	65,56	24,20	14,53	92,00	105,78	172,74
4.5.2018.	199,24	193,00	86,65	100,00	66,33	24,60	14,47	95,20	109,08	172,90
11.5.2018.	191,44	189,25	86,63	100,42	66,97	24,00	14,26	97,21	115,44	171,94
18.5.2018.	191,22	195,55	88,77	103,03	67,37	24,20	13,47	95,97	117,28	173,00
25.5.2018.	187,02	194,20	87,57	101,36	64,85	24,20	13,35	97,65	115,24	170,06
1.6.2018.	179,86	193,70	85,13	101,62	61,91	23,20	13,23	97,00	113,30	162,22
8.6.2016.	178,68	199,50	85,92	98,27	61,89	22,60	13,31	100,82	113,92	159,74
15.6.2018.	180,54	200,10	87,64	100,18	62,22	22,80	13,57	103,62	119,40	161,74
22.6.2018.	176,00	191,00	83,44	99,25	57,73	22,60	13,57	101,12	116,36	149,80
29.6.2018.	177,16	187,00	81,91	94,80	55,33	20,80	13,30	98,98	113,20	141,88

Izvor: izračun autora

Na temelju tjednih zaključnih cijena prikazanih u tablici 14, izračunati su tjedni prinosa odabranih dionica.

Tablica 15: Tjedni prinosi odabranih dionica njemačkog tržišta kapitala

Datum	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
10.6.2016.	-5,85%	1,45%	-1,32%	-1,57%	-3,76%	-8,77%	-6,26%	-3,04%	-2,60%	-4,21%
17.6.2016.	-3,08%	-0,69%	-0,15%	0,78%	-1,76%	-1,14%	-3,14%	-2,10%	-0,73%	-4,73%
24.6.2016.	-3,02%	1,85%	-1,19%	-0,81%	-2,05%	-2,87%	-2,05%	-1,13%	-2,49%	-3,79%
1.7.2016.	0,46%	6,53%	3,82%	3,05%	-0,29%	-3,61%	8,29%	0,68%	1,97%	-1,18%
8.7.2016.	-3,57%	-1,50%	-3,08%	0,11%	-1,62%	1,50%	-2,55%	2,27%	-2,72%	-3,85%

15.7.2016.	3,89%	4,34%	6,48%	3,41%	7,66%	3,83%	3,97%	2,88%	5,19%	5,59%
22.7.2016.	-1,75%	4,29%	-0,27%	-1,88%	1,73%	-7,32%	-0,74%	7,83%	0,74%	3,95%
29.7.2016.	2,34%	6,70%	-2,38%	4,40%	2,35%	1,62%	-0,95%	1,46%	2,10%	4,00%
5.8.2016.	-1,77%	-0,04%	-0,62%	-0,57%	0,44%	-1,62%	2,03%	-0,67%	5,30%	-1,97%
12.8.2016.	6,20%	5,53%	4,62%	2,12%	2,64%	4,70%	1,00%	1,05%	4,90%	1,33%
19.8.2016.	-3,54%	0,87%	-1,00%	-1,39%	-2,11%	-5,66%	-3,02%	-0,58%	-0,61%	-4,51%
26.8.2016.	-0,88%	-2,54%	0,03%	-0,57%	-0,10%	-0,19%	-1,44%	-0,57%	0,56%	3,01%
2.9.2016.	5,10%	-5,26%	1,38%	-1,09%	2,37%	2,02%	0,55%	3,52%	0,94%	1,17%
9.9.2016.	0,72%	-0,01%	-0,98%	0,25%	0,59%	4,84%	-1,74%	-1,99%	-3,44%	-0,17%
16.9.2016.	-4,70%	3,14%	-2,31%	-4,68%	-4,09%	-6,47%	-1,98%	-1,05%	-0,47%	-4,62%
23.9.2016.	4,53%	3,46%	3,96%	0,79%	4,69%	-0,29%	4,81%	4,54%	1,80%	0,44%
30.9.2016.	-2,83%	0,12%	3,12%	-2,30%	-1,36%	-2,86%	-1,72%	-0,22%	-1,43%	-1,92%
7.10.2016.	2,66%	0,16%	2,93%	0,63%	2,13%	-7,90%	-3,81%	-1,52%	0,28%	1,03%
14.10.2016.	1,61%	1,24%	1,02%	0,55%	0,45%	10,67%	-0,07%	-1,31%	0,49%	2,05%
21.10.2016.	1,30%	-0,05%	0,85%	-0,26%	0,71%	8,30%	1,00%	3,17%	1,20%	2,30%
28.10.2016.	1,18%	-5,00%	0,85%	0,44%	0,59%	3,69%	2,26%	-1,46%	-2,96%	1,65%
…										
2.2.2018.	-2,03%	-2,71%	-5,26%	-4,40%	-4,68%	-3,56%	-5,55%	-4,46%	-5,73%	-5,10%
9.2.2018.	-8,93%	-2,88%	-7,38%	-7,63%	-2,61%	-7,52%	-7,34%	-7,21%	-8,83%	-7,00%
16.2.2018.	4,31%	3,37%	3,43%	4,27%	4,21%	3,83%	2,38%	3,63%	5,63%	4,08%
23.2.2018.	0,38%	0,61%	1,13%	-0,75%	-1,63%	2,96%	1,80%	0,06%	-0,40%	-2,48%
2.3.2018.	-3,86%	-4,58%	-5,61%	-5,03%	-4,99%	-3,72%	-3,57%	-2,57%	-6,77%	-5,40%
9.3.2018.	2,93%	0,15%	2,15%	4,66%	0,00%	-1,53%	2,37%	6,95%	2,12%	1,47%
16.3.2018.	0,04%	11,52%	-0,28%	-1,82%	2,10%	5,24%	1,65%	-1,03%	1,42%	3,90%
23.3.2018.	-5,38%	-0,05%	-4,95%	-6,37%	-5,27%	-7,58%	-3,86%	-4,91%	-5,81%	-6,40%
30.3.2018.	2,49%	0,69%	1,62%	2,23%	4,94%	1,56%	2,59%	1,84%	2,36%	5,32%
6.4.2018	0,95%	3,45%	2,26%	1,47%	-5,26%	2,30%	1,19%	1,64%	0,37%	2,03%
13.4.2018.	1,42%	3,62%	0,02%	5,50%	0,05%	-0,76%	3,57%	1,59%	0,73%	7,22%
20.4.2018.	2,23%	0,61%	3,14%	-0,14%	-0,80%	2,26%	1,07%	-1,62%	3,04%	-3,39%
27.4.2018.	0,90%	-3,06%	-0,51%	0,04%	0,80%	-10,20%	2,93%	6,19%	-2,24%	0,74%
4.5.2018.	2,15%	-6,42%	0,46%	2,81%	1,17%	1,64%	-0,41%	3,42%	3,07%	0,09%
11.5.2018.	-3,99%	-1,96%	-0,02%	0,42%	0,96%	-2,47%	-1,46%	2,09%	5,67%	-0,56%
18.5.2018.	-0,11%	3,27%	2,44%	2,57%	0,60%	0,83%	-5,70%	-1,28%	1,58%	0,61%
25.5.2018.	-2,22%	-0,69%	-1,36%	-1,63%	-3,81%	0,00%	-0,89%	1,74%	-1,75%	-1,71%
1.6.2018.	-3,90%	-0,26%	-2,83%	0,26%	-4,64%	-4,22%	-0,90%	-0,67%	-1,70%	-4,72%
8.6.2016.	-0,66%	2,95%	0,92%	-3,35%	-0,03%	-2,62%	0,60%	3,86%	0,55%	-1,54%
15.6.2018.	1,04%	0,30%	1,98%	1,92%	0,53%	0,88%	1,93%	2,74%	4,70%	1,24%
22.6.2018.	-2,55%	-4,65%	-4,91%	-0,93%	-7,49%	-0,88%	0,00%	-2,44%	-2,58%	-7,67%
29.6.2018.	0,66%	-2,12%	-1,85%	-4,59%	-4,25%	-8,30%	-2,01%	-2,14%	-2,75%	-5,43%

Izvor: izračun autora

U nastavku slijedi prikaz izračuna očekivanog tjednog prinosa i rizika odabranih dionica.

Tablica 16: Očekivani tjedni prinos i rizik na njemačkom tržištu kapitala

	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
E (R)	0,20%	0,44%	0,17%	0,07%	-0,07%	0,47%	-0,12%	0,30%	0,16%	0,07%
σ^2	0,000717	0,001204	0,00062	0,000854	0,000749	0,001761	0,000625	0,000615	0,000771	0,001266
σ	2,68%	3,47%	2,49%	2,92%	2,74%	4,20%	2,50%	2,48%	2,78%	3,56%

Izvor: izračun autora

Tablica 16 prikazuje očekivani tjedni prinos i rizik odabranih dionica na njemačkom tržištu kapitala. Prema rezultatima dobivenim u Excelu, dionica s najvećim očekivanim prinosom je dionica kompanije Deutsche Lufthansa (0,47%), odmah iza nje je dionica kompanije Adidas (0,44%). S druge strane, najmanji očekivani prinos ima dionica kompanije Deutsche Telekom (-0,12%).

Gledajući rizik, dionica kompanije Deutsche Lufthansa ima najveći rizik mjeren standardnom devijacijom (4,20%), a najmanji rizik ima dionica kompanije SAP (2,48%).

Kao i kod analize na hrvatskom tržištu kapitala i ovdje je izvršen prikaz efikasne granice. Prije prikaza udjela dionica u portfelju i same efikasne granice, potrebno je izračunati matricu varijanci i kovarijanci.

Tablica 17: Matrica varijanci i kovarijanci na njemačkom tržištu kapitala

	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
Allianz	0,000717	0,000271	0,000468	0,000461	0,000484	0,000582	0,000346	0,000315	0,000477	0,000537
Adidas	0,000271	0,001204	0,000282	0,000176	0,000280	0,000211	0,000206	0,000237	0,000295	0,000335
BASF	0,000468	0,000282	0,000620	0,000423	0,000471	0,000352	0,000322	0,000324	0,000511	0,000502
Bayer	0,000461	0,000176	0,000423	0,000854	0,000459	0,000390	0,000365	0,000353	0,000522	0,000501
Daimler	0,000484	0,000280	0,000471	0,000459	0,000749	0,000466	0,000328	0,000347	0,000503	0,000678
Deutsche Lufthansa	0,000582	0,000211	0,000352	0,000390	0,000466	0,001761	0,000333	0,000187	0,000428	0,000575
Deutsche Telekom	0,000346	0,000206	0,000322	0,000365	0,000328	0,000333	0,000625	0,000353	0,000367	0,000386
SAP	0,000315	0,000237	0,000324	0,000353	0,000347	0,000187	0,000353	0,000615	0,000377	0,000461
Siemens	0,000477	0,000295	0,000511	0,000522	0,000503	0,000428	0,000367	0,000377	0,000771	0,000539
Volkswagen	0,000537	0,000335	0,000502	0,000501	0,000678	0,000575	0,000386	0,000461	0,000539	0,001266

Izvor: izračun autora

Slijedi prikaz portfelja na efikasnoj granici također u istoj situaciji kao i na hrvatskom tržištu kapitala, odnosno kada kratka prodaja nije dozvoljena.

Tablica 18: Portfelji na efikasnoj granici kada kratka prodaja nije dozvoljena na njemačkom tržištu kapitala

E (R)	σ	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
0,184%	1,96%	0,028458	0,156114	0,169687	0,072433	0,030813	0,062675	0,225928	0,253892	0	0
0,395%	2,25%	0	0,349886	0	0	0	0,270372	0	0,379742	0	0
0,423%	2,50%	0	0,449805	0	0	0	0,356097	0	0,194097	0	0
0,443%	2,75%	0	0,522248	0	0	0	0,419349	0	0,058403	0	0
0,457%	3,00%	0	0,428017	0	0	0	0,571983	0	0	0	0
0,461%	3,25%	0	0,302228	0	0	0	0,697772	0	0	0	0
0,464%	3,50%	0	0,208497	0	0	0	0,791503	0	0	0	0
0,467%	3,75%	0	0,127749	0	0	0	0,872251	0	0	0	0
0,470%	4,00%	0	0,054211	0	0	0	0,945789	0	0	0	0
0,472%	4,20%	0	0	0	0	0	1	0	0	0	0

Izvor: izračun autora

Tablicom 18 prikazani su portfelji na efikasnoj granici i to u slučaju kada kratka prodaja nije dozvoljena. Raspon rasta rizika mjerenog standardnom devijacijom je od 1,96% do 4,20%. Očekivani prinos raste s razine od 0,184% do 0,472% kako raste i razina rizika. Pri očekivanom prinosu od 0,472% i riziku od 4,20% portfelj se sastoji od samo jedne dionice (Deutsche Lufthansa). Ovdje, kao i u slučaju Hrvatske, na nižim razinama rasta rizika,

očekivani prinos raste više, a na višim razinama rizika, prinos raste sporije i u malim stopama. Također, učinak diversifikacije smanjuje rizik portfelja, što se može vidjeti prema rezultatima, jer kako u portfelju ostaje sve manje dionica, sve je veća razina rizika.

Također, dobiveni rezultati u tablici 18 upućuju na malu razinu diversifikacije portfelja na njemačkom tržištu kapitala i to već na prvim razinama zadanog rizika. Primjerice, pri razini rizika od 1,96% od deset odabranih dionica, već dvije dionice nisu dio efikasnih portfelja. Povećanjem razine rizika sve je manje dionica koje tvore efikasni portfelj, te jedine koje su do samog kraja su dionice kompanije Adidas i Deutsche Lufthansa. Te dvije dionice imaju i veliku razinu rizika mjerenog standardnom devijacijom, čiji su rezultati prikazani u tablici 16. Razlog tome također može biti i sama situacija na tržištu, odnosno poslovanje ove dvije kompanije. Tako su, primjerice, dionice Adidas-a pale za 15% u zadnjih šest mjeseci. Uz to, ova kompanija susrela se sa višegodišnjim lošim poslovanjem koje se može prepisati snažnoj konkurenciji u SAD-u i lošoj prodaji marke Reebok koja je zapravo dio Adidas Grupe. Dobra vijest je da su pozitivni rezultati poslovanja počeli kada izvršena zamjena na funkciji izvršnog direktora Adidas Grupe.

Deutsche Lufthansa u proteklim godinama potresali su štrajkovi zaposlenika, koji su se značajno utjecali na samo poslovanje ove kompanije. Zbog takvih štrajkova kompanija je bila prisiljena otkazati na stotine nacionalnih i međunarodnih letova koji su zahvatili oko 90.000 putnika. Svaka promjena na tržištu i u poslovanju određene kompanije ima odraz na kretanje cijena dionica na burzama. Također, sukladno tablici 15 koja prikazuje tjedne prinose dionica, može se vidjeti kako upravo dionice Deutsche Lufthansa kroz promatrano razdoblje ima stalne i često velike oscilacije u tjednim prinosima. Prema svemu navedenom, može se zaključiti kako su dionice ove dvije kompanije s razlogom imale veće razine rizika u odnosu na ostale.

U sljedećem koraku, prikazana je efikasna granica portfelja na njemačkom tržištu kapitala.



Grafikon 2: Efikasna granica portfelja na njemačkom tržištu kapitala

Izvor: izračun autora

Na grafikonu 2 mogu se uočiti različiti portfelji na efikasnoj granici. Početna točka na efikasnoj granici je portfelj pri razini rizika od 1,96% i 0,184% prinosa. Takav portfelj ima sastav dionica na sljedeći način: 2,85% dionica Allianz-a, 15,61% Adidas, 16,97% BASF, 7,24% Bayer, 3,08% Daimler, 6,27% Deutsche Lufthansa, 22,59% Deutsche Telekom, 25,39% SAP, te dionice kompanija Siemens i Volkswagen 0%. Kao završna točka na efikasnoj granici je onaj portfelj koji se nalazi od samo jedne dionice i to dionice kompanije Deutsche Lufthansa pri razini prinosa od 0,472% i rizika od 4,20%.

Također i za Njemačku je proveden Kolmogorov – Smirnov test kako bi se mogla upotpuniti cijela analiza i kako bi se mogao donijeti zaključak u odnosu na postavljene hipoteze rada.

Tablica 19: Kolmogorov – Smirnov test za normalnu distribuciju na njemačkom tržištu kapitala

One-Sample Kolmogorov-Smirnov Test

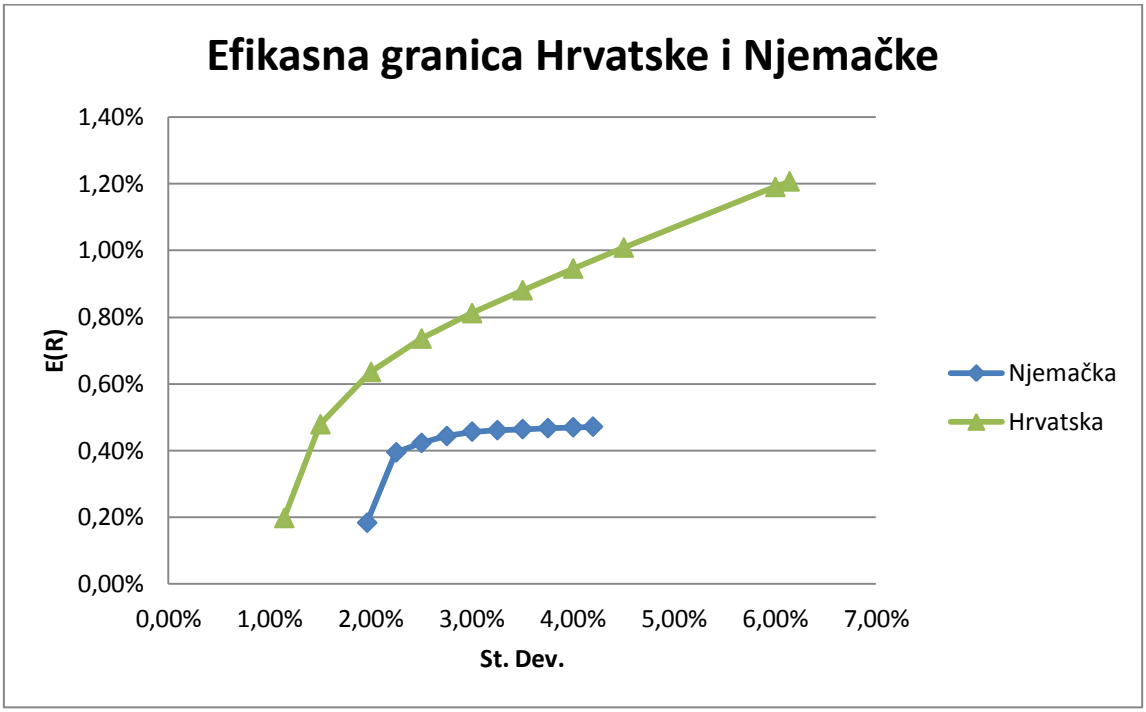
		Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswagen
N		108	108	108	108	108	108	108	108	108	108
Normal Parameters[a,b]	Mean	,001994	,004361	,001652	,000702	-,000652	,004719	-,001221	,003009	,001588	,000731
	Std. Deviation	,0268955	,0348631	,0250121	,0293643	,0275015	,0421499	,0251195	,0249209	,0279009	,0357354
Most Extreme Differences	Absolute	,076	,068	,038	,070	,074	,100	,073	,077	,065	,049
	Positive	,069	,065	,028	,070	,061	,070	,048	,077	,065	,044
	Negative	-,076	-,068	-,038	-,062	-,074	-,100	-,073	-,057	-,058	-,049
Test Statistic		,076	,068	,038	,070	,074	,100	,073	,077	,065	,049
Asymp. Sig. (2-tailed)		,157[c]	,200[c,d]	,200[c,d]	,200[c,d]	,180[c]	,010[c]	,196[c]	,122[c]	,200[c,d]	,200[c,d]

Izvor: izračun autora

Prema dobivenim rezultatima Kolmogorov – Smirnov testa u tablici 19, može se vidjeti kako sve odabrane dionice osim jedne (Deutsche Lufthansa) imaju empirijsku signifikantnost veću od 5%, što znači da prinosi za sve te dionice imaju normalan oblik distribucije. Ovakvi rezultati su očekivani za njemačko tržište kapitala, koje je razvijeno i stabilno u odnosu na hrvatsko tržište kapitala.

5.2. Usporedba efikasnih granica hrvatskog i njemačkog tržišta kapitala

Nakon analize hrvatskog i njemačkog tržišta kapitala, izračuna portfelja na efikasnoj granici i prikaza same efikasne granice za svaku zemlju pojedinačno, predstavljena je glavna usporedba dviju efikasnih granica na jednom grafikonu.



Grafikon 3: Usporedba efikasne granice hrvatskog i njemačkog tržišta kapitala

Izvor: izračun autora

Prema grafikonu 3 može se vidjeti kako hrvatsko tržište kapitala ostvaruje veće prinose u odnosu na njemačko tržište kapitala, uz veći rizik mjeren standardnom devijacijom. Pri razini rizika od 2,50% hrvatsko tržište kapitala ostvaruje prinos od 0,74% , a njemačko tržište kapitala prinos od 0,42%. Zatim pri razini rizika od 3,50% ostvareni prinos na hrvatskom tržištu kapitala je 0,88%, a na njemačkom tržištu kapitala pri razini rizika od 3,25%, ostvaruje se prinos od 0,46%. Također, može se uočiti kako se na hrvatskom tržištu kapitala razina rizika kreće od 1,14% do 6,14%, a s druge strane na njemačkom tržištu kapitala od 1,96% do 4,20%. Sve to skupa, još jednom potvrđuje kako na hrvatskom tržištu kapitala investitori mogu ostvariti veće prinose, ali uz prihvaćanje veće razine rizika u odnosu na njemačko tržište kapitala. Kao zaključak ove analize prihvaća se postavljena hipoteza na početku ovog rada.

6. ZAKLJUČAK

Prilikom ulaganja u vrijednosne papire bitne postavke su razina prinosa i rizika. Markowitzev model optimizacije dioničkog portfelja polazi od pretpostavke maksimizacije prinosa uz zadanu razinu rizika, odnosno minimiziranje rizika uz zadanu razinu prinosa. Takvi portfelji se nalaze na samoj efikasnoj granici i nazivaju se efikasni portfelji i kao takvi, jedini portfelji koji će zanimati investitora prilikom ulaganja sredstava.

Upravo taj odnos prinosa i rizika bio je crta vodilja ovog rada. U središte ovog rada postavila se usporedba odnosa rizika i prinosa između dvije zemlje, Hrvatske i Njemačke. Hrvatska kao jedna od zemalja s tržištem kapitala u nastajanju, te s druge strane, Njemačka, s razvijenim tržištem kapitala. Na samom početku, kada su se analizirala ta dva tržišta kapitala pojedinačno, mogle su se vidjeti te razlike u razvijenosti, po različitim pokazateljima i kriterijima. Tako, počevši od općenitih pokazatelja razvijenosti neke zemlje (BDP, stopa nezaposlenosti, BDP – per capita), do pokazatelja koji se vežu za samo tržište kapitala (tržišna kapitalizacija nacionalnih burzi, vrijednosti glavnih indeksa, promet na burzama vrijednosnih papira i dr.), mogla se uočiti prednost Njemačke nad Hrvatskom.

Cilj ovog rada bio je odrediti koliko je zapravo hrvatsko tržište kapitala blizu ili daleko u odnosu na njemačko tržište kapitala usporedbom odnosa prinosa i rizika primjenom Markowitzeva modela.

Za analizu su odabrane dionice koje su sastavni dio glavnih indeksa nacionalnih burzi Hrvatske i Njemačke. S jedne strane su to dionice CROBEX-a, a s druge strane dionice DAX-a. Podaci koji su se koristili u analizi su tjedne zaključne cijene odabranih dionica u razdoblju od dvije godine, odnosno od 3. lipnja 2016. do 29. lipnja 2018. godine.

Nakon provedene analize, prihvaća se glavna hipoteza ovog rada, što znači da je moguće ostvariti veći prinos uz veći rizik na hrvatskom tržištu kapitala u odnosu na njemačko razvijeno tržište kapitala. Ovakav rasplet se mogao očekivati s obzirom na navedene karakteristike tržišta u nastajanju na početku ovog rada. Također, dobivenim rezultatima potvrdilo se to nepisano pravilo kako tržišta kapitala u nastajanju nude prednosti diversifikacije, jer prema se rezultatima Hrvatske u odnosu na Njemačku to može potvrditi.

Ulagačeva odluka će ovisiti prvenstveno o njegovoj averziji prema riziku te o njegovoj funkciji korisnosti. Oni ulagači koji vole riskirati i oni koji podržavaju ulaganje u uvjetima

oscilacije, izabrat će hrvatsko tržište kapitala, gdje uz prihvaćanje veće razine rizika mogu ostvariti veće prinose nego što bi ostvarili na njemačkom tržištu kapitala. Investitori na ovakvim tržištima moraju biti svakako oprezni zbog nepredvidivih situacija u zemlji.

S druge strane nalazi se njemačko tržište kapitala, koje je dosta zrelije, likvidnije, razvijenije i stabilnije tržište kapitala posebice prilikom utjecaja svjetskih događaja na samo tržište. Prema dobivenim rezultatima pruža manji prinos investitoru, ali uz manji rizik. Time pruža investitoru manje riskantnije ulaganje i predvidljivije u odnosu na Hrvatsku.

Burne godine u bliskoj prošlosti donijele su riskantne događaje kako u svijetu tako i u Njemačkoj. Poznato je da političko stanje u državi utječe i na financije iste države. Događaji poput Brexit-a, američki izbori odnosno pobjeda Donalda Trumpa, teroristički napadi u svijetu ali posebno onaj u Bruxellesu, neizvjesnost o dugo najavljivanoj fuziji burzi u Frankfurtu i Londonu i sl. nisu bitno utjecali na vrijednost neke dionice. To još jednom potvrđuje stabilnost ovog tržišta kapitala.

Uz glavnu hipotezu, predstavljena je i pomoćna, ona koja govori kako su prinosi ova dva tržišta kapitala normalno distribuirani. Prema dobivenim rezultatima Kolmogorov – Smirnov testa može se vidjeti kako na hrvatskom tržištu kapitala postoje dionice čiji prinosi imaju normalan oblik distribucije, ali i dionice čiji prinosi nemaju normalan oblik. To još jednom potvrđuje pretpostavke s početka priče, kada se govorilo o karakteristikama tržišta kapitala u nastajanju. Jedna od karakteristika takvih tržišta kapitala bila je i ta kako prinosi nemaju normalan oblik. S druge strane, prema rezultatima istoimenog testa, na njemačkom tržištu kapitala većina, odnosno svi prinosi odabranih dionica osim jedne, imaju normalan oblik distribucije. Stoga, pomoćna hipoteza ovog rada se djelomično prihvaća upravo zbog rezultata na hrvatskom tržištu kapitala. Zbog takvog raspleta, rizik vezan uz dionice hrvatskog tržišta kapitala može biti podcijenjen pa bi rezultate vezane za hrvatsko tržište kapitala trebalo uzimati u obzir s rezervom.

Zaključno, može se reći kako u Hrvatskoj s tržištem kapitala u nastajanju, ulagači mogu ostvariti veći prinos uz veću razinu rizika u odnosu na Njemačku razvijenim tržištem kapitala gdje je ulaganje sigurnije. Također, konačna odluka o ulaganju ovisi o percepciji investitora o riziku. Prvi korak koji bi Hrvatska mogla napraviti, jest početi stvaranje bazena likvidnosti koji će moći zgrabiti privatni ulagači i kompanije kako bi se izvukla iz trenutne situacije tržišta u nastajanju i lagano otvorila put prema postizanju statusa razvijene zemlje i tako barem malo približila Njemačkoj.

LITERATURA

1. Aljinović, Z., Marasović, B., Šego, B., (2008.): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split
2. Aljinović, Z., Marasović, B., (2012.): Matematički modeli u analizi razvoja hrvatskog financijskog tržišta, Sveučilište u Splitu, Ekonomski fakultet, Split
3. Aljimović, Z. (2017.): Materijali s predavanja iz kolegija Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet, Split
4. Angelovska J. (2017.): Long and Short – Term Dynamic Relationship between Macedonian and Croatian Stock Markets, Zagreb International Review of Economics & Business, Vol. 20, No. 2, str. 11-20.
5. Barbić, T. (2010.): Pregled razvoja hipoteze efikasnog tržišta, Privredna kretanja i ekonomska politika, Vol. 20, No. 124, str. 29-62.
6. Bekaert, G., Campbell, R. H. (2002.): Research in emerging markets finance: looking to the future, Emerging markets review, Vol. 3, No. 4, str. 2-13.
7. 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., dostupno na: (https://hrcak.srce.hr/34057).
8. Burilović, L. (2018.): Gospodarska kretanja ½ 2018, Hrvatska gospodarska komora, Zagreb.
9. Caruana, J., Deppler, M., (2008.): Procjena stabilnosti financijskog sustava- ažurirana verzija, Sektor na monetarnu politiku i tržišta kapitala i Sektor za Europu, Međunarodni monetarni fond, Republika Hrvatska, dostupno na: (https://www.hnb.hr/documents/20182/123145/h-procjena-stabilnosti-fin-sustava-2008/7b4cedfa-2b41-4ec9-b678-a7a749b81626).
10. Ćurak, M., Kundid, A., Visković, J.(2014.) : Financije nakon krize – forenzika, etika i održivost, Sveučilište u Splitu, Ekonomski fakultet, Split, dostupno na: (https://bib.irb.hr/datoteka/700561.OlgicDrazenovic_Preni_Split_2014_Razvoj_trita_kapitala_u_post-tranzicijskim_zemljama_EU.pdf).
11. Dalić, M. (2002.): Usporedna analiza hrvatskog financijskog sustava i financijskih sustava naprednih tranzicijskih zemalja, Privredna kretanja i ekonomska politika, Vol. 12, No. 92, str. 27.-52., dostupno na: (https://hrcak.srce.hr/18614).

12. Horst, S. (2004): Germany's Capital Market and Corporate Governance, Kiel Working Paper, No. 1206. Kiel Institute for World Economics
13. Jakšić, S., (2007.): Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 5, No. 1, str. 331.-344., dostupno na: (https://hrcak.srce.hr/26139).
14. Jerončić, M., Aljinović, Z. (2011.): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Ekonomski pregled, Vol. 62, No. 9-10, str. 583-606., dostupno na: (https://hrcak.srce.hr/72849)
15. Marasović, B., (2006.): Modeli optimizacije investicijskog portfelja, magistarski rad, Sveučilište u Zagrebu, Ekonomski fakultet, Split
16. Maričić, Z., (2011.): Portfelj i izbor vrijednosnica, Praktični menadžment, Vol. 2, No. 3, str. 87-92., dostupno na: (https://hrcak.srce.hr/file/113570)
17. Pivac, S.(2010.): Statističke metode (predavanja, diplomski studij, kolegij ″Statističke metode¨), e-nastavni materijal, Sveučilište u Splitu, Ekonomski fakultet, Split
18. Poslovna očekivanja (2018.), Privredni vjesnik, posebno izdanje, Hrvatska gospodarska komora
19. Tomić- Plazibat, N., Aljinović, Z., Marasović, B., (2006.): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split
20. Vidović, J. (2010.): Model optimizacije portfelja dionica na tržištima kapitala zemalja novih članica i kandidata za ulazak u EU, Doktorska disertacija, Sveučilište u Splitu, Ekonomski fakultet, Split
21. Žiković, S. (2005.): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet, Ljubljana
22. http://www.poslovni.hr/ (2.4.2018.)
23. https://lider.media/ (2.4.2018.)
24. http://www.zse.hr/ (28.3.2018.)
25. http://en.boerse-frankfurt.de/ (28.3.2018.)
26. https://www.wikipedia.org/ (28,3.2018.)
27. https://hrcak.srce.hr/18614 (28.3.2018.)
28. http://www.glas-slavonije.hr/329544/7/Agrokor-uzdrmao-trziste-kapitala (28.3.2018.)
29. https://poslovnipuls.com/ (28.3.2018.)
30. https://countryeconomy.com/countries/compare (04.05.2018.)

31. https://www.hanfa.hr/ (12.06.2018.)
32. https://hgk.hr (12.06.2018.)

PRILOZI

Prilog 1: Zaključne tjedne cijene odabranih dionica na hrvatskom tržištu kapitala

Datum	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
3.6.2016.	114,62	387,50	325,00	815,25	129,06	1.012,35	141,17	686,13	341,71	24,01
10.6.2016.	111,25	399,20	325,00	818,49	130,65	1.004,35	140,72	670,00	343,00	23,98
17.6.2016.	112,95	387,53	336,00	815,41	136,31	1.008,01	140,82	667,07	339,56	23,98
24.6.2016.	109,08	387,73	345,00	793,83	132,19	1.001,02	139,26	650,00	325,18	23,93
1.7.2016.	112,33	377,95	346,99	814,74	136,68	1.004,95	141,63	636,85	330,22	24,77
8.7.2016.	122,54	381,82	359,00	814,37	146,68	1.020,40	142,76	675,00	342,80	25,05
15.7.2016.	119,66	383,87	360,00	824,09	174,42	1.006,38	142,79	662,68	333,99	24,76
22.7.2016.	114,52	393,46	399,92	818,85	195,00	1.003,96	142,85	675,77	335,71	25,45
29.7.2016.	111,65	408,49	401,00	816,14	181,16	1.009,09	143,18	663,00	359,00	26,66
5.8.2016.	112,52	402,19	398,99	814,20	172,15	1.010,47	142,45	656,87	356,00	26,88
12.8.2016.	115,36	401,22	390,50	814,03	184,14	1.016,31	142,24	658,06	359,76	27,22
19.8.2016.	118,01	404,26	389,24	816,58	185,00	1.016,91	143,43	657,90	360,35	29,33
26.8.2016.	119,00	406,95	408,00	819,16	182,37	1.030,85	145,53	669,89	365,79	29,00
2.9.2016.	123,83	405,46	392,20	821,98	173,31	1.095,75	154,59	674,90	356,97	28,78
9.9.2016.	128,17	415,90	415,00	844,11	193,60	1.127,12	156,19	673,00	360,34	28,85
16.9.2016.	126,42	417,93	427,00	847,00	176,11	1.163,74	161,10	662,23	361,06	30,32
23.9.2016.	131,19	435,66	429,99	871,03	193,57	1.138,20	164,87	673,67	383,84	32,84
30.9.2016.	136,88	436,19	435,00	868,62	180,03	1.142,00	163,60	676,38	379,00	34,15
7.10.2016.	140,01	480,19	429,00	879,01	196,71	1.149,09	165,17	690,27	381,00	34,48
14.10.2016.	140,04	459,15	435,00	869,94	240,84	1.149,67	161,81	682,76	374,20	35,00
21.10.2016.	140,01	449,74	422,00	866,03	281,90	1.152,58	159,93	683,20	371,60	32,98
28.10.2016.	139,86	450,00	426,00	865,04	295,17	1.144,50	164,23	678,75	369,60	32,55
4.11.2016.	138,80	454,45	400,25	873,07	301,31	1.124,34	166,07	670,91	370,37	31,47
11.11.2016.	137,49	451,55	424,94	882,41	342,26	1.115,05	162,71	683,79	367,43	31,78
18.11.2016.	137,64	451,78	430,00	883,31	367,92	1.102,00	162,30	682,03	379,87	33,89
25.11.2016.	139,88	457,47	432,00	891,00	351,04	1.129,66	163,24	691,67	381,85	34,53
2.12.2016.	138,19	459,57	427,00	874,90	329,35	1.145,92	167,09	680,03	380,44	34,07
9.12.2016.	135,67	456,57	417,07	869,69	321,24	1.140,31	171,14	682,00	375,51	34,33
16.12.2016.	134,09	453,02	429,99	867,05	283,93	1.144,47	171,86	680,00	374,58	33,90
23.12.2016.	135,62	457,78	440,00	870,02	282,83	1.153,33	175,50	690,39	378,78	33,98
30.12.2016.	138,61	456,30	468,50	884,12	282,55	1.163,99	169,03	690,00	379,22	34,59
6.1.2017.	138,02	460,00	494,00	881,36	282,16	1.187,80	167,64	703,41	382,61	36,22
13.1.2017.	139,46	466,81	515,95	910,00	291,71	1.240,26	173,17	710,00	380,15	38,92
20.1.2017.	139,80	469,74	511,00	931,38	307,72	1.257,54	173,38	755,49	381,10	38,56
27.1.2017.	141,98	470,02	511,66	922,00	336,52	1.247,43	172,65	777,87	394,36	39,03
3.2.2017.	146,99	487,60	534,99	929,81	334,01	1.292,87	173,71	824,83	413,90	41,95
10.2.2017.	152,97	496,25	580,00	943,59	329,27	1.320,24	174,47	799,43	412,85	41,55
17.2.2017.	152,45	497,63	560,00	943,83	329,90	1.342,56	179,11	819,54	409,05	42,11
24.2.2017.	158,17	511,37	520,00	984,26	312,95	1.424,46	189,50	856,06	418,67	42,07

3.3.2017.	162,88	505,57	529,95	909,08	324,46	1.406,97	187,06	849,90	407,91	42,54
10.3.2017.	164,24	499,76	510,00	916,32	377,44	1.407,05	185,12	849,29	403,17	41,99
17.3.2017.	164,77	493,07	505,90	901,05	382,65	1.402,35	179,90	829,94	390,29	43,91
24.3.2017.	160,01	488,71	500,00	881,34	388,54	1.408,65	174,11	799,99	365,24	42,78
31.3.2017.	156,89	461,75	485,00	784,12	408,94	1.358,22	172,63	787,62	351,38	42,29
7.4.2017.	157,57	457,72	489,88	795,29	432,33	1.371,93	173,70	786,68	349,27	42,04
14.4.2017.	157,90	452,78	500,00	790,62	465,25	1.368,88	175,28	752,53	350,01	42,19
21.4.2017.	159,00	469,68	515,49	819,97	430,56	1.341,92	174,36	767,70	367,43	42,48
28.4.2017.	163,75	457,32	485,60	794,93	417,59	1.313,70	178,44	799,10	348,57	41,92
5.5.2017.	165,64	457,20	509,95	780,02	406,23	1.343,78	176,38	799,90	346,23	41,82
12.5.2017.	171,49	469,98	477,00	780,07	400,63	1.320,92	172,06	801,54	347,00	40,56
19.5.2017.	170,47	462,75	455,01	771,59	370,04	1.306,62	168,52	788,48	340,16	40,26
26.5.2017.	172,31	460,05	479,99	750,97	383,56	1.302,62	168,19	793,38	339,61	40,03
2.6.2017.	166,64	474,62	490,53	758,56	380,08	1.292,36	173,42	757,30	320,61	41,34
9.6.2017.	168,87	456,66	450,43	754,49	399,60	1.178,38	174,42	741,27	311,22	41,41
16.6.2017.	167,46	464,93	466,68	770,00	381,72	1.243,36	177,42	726,14	316,22	43,56
23.6.2017.	169,28	471,83	474,16	775,04	389,92	1.229,27	175,57	725,52	324,66	43,12
30.6.2017.	166,15	464,96	471,63	770,40	397,65	1.245,72	181,91	730,05	323,61	43,85
7.7.2017.	166,00	455,00	481,69	788,00	386,01	1.245,56	180,20	727,00	325,20	43,95
14.7.2017.	168,92	460,00	480,00	789,99	395,00	1.181,00	180,42	721,00	315,00	43,64
21.7.2017.	173,60	460,00	480,00	766,20	424,99	1.222,00	181,25	730,00	319,00	43,40
28.7.2017.	170,00	453,05	470,01	854,99	421,99	1.222,00	180,87	717,01	315,00	43,69
4.8.2017.	169,99	455,99	482,00	826,75	419,99	1.275,00	179,00	717,01	314,05	43,94
11.8.2017.	167,25	453,00	489,00	823,00	424,00	1.249,00	180,53	719,00	315,00	43,98
18.8.2017.	169,00	450,02	489,99	815,11	437,99	1.205,02	179,15	750,00	317,90	44,90
25.8.2017.	170,00	456,00	485,00	812,05	434,46	1.215,00	181,01	725,40	313,00	45,72
1.9.2017.	163,60	453,50	489,90	814,01	405,00	1.200,00	179,01	730,00	318,00	47,45
8.9.2017.	166,55	449,19	485,40	805,00	434,99	1.200,00	176,00	730,00	310,01	46,88
15.9.2017.	160,00	430,00	480,00	799,01	416,50	1.110,00	176,40	720,00	299,01	43,88
22.9.2017.	161,00	437,40	472,01	806,00	413,98	1.106,00	178,40	700,50	297,31	44,45
29.9.2017.	162,00	434,00	462,90	802,05	408,99	1.141,00	176,00	695,10	296,99	43,18
6.10.2017.	161,97	445,00	466,50	810,00	429,70	1.120,04	174,00	660,03	293,95	43,67
13.10.2017.	166,00	450,00	468,02	823,55	455,00	1.184,00	174,60	675,00	314,48	45,01
20.10.2017.	166,99	440,00	458,50	835,00	499,90	1.155,00	170,12	680,00	301,00	44,90
27.10.2017.	171,50	455,00	455,12	851,17	530,00	1.173,00	172,50	700,00	316,00	45,85
3.11.2017.	166,00	439,99	471,00	840,00	480,00	1.146,00	169,24	676,00	300,02	44,10
10.11.2017.	172,00	451,00	469,01	838,00	511,44	1.167,00	169,05	700,50	300,00	44,12
17.11.2017.	170,00	440,00	468,00	890,01	519,00	1.176,00	167,40	686,00	298,01	43,90
24.11.2017.	168,32	435,56	470,03	852,00	578,99	1.210,00	166,94	697,77	297,50	43,69
1.12.2017.	170,00	434,00	469,00	834,30	620,00	1.181,00	166,71	700,09	297,22	44,96
8.12.2017.	168,00	422,50	467,00	846,20	635,08	1.149,00	167,00	696,07	291,00	44,01
15.12.2017.	168,20	429,99	460,10	855,01	670,00	1.170,00	167,75	704,00	288,10	43,92
22.12.2017.	167,97	420,00	450,00	855,03	619,96	1.200,00	165,55	714,00	280,00	42,96
29.12.2017.	169,10	429,00	450,00	862,00	638,90	1.203,99	165,40	714,95	270,00	43,75
5.1.2018.	169,50	417,00	438,00	865,00	684,00	1.200,00	165,00	700,00	276,00	43,30

12.1.2018.	170,00	438,00	440,00	930,00	680,00	1.200,00	168,00	705,00	270,00	43,00
19.1.2018.	180,00	441,00	445,00	930,00	666,00	1.200,00	167,50	710,00	270,00	42,60
26.1.2018.	189,50	429,00	447,00	910,00	662,00	1.205,00	165,00	700,00	270,00	42,80
2.2.2018.	182,50	430,00	452,00	950,00	660,00	1.230,00	165,00	705,00	269,00	43,00
9.2.2018.	187,00	441,00	442,00	935,00	640,00	1.220,00	167,00	705,00	261,00	41,90
16.2.2018.	190,50	428,00	443,00	940,00	626,00	1.210,00	165,00	710,00	264,00	41,40
23.2.2018.	192,50	427,00	435,00	890,00	640,00	1.170,00	163,00	700,00	253,00	40,80
2.3.2018.	191,50	418,00	440,00	970,00	620,00	1.155,00	163,00	695,00	265,00	42,30
9.3.2018.	195,00	434,00	439,00	960,00	644,00	1.170,00	162,50	700,00	264,00	41,70
16.3.2018.	195,00	435,00	425,00	970,00	628,00	1.165,00	165,50	660,00	263,00	42,10
23.3.2018.	192,00	440,00	430,00	965,00	570,00	1.170,00	163,50	680,00	261,00	40,90
30.3.2018.	186,00	424,00	425,00	970,00	568,00	1.165,00	164,00	655,00	260,00	40,10
6.4.2018	189,00	432,00	426,00	955,00	514,00	1.160,00	161,50	660,00	260,00	40,60
13.4.2018.	181,50	421,00	429,00	935,00	516,00	1.165,00	161,50	645,00	261,00	39,80
20.4.2018.	180,00	420,00	417,00	940,00	562,00	1.145,00	160,00	670,00	270,00	39,40
27.4.2018.	190,00	418,00	420,00	945,00	536,00	1.055,00	163,00	665,00	290,00	40,00
4.5.2018.	189,50	429,00	424,00	960,00	520,00	1.055,00	165,50	695,00	302,00	42,80
11.5.2018.	193,00	437,00	423,00	945,00	518,00	1.075,00	156,50	700,00	315,00	42,50
18.5.2018.	198,50	451,00	430,00	965,00	499,00	1.080,00	159,00	685,00	315,00	42,10
25.5.2018.	197,00	450,00	428,00	1.040,00	468,00	1.100,00	157,00	670,00	315,00	41,50
1.6.2018.	197,00	427,00	421,00	1.040,00	494,00	1.100,00	154,00	675,00	313,00	41,60
8.6.2016.	191,50	429,00	424,00	1.010,00	485,00	1.085,00	153,00	660,00	315,00	41,50
15.6.2018.	191,00	428,00	422,00	1.040,00	470,00	1.070,00	148,00	665,00	312,00	41,50
22.6.2018.	198,00	432,00	426,00	1.050,00	468,00	1.085,00	150,00	670,00	318,00	41,50
29.6.2018.	196,50	424,00	424,00	975,00	475,00	1.045,00	151,00	665,00	322,00	40,50

Prilog 2: Tjedni prinosi odabranih dionica na hrvatskom tržištu kapitala

Datum	ADPL	ADRS2	ARNT	ATGR	ATPL	ERNT	HT	KOEI	PODR	RIVP
10.6.2016.	-2,98%	2,97%	0,00%	0,40%	1,22%	-0,79%	-0,32%	-2,38%	0,38%	-0,13%
17.6.2016.	1,52%	-2,97%	3,33%	-0,38%	4,24%	0,36%	0,07%	-0,44%	-1,01%	0,00%
24.6.2016.	-3,49%	0,05%	2,64%	-2,68%	-3,07%	-0,70%	-1,11%	-2,59%	-4,33%	-0,21%
1.7.2016.	2,94%	-2,55%	0,58%	2,60%	3,34%	0,39%	1,69%	-2,04%	1,54%	3,45%
8.7.2016.	8,70%	1,02%	3,40%	-0,05%	7,06%	1,53%	0,79%	5,82%	3,74%	1,12%
15.7.2016.	-2,38%	0,54%	0,28%	1,19%	17,32%	-1,38%	0,02%	-1,84%	-2,60%	-1,16%
22.7.2016.	-4,39%	2,47%	10,52%	-0,64%	11,15%	-0,24%	0,04%	1,96%	0,51%	2,75%
29.7.2016.	-2,54%	3,75%	0,27%	-0,33%	-7,36%	0,51%	0,23%	-1,91%	6,71%	4,64%
5.8.2016.	0,78%	-1,55%	-0,50%	-0,24%	-5,10%	0,14%	-0,51%	-0,93%	-0,84%	0,82%
12.8.2016.	2,49%	-0,24%	-2,15%	-0,02%	6,73%	0,58%	-0,15%	0,18%	1,05%	1,26%
19.8.2016.	2,27%	0,75%	-0,32%	0,31%	0,47%	0,06%	0,83%	-0,02%	0,16%	7,47%
26.8.2016.	0,84%	0,66%	4,71%	0,32%	-1,43%	1,36%	1,45%	1,81%	1,50%	-1,13%
2.9.2016.	3,98%	-0,37%	-3,95%	0,34%	-5,10%	6,11%	6,04%	0,75%	-2,44%	-0,76%
9.9.2016.	3,44%	2,54%	5,65%	2,66%	11,07%	2,82%	1,03%	-0,28%	0,94%	0,24%

16.9.2016.	-1,37%	0,49%	2,85%	0,34%	-9,47%	3,20%	3,10%	-1,61%	0,20%	4,97%
23.9.2016.	3,70%	4,15%	0,70%	2,80%	9,45%	-2,22%	2,31%	1,71%	6,12%	7,98%
30.9.2016.	4,25%	0,12%	1,16%	-0,28%	-7,25%	0,33%	-0,77%	0,40%	-1,27%	3,91%
7.10.2016.	2,26%	9,61%	-1,39%	1,19%	8,86%	0,62%	0,96%	2,03%	0,53%	0,96%
14.10.2016.	0,02%	-4,48%	1,39%	-1,04%	20,24%	0,05%	-2,06%	-1,09%	-1,80%	1,50%
21.10.2016.	-0,02%	-2,07%	-3,03%	-0,45%	15,74%	0,25%	-1,17%	0,06%	-0,70%	-5,94%
28.10.2016.	-0,11%	0,06%	0,94%	-0,11%	4,60%	-0,70%	2,65%	-0,65%	-0,54%	-1,31%
4.11.2016.	-0,76%	0,98%	-6,23%	0,92%	2,06%	-1,78%	1,11%	-1,16%	0,21%	-3,37%
11.11.2016.	-0,95%	-0,64%	5,99%	1,06%	12,74%	-0,83%	-2,04%	1,90%	-0,80%	0,98%
18.11.2016.	0,11%	0,05%	1,18%	0,10%	7,23%	-1,18%	-0,25%	-0,26%	3,33%	6,43%
25.11.2016.	1,61%	1,25%	0,46%	0,87%	-4,70%	2,48%	0,58%	1,40%	0,52%	1,87%
2.12.2016.	-1,22%	0,46%	-1,16%	-1,82%	-6,38%	1,43%	2,33%	-1,70%	-0,37%	-1,34%
9.12.2016.	-1,84%	-0,65%	-2,35%	-0,60%	-2,49%	-0,49%	2,39%	0,29%	-1,30%	0,76%
16.12.2016.	-1,17%	-0,78%	3,05%	-0,30%	-12,35%	0,36%	0,42%	-0,29%	-0,25%	-1,26%
23.12.2016.	1,13%	1,05%	2,30%	0,34%	-0,39%	0,77%	2,10%	1,52%	1,12%	0,24%
30.12.2016.	2,18%	-0,32%	6,28%	1,61%	-0,10%	0,92%	-3,76%	-0,06%	0,12%	1,78%
6.1.2017.	-0,43%	0,81%	5,30%	-0,31%	-0,14%	2,02%	-0,83%	1,92%	0,89%	4,60%
13.1.2017.	1,04%	1,47%	4,35%	3,20%	3,33%	4,32%	3,25%	0,93%	-0,65%	7,19%
20.1.2017.	0,24%	0,63%	-0,96%	2,32%	5,34%	1,38%	0,12%	6,21%	0,25%	-0,93%
27.1.2017.	1,55%	0,06%	0,13%	-1,01%	8,95%	-0,81%	-0,42%	2,92%	3,42%	1,21%
3.2.2017.	3,47%	3,67%	4,46%	0,84%	-0,75%	3,58%	0,61%	5,86%	4,84%	7,21%
10.2.2017.	3,99%	1,76%	8,08%	1,47%	-1,43%	2,09%	0,44%	-3,13%	-0,25%	-0,96%
17.2.2017.	-0,34%	0,28%	-3,51%	0,03%	0,19%	1,68%	2,62%	2,48%	-0,92%	1,34%
24.2.2017.	3,68%	2,72%	-7,41%	4,19%	-5,27%	5,92%	5,64%	4,36%	2,32%	-0,10%
3.3.2017.	2,93%	-1,14%	1,90%	-7,95%	3,61%	-1,24%	-1,30%	-0,72%	-2,60%	1,11%
10.3.2017.	0,83%	-1,16%	-3,84%	0,79%	15,12%	0,01%	-1,04%	-0,07%	-1,17%	-1,30%
17.3.2017.	0,32%	-1,35%	-0,81%	-1,68%	1,37%	-0,33%	-2,86%	-2,30%	-3,25%	4,47%
24.3.2017.	-2,93%	-0,89%	-1,17%	-2,21%	1,53%	0,45%	-3,27%	-3,68%	-6,63%	-2,61%
31.3.2017.	-1,97%	-5,67%	-3,05%	-11,69%	5,12%	-3,65%	-0,85%	-1,56%	-3,87%	-1,15%
7.4.2017.	0,43%	-0,88%	1,00%	1,41%	5,56%	1,00%	0,62%	-0,12%	-0,60%	-0,59%
14.4.2017.	0,21%	-1,09%	2,04%	-0,59%	7,34%	-0,22%	0,91%	-4,44%	0,21%	0,36%
21.4.2017.	0,69%	3,66%	3,05%	3,65%	-7,75%	-1,99%	-0,53%	2,00%	4,86%	0,69%
28.4.2017.	2,94%	-2,67%	-5,97%	-3,10%	-3,06%	-2,13%	2,31%	4,01%	-5,27%	-1,33%
5.5.2017.	1,15%	-0,03%	4,89%	-1,89%	-2,76%	2,26%	-1,16%	0,10%	-0,67%	-0,24%
12.5.2017.	3,47%	2,76%	-6,68%	0,01%	-1,39%	-1,72%	-2,48%	0,20%	0,22%	-3,06%
19.5.2017.	-0,60%	-1,55%	-4,72%	-1,09%	-7,94%	-1,09%	-2,08%	-1,64%	-1,99%	-0,74%
26.5.2017.	1,07%	-0,59%	5,34%	-2,71%	3,59%	-0,31%	-0,20%	0,62%	-0,16%	-0,57%
2.6.2017.	-3,35%	3,12%	2,17%	1,01%	-0,91%	-0,79%	3,06%	-4,65%	-5,76%	3,22%
9.6.2017.	1,33%	-3,86%	-8,53%	-0,54%	5,01%	-9,23%	0,57%	-2,14%	-2,97%	0,17%
16.6.2017.	-0,84%	1,79%	3,54%	2,03%	-4,58%	5,37%	1,71%	-2,06%	1,59%	5,06%
23.6.2017.	1,08%	1,47%	1,59%	0,65%	2,13%	-1,14%	-1,05%	-0,09%	2,63%	-1,02%
30.6.2017.	-1,87%	-1,47%	-0,54%	-0,60%	1,96%	1,33%	3,55%	0,62%	-0,32%	1,68%
7.7.2017.	-0,09%	-2,17%	2,11%	2,26%	-2,97%	-0,01%	-0,94%	-0,42%	0,49%	0,23%
14.7.2017.	1,74%	1,09%	-0,35%	0,25%	2,30%	-5,32%	0,12%	-0,83%	-3,19%	-0,71%
21.7.2017.	2,73%	0,00%	0,00%	-3,06%	7,32%	3,41%	0,46%	1,24%	1,26%	-0,55%

28.7.2017.	-2,10%	-1,52%	-2,10%	10,96%	-0,71%	0,00%	-0,21%	-1,80%	-1,26%	0,67%
4.8.2017.	-0,01%	0,65%	2,52%	-3,36%	-0,48%	4,25%	-1,04%	0,00%	-0,30%	0,57%
11.8.2017.	-1,62%	-0,66%	1,44%	-0,45%	0,95%	-2,06%	0,85%	0,28%	0,30%	0,09%
18.8.2017.	1,04%	-0,66%	0,20%	-0,96%	3,25%	-3,58%	-0,77%	4,22%	0,92%	2,07%
25.8.2017.	0,59%	1,32%	-1,02%	-0,38%	-0,81%	0,82%	1,03%	-3,33%	-1,55%	1,81%
1.9.2017.	-3,84%	-0,55%	1,01%	0,24%	-7,02%	-1,24%	-1,11%	0,63%	1,58%	3,71%
8.9.2017.	1,79%	-0,95%	-0,92%	-1,11%	7,14%	0,00%	-1,70%	0,00%	-2,54%	-1,21%
15.9.2017.	-4,01%	-4,37%	-1,12%	-0,75%	-4,34%	-7,80%	0,23%	-1,38%	-3,61%	-6,61%
22.9.2017.	0,62%	1,71%	-1,68%	0,87%	-0,61%	-0,36%	1,13%	-2,75%	-0,57%	1,29%
29.9.2017.	0,62%	-0,78%	-1,95%	-0,49%	-1,21%	3,12%	-1,35%	-0,77%	-0,11%	-2,90%
6.10.2017.	-0,02%	2,50%	0,77%	0,99%	4,94%	-1,85%	-1,14%	-5,18%	-1,03%	1,13%
13.10.2017.	2,46%	1,12%	0,33%	1,66%	5,72%	5,55%	0,34%	2,24%	6,75%	3,02%
20.10.2017.	0,59%	-2,25%	-2,06%	1,38%	9,41%	-2,48%	-2,60%	0,74%	-4,38%	-0,24%
27.10.2017.	2,66%	3,35%	-0,74%	1,92%	5,85%	1,55%	1,39%	2,90%	4,86%	2,09%
3.11.2017.	-3,26%	-3,35%	3,43%	-1,32%	-9,91%	-2,33%	-1,91%	-3,49%	-5,19%	-3,89%
10.11.2017.	3,55%	2,47%	-0,42%	-0,24%	6,34%	1,82%	-0,11%	3,56%	-0,01%	0,05%
17.11.2017.	-1,17%	-2,47%	-0,22%	6,02%	1,47%	0,77%	-0,98%	-2,09%	-0,67%	-0,50%
24.11.2017.	-0,99%	-1,01%	0,43%	-4,36%	10,94%	2,85%	-0,28%	1,70%	-0,17%	-0,48%
1.12.2017.	0,99%	-0,36%	-0,22%	-2,10%	6,84%	-2,43%	-0,14%	0,33%	-0,09%	2,87%
8.12.2017.	-1,18%	-2,69%	-0,43%	1,42%	2,40%	-2,75%	0,17%	-0,58%	-2,11%	-2,14%
15.12.2017.	0,12%	1,76%	-1,49%	1,04%	5,35%	1,81%	0,45%	1,13%	-1,00%	-0,20%
22.12.2017.	-0,14%	-2,35%	-2,22%	0,00%	-7,76%	2,53%	-1,32%	1,41%	-2,85%	-2,21%
29.12.2017.	0,67%	2,12%	0,00%	0,81%	3,01%	0,33%	-0,09%	0,13%	-3,64%	1,82%
5.1.2018.	0,24%	-2,84%	-2,70%	0,35%	6,82%	-0,33%	-0,24%	-2,11%	2,20%	-1,03%
12.1.2018.	0,29%	4,91%	0,46%	7,25%	-0,59%	0,00%	1,80%	0,71%	-2,20%	-0,70%
19.1.2018.	5,72%	0,68%	1,13%	0,00%	-2,08%	0,00%	-0,30%	0,71%	0,00%	-0,93%
26.1.2018.	5,14%	-2,76%	0,45%	-2,17%	-0,60%	0,42%	-1,50%	-1,42%	0,00%	0,47%
2.2.2018.	-3,76%	0,23%	1,11%	4,30%	-0,30%	2,05%	0,00%	0,71%	-0,37%	0,47%
9.2.2018.	2,44%	2,53%	-2,24%	-1,59%	-3,08%	-0,82%	1,20%	0,00%	-3,02%	-2,59%
16.2.2018.	1,85%	-2,99%	0,23%	0,53%	-2,21%	-0,82%	-1,20%	0,71%	1,14%	-1,20%
23.2.2018.	1,04%	-0,23%	-1,82%	-5,47%	2,21%	-3,36%	-1,22%	-1,42%	-4,26%	-1,46%
2.3.2018.	-0,52%	-2,13%	1,14%	8,61%	-3,17%	-1,29%	0,00%	-0,72%	4,63%	3,61%
9.3.2018.	1,81%	3,76%	-0,23%	-1,04%	3,80%	1,29%	-0,31%	0,72%	-0,38%	-1,43%
16.3.2018.	0,00%	0,23%	-3,24%	1,04%	-2,52%	-0,43%	1,83%	-5,88%	-0,38%	0,95%
23.3.2018.	-1,55%	1,14%	1,17%	-0,52%	-9,69%	0,43%	-1,22%	2,99%	-0,76%	-2,89%
30.3.2018.	-3,17%	-3,70%	-1,17%	0,52%	-0,35%	-0,43%	0,31%	-3,75%	-0,38%	-1,98%
6.4.2018	1,60%	1,87%	0,24%	-1,56%	-9,99%	-0,43%	-1,54%	0,76%	0,00%	1,24%
13.4.2018.	-4,05%	-2,58%	0,70%	-2,12%	0,39%	0,43%	0,00%	-2,30%	0,38%	-1,99%
20.4.2018.	-0,83%	-0,24%	-2,84%	0,53%	8,54%	-1,73%	-0,93%	3,80%	3,39%	-1,01%
27.4.2018.	5,41%	-0,48%	0,72%	0,53%	-4,74%	-8,19%	1,86%	-0,75%	7,15%	1,51%
4.5.2018.	-0,26%	2,60%	0,95%	1,57%	-3,03%	0,00%	1,52%	4,41%	4,05%	6,77%
11.5.2018.	1,83%	1,85%	-0,24%	-1,57%	-0,39%	1,88%	-5,59%	0,72%	4,21%	-0,70%
18.5.2018.	2,81%	3,15%	1,64%	2,09%	-3,74%	0,46%	1,58%	-2,17%	0,00%	-0,95%
25.5.2018.	-0,76%	-0,22%	-0,47%	7,48%	-6,41%	1,83%	-1,27%	-2,21%	0,00%	-1,44%
1.6.2018.	0,00%	-5,25%	-1,65%	0,00%	5,41%	0,00%	-1,93%	0,74%	-0,64%	0,24%

8.6.2016.	-2,83%	0,47%	0,71%	-2,93%	-1,84%	-1,37%	-0,65%	-2,25%	0,64%	-0,24%
15.6.2018.	-0,26%	-0,23%	-0,47%	2,93%	-3,14%	-1,39%	-3,32%	0,75%	-0,96%	0,00%
22.6.2018.	3,60%	0,93%	0,94%	0,96%	-0,43%	1,39%	1,34%	0,75%	1,90%	0,00%
29.6.2018.	-0,76%	-1,87%	-0,47%	-7,41%	1,48%	-3,76%	0,66%	-0,75%	1,25%	-2,44%

Prilog 3: Zaključne tjedne cijene odabranih dionica na njemačkom tržištu kapitala

Datum	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
3.6.2016.	142,84	116,70	68,50	87,87	59,37	12,50	15,17	71,48	95,40	131,00
10.6.2016.	134,73	118,41	67,60	86,50	57,18	11,45	14,25	69,34	92,95	125,60
17.6.2016.	130,64	117,60	67,50	87,18	56,18	11,32	13,81	67,90	92,27	119,80
24.6.2016.	126,75	119,80	66,70	86,48	55,04	11,00	13,53	67,14	90,00	115,35
1.7.2016.	127,34	127,89	69,30	89,16	54,88	10,61	14,70	67,60	91,79	114,00
8.7.2016.	122,87	125,98	67,20	89,26	54,00	10,77	14,33	69,15	89,33	109,69
15.7.2016.	127,75	131,57	71,70	92,36	58,30	11,19	14,91	71,17	94,09	116,00
22.7.2016.	125,53	137,34	71,51	90,64	59,32	10,40	14,80	76,97	94,79	120,67
29.7.2016.	128,50	146,86	69,83	94,72	60,73	10,57	14,66	78,10	96,80	125,60
5.8.2016.	126,25	146,80	69,40	94,18	61,00	10,40	14,96	77,58	102,07	123,15
12.8.2016.	134,33	155,15	72,68	96,20	62,63	10,90	15,11	78,40	107,20	124,80
19.8.2016.	129,66	156,51	71,96	94,87	61,32	10,30	14,66	77,95	106,55	119,30
26.8.2016.	128,52	152,58	71,98	94,33	61,26	10,28	14,45	77,51	107,15	122,95
2.9.2016.	135,25	144,76	72,98	93,31	62,73	10,49	14,53	80,29	108,16	124,40
9.9.2016.	136,23	144,75	72,27	93,54	63,10	11,01	14,28	78,71	104,50	124,19
16.9.2016.	129,98	149,36	70,62	89,26	60,57	10,32	14,00	77,89	104,01	118,58
23.9.2016.	136,01	154,62	73,47	89,97	63,48	10,29	14,69	81,51	105,90	119,10
30.9.2016.	132,22	154,80	75,80	87,92	62,62	10,00	14,44	81,33	104,40	116,84
7.10.2016.	135,78	155,05	78,05	88,48	63,97	9,24	13,90	80,10	104,69	118,05
14.10.2016.	137,98	156,98	78,85	88,97	64,26	10,28	13,89	79,06	105,20	120,50
21.10.2016.	139,78	156,90	79,52	88,74	64,72	11,17	14,03	81,61	106,47	123,30
28.10.2016.	141,44	149,25	80,20	89,13	65,10	11,59	14,35	80,43	103,36	125,35
4.11.2016.	136,29	132,43	77,35	86,53	61,95	11,67	13,91	77,08	101,33	119,10
11.11.2016.	151,10	133,44	80,93	92,41	64,49	12,51	13,95	76,73	108,30	117,66
18.11.2016.	150,81	138,81	80,15	90,24	65,30	12,63	13,97	78,26	106,49	117,40
25.11.2016.	150,78	139,01	80,40	87,68	64,62	12,51	14,27	80,60	107,30	124,90
2.12.2016.	147,74	138,48	80,80	86,11	62,50	12,01	14,19	77,02	105,69	118,78
9.12.2016.	157,13	144,31	85,15	92,82	68,28	12,69	15,19	79,73	114,78	127,85
16.12.2016.	156,65	144,98	87,35	95,73	70,25	12,85	15,40	81,36	115,54	130,93
23.12.2016.	156,68	144,40	87,09	96,82	70,82	12,78	15,51	81,62	114,94	137,36
30.12.2016.	156,44	149,80	87,96	97,22	70,71	12,26	15,74	82,65	116,40	133,44
6.1.2017.	161,03	145,00	87,38	100,80	72,00	12,46	16,00	84,00	116,23	139,40
13.1.2017.	160,36	147,83	89,02	99,97	71,20	11,41	15,78	84,22	116,20	149,35
20.1.2017.	159,28	151,85	89,42	100,41	70,40	12,04	15,81	83,70	116,91	147,21

27.1.2017.	161,96	153,72	91,08	104,65	70,71	12,63	15,77	85,30	119,29	149,80
3.2.2017.	158,48	147,26	89,12	101,78	67,85	12,27	15,45	85,61	118,31	144,95
10.2.2017.	156,85	149,27	88,50	104,30	67,27	12,63	15,46	86,49	119,91	142,36
17.2.2017.	162,97	148,59	89,00	104,71	67,51	13,11	15,35	86,80	120,59	141,11
24.2.2017.	163,88	152,02	87,41	102,61	68,66	13,58	15,87	88,17	122,15	142,39
3.3.2017.	167,76	160,81	90,47	105,61	69,92	13,70	15,65	89,22	124,99	145,10
10.3.2017.	169,28	179,07	89,30	104,94	69,95	14,43	15,53	89,01	123,13	141,73
17.3.2017.	170,53	182,94	89,49	105,20	71,29	15,14	15,58	90,97	124,32	138,90
24.3.2017.	169,08	178,59	90,24	105,06	70,62	14,90	15,61	90,71	124,15	135,62
31.3.2017.	173,50	178,24	93,06	106,23	69,20	15,11	15,85	92,00	128,08	136,83
7.4.2017.	172,39	178,27	93,34	106,10	67,01	14,83	15,65	91,89	128,30	132,96
14.4.2017.	171,00	177,76	90,70	104,90	66,24	15,04	15,54	90,80	126,52	130,77
21.4.2017.	170,72	178,71	89,11	103,53	66,30	15,89	15,44	90,75	125,75	140,10
28.4.2017.	175,24	183,93	89,83	111,66	68,44	15,75	15,59	92,24	131,12	145,60
5.5.2017.	174,30	184,73	90,70	113,40	68,55	16,17	16,04	94,10	132,14	144,50
12.5.2017.	172,62	176,21	89,69	114,71	68,97	16,68	16,86	94,76	130,19	144,35
19.5.2017.	169,88	172,29	85,89	114,94	67,89	16,19	17,21	93,92	128,17	139,54
26.5.2017.	170,58	172,09	84,19	114,79	65,38	16,95	17,36	94,98	125,88	137,71
2.6.2017.	173,57	171,66	85,35	119,57	65,95	17,66	17,42	96,30	129,30	137,73
9.6.2017.	173,38	170,08	86,55	116,91	65,31	17,94	17,05	94,93	128,97	132,64
16.6.2017.	174,10	174,06	85,03	120,74	65,35	18,51	16,71	94,25	124,21	131,20
23.6.2017.	173,73	168,89	85,15	119,94	65,14	18,72	16,64	95,73	124,78	133,68
30.6.2017.	173,26	168,73	81,91	111,50	63,55	19,74	15,81	91,84	120,74	133,34
7.7.2017.	178,33	176,16	81,30	108,39	63,58	20,10	15,59	90,70	121,00	138,65
14.7.2017.	182,81	180,50	83,42	110,95	64,67	20,72	15,84	91,35	120,43	145,14
21.7.2017.	176,77	177,04	81,02	108,92	62,42	18,39	15,64	89,17	116,07	136,92
28.7.2017.	180,20	192,88	79,89	105,89	59,68	18,27	15,57	90,48	115,95	131,95
4.8.2017.	185,81	199,41	82,05	105,76	60,62	19,30	15,75	91,25	111,65	130,68
11.8.2017.	179,85	191,92	79,83	104,13	59,87	19,42	15,48	88,36	109,24	127,30
18.8.2017.	183,05	189,19	81,43	106,21	60,20	20,83	15,50	89,07	111,39	127,91
25.8.2017.	182,61	187,90	82,26	107,17	62,29	20,62	15,34	88,53	111,20	127,38
1.9.2017.	181,26	190,38	82,47	106,63	61,88	21,49	15,16	88,55	111,22	127,01
8.9.2017.	179,81	194,88	84,20	107,02	64,92	21,79	15,02	90,33	112,34	132,33
15.9.2017.	185,05	198,01	86,15	108,64	66,34	22,33	14,98	91,95	116,70	136,86
22.9.2017.	187,00	192,00	88,65	108,48	66,90	23,02	15,55	92,20	117,00	137,67
29.9.2017.	189,18	191,43	89,69	113,56	67,32	23,26	15,76	92,60	119,45	137,65
6.10.2017.	193,05	192,36	89,80	115,04	68,65	23,92	15,63	94,51	119,87	142,45
13.10.2017.	195,11	193,19	89,11	115,93	67,81	25,25	15,48	95,32	119,95	144,06
20.10.2017.	196,78	187,16	90,25	116,06	68,36	25,39	15,40	95,31	116,15	141,73
27.10.2017.	199,53	191,00	93,65	110,17	70,83	27,10	15,65	98,00	120,29	151,25
3.11.2017.	202,77	183,38	96,99	116,06	73,14	27,83	15,67	99,19	124,06	163,18
10.11.2017.	200,34	181,20	94,02	107,96	70,25	26,71	15,10	96,44	117,30	156,20
17.11.2017.	197,43	185,63	92,00	105,89	69,06	27,93	15,05	96,44	115,02	159,14
24.11.2017.	198,40	180,91	94,80	105,98	70,09	28,50	14,80	97,45	114,13	169,61
1.12.2017.	196,80	175,78	93,20	105,10	68,88	29,07	15,06	93,65	113,50	173,88

8.12.2017.	199,00	181,13	94,30	103,10	70,50	30,10	15,56	95,70	115,65	172,48
15.12.2017.	197,35	172,37	93,61	104,81	70,92	30,00	15,09	97,24	116,75	169,45
22.12.2017.	195,10	169,50	93,55	103,92	71,47	31,09	15,03	94,74	117,52	169,10
29.12.2017.	192,18	167,35	91,80	102,22	70,73	31,26	14,80	93,54	116,35	166,79
5.1.2018.	198,00	172,15	94,67	106,77	72,86	30,40	14,94	96,42	120,28	178,60
12.1.2018.	202,05	168,55	94,69	103,33	74,27	30,00	14,49	90,72	122,22	179,60
19.1.2018.	205,15	182,55	97,55	102,82	74,92	29,80	14,46	92,41	123,94	183,20
26.1.2018.	204,10	184,85	95,55	105,30	74,77	28,60	14,64	91,90	121,80	181,58
2.2.2018.	200,00	179,90	90,65	100,77	71,35	27,60	13,85	87,89	115,02	172,56
9.2.2018.	182,92	174,80	84,20	93,37	69,51	25,60	12,87	81,78	105,30	160,90
16.2.2018.	190,98	180,80	87,14	97,44	72,50	26,60	13,18	84,80	111,40	167,60
23.2.2018.	191,70	181,90	88,13	96,71	71,33	27,40	13,42	84,85	110,96	163,50
2.3.2018.	184,44	173,75	83,32	91,97	67,86	26,40	12,95	82,70	103,70	154,90
9.3.2018.	189,92	174,01	85,13	96,36	67,86	26,00	13,26	88,65	105,92	157,20
16.3.2018.	190,00	195,25	84,89	94,62	69,30	27,40	13,48	87,74	107,44	163,46
23.3.2018.	180,04	195,15	80,79	88,78	65,74	25,40	12,97	83,54	101,38	153,32
30.3.2018.	184,58	196,50	82,11	90,78	69,07	25,80	13,31	85,09	103,80	161,70
6.4.2018	186,34	203,40	83,99	92,12	65,53	26,40	13,47	86,50	104,18	165,02
13.4.2018.	189,00	210,90	84,01	97,33	65,56	26,20	13,96	87,89	104,94	177,38
20.4.2018.	193,26	212,20	86,69	97,19	65,04	26,80	14,11	86,48	108,18	171,46
27.4.2018.	195,00	205,80	86,25	97,23	65,56	24,20	14,53	92,00	105,78	172,74
4.5.2018.	199,24	193,00	86,65	100,00	66,33	24,60	14,47	95,20	109,08	172,90
11.5.2018.	191,44	189,25	86,63	100,42	66,97	24,00	14,26	97,21	115,44	171,94
18.5.2018.	191,22	195,55	88,77	103,03	67,37	24,20	13,47	95,97	117,28	173,00
25.5.2018.	187,02	194,20	87,57	101,36	64,85	24,20	13,35	97,65	115,24	170,06
1.6.2018.	179,86	193,70	85,13	101,62	61,91	23,20	13,23	97,00	113,30	162,22
8.6.2016.	178,68	199,50	85,92	98,27	61,89	22,60	13,31	100,82	113,92	159,74
15.6.2018.	180,54	200,10	87,64	100,18	62,22	22,80	13,57	103,62	119,40	161,74
22.6.2018.	176,00	191,00	83,44	99,25	57,73	22,60	13,57	101,12	116,36	149,80
29.6.2018.	177,16	187,00	81,91	94,80	55,33	20,80	13,30	98,98	113,20	141,88

Prilog 4: Tjedni prinosi odabranih dionica na njemačkom tržištu kapitala

Datum	Allianz	Adidas	BASF	Bayer	Daimler	Deutsche Lufthansa	Deutsche Telekom	SAP	Siemens	Volkswa-gen
10.6.2016.	-5,85%	1,45%	-1,32%	-1,57%	-3,76%	-8,77%	-6,26%	-3,04%	-2,60%	-4,21%
17.6.2016.	-3,08%	-0,69%	-0,15%	0,78%	-1,76%	-1,14%	-3,14%	-2,10%	-0,73%	-4,73%
24.6.2016.	-3,02%	1,85%	-1,19%	-0,81%	-2,05%	-2,87%	-2,05%	-1,13%	-2,49%	-3,79%
1.7.2016.	0,46%	6,53%	3,82%	3,05%	-0,29%	-3,61%	8,29%	0,68%	1,97%	-1,18%
8.7.2016.	-3,57%	-1,50%	-3,08%	0,11%	-1,62%	1,50%	-2,55%	2,27%	-2,72%	-3,85%
15.7.2016.	3,89%	4,34%	6,48%	3,41%	7,66%	3,83%	3,97%	2,88%	5,19%	5,59%
22.7.2016.	-1,75%	4,29%	-0,27%	-1,88%	1,73%	-7,32%	-0,74%	7,83%	0,74%	3,95%
29.7.2016.	2,34%	6,70%	-2,38%	4,40%	2,35%	1,62%	-0,95%	1,46%	2,10%	4,00%
5.8.2016.	-1,77%	-0,04%	-0,62%	-0,57%	0,44%	-1,62%	2,03%	-0,67%	5,30%	-1,97%
12.8.2016.	6,20%	5,53%	4,62%	2,12%	2,64%	4,70%	1,00%	1,05%	4,90%	1,33%

19.8.2016.	-3,54%	0,87%	-1,00%	-1,39%	-2,11%	-5,66%	-3,02%	-0,58%	-0,61%	-4,51%
26.8.2016.	-0,88%	-2,54%	0,03%	-0,57%	-0,10%	-0,19%	-1,44%	-0,57%	0,56%	3,01%
2.9.2016.	5,10%	-5,26%	1,38%	-1,09%	2,37%	2,02%	0,55%	3,52%	0,94%	1,17%
9.9.2016.	0,72%	-0,01%	-0,98%	0,25%	0,59%	4,84%	-1,74%	-1,99%	-3,44%	-0,17%
16.9.2016.	-4,70%	3,14%	-2,31%	-4,68%	-4,09%	-6,47%	-1,98%	-1,05%	-0,47%	-4,62%
23.9.2016.	4,53%	3,46%	3,96%	0,79%	4,69%	-0,29%	4,81%	4,54%	1,80%	0,44%
30.9.2016.	-2,83%	0,12%	3,12%	-2,30%	-1,36%	-2,86%	-1,72%	-0,22%	-1,43%	-1,92%
7.10.2016.	2,66%	0,16%	2,93%	0,63%	2,13%	-7,90%	-3,81%	-1,52%	0,28%	1,03%
14.10.2016.	1,61%	1,24%	1,02%	0,55%	0,45%	10,67%	-0,07%	-1,31%	0,49%	2,05%
21.10.2016.	1,30%	-0,05%	0,85%	-0,26%	0,71%	8,30%	1,00%	3,17%	1,20%	2,30%
28.10.2016.	1,18%	-5,00%	0,85%	0,44%	0,59%	3,69%	2,26%	-1,46%	-2,96%	1,65%
4.11.2016.	-3,71%	-11,96%	-3,62%	-2,96%	-4,96%	0,69%	-3,11%	-4,25%	-1,98%	-5,11%
11.11.2016.	10,32%	0,76%	4,52%	6,57%	4,02%	6,95%	0,29%	-0,46%	6,65%	-1,22%
18.11.2016.	-0,19%	3,95%	-0,97%	-2,38%	1,25%	0,95%	0,14%	1,97%	-1,69%	-0,22%
25.11.2016.	-0,02%	0,14%	0,31%	-2,88%	-1,05%	-0,95%	2,12%	2,95%	0,76%	6,19%
2.12.2016.	-2,04%	-0,38%	0,50%	-1,81%	-3,34%	-4,08%	-0,56%	-4,54%	-1,51%	-5,02%
9.12.2016.	6,16%	4,12%	5,24%	7,50%	8,85%	5,51%	6,81%	3,46%	8,25%	7,36%
16.12.2016.	-0,31%	0,46%	2,55%	3,09%	2,84%	1,25%	1,37%	2,02%	0,66%	2,38%
23.12.2016.	0,02%	-0,40%	-0,30%	1,13%	0,81%	-0,55%	0,71%	0,32%	-0,52%	4,79%
30.12.2016.	-0,15%	3,67%	0,99%	0,41%	-0,16%	-4,15%	1,47%	1,25%	1,26%	-2,90%
6.1.2017.	2,89%	-3,26%	-0,66%	3,62%	1,81%	1,62%	1,64%	1,62%	-0,15%	4,37%
13.1.2017.	-0,42%	1,93%	1,86%	-0,83%	-1,12%	-8,80%	-1,38%	0,26%	-0,03%	6,89%
20.1.2017.	-0,68%	2,68%	0,45%	0,44%	-1,13%	5,37%	0,19%	-0,62%	0,61%	-1,44%
27.1.2017.	1,67%	1,22%	1,84%	4,14%	0,44%	4,78%	-0,25%	1,89%	2,02%	1,74%
3.2.2017.	-2,17%	-4,29%	-2,18%	-2,78%	-4,13%	-2,89%	-2,05%	0,36%	-0,82%	-3,29%
10.2.2017.	-1,03%	1,36%	-0,70%	2,45%	-0,86%	2,89%	0,06%	1,02%	1,34%	-1,80%
17.2.2017.	3,83%	-0,46%	0,56%	0,39%	0,36%	3,73%	-0,71%	0,36%	0,57%	-0,88%
24.2.2017.	0,56%	2,28%	-1,80%	-2,03%	1,69%	3,52%	3,33%	1,57%	1,29%	0,90%
3.3.2017.	2,34%	5,62%	3,44%	2,88%	1,82%	0,88%	-1,40%	1,18%	2,30%	1,89%
10.3.2017.	0,90%	10,76%	-1,30%	-0,64%	0,04%	5,19%	-0,77%	-0,24%	-1,50%	-2,35%
17.3.2017.	0,74%	2,14%	0,21%	0,25%	1,90%	4,80%	0,32%	2,18%	0,96%	-2,02%
24.3.2017.	-0,85%	-2,41%	0,83%	-0,13%	-0,94%	-1,60%	0,19%	-0,29%	-0,14%	-2,39%
31.3.2017.	2,58%	-0,20%	3,08%	1,11%	-2,03%	1,40%	1,53%	1,41%	3,12%	0,89%
7.4.2017.	-0,64%	0,02%	0,30%	-0,12%	-3,22%	-1,87%	-1,27%	-0,12%	0,17%	-2,87%
14.4.2017.	-0,81%	-0,29%	-2,87%	-1,14%	-1,16%	1,41%	-0,71%	-1,19%	-1,40%	-1,66%
21.4.2017.	-0,16%	0,53%	-1,77%	-1,31%	0,09%	5,50%	-0,65%	-0,06%	-0,61%	6,89%
28.4.2017.	2,61%	2,88%	0,80%	7,56%	3,18%	-0,88%	0,97%	1,63%	4,18%	3,85%
5.5.2017.	-0,54%	0,43%	0,96%	1,55%	0,16%	2,63%	2,85%	2,00%	0,77%	-0,76%
12.5.2017.	-0,97%	-4,72%	-1,12%	1,15%	0,61%	3,11%	4,99%	0,70%	-1,49%	-0,10%
19.5.2017.	-1,60%	-2,25%	-4,33%	0,20%	-1,58%	-2,98%	2,05%	-0,89%	-1,56%	-3,39%
26.5.2017.	0,41%	-0,12%	-2,00%	-0,13%	-3,77%	4,59%	0,87%	1,12%	-1,80%	-1,32%
2.6.2017.	1,74%	-0,25%	1,37%	4,08%	0,87%	4,10%	0,35%	1,38%	2,68%	0,01%
9.6.2017.	-0,11%	-0,92%	1,40%	-2,25%	-0,98%	1,57%	-2,15%	-1,43%	-0,26%	-3,77%
16.6.2017.	0,41%	2,31%	-1,77%	3,22%	0,06%	3,13%	-2,01%	-0,72%	-3,76%	-1,09%
23.6.2017.	-0,21%	-3,02%	0,14%	-0,66%	-0,32%	1,13%	-0,42%	1,56%	0,46%	1,87%

30.6.2017.	-0,27%	-0,09%	-3,88%	-7,30%	-2,47%	5,31%	-5,12%	-4,15%	-3,29%	-0,25%
7.7.2017.	2,88%	4,31%	-0,75%	-2,83%	0,05%	1,81%	-1,40%	-1,25%	0,22%	3,91%
14.7.2017.	2,48%	2,43%	2,57%	2,33%	1,70%	3,04%	1,59%	0,71%	-0,47%	4,57%
21.7.2017.	-3,36%	-1,94%	-2,92%	-1,85%	-3,54%	-11,93%	-1,27%	-2,42%	-3,69%	-5,83%
28.7.2017.	1,92%	8,57%	-1,40%	-2,82%	-4,49%	-0,65%	-0,45%	1,46%	-0,10%	-3,70%
4.8.2017.	3,07%	3,33%	2,67%	-0,12%	1,56%	5,48%	1,15%	0,85%	-3,78%	-0,97%
11.8.2017.	-3,26%	-3,83%	-2,74%	-1,55%	-1,24%	0,62%	-1,73%	-3,22%	-2,18%	-2,62%
18.8.2017.	1,76%	-1,43%	1,98%	1,98%	0,55%	7,01%	0,13%	0,80%	1,95%	0,48%
25.8.2017.	-0,24%	-0,68%	1,01%	0,90%	3,41%	-1,01%	-1,04%	-0,61%	-0,17%	-0,42%
1.9.2017.	-0,74%	1,31%	0,25%	-0,51%	-0,66%	4,13%	-1,18%	0,02%	0,02%	-0,29%
8.9.2017.	-0,80%	2,34%	2,08%	0,37%	4,80%	1,39%	-0,93%	1,99%	1,00%	4,10%
15.9.2017.	2,87%	1,59%	2,29%	1,50%	2,16%	2,45%	-0,27%	1,78%	3,81%	3,37%
22.9.2017.	1,05%	-3,08%	2,86%	-0,15%	0,84%	3,04%	3,73%	0,27%	0,26%	0,59%
29.9.2017.	1,16%	-0,30%	1,17%	4,58%	0,63%	1,04%	1,34%	0,43%	2,07%	-0,01%
6.10.2017.	2,03%	0,48%	0,12%	1,29%	1,96%	2,80%	-0,83%	2,04%	0,35%	3,43%
13.10.2017.	1,06%	0,43%	-0,77%	0,77%	-1,23%	5,41%	-0,96%	0,85%	0,07%	1,12%
20.10.2017.	0,85%	-3,17%	1,27%	0,11%	0,81%	0,55%	-0,52%	-0,01%	-3,22%	-1,63%
27.10.2017.	1,39%	2,03%	3,70%	-5,21%	3,55%	6,52%	1,61%	2,78%	3,50%	6,50%
3.11.2017.	1,61%	-4,07%	3,50%	5,21%	3,21%	2,66%	0,13%	1,21%	3,09%	7,59%
10.11.2017.	-1,21%	-1,20%	-3,11%	-7,23%	-4,03%	-4,11%	-3,71%	-2,81%	-5,60%	-4,37%
17.11.2017.	-1,46%	2,42%	-2,17%	-1,94%	-1,71%	4,47%	-0,33%	0,00%	-1,96%	1,86%
24.11.2017.	0,49%	-2,58%	3,00%	0,08%	1,48%	2,02%	-1,68%	1,04%	-0,78%	6,37%
1.12.2017.	-0,81%	-2,88%	-1,70%	-0,83%	-1,74%	1,98%	1,74%	-3,98%	-0,55%	2,49%
8.12.2017.	1,11%	3,00%	1,17%	-1,92%	2,32%	3,48%	3,27%	2,17%	1,88%	-0,81%
15.12.2017.	-0,83%	-4,96%	-0,73%	1,64%	0,59%	-0,33%	-3,07%	1,60%	0,95%	-1,77%
22.12.2017.	-1,15%	-1,68%	-0,06%	-0,85%	0,77%	3,57%	-0,40%	-2,60%	0,66%	-0,21%
29.12.2017.	-1,51%	-1,28%	-1,89%	-1,65%	-1,04%	0,55%	-1,54%	-1,27%	-1,00%	-1,38%
5.1.2018.	2,98%	2,83%	3,08%	4,35%	2,97%	-2,79%	0,94%	3,03%	3,32%	6,84%
12.1.2018.	2,02%	-2,11%	0,02%	-3,27%	1,92%	-1,32%	-3,06%	-6,09%	1,60%	0,56%
19.1.2018.	1,52%	7,98%	2,98%	-0,49%	0,87%	-0,67%	-0,21%	1,85%	1,40%	1,98%
26.1.2018.	-0,51%	1,25%	-2,07%	2,38%	-0,20%	-4,11%	1,24%	-0,55%	-1,74%	-0,89%
2.2.2018.	-2,03%	-2,71%	-5,26%	-4,40%	-4,68%	-3,56%	-5,55%	-4,46%	-5,73%	-5,10%
9.2.2018.	-8,93%	-2,88%	-7,38%	-7,63%	-2,61%	-7,52%	-7,34%	-7,21%	-8,83%	-7,00%
16.2.2018.	4,31%	3,37%	3,43%	4,27%	4,21%	3,83%	2,38%	3,63%	5,63%	4,08%
23.2.2018.	0,38%	0,61%	1,13%	-0,75%	-1,63%	2,96%	1,80%	0,06%	-0,40%	-2,48%
2.3.2018.	-3,86%	-4,58%	-5,61%	-5,03%	-4,99%	-3,72%	-3,57%	-2,57%	-6,77%	-5,40%
9.3.2018.	2,93%	0,15%	2,15%	4,66%	0,00%	-1,53%	2,37%	6,95%	2,12%	1,47%
16.3.2018.	0,04%	11,52%	-0,28%	-1,82%	2,10%	5,24%	1,65%	-1,03%	1,42%	3,90%
23.3.2018.	-5,38%	-0,05%	-4,95%	-6,37%	-5,27%	-7,58%	-3,86%	-4,91%	-5,81%	-6,40%
30.3.2018.	2,49%	0,69%	1,62%	2,23%	4,94%	1,56%	2,59%	1,84%	2,36%	5,32%
6.4.2018	0,95%	3,45%	2,26%	1,47%	-5,26%	2,30%	1,19%	1,64%	0,37%	2,03%
13.4.2018.	1,42%	3,62%	0,02%	5,50%	0,05%	-0,76%	3,57%	1,59%	0,73%	7,22%
20.4.2018.	2,23%	0,61%	3,14%	-0,14%	-0,80%	2,26%	1,07%	-1,62%	3,04%	-3,39%
27.4.2018.	0,90%	-3,06%	-0,51%	0,04%	0,80%	-10,20%	2,93%	6,19%	-2,24%	0,74%
4.5.2018.	2,15%	-6,42%	0,46%	2,81%	1,17%	1,64%	-0,41%	3,42%	3,07%	0,09%

11.5.2018.	-3,99%	-1,96%	-0,02%	0,42%	0,96%	-2,47%	-1,46%	2,09%	5,67%	-0,56%
18.5.2018.	-0,11%	3,27%	2,44%	2,57%	0,60%	0,83%	-5,70%	-1,28%	1,58%	0,61%
25.5.2018.	-2,22%	-0,69%	-1,36%	-1,63%	-3,81%	0,00%	-0,89%	1,74%	-1,75%	-1,71%
1.6.2018.	-3,90%	-0,26%	-2,83%	0,26%	-4,64%	-4,22%	-0,90%	-0,67%	-1,70%	-4,72%
8.6.2016.	-0,66%	2,95%	0,92%	-3,35%	-0,03%	-2,62%	0,60%	3,86%	0,55%	-1,54%
15.6.2018.	1,04%	0,30%	1,98%	1,92%	0,53%	0,88%	1,93%	2,74%	4,70%	1,24%
22.6.2018.	-2,55%	-4,65%	-4,91%	-0,93%	-7,49%	-0,88%	0,00%	-2,44%	-2,58%	-7,67%
29.6.2018.	0,66%	-2,12%	-1,85%	-4,59%	-4,25%	-8,30%	-2,01%	-2,14%	-2,75%	-5,43%

POPIS SLIKA

Slika 1: Skup mogućih portfelja

Slika 2: Skup minimalne varijance i efikasna granica

Slika 3: Sistematski i nesistematski rizik u odnosu na ukupni rizik

Slika 4: Vrijednost CROBEX-a za razdoblje od pet godina (17.06.2013.- 15.06.2018.)

Slika 5: Promet na Zagrebačkoj burzi

Slika 6: Promet i zaključna cijena najaktivnijih dionica u sastavu indeksa DAX na dan 02.07.2018. godine

Slika 7: Kretanje indeksa DAX u razdoblju od tri godine (02.07.2015.-02.07.2018.)

Slika 8: Sastav CROBEX10

Slika 9: Odabrane dionice njemačkog tržišta kapitala

POPIS TABLICA

Tablica 1: Tržišna kapitalizacija Zagrebačke burze za razdoblje 2013.-2017. godine u milijardi kuna

Tablica 2: Broj uvrštenih vrijednosnica na Zagrebačkoj burzi

Tablica 3: Promet na Zagrebačkoj burzi u milijunima kuna

Tablica 4: Zaključna cijena CROBEX-a i stanje prometa dionica u sastavu indeksa

Tablica 5: Tržišna kapitalizacija Njemačke burze izražena u mil. €

Tablica 6: Broj domaćih i stranih poduzeća čije su dionice uvrštene na Njemačkoj burzi

Tablica 7: Zaključna cijena indeksa DAX

Tablica 8: Zaključne tjedne cijene odabranih dionica hrvatskog tržišta kapitala

Tablica 9: Tjedni prinosi odabranih dionica hrvatskog tržišta kapitala

Tablica 10: Očekivani tjedni prinos i rizik odabranih dionica na hrvatskom tržištu kapitala

Tablica 11: Matrica varijanci i kovarijanci na hrvatskom tržištu kapitala

Tablica 12: Portfelji na efikasnoj granici kada kratka prodaja nije dozvoljena na hrvatskom tržištu kapitala

Tablica 13: Kolmogorov – Smirnov test za normalnu distribuciju na hrvatskom tržištu kapitala

Tablica 14: Tjedne zaključne cijene odabranih dionica na njemačkom tržištu kapitala

Tablica 15: Tjedni prinosi odabranih dionica njemačkog tržišta kapitala

Tablica 16: Očekivani tjedni prinos i rizik na njemačkom tržištu kapitala

Tablica 17: Matrica varijanci i kovarijanci na njemačkom tržištu kapitala

Tablica 18: Portfelji na efikasnoj granici kada kratka prodaja nije dozvoljena na njemačkom tržištu kapitala

Tablica 19: Kolmogorov – Smirnov test za normalnu distribuciju na njemačkom tržištu kapitala

POPIS GRAFIKONA

Grafikon 1: Efikasna granica portfelja na hrvatskom tržištu kapitala

Grafikon 2: Efikasna granica portfelja na njemačkom tržištu kapitala

Grafikon 3: Usporedba efikasne granice hrvatskog i njemačkog tržišta kapitala

SAŽETAK

Cilj rada bio je usporedba odnosa prinosa i rizika dva tržišta kapitala primjenom Markowitzeva modela. U analizi su bile korištene dvije zemlje, Hrvatska s tržištem kapitala u nastajanju, te Njemačka s razvijenim tržištem kapitala. Radom se zapravo nastojalo utvrditi da li u Hrvatskoj investitori mogu ostvariti veće prinose uz veću razinu rizika u odnosu na njemačko tržište kapitala.

Nakon teorijskog dijela u kojem je objašnjen Markowitzev model, prezentirana su oba tržišta kapitala pojedinačno, s njihovim glavnim burzama vrijednosnih papira. U praktičnom dijelu, izvršena je analiza dionica prema spomenutom modelu, kako bi se donio zaključak o prihvaćanju ili odbacivanju postavljenih hipoteza. Nakon analize za svako tržište kapitala pojedinačno, donosi se zaključak kako se na hrvatskom tržištu kapitala mogu ostvariti veći prinosi ali uz veći rizik, u odnosu na njemačko tržište kapitala, gdje investitori ostvaruju manje prinose ali uz manju razinu rizika. Također, uz glavnu hipotezu postavljena je i dodatna hipoteza, koja navodi da su prinosi oba tržišta kapitala normalno distribuirani. Navedena hipoteza se djelomično prihvaća jer prinosi dionica na hrvatskom tržištu kapitala nemaju u potpunosti normalan oblik distribucije.

Ključne riječi: Markowitzev model, hrvatsko tržište kapitala, njemačko tržište kapitala, odnos prinosa i rizika, normalna distribucija

SUMMARY

The aim of the paper was to compare the yield and risk ratio of the two capital markets using the Markowitz model. In the analyzes were used two countries, Croatia with emerging capital market, and Germany with developed capital market. The paper was actually attempting to determine whether Croatian investors could achieve higher returns with a higher level of risk than the German capital market.

After the theoretical part explaining Markowitz's model, both capital markets were presented individually, with their major stock exchanges. In the practical part, a stock analysis was performed according to the mentioned model in order to conclude on the acceptance or rejection of the set hypothesis. After analyzing each capital market individually, it is concluded that on the Croatian capital market can be achieved higher yields, but with a higher risk, compared to the German capital market, where investors yield lower returns but with a lower level of risk. Also, along with the main hypothesis, there is an additional hypothesis that the yields of both capital markets are normally distributed. This hypothesis is partially accepted because yields of shares of the Croatian capital market don't have a completely normal distribution form.

Key words: Markowitz model, the Croatian capital market, the German capital martket, yield and risk ratio, normal distribution