ODABIR OPTIMALNOG PORTFELJA KOMBINIRANOM PRIMJENOM FUNDAMENTALNE I TEHNIČKE ANALIZE, TE MATEMATIČKIH MODELA

Zubović, Emili

Master's thesis / Diplomski rad

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:855964

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

ODABIR OPTIMALNOG PORTFELJA KOMBINIRANOM PRIMJENOM FUNDAMENTALNE I TEHNIČKE ANALIZE, TE MATEMATIČKIH MODELA

Mentorica:

prof. dr. sc. Zdravka Aljinović

Studentica:

Emili Zubović, mag.ing.aedif.

Matični broj: 2142643

Split, kolovoz 2017.

SADRŽAJ

1. UVOD 4

1.1. Problem istraživanja 4

1.2. Predmet istraživanja 6

1.3. Svrha i ciljevi istraživanja 6

1.4. Istraživačke hipoteze 7

1.5. Metodologija istraživanja 7

1.6. Doprinos istraživanja 9

1.7. Sadržaj diplomskog rada 10

2. Fundamentalna analiza 12

2.1. Općenito o fundamentalnoj analizi 12

2.2. Makroekonomska analiza i analiza djelatnosti 12

2.3. Analiza uspješnosti poslovanja poduzeća 15

2.3.1. Pokazatelji likvidnosti 15

2.3.2. Pokazatelji zaduženosti 16

2.3.3. Pokazatelji menadžmenta imovine 16

2.3.4. Pokazatelji profitabilnosti 17

2.3.5. Pokazatelji investiranja 18

2.3.6. Skupni pokazatelji 19

2.4. Metode procjene vrijednosti poduzeća 20

2.4.1. Statički pristup 20

2.4.2. Dinamički pristup 22

2.4. Primjena odabranih pokazatelja fundamentalne analize u odabiru dionica na hrvatskom tržištu kapitala 26

2.4.1. Odabir uzorka poduzeća 26

2.4.2. Sektorska analiza odabranih poduzeća iz početnog uzorka 31

2.4.3. Analiza uspješnosti poslovanja odabranog uzorka poduzeća 33

2.4.3.1. Pokazatelji likvidnosti 33
2.4.3.2. Pokazatelji zaduženosti 36
2.4.3.3. Pokazatelji profitabilnosti 39
2.4.3.4. Skupni pokazatelji 40
2.4.4. Procjena vrijednosti poduzeća knjigovodstvenom metodom 43
2.4.5. Procjena vrijednosti poduzeća metodom multiplikatora 46
2.4.5.1. Procjena vrijednosti poduzeća P/E multiplikatorom 47
2.4.5.2. Procjena vrijednosti poduzeća P/B multiplikatorom 50
3. Matematički model u odabiru optimalnog portfelja 56
3.1. Markowitzev model optimizacije portfelja – teoretske postavke 56
3.1.1. Osnovni pojmovi i definicije 57
3.2. Primjena Markowitzevog modela optimizacije portfelja na hrvatskom tržištu kapitala 62
4. Tehnička analiza 70
4.1. Teoretska osnova 70
4.1.1. Grafikoni 71
4.1.2. Trend 73
4.1.2.1. Dow teorija 73
4.1.3. Grafičke formacije 75
4.1.4. Indikatori 77
4.1.4.1. Pomični prosjeci 77
4.1.4.2. Bollingerov pojas (eng. bollinger bands) 79
4.1.4.3. Oscilatori 80
4.1.4.3.1. Momentum 80
4.1.4.3.2. Indeks relativne snage - RSI (eng. Relative Strenght Index) 80
4.1.4.3.3. MACD (eng. Moving average convergence-divergence) 81
4.2. Primjena tehničke analize na hrvatskom tržištu kapitala 82
5. Zaključak 104

Literatura 106
Popis slika 111
Popis tablica 114
Sažetak 116
Summary 117

1. UVOD

1.1. Problem istraživanja

Dionice se mogu definirati na više načina: to su vrijednosni papiri koji reprezentiraju idealni dio vlasništva nekog dioničkog poduzeća, tj. to su dugoročni vrijednosni papiri bez unaprijed utvrđenog dospijeća, odnosno povrata uloženog iznosa. Dionica predstavlja skup svih prava i obveza vezanih za članstvo u dioničkom društvu, odnosno osigurava vlasnicima udio u poslovnom rezultatu (dobiti) dioničkog poduzeća, a u slučaju likvidacije poduzeća, udio u likvidacijskoj masi poduzeća nakon što su podmireni interesi njegovih vjerovnika.[1]
Prodajom dionica na primarnom tržištu (kada se dionica prodaje prvi put) poduzeće prikuplja ulagački kapital od kupaca dionica, koji zatim mogu trgovati istim dionicama na sekundarnom tržištu, pri čemu poduzeće emitent dionice ne sudjeluje u transakciji ni na koji način.[2]
Želja svakog investitora u dionice je kupiti dionicu po najnižoj cijeni, te prodati dionicu po najvišoj cijeni. Također, pri investiranju u dionice, racionalni investitor neće uložiti sav novac u dionice istog poduzeća, odnosno neće "staviti sva jaja u jednu košaru", jer time riskira veliki gubitak. Uobičajna praksa racionalnog investitora je diverzificirano ulaganje, odnosno ulaganje u dionice različitih poduzeća, kako bi umanjio rizik neostvarivanja povrata na uloženo. Svaki racionalni investitor pri donošenju odluke o trgovanju dionicama, iste će prethodno analizirati, kako bi formirao optimalni portfelj koji će mu donijeti određeni povrat.

Investitori pri odabiru optimalnog portfelja najčešće koriste matematičke modele. Jedan od najpopularnijih matematičkih modela analize dionica je Markowitzev model optimizacije portfelja, poznat i kao M-V model (Mean – Variance model), kojim se nužno ne maksimalizira očekivani prinos portfelja, već se uz određeni stupanj rizika maksimalizira profit, odnosno za zadanu stopu prinosa minimalizira se rizik ulaganja. Dakle, Markowitzevim modelom optimizira se odnos između očekivanog prinosa i rizika. Investitori koji nisu skloni riziku izabrat će portfelj koji ima manji rizik, ali i daje manji očekivani prinos, dok će ulagači skloniji riziku odabrati portfelj s većim rizikom, ali i većim očekivanim prinosom. Markowitzev model kao pretpostavku uzima normalnu distribuciju prinosa. Prednost te distribucije je činjenica da se definira samo s dva parametra: varijancom i očekivanom vrijednosti. Iako se pretpostavka normalne distribucije često koristi u financijskoj

[1] Baletić, Z. (urednik): *Ekonomski leksikon*, Leksikografski zavod Miroslav Krleža, Zagreb, 1996. (izdanje na CD ROM-u)
[2] Sabolić, D.: *Financijska tržišta I., Krediti, obveznice, dionice, Bilješke s predavanja*, Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Zagreb, 2013., str. 256.

analizi, istraživanja provedena na različitim tržištima kapitala pokazala su da pretpostavka o normalnoj distribuciji prinosa često nije zadovoljena u praksi.[3]

Nedostatak Markowitzevog modela je njegova statičnost. Primjenom tog modela pri analizi dionica dobiva se informacija u koje bi se dionice uz određeni stupanj rizika trebalo uložiti, ali ne dobiva se informaciju kada je napovoljniji trenutak za kupnju ili prodaju dionice.

Osim primjene matematičkih modela analize dionica, potrebno je izvršiti fundamentalnu analizu, odnosno sagledati sve aspekte poslovanja promatranih poduzeća. Fundamentalna analiza pretpostavlja temeljnu analizu financijskih izvješća poduzeća, ali nastavlja se ukupnom ekonomskom analizom sposobnosti menadžmenta poduzeća, sektora u kojem se poduzeće nalazi, te sveukupnog mikro i makroekonomskog okruženja u kojem poduzeće posluje. Fundamentalnom analizom analitičar procjenjuje buduće zarade poduzeća, dividende, kamatne stope, te rizike koje se nalaze pred pojedinim poduzećem ili sektorom. Cilj fundamentalne analize jest otkriti dionicu poduzeća koja je prema navedenim kriterijima još uvijek podcijenjena.[4] Fundamentalnom se analizom, uz makroekonomsku analizu i analizu djelatnosti, vrši analiza financijskih izvještaja i pokazatelja, kao što su pokazatelji profitabilnosti, zaduženosti, obrtaja imovine, likvidnosti, analiza pokazatelja efikasnosti investiranja dioničara, analiza dodane vrijednosti…

Vrijednost pokazatelja se može uspoređivati s planiranim pokazateljem izvedenim iz racionalnih očekivanja, s pokazateljem istog poduzeća u drugom vremenskom trenutku ili periodu, te s istim pokazateljem u poduzećima iz iste djelatnosti.[5] Fundamentalna analiza se najčešće primjenjuje prilikom dugoročnih ulaganja jer tržišna cijena može odstupati značajno od fer vrijednosti duži vremenski period.[6] Osim navedenih metoda, pri odabiru dionica u koje će ulagati, investitori često koriste i tehničku analizu, koja predstavlja pokušaj iskorištavanja ponavljajućih i predvidivih obrazaca kretanja cijena dionica kako bi se ostvarili nadprosječni profiti na trgovanju.[7]

Za razliku od fundamentalne, tehnička analiza ne pokušava procijeniti fer vrijednost kompanije, već isključivo smjer i intenzitet kretanja cijene na temelju povijesnih kretanja cijena i volumena, te obrazaca ponašanja mase. Analitičari koji koriste tehničku analizu donose odluke na temelju tehničkih signala koje generira analiza pokušavajući procijeniti

[3] Marasović, B.: *Model za rebalans portfelja s uključenim transakcijskim troškovima i donjom poluapsolutnom devijacijom kao mjerom rizika*, Ekonomska misao i praksa, god. XXV. (2016.), br. 2, str. 516.

[4] Effect d.o.o. za reviziju i ekonomski konzalting - Dubrovnik, rubrika *Spektar, Fundamentalna i tehnička analiza* http://www.effect.hr/, 06.01.2017.

[5] Ibid

[6] Agram brokeri, *Uvod u tehničku analizu*, http://www.agram-brokeri.hr/UserDocsImages/publikacije/Uvod%20u%20tehni%C4%8Dku%20analizu.pdf, 07.01.2017.

[7] Bodie, Z., Kane, A., Marcus, A. J.: *Počela ulaganja*, IV. Izdanje, Mate, Zagreb, 2006., str. 476.

psihološke obrasce ponašanja tržišta.[8] Tehnička analiza podrazumijeva proučavanje povijesnih podataka o cijenama dionica ili burzovnih indeksa, te u njima uz pomoć statističkih metoda pokušava raspoznati periodičnost pojava, kako bi se predvidila njihova buduća kretanja. Tehnička analiza temelji se na vjerovanju da se sve što može utjecati na cijenu već odražava u tržišnoj cijeni. Ovom metodom moguće je odabrati približno najpovoljniji trenutak kupnje, odnosno prodaje određene dionice. Dakle, tehnička metoda donekle "rješava" problem statičnosti Markowitzevog modela.

Iako se tehnička analiza koristi već stoljećima, i dalje nailazi na brojne kritike kritičara koji smatraju da dosljednost profitabilnosti upotrebom te metode nije dokazana.

1.2. Predmet istraživanja

Pri analizi dionica i odabiru optimalnog portfelja investitori uglavnom koriste neku od navedenih metoda. U ovom radu će se teorijski i empirijski istražiti i analizirati različite metode odabira optimalnog portfelja, te će se konačni odabir optimalnog portfelja izvršiti kombinacijom navedenih metoda: fundamentalnom i tehničkom analizom, te matematičkih modela.

Najprije će se primjenom fundamentalne analize izabrati uzorak dionica, a zatim će se matematičkim modelom, odnosno Markowitzevim modelom optimizacije portfelja formirati optimalni portfelj. Tehničkom analizom pokušat će se procijeniti najpovoljniji trenutak za prodaju, odnosno kupnju određene dionice.

1.3. Svrha i ciljevi istraživanja

Cilj ovog rada je odabir optimalnog portfelja kombiniranom primjenom postojećih metoda analize dionica, kako bi se maksimalno iskoristile prednosti svake od navedenih metoda. Svrha rada je pokazati kako iskombinirati tri navedene metode u jedan postupak odabira optimalnog portfelja.

[8] Agram brokeri, Op.cit.

1.4. Istraživačke hipoteze

Temeljna radna hipoteza je sljedeća:

Kombiniranom primjenom fundamentalne i tehničke analize, te matematičkih modela omogućuje se dobivanje šire slike o poslovanju i vrijednosti promatranih poduzeća, a tako i izbor " "kvalitetnog" uzorka dionica, formiranje optimalnog portfelja koji će uz određeni stupanj rizika maksimalizirati profit, te procjena najpovoljnijeg trenutka za rebalans portfelja.

Pomoćne istraživačke hipoteze koje ovaj rad treba ispitati su sljedeće:

1. Fundamentalna analiza je metoda kojom treba započeti proces analize dionica pri odabiru optimalnog portfelja, kako bi promatranjem sveukupnog mikroekonomskog i makroekonomskog okruženja u kojem poduzeća posluju, odnosno procjenom smjera kretanja gospodarstva i određenog sektora djelatnosti, te analizom financijskih izvještaja i pokazatelja otkrili podcijenjenu ili precijenjenu dionicu, te u istu uložili, odnosno izbacili ju iz portfelja.
2. Tehničkom analizom je proučavanjem povijesnih podataka o cijenama dionica ili burzovnih indeksa moguće raspoznati periodičnost pojava, što bi trebalo omogućiti procjenu približno najpovoljnijeg trenutka za kupnju ili prodaju određene dionice.
3. Markowitzevim modelom moguće je odabrati optimalni portfelj koji će za određenu razinu rizika maksimalizirati očekivane prinose na hrvatskom tržištu kapitala, čak i ako nije zadovoljen uvjet normalne distribucije prinosa.

1.5. Metodologija istraživanja

Diplomski rad će se sastojati od teorijskog i empirijskog dijela istraživanja.

U teorijskom dijelu rada i pri donošenju zaključaka koristit će se induktivna metoda, deduktivna metoda, metoda kompilacije, metoda analize, sinteze, klasifikacije, dokazivanja, opovrgavanja, deskripcije, komparativna metoda, metoda generalizacije, specijalizacije, apstrakcije i konkretizacije. Induktivnom metodom se otkrivaju uzročno posljedične veze između događaja koji prethode i događaja koji slijede, donoseći opći zaključak na temelju analize pojedinačnih pojava, dok se deduktivnom metodom pretpostavlja poznavanje općih stavova na temelju kojih se donosi zaključak o pojedinačnim događajima. Metoda kompilacije je postupak preuzimanja tuđih rezultata znanstvenoistraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja.[9] Metodom analize se raščlanjuju složeni pojmovi,

[9] Kulenović, Z., Slišković, M.: *Metodologija znanstvenoistraživačkog rada, Metoda kompilacije*, Sveučilište u Splitu, Pomorski fakultet, http://www.pfst.unist.hr/ , 07.01.2017.

sudovi i zaključci na njihove jednostavnije sastavne dijelove i elemente.[10] Metodom sinteze se jednostavni zaključci spajaju u složene zaključke. Metoda klasifikacije najstarija je i najjednostavnija znanstvena metoda. Klasifikacija je sistematska i potpuna podjela općega pojma na posebne, u okviru opsega pojma.[11] Metodom dokazivanja utvrđuje se istinitost pojedinih stavova na temelju znanstvenih činjenica ili na temelju ranije utvrđenih istinitih stavova, zbog utvrđivanja točnosti neke spoznaje, stava ili teorije. Metodom opovrgavanja teza se odbacuje i pobija. Metodom deskripcije jednostavno se opisuje činjenica ili neka pojava u prirodi, bez znanstvenog tumačenja i objašnjavanja.

Komparativnom metodom se uspoređuju iste ili srodne činjenice, pojave, procesi i odnosi, odnosno utvrđuju se njihove sličnosti i razlike.[12]

Metoda generalizacije je misaoni postupak uopćavanja kojim se od jednog posebnog pojma dolazi do općenitijeg koji je po stupnju viši od ostalih pojedinačnih.[13]

Metoda specijalizacije je postupak kojim se od općeg pojma dolazi do novog pojma, manjeg opsega, a većeg sadržaja. Specijalizacija se temelji na analitičko - sintetičkoj metodi i apstraktno - konkretiziranoj metodi. Da bi se tom metodom došlo od općeg do posebnog, potrebno je izvršiti: konkretizaciju općeg u posebno, ili sintezu, apstrakciju posebnog iz općeg i analizu stvarnog općeg.[14] Apstrakcija je misaoni postupak bilo kakvog odvajanja, bilo odvajanje općeg i eliminiranje posebnog, bilo misaoni postupak odvajanja posebnog i individualnog, zanemarivanje općeg. Apstrakcijom se odvajaju nebitni od bitnih elemenata pojave ili predmeta istraživanja.[15] Konkretizacija je postupak suprotan apstrakciji. Konkretizacija može biti: shvaćanje jedinstva apstraktno - općeg u posebnom i individualnom, shvaćanje jedinstva apstraktno - posebnog s općim u svakom predmetu ili pojavi.[16]

U empirijskom dijelu rada, konkretnije pri formiranju optimalnog portfelja Markowitzevim modelom koristit će se matematičke i statističke metode, te povijesna metoda. Pri fundamentalnoj analizi poduzeća koristit će se povijesna metoda, metoda analize, sinteze, deskripcije, klasifikacije, komparacije, apstrakcije, konkretizacije i matematičke metode.

Pri tehničkoj analizi koristit će se povijesna metoda, statističke metode, matematičke metode, te induktivna i deduktivna metoda.

---

[10] *Metode znanstvenih istraživanja, Metoda analize*, http://www.unizd.hr/, 07.01.2017.
[11] *Metode znanstvenih istraživanja, Metoda klasifikacije*, http://www.unizd.hr/, 07.01.2017.
[12] Zelenika, R.: *Metodologija i tehnologija izrade znanstvenog i stručnog dijela*, treće dopunjeno i izmijenjeno izdanje, EF u Rijeci, Rijeka, 1998., str. 323. – 339.
[13] *Metode znanstvenih istraživanja, Metoda generalizacije*, http://www.unizd.hr/, 07.01.2017.
[14] *Metode znanstvenih istraživanja, Metoda specijalizacije*, http://www.unizd.hr/ , 07.01.2017.
[15] *Metode znanstvenih istraživanja, Metoda apstrakcije*, http://www.unizd.hr/, 07.01.2017.
[16] *Metode znanstvenih istraživanja, Metoda konkretizacije*, http://www.unizd.hr/ , 07.01.2017.

Povijesna metoda je postupak kojim se na temelju raznovrsnih dokumenata i dokaznog materijala može egzaktno saznati ono što se u prošlosti dogodilo i, po mogućnosti, kako i zašto se to tako dogodilo. Uzima se u obzir naročito kronologija, razvoj i uzročno - posljedične veze o predmetu istraživanja.[17] Matematička metoda je znanstveni sustavni postupak koji se sastoji u primjeni matematičke logike, matematičkih formula, matematičkih simbola i matematičkih operacija u znanstvenoistraživačkom radu.[18] Statistička metoda je induktivno generalizatorska jer se na temelju obilježja određenog broja elemenata neke skupine ili serije pojava, izvodi opći zaključak o prosječnoj vrijednosti obilježja, devijaciji od srednje vrijednosti. Važnost statističke metode je u tome što se jedino s pomoću statističke metode mogu na prihvatljivo egzaktan način saznati opća određenost, pravilnosti i zakonitosti masovnih pojava.[19]

Analizirani podaci i dobiveni rezultati će se zbog bolje preglednosti prikazati tablično i grafički.

1.6. Doprinos istraživanja

Svaka od navedenih metoda u praksi ima svoje zagovornike i kritičare, te se u određenoj mjeri koristi pri analiziranju dionica i odabiru optimalnog portfelja, međutim kombinacija navedenih metoda može predstavljati dodanu vrijednost, odnosno noviji, poboljšani, sveobuhvatniji pristup optimizaciji portfelja. Doprinos istraživanja moguć je kroz proširivanje saznanja o poznatim metodama odabira optimalnog portfelja, te njihovoj kombiniranoj primjeni, kojom se vrši sveobuhvatna analiza promatranih dionica, za razliku od upotrebe svake od metoda pojedinačno, pri čemu se zanemaruju određeni pokazatelji. Istraživanje će doprinijeti boljem razumijevanju postojećih metoda odabira optimalnog portfelja, te mogućnosti ostvarivanja većih povrata na uloženo njihovom kombiniranom primjenom.

[17]Kulenović, Z., Slišković, M.: *Metodologija znanstvenoistraživačkog rada, Povijesna metoda*, Sveučilište u Splitu, Pomorski fakultet, http://www.pfst.unist.hr/ , 07.01.2017.
[18]Kulenović, Z., Slišković, M.: *Metodologija znanstvenoistraživačkog rada, Matematička metoda*, Sveučilište u Splitu, Pomorski fakultet, http://www.pfst.unist.hr/, 07.01.2016.
[19] *Metode znanstvenih istraživanja, Statistička metoda*, http://www.unizd.hr/ , 07.01.2017.

1.7. Sadržaj diplomskog rada

Razrada teorijskog i empirijskog dijela istraživanja prikazat će se kroz pet poglavlja, uključujući zaključak.

U uvodu u prvom poglavlju definirat će se problem i predmet diplomskog rada, te svrha i ciljevi istraživanja. Zatim će se postaviti hipoteze koje će se istraživati, te će se opisati metode kojima će se provoditi istraživanje. Navest će se doprinos koji se očekuje od rezultata istraživanja, te će se opisati sadržaj i struktura rada.

Drugo poglavlje sastoji se od teorijskog i empirijskog dijela. U teorijskom dijelu opisat će se pojam i karakteristike fundamentalne analize, te pojmovi vezani za fundamentalnu analizu, a u empirijskom dijelu prikazat će se primjena fundamentalne analize u odabiru dionica na hrvatskom tržištu kapitala. Fundamentalna analiza podrazumijeva sveobuhvatnu mikroekonomsku i makroekonomsku analizu, analizu djelatnosti kojom se poduzeće bavi, te analizu financijskih izvještaja i pokazatelja, kako bi se odredila prava vrijednost dionica promatranog poduzeća. Cijene dionica ne odražavaju nužno stvarnu vrijednost poduzeća, već neke dionice mogu biti precijenjene ili podcijenjene, iz čega je proizašla potreba za fundamentalnom analizom. Vrijednost dionica može se izračunati kao diskontirana sadašnja vrijednost svih budućih dividendi.[20]

U teorijskom dijelu trećeg poglavlja opisat će se matematički model analize dionica, odnosno Markowitzev model optimizacije portfelja, koji predstavlja temelje moderne teorije portfelja. U empirijskom dijelu poglavlja prikazat će se primjena suvremene teorije portfelja u odabiru optimalnog portfelja na hrvatskom tržištu kapitala. H. M. Markowitz je razvio model koji se temelji na dvama kriterijima: prinosu i riziku koji je mjeren varijancom. Markowitzeva ideja bila je naći ravnotežu između rizika i prinosa te izabrati portfelj dionica koji rezultira najvećim mogućim prinosom uz najmanji mogući rizik. Naravno, preuzimanjem većeg rizika moguće je očekivati i veći prinos. Dakle, njegova ideja bila je formirati matematički model za izbor portfelja koji donosi najveću stopu prinosa, ali uz određeni (unaprijed zadani) stupanj rizika. Takav portfelj, koji za zadanu stopu rizika ima najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalan rizik, Markowitz je nazvao efikasnim portfeljem.[21]

U teorijskom dijelu četvrtog poglavlja opisat će se tehnička analiza i pojmovi vezani za nju, a u empirijskom dijelu prikazat će se primjena tehničke analize u odabiru dionica na hrvatskom

[20] Bodie, Z., Kane, A., Marcus, A. J.: Op. cit., str. 272.
[21] Marasović, B.: Op. cit., str 515.-516.

tržištu kapitala. Tehnička analiza proučava tržišna kretanja, primarno korištenjem grafikona, u svrhu predviđanja budućih cjenovnih trendova, uz tri pretpostavke: tržišna kretanja uzimaju u obzir sve dostupne informacije, cijene slijede trendove i povijest se ponavlja.[22] Tržišnom analizom pokušat će se odrediti povoljni trenutak za kupnju ili prodaju određene dionice.

U petom poglavlju donijet će se zaključak na temelju kombinacije dobivenih rezultata svake od navedenih metoda, te će se hipoteze postavljene u uvodnom dijelu prihvatiti ili odbaciti.

Korištena literatura, slike, tablice i grafikoni bit će popisani na samom kraju diplomskog rada.

[22] Murphy, J.J.: *Tehnička analiza financijskih tržišta*, Poslovni dnevnik, Masmedia, Zagreb, 2007., str. 25.

2. Fundamentalna analiza

2.1. Općenito o fundamentalnoj analizi

Kao što je već navedeno u uvodnom dijelu, zadatak fundamentalne analize jest procijeniti fer vrijednost poduzeća s ciljem otkrivanja dionice koja je podcijenjena, a što se postiže sveobuhvatnom analizom mikroekonomskog i makroekonomskog okruženja u kojem poduzeće posluje, odnosno procjenom smjera kretanja gospodarstva i određenog sektora djelatnosti, te analizom financijskih izvještaja i pokazatelja.

2.2. Makroekonomska analiza i analiza djelatnosti

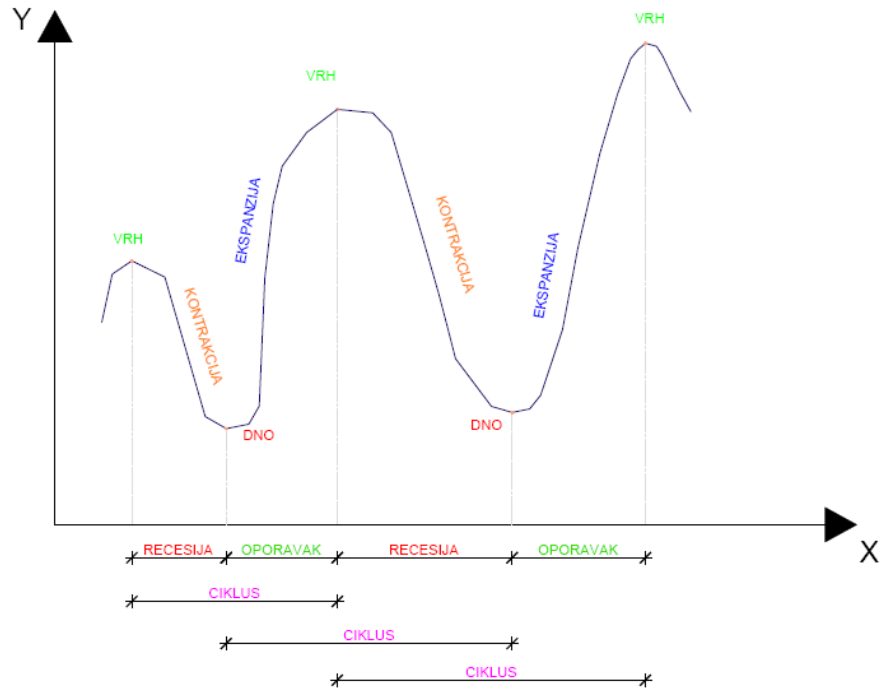
Promjene u globalnom gospodarstvu odražavaju se na nacionalno gospodarstvo, a promjene u nacionalnom gospodarstvu odražavaju se na tržište vrijednosnica, te je stoga pri fundamentalnoj analizi poduzeća potrebno analizirati trendove u monetarnoj i fiskalnoj politici, kao i ekonomske pokazatelje, poput kretanja BDP-a, stope nezaposlenosti i stope inflacije, odnosno promjene u gospodarskim ciklusima. Fiskalnu ekonomiju možemo definirati kao svjesne promjene državnih prihoda i rashoda kojima je svrha ostvarivanje makroekonomskih ciljeva ekonomske politike: pune zaposlenosti, stabilnih cijena, zadovoljavajuće stope rasta i eksterne ravnoteže. Monetarna politika treba ekonomske subjekte opskrbiti dovoljnom količinom novca, odnosno likvidnih sredstava kako se to često kaže da bi realni sektor mogao dobro funkcionirati i ostvarivati svoje ciljeve: porast proizvodnje, zaposlenosti, potrošnje itd.[23]

Gospodarski ciklus uglavnom traje od dvije do deset godina i može se podijeliti u dvije velike faze: recesija (nastaje uslijed kontrakcije) i oporavak (nastaje uslijed ekspanzije). U fazi recesije dolazi do pada ukupne proizvodnje, dohotka i zaposlenosti, a definira se kao razdoblje u kojem se BDP smanjuje tijekom barem dva uzastopna tromjesečja. Za ovu fazu gospodarskog ciklusa tipičan je nagli pad potrošnje, dok istovremeno zalihe trajnih dobara rastu, zatim smanjenje proizvodnje i pad ulaganja u proizvodnju, pad potražnje za radom, porast nezaposlenosti, usporavanje inflacije, pad BDP-a, pad cijena dionica... Jaka, duboka recesija zove se depresija. Ekspanzija/oporavak je zrcalna slika kontrakcije/recesije.[24]

Točke infleksije (točka promjene nagiba krivulje iz faze kontrakcije u fazu ekspanzije i obrnuto) nazivaju se dno, odnosno vrh. Kao što je prikazano na slici 1, jednu fazu predstavlja razdoblje između "vrha" i "dna", ili između "dna" i "vrha", dok dvije faze, odnosno

[23] Babić, M.: *Makroekonomija*, Petnaesto dopunjeno i izmijenjeno izdanje, MATE d.o.o. Zagreb, Tisak ITG, Zagreb, 2007., str. 254.
[24] Kolaković, M.: *Poglavlje 23: Poslovna kolebanja*, http://www.efzg.hr/,18.03.2017.

jedan gospodarski ciklus čini razdoblje između dvije istoimene točke infleksije, npr. između dva "vrha" ili između dva "dna". Fundamentalna analiza uključuje prognozu gospodarskih ciklusa, s čime je usko povezana osjetljivost, odnosno neosjetljivost određenih grana industrije na promjene gospodarskih ciklusa, pa se tako određene djelatnosti, odnosno dionice mogu podijeliti na dvije skupine: cikličke dionice i defenzivne dionice. Tipični predstavnik cikličnih djelatnosti je proizvodnja trajnih dobara (automobili, bijela tehnika) i kapitalnih dobara (temeljna dobra koja su uvjet za stvaranje drugih potrošnih dobara, poput sirovina, postrojenja i sl.) i te su djelatnosti osjetljive na promjenu gospodarskih ciklusa, dok se defenzivne djelatnosti odnose na prehrambenu industriju, farmaceutsku industriju i sl., te su one manje osjetljive na stanje u gospodarstvu. Ulaganjem u cikličke dionice neposredno prije izlaska iz recesije mogu se ostvariti iznadprosječni povrati, te se u ciklične dionice ulaže kada se očekuje ekspanzija, a u defenzivne vrijednosnice se ulaže ako se očekuje recesija.[25]



Slika 1: Faze gospodarskog ciklusa

Izvor: Autor

Teško je točno prognozirati kada će uslijediti koja faza gospodarskog ciklusa i koliko dugo će pojedina faza trajati, ali je praćenjem i analizom gore navedenih čimbenika moguće barem okvirno procijeniti u kojoj se fazi gospodarskog ciklusa nacionalno gospodarstvo trenutno nalazi.

[25] Vidučić, Lj.: *Financijski menadžment*, VIII. Izdanje, RRIF plus, Zagreb, 2012., str. 124.

Osim makroekonomske analize, pri fundamentalnoj analizi potrebno je izvršiti i analizu industrije (djelatnosti), tj. sektorsku analizu, što uključuje životni ciklus i strukturu industrije, konkurenciju, regulativu, poslovni ciklus, te financijske standarde. [26] Životni ciklus djelatnosti/poduzeća može se podijeliti na pet faza: osnivanje, rast, ekspanzija, zrelost i pad. U tablici 1 prikazane su faze životnog ciklusa djelatnosti/poduzeća i njihove karateristike:

Tablica 1: Faze životnog ciklusa djelatnosti/poduzeća

FAZE ŽIVOTNOG CIKLUSA DJELATNOSTI/PODUZEĆA					
	Osnivanje	Rast	Ekspanzija	Zrelost	Pad
Karakteristike faze	Izvor kapitala: vlastiti/bankarski kredit; dobit se reinvestira	Tvrtka se pozicionirala na tržištu; rast profitabilnosti po ubrzanoj stopi; dividende se rijetko dijele, i to u obliku dionica	Smanjena stopa rasta zarade i imovine zbog ulaska konkurencije; pad cijena dionica zbog smanjene stope rasta i očekivanja daljneg sporijeg rasta	Stopa rasta prodaje tvrtke pada na razinu stope rasta gospodarstva; velik gotovinski tijek	Pad prodaje, najčešće zbog nedostatka inovacija i nezadržavanja konkurentske prednosti
	Veliki rizik s aspekta investitora		Gotovinske dividende se isplaćuju u većoj mjeri (25%-30% neto dobiti)	Dividende veće od 50% neto dobiti	

Izvor: Autor (podaci za kreiranje tablice preuzeti iz Vidučić, Lj.: *Financijski menadžment*, VIII. Izdanje, RRIF plus, Zagreb, 2012., str. 124.-125.)

Konkurencija unutar određene djelatnosti ovisi o strukturi djelatnosti, koje mogu biti: savršena konkurencija, monopol, monopolistička konkurencija ili oligopol. Za savršenu konkurenciju karakterističan je veliki broj proizvođača i kupaca, proizvod je homogen (ima ista obilježja kao i proizvod drugog proizvođača), proizvođači i kupci imaju pristup svim relevantnim informacijama i mogućnost odabira između različitih alternativa, nova poduzeća mogu ući na tržište bez prepreka, a postojećim je poduzećima omogućen slobodan izlaz s tržišta. Kod monopola postoji samo jedan proizvođač čiji proizvod nema bliskih supstituta (dobra koja se mogu međusobno zamijeniti u potrošnji), te je drugim poduzećima ulaz na tržište otežan. U stvarnosti se češće može naići na nesavršenu konkurenciju: monopolističku konkurenciju ili oligopol. Monopolističku konkurenciju karakteriziraju velik broj proizvođača i potrošača na tržištu, proizvodi su slični, ali nisu identični (diferencirani su), te je moguć

[26] Vidučić, Lj., Op.Cit., str. 125.

slobodan ulaz i izlaz s tržišta. U slučaju oligopola postoji manji broj međusobno ovisnih proizvođača čiji proizvodi i usluge mogu biti homogeni ili diferencirani, a mogućnost ulaska na tržište i izlaska s istog je ograničena. Kod nesavršene konkurencije pojavljuje se pitanje tržišne moći, odnosno mogućnosti poduzeća da na tržištu nesavršene konkurencije više ili manje autonomno odredi cijenu proizvoda, koja ovisi o tržišnom udjelu, odnosno o udjelu poduzeća u ukupnoj tržišnoj ponudi nekog proizvoda.[27] Osim navedenog, pri analizi strukture djelatnosti treba pripaziti i na moguće postojanje zakonskih regulativa vezanih za određene djelatnosti.

2.3. Analiza uspješnosti poslovanja poduzeća

Uspješnost poslovanja poduzeća može se mjeriti kroz nekoliko pokazatelja: pokazatelje likvidnosti, pokazatelje zaduženosti, pokazatelje menadžmenta imovine, pokazatelje profitabilnosti, pokazatelje investiranja i skupne pokazatelje.

2.3.1. Pokazatelji likvidnosti

Likvidnost se može definirati kao sposobnost tvrtke da u roku podmiri sve svoje tekuće obveze. Pokazatelji likvidnosti su sljedeći: koeficijent tekuće likvidnosti, koeficijent ubrzane likvidnosti, koeficijent trenutne likvidnosti i koeficijent financijske stabilnosti. Koeficijentom tekuće likvidnosti (eng. current ratio) mjeri se sposobnost poduzeća da podmiri svoje kratkoročne obveze, a računa se kao omjer kratkotrajne imovine i kratkotrajnih obveza poduzeća. Minimalna preporučena vrijednost ovog pokazatelja je 2 (k>2). Međutim, kao usporedna vrijednost može se uzeti i industrijski prosjek (konkurencija). Ako je koeficijent tekuće likvidnosti značajno manji od industrijskog prosjeka (konkurencije), to implicira mogućnost da poduzeće ostane bez sredstava za podmirenje kratkoročnih obveza, a ako je ovaj pokazatelj značajno viši od prosjeka industrije može značiti da poduzeće ne koristi efikasno svoja sredstva.[28] Koeficijentom ubrzane likvidnosti (eng. quick ratio) mjeri se sposobnost poduzeća da podmiri svoje kratkoročne obveze, a bez prodaje zaliha. Ovaj pokazatelj također ne bi trebao značajno odstupati od industrijskog prosjeka. Minimalna preporučena vrijednost koeficijenta ubrzane likvidnosti je 1 (k>1), a računa se kao omjer kratkotrajne imovine umanjene za zalihe i kratkoročnih obveza. Koeficijent trenutne likvidnosti (eng. cash ratio) mjeri sposobnost poduzeća da novcem kojeg ima u banci i

[27] Pavić, I., Benić, Đ., Hashi, I.: *Mikroekonomija*, treće izdanje, Sveučilište u Splitu, Ekonomski fakultet Split, Split, 2009., str. 409.-490.
[28] Financijski pokazatelji – pokazatelji likvidnosti, http://profitiraj.hr/financijski-pokazatelji-pokazatelji-likvidnosti/, 07.05.2017.

blagajni podmiri kratkoročne obveze. Preporučena vrijednost koeficijenta je k>0,1, a koeficijent se računa kao omjer novca u banci i blagajni i kratkoročnih obveza poduzeća. Koeficijent financijske stabilnosti računa se kao omjer dugotrajne imovine i kapitala uvećanog za dugoročne obveze. Ovaj bi koeficijent trebao biti manji od 1 (k<1). Ako je koeficijent financijske stabilnosti manji od 1, znači da se iz dijela dugoročnih izvora financira kratkotrajna imovina, a ako je veći od 1 znači da je dugotrajna imovina financirana iz kratkoročnih obveza[29], tj. da postoji deficit radnog (obrtnog) kapitala.

2.3.2. Pokazatelji zaduženosti

Najčešće korišteni pokazatelji zaduženosti pri analizi uspješnosti poslovanja poduzeća su sljedeći: koeficijent zaduženosti, koeficijent vlastitog financiranja, koeficijent financiranja, stupanj pokrića I i stupanj pokrića II. Koeficijent zaduženosti računa se kao omjer ukupnih obveza i ukupne imovine poduzeća, te bi trebao biti manji ili jednak vrijednosti 0,5 (k≤0,5). Ako je koeficijent zaduženosti veći od preporučene vrijednosti 0,5, to znači da je više od 50% imovine poduzeća financirano iz tuđih izvora. Koeficijent vlastitog financiranja prikazuje odnos vlastitog kapitala i ukupne imovine, odnosno pokazuje koliki je dio imovine financiran iz vlastitih izvora. Preporuka je da koeficijent vlastitog financiranja bude veći od 0,5 (k>0,5). Ako je koeficijent vlastitog financiranja ispod minimalne preporučene vrijednosti 0,5 to znači da je manje od 50% imovine poduzeća financirano iz vlastitih izvora. Koeficijent financiranja pokazuje odnos ukupnih obveza (duga, tj. tuđeg kapitala) i vlastitog kapitala, te je preporuka da navedeni pokazatelj bude manji od 2 (k<2). Međutim, ako je navedeni koeficijent znatno veći od ostalih poduzeća u pripadnom sektoru djelatnosti, to može ukazivati na moguće poteškoće pri vraćanju posuđenih sredstava.
Stupanj pokrića I računa se kao omjer vlastitog kapitala i dugotrajne imovine, a stupanj pokrića II prikazuje odnos vlastitog kapitala uvećanog za dugoročne obveze i dugotrajne imovine. Vrijednost stupnja pokrića II bi trebala biti veća od 1 (k>1), jer dio dugoročnih izvora mora biti iskorišten za financiranje kratkotrajne imovine kako bi se održala likvidnost poduzeća.

2.3.3. Pokazatelji menadžmenta imovine

Pokazatelji menadžmenta imovine ili pokazatelji aktivnosti upućuju na brzinu cirkulacije imovine u poslovnom procesu. Najčešće korišteni pokazatelji aktivnosti su:

[29] Financijska analiza – financijski pokazatelji, https://www.mathos.unios.hr//, 01.04.2017.

koeficijent obrta ukupne imovine, koeficijent obrta dugotrajne imovine, koeficijent obrta kratkotrajne imovine, koeficijent obrta zaliha i koeficijent obrta potraživanja.[30] Jedan od najčešće korištenih pokazatelja aktivnosti, koeficijent obrta ukupne imovine pokazuje koliko puta se ukupna imovina tvrtke obrne u tijeku jedne godine, odnosno koliko tvrtka uspješno koristi imovinu s ciljem stvaranja prihoda. Računa se kao omjer ukupnog prihoda i ukupne imovine, pri čemu se imovina može računati kao prosjek vrijednosti imovine na početku i na kraju razdoblja.[31] Koeficijent obrta dugotrajne imovine računa se kao omjer ukupnih prihoda i dugotrajne imovine, a pokazuje koliko uspješno tvrtka koristi dugotrajnu imovinu s ciljem stvaranja prihoda. Poželjno je da je taj koeficijent što veći, jer to znači da je manji dio novca potreban za stvaranje prihoda vezan u obliku dugotrajne imovine. Smanjenje navedenog koeficijenta može ukazati na investiranje u nove tehnologije.[32] Koeficijent obrta kratkotrajne imovine govori koliko puta se kratkotrajna imovina tvrtke obrne u tijeku jedne godine, odnosno on mjeri relativnu efikasnost kojom poduzeće koristi kratkotrajnu imovinu za stvaranje prihoda.[33] Računa se kao omjer ukupnih prihoda i kratkotrajne imovine. Koeficijent obrta zaliha pokazuje koliko se puta zalihe obrnu u tijeku jedne godine, a računa se kao omjer prihoda od prodaje i stanja zaliha. Uglavnom se pri izračunu ovog koeficijenta koristi prosjek zaliha na početku i na kraju razdoblja. Budući da su zalihe najnelikvidniji oblik imovine, poželjna je veća vrijednost koeficijenta obrta zaliha. Međutim, ako je navedeni koeficijent znatno veći od prosjeka industrije, to bi moglo značiti da tvrtka ima manjak zaliha, te da bi moglo doći do pada prodaje, odnosno pada prihoda.[34] Koeficijent obrta potraživanja računa se kao omjer prihoda od prodaje i potraživanja, a temeljem njega je moguće utvrditi prosječno trajanje naplate potraživanja od kupaca.[35]

2.3.4. Pokazatelji profitabilnosti

Najčešće korišteni pokazatelji profitabilnosti su: marža profita, stopa povrata imovine i stopa povrata glavnice. Marža profita se računa kao omjer neto dobiti i ukupnog prihoda poduzeća. Stopa povrata na ukupnu imovinu (eng. return on assets, ROA) je dobit koju poduzeće generira iz jedne novčane jedinice ukupne imovine, a računa se kao omjer neto dobiti i ukupne imovine poduzeća, izraženo u postocima. Budući da različiti sektor djelatnosti

[30] Šarlija, N.: *Financijska analiza, Predavanja za kolegij 'Analiza poslovanja poduzeća'*, https://www.mathos.unios.hr/analizapp/Files/Financijska_analiza.doc.pdf , 01.04.2017., str. 7
[31] Ibid
[32] Ibid, str. 8
[33] Ibid
[34] Ibid, str. 9
[35] Ibid

zahtijeva različitu količinu imovine (tzv. intenzivnost imovine) za poslovanje (npr. autoindustrija koristi skupu opremu, dok marketinško poduzeće gotovo uopće ne troši na opremu potrebnu za poslovanje), vrijednost stope povrata imovine jako varira ovisno o industriji ili djelatnosti kojom se poduzeće bavi. Nije točno definirana preporučena vrijednost ROA-e, ali kaže se da poduzeća čija je ROA manja od 5% imaju visok stupanj intenzivnosti imovine, dok poduzeća poduzeća čija je ROA veća od 20% imaju nisku intenzivnost imovine. Stopa povrata glavnice, odnosno stopa povrata na vlastiti kapital (eng. return on equity, ROE) pokazuje koliko novčanih jedinica dobiti poduzeće ostvaruje na jednu jedinicu vlastitog kapitala, a računa se kao omjer neto dobiti i vlastitog kapitala, izraženo u postocima. Poduzeća sa stopom povrata na vlastiti kapital od 15 % smatraju se uspješnim.

2.3.5. Pokazatelji investiranja

Pokazatelji investiranja koji su najčešće u upotrebi su sljedeći: dobit po dionici (EPS), dividenda po dionici (DPS), odnos isplate dividendi (DPR), ukupna rentabilnost dionice (P/E ratio) i dividendna rentabilnost dionice, od kojih su najznačajniji pokazatelji investiranja posljednja dva navedena. Dobit po dionici (eng. earnings per share - EPS) računa se kao odnos neto dobiti i broja dionica, odnosno pokazuje neto dobit ostvarenu po jednoj dionici poduzeća, te izražava sposobnost poduzeća da stvara dobit.[36] Dobit po dividendi (eng. dividends per share - DPS) računa se kao omjer dijela neto dobiti za dividende i broja dionica, a pokazuje iznos dividende koji će dioničar dobiti za svaku dionicu koju posjeduje.[37] Odnos isplate dividendi (eng. dividend payout ratio - DPR) računa se kao omjer dividende po dionici i dobiti po dionici. Budući da poduzeća uglavnom zadržavaju dio dobiti, taj je omjer najčešće manji od 1.[38] Ukupna rentabilnost dionice (eng. price earnings ratio - P/E) računa se kao omjer dobiti po dionici (eng. earnings per share – EPS) i tržišne cijene dionice, dok EPS predstavlja omjer neto dobiti i broja dionica. Dividendna rentabilnost dionice računa se kao omjer dividende po dionici i tržišne cijene dionice. Ukupna i dividendna rentabilnost dionice izražavaju se u postotku.

[36] Ibid, str. 13
[37] Ibid
[38] Ibid, str. 13. – 14.

2.3.6. Skupni pokazatelji

Skupni pokazatelji predstavljaju kombinaciju više podataka ili pokazatelja pomnoženih određenim težinskim koeficijentom, a kojima se može procijeniti uspješnost ili rizičnost poslovanja promatranog poduzeća. Neki od njih su: Altmanov Z - score model, Zmijewski model, Springate model, Kralicek Quicktest i BEX model. Altmanov Z – score model je najpoznatiji skupni pokazatelj, a računa se na sljedeći način:

$$Z= 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 +1,0X_5, \quad (2.1)$$

pri čemu je X_1 = obrtni kapital / ukupna imovina; a obrtni kapital predstavlja razliku kratkotrajne imovine i kratkoročnih obveza;

X_2 = zadržana dobit / ukupna imovina;

X_3 = dobit prije kamata i poreza / ukupna imovina;

X_4= tržišna vrijednost dioničkog kapitala / knjigovodstvena vrijednost ukupnih obveza;

X_5 = prihodi od prodaje / ukupna imovina;

Ako je $Z < 1,81$, poduzeću prijeti bankrot, dok se vrijednosti Altmanovog Z – score-a u rasponu od 1,81 do 2,99 nalaze u sivoj zoni, što znači da postoje relativno dobre šanse za podmirenje duga. Poduzeća čiji je $Z > 2,99$ nalaze se u sigurnoj zoni.

Ovaj je model 1993. godine korigiran, pri čemu je kod izračuna X_4 tržišna vrijednost dioničkog kapitala zamijenjena knjigovodstvenom vrijednosti (oznaka Z`)[39], a 1995. godine Altman je uveo još jedan korigirani model (Z``), čime je iz formule izostavljen član X_5, jer njegova vrijednost može dosta varirati ovisno o sektoru djelatnosti. Formula za ovaj korigirani model glasi:

$$Z``= 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4 \quad (2.2)$$

Ako je $Z``< 1,11$ poduzeću prijeti bankrot. Siva zona nalazi se u rasponu vrijednosti 1,11 do 2,59, dok je poduzeće u sigurnoj zoni ako je $Z``>2,59$.

Potrebno je napomenuti da je Altmanov model razvijen u uvjetima američkog gospodarstva sedamdesetih godina prošlog stoljeća, pa su u slučaju današnje primjene tog modela na hrvatskom tržištu vjerojatno potrebne određene prilagodbe modela.[40]

[39] Šarlija, N.: *Objašnjenje Altman z-score modela*, http://www.efos.unios.hr/nsarlija/wp-content/uploads/sites/88/2013/04/Altman-z-score.pdf, 27.04.2017.
[40] Ibid

2.4. Metode procjene vrijednosti poduzeća

Razlikuju se dva temeljna pristupa procjene vrijednosti poduzeća: statički i dinamički pristup.

2.4.1. Statički pristup

Statički pristup procjenjuje vrijednost tvrtke na temelju imovine, tj. analizira postojeće stanje tvrtke, ne uzimajući u obzir moguće buduće događaje, poput potencijala tvrtke za razvoj novih proizvoda ili buduće zarade. Najpoznatije statičke metode su:

- knjigovodstvena vrijednost
- ispravljena (korigirana) knjigovodstvena vrijednost
- zamjenska vrijednost
- likvidacijska vrijednost[41]

Knjigovodstvena vrijednost koristi povijesne, odnosno knjigovodstvene podatke:

$$\text{Neto knjigovodstvena vrijednost} =$$

$$= \text{knjigovodstvena vrijednost imovine} - \text{vrijednost obveza} \qquad (2.3)$$

Budući da su podaci o knjigovodstvenoj vrijednosti imovine (nekretnina poput zemljišta i zgrada, te opreme, odnosno materijalne imovine) povijesni podaci, potrebna je njezina korekcija kako bi imali ispravnu informaciju o trenutno realnoj tržišnoj vrijednosti imovine. Stoga se vrši procjena vrijednosti imovine, pa je ispravljena (korigirana) knjigovodstvena vrijednost jednaka procijenjenoj tržišnoj vrijednosti imovine umanjenoj za obveze tvrtke, za koje najčešće nije potrebna korekcija. Pri procjeni imovine potrebno je pripaziti na moguću podcijenjenu/precijenjenu aktivu i/ili pasivu, što znači da se može dogoditi da je knjigovodstvena vrijednost imovine precijenjena, a vrijednost pasive podcijenjena, a što može dovesti do skrivenih gubitaka. Kod procjene vrijednosti nekretnina, procjenitelj određuje tržišnu vrijednost nekretnine (zemljišta, stana, kuće, poslovnog prostora, stambeno – poslovne zgrade, poslovnog kompleksa, hotela ili specifičnih nekretnina, poput benzinske pumpe) koristeći jednu od tri metode: poredbenu, troškovnu ili prihodovnu metodu, ovisno o vrsti, odnosno namjeni nekretnine, pri čemu je jedna od navedenih metoda glavna metoda, dok se ostale metode mogu koristiti kao sporedne metode (kao pomoć za izračun tržišne vrijednosti nekretnine glavnom metodom).

Osim prema neto knjigovodstvenoj vrijednosti, poduzeće se može vrednovati i na temelju vrijednosti materijalne imovine, prema izrazu:

[41] Vidučić, Lj., Op.Cit., str. 127.

$$\mathrm{BVS} = \frac{(\mathrm{TA} - \mathrm{GW} - \mathrm{TL})}{\mathrm{S}}, \tag{2.4}$$

gdje je BVS knjigovodstvena vrijednost materijalne imovine po dionici, TA je dugotrajna materijana imovina, GW je evidentirani kupljeni goodwill, TL su ukupne obveze, a S je broj emitiranih i prodanih dionica.[42]

Zamjenska vrijednost predstavlja iznos potreban da bi se postojeća imovina tvrtke zamijenila novom imovinom u sadašnjem trenutku, te se u tu svrhu također vrši procjena tržišne vrijednosti imovine i obveza. Zamjenska vrijednost računa se prema sljedećem izrazu:

$$\mathrm{V_Z} = \mathrm{Z} - \mathrm{O}, \tag{2.5}$$

gdje je Vz oznaka za zamjensku vrijednost poduzeća, Z označava zamjensku vrijednost imovine poduzeća, a oznakom O označena je tržišna vrijednost obveza poduzeća. Ova metoda pretpostavlja da racionalan investitor postojeću nekretninu neće platiti više nego što bi istu platio kada bi se ponovno izgradila, odnosno zamijenila novom nekretninom.

Likvidacijska vrijednost dobiva se simulacijom stečaja i likvidacije tvrtke, pri čemu se procjenjuje tržišna vrijednost imovine koja se može prodati kako bi se namirile obveze tvrtke, uključujući i troškove likvidacije tvrtke i zbrinjavanja radnika.

U slučaju da se pri procjeni vrijednosti imovine u analizu uključi i nematerijalna imovina, poput patenata i goodwill-a (dobar glas), te tehnoloških inovacija, tada se radi o kombiniranoj metodi, odnosno kombinaciji statičkih i dinamičkih metoda. U tom se slučaju vrijednosti postojeće imovine dodaje vrijednost mogućih budućih zarada. S ekonomskog gledišta, goodwill označava ugled biznisa[43] te se u bilanci iskazuje kao dio dugotrajne nematerijalne imovine. Goodwill kao stavka u bilanci nastaje kod preuzimanja poduzeća, kada postoji razlika između plaćene i fer vrijednosti poduzeća.[44] Goodwill se može definirati i kao osobne karakteristike vlasnika kompanije koje stvaraju dobre odnose s kupcima, a iz kojih proizlaze tekuće i buduće koristi za kompaniju[45], odnosno goodwill odražava sve faktore koji mogu doprinijeti iznadprosječnoj profitabilnosti.[46] Oni čimbenici goodwilla na koje menadžment može utjecati zovu se unutarnji ili kontrolabilni čimbenici kao što su organizacija, kadrovi, ulaganje u istraživanja i razvoj proizvoda i ulaganje u obuku zaposlenika, dok se na čimbenike poput zakonske regulative i porezne politike ne može

[42] Prevan, I.: *Računovodstvo poslovnih spajanja*, RriF Plus d.o.o., Zagreb, 2012., str. 14.
[43] Collin, P.H., Joliffe, A.: *Dictionary of Accounting*, Peter Collin Publishing, Middlesex, 1992., str. 101.
[44] Novak, B.: *Mjerenje i upravljanje dodanom ekonomskom vrijednošću tvrtke*, EKONOMSKI PREGLED, 53 (3-4), (2002.), str. 280.
[45] Pervan, I., Op.Cit., str. 86.-87.
[46] Ibid, str. 86.

direktno utjecati, pa se oni nazivaju vanjskim ili nekotrolabilnim čimbenicima.[47] Određeni dio goodwilla može biti upravo ono što naziv kaže, dobar glas koji su preuzeta tvrtka i njeni proizvodi uspostavili s kupcima i dobavljačima.[48]

2.4.2. Dinamički pristup

Dinamički pristup se može podijeliti na dvije podskupine:

- pristup relativnog vrednovanja (multiplikatora/pokazatelja)
- model diskontiranih dividendi (DDM model)
- model diskontiranih gotovinskih tijekova (DCFM model)

Pristup relativnog vrednovanja (multiplikatora/pokazatelja) temelji se na izračunu pokazatelja financijske analize, kao što su pokazatelji likvidnosti (eng. liquidity ratios), pokazatelji zaduženosti (eng. leverage ratios), pokazatelji aktivnosti (eng. activity ratios), pokazatelji ekonomičnosti, pokazatelji profitabilnosti (eng. profitability ratios) i pokazatelji investiranja (eng. investibility ratios), stavljanjem u odnos podataka iz financijskih izvještaja – bilance, računa dobiti i gubitka, te izvješća o novčanim tokovima. Najčešće korišteni multiplikatori su P/E multiplikatori i P/B multiplikator.

Multiplikator cijene i zarade P/E (eng. price-earnings ratio) računa se kao omjer tržišne cijene dionice (P) i dobiti po dionici (E):

$$\frac{\mathrm{P}}{\mathrm{E}} = \frac{\text{tržišna cijena dionice}}{\text{dobit po dionici}} . \tag{2.6}$$

Za izračun multiplikatora P/E umjesto dobiti može se koristiti dobit nakon oporezivanja (neto dobit, EPS), dobit prije kamata i poreza (EBIT) ili dobit prije kamata, poreza, deprecijacije i amortizacije (EBITDA). Dakle izračun multiplikatora P/E može biti temeljen na povijesnim podacima, ali i na budućim, odnosno može se izračunati i prognozirani multiplikator na temelju tekuće tržišne cijene i prognoziranog EPS-a.[49]

Vrijednost poduzeća zatim se određuje kao umnožak multiplikatora P/E usporedive tvrtke i neto dobiti vrednovane tvrtke:

$$\mathrm{V_e} = \left(\frac{\mathrm{P}}{\mathrm{E}}\right)_{\text{usporedive tvrtke}} \cdot \text{neto dobit}_{\text{vrednovane tvrtke}} . \tag{2.7}$$

Iako je ova metoda popularna kod vrednovanja tvrtke, ona ima i neke nedostatke, poput neupotrebljivosti iste kada poduzeće posluje s gubitkom, upotrebe različitih računovodstvenih

[47] Ibid, str. 85.-94.
[48] Novak, B., Op.Cit.,, str. 280.
[49] Pervan, I., Op.Cit., str. 22.

standarda kod usporedivih poduzeća, ali i veliku osjetljivost rezultata vezano za odabir usporedivih poduzeća. Naime, ako analitičar nije odabrao adekvatna usporediva poduzeća, rezultati mogu jako odstupati od realnog stanja, te se mogu donijeti pogrešni zaključci.

Multiplikator P/B (eng. price to book ratio) računa se kao omjer tržišne cijene dionice (P) i knjigovodstvene vrijednosti poduzeća (glavnice) po dionici, pri čemu je knjigovodstvena vrijednost glavnice jednaka razlici ukupne imovine i obveza, podijeljenoj s brojem izdanih dionica:

$$\frac{\mathrm{P}}{\mathrm{B}} = \frac{\text{tržišna cijena dionice}}{\text{knjigovodstvena vrijednost glavnice po dionici}} . \tag{2.8}$$

Vrijednost poduzeća zatim se određuje kao umnožak multiplikatora P/B usporedive tvrtke i knjigovodstvene vrijednosti glavnice po dionici vrednovane tvrtke:

$$\mathrm{V_e} = \left(\frac{\mathrm{P}}{\mathrm{B}}\right)_{\text{usporedive tvrtke}} \cdot \text{knjigovodstvena vrijednost glavnice po dionici}_{\text{vrednovane tvrtke}} \cdot \tag{2.9}$$

Iako je ovaj multiplikator moguće koristiti i kada poduzeće posluje s gubitkom, usporediva poduzeća mogu imati veliku razliku u imovini zbog različitog odabira poslovnog modela, te se ponovno javlja pitanje pravilnog odabira usporedivih poduzeća, osjetljivosti rezultata na isti i mogućeg donošenja pogrešnih zaključaka temeljem neadekvatnog odabira usporedivih poduzeća.

Model diskontiranih dividendi (DDM model) polazi od teorije da su dividende osnova za vrednovanje dionica i on uključuje:

- model konstantnih dividendi
- model konstantnog rasta dividendi (Gordonov model)
- model nekonstantnog rasta[50]

Emitiranjem dionica poduzeće pribavlja potrebna novčana sredstva. Razlikuju se prioritetne (povlaštene, preferencijalne) dionice i obične dionice. Obična dionica je vrijednosni papir koji imatelju daje pravo na dividendu (pravo na udio u dobiti poduzeća) i pravo glasa u pitanjima upravljanja poduzećem, dok imatelj prioritetne dionice uglavnom nema pravo glasa u pitanjima upravljanja poduzećem, ali zato ima prednost pri isplati dividende i u slučaju likvidacije poduzeća.

Postoji razlika između nominalne vijednosti dionice i njezine burzovne vrijednosti, odnosno tržišne vrijednosti. Nominalna vrijednost dionice izražava idealni dio vlasništva dioničarskog

[50] Vidučić, Lj., Op.Cit., str. 130.

poduzeća, na temelju koje se određuje pravo udjela u dobiti poduzeća, dok tržišna vrijednost dionice izražava sadašnju vrijednost očekivanih budućih prinosa.[51] Budući da se dividenda kod prioritetnih dionica određuje pri emisiji dionica kao postotak u odnosu na nominalnu vrijednost emitiranih dionica ili kao određeni iznos po dionici[52], prioritetne dionice se vrednuju pomoću jednadžbe:

$$P_0 = \frac{D_p}{k_p} \quad , \tag{2.10}$$

pri čemu je:

P_o = vrijednost prioritetne dionice

D_p = prioritetna dividenda

k_p = tražena stopa povrata na prioritetnu dionicu

Slična jednažba vrijedi i za vrednovanje običnih dionica s konstantnim dividendama (dionica s nultim rastom), odnosno s vječnim povratom:

$$P_0 = \frac{D}{k_s}, \tag{2.11}$$

pri čemu je:

D = dividenda koja se dobija zauvijek

k_s = tražena stopa povrata dioničara

U praksi je češći slučaj da dividende običnih dionica rastu konstantno po istoj stopi. Takav model konstantnog ili normalnog rasta poznat je pod nazivom Gordonov model, prema profesoru Myronu Gordonu koji je taj model razvio.[53] Jednadžba Gordonovog modela glasi:

$$P_0 = \frac{D_0(1+g)}{(1+k_s)^1} + \frac{D_0(1+g)^2}{(1+k_s)^2} + \frac{D_0(1+g)^3}{(1+k_s)^3} + \cdots + \frac{D_0(1+g)^n}{(1+k_s)^n} = \frac{D_0(1+g)}{k_s - g} = \frac{D_1}{k_s - g}, \tag{2.12}$$

gdje je:

D_0 = zadnja isplaćena dividenda

k_s = tražena stopa povrata na dionice

g = stopa rasta dividendi zauvijek

Vrijednost dionice s dividendama s nekonstantnim (iznadnormalnim) rastom računa se uz primjenu teorije životnog ciklusa, gdje je vrijednost dionice jednaka zbroju sadašnje

[51] Pavić, I., Benić, Đ., Hashi, I., Op.Cit., str. 531.-532.
[52] Vidučić, Lj., Op.Cit., str. 145.
[53] Ibid, str. 150.

vrijednosti dividendi u prvim fazama (iznadnormalni rast), te sadašnje vrijednosti očekivane vrijednosti dionice na kraju zadnje faze iznadnormalnog rasta, što je zapravo početak faze s konstantnim, normalnim rastom dividende[54]:

$$P_0 = \begin{matrix}\text{SV dividendi}\\ \text{u prvoj fazi}\end{matrix} + \begin{matrix}\text{SV dividendi}\\ \text{u drugoj fazi}\end{matrix} + \begin{matrix}\text{SV cijene dionice u zadnjoj}\\ \text{godini iznadnormalnog rasta},\end{matrix} \qquad (2.13)$$

U slučaju kada se dividende ne isplaćuju, prikladniji je model diskontiranih gotovinskih (novčanih) tijekova – DCF model (eng. discounted cash flow), po kojem se pri vrednovanju poduzeća polazi od toga da je sadašnja vrijednost kompanije jednaka sumi očekivanih budućih novčanih tijekova njenog poslovanja, diskontiranih po stopi koja odražava rizičnost tih novčanih tijekova.[55] Pritom se koriste sljedeći slobodni novčani tokovi – FCF (eng. free cash flow): slobodni novčani toka za kompaniju – FCFF (eng. free cash flow to firm) i slobodni novčani tok za diončare – FCFE (eng. free cash flow to equity). Slobodni novčani tok za kompaniju odnosi se na novčani tok koji je na raspolaganju svim dioničarima i kreditorima nakon podmirivanja operativnih troškova, poreza na dobit, ulaganja u dugotrajnu i obrtnu imovinu, dok se slobodni novčani tok za dioničare odnosi na novčani tok koji je na raspolaganju samo dioničarima kompanije (vlasnicima redovitih dionica), nakon podmirivanja operativnih troškova, troškova kamata, poreza na dobit, ulaganja u dugotrajnu i obrtnu imovinu.[56]

[54] Ibid, str. 149.-153.
[55] Pervan, I., Op.Cit., str. 16.
[56] Ibid

2.4. Primjena odabranih pokazatelja fundamentalne analize u odabiru dionica na hrvatskom tržištu kapitala

2.4.1. Odabir uzorka poduzeća

Za početni uzorak dionica izračunat će se odabrani fundamentalni pokazatelji, a zatim će se ovisno o rezultatima fundamentalne analize iz uzorka izbaciti dionice koje su precijenjene ili ne zadovoljavaju neke od bitnih fundamentalnih pokazatelja. Zatim će se takav uzorak u poglavlju 3 analizirati primjenom matematičkih modela, odnosno Markowitzevog modela optimizacije portfelja. S obzirom na veliki broj poduzeća koja emitiraju dionice na Zagrebačkoj burzi i na veliki obujam podataka koji bi se njihovom cjelovitom analizom morao obraditi, a sukladno s preporučenim brojem dionica koji bi trebao biti obuhvaćen u uzorku pri primjeni Markowitzevog modela optimizacije portfelja (koji je objašnjen u poglavlju 3), kao početni uzorak za primjenu fundamentalne analize odabrane su dionice koje su uvrštene u CROBEX 10, odnosno 10 dionica iz indeksa CROBEX s najvećom free float tržišnom kapitalizacijom i prometom. Budući da u trenutku izrade empirijskog dijela fundamentalne analize na internetskoj stranici zagrebačke burze nisu bila dostupna financijska izvješća za prvi kvartal tekuće 2017. godine, fundamentalna analiza izvršena je temeljem podataka iz dostupnih godišnjih financijskih izvještaja za 2016. godinu, a prema potrebi i za 2015. i 2014. godinu. Tržišna kapitalizacija jednaka je umnošku tržišne cijene dionice i broja dionica određenog poduzeća na burzi, dok se free float tržišna kapitalizacija dobiva izbacivanjem onih dionica iz tržišne kapitalizacije za čije se vlasnike pretpostavlja da su dugoročni ulagači, odnosno onih dionica za koje se pretpostavlja da u bližoj budućnosti neće biti ponuđene na prodaju. Prva na popisu deset dionica s najvećom free float tržišnom kapitalizacijom na slici 4 je dionica Hrvatskog telekoma d.d., koja je ujedno i dionica s najvećim prometom u 2016. godini, kao i najlikvidnija dionica u 2016. godini, te je nosila gotovo 19% ukupnog prometa (u 2015. radilo se o 15% udjela u prometu). Na popisu dionica s najvećom free float tržišnom kapitalizacijom se nalazi i dionica Valamar Riviere d.d., koja je proglašena dionicom godine prema izboru javnosti. Prema Pregledu trgovine u 2016. godini, koji je dostupan na stranicama Zagrebačke burze: www.zse.hr, u prvih pet dionica s najvećom free float tržišnom kapitalizacijom sumirano je 46% ukupne tržišne kapitalizacije (HT-R-A, ADRS-P-A, ADRS-R-A, RIVP-R-A, PODR-R-A), dok je istih pet najtrgovanijih dionica zaslužno za 49% prometa (HT-R-A, RIVP-R-A, ADRS-P-A, PODR-R-A i ADRS-R-A). Slika 3 prikazuje deset dionica s najvećom tržišnom kapitalizacijom, a slika 5 prikazuje deset dionica s najvećim prometom 2016. godine.

Dakle, odabran je početni uzorak od deset poduzeća uvrštenih u CROBEX10, od kojih je dionica poduzeća Adris d.d. povlaštena, dok su dionice preostalih poduzeća redovne dionice, te su iste navedene abecednim redom u tablici na slici 2:

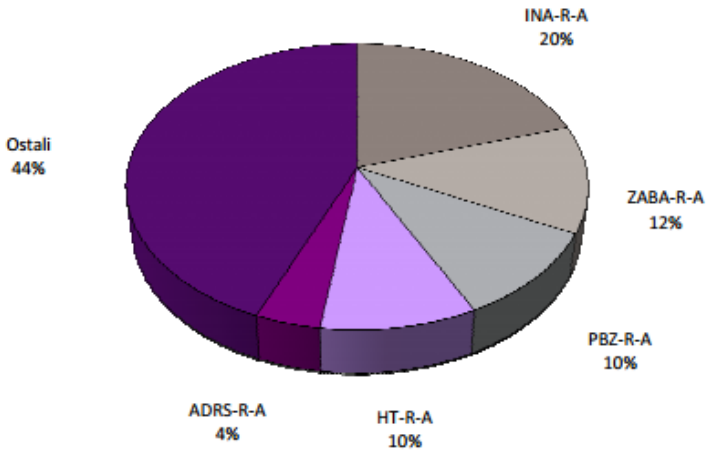
	Simbol	Izdavatelj	*Free float* faktor
1	ADPL-R-A	AD Plastik d.d.	70
2	ADRS-P-A	Adris grupa d.d.	100
3	ATGR-R-A	Atlantic Grupa d.d.	45
4	ATPL-R-A	Atlantska plovidba d.d.	75
5	ERNT-R-A	Ericsson Nikola Tesla d.d.	55
6	HT-R-A	HT d.d.	45
7	KOEI-R-A	Končar - elektroindustrija d.d.	100
8	LEDO-R-A	Ledo d.d.	55
9	PODR-R-A	Podravka d.d.	80
10	RIVP-R-A	VALAMAR RIVIERA d.d.	50

Slika 2: Odabrani uzorak dionica – CROBEX 10

Izvor: http://zse.hr/default.aspx?id=76010, 01.04.2017.

Za neka poduzeća na internetskoj stranici Zagrebačke burze objavljena su konsolidirana i nekonsolidirana financijska izvješća. Transakcije između povezanih društava (npr. između društva – majke i društva – kćeri) nisu prikazane u konsolidiranim izvještajima jer se ne smatraju transakcijom između neovisnih stranaka s aspekta gospodarskog subjekta, pa se zato konsolidirana financijska izvješća smatraju realnijim i objektivnijim prikazom poslovanja poduzeća. Iz tog razloga za poduzeća iz odabranog uzorka analizirani su podaci samo iz konsolidiranih financijskih izvještaja.

	Oznaka	Izdavatelj	Tržišna kapitalizacija (HRK mil)	Udjel (%)	Kumulativ (%)
1	INA-R-A	Ina d.d.	29.000,0	20,3	20,3
2	ZABA-R-A	Zagrebačka banka d.d.	17.293,1	12,1	32,3
3	PBZ-R-A	PBZ d.d.	14.668,5	10,2	42,6
4	HT-R-A	HT d.d.	13.839,2	9,7	52,2
5	ADRS-R-A	Adris grupa d.d.	5.769,5	4,0	56,3
6	JNAF-R-A	Janaf d.d.	5.340,6	3,7	60,0
7	RIVP-R-A	VALAMAR RIVIERA d.d.	4.393,3	3,1	63,1
8	LEDO-R-A	Ledo d.d.	3.348,0	2,3	65,4
9	ADRS-P-A	Adris grupa d.d.	3.120,0	2,2	67,6
10	JMNC-R-A	Jamnica d.d.	3.097,6	2,2	69,7
		Ostali	43.319,1	30,3	100,1
		Ukupno	**143.188,9**		

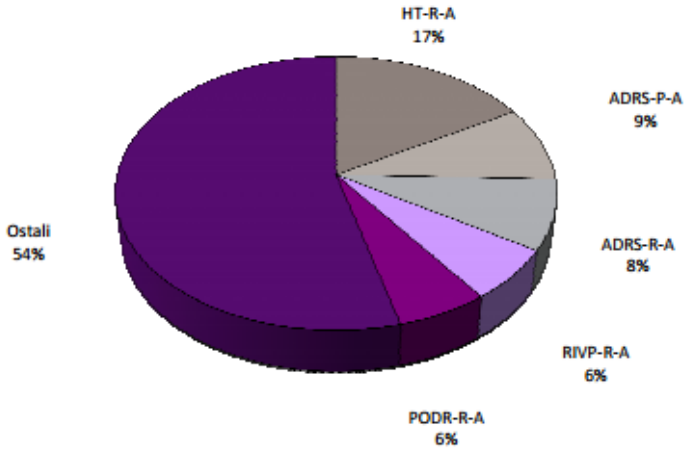


Slika 10: Struktura tržišne kapitalizacije

Slika 3: Dionice s najvećom tržišnom kapitalizacijom

Izvor: Zagrebačka burza, Pregled trgovine u 2016. godini, http://zse.hr/UserDocsImages/reports/ZSE-2016-nn.pdf, 01.04.2016.

	Oznaka	Izdavatelj	Free float (%)	Free float tržišna kapitalizacija (HRK mil)	Udjel (%)	Kumulativ (%)
1	HT-R-A	HT d.d.	42,3	5.859,5	16,7	16,7
2	ADRS-P-A	Adris grupa d.d.	100,0	3.120,0	8,9	25,5
3	ADRS-R-A	Adris grupa d.d.	50,5	2.913,6	8,3	33,8
4	RIVP-R-A	VALAMAR RIVIERA d.d.	49,3	2.164,6	6,2	40,0
5	PODR-R-A	Podravka d.d.	77,6	2.085,2	5,9	45,9
6	KOEI-R-A	Končar - elektroindustrija d.d.	99,8	1.770,7	5,0	50,9
7	INA-R-A	Ina d.d.	6,1	1.763,2	5,0	55,9
8	LEDO-R-A	Ledo d.d.	51,1	1.710,5	4,9	60,8
9	ATGR-R-A	Atlantic Grupa d.d.	44,0	1.294,0	3,7	64,5
10	ERNT-R-A	Ericsson Nikola Tesla d.d.	50,8	787,7	2,2	66,7
		Ostali		11.717,1	33,3	100,0
		Ukupno		**35.186,0**		

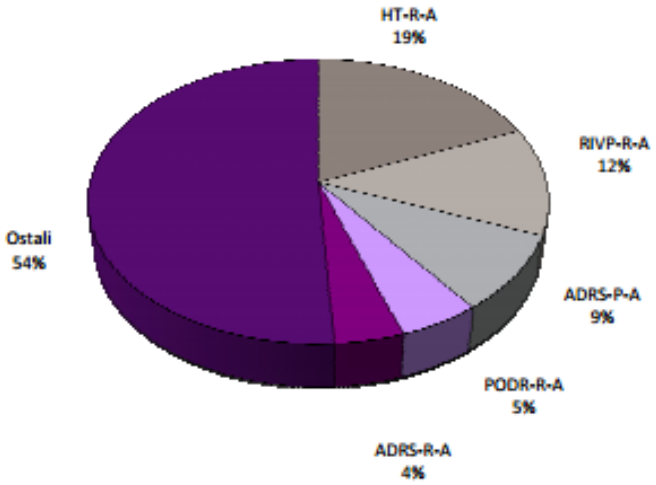


Slika 11: Struktura free float tržišne kapitalizacije

Slika 4: Dionice s najvećom free float tržišnom kapitalizacijom

Izvor: Zagrebačka burza, Pregled trgovine u 2016. godini, http://zse.hr/UserDocsImages/reports/ZSE-2016-nn.pdf, 01.04.2016.

	Oznaka	Izdavatelj	Promet (HRK)	Udjel (%)	Kumulativ (%)
1	HT-R-A	HT d.d.	356.689.146	18,7	18,7
2	RIVP-R-A	VALAMAR RIVIERA d.d.	233.599.222	12,2	30,9
3	ADRS-P-A	Adris grupa d.d.	168.052.920	8,8	39,7
4	PODR-R-A	Podravka d.d.	96.179.100	5,0	44,8
5	ADRS-R-A	Adris grupa d.d.	81.765.009	4,3	49,0
6	LEDO-R-A	Ledo d.d.	63.580.143	3,3	52,4
7	ERNT-R-A	Ericsson Nikola Tesla d.d.	53.187.987	2,8	55,1
8	ZABA-R-A	Zagrebačka banka d.d.	49.605.134	2,6	57,7
9	ATGR-R-A	Atlantic Grupa d.d.	49.176.388	2,6	60,3
10	HIMR-R-A	Imperial d.d.	45.396.117	2,4	62,7
		Ostali	712.259.692	37,3	100,0
		Ukupno	**1.909.490.857**		



Slika 12: Struktura prometa dionicama

Slika 5: Dionice s najvećim prometom

Izvor: Zagrebačka burza, Pregled trgovine u 2016. godini, http://zse.hr/UserDocsImages/reports/ZSE-2016-nn.pdf, 01.04.2016.

2.4.2. Sektorska analiza odabranih poduzeća iz početnog uzorka

Sektorska analiza poduzeća unutar djelatnosti se najčešće vrši prema udjelu proizvodnje promatranog poduzeća u usporedbi s proizvodnjom cijelog sektora ili prema prihodima. Za potrebe ovog rada, a u svrhu vremenskog skraćivanja cjelokupne analize poduzeća, nije izvršena sektorska analiza poduzeća iz odabranog uorka, već su podaci za 2015. godinu i 2014. godinu preuzeti s internetske stranice Ekonomskog Instituta Zagreb: www.eizg.hr, uz pretpostavku da se u 2016. godini stanje u pojedinim sektorima nije značajno promijenilo. Prema zadnjoj dostupnoj sektorskoj analizi telekomunikacija (za 2015. godinu) koju je izradio Ekonomski Institut Zagreb, poduzeće HT d.d. uvjerljivo je vodeće poduzeće u sektoru telekomunikacija s najvećim ukupnim prihodima, dok su mu glavni konkurenti u sektoru djelatnosti VIPnet d.o.o. i Tele2 d.o.o. (slika 6).

	Ukupni prihodi	Koeficijent zaduženosti	Koeficijent tekuće likvidnosti	Bruto marža	Proizvodnost rada
HT d.d.	6.014.665.200	0,13	3,24	18,63	1.546.584
VIPnet d.o.o.	2.920.318.700	0,82	0,49	1,10	2.500.273
Tele2 d.o.o.	1.244.177.500	1,19	0,91	-4,91	9.081.588
OT – Optima Telekom d.d.	441.444.600	0,85	1,10	2,77	1.155.614
Iskon Internet d.d.	384.127.700	0,31	1,08	2,28	2.099.058
H1 Telekom d.d.	254.034.000	1,77	0,75	1,63	1.309.454
Odašiljači i veze d.o.o.	232.526.900	0,29	1,47	11,14	807.385
Metronet telekomunikacije d.d.	224.527.500	0,93	1,13	13,13	1.100.625
Nokia Solutions and Networks d.o.o.	138.518.100	0,34	2,84	2,37	2.947.194
VIPnet usluge d.o.o.	134.293.400	0,01	28,31	46,12	1.839.636

Slika 6: Odabrani financijski pokazatelji poslovanja deset vodećih trgovačkih društava u sektoru telekomunikacija u 2015. godini

Izvor: Ekonomski Institut Zagreb, Sektorske analize – telekomunikacije, lipanj 2016., http://www.eizg.hr/hr-HR/Sektorske-analize-993.aspx, 20.04.2017.

Sektorska analiza turizma (za 2015. godinu) pokazuje da je poduzeće Valamar Riviera d.d. vodeće u tom sektoru, dok su mu glavni konkurenti u sektoru djelatnosti poduzeća Maistra d.d., Plava laguna d.d. i Istraturist Umag d.d., kao što je vidljvo na slici 7.

	Ukupni prihodi (u mil. kuna)	Bruto dobit (u mil. kuna)	Koeficijent zaduženosti	Koeficijent tekuće likvidnosti	Bruto marža	Produktivnost (u tis. kuna)
Valamar Riviera d.d.	1.269,3	126,8	0,4	1,8	10,0	583,0
Maistra d.d.	882,9	127,2	0,4	0,03	14,4	615,7
Plava laguna d.d.	524,2	75,5	0,3	1,6	14,4	83,8
Istraturist Umag d.d.	505,9	53,0	0,3	0,5	10,5	96,1
Jadranski luksuzni hoteli d.d.	396,5	85,7	0,5	1,2	21,6	500,0
Arenaturist d.d.	363,9	24,5	0,4	2,2	6,7	48,0
Dubrovački vrtovi sunca d.o.o.	340,0	-0,5	1,0	2,9	-0,1	1.434,6
Globalna hrana d.o.o.	322,1	37,5	0,2	1,6	11,6	503,2
Solaris d.d.	310,3	3,8	0,4	0,8	1,2	497,2
Liburnia Riviera Hoteli d.d.	278,1	0,3	0,2	1,4	0,1	468,2

Slika 7: Odabrani pokazatelji poslovanja deset najvećih trgovačkih društava prema prihodima u sektoru turizma u 2015. godini

Izvor: Ekonomski Institut Zagreb, Sektorske analize – turizam, studeni 2016., http://www.eizg.hr/hr-HR/Sektorske-analize-993.aspx, 20.04.2017.

Posljednja dostupna sektorska analiza sektora hrane i pića Ekonomskog Instituta Zagreb (za 2014. godinu) pokazuje da se poduzeća Podravka d.d. i Ledo d.d. nalaze na popisu pet vodećih trgovačkih društava u proizvodnji hrane, što je vidljivo na slici 8.

	Ukupni prihodi (mil. kn)	Koeficijent zaduženosti	Koeficijent tekuće likvidnosti	Bruto marža
Vindija d.d.	2.575,3	0,6	1,9	0,7
PIK Vrbovec – Mesna industrija d.d.	2.190,6	0,6	1,5	4,1
Podravka d.d.	1.957,9	0,5	0,7	10,3
Dukat d.d.	1.711,9	0,4	1800,2	4,4
Ledo d.d.	1.157,3	0,1	0,9	14,8
Mesna industrija braća Pivac d.o.o.	1.105,2	0,3	2,0	7,0
Kraš d.d.	891,1	0,5	2,7	2,3
Zvijezda d.d.	882,9	0,2	2,6	5,3
PPK d.d.	869,7	0,5	4,4	1,9
Franck d.d.	804,9	0,4	27,2	3,0

Slika 8: Deset vodećih trgovačkih društava u djelatnosti proizvodnje hrane – odabrani financijski pokazatelji, 2014.

Izvor: Ekonomski Institut Zagreb, Sektorske analize – hrana i piće, svibanj 2016., http://www.eizg.hr/hr-HR/Sektorske-analize-993.aspx, 20.04.2017.

2.4.3. Analiza uspješnosti poslovanja odabranog uzorka poduzeća

2.4.3.1. Pokazatelji likvidnosti

Fundamentalna analiza započeta je izračunom pokazatelja sigurnosti poslovanja, odnosno izračunom najčešće korištenih pokazatelja likvidnosti i pokazatelja zaduženosti za razdoblje od 2014. do 2016. godine. Kao pokazatelji likvidnosti odabranog uzorka izračunati su koeficijent tekuće likvidnosti, koeficijent ubrzane likvidnosti, koeficijent trenutne likvidnosti i koeficijent financijske stabilnosti. Koeficijentom tekuće likvidnosti (eng. current ratio) mjeri se sposobnost poduzeća da podmiri svoje kratkoročne obveze. U tablici 5 vidljivo je da je u posljednje tri godine koeficijent tekuće likvidnosti poduzeća Valamar Riviera d.d., Atlantic grupa d.d., AD Plastik d.d., Atlantska plovidba d.d. i Adris grupa d.d. (izuzev posljednje godine) manji od preporučenog koeficijenta (k>2), što znači da postoji mogućnost da navedena poduzeća ostanu bez sredstava za podmirenje svojih kratkoročnih obveza. Tekuća likvidnost ostalih poduzeća veća je od minimalne preporučene vrijednosti (označeno zelenom bojom u tablici 2). Ipak, realniji rezultati bi se dobili usporedbom koeficijenata tekuće likvidnosti analiziranih poduzeća s industrijskim prosjekom pojedinog sektora djelatnosti kojem promatrana poduzeća pripadaju, pri čemu koeficijent tekuće likvidnosti promatranog poduzeća ne bi trebao puno odstupati od industrijskog prosjeka.

Tablica 2: Izračun koeficijenta tekuće likvidnosti

PODUZEĆA		koeficijent tekuće likvidnosti (preporuka >2) = kratkotrajna imovina/kratkoročne obveze		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	3,05	3,02	3,05
2	Adris grupa d.d.	1,57	1,40	2,25
3	Valamar Riviera d.d.	1,09	1,55	0,85
4	Podravka d.d.	2,33	2,13	2,19
5	Končar - Elektroindustrija d.d.	2,20	2,82	2,97
6	Ledo d.d.	2,30	2,45	2,73
7	Atlantic grupa d.d.	1,64	1,37	1,54
8	Ericsson Nikola Tesla d.d.	2,68	2,60	2,16
9	AD Plastik d.d.	0,58	0,74	0,84
10	Atlantska plovidba d.d.	0,90	0,74	0,37

Izvor: Autor

Koeficijentom ubrzane likvidnosti (eng. quick ratio) mjeri se sposobnost poduzeća da podmiri svoje kratkoročne obveze, a bez prodaje zaliha. Također, ni ovaj pokazatelj ne bi trebao značajno odstupati od industrijskog prosjeka. Budući da industrijski prosjek za svaki od sektora djelatnosti analiziranih poduzeća nije poznat, odnosno nije izračunat, minimalna

zahtijevana vrijednost koeficijenta ubrzane likvidnosti je k>1. Iz tablice 3 vidljivo je da su poduzeća AD Plastik d.d. i Atlantska plovidba d.d. kroz cjelokupno promatrano razdoblje imali koeficijent ubrzane likvidnosti znatno manji od minimalne preporučene vrijednosti, dok je koeficijent ubrzane likvidnosti poduzeća Valamar Riviera d.d. i Atlantic grupa d.d. bi neznatno manji od minimalne preporučene vrijednosti, i to samo u jednoj od tri promatrane godine. Koeficijent ubrzane likvidnosti ostalih poduzeća veći je od minimalne preporučene vrijednosti, što znači da su poduzeća sposobna podmiriti svoje kratkoročne obveze bez prodaje zaliha (označeno zelenom bojom u tablici 3).

Tablica 3: Izračun koeficijenta ubrzane likvidnosti

PODUZEĆA		koeficijent ubrzane likvidnosti (preporuka > 1) = (kratkotrajna imovina-zalihe)/kratkoročne obveze		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	2,98	2,96	2,98
2	Adris grupa d.d.	1,33	1,29	2,12
3	Valamar Riviera d.d.	1,05	1,51	0,81
4	Podravka d.d.	1,37	1,25	1,34
5	Končar - Elektroindustrija d.d.	1,72	2,14	2,30
6	Ledo d.d.	1,68	1,82	2,26
7	Atlantic grupa d.d.	1,15	0,94	1,13
8	Ericsson Nikola Tesla d.d.	2,52	2,50	2,12
9	AD Plastik d.d.	0,43	0,50	0,58
10	Atlantska plovidba d.d.	0,63	0,54	0,28

Izvor: Autor

Koeficijent trenutne likvidnosti (eng. cash ratio) mjeri sposobnost poduzeća da novcem kojeg ima u banci i blagajni podmiri kratkoročne obveze. Preporučena vrijednost koeficijenta je k>0,1. Prema rezultatima prikazanim u tablici 4 vidljivo je da poduzeća Adris grupa d.d., Ledo d.d. i AD Plastik d.d. nemaju u banci i blagajni dovoljno novca za podmirenje kratkoročnih obveza, i to kroz cjelokupno promatrano razdoblje. Koeficijent trenutne likvidnosti ostalih poduzeća veći je od minimalne preporučene vrijednosti, što znači da su poduzeća sposobna podmiriti kratkoročne obveze novcem iz banke i blagajne (označeno zelenom bojom u tablici 4).

Tablica 4: Izračun koeficijenta trenutne likvidnosti

PODUZEĆA		koeficijent trenutne likvidnosti (preporuka > 0,1) = novac/kratkoročne obveze		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	1,24	1,79	1,54
2	Adris grupa d.d.	0,06	0,05	0,07
3	Valamar Riviera d.d.	0,89	1,39	0,70
4	Podravka d.d.	0,26	0,26	0,30
5	Končar - Elektroindustrija d.d.	0,36	0,46	0,66
6	Ledo d.d.	0,05	0,03	0,03
7	Atlantic grupa d.d.	0,30	0,22	0,32
8	Ericsson Nikola Tesla d.d.	0,93	1,09	0,84
9	AD Plastik d.d.	0,01	0,03	0,02
10	Atlantska plovidba d.d.	0,54	0,44	0,21

Izvor: Autor

U tablici 5 vidljivo je da je koeficijent financijske stabilnosti poduzeća Valamar Riviera d.d., AD Plastik d.d. i Atlantska plovidba d.d. neznatno veći od preporučene gornje granice (k<1), što znači da je dugotrajna imovina navedenih poduzeća financirana iz kratkoročnih obveza, tj. da postoji deficit radnog (obrtnog) kapitala. Ostala poduzeća imaju koeficijent u preporučenim granicama (označeno zelenom bojom u tablici 5).

Tablica 5: Izračun koeficijenta financijske stabilnosti

PODUZEĆA		koeficijent financijske stabilnosti (preporuka < 1) = dugotrajna imovina/(kapital+dugoročne obveze)		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	0,69	0,69	0,71
2	Adris grupa d.d.	0,91	0,91	0,77
3	Valamar Riviera d.d.	1,01	1,01	1,04
4	Podravka d.d.	0,60	0,60	0,70
5	Končar - Elektroindustrija d.d.	0,61	0,61	0,58
6	Ledo d.d.	0,46	0,46	0,34
7	Atlantic grupa d.d.	0,80	0,80	0,82
8	Ericsson Nikola Tesla d.d.	0,46	0,46	0,70
9	AD Plastik d.d.	1,24	1,09	1,05
10	Atlantska plovidba d.d.	1,05	1,08	1,15

Izvor: Autor

2.4.3.2. Pokazatelji zaduženosti

Koeficijent zaduženosti pokazuje odnos ukupnih obveza i ukupne imovine, te bi trebao biti manji ili jednak vrijednosti 0,5 (50%). Iz tablice 6 vidi se da je koeficijent zaduženosti poduzeća Atlantic grupa d.d., Ericsson Nikola Tesla d.d. i Atlantska plovidba d.d. kroz promatrano trogodišnje razdoblje bio nešto veći od maksimalne preporučene vrijednosti (označeno crvenom bojom u tablici 6), što znači da je čak 63% imovine poduzeća Atlantic grupa d.d., odnosno 65% imovine poduzeća Ericsson Nikola Tesla d.d. i 68% imovine poduzeća Atlantska plovidba d.d. 2016. godine financirano iz tuđih izvora, dok se koeficijent zaduženosti poduzeća AD Plastik d.d. u posljednjoj promatranoj godini stabilizirao na vrijednosti 0,48. Ostala poduzeća imaju koeficijent zaduženosti u preporučenim granicama (obojano zelenom bojom u tablici 6).

Tablica 6: Izračun koeficijenta zaduženosti

PODUZEĆA		koeficijent zaduženosti (preporuka ≤ 0,5) = ukupne obveze/ukupna imovina		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	0,19	0,17	0,17
2	Adris grupa d.d.	0,49	0,50	0,47
3	Valamar Riviera d.d.	0,38	0,47	0,47
4	Podravka d.d.	0,49	0,43	0,45
5	Končar - Elektroindustrija d.d.	0,42	0,36	0,36
6	Ledo d.d.	0,31	0,30	0,29
7	Atlantic grupa d.d.	0,67	0,63	0,63
8	Ericsson Nikola Tesla d.d.	0,52	0,57	0,65
9	AD Plastik d.d.	0,60	0,54	0,48
10	Atlantska plovidba d.d.	0,64	0,66	0,68

Izvor: Autor

Koeficijent vlastitog financiranja prikazuje odnos vlastitog kapitala i ukupne imovine, odnosno pokazuje koliki je dio imovine financiran iz vlastitih izvora. Prema podacima prikazanim u tablici 7, poduzeća Atlantic grupa d.d., Ericsson Nikola Tesla d.d. i Atlantska plovidba d.d. kroz cjelokupno promatrano trogodišnje razdoblje imaju koeficijent vlastitog financiranja ispod preporučene minimalne preporučene vrijednosti 0,5 (označeno crvenom bojom u tablici 7). Dakle, samo 37% imovine poduzeća Atlantic grupa d.d., odnosno 35% imovine poduzeća Ericsson Nikola Tesla d.d. i 32% imovine poduzeća Atlantska plovidba d.d. financirano je iz vlastitih izvora u 2016. godini. Poduzeće AD Plastik povećalo je tu vrijednost malo iznad minimalne preporučene vrijednosti u zadnjoj promatranoj godini, pa je 52% imovine u 2016. godini financirano iz vlastitih sredstava. Ostala poduzeća kroz

cjelokupno promatrano razdoblje imaju koeficijent vlastitog financiranja >0,5 (označeno zelenom bojom u tablici 7).

Tablica 7: Izračun koeficijenta vlastitog financiranja

PODUZEĆA		koeficijent vlastitog financiranja (preporuka > 0,5) = vlastiti kapital/ukupna imovina		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	0,81	0,83	0,83
2	Adris grupa d.d.	0,51	0,50	0,53
3	Valamar Riviera d.d.	0,62	0,53	0,53
4	Podravka d.d.	0,51	0,57	0,55
5	Končar - Elektroindustrija d.d.	0,58	0,64	0,64
6	Ledo d.d.	0,69	0,70	0,71
7	Atlantic grupa d.d.	0,33	0,37	0,37
8	Ericsson Nikola Tesla d.d.	0,48	0,43	0,35
9	AD Plastik d.d.	0,40	0,46	0,52
10	Atlantska plovidba d.d.	0,36	0,34	0,32

Izvor: Autor

Zbroj koeficijenta zaduženosti i koeficijenta vlastitog financiranja bi trebao biti 1, odnosno 100%, što je slučaj kod svih poduzeća u tablicama 6 i 7.

Koeficijent financiranja pokazuje odnos ukupnih obveza (duga, tj. tuđeg kapitala) i vlastitog kapitala, te je preporuka da navedeni pokazatelj bude manji od 2. Prema rezultatima prikazanim u tablici 8, sva poduzeća zadovoljavaju zadani kriterij kroz promatrano trogodišnje razdoblje, osim poduzeća Atlantic grupa d.d. čiji je koeficijent financiranja 2014. godine bio neznatno veći od 2 i poduzeća Atlantska plovidba d.d. čiji je koeficijent financiranja 2016. godine iznosio 2,15. Također, može se primijetiti da osim poduzeća Atlantska plovidba d.d. i poduzeća Atlantic grupa d.d. i Ericsson Nikola Tesla d.d. imaju dosta veći koeficijent financiranja u usporedbi s ostalim poduzećima, što može ukazivati na moguće poteškoće pri vraćanju posuđenih sredstava i plaćanju kamata.

Tablica 8: Izračun koeficijenta financiranja

PODUZEĆA		koeficijent financiranja (preporuka < 2) = ukupni dug (obveze)/vlastiti kapital		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	0,23	0,21	0,20
2	Adris grupa d.d.	0,95	0,99	0,90
3	Valamar Riviera d.d.	0,60	0,88	0,88
4	Podravka d.d.	0,97	0,76	0,81
5	Končar - Elektroindustrija d.d.	0,71	0,57	0,55
6	Ledo d.d.	0,46	0,44	0,40
7	Atlantic grupa d.d.	2,01	1,72	1,68
8	Ericsson Nikola Tesla d.d.	1,09	1,35	1,82
9	AD Plastik d.d.	1,51	1,16	0,92
10	Atlantska plovidba d.d.	1,76	1,98	2,15

Izvor: Autor

U tablici 9 prikazan je stupanj pokrića II, koji prikazuje odnos vlastitog kapitala uvećanog za dugoročne obveze i dugotrajne imovine, a njegova preporučena vrijednost bi trebala biti veća od 1, jer dio dugoročnih izvora mora biti iskorišten za financiranje kratkotrajne imovine kako bi se održala likvidnost poduzeća. U tablici 9 vidljivo je da poduzeća AD Plastik d.d. i Atlantska plovidba d.d. ne zadovoljavaju zadani kriterij kroz trogodišnje promatrano razdoblje, dok poduzeće Valamar Riviera d.d. taj kriterij nije zadovoljilo 2014. i 2016. godine (označeno crvenom bojom u tablici 9).

Tablica 9: Izračun stupnja pokrića II

PODUZEĆA		stupanj pokrića II (preporuka >1) = (vl. kapital+dugoročne obveze)/dugotrajna imovina		
		2014.	2015.	2016.
1	Hrvatski Telekom d.d.	1,44	1,44	1,41
2	Adris grupa d.d.	1,10	1,00	1,29
3	Valamar Riviera d.d.	0,92	1,01	0,96
4	Podravka d.d.	1,66	1,46	1,43
5	Končar - Elektroindustrija d.d.	1,63	1,64	1,72
6	Ledo d.d.	2,19	2,56	2,94
7	Atlantic grupa d.d.	1,25	1,14	1,22
8	Ericsson Nikola Tesla d.d.	2,18	2,01	1,42
9	AD Plastik d.d.	0,80	0,92	0,95
10	Atlantska plovidba d.d.	0,95	0,93	0,87

Izvor: Autor

2.4.3.3. Pokazatelji profitabilnosti

U tablici 10 prikazani su podaci potrebni za izračun najčešće korištenih pokazatelja profitabilnosti, povrata na ukupnu imovinu (eng. return on assets, ROA) i povrata na vlastiti kapital (eng. return on equity, ROE), dok je u tablici 11 prikazan izračun navedenih pokazatelja za 2016. godinu. Neto dobit u tablici 10 je sveobuhvatna dobit razdoblja preuzeta iz konsolidiranog financijskog izvještaja za 2016. godinu, odnosno iz računa dobiti i gubitka.

Tablica 10: Podaci za izračun pokazatelja profitabilnosti ROA i ROE

PODUZEĆA		PODACI ZA IZRAČUN POKAZATELJA ROA I ROE (2016.g.)		
		NETO DOBIT (kn)	UKUPNA IMOVINA (kn)	VLASTITI KAPITAL (kn)
1	Hrvatski Telekom d.d.	926.394.441	14.454.562.443	12.046.280.716
2	Adris grupa d.d.	605.171.640	19.114.926.595	10.051.054.213
3	Valamar Riviera d.d.	311.397.563	4.465.334.310	2.373.637.039
4	Podravka d.d.	177.324.119	5.285.727.544	2.926.394.388
5	Končar - Elektroindustrija d.d.	174.888.547	3.794.665.652	2.446.144.255
6	Ledo d.d.	272.785.378	2.630.214.571	1.876.128.952
7	Atlantic grupa d.d.	123.532.923	5.395.840.728	2.016.487.925
8	Ericsson Nikola Tesla d.d.	110.695.198	808.124.124	286.878.862
9	AD Plastik d.d.	75.065.045	1.340.480.429	697.373.047
10	Atlantska plovidba d.d.	-69.284.136	1.848.335.260	586.143.861

Izvor: Autor

Tablica 11: Izračun pokazatelja profitabilnosti ROA i ROE

PODUZEĆA		IZRAČUN POKAZATELJA ROA I ROE (2016. g.)	
		ROA (%)	ROE (%)
1	Hrvatski Telekom d.d.	6,41	7,69
2	Adris grupa d.d.	3,17	6,02
3	Valamar Riviera d.d.	6,97	13,12
4	Podravka d.d.	3,35	6,06
5	Končar - Elektroindustrija d.d.	4,61	7,15
6	Ledo d.d.	10,37	14,54
7	Atlantic grupa d.d.	2,29	6,13
8	Ericsson Nikola Tesla d.d.	13,70	38,59
9	AD Plastik d.d.	5,60	10,76
10	Atlantska plovidba d.d.	-3,75	-11,82

Izvor: Autor

ROA pokazuje dobit koju poduzeće generira iz jedne novčane jedinice ukupne imovine. Prema podacima iz tablice 11 vidljivo je da su najveći povrat na ukupnu imovinu 2016. godine ostvarila poduzeća Ericson Nikola Tesla d.d. i Ledo d.d., dok je poduzeće Atlantska plovidba d.d. 2016. godine ostvarilo gubitak, pa je zato ROA negativan. ROE pokazuje koliko novčanih jedinica dobiti poduzeće ostvaruje na jednu jedinicu vlastitog kapitala. Najveći povrat na vlastiti kapital 2016. godine ostvarilo je poduzeće Ericsson Nikola Tesla d.d., i to čak 38,59 %, što je znatno više od minimalnih preporučenih 15 %, pri kojima se poduzeće smatra uspješnim, dok je poduzeće Atlantska plovidba d.d. 2016. godine ostvarilo gubitak, pa je sukladno tome i ROE negativan.

2.4.3.4. Skupni pokazatelji

Za poduzeća iz odabranog uzorka izračunat je skupni pokazatelj uporabom korigiranog Altmanovog Z-score modela (Z``), jednog od najpoznatijih i najčešće korištenih modela za izračun skupnih pokazatelja. Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a prikazani su u tablici 12, 13 i 14 (podaci za 2016. godinu), dok je u tablici 15 prikazana izračunata vrijednost navedenog skupnog pokazatelja za svako poduzeće iz odabranog uzorka.

Tablica 12: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a

PODUZEĆA		PODACI ZA IZRAČUN KORIGIRANOG ALTMANOVOG Z" SCORE-A			
		Kratkotrajna imovina (kn)	Kratkoročne obveze (kn)	Obrtni kapital (kn)	Ukupna imovina(kn)
1	Hrvatski Telekom d.d.	5.303.862.887	1.741.222.810	3.562.640.077	14.454.562.443
2	Adris grupa d.d.	7.235.080.393	3.218.513.723	4.016.566.670	19.114.926.595
3	Valamar Riviera d.d.	336.880.206	394.111.168	-57.230.962	4.465.334.310
4	Podravka d.d.	2.468.920.107	1.125.024.230	1.343.895.877	5.285.727.544
5	Končar - Elektroindustrija d.d.	2.298.840.155	772.789.614	1.526.050.541	3.794.665.652
6	Ledo d.d.	1.980.466.270	725.735.408	1.254.730.862	2.630.214.571
7	Atlantic grupa d.d.	2.375.796.176	1.545.779.942	830.016.234	5.395.840.728
8	Ericsson Nikola Tesla d.d.	576.820.993	267.298.329	309.522.664	808.124.124
9	AD Plastik d.d.	352.261.291	421.301.055	-69.039.764	1.340.480.429
10	Atlantska plovidba d.d.	125.078.980	333.971.899	-208.892.919	1.848.335.260

Izvor: Autor

Tablica 13: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a

PODUZEĆA		PODACI ZA IZRAČUN KORIGIRANOG ALTMANOVOG Z" SCORE-A	
		Zadržana dobit (kn)	Dobit prije kamata i poreza (kn)
1	Hrvatski Telekom d.d.	633.035.014	1.162.296.942
2	Adris grupa d.d.	414.056.394	649.696.504
3	Valamar Riviera d.d.	36.580.064	271.909.189
4	Podravka d.d.	400.872.825	238.962.374
5	Končar - Elektroindustrija d.d.	293.603.279	193.631.055
6	Ledo d.d.	592.367.466	346.283.079
7	Atlantic grupa d.d.	916.898.363	204.145.102
8	Ericsson Nikola Tesla d.d.	22.120.979	118.827.444
9	AD Plastik d.d.	54.290.345	47.496.264
10	Atlantska plovidba d.d.	-1.447.275	-93.639.823

Izvor: Autor

Tablica 14: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a

PODUZEĆA		PODACI ZA IZRAČUN KORIGIRANOG ALTMANOVOG Z" SCORE-A	
		Knjigovodstvena vr. dioničkog kapitala (kn)	Knjigovodstvena vr. ukupnih obveza (kn)
1	Hrvatski Telekom d.d.	9.822.853.500	2.408.281.727
2	Adris grupa d.d.	164.000.000	9.063.872.382
3	Valamar Riviera d.d.	1.672.021.210	2.091.697.271
4	Podravka d.d.	1.566.400.660	2.359.333.156
5	Končar - Elektroindustrija d.d.	1.208.895.930	1.348.521.397
6	Ledo d.d.	119.289.600	754.085.619
7	Atlantic grupa d.d.	133.372.000	3.379.352.803
8	Ericsson Nikola Tesla d.d.	133.165.000	521.245.263
9	AD Plastik d.d.	419.958.400	643.107.382
10	Atlantska plovidba d.d.	418.656.000	1.262.191.399

Izvor: Autor

Tablica 15: Izračunata vrijednost korigiranog Altmanovog Z`` score-a

PODUZEĆA		IZRAČUN KORIGIRANOG ALTMANOVOG Z'' SCORE-A				
		X1	X2	X3	X4	Z'' SCORE
1	Hrvatski Telekom d.d.	0,25	0,04	0,08	4,08	6,58
2	Adris grupa d.d.	0,21	0,02	0,03	0,02	1,70
3	Valamar Riviera d.d.	-0,01	0,01	0,06	0,80	1,19
4	Podravka d.d.	0,25	0,08	0,05	0,66	2,92
5	Končar - Elektroindustrija d.d.	0,40	0,08	0,05	0,90	4,17
6	Ledo d.d.	0,48	0,23	0,13	0,16	4,91
7	Atlantic grupa d.d.	0,15	0,17	0,04	0,04	1,86
8	Ericsson Nikola Tesla d.d.	0,38	0,03	0,15	0,26	3,86
9	AD Plastik d.d.	-0,05	0,04	0,04	0,65	0,72
10	Atlantska plovidba d.d.	-0,11	0,00	-0,05	0,33	-0,74

Izvor: Autor

Prema izračunatoj vrijednosti korigiranog Altmanovog Z``score-a u tablici 15 može se zaključiti da poduzećima Atlantska plovidba d.d. i AD Plastik d.d. prijeti bankrot (Z``<1,11), poduzeća Adris grupa d.d., Valamar Riviera d.d. i Atlantic grupa d.d. se nalaze u tzv. sivoj zoni, pri čemu je poduzeće Valamar Riviera d.d. na granici bankrota (1,11<Z``<2,59), dok se poduzeća Hrvatski Telekom d.d., Podravka d.d., Končar – Elektroindustrija d.d., Ledo d.d. i Ericsson Nikola Tesla d.d. nalaze u sigurnoj zoni, odnosno financijski su zdrava poduzeća.

2.4.4. Procjena vrijednosti poduzeća knjigovodstvenom metodom

Knjigovodstvena vrijednost poduzeća jednaka je vrijednosti aktive (ukupne imovine) poduzeća umanjenoj za vrijednost ukupnih obveza. Prema podacima preuzetim iz bilanci analiziranih poduzeća objavljenih na internetskoj stranici Zagrebačke burze: www.zse.hr, kreirane su tablice 16, 17 i 18 s izračunom knjigovodstvene vrijednosti poduzeća za 2014., 2015. i 2016. godinu.

Tablica 16: Izračun knjigovodstvene vrijednosti poduzeća (2014. godina)

PODUZEĆA		KNJIGOVODSTVENA VRIJEDNOST = AKTIVA - UKUPNE OBVEZE (2014. godina)		
		AKTIVA (ukupna imovina) (kn)	UKUPNE OBVEZE (kn)	KNJIGOVODSTVENA VRIJEDNOST (kn)
1	Hrvatski Telekom d.d.	13.840.244.870	2.564.000.503	11.276.244.367
2	Adris grupa d.d.	18.053.653.847	8.800.132.564	9.253.521.283
3	Valamar Riviera d.d.	3.015.504.267	1.131.767.645	1.883.736.622
4	Podravka d.d.	3.508.570.553	1.723.307.395	1.785.263.158
5	Končar - Elektroindustrija d.d.	3.918.482.969	1.633.478.131	2.285.004.838
6	Ledo d.d.	2.326.713.538	731.856.316	1.594.857.222
7	Atlantic grupa d.d.	5.274.256.928	3.519.193.233	1.755.063.695
8	Ericsson Nikola Tesla d.d.	699.584.715	364.118.140	335.466.574
9	AD Plastik d.d.	1.520.701.175	914.223.155	606.478.020
10	Atlantska plovidba d.d.	2.227.862.566	1.421.773.660	806.088.906

Izvor: Autor

Tablica 17: Izračun knjigovodstvene vrijednosti poduzeća (2015. godina)

PODUZEĆA		KNJIGOVODSTVENA VRIJEDNOST = AKTIVA - UKUPNE OBVEZE (2015. godina)		
		AKTIVA (ukupna imovina) (kn)	UKUPNE OBVEZE (kn)	KNJIGOVODSTVENA VRIJEDNOST (kn)
1	Hrvatski Telekom d.d.	14.079.437.450	2.438.091.712	11.641.345.738
2	Adris grupa d.d.	19.185.135.204	9.546.118.912	9.639.016.292
3	Valamar Riviera d.d.	3.566.618.693	1.664.928.013	1.901.690.680
4	Podravka d.d.	4.945.750.520	2.127.994.834	2.817.755.686
5	Končar - Elektroindustrija d.d.	3.650.038.393	1.328.542.359	2.321.496.034
6	Ledo d.d.	2.558.895.389	779.266.837	1.779.628.552
7	Atlantic grupa d.d.	5.294.568.091	3.349.260.913	1.945.307.178
8	Ericsson Nikola Tesla d.d.	723.866.108	415.938.344	307.927.764
9	AD Plastik d.d.	1.345.377.124	722.421.608	622.955.516
10	Atlantska plovidba d.d.	1.967.881.036	1.307.537.373	660.343.663

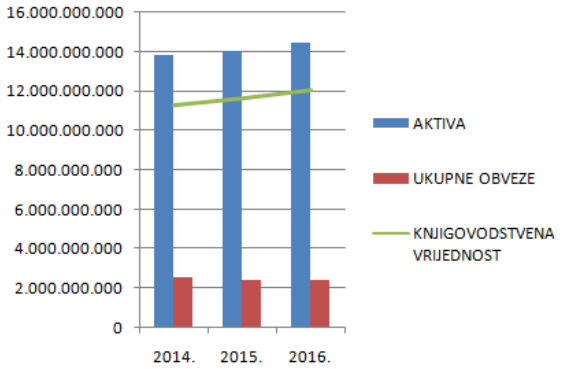
Izvor: Autor

Tablica 18: Izračun knjigovodstvene vrijednosti poduzeća (2016. godina)

PODUZEĆA		KNJIGOVODSTVENA VRIJEDNOST = AKTIVA - UKUPNE OBVEZE (2016. godina)		
		AKTIVA (ukupna imovina) (kn)	UKUPNE OBVEZE (kn)	KNJIGOVODSTVENA VRIJEDNOST (kn)
1	Hrvatski Telekom d.d.	14.454.562.443	2.408.281.727	12.046.280.716
2	Adris grupa d.d.	19.114.926.595	9.063.872.382	10.051.054.213
3	Valamar Riviera d.d.	4.465.334.310	2.091.697.271	2.373.637.039
4	Podravka d.d.	5.285.727.544	2.359.333.156	2.926.394.388
5	Končar - Elektroindustrija d.d.	3.794.665.652	1.348.521.397	2.446.144.255
6	Ledo d.d.	2.630.214.571	754.085.619	1.876.128.952
7	Atlantic grupa d.d.	5.395.840.728	3.379.352.803	2.016.487.925
8	Ericsson Nikola Tesla d.d.	808.124.124	521.245.263	286.878.862
9	AD Plastik d.d.	1.340.480.429	643.107.382	697.373.047
10	Atlantska plovidba d.d.	1.848.335.260	1.262.191.399	586.143.861

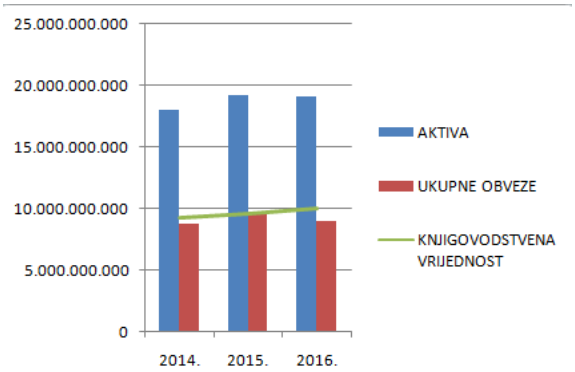
Izvor: Autor

Dobiveni rezultati su grafički prikazani na slikama 9 – 18, pojedinačno za svako poduzeće:



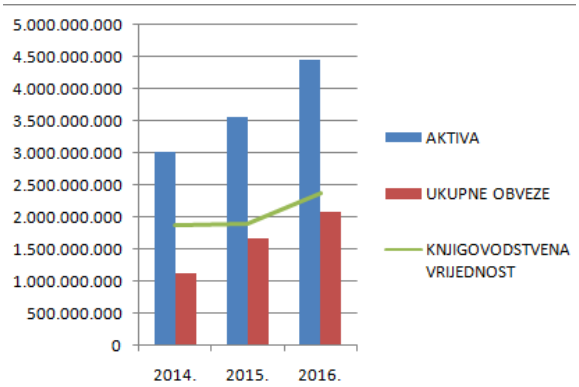
Slika 9: HT d.d.

Izvor: Autor



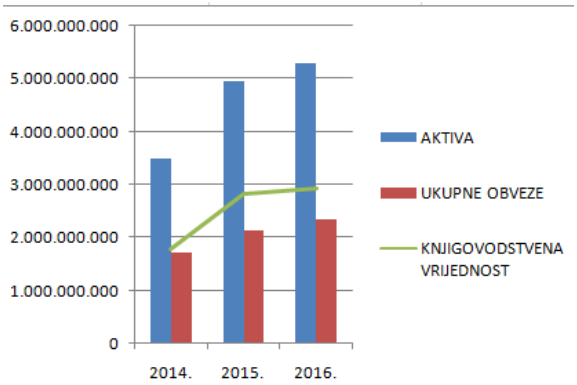
Slika 10: Adris grupa d.d.

Izvor: Autor



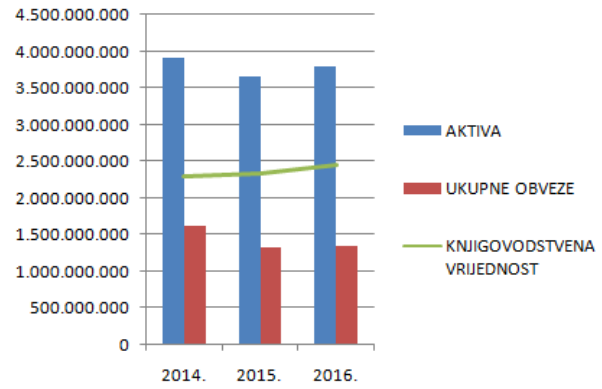
Slika 11: Valamar Riviera d.d.

Izvor: Autor



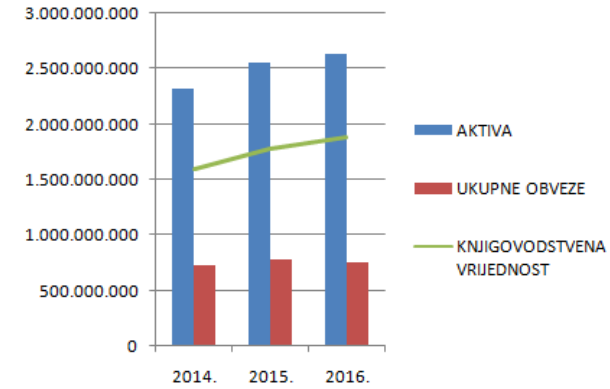
Slika 12: Podravka d.d.

Izvor: Autor



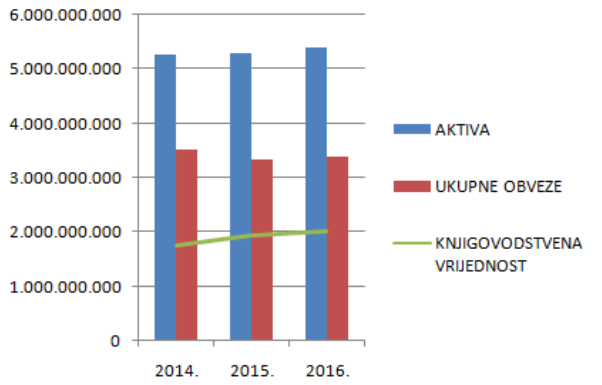
Slika 13: Končar - Elektroindustrija d.d.

Izvor: Autor



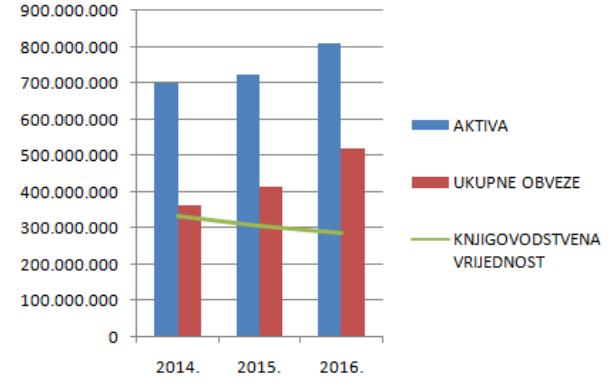
Slika 14: Ledo d.d.

Izvor: Autor



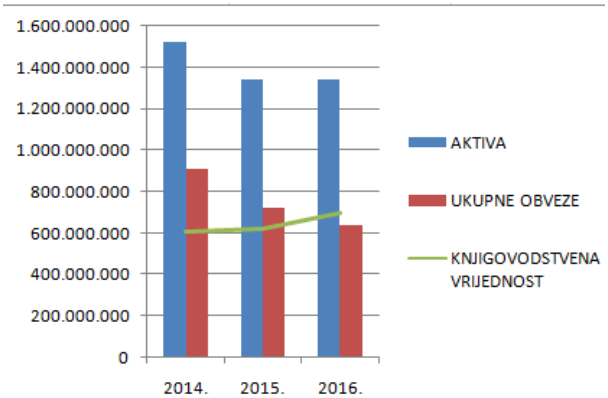
Slika 15: Atlantic grupa d.d.

Izvor: Autor



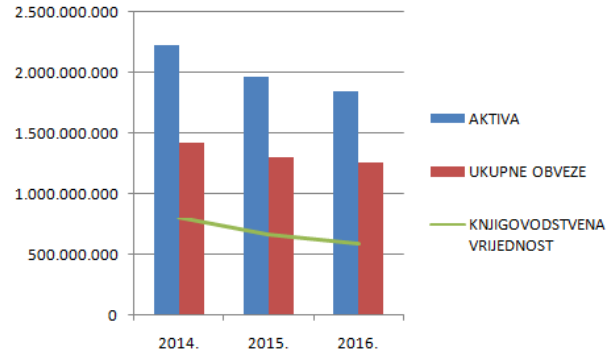
Slika 16: Ericsson Nikola Tesla d.d.

Izvor: Autor



Slika 17: AD Plastik d.d.

Izvor: Autor



Slika 18: Atlantska plovidba d.d.

Izvor: Autor

Iz grafičkog prikaza knjigovodstvene vrijednosti poduzeća na slikama 9-18 vidljivo je da je u posljednje tri godine knjigovodstvena vrijednost poduzeća HT d.d., Adris d.d., Valamar

Riviera d.d., Podravka d.d., Končar – Elektroindustrija d.d., Ledo d.d., Atlantic grupa d.d. i AD Plastik d.d. kroz promatrano razdoblje rasla, dok je knjigovodstvena vrijednost poduzeća Atlantska plovidba d.d. i Ericsson Nikola Tesla d.d. pokazala pad kroz promatrano razdoblje. Poduzeća Valamar Riviera d.d., Končar – Elektroindustrija d.d. i AD Plastik d.d. u posljednjih godinu dana (od 2015.g. do 2016.g.) pokazuju rast knjigovodstvene vrijednosti po rastućoj stopi, što je najviše vidljivo kod poduzeća Valamar Riviera d.d., a knjigovodstvena vrijednost poduzeća Podravka d.d., Ledo d.d. i Atlantic grupa d.d. je rastuća po opadajućoj stopi. U tablici 19 prikazan je izračun knjigovodstvene vrijednosti poduzeća po dionici za 2016. godinu, pri čemu je za poduzeće Adris d.d. broj dionica izračunat kao zbroj redovnih i povlaštenih dionica emitiranih na Zagrebačkoj burzi.

Tablica 19: Izračun knjigovodstvene vrijednosti poduzeća po dionici (2016. godina)

PODUZEĆA		KNJIGOVODSTVENA VRIJEDNOST PO DIONICI (2016.g.)		
		KNJIGOVODSTVENA VRIJEDNOST (kn)	BROJ DIONICA	KNJIGOVODSTVENA VR. PO DIONICI (kn)
1	Hrvatski Telekom d.d.	12.046.280.716	81.888.535	147,11
2	Adris grupa d.d.	10.051.054.213	16.400.000	612,87
3	Valamar Riviera d.d.	2.373.637.039	126.027.542	18,83
4	Podravka d.d.	2.926.394.388	7.120.003	411,01
5	Končar - Elektroindustrija d.d.	2.446.144.255	2.572.119	951,02
6	Ledo d.d.	1.876.128.952	313.920	5.976,46
7	Atlantic grupa d.d.	2.016.487.925	3.334.300	604,77
8	Ericsson Nikola Tesla d.d.	286.878.862	1.331.650	215,43
9	AD Plastik d.d.	697.373.047	4.199.584	166,06
10	Atlantska plovidba d.d.	586.143.861	1.395.520	420,02

Izvor: Autor

2.4.5. Procjena vrijednosti poduzeća metodom multiplikatora

U nastavku će se prikazati izračun vrijednosti poduzeća P/E multiplikatorom i P/B multiplikatorom.

2.4.5.1. Procjena vrijednosti poduzeća P/E multiplikatorom

U tablici 20 prikazan je izračun neto dobiti po dionici poduzeća (EPS), a u tablici 21 prikazan je izračun P/E multiplikatora.

Tablica 20: Izračun EPS-a

PODUZEĆA		EPS (earnings per share) = NETO DOBIT/BROJ DIONICA		
		NETO DOBIT (kn)	BROJ DIONICA	EPS (kn)
1	Hrvatski Telekom d.d.	926.394.441	81.888.535	11,31
2	Adris grupa d.d.	605.171.640	16.400.000	36,90
3	Valamar Riviera d.d.	311.397.563	126.027.542	2,47
4	Podravka d.d.	177.324.119	7.120.003	24,91
5	Končar - Elektroindustrija d.d.	174.888.547	2.572.119	67,99
6	Ledo d.d.	272.785.378	313.920	868,96
7	Atlantic grupa d.d.	123.532.923	3.334.300	37,05
8	Ericsson Nikola Tesla d.d.	110.695.198	1.331.650	83,13
9	AD Plastik d.d.	75.065.045	4.199.584	17,87
10	Atlantska plovidba d.d.	-69.284.136	/	/

Izvor: Autor

Tablica 21: Izračun P/E multiplikatora

PODUZEĆA		MULTIPLIKATOR P/E=CIJENA DIONICE (ZAKLJUČNA)/EPS		
		EPS (kn)	ZAKLJUČNA CIJENA DIONICE 2016. G. (kn)	P/E
1	Hrvatski Telekom d.d.	11,31	169,00	14,94
2	Adris grupa d.d.	36,90	529,95	14,36
3	Valamar Riviera d.d.	2,47	34,86	14,11
4	Podravka d.d.	24,91	377,50	15,16
5	Končar - Elektroindustrija d.d.	67,99	690,00	10,15
6	Ledo d.d.	868,96	10.665,00	12,27
7	Atlantic grupa d.d.	37,05	882,00	23,81
8	Ericsson Nikola Tesla d.d.	83,13	1.164,00	14,00
9	AD Plastik d.d.	17,87	138,00	7,72
10	Atlantska plovidba d.d.	/	/	/

Izvor: Autor

Neto dobit u tablici 20 je sveobuhvatna dobit razdoblja preuzeta iz konsolidiranog financijskog izvještaja za 2016. godinu, odnosno iz računa dobiti i gubitka. Tablica 21 prikazuje izračun P/E multiplikatora, pri čemu je zbog pojednostavnjenja postupka kao zaključna cijena dionice poduzeća Adris d.d. korišten prosjek zaključne cijene redovne dionice (600,00 kn) i zaključne cijene povlaštene dionice (459,90 kn). U tablici 22 prikazan je

izračun vrijednosti poduzeća metodom multiplikatora P/E, a u tablici 23 je prikazana vrijednost poduzeća po dionici izračunata uporabom metode P/E multiplikatora. Kao usporedivi multiplikator P/E za poduzeće HT d.d. izračunat je multiplikator za poduzeće OT – Optima telekom d.d.. Iako su poduzeća VIPnet d.o.o. Tele2 d.o.o. odmah iza poduzeća HT d.d. na popisu deset vodećih trgovačkih društava u sektoru telekomunikacija 2015. godine, nisu uzeti u obzir pri izračunu usporedivog multiplikatora P/E jer nisu dionička društva, dok dionice konkurentskih poduzeća Iskon Internet d.d. i H1 Telekom d.d. nisu uvrštena na burzu. Kao usporediva poduzeća za poduzeće Valamar Riviera d.d. odabrani su Maistra d.d. i Plava laguna d.d. kao najveći konkurenti u sektoru djelatnosti, te je na taj popis dodana i Adris grupa d.d., budući da je većim dijelom glavna djelatnost tog poduzeća turističkog karaktera. Ista poduzeća odabrana su kao usporediva poduzeća za poduzeće Adris grupa d.d., pri čemu je poduzećima Maistra d.d. i Plava laguna d.d. pridodano i poduzeće Valamar Riviera d.d.. U istu grupu poduzeća pri izračunu P/E multiplikatora za poduzeća Podravka d.d., Ledo d.d. i Atlantic grupa d.d. uvršteno je i poduzeće Dukat d.d.. Iako su poduzeća Vindija d.d. i PIK Vrbovec – Mesna industrija d.d. bili najveći konkurenti navedenim poduzećima 2014.godine prema popisu deset vodećih trgovačkih društava u djelatnosti proizvodnje hrane za 2014. godinu, nisu uzeti u obzir jer su izvršteni s burze. Kao usporediva poduzeća za Končar - Elektroindustrija d.d. korišteno je poduzeće Končar – distributivni i specijalni transformatori d.d., dok je konkurentsko poduzeće Đuro Đaković grupa d.d. isključeno iz grupe usporedivih poduzeća jer je 2016. godine ostvarilo gubitak. Poduzeće RIZ odašiljači d.d. odabrano je kao usporedivo poduzeće za Ericsson Nikola Tesla d.d., dok je poduzeće Uljanik d.d. odabrano kao usporedivo poduzeće za poduzeće AD Plastik d.d.. P/E multiplikator nije izračunat za poduzeće Atlantska plovidba d.d. jer je poduzeće 2016. godine poslovalo s gubitkom.

Tablica 22: Vrijednost poduzeća metodom P/E multiplikatora

PODUZEĆA		VRIJEDNOST PODUZEĆA = P/E USPOREDIVE TVRTKE*NETO DOBIT VREDNOVANE TVRTKE		
		NETO DOBIT (kn)	P/E USPOREDIVE TVRTKE	VRIJEDNOST PODUZEĆA (kn)
1	Hrvatski Telekom d.d.	926.394.441	12,37	11.462.645.970
2	Adris grupa d.d.	605.171.640	15,89	9.615.964.116
3	Valamar Riviera d.d.	311.397.563	15,97	4.974.270.830
4	Podravka d.d.	177.324.119	14,56	2.581.119.520
5	Končar - Elektroindustrija d.d.	174.888.547	7,57	1.323.282.835
6	Ledo d.d.	272.785.378	15,52	4.232.916.103
7	Atlantic grupa d.d.	123.532.923	11,67	1.442.006.419
8	Ericsson Nikola Tesla d.d.	110.695.198	49,36	5.464.148.742
9	AD Plastik d.d.	75.065.045	17,77	1.334.270.597
10	Atlantska plovidba d.d.	-69.284.136	/	/

Izvor: Autor

Tablica 23: Vrijednost poduzeća po dionici metodom P/E multiplikatora

PODUZEĆA		VRIJEDNOST PODUZEĆA PO DIONICI METODOM P/E MULTIPLIKATORA		
		VRIJEDNOST PODUZEĆA (kn)	BROJ DIONICA	VRIJEDNOST PO DIONICI (kn)
1	Hrvatski Telekom d.d.	11.462.645.970	81.888.535	139,98
2	Adris grupa d.d.	9.615.964.116	16.400.000	586,34
3	Valamar Riviera d.d.	4.974.270.830	126.027.542	39,47
4	Podravka d.d.	2.581.119.520	7.120.003	362,52
5	Končar - Elektroindustrija d.d.	1.323.282.835	2.572.119	514,47
6	Ledo d.d.	4.232.916.103	313.920	13484,06
7	Atlantic grupa d.d.	1.442.006.419	3.334.300	432,48
8	Ericsson Nikola Tesla d.d.	5.464.148.742	1.331.650	4103,29
9	AD Plastik d.d.	1.334.270.597	4.199.584	317,71
10	Atlantska plovidba d.d.	/	/	/

Izvor: Autor

2.4.5.2. Procjena vrijednosti poduzeća P/B multiplikatorom

U tablici 24 prikazan je izračun P/B multiplikatora analiziranih poduzeća, a u tablici 25 prikazan je izračun vrijednosti poduzeća uporabom P/B multiplikatora usporedivih poduzeća. Kao usporediva poduzeća odabrana su ista poduzeća kao i kod izračuna P/E multiplikatora, pri čemu su kao usporediva poduzeća za poduzeće Adris d.d. odabrana ista poduzeća kao iza poduzeće Valamar Riviera d.d., jer glavna djelatnost poduzeća Adris d.d. spada u sektor turizma. Pri izračunu vrijednosti poduzeća uporabom P/B multiplikatora za poduzeće Atlantska plovidba d.d. korišteni su podaci sljedećih usporedivih poduzeća: Jadroagent međunarodna pomorska i prometna agencija d.d., Jadroplov d.d., Lošinjska plovidba - holding d.d., TANKERSKA NEXT GENERATION d.d. i Uljanik Plovidba pomorski promet d.d..

Tablica 24: Izračun P/B multiplikatora

PODUZEĆA		P/B MULTIPLIKATOR=CIJENA DIONICE/KNJIG.VR. PO DIONICI		
		ZAKLJUČNA CIJENA DIONICE 2016. G. (kn)	KNJIGOVODSTVENA VR. PO DIONICI (kn)	P/B MULTIPLIKATOR
1	Hrvatski Telekom d.d.	169,00	147,11	1,15
2	Adris grupa d.d.	529,95	612,87	0,86
3	Valamar Riviera d.d.	34,86	18,83	1,85
4	Podravka d.d.	377,50	411,01	0,92
5	Končar - Elektroindustrija d.d.	690,00	951,02	0,73
6	Ledo d.d.	10.665,00	5.976,46	1,78
7	Atlantic grupa d.d.	882,00	604,77	1,46
8	Ericsson Nikola Tesla d.d.	1.164,00	215,43	5,40
9	AD Plastik d.d.	138,00	166,06	0,83
10	Atlantska plovidba d.d.	282,55	420,02	0,67

Izvor: Autor

Tablica 25: Izračun vrijednosti poduzeća metodom P/B multiplikatora

PODUZEĆA		VRIJEDNOST PODUZEĆA=P/B USPOREDIVE TVRTKE *KNJIGOVODSTVENA VRIJEDNOST		
		P/B USPOREDIVE TVRTKE	KNJIGOVODSTVENA VRIJEDNOST (kn)	VRIJEDNOST PODUZEĆA (kn)
1	Hrvatski Telekom d.d.	3,73	12.046.280.716	44.899.104.633
2	Adris grupa d.d.	1,79	10.051.054.213	17.946.636.916
3	Valamar Riviera d.d.	1,46	2.373.637.039	3.457.966.108
4	Podravka d.d.	1,27	2.926.394.388	3.718.867.568
5	Končar - Elektroindustrija d.d.	0,99	2.446.144.255	2.431.515.409
6	Ledo d.d.	0,98	1.876.128.952	1.842.591.112
7	Atlantic grupa d.d.	1,09	2.016.487.925	2.199.632.729
8	Ericsson Nikola Tesla d.d.	0,39	286.878.862	111.249.269
9	AD Plastik d.d.	0,24	697.373.047	170.799.563
10	Atlantska plovidba d.d.	1,14	586.143.861	666.285.118

Izvor: Autor

Potrebno je napomenuti da za neka od analiziranih poduzeća, poput poduzeća Ericsson Nikola Tesla d.d., Končar – Elektroindustrija d.d. i AD Plastik d.d., ova metoda nije preporučljiva prvenstveno zbog malog broja konkurenata na burzi. Također, neka od korištenih usporedivih poduzeća, kao što je Uljanik d.d. koje je izabrano kao usporedivo poduzeće za AD Plastik d.d., nisu u pravom smislu konkurenti analiziranim poduzećima, dok za neka poduzeća postoji mogućnost odabira usporedivih poduzeća koja bi bila prikladnija s obzirom na konkurentnost, ali nisu dionička društva pa izračun P/E i P/B multiplikatora na klasičan način nije moguć. Samim time, rezultati dobiveni uporabom metoda multiplikatora su relativni i ovisni o subjektivnosti vršitelja analize pri odabiru usporedivih poduzeća, kao i o dostupnosti podataka potrebnih za analizu poduzeća.

Tablica 26 prikazuje izračun vrijednosti poduzeća po dionici metodom P/B multiplikatora:

Tablica 26: Izračun vrijednosti poduzeća po dionici metodom P/B multiplikatora

PODUZEĆA		VRIJEDNOST PODUZEĆA PO DIONICI METODOM P/B MULTIPLIKATORA		
		VRIJEDNOST PODUZEĆA (kn)	BROJ DIONICA	VRIJEDNOST PO DIONICI (kn)
1	Hrvatski Telekom d.d.	44.899.104.633	81.888.535	548,30
2	Adris grupa d.d.	17.946.636.916	16.400.000	1094,31
3	Valamar Riviera d.d.	3.457.966.108	126.027.542	27,44
4	Podravka d.d.	3.718.867.568	7.120.003	522,31
5	Končar - Elektroindustrija d.d.	2.431.515.409	2.572.119	945,34
6	Ledo d.d.	1.842.591.112	313.920	5869,62
7	Atlantic grupa d.d.	2.199.632.729	3.334.300	659,70
8	Ericsson Nikola Tesla d.d.	111.249.269	1.331.650	83,54
9	AD Plastik d.d.	170.799.563	4.199.584	40,67
10	Atlantska plovidba d.d.	666.285.118	1.395.520	477,45

Izvor: Autor

2.4.6. Usporedba rezultata dobivenih upotrebom različih metoda

U tablici 27 prikazana je usporedba cijene dionica analiziranih poduzeća dobivenih različitim metodama, a u tablici 28 njihovo odstupanje od zaključne cijene dionica iz 2016. godine i od prosječne godišnje cijene dionica iz 2016. godine, pri čemu je prosječna godišnja cijena dionice poduzeća Adris d.d. izračunata kao prosjek prosječne godišnje cijene redovne dionice (545,20) i prosječne godišnje cijene povlaštene dionice (402,80 kn).

Tablica 27: Usporedba cijena dionica izračunatih različitim metodama

PODUZEĆA		USPOREDBA CIJENE DIONICA (2016. G.)				
		KNJIGOVODSTVENA VRIJEDNOST (kn)	P/E (kn)	P/B (kn)	ZAKLJUČNA CIJENA (kn)	PROSJEČNA GODIŠNJA CIJENA (kn)
1	Hrvatski Telekom d.d.	147,11	139,98	548,30	169,00	149,27
2	Adris grupa d.d.	612,87	586,34	1094,31	529,95	474,00
3	Valamar Riviera d.d.	18,83	39,47	27,44	34,86	27,37
4	Podravka d.d.	411,01	362,52	522,31	377,50	346,47
5	Končar - Elektroindustrija d.d.	951,02	514,47	945,34	690,00	660,32
6	Ledo d.d.	5.976,46	13484,06	5869,62	10.665,00	10036,90
7	Atlantic grupa d.d.	604,77	432,48	659,70	882,00	832,47
8	Ericsson Nikola Tesla d.d.	215,43	4103,29	83,54	1.164,00	1068,60
9	AD Plastik d.d.	166,06	317,71	40,67	138,00	115,20
10	Atlantska plovidba d.d.	420,02	/	477,45	282,55	180,49

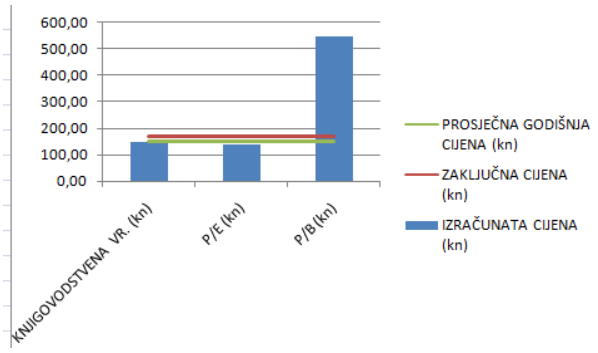
Izvor: Autor

Tablica 28: Odstupanje izračunate cijene dionica od zaključne i prosječne godišnje cijene

PODUZEĆA		ODSTUPANJE OD ZAKLJUČNE CIJENE 2016. G. (%)			ODSTUPANJE OD PROSJEČNE CIJENE 2016. G. (%)		
		KNJIGOVODSTVENA VRIJEDNOST (kn)	P/E (kn)	P/B (kn)	KNJIGOVODSTVENA VRIJEDNOST (kn)	P/E (kn)	P/B (kn)
1	Hrvatski Telekom d.d.	-12,96	-17,17	224,44	-1,45	-6,22	267,32
2	Adris grupa d.d.	15,65	10,64	106,49	29,30	23,70	130,87
3	Valamar Riviera d.d.	-45,97	13,22	-21,29	-31,18	44,22	0,25
4	Podravka d.d.	8,88	-3,97	38,36	18,63	4,63	50,75
5	Končar - Elektroindustrija d.d.	37,83	-25,44	37,01	44,03	-22,09	43,16
6	Ledo d.d.	-43,96	26,43	-44,96	-40,46	34,34	-41,52
7	Atlantic grupa d.d.	-31,43	-50,97	-25,20	-27,35	-48,05	-20,75
8	Ericsson Nikola Tesla d.d.	-81,49	252,52	-92,82	-79,84	283,99	-92,18
9	AD Plastik d.d.	20,33	130,23	-70,53	44,15	175,80	-64,70
10	Atlantska plovidba d.d.	48,65	/	68,98	132,71	/	164,53

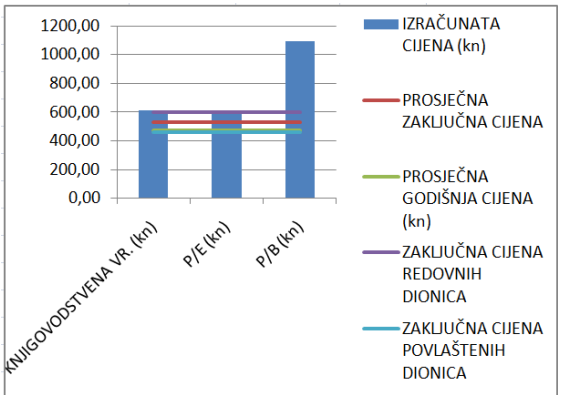
Izvor: Autor

Analizirajući rezultate iz tablice 28, kao i njihov grafički prikaz na slikama 19 – 28 može se uočiti da se za neka poduzeća ne može točno utvrditi da li su precijenjena ili podcijenjena. Naime, kod poduzeća Hrvatski Telekom d.d. i Podravka d.d. vrijednost poduzeća izračunata knjigovodstvenom metodom i metodom P/E multiplikatora pokazala se puno bližom zaključnoj cijeni i prosječnoj godišnjoj cijeni od vrijednosti izračunate metodom multiplikatora P/B. Kod poduzeća Ericsson Nikola Tesla d.d. i AD Plastik d.d. najveća odstupanja od zaključne cijene i od prosječne zaključne cijene dobivena su izračunom cijene dionica metodom multiplikatora P/E, što potvrđuje ranije navedeno zapažanje da su rezultati dobiveni uporabom metode multiplikatora upitni u slučaju uporabe neadekvatnih podataka, odnosno teško usporedivih poduzeća ili nedostatka konkurencije u pripadnom sektoru djelatnosti. Potrebno je napomenuti da je na slici 20 vidljivo da je u svakom slučaju dionica poduzeća Atlantic grupa d.d. precijenjena, dok je povlaštena dionica poduzeća Adris d.d. podcijenjena.



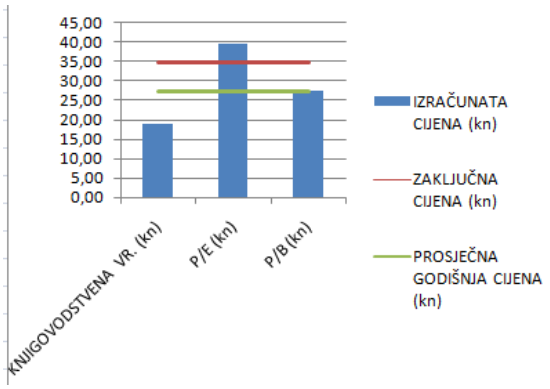
Slika 19: HT d.d.

Izvor: Autor



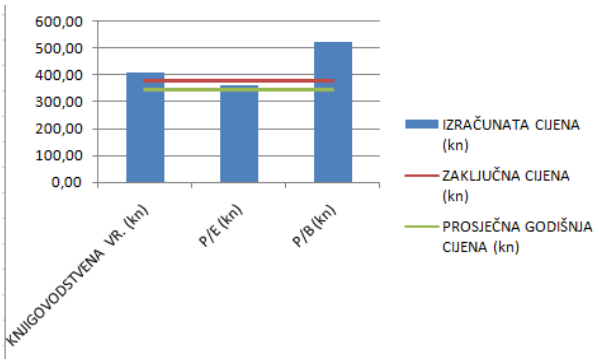
Slika 20: Adris grupa d.d.

Izvor: Autor



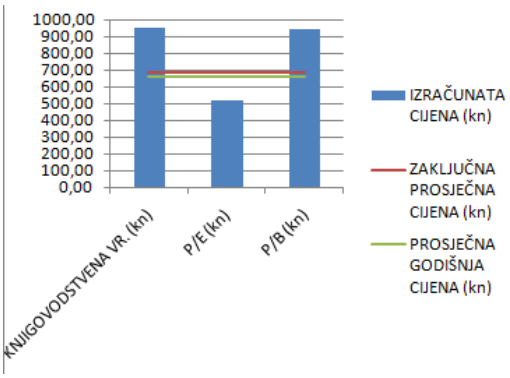
Slika 21: Valamar Riviera d.d.

Izvor: Autor



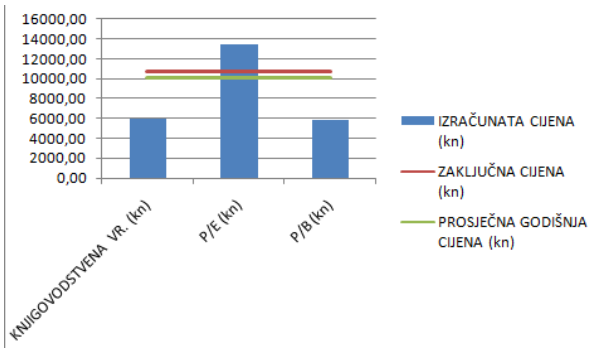
Slika 22: Podravka d.d.

Izvor: Autor



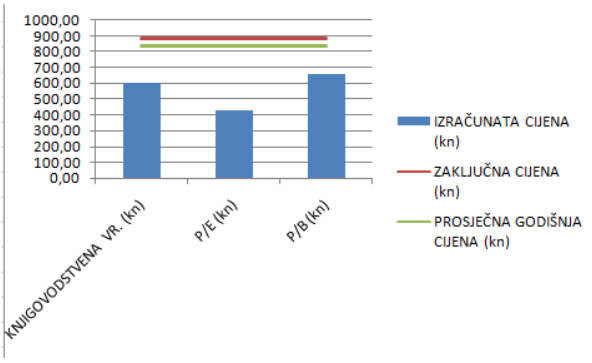
Slika 23: Končar - Elektroindustrija d.d.

Izvor: Autor



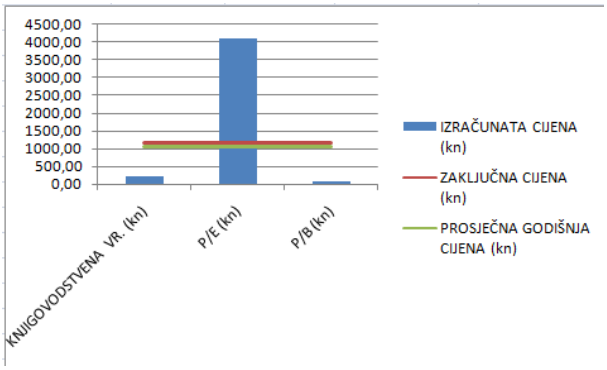
Slika 24: Ledo d.d.

Izvor: Autor



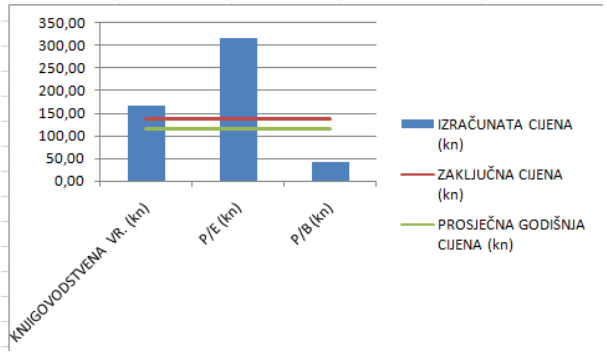
Slika 25: Atlantic grupa d.d.

Izvor: Autor



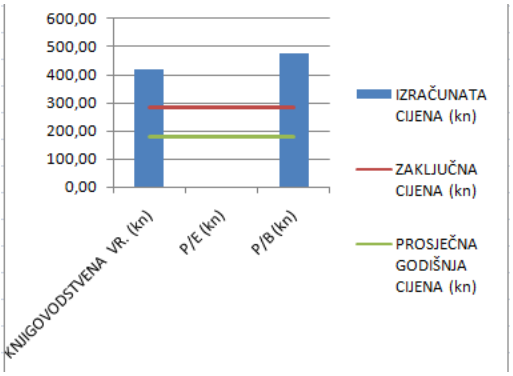
Slika 26: Ericsson Nikola Tesla d.d.

Izvor: Autor



Slika 27: AD Plastik d.d.

Izvor: Autor



Slika 28: Atlantska plovidba d.d.

Izvor: Autor

3. Matematički model u odabiru optimalnog portfelja

3.1. Markowitzev model optimizacije portfelja – teoretske postavke

Modernu (suvremenu) teoriju portfelja razvio je profesor Harry Markowitz, te ju je predstavio javnosti znanstvenim člankom "Portfolio Selection" koji je objavljen 1952. godine u časopisu "Journal of finance", te u knjizi "Portfolio Selection; Efficient Diversification of Investments" 1959. godine. Za izvanredno postignuće u ekonomiji 1990. godine dobio je Nobelovu nagradu.[57] Markowitz je smatrao da osim o očekivanim prinosima racionalni investitor mora voditi računa i o riziku, pa se sukladno tome njegov Markowitzev model optimizacije portfelja, poznat i pod nazivom Markowitzev mean – variance (M-V) model, koristi kako bi se optimirao odnos očekivanog prihoda i pripadnog rizika. Ovim matematičkim modelom se formira diverzificirani portfelj na način da se uz određeni stupanj rizika maksimalizira profit, odnosno da se za zadanu očekivanu stopu prinosa postigne minimalni rizik, ovisno o investitorovoj sklonosti riziku. Ovakav portfelj naziva se još i efikasni portfelj. Efikasni portfelj u skladu je s poznatom maksimom Burtona K. Malkiela: "You should not put all your eggs in one basket'' ("Nije dobro staviti sva jaja u jednu košaru"). Iz analize uzorka dionica u empirijskom dijelu ovog poglavlja bit će vidljivo da je s većim stupnjem diverzifikacije portfelja manji očekivani prinos i rizik i obrnuto, smanjenjem diverzifikacije portfelja rastu očekivani prinos i rizik. Dakle, s porastom rizika raste i očekivani prinos, ali njihov odnos nije linearan, već očekivani prinos raste s opadajućom stopom po krivulji koja se naziva efikasna granica. Na efikasnoj granici nalazi skup efikasnih portfelja koji dominiraju u odnosu na sve druge kombinacije investicija, bilo sa stajališta rizika, bilo sa stajališta profitabilnosti.[58] Investitor će iz skupa svih mogućih portfelja odabrati onaj (efikasni) portfelj čiji odnos očekivanog prihoda i očekivanog rizika odgovara njegovoj osobnoj ulagačkoj filozofiji.[59] Rizik je mjeren varijancom prinosa ili standardnom devijacijom.

[57] Alihodžić, A.: *Moderna portfolio teorija i diversifikacija*, Bankarstvo, 11-12 (2010.), str. 64., http://web.efzg.hr/dok/mat/pposedel/Moderna%20teorija%20portfelja.pdf, 20.05.2017.
[58] Agram brokeri: *Rječnik ekonomskih pojmova- efikasna granica*, http://www.agram-brokeri.hr/default.aspx?id=27719, 20.05.2017.
[59] Aljinović, Z., Marasović, B., Šego, B.,: *Financijsko modeliranje*, Zgombić&Partneri, Split - Zagreb, 2008., str. 134.

3.1.1. Osnovni pojmovi i definicije

Za formiranje optimalnog portfelja primjenom Markowitzevog modela optimitzacije portfelja potrebno je odabrati početi uzorak dionica. Naravno da bi bilo bolje odabrati što veći broj dionica kako bi se minimalizirao rizik, ali svakim dodavanjem nove dionice u portfelj osim što se umanjuje rizik, povećavaju se troškovi (troškovi istraživanja: vrijeme, novac i trud), a što u konačnici umanjuje povrat. Prema tome, potrebno je formirati portfelj s takvim brojem dionica s kojim će se rizik dovoljno umanjiti uslijed veće diverzifikacije, a da troškovi budu prihvatljivi.
Preporuka je izabrati deset do petnaest dionica jer je redukcija rizika nakon tog broja dionica minimalne veličine.[60] Nakon odabira početnog uzorka dionica, analiziraju se podaci o cijenama zatvaranja dionica ili prosječnim cijenama, koje po izboru mogu biti dnevne, tjedne ili mjesečne. Računaju se dnevni, tjedni ili mjesečni prinosi i-te dionice, ovisno o vrsti odabranih cijena, prema sljedećoj formuli:

$$R_i(t) = \ln\left(\frac{P_i(t)}{P_i(t-1)}\right), \tag{3.1}$$

gdje je $P_i(t)$ cijena i-te dionice u trenutku t, a $P_i(t-1)$ cijena i-te dionice u trenutku t-1. Navedeni izraz definira prinos u kontinuiranom vremenu, dok se diskretni prinos i-te dionice definira izrazom:

$$R_i(t) = \frac{P_i(t)}{P_i(t-1)} - 1 . \tag{3.2}$$

Budući da razlika između prinosa izračunatog kontinuiranim ukamaćivanjem i prinosa izračunatog diskretnim ukamaćivanjem nije velika, zbog pojednostavnjenja daljnjeg postupka koristi se kontinurano ukamaćivanje. U slučaju da je u trenutku t isplaćena dividenda $Div_i(t)$, tada izraz (3.1) poprima sljedeći oblik:

$$R_i(t) = \ln\left(\frac{P_i(t)+Div_i(t)}{P_i(t-1)}\right) . \tag{3.3}$$

U ovom radu dividenda je zanemarena. Sada se može definirati i očekivana vrijednost prinosa i-te dionice:

$$E(R_i) = \frac{\sum_{t=1}^{M} R_i(t)}{M}, \tag{3.4}$$

[60] Irala, L. R., Patil, P.: *Portfolio Size and Diversification*, SCMS Journal of Indian Management, Vol. 4, No. 1, (2007.), str. 1.-6.

gdje je M broj korištenih podataka. Dakle, očekivani prinos i-te dionice jednak je prosječnoj vrijednosti sume svih ostvarenih prinosa u promatranom razdoblju. Kako će se sva predviđanja temeljiti na pretpostavci normalne distribucije prinosa, osim očekivanog prinosa potrebno je definirati i drugi parametar normalne distribucije – varijancu prinosa i-te dionice:

$$\sigma_i^2 = \mathrm{E}[\mathrm{R_i} - \mathrm{E}(\mathrm{R_i})]^2 = \frac{\sum_{t=1}^{M}(\mathrm{R_i}(t)-\mathrm{E}(\mathrm{R_i}))^2}{M}, \tag{3.5}$$

Osim toga, potrebno je definirati kovarijancu i koeficijent korelacije prinosa dviju dionica. Neka su to dvije dionice i i j. Kovarijanca prinosa zadana je izrazom:

$$\mathrm{Cov}(\mathrm{R_i}, \mathrm{R_j}) = \frac{\sum_{t=1}^{M}(\mathrm{R_i}(t)-\mathrm{E}(\mathrm{R_i}))\cdot(\mathrm{R_j}(t)-\mathrm{E}(\mathrm{R_j}))}{M}, \tag{3.6}$$

gdje je M broj korištenih podataka. Koeficijent korelacije definiran je izrazom:

$$\rho_{i,j} = \frac{\mathrm{Cov}(\mathrm{R_i},\mathrm{R_j})}{\sigma_i \sigma_j}, \tag{3.7}$$

pri čemu vrijedi sljedeća nejednakost:

$$-1 \leq \rho_{i,j} \leq 1\ . \tag{3.8}$$

Kovarijanca i koeficijent korelacije mjere stupanj linearne povezanosti promjena prinosa dviju vrijednosnica.[61] Dakle, prema izrazu (3.8) koeficijent korelacije može poprimiti vrijednost između -1 i 1, uključujući i ta dva broja. Ako koeficijent korelacije poprimi vrijednost nula, znači da ne postoji linearna povezanost promjene prinosa promatranih dionica. Ako se vrijednost koeficijenta korelacije nalazi između 0 i 1, postoji pozitivna korelacija, a ako se vrijednost koeficijenta korelacije nalazi između 0 i -1, postoji negativna korelacija. Što je koeficijent korelacije bliži vrijednosti 1, to je veća i pozitivna korelacija između promatranih vrijednosti, dok negativna korelacija raste kada koeficijent korelacije poprimi vrijednost bližu vrijednosti -1.

Nakon definiranja očekivanog prinosa i varijance prinosa i-te dionice, isti će se definirati i za portfelj s N rizičnih dionica. Neka je π_i udio dionice i u portfelju. Tada je vektor portfelja zadan izrazom:

$$\pi = \begin{bmatrix} \pi_1 \\ \pi_2 \\ \vdots \\ \pi_N \end{bmatrix}, \tag{3.9}$$

[61] Aljinović, Z., Marasović, B., Šego, B., Op.Cit., str. 122.

pod pretpostavkom da nema drugih dionica u portfelju, tj. da vrijedi:

$$\sum_{i=1}^{N} \pi_i = 1 \, . \tag{3.10}$$

Očekivana vrijednost prinosa portfelja je vagana aritmetička sredina očekivanih prinosa pojedinih ulaganja, pri čemu su ponderi udjeli pojedinih vrijednosnica π_i u portfelju:

$$E(R_\pi) = \sum_{i=1}^{N} \pi_i E(R_i), \tag{3.11}$$ [62]

Ako se uvede oznaka E(R) za vektor očekivanih prinosa pojedinih ulaganja:

$$E(R) = \begin{bmatrix} E(R_1) \\ E(R_2) \\ \vdots \\ E(R_N) \end{bmatrix}, \tag{3.12}$$

tada se izraz (3.11) može iskazati kao skalarni umnožak vektora π i E(R):

$$E(R_\pi) = \sum_{i=1}^{N} \pi_i E(R_i) = \pi' \cdot E(R) = E(R)' \cdot \pi \tag{3.13}$$

Uvođenjem oznake:

$$Cov(R_i, R_j) = \sigma_{i,j} \, , \tag{3.14}$$

varijanca portfelja može se iskazati izrazom:

$$\sigma_\pi^2 = \sum_{i=1}^{N} \pi_1^2 \cdot \sigma_i^2 + \sum_{\substack{i,j=1 \\ i \neq 1}}^{N} 2 \cdot \pi_i \, \pi_j \cdot Cov(R_i, R_j) = \sum_{i=1}^{N} \sum_{j=1}^{N} \pi_i \pi_j \sigma_{ij} \, . \tag{3.15}$$

U svrhu lakše primjene ovog modela u excelu, uvodi se matrica varijanci i kovarijanci S koja u i-tom retku i j-tom stupcu ima element $\sigma_{i,j}$:

$$S = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} & \cdots & \sigma_{2N} \\ \vdots & & & & \vdots \\ \sigma_{N1} & \sigma_{N2} & \sigma_{N3} & \ldots & \sigma_{NN} \end{bmatrix} \tag{3.16}$$

[62] Ibid, str. 127.

Sada se varijanca portfelja može zapisati u matričnom obliku:

$$\sigma_\pi^2 = \sum_{i=1}^{N} \sum_{j=1}^{N} \pi_i \pi_j \sigma_{ij} = \pi' \cdot S \cdot \pi \quad . \tag{3.17}$$

Analogno tome, kovarijanca za dva portfelja π_1 i π_2 može se iskazati kao:

$$\mathrm{Cov}(R_{\pi_1}, R_{\pi_2}) = (\pi_1)' \cdot S \cdot \pi_2 \,.^{63} \tag{3.18}$$

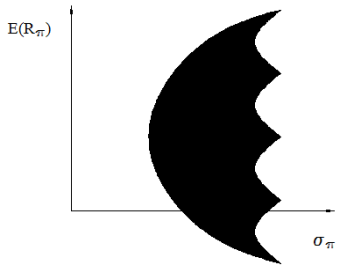
Kako bi se matrica varijanci i kovarijanci lakše izračunala, najprije se računa matrica A:

$$A = \begin{bmatrix} R_{11} - E(R_1) & R_{21} - E(R_2) & \dots & \dots & R_{N1} - E(R_N) \\ R_{12} - E(R_1) & R_{22} - E(R_2) & \dots & \dots & R_{N2} - E(R_N) \\ \vdots & & & & \vdots \\ R_{1M} - E(R_1) & R_{2M} - E(R_2) & \dots & \dots & R_{NM} - E(R_N) \end{bmatrix}, \tag{3.19}$$

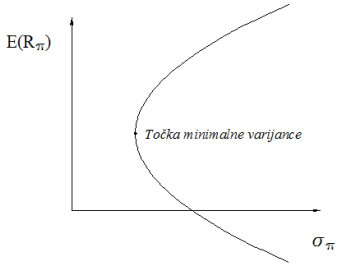
pri čemu je N broj dionica, M broj promatranih razdoblja (npr. broj dana ako su korišteni dnevni prinosi), a R_{ij}, $i \in \{1, \dots, N\}$, $j \in \{1, \dots, M\}$ je prinos i-te dionice u j-tom razdoblju. Sada se matrica varijanci i kovarijanci može iskazati sljedećim izrazom:

$$S = \frac{1}{M} A' \cdot A. \tag{3.20}$$

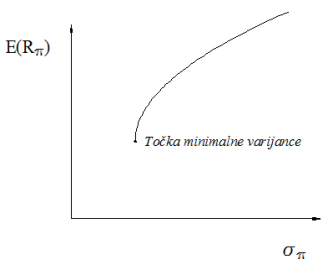
Svi portfelji koji se mogu sastaviti od N rizičnih vrijednosnica čine skup mogućih portfelja koji se može prikazati u $\sigma_\pi - E(R_\pi)$ koordinatnom sustavu, što je prikazano na slici 29:



Slika 29: Skup mogućih portfelja



Slika 30: Skup minimalne varijance



Slika 31: Efikasna granica

Izvor: Aljinović, Z., Marasović, B., Šego, B.,: *Financijsko modeliranje*, Zgombić&Partneri, Split - Zagreb, 2008., str. 135.-137.

Na slici 30 prikazana je lijeva granica skupa mogućih portfelja – skup minimalne varijance (eng. minimum-variance set) koju čine točke koje za danu stopu prinosa imanju najmanju varijancu. Dio skupa minimalne varijance koji za zadanu standardnu devijaciju (stopu rizika) imaju maksimalan prinos naziva se efikasnom granicom (eng. efficient frontier)[64] i prikazan je

[63] Ibid, str. 128.-129.
[64] Ibid, str. 135.

na slici 31, a portfelji koji leže na efikasnoj granici nazivaju se efikasni portfelji. Dakle, efikasni portfelj može se definirati kao rješenje problema:

$$\max E(R_\pi) = \pi' \cdot E(R) = \sum_{i=1}^{N} \pi_i \cdot E(R_i) \,, \tag{3.21}$$

uz ograničenja:

$$\pi' S \, \pi = c \tag{3.22}$$

$$\sum_{i=1}^{N} \pi_i = 1 \,, \tag{3.23}$$

gdje je c konstanta koja prikazuje rizik mjeren varijancom koji je investitor spreman prihvatiti.[65]

Dakle, potrebno je izračunati optimalne udjele (π_i) pojedine dionice u portfelju da bi prinos bio maksimalan uz unaprijed zadani rizik koji je investitor spreman prihvatiti (c). Ako su zadani samo uvjeti prikazani u izrazima (3.22) i (3.23), udio pojedine dionice u portfelju može poprimiti negativnu vrijednost. To znači da investitor smije pozajmiti dionicu (npr. od brokera) i prodati ju, ali ju je obavezan u budućnosti kupiti, što je poznato pod terminom kratka prodaja. U slučaju da nije dozvoljena kratka prodaja, uz navedene uvjete zadaje se i uvjet da su udjeli svake pojedine dionice u portfelju veći od nule ili jednaki nuli.

[65] Ibid, str. 136.-137.

3.2. Primjena Markowitzevog modela optimizacije portfelja na hrvatskom tržištu kapitala

Kao početni uzorak odabrane su dionice koje su uvrštene u CROBEX 10 na datum izrade empirijskog dijela ovog poglavlja 29.05.2017., odnosno 10 dionica iz indeksa CROBEX s najvećom free float tržišnom kapitalizacijom i prometom. To su abecednim redom dionice sljedećih poduzeća: AD Plastik d.d., Adris grupa d.d., Atlantic Grupa d.d., Atlantska plovidba d.d., Ericsson Nikola Tesla d.d., HT d.d., Končar - Elektroindustrija d.d., Podravka d.d., Valamar Riviera d.d., pri čemu su dionice poduzeća Adris d.d. povlaštene dionice, dok su dionice ostalih poduzeća redovne dionice. Iako su svi fundamentalni pokazatelji zadovoljavajući, dionice poduzeća Ledo d.d. su izvranrednom revizijom 08.05.2017. godine isključene s popisa dionica indexa CROBEX 10, pa su isključene i iz daljnje analize. Nadalje, iako je knjigovodstvena vrijednost poduzeća AD Plastik d.d. kroz promatrano trogodišnje razdoblje od 2014. do 2016. godine rasla, analizirajući druge rezultate dobivene provedenom fundamentalnom analizom vidljivo je da je poduzeće AD Plastik d.d. nelikvidno i prema izračunatom korigiranom Altmanovom Z``score-u prijeti mu bankrot, pa su dionice tog poduzeća također isključene iz daljnje analize. Iako vrijednost dionice poduzeća Atlantska plovidba d.d. izračunata knjigovodstvenom metodom i metodom P/B multiplikatora znatno prelaze zaključnu i prosječnu cijenu dionice poduzeća 2016. godine, te se na temelju tablice 28 i slike 28 može zaključiti da je dionica navedenog poduzeća podcijenjena te da bi se u nju isplatilo ulagati, gotovo svi odabrani pokazatelji analize uspješnosti poduzeća koji su izračunati primjenom fundamentalne analize, poput koeficijenta tekuće likvidnosti, koeficijenta ubrzane likvidnosti, koeficijenta financijske stabilnosti, koeficijenta zaduženosti, koeficijenta vlastitog financiranja, koeficijenta financiranja i stupnja pokrića II nisu u preporučenim granicama. Korigirani Altmanov Z'' score je negativan, što znači da poduzeću prijeti bankrot. ROA i ROE su negativni jer je promatrane 2016. godine poduzeće ostvarilo gubitak. Zbog navedenih razloga poduzeće Atlantska plovidba d.d. izbačeno je iz daljnje analize. Neki od pokazatelja likvidnosti i zaduženosti poduzeća Adris grupa d.d., Atlantic grupa d.d. i Valamar Riviera d.d. nisu zadovoljavajući, odnosno ne nalaze se u preporučenim granicama, te je izračun vrijednosti poduzeća pokazao da je Atlantic grupa d.d. precijenjena, ali prema izračunatom korigiranom Altmanovom Z``score-u, nalaze se u sivoj zoni, pa navedena poduzeća nisu isključena iz daljnje analize. Također, fundamentalna analiza pokazala je da je povlaštena dionica poduzeća Adris d.d. podcijenjena, što je još jedan od razloga da se navedeno poduzeće ne isključi iz daljnje analize. Ostala navedena poduzeća za koja je provedena fundamentalna analiza s odabranim pokazateljima većinom

zadovoljavaju zadane kriterije pri analizi uspješnosti poslovanja, pa nisu isključena iz daljnje analize.

Pri formiranju početnog uzorka za primjenu Markowitzevog modela optimizacije portfelja promatrane su dvogodišnje prosječne dnevne cijene sedam dionica dioničkih društava preostalih nakon izbacivanja pojedinih dionica nakon izvršene fundamentalne analize, u razdoblju od 29.05.2015. do 29.05.2017. godine, čime su obuhvaćeni i nedavni tzv. 'potresi' na Zagrebačkoj burzi, odnosno nagle promjene u cijeni određenih dionica i količini prometa na burzi, a čiji je uzrok bila kriza u poslovanju koncerna Agrokor, kojeg čine kompanije u djelatnostima maloprodaje, hrane, poljoprivrede i u ostalim djelatnostima, a što je uzrokovalo isključivanje poduzeća Ledo d.d. s popisa CROBEX10. Jedan od kriterija za formiranje uzorka dionica jest broj dana kada se određenom dionicom trgovalo. Kao reprezentativni primjer uzeta je dionica poduzeća HT d.d., odnosno Valamar Riviera d.d.. Navedenim se dionicama najviše trgovalo u promatranom dvogodišnjem razdoblju, i to 500 dana. Za preostalih pet dionica iz uzorka postavljena je granica od maksimalnih 20% do koje promatranoj dionici smije nedostajati podataka o prosječnoj dnevnoj cijeni. Sva poduzeća zadovoljila su taj uvjet, što je vidljivo u tablici 29.

Tablica 29: Odabrani početni uzorak dionica

SIMBOL	IZDAVATELJ	PODACI O CIJENI KOJI NEDOSTAJU (%)
ADRS-P-A	Adris grupa d.d.	0,80
ATGR-R-A	Atlantic grupa d.d.	2,20
ERNT-R-A	Ericsson Nikola Tesla d.d.	0,40
HT-R-A	HT d.d.	0,00
KOEI-R-A	Končar - Elektroindustrija d.d.	13,80
PODR-R-A	Podravka d.d.	1,20
RIVP-R-A	Valamar Riviera d.d.	0,00

Izvor: Autor

Zatim su izračunati dnevni prinosi dionica za promatrano dvogodišnje razdoblje primjenom programa Excel, pri čemu je za dane kada se određenom dionicom nije trgovalo prepisana prosječna dnevna cijena od prethodnog dana kada se tom dionicom trgovalo. Budući da tablice s prosječnim dnevnim cijenama i s izračunatim dnevnim prinosima imaju 500 redova, u nastavku su u tablici 30 i 31 prikazane prosječne dnevne cijene i dnevni prinosi samo za 14 dana.

Tablica 30: Dio korištenih prosječnih dnevnih cijena (za 14 dana)

	B	C	D	E	F	G	H	I
3	Datum	PROSJEČNA DNEVNA CIJENA DIONICA (kn)						
4		HT d.d.	Adris grupa d.d.	Atlantic grupa d.d.	Ericsson Nikola Tesla d.d.	Končar - Elektroindustrija d.d.	Podravka d.d.	Valamar Riviera d.d.
5	29.5.2017	169,18	460,45	753,01	1302,77	778,29	339,78	40,01
6	26.5.2017	168,19	460,05	750,97	1302,62	793,38	339,61	40,03
7	25.5.2017	166,12	459,14	744	1293,17	793,38	339,61	40
8	24.5.2017	166,16	459,14	745,24	1302,1	796,82	340,1	40,07
9	23.5.2017	166,3	461,63	754,36	1303,63	796,82	344,69	40,4
10	22.5.2017	167,4	462,56	766,49	1298	785,01	342,68	40,16
11	19.5.2017	168,52	462,75	771,59	1306,62	788,48	340,16	40,26
12	18.5.2017	167,23	464,49	773,03	1318,87	788,48	344,18	40,26
13	17.5.2017	169,13	463,41	769,1	1324,22	780	342,45	40,45
14	16.5.2017	169,09	460,62	771,42	1324,35	797,13	343,25	39,98
15	15.5.2017	170,16	469,05	784,96	1328,8	797,13	340,53	40,03
16	12.5.2017	172,06	469,98	780,07	1320,92	801,54	347	40,56
17	11.5.2017	172,1	477,76	790	1323,83	801,54	342,87	41,28
18	10.5.2017	173,52	465,4	780,04	1337,28	787,64	342,02	41,56

Izvor: Autor

Tablica 31: Dio izračunatih dnevnih prinosa dionica (za 14 dana)

	K	L	M	N	O	P	Q
3	DNEVNI PRINOSI DIONICA (%)						
4	HT d.d.	Adris grupa d.d.	Atlantic grupa d.d.	Ericsson Nikola Tesla d.d.	Končar - Elektroindustrija d.d.	Podravka d.d.	Valamar Riviera d.d.
5	0,59%	0,09%	0,27%	0,01%	-1,92%	0,05%	-0,05%
6	1,24%	0,20%	0,93%	0,73%	0,00%	0,00%	0,07%
7	-0,02%	0,00%	-0,17%	-0,69%	-0,43%	-0,14%	-0,17%
8	-0,08%	-0,54%	-1,22%	-0,12%	0,00%	-1,34%	-0,82%
9	-0,66%	-0,20%	-1,60%	0,43%	1,49%	0,58%	0,60%
10	-0,67%	-0,04%	-0,66%	-0,66%	-0,44%	0,74%	-0,25%
11	0,77%	-0,38%	-0,19%	-0,93%	0,00%	-1,17%	0,00%
12	-1,13%	0,23%	0,51%	-0,40%	1,08%	0,50%	-0,47%
13	0,02%	0,60%	-0,30%	-0,01%	-2,17%	-0,23%	1,17%
14	-0,63%	-1,81%	-1,74%	-0,34%	0,00%	0,80%	-0,12%
15	-1,11%	-0,20%	0,62%	0,59%	-0,55%	-1,88%	-1,32%
16	-0,02%	-1,64%	-1,26%	-0,22%	0,00%	1,20%	-1,76%
17	-0,82%	2,62%	1,27%	-1,01%	1,75%	0,25%	-0,68%
18	-0,54%	0,84%	0,01%	-0,25%	-0,46%	0,07%	-0,70%

Izvor: Autor

Dnevni prinos dionice poduzeća HT d.d. u polju K5 tablice 31 izračunat je primjenom formule: =LN(C5/C6); dnevni prinos u polju K6 izračunat je primjenom formule: =LN(C6/C7), te su analogno tome izračunati svi dnevni prinosi za sve dionice u tablici 31 za svih 500 dana trgovanja dionicama.

Također su izračunati parametri kao što su: očekivani prinos dionica, varijanca prinosa dionica, standardna devijacija, kovarijanca i koeficijent korelacije, što je prikazano u tablici 32, pomoću kojih je zatim formirana matrica A prikazana u tablici 33, te matrica varijanci i kovarijanci S koja je prikazana u tablici 34.

Tablica 32: Izračun parametara

	I	J	K	L	M	N	O	P	Q
506			HT d.d.	Adris grupa d.d.	Atlantic grupa d.d.	Ericsson Nikola Tesla d.d.	Končar - Elektroindustrija d.d.	Podravka d.d.	Valamar Riviera d.d.
507	OČEKIVANI PRINOS DIONICE	E(Ri)	0,018%	0,049%	-0,036%	0,001%	0,028%	0,018%	0,135%
508	VARIJANCA PRINOSA DIONICE	σi^2	5,57639E-05	0,000143703	8,61142E-05	0,000122307	0,000176158	0,000131065	0,000124276
509	STANDARDA DEVIJACIJA	σi	0,00746752	0,011987637	0,009279775	0,011059239	0,013272471	0,011448378	0,011147907
510	KOVARIJANCA	Cov (Ri, Rj)	1,09222E-05	2,49218E-05	1,07586E-05	7,66121E-06	3,5941E-05	3,90903E-05	#DIV/0!
511	KOEFICIJENT KORELACIJE	ρ(i,j)	0,122011605	0,22403135	0,104831397	0,052193937	0,236534377	0,306288982	#DIV/0!

Izvor: Autor

Izračun parametara u tablici 32 objasnit će se na primjeru poduzeća HT d.d. (prvi stupac).

Očekivani prinos dionice poduzeća HT d.d. u polju K507 u tablici 32 izračunat je primjenom formule: =AVERAGE(K5:K503), dakle kao prosjek svih izračunatih dnevnih prinosa poduzeća HT d.d..

Varijanca prinosa izračunata je primjenom formule: =VARP(K5:K503), pri čemu obuhvat (K5:K503) predstavlja sve izračunate dnevne prinose poduzeća HT d.d. iz tablice 31.

Standardna devijacija izračunata je primjenom formule: =SQRT(K508), pri čemu se funkcijom SQRT računa korijen, u ovom slučaju korijen varijance poduzeća HT d.d. prethodno izračunate u polju K508 iste tablice.

Kovarijanca je izračunata primjenom formule: =COVAR(K5:K503;L5:L503), pri čemu obuhvat (K5:K503) predstavlja sve izračunate dnevne prinose poduzeća HT d.d., a obuhvat (L5:L503) predstavlja sve izračunate dnevne prinose poduzeća Adris grupa d.d. (susjedni stupac).

Koristeći isti obuhvat podataka kao kod izračuna kovarijance izračunat je i koeficijent korelacije, primjenom formule: =CORREL(K5:K503;L5:L503).

Analogno tome, izračunati su parametri ostalih poduzeća u tablici 32.

Tablica 33: Matrica A (prvih 14 redova)

	C	D	E	F	G	H	I
513				MATRICA A			
514	HT d.d.	Adris grupa d.d.	Atlantic grupa d.d.	Ericsson Nikola Tesla d.d.	Končar - Elektroindustrija d.d.	Podravka d.d.	Valamar Riviera d.d.
515	0,57%	0,04%	0,31%	0,01%	-1,95%	0,03%	-0,19%
516	1,22%	0,15%	0,97%	0,73%	-0,03%	-0,02%	-0,06%
517	-0,04%	-0,05%	-0,13%	-0,69%	-0,46%	-0,16%	-0,31%
518	-0,10%	-0,59%	-1,18%	-0,12%	-0,03%	-1,36%	-0,96%
519	-0,68%	-0,25%	-1,56%	0,43%	1,46%	0,57%	0,46%
520	-0,68%	-0,09%	-0,63%	-0,66%	-0,47%	0,72%	-0,38%
521	0,75%	-0,42%	-0,15%	-0,93%	-0,03%	-1,19%	-0,14%
522	-1,15%	0,18%	0,55%	-0,41%	1,05%	0,49%	-0,61%
523	0,01%	0,55%	-0,27%	-0,01%	-2,20%	-0,25%	1,03%
524	-0,65%	-1,86%	-1,70%	-0,34%	-0,03%	0,78%	-0,26%
525	-1,13%	-0,25%	0,66%	0,59%	-0,58%	-1,90%	-1,45%
526	-0,04%	-1,69%	-1,23%	-0,22%	-0,03%	1,18%	-1,89%
527	-0,84%	2,57%	1,30%	-1,01%	1,72%	0,23%	-0,81%
528	-0,56%	0,79%	0,04%	-0,25%	-0,49%	0,05%	-0,83%

Izvor: Autor

Prvi član matrice A u tablici 33 - u prvom retku i prvom stupcu, odnosno član matrice A u polju C515 izračunat je primjenom formule: =K5-$K$507, pri čemu je K5 izračunati dnevni

prinos poduzeća HT d.d. iz tablice 31, a K507 je izračunati očekivani prinos dionice poduzeća HT d.d. iz tablice 32. Isto tako, član matrice A u drugom retku i prvom stupcu, odnosno u polju C516 izračunat je primjenom formule: =K6-$K$507. Oznakom dolara u formuli fiksira se ćelija K507 u formuli u svim redovima prvog stupca matrice A (poduzeće HT d.d.). Analogno tome, računaju se i preostali članovi matrice A (drugih poduzeća), čime se formira matrica A s 500 redova i 7 stupaca.

Tablica 34: Matrica varijanci i kovarijanci S

	B	C	D	E	F	G	H	I
1017	PODUZEĆA	MATRICA VARIJANCI I KOVARIJANCI S						
1018		HT d.d.	Adris grupa d.d.	Atlantic grupa d.d.	Ericsson Nikola Tesla d.d.	Končar - Elektroindustrija d.d.	Podravka d.d.	Valamar Riviera d.d.
1019	HT d.d.	5,57E-05	1,09006E-05	1,35421E-05	1,19619E-05	1,40087E-05	1,87931E-05	1,62505E-05
1020	Adris grupa d.d.	1,09E-05	0,000143417	2,48716E-05	1,45362E-05	2,32556E-05	3,05931E-05	2,73032E-05
1021	Atlantic grupa d.d.	1,35E-05	2,48716E-05	8,59423E-05	1,0737E-05	2,8281E-05	3,23512E-05	2,49932E-05
1022	Ericsson Nikola Tesla d.d.	1,2E-05	1,45362E-05	1,0737E-05	0,000122062	7,64589E-06	1,7633E-05	9,5709E-06
1023	Končar - Elektroindustrija d.d.	1,4E-05	2,32556E-05	2,8281E-05	7,64589E-06	0,000175806	3,58692E-05	2,07786E-05
1024	Podravka d.d.	1,88E-05	3,05931E-05	3,23512E-05	1,7633E-05	3,58692E-05	0,000130803	3,90126E-05
1025	Valamar Riviera d.d.	1,63E-05	2,73032E-05	2,49932E-05	9,5709E-06	2,07786E-05	3,90126E-05	0,000124031

Izvor: Autor

Matrica varijanci i kovarijanci sa sedam redova i sedam stupaca računa se tako da se u prvi redak i prvi stupac matrice S, odnosno u polje C1019 tablice 34 upiše sljedeća formula: =MMULT(TRANSPOSE(C515:I1014);C515:I1014)/500, pri čemu obuhvat (C515:I1014) predstavlja sve članove matrice A, funkcijom TRANSPOSE označava se transponirana matrica matrice A, dok se funkcijom MMULT računa umnožak transponirane matrice i matrice A, te se sve dijeli s 500 (broj redova matrice A). Kako bi se ova formula 'proširila' na ostale ćelije matrice S, potrebno je označiti sva polja buduće matrice S (sa sedam redova i sedam stupaca), kliknuti na alatnu traku i istovremeno pritisnuti Ctrl+Shift+Enter, čime je početna formula ograđena vitičastom zagradom: {=MMULT(TRANSPOSE(C515:I1014);C515:I1014)/500}.

Nakon formiranja matrice varijanci i kovarijanci – matrice S, potrebno je pomoću funkcije Solver u programu Excel izračunati efikasne portfelje za niz zadanih rizika (mjerenih standardnom devijacijom), odnosno odrediti udjele π_i svake dionice s kojima će promatrani portfelj za zadani rizik c postići maksimalni očekivani prinos. Napravljen je izračun efikasnih portfelja s dozvoljenom i bez dozvoljene kratke prodaje. Izračun je započet za portfelj s rizikom c≤0,005 mjeren standardnom devijacijom, pri čemu Solver nije mogao pronaći rješenje koje zadovoljava sve zadane uvjete. Zatim je rizik povećan na c≤0,0055 (0,55%), te je uz uvjete da je udio svih dionica u porftelju ≥0 i da je suma svih udjela dionica u portfelju jednaka 1, dobiven očekivani prinos portfelja bez dozvoljene kratke prodaje u iznosu od 0,0003506 (0,03506%). Navedeno je prikazano u tablici 35:

Tablica 35: Izračun optimalnih udjela i maksimalnog očekivanog prinosa portfelja za rizik 0,0055

	A	B	C	D
1	Max			
2	Max $E(R_\pi)$=	0,000350605		
3				
4	Uz uvjete:	$\sigma\pi$	≤	c
5		0,0055	≤	0,0055
6		π_i	≥	0
7	HT d.d.	0,37	≥	0
8	Adris grupa d.d.	0,11	≥	0
9	Atlantic grupa d.d.	0,10	≥	0
10	Ericsson Nikola Tesla d.d.	0,15	≥	0
11	Končar - Elektroindustrija d.d.	0,08	≥	0
12	Podravka d.d.	0,02	≥	0
13	Valamar Riviera d.d.	0,18	≥	0
14		$\Sigma(\pi_i)$	=	1
15		1,00	=	1

Izvor: Autor

Prije uporabe Solvera, u polju obojanom sivom bojom u tablici 35 potrebno je upisati formulu =SUMPRODUCT, te u obuhvatu formule označiti sva polja gdje su udjeli dionica, te odvojeno oznakom ";" označiti polja s prethodno izračunatim očekivanim prinosima dionica $E(R_i)$ iz tablice 32, npr.: =SUMPRODUCT(B7:B13;$J$27:$J$33), gdje su obuhvatom (B7:B13) odabrana polja u kojima su upisani udjeli pojedinih dionica π_i, a obuhvatom ($J$27:$J$33) su odabrana polja s prethodno izračunatim očekivanim prinosima dionica $E(R_i)$. Također je u polje obojano žutom bojom u tablici 35 potrebno upisati formulu =SQRT(MMULT(MMULT(TRANSPOSE(...)))), pri čemu je kao obuhvat formule potrebno odabrati polja u kojima su upisani udjeli pojedinih dionica i polja kojima se obuhvaća matrica varijanci i kovarijanci S koja je prethodno izračunata u tablici 34, npr.: =SQRT(MMULT(MMULT(TRANSPOSE(B7:B13);$B$27:$H$33);B7:B13)). Obuhvat (B7:B13) označava polja u kojima su upisani udjeli pojedinih dionica π_i, a obuhvat ($B$27:$H$33) označava polja u kojima je upisana prethodno izračunata matrica varijanci i kovarijanci S. Na isti način izračunati su i udjeli dionica u portfelju u slučaju kada je dozvoljena kratka prodaja, pri čemu je iz Solvera izbačen uvjet da svi udjeli dionica u portfelju moraju biti ≥0. Rizik je zatim povećan na 0,006, pa na 0,007 i tako dalje sve do vrijednosti 0,012, pri čemu je s porastom rizika rastao i očekivani prinos portfelja, dok je stupanj diverzificiranosti portfelja padao. Kod rizika c≤0,012 u slučaju kada nije dozvoljena kratka prodaja postignut je maksimalni očekivani prinos portfelja, ali pod uvjetom da se novac uloži samo u dionicu poduzeća Valamar Riviera d.d.. Dakle, povećanjem rizika raste i

očekivani prinos portfelja, ali pada stupanj diverzificiranosti portfelja. Dobiveni rezultati prikazani su u tablicama 36 i 37, te grafički na slici 32:

Tablica 36: Efikasni portfelji bez dozvoljene kratke prodaje za razdoblje od 29.05.2015. do 29.05.2017.

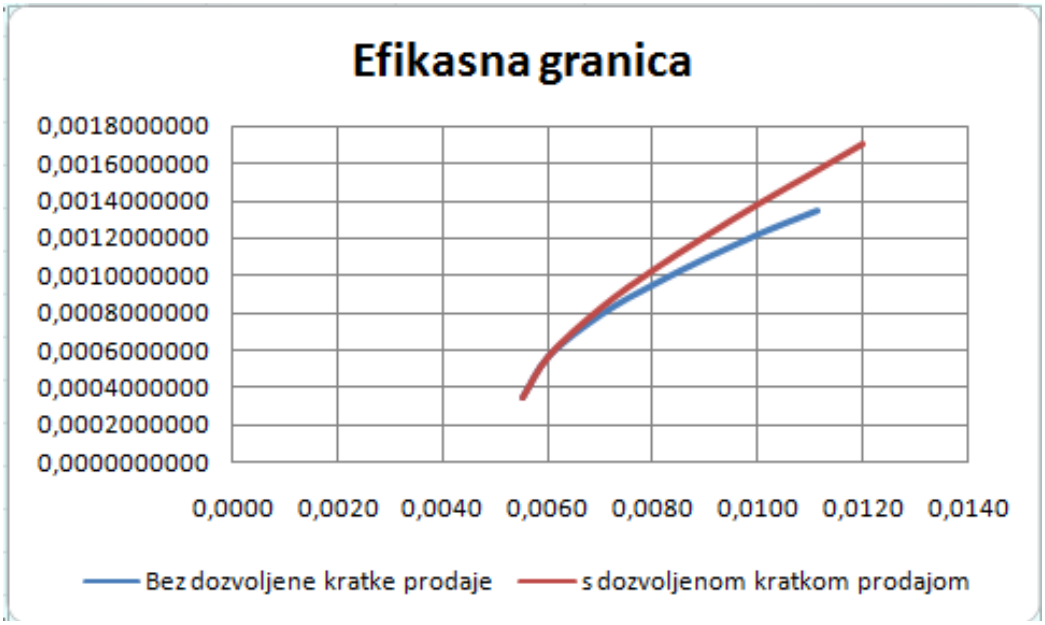
	Efikasni portfelji bez dozvoljene kratke prodaje							
	1	2	3	4	5	6	7	8
HT d.d.	0,3658	0,3434	0,2428	0,1674	0,0892	0,0025	0,0000	0,0000
Adris grupa d.d.	0,1056	0,1258	0,1306	0,1308	0,1212	0,1169	0,0159	0,0000
Atlantic grupa d.d.	0,1009	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Ericsson Nikola Tesla d.d.	0,1473	0,1268	0,0684	0,0246	0,0000	0,0000	0,0000	0,0000
Končar - Elektroindustrija d.d.	0,0784	0,0850	0,0630	0,0501	0,0432	0,0216	0,0000	0,0000
Podravka d.d.	0,0238	0,0055	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Valamar Riviera d.d.	0,1782	0,3135	0,4951	0,6270	0,7465	0,8590	0,9841	1,0000
suma udjela π_i u portfelju	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Max $E(R_\pi)$	0,035%	0,057%	0,080%	0,096%	0,110%	0,123%	0,134%	0,135%
σ_π	0,550%	0,600%	0,700%	0,800%	0,900%	1,000%	1,100%	1,114%

Izvor: Autor

Tablica 37: Efikasni portfelji s dozvoljenom kratkom prodajom za razdoblje od 29.05.2015. do 29.05.2017.

	Efikasni portfelji s dozvoljenom kratkom prodajom							
	1	2	3	4	5	6	7	8
HT d.d.	0,3659	0,3522	0,3299	0,3183	0,3117	0,2934	0,2820	0,2730
Adris grupa d.d.	0,1056	0,1274	0,1535	0,1734	0,1978	0,2099	0,2435	0,2413
Atlantic grupa d.d.	0,1009	-0,0107	-0,1390	-0,2434	-0,3188	-0,4179	-0,4663	-0,5790
Ericsson Nikola Tesla d.d.	0,1473	0,1288	0,1099	0,0955	0,0691	0,0699	0,0249	0,0449
Končar - Elektroindustrija d.d.	0,0784	0,0870	0,0989	0,1069	0,1265	0,1207	0,1481	0,1340
Podravka d.d.	0,0238	0,0067	-0,0126	-0,0272	-0,0701	-0,0581	-0,1109	-0,0839
Valamar Riviera d.d.	0,1782	0,3087	0,4594	0,5765	0,6839	0,7821	0,8787	0,9695
suma udjela π_i u portfelju	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Max $E(R_\pi)$	0,035%	0,057%	0,083%	0,103%	0,121%	0,139%	0,155%	0,171%
σ_π	0,550%	0,600%	0,700%	0,800%	0,900%	1,000%	1,100%	1,200%

Izvor: Autor



Slika 32: Efikasna granica

Izvor: Autor

Početna točka na slici 32 u kojoj je za rizik mjeren standarnom devijacijom od 0,55% očekivani prinos portfelja 0,035% naziva se točka minimalne varijance i u toj se točki efikasni portfelj bez dozvoljene kratke prodaje sastoji od 36,58% dionica poduzeća HT d.d., 10,56% dionica poduzeća Adris grupa d.d., 10,09% dionica poduzeća Atlantic grupa d.d., 14,73% dionica poduzeća Ericsson Nikola Tesla d.d., 7,84 % dionica poduzeća Končar – Elektroindustrija d.d., 2,38% dionica poduzeća Podravka d.d. i 17,82% dionica poduzeća Valamar Riviera d.d.. Najveći prinos u iznosu 0,135% ostvaren za rizik od 1,114%, ali taj se portfelj sastoji samo od dionice poduzeća Valamar Riviera d.d.. Može se primijetiti da je u slučaju dozvoljene kratke prodaje gotovo za sve analizirane vrijednosti rizika očekivani prinos veći, ali i da porastom rizika nije smanjen stupanj diverzificiranosti efikasnih portfelja. Također se može primijetiti da na slici 32 krivulja efikasne granice bez dozvoljene kratke prodaje završava prije krivulje efikasne granice s dozvoljenom kratkom prodajom. Razlog toga se može vidjeti u tablici 36, gdje je vidljivo da je Solver izračunao maksimalni očekivani prinos od 0,135% za rizik σ_π=0,01114, tj. za rizik od 1,114%, pri čemu se efikasni portfelj sastoji samo od jedne dionice. Dakle, to je maksimalni mogući rizik kojem se investitor u ovom slučaju (bez dozvoljene kratke prodaje) može izložiti.

4. Tehnička analiza

4.1. Teoretska osnova

Tehničkom analizom se proučavaju povijesni i aktualni podaci o tržištu - cijenama i volumenu trgovanja s ciljem predviđanja budućih aktivnosti na tržištu[66], pri čemu se statistički analizirani podaci grafički prikazuju i analiziraju, s ciljem predviđanja smjera i intenziteta kretanja cijene vrijednosnice u budućnosti, odnosno s ciljem prepoznavanja pravog trenutka za prodaju precijenjene ili kupnju podcijenjene vrijednosnice. Osim grafikona, koriste se i indikatori – tehnički pokazatelji za prognoziranje rasta i pada tržišta.[67] Tehničari traže formacije grafikona ili ponavljanja u kretanju cijena da bi pogodili vjerojatan ishod budućih trendova cijena, tj. oni istražuju trendove.[68] Za razliku od fundamentalne analize, u tehničkoj se analizi ne traže uzroci promjene cijene vrijednosnice. Tehničari vjeruju da se sve što može utjecati na cijenu vrijednosnice već odražava u tržišnoj cijeni iste. Kao što je već rečeno u uvodnom dijelu rada, tehnička analiza se temelji na tri pretpostavke: tržišna kretanja uzimaju u obzir sve dostupne informacije, cijene slijede trendove i povijest se ponavlja.[69] Iako primjena tehničke analize značajno raste od sredine 1980-ih godina, ona se zapravo koristi već stoljećima, pa se tako u Europi koristi od 16. stoljeća, a u Japanu se tehnička analiza primjenjivala od 17. stoljeća na tržištima riže.[70]

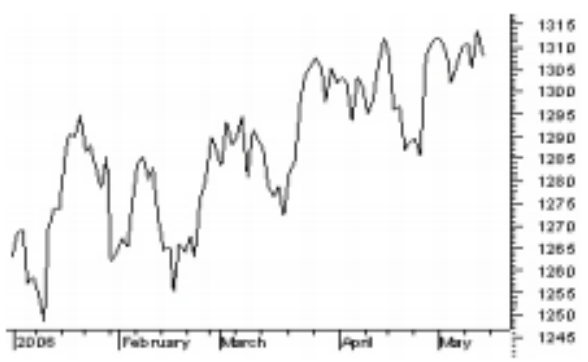
Prilikom primjene tehničke analize volumen trgovanja mora biti zadovoljavajući kako bi njezina referentnost bila veća. Volumen predstavlja broj dionica ili nekih drugih financijskih instrumenata kojima se trguje u određenom vremenskom intervalu. Veći volumeni znače i referentniju analizu jer je veći broj tržišnih sudionika uključen u trgovanje. Iako je teško predvidjeti ponašanje pojedinca, procjena ponašanja mase pokazala se znatno uspješnijom jer se kroz povijest masa najčešće ponašala kao krdo. Pouzdani zaključci se mogu dobiti i kombiniranjem cijene i volumena. Kada se u dobro uspostavljenom trendu pojavi dan s izrazito visokim trgovinskim volumenom, može se očekivati zaokret u trendu jer taj vremenski period s visokim volumenom predstavlja histeriju ili paniku koja je karakteristična za kraj trenda. Budući da se u zadnje vrijeme značajno povećala likvidnost tržišta na hrvatskom tržištu kapitala, tj. budući da su porasli volumeni i prometi na burzi, povećala se i

[66] Tehnička analiza, https://www.fortrade.eu/edukacija/tehnicka-analiza/, 28.06.2017.
[67] Bodie, Z., Kane, A., Marcus, A.J.: Op.Cit., str. 485.
[68] Tehniča analiza, https://www.fortrade.eu/edukacija/tehnicka-analiza/, 28.06.2017.
[69] Murphy, J.J., Op.Cit., str. 25.
[70] Agram brokeri, *Uvod u tehničku analizu*, http://www.agram-brokeri.hr/UserDocsImages/publikacije/Uvod%20u%20tehni%C4%8Dku%20analizu.pdf, 28.06.2017., str. 4.

upotreba tehničke analize, iako je njezina uporaba još uvijek puno manja nego na razvijenim tržištima.[71] Tehnička analiza se najčešće koristi za procjenjivanje kratkoročnih kretanja cijena (dnevno trgovanje , eng. day trading), ali postoje i alati koji omogućuju dugoročnije pozicioniranje. Prednost tehničke analize je njezina fleksibilnost glede instrumenta, tržišta i vremenskog intervala u kojemu se vrši predviđanje kretanja cijene, a najveći nedostatak tehničke analize je podložnost subjektivnoj interpretaciji, te kao takva više sliči umjetnosti nego znanosti.[72]

4.1.1. Grafikoni

Najčešće korišteni grafikoni u tehničkoj analizi su: linijski grafikon (eng. line chart), stupičasti grafikon (eng. bar chart), grafikon s Japanskim svijećama (en. candlestick chart) i krug -križ grafikon (eng. point and figure chart). Osnovni tip grafikona – linijski grafikon prikazan na slici 33 sastoji se od točaka koje predstavljaju jednu referentnu cijenu (npr. početnu, najnižu, najvišu ili zadnju) u promatranom vremenskom intervalu, međusobno povezanih ravnim linijama, što ga čini kontinuiranom grafikonom u kojem se ne mogu uočiti praznine (intervali kada se vrijendosnicom nije trgovalo), a što je njegov glavni nedostatak.



Slika 33: Primjer linijskog grafikona

Izvor: Agram brokeri: *Uvod u tehničku analizu*, http://www.agram-brokeri.hr/UserDocsImages/publikacije/Uvod%20u%20tehni%C4%8Dku%20analizu.pdf, 28.06.2017., str. 5

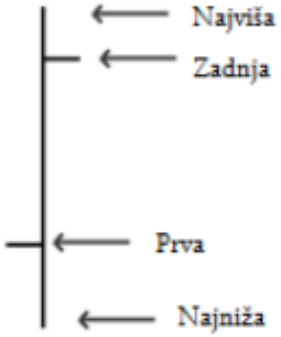
Stupičasti grafikon (eng. OHLC chart, tj. open, high, low, close chart) prikazan na slici 34 se za razliku od linijskog grafikona sastoji od sve četiri referentne cijene (početne, najniže, najviše i zadnje), te nije kontinuiran, pa se mogu uočiti praznine koje mogu predstavljati određeni tehnički signal. Na slici 35 prikazan je primjer jednog intervala stupičastog grafikona.

[71] Ibid, str. 3.
[72] Ibid, str. 4.



Slika 34: Primjer stupičatog grafikona

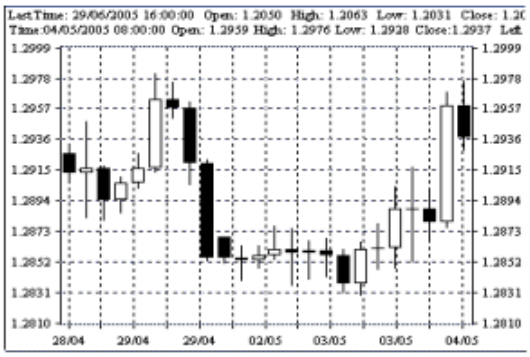
Izvor: Ibid, str. 6.



Slika 35: Primjer jednog intervala

Izvor: Ibid

Grafikon s Japanskim svijećama prikazan na slici 36 također sadrži sve četiri refrentne cijene i nije kontinuiran pa se mogu uočiti cjenovne praznine. Ako je tijelo svijeće prazno (neobojano), tada je zadnja cijena viša od prve cijene, odnosno vidljiv je rast unutar promatranog vremenskog intervala, a ako je tijelo svijeće obojano, tada je zadnja cijena niža od prve cijene, odnosno došlo je do pada cijene promatrane vrijednosnice.



Slika 36: Primjer grafikona s Japanskim svijećama

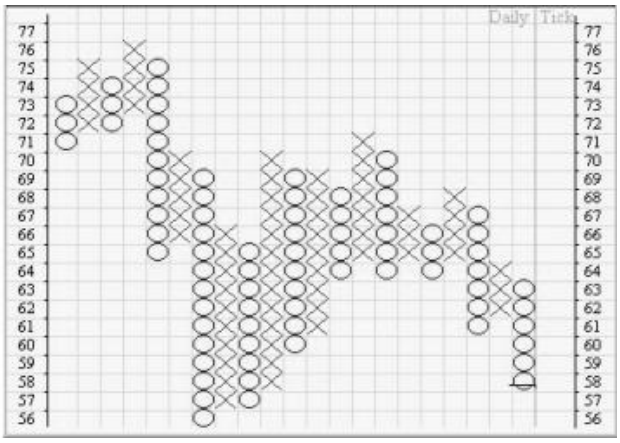
Izvor: Ibid



Slika 37: Primjer jednog intervala

Izvor: Ibid, str. 7.

Krug – križ grafikon zanemaruje vremensku komponentu i bilježi samo cjenovne aktivnosti, pri čemu se rast cijene promatrane vrijednosnice označava križićem, a pad cijene kružićem, što je prikazano na slici 38.



Slika 38: Primjer grafikona krug-križ

Izvor: Ibid

4.1.2. Trend

Pojam trend se može definirati kao smjer u kojem se financijski instrument ili tržište kreće. Budući da se cijene ne kreću pravilno kao pravac već osciliraju oko pravca trenda, trend se može definirati i kao serija viših dna i vrhova (rastući ili bikovski trend), odnosno serija nižih dna i vrhova (padajući ili medvjeđi trend).[73] Dakle, ovisno o smjeru kretanja cijene trend može biti rastući, padajući ili horizontalni, a ovisno o vremenskom trajanju može biti dugoročni (trend koji traje duže od godinu dana), srednjoročni (trend trajanja od jedan do tri mjeseca) ili kratkoročni (trend koji traje kraće od mjesec dana). Trend se na grafikonu prikazuje linijski i naziva se crta trenda (eng. trendline). Prema jednom od najpoznatijih tehničkih analitičara 20. stoljeća W.D. Gannu, crte trenda koje nastaju pod kutom od 45° su najvažnije, crte trenda koje su strmije označavaju trend koji nije održiv, a crte trenda s manjim kutom označavaju slabiji trend koji je pred zaokretom.[74] Razlikuju se rastuća crta trenda, padajuća crta trenda i horizontalna crta trenda.

4.1.2.1. Dow teorija

Prema utemeljitelju tehničke analize Charlesu H. Dowu tržišta imaju tri trenda: primarni, sekundarni i manji trend. Primarni (dugoročni) trend traje od jedne do nekoliko godina i može se usporediti s plimom ili osekom, dok sekundarni (srednjoročni) trend traje od tri tjedna do tri mjeseca, predstavlja korekciju primarnog trenda i može se usporediti s valovima koji čine plimu ili oseku. Manji (kratkoročni) trendovi uglavnom traju manje od tri tjedna, mogu se promatrati kao korekcija srednjoročnog trenda i mogu se usporediti s gibanjem valova. Primarni trendovi imaju tri faze: akumulacijske faze (eng. accumulation

[73] Ibid, str. 7.
[74] Ibid, str. 9.

phase), faze participacije javnosti (eng. public participation phase) i distribicijske faze ili faze viška (eng. excess phase). Akumulacijska faza se javlja na kraju padajućeg trenda, odnosno na početku novog, rastućeg treda u trenutku kada se kupci povlače s tržišta i kada je zbog pesimističnog raspoloženja kupaca i povećane averzije prema riziku tržište dovedeno u podcijenjenu fazu. U toj fazi je preporučljiva kupnja i tada informirani kupci ulaze na tržište.[75] U fazi participacije javnosti raspoloženje kupaca se popravlja, veći broj ulagača ulazi na tržište, uslijed toga rastu cijene pa tehnički trgovci uglavnom ulaze na tržište jer je rastući trend definiran. U distribucijskoj fazi poduzeća ostvaruju iznadprosječne rezultate te se na tržištu pojavljuje iluzija da će takav trend trajati beskonačno, te zbog toga neiskusni ulagači u toj fazi ulaze na tržište, dok se iskusni ulagači povlače s tržišta. Distribucijskom fazom započinje primarni padajući trend.

Dow je smatrao da dionice jedanaest poduzeća (kombinacija željezničkih i prerađivačih poduzeća) najbolje signaliziraju ekonomsko stanje zemlje, pa je 1884. godine objavio prvi indeks dionica sastavljen od završnih cijena tih dionica. Kasnije je te dionice odvojio u dva zasebna pokazatelja (indeksa), jedan s 12 dionica (s industrijskim poduzećima), a drugi s 20 dionica (željeznička poduzeća). Jedna od njegovih pretpostavki na kojoj se danas temelji tehnička analiza jest da tržišna cijena vrijednosnice odražava sve čimbenike koji na nju mogu utjecati, a ako dođe do neočekivanih promjena, tržišna cijena se brzo prilagodi novonastaloj situaciji. Osim navedenog, prema Dow teoriji primarni trend se ne može promijeniti ako se oba indeksa (i industrijskog i željezničkog sektora) ne kreću u istom smjeru.[76] Volumen trgovine također je jedan od bitnih pokazatelja kretanja trenda – za vrijeme rastućeg trenda, volumen trgovine bi se trebao povećavati s porastom cijena i smanjivati s padom cijena. Kod padajućeg trenda vrijedni obrnuto – s padom cijena volumen trgovanja bi se trebao povećavati, a smanjivati s oporavkom cijena.

[75] Ibid, str. 8.
[76] Vidučić, Lj., Op.Cit., str. 154.

4.1.3. Grafičke formacije

Grafička formacija (eng. chart pattern) je specifična formacija na grafikonu koja generira tehnički (trgovinski) signal (eng. trading signal). Grafička formacija se koristi za predviđanje budućih tržišnih kretnji uz određenu vjerojatnost, temeljem pretpostavke tehničke analize da povijest ima tendenciju ponavljanja. Razlikuju se formacije zaokreta trenda i formacije nastavka trenda.[77] Zaokret trenda ne mora značiti da će se smjer kretanja cijene zaokrenuti, već može značiti i da će doći do konsolidacije, odnosno osciliranja cijene unutar određenog raspona, bez jasno izraženog trenda. Najpoznatije formacije zaokreta trenda su: glava i ramena (eng. head and shoulders pattern), dvostruki vrh i dvostruko dno (eng. double top, double bottom pattern), te trostruki vrh i trostruko dno (eng. triple top, triple bottom pattern). Formacija glave i ramena ima tri vrha – dva ramena i jednu glavu, koja je najviši vrh na grafikonu. Trgovinski signal nastaje kada dođe do proboja crte vrata (eng. neckline).[78] Formacija dvostruki vrh i dvostruko dno se sastoji se od dva vrha ili dna približno jednake visine, a trgovinski signal također nastaje kada se dogodi proboj crte vrata. Kod obje formacije je bitno da se radi o velikom volumenu trgovanja, jer se inače može pojaviti lažni signal. Slična ovoj formaciji je formacija trostruki vrh i trostruko dno. Najpoznatije formacije nastavka trenda su: zastave (eng. flags), zastavice (eng. pennants) i trokuti (eng. triangles). Formacije nastavka trenda signaliziraju nastavak smjera kretanja cijene vrijednosnice. Formaciju zastave čine kratka razdoblja konsolidacije koja se pojavljuju nakon snažnog i strmog trenda rasta ili pada cijene. Zastava može biti bikova ili medvjeđa, ovisno o tome da li je prije konsolidacije cijena bila u trendu rasta ili pada. Konsolidacija se odvija unutar cjenovnog raspona (tzv. cjenovnog kanala) omeđenog crtom otpora i potpore. [79] Crta otpora može se definirati kao cjenovna razina na kojoj je pritisak prodavatelja veći od pritiska kupaca zbog čega se formira razina otpora (eng. resistance level). Otpor se javlja na vrhu svakog rastućeg trenda. U padajućem trendu crta potpore se javlja na cjenovnoj razini na kojoj kupci vrše veći pritisak od prodavatelja, pa se formira se razina potpore (eng . support level).[80] Formacija zastavice se od formacije zastave razlikuje po tome što crte otpora i potpore konvergiraju jedna prema drugoj. Primjer obje formacije prikazan je na slici 39, pri čemu je slovom D označen primjer formacije zastave, a slovom B je označen primjer formacije zastavice:

[77] Agram brokeri, *Uvod u tehničku analizu,* Op.Cit., str. 10.
[78] Ibid, str. 11.
[79] Ibid, str. 11.-13.
[80] Ibid, str. 10.



Slika 39: Primjer formacije zastave i zastavice

Izvor: Ibid, str. 13.

Kao i kod formacije zastavice, u formaciji trokuta crte otpora i potpore međusobno konvergiraju jedna prema drugoj. Cijena vrijednosnice se kreće unutar cjenovnog raspona omeđenoga crtom otpora i potpore. Razlikuju se četiri vrste formacije trokuta: simetrični trokut (eng. symmetrical triangle), rastući trokut (eng. ascending triangle), padajući trokut (eng. descending triangle) i ekspanzijski trokut (eng. expanding triangle), te su primjeri takvih formacija prikazani na slici 40, 41 i 42:



Slika 40: Primjer simetričnog trokuta

Izvor: Ibid, str. 14.



Slika 41: Primjer rastućeg trokuta

Izvor: Ibid, str. 15.



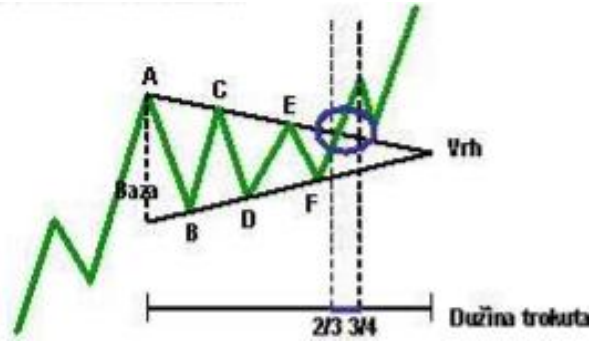
Slika 42: Primjer padajućeg trokuta

Izvor: Ibid

Crta otpora i potpore kod simetričnog trokuta simetrično konvergiraju jedna prema drugoj. Ako je trend kretanja cijene prije formacije simetričnog trokuta bio rastući, može se očekivati daljnji rast cijene, a ako je trend prije formacije simetričnog trokuta bio padajući, može se očekivati daljnji pad cijene.[81] Prethodni trend se nastavlja u trenutku kada cijena 'probije'

[81] Ibid, str. 14.

trokut, a taj trenutak se uglavnom nalazi na 2/3 do 3/4 dužine trokuta, pa se on može izračunati ako se točno procijeni dužina (visina) trokuta. Navedeno je prikazano na slici 43:



Slika 43: Primjer simetričnog trokuta s prikazom položaja točke proboja

Izvor: *Tehnička analiza (primjeri)*, http://www.poslovni.hr/media/PostAttachments/179097/TA-Primjeri.pdf, 02.07.2017.

Na jednaki način računa se točka proboja i kod formacije rastućeg i padajućeg trokuta. Rastući trokut je karakterističan za bikovska kretanja tj. za uzlazni trend, dok je padajući trokut je karakterističan za medvjeđa kretanja, tj. za silazni trend.[82]

4.1.4. Indikatori

Uz grafikone u tehničkoj se analizi koriste i indikatori, u svrhu potvrde trenda ili generiranja signala za kupnju ili prodaju. Indikatori mogu biti vodeći i zaostajući (eng. leading and lagging indicators). Dok vodeći indikatori prethode tržišnoj aktivnosti dajući signal za kupnju ili prodaju prije novog trenda ili zaokreta, zaostajući indikatori su potvrdni alati jer prate trend i kasne za tržišnom aktivnošću.[83] U nastavku su objašnjeni najčešće korišteni indikatori.

4.1.4.1. Pomični prosjeci

Pomični prosjeci spadaju u kvantitativne ili matematičke trgovinske metode, a predstavljaju prosjek unaprijed određenog broja cijena podijeljenog s brojem trgovinskih dana. Tri osnovna tipa pomičnih prosjeka su: jednostavni pomični prosjek (eng. simple moving average - SMA), linearni pomični prosjek (eng. weighted moving average - MWA) i eksponencijalni pomični prosjek (eng. exponential moving average - EMA).[84] Kod pomičnih prosjeka u analizu se uzimaju cijene s vremenskim intervalom od 10 do 50 dana za kratki rok,

[82] *Tehnička analiza (primjeri)*, http://www.poslovni.hr/media/PostAttachments/179097/TA-Primjeri.pdf, 02.07.2017.
[83] Agram brokeri, *Uvod u tehničku analizu*, Op.Cit., str. 15.

[84] Ibid, str. 16.

odnosno 200-dnevni podaci o cijeni za srednji rok. Poželjno je kombinirati dva pomična prosjeka različitih vremenskih intervala, pri čemu trgovinski signal nastaje kada kraći pomični prosjek presječe duži vremenski prosjek. Presijecanjem dužeg vremenskog prosjeka prema gore (tzv. zlatnim križanjem, eng. golden crossover) javlja se signal za kupnju, a probijanjem dužeg vremenskog prosjeka prema dolje (tzv. mrtvo križanje, eng. dead crossover) javlja se signal za prodaju.[85] Kod jednostavnog pomičnog prosjeka najčešće se koristi zadnja cijena, iako se može koristiti i prosjek četiri referentne cijene: prve, najniže, najviše i zadnje cijene. Sve vrijednosti koje ulaze u proračun imaju jednaku težinu, pa se to smatra jednim od nedostataka ovog indikatora. Kod ovog se indikatora svakog dana u izračun dodaje nova cijena, a oduzima se najstarija, odnosno cijena prvog dana uključenog u izračun jednostavnog pomičnog prosjeka. Računa se prema izrazu:

$$\mathrm{JPP} = \frac{\mathrm{P}_1 + \mathrm{P}_2 + \cdots + \mathrm{P}_\mathrm{N}}{\mathrm{N}}, \tag{4.1}$$

pri čemu je JPP jednostavni pomični prosjek, P_1, P_2,..., P_N predstavljaju cijene za N dana koje ulaze u prosjek, a N je broj dana za koje se računa jednostavni pomični prosjek. Kod linearnog pomičnog projeka također se najčešće koristi zadnja cijena, a razlikuje se od jednostavnog pomičnog prosjeka po tome što novije cijene imaju veću težinu, dok se starijim cijenama koje ulaze u prosjek daje manja težina. Linearni pomični prosjek se računa prema izrazu:

$$\mathrm{LPP} = \frac{(\mathrm{P}_\mathrm{N} \cdot 1) + \cdots + (\mathrm{P}_3 \cdot (\mathrm{N}-2)) + (\mathrm{P}_2 \cdot (\mathrm{N}-1)) + (\mathrm{P}_1 \cdot \mathrm{N})}{\mathrm{N}}, \tag{4.2}$$

gdje je LPP linearni pomični prosjek, P_1,...,P_N predstavljaju cijene za N dana koje ulaze u prosjek, a N je broj dana za koje se računa linearni pomični prosjek.

Eksponencijalni pomični prosjek također ima različite težine cijena, ali i brže reagira na tržišne promjene, te se računa prema izrazu:

$$\mathrm{EPP}_{(\mathrm{t})} = \mathrm{P}_{(\mathrm{t})} \cdot \mathrm{K} + \mathrm{EPP}_{(\mathrm{t}-1)} \cdot (1 - \mathrm{K}), \tag{4.3}$$

$$\mathrm{K} = \frac{2}{\mathrm{N}+1}, \tag{4.4}$$

[85] Ibid, str. 17.

pri čemu je $EPP_{(t)}$ zadnja vrijednost eksponencijalnog pomičnog prosjeka, $EPP_{(t-1)}$ predstavlja predzadnju vrijednost eksponencijalnog pomičnog prosjeka, $P_{(t)}$ je zadnja tržišna cijena uključena u prosjek, a N je broj dana za koji se računa eksponencijalni pomični prosjek.[86]

4.1.4.2. Bollingerov pojas (eng. bollinger bands)

Kombinacijom pomičnog prosjeka i volatilnosti vrijednosnice dobiva se indikator Bollingerov pojas ili raspon. Volatilnost je statistička mjera disperzije povrata za pojedinu vrijednosnicu ili tržišni indeks, a može se mjeriti standardnom devijacijom ili varijancom. Veća volatilnost predstavlja veći rizik.[87] Bollingerov pojas ne daje signale za kupnju i prodaju vrijednosnica, već samo daje informaciju, tj. odgovara na pitanje je li neka cijena previsoka ili preniska u relativnom smislu.[88] Relativnost znači da ista cijena u određenom trenutku može biti proglašena visokom, a u drugom trenutku može biti proglašena niskom. Bollingerov pojas se formira na način da se na grafikon najprije ucrta linija jednostavnog pomičnog prosjeka (JPP), a zatim se određuje gornja granica pojasa dodavanjem dvije standardne devijacije na JPP, dok se donja granica pojasa dobiva oduzimanjem dvije standardne devijacije od JPP-a. Ako cijena dotakne gornju granicu pojasa, previše je narasla i u nekim slučajvima može se preporučiti prodaja vrijednosnice, a ako cijena dotakne donju granicu pojasa, previše je pala i može se preporučiti kupnja vrijednosnice. Ako se trguje vrijednosnicom dok se ona nalazi u konsolidacijskom periodu, rast volatilnosti signalizira da nakon konsolidacije započinje novi trend.[89] Vrlo širok raspon krivulja (velika volatilnost) često je znak da postojeći trend završava i obrnuto, vrlo uzak raspon krivulja (mala volatilnost) često je znak mogućeg početka novog trenda.[90] U uskom rasponu krivulja često dolazi do proboja gornje ili donje granice Bollingerovog pojasa. Ako dođe do proboja gornje granice, počet će uzlazni trend, a ako dođe do proboja donje granice, to je početak silaznog trenda. Potrebno je napomenuti da cijena vrijednosnice uvijek teži vraćanju između dviju linija Bollingerovog pojasa, pa se zbog toga promatranjem kretanja tržišne cijene vrijednosnice na grafikonu s ucrtanim Bollingerovim pojasom može predvidjeti njezino buduće kretanje.

[86] Ibid, str. 16.-17.
[87] Fima vrijednosnice, *Fima tražilica*: http://www.fima-vrijednosnice.hr/default.aspx?id=133855, 03.07.2017.
[88] HUTA/CTAA – Hrvatska udruga za Tehničku analizu: *FINANCIJSKA TRŽIŠTA-Perspektiva domaćeg tržišta kapitala jučer, danas, sutra*, Bilten br.3, rujan 2016., Zagreb, str. 17.
[89] Ibid, str. 24
[90] *Tehnička analiza*, http://www.poslovni.hr/media/PostAttachments/179097/Tehnicka%20analiza.pdf, 03.07.2017., str. 2.

4.1.4.3. Oscilatori

Oscilatori kreiraju signale precijenjenosti ili podcijenjenosti financijskog instrumenta, te se njihova vrijednost najčešće kreće unutar raspona vrijednosti od 0 do 100. Nedostatak oscilatora jest da tijekom dužeg trenda signaliziraju iscrpljenost trenda prerano, te mogu navesti na krivi potez.[91] Oscilatori se koriste kao pomoćni ili sekundarni pokazatelji uz osnovne indikatore ili indikatore trenda (npr. uz pomične prosjeke, Bollingerov pojas…), u svrhu dodatne potvrde pri određivanju kupovnog ili prodajnog signala.

4.1.4.3.1. Momentum

Momentum je najjednostavniji pomoćni (sekundarni) indicator, odnosno oscillator. Ovaj oscillator mjeri brzinu promjene cijene vrijednosnice, a izračunava se kao razlika između posljednje zaključne cijene i zaključne cijene prvog dana promatranog vremenskog perioda. Momentum se crta na grafu odvojenom od grafa s tržišnom cijenom vrijednosnice, te se sastoji od krivulje koja se kreće iznad i ispod središnje, 'nulte' linije. Kada linija momentum 'probije' nultu liniju prema gore, javlja se kupovni signal, a kada linija momentum 'probije' nultu liniju prema dolje, radi se o prodajnom signalu.[92]

4.1.4.3.2. Indeks relativne snage - RSI (eng. Relative Strenght Index)

RSI je jedan od vodećih indikatora kojeg je razvio J. Welles Wilder. Ovaj oscilator mjeri jačinu vrijednosnice prateći promjene u zadnjim cijenama, te može poprimiti vrijednost od 0 do 100. Računa se prema izrazu:

$$\mathrm{RSI} = 100 - \frac{100}{1+\mathrm{RS}}, \tag{4.5}$$

pri čemu je:

$$\mathrm{RS} = \frac{\text{prosjek neto rastućih zadnjih cijena za N dana}}{\text{prosjek neto padajućih zadnjih cijena za N dana}}, \tag{4.6}$$

gdje je N broj dana za koje se računa RSI oscilator.[93]

Ako je RSI veći od 70, to može značiti da je vrijednosnica precijenjena i to daje prodajni signal, a vrijednosti RSI oscilatora ispod 30 mogu značiti da je vrijednosnica podcijenjena, te se to smatra kupovnim signalom. Kretanje RSI oscilatora ovisi i o općem kretanju tržišta, pa se tako te se granice prodajnih signala mogu pomicati na vrijednost 80 ako je tržište u

[91] Agram brokeri, Uvod u tehničku analizu, Op.Cit., str. 19.
[92] *Tehnička analiza*, http://www.poslovni.hr/media/PostAttachments/179097/Tehnicka%20analiza.pdf, 03.07.2017., str. 4.
[93] Agram brokeri, Uvod u tehničku analizu, Op.Cit., str. 17.

uzlaznom trendu ili spustiti na 20 ako je tržište u silaznom trendu. To vrijedi i u slučaju kada se određena dionica pokaže posebno 'slabom' ili posebno 'jakom' u usporedbi s drugim dionicama.[94]

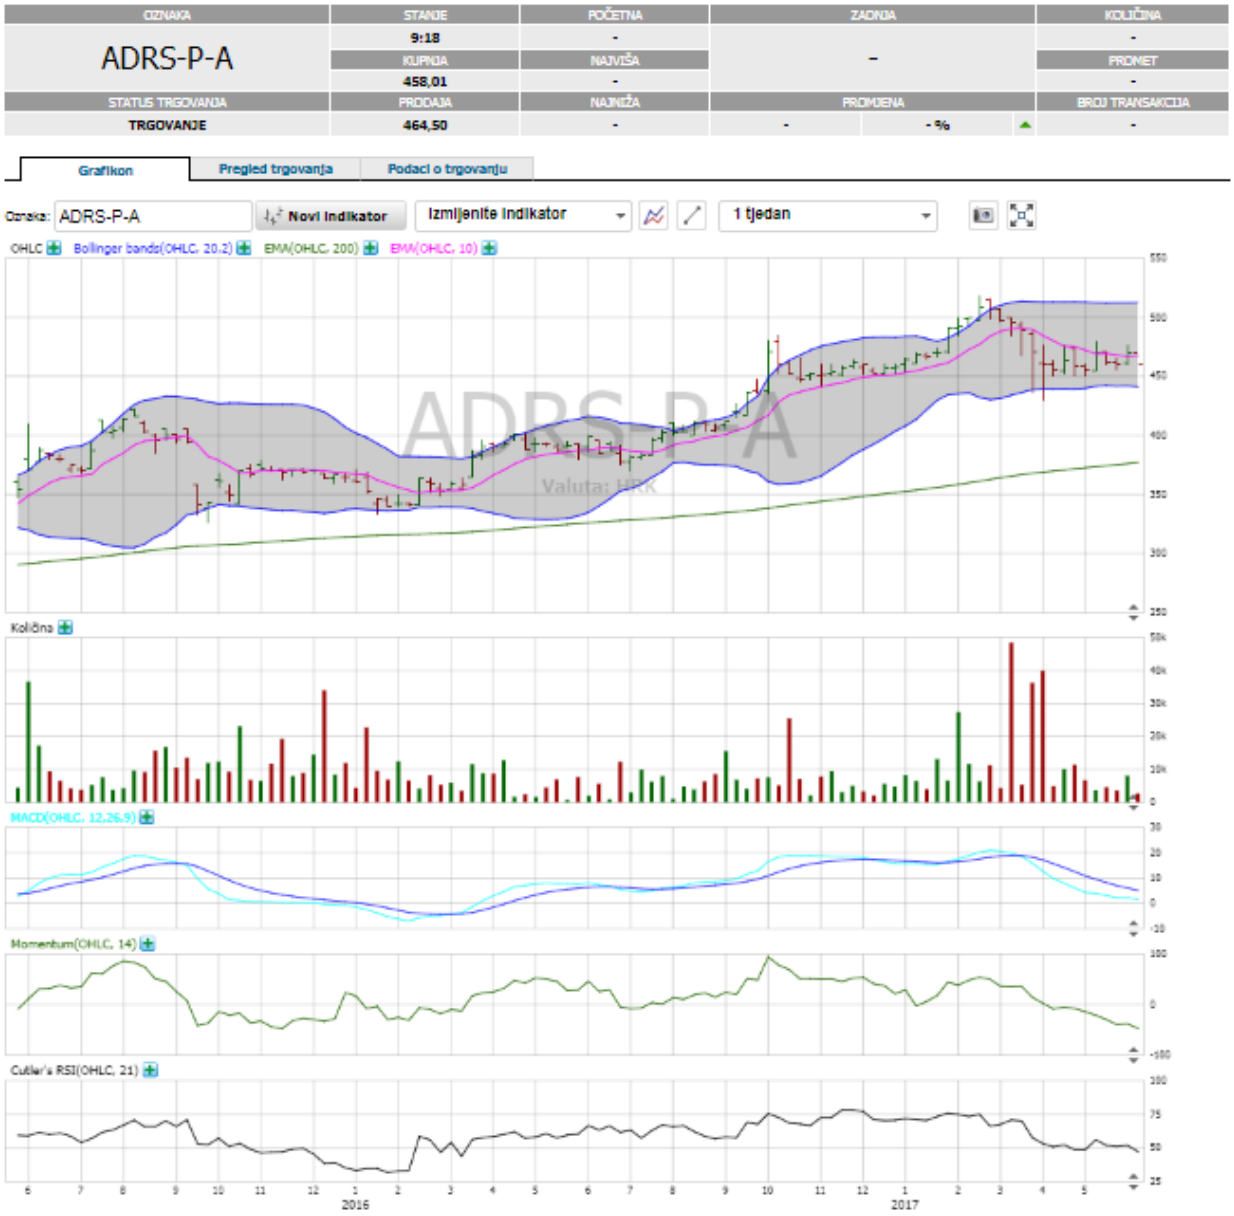
4.1.4.3.3. MACD (eng. Moving average convergence-divergence)

Indikator konvergencija/divergencija pomičnih prosjeka - MACD čine tri eksponencijalna pomična prosjeka, a na grafikonu se prikazuje u obliku dvije linije - MACD linije i signalne linije, čija križanja daju trgovinske signale. Kada signalna linija probije MACD liniju prema gore, javlja se kupovni signal, a kada signalna linija probije MACD liniju prema dolje, radi se o prodajnom signalu. MACD liniju čine dva eksponencijalna pomična prosjeka, a signalna linija je eksponencijalni prosjek MACD linije. MACD linija se kreira na način da se najprije izračuna 12-dnevni EPP cijena, zatim 26-dnevni EPP cijena, pa se od 12-dnevnog EPP-a oduzima od 26-dnevni EPP. Signalna linija se dobije izračunom 9-dnevnog EPP-a MACD linije.[95] MACD histogram mjeri razliku između MACD i signalne linije.

[94] *Tehnička analiza*, http://www.poslovni.hr/media/PostAttachments/179097/Tehnicka%20analiza.pdf, 03.07.2017., str. 9.
[95] Agram brokeri, Uvod u tehničku analizu, Op.Cit., str. 19.-20.

4.2. Primjena tehničke analize na hrvatskom tržištu kapitala

Nakon izračuna efikasnih portfelja primjenom Markowitzevog modela optimizacije portfelja u poglavlju 3, uporabom najpopularnijih tehničkih pokazatelja izvršena je tehnička analiza na istom uzorku od 7 dionica slijedećih poduzeća: Adris grupa d.d. (ADRS-P-A), Atlantic grupa d.d. (ATGR-R-A), Ericsson Nikola Tesla d.d. (ERNT-R-A), Hrvatski telekom d.d. (HT-R-A), Končar - Elektroindustrija d.d.(KOEI-R-A), Podravka d.d. (PODR-R-A) i Valamar Riviera d.d. (RIVP-R-A). Pretpostavka je da je 29.05.2017. godine nakon provedene fundamentalne analize i primjene Markowitzevog modela optimizacije portfelja na odabrani uzorak dionica, te formiranja efikasne granice investitor odlučio uložiti novac u jedan od efikasnih portfelja navedenih dionica po izboru, ovisno o njegovoj sklonosti riziku. Tehnička analiza svake dionice iz uzorka najprije je provedena za razdoblje od 29.05.2015. godine do 29.05.2017. godine kako bi se analizirala povijesna kretanja cijene u promatranom dvogodišnjem razdoblju, a zatim posebno za razdoblje od 29.05.2017. godine (datum kada je investitor odabrao efikasni portfelj u koji će uložiti) do trenutka izrade empirijskog dijela ovog poglavlja na dan 03.07.2017. godine, odnosno do zadnjeg dana dostupnih podataka na internetu, kako bi investitor mogao odabrati najpovoljniji trenutak za kupnju dionica. Zbog bolje preglednosti odabran je prikaz tjednih cijena na stupčastom grafikonu za razdoblje od 29.05.2015. godine do 29.05.2017. godine, dok je za radoblje od 29.05.2017. godine do 03.07.2017. godine odabran prikaz dnevnih cijena na grafikonu. Na slici 44 stupičastim grafom prikazana su kretanja svih četiri relevantnih tržišnih cijena dionice (početna, najniža, najviša i zadnja) poduzeća Adris grupa d.d. u razdoblju od 29.05.2015. godine do 29.05.2017. godine.



Slika 44: Tehnička analiza povlaštene dionice poduzeća Adris d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/ADRS-P-A.html#Grafikon, 04.07.2017.

Na slici 44 oko stupičastog grafa formiran je Bollingerov pojas (označeno plavom bojom) i dvije linije eksponencijalnog pomičnog prosjeka EPP (eng. EMA): rozom bojom označena je EMA u kratkom razdoblju (10 dana), dok je zelenom bojom označena EMA u drugom razdoblju (200 dana). Iako na slici nije vidljiv zlatni ili mrtvi presjek krivulja pomičnog prosjeka koji bi signalizirao kupovni ili prodajni signal, promatranjem kretanja tržišne cijene dionice unutar Bollingerovog pojasa mogu se detektirati prodajni i kupovni signali, kao i nagovještaj promjene trenda. Tako je sredinom rujna 2015. godine stupičasti graf tržišne cijene povlaštene dionice poduzeća Adris d.d. probio je donju granicu Bollingerovog pojasa,

što je bio kupovni signal. U tom je trenutku najniža cijena dionice dosegnula iznos od 332,60 kn, što je ujedno bila i najniža cijena te dionice u cjelokuponom promatranom dvogodišnjem razdoblju. Neposredno prije probijanja donje granice Bollingerovog pojasa, oscilator MACD pokazao je kupovni signal jer je signalna linija probila MACD liniju prema gore. Neposredno prije presijecanja donje granice Bollingerovog pojasa oscilator momentum pokazao je suprotni – prodajni signal, probijanjem nulte linije prema dolje, dok je oscilator RSI u točki probijanja Bollingerovog pojasa iznosio je 53,15, što znači da nije davao nikakav signal. Iako se preporuča istovremena upotreba primarnih indikatora s nekoliko sekundarnih indikatora (oscilatora) koji će potvrditi (ili odbaciti) uočeni signal, na ovom je primjeru vidljivo da su signali koje daju indikatori nekad nejasni i međusobno kontradiktorni. Najvišu cijenu u promatranom dvogodišnjem razdoblju u iznosu od 515,00 kn dionica je dosegnula krajem veljače 2017. godine, međutim do proboja gornje granice Bollingerovog pojasa došlo je krajem siječnja 2017. godine kada je najviša cijena dionice iznosila 491,00 kn. U toj točki proboja signalna linija probila je MACD liniju prema dolje, što je značilo prodajni signal, dok je RSI pokazatelj iznosio 75,86, što je također značilo prodajni signal. Dakle, prodajom dionice u trenutku prodajne signalizacije moglo se dosta zaraditi, ali cijena je još mjesec dana rasla. Momentum je pokazao prodajni signal dosta prije točke probijanja Bollingerovog pojasa, dok je cijena dionice još uvijek rasla. U točkama prodajnih i kupovnih signala očekivano je vidljiv porast količine prometa.



Slika 45: Tehnička analiza povlaštene dionice poduzeća Adris d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid, 05.07.2017.

Na slici 45 prikazana je tehnička analiza povlaštene dionice poduzeća Adris d.d. za razdoblje od 29.05.2017. godine do 03.07.2017. godine. Vidljivo je da cijena dionice u promatranom razdoblju nije probila niti jednu granicu Bollingerovog pojasa, već je iste samo dodirivala, te se sa svakim dodirom granice mijenjao trend. Najpovoljniji trenutak za kupnju dionice bio je 12.06.2017. godine u trenutku dodirivanja donje granice pojasa, kada je najniža cijena dionice iznosila 453,10 kn. Pokazatelj MACD je uranio nekoliko dana s kupovnim signalom, dok je pokazatelj momentum probijanjem nulte linije prema gore pokazao kupovni signal isti dan. Isti dan RSI je dostigao svoju minimalnu vrijednost u promatranom razdoblju u iznosu

od 40,93, što se također moglo protumačiti kao kupovni signal. Ako je investitor propustio priliku, dionicu je povoljno mogao kupiti (za 458,00 kn) i 30.06.2017. godine, kada je signalna linija probila MACD liniju prema gore i time pokazala kupovni signal, pri čemu je i RSI pokazatelj bio nizak. S obzirom na nagib krivulje RSI na kraju promatranog razdoblja, te na položaj tržišne cijene unutar granica Bollingerovog raspona, može se pretpostaviti da će u prvih nekoliko dana nakon 03.07.2017. godine cijena dionice još padati, pa ako investor još uvijek nije kupio dionicu, preporuka je da to učini tada. U slučaju da je investitor u navedenom razdoblju od 29.05.2017. godine do 03.07.2017. godine kupio dionicu, mogao je zaraditi njezinom prodajom 21.06.2017. godine kada je najviša cijena dionice iznosila 476,00 kn. Međutim, prodajni signal MACD-a je uranio nekoliko dana, a prodajni signal momentuma je zakasnio nekoliko dana, s obzirom na maksimalnu postignutu cijenu dionice na taj datum.



Slika 46: Tehnička analiza redovne dionice poduzeća Atlantic grupa d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/ATGR-R-A.html, 05.07.2017.

Na slici 46 prikazana je tehnička analiza redovne dionice poduzeća Atlantic grupa d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Prodaja dionice bila je najisplativija sredinom veljače 2017. godine, kada je najviša cijena iznosila 1010,00 kn. Međutim, grafikon tržišne cijene probio je gornju granicu Bollingerovog pojasa početkom siječnja 2017. godine, a tada je i signalna linija probila krivulju MACD-a prema dolje, što je signaliziralo prodaju dionice. RSI je pokazao visoku vrijednost (79,69) neposredno nakon probijanja gornje granice Bollingerovog pojasa, kao i u trenutku postizanja najviše cijene dionice krajem veljače (78,09), što se u oba slučaja moglo protumačiti kao prodajni signal. Pokazatelj momentum probio je nultu liniju prema dolje krajem veljače, što je također bio prodajni signal. Krajem

ožujka je bio najpovoljniji trenutak za kupnju dionice, kada je najniža cijena iznosila 736,00 kn. Signalna linija je probila liniju MACD-a prema gore signalizirajući kupnju desetak dana prije nego što je tržišna cijena probila donju granicu Bollingerovog pojasa i dosegnula svoj minimum. Isto vrijedi i za oscilator RSI, koji je u promatranom trenutku probijanja donje granice Bollingerovog pojasa bio prilično nizak i iznosio 43,77, dok je momentum pokazivao suprotni, prodajni signal. Međutim, početkom svibnja krivulja kraćeg pomičnog prosjeka EMA probija krivulju dužeg pomičnog prosjeka prema dolje, što također daje prodajni signal, što se može protumačiti kao zakašnjeli prodajni signal, ali i kao prodajni signal uslijed daljnjeg pada tržišnih cijena, koji je vidljiv iz kretanja cijena na stupičastom grafikonu na kraju promatranog razdoblja, kao i na grafičkom prikazu kretanja oscilatora RSI.



Slika 47: Tehnička analiza redovne dionice poduzeća Atlantic grupa d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Na slici 47 vidljivo je da je u navedenom razdoblju od 29.05.2017. godine do 03.07.2017. godine najpovoljniji trenutak za kupnju redovne dionice poduzeća Atlantic grupa d.d. bio 06.06.2017. godine, kada je njezina najniža cijena iznosila 741,00 kn. Međutim, jedino se je oscilator RSI sa svojom niskom vrijednosti od 36,49 mogao protumačiti kao kupovni signal, uz promatranje kretanja tržišne cijene na grafikonu koja se je jako približila donjoj granici Bollingerovog raspona, dok je kod pokazatelja momentum kupovni signal kasnio nekoliko dana, a kod pokazatelja MACD izostao je bilo kakav signal. Investitor je mogao zaraditi prodajom dionice na datum 20.06.2017. godine, kada je dionica u promatranom razdoblju dosegnula najvišu cijenu u iznosu od 777,99 kn. Međutim, u ovom je slučaju izostao bilo

kakav signal pomoćnih indikatora, odnosno oscilatora MACD, momentum i RSI, tako da se je prodajni signal mogao uočiti jedino promatranjem kretanja tržišne cijene dionice na grafikonu, koja je na datum postizanja maksimalne cijene probila gornju granicu Bollingerovog pojasa.



Slika 48: Tehnička analiza redovne dionice poduzeća Ericsson Nikola Tesla d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/ERNT-R-A.html, 05.07.2017.

Na slici 48 prikazana je tehnička analiza redovne dionice poduzeća Ericsson Nikola Tesla d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Sredinom listopada 2015. godine dionica je postigla najnižu vrijednost u promatranom dvogodišnjem razdoblju, pri čemu je najniža vrijednost tog dana iznosila 930,00 kn. Tržišna cijena probila je donju granicu

Bollingerovog pojasa, što je bio kupovni signal, kojeg je potvrdio i pomoćni indikator RSI koji je tada iznosio 19,61. Kupovni signal oscilatora momentum i MACD je izostao. Tržišna cijena je još neko vrijeme oscilirala oko krivulje kraćeg pomičnog prosjeka EMA, sve do suženja Bollingerovog pojasa koje je nagovijestilo zaokret trenda. U tom suženju početkom veljače 2016. godine tržišna cijena opet je probila donju granicu Bollingerovog pojasa, što je ponovno bio kupovni signal. Kupovni signal pomoćnog pokazatelja momentum pojavio se dvadesetak dana nakon početka trenda rasta cijene. Iako se signalna linija jako približila krivulji MACD s donje strane, nije došlo do probijanja MACD krivulje pa je kupovni signal pokazatelja MACD ponovno izostao. Najveća tržišna cijena u promatranom razdoblju u iznosu od 1444,00 kn postignuta je krajem veljače 2017. godine, ali prodajni signal pojavio se dvadesetak dana ranije probijanjem gornje granice Bollingerovog pojasa kada je najviša tržišna cijena dionice iznosila 1309,00 kn, a koji je potvrđen od strane sva tri pomoćna indikatora: signalna linija probila je MACD krivulju prema dolje, linija momentuma probila je nultu liniju prema dolje, a RSI je iznosio 78,95. Međutim, poznavatelj tehničke analize pričekao bi još malo s prodajom dionice jer je vidljivo da se Bollingerov pojas još širio, a tek najširi dio označava kraj trenutnog trenda (u ovom slučaju trenda rasta cijene). Promatrajući pak presjek krivulja pomičnog prosjeka EMA može se zaključiti da je početkom veljače 2017. godine bio povoljan trenutak za kupnju dionice, što je kratkoročno gledano točno, jer se kupovni signal javio malo nakon početka rastućeg trenda, ali promatrajući cjelokupno dvogodišnje razdoblje, bilo je puno povoljnijih trenutaka za kupnju dionice.



Slika 49: Tehnička analiza redovne dionice poduzeća Ericsson Nikola Tesla d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Na slici 49 je vidljivo da se kupovni signal u promatranom razdoblju javio 08.06.2017. godine probijanjem donje granice Bollingerovog pojasa, što je istog dana potvrđeno pomoćnim indikatorom MACD, kada je signalna linija probila MACD krivulju prema gore. Međutim, prema negativnom nagibu RSI krivulje mogao se očekivati daljnji pad cijene donice, pa je tako slijedećeg dana, 09.12.2017. godine cijena dosegnula najmanju vrijednost u promatranom razdoblju u iznosu 1150,00 kn, te je to bio najpovoljniji trenutak za kupnju dionice. Pomoćni indikator RSI je iznosio 28,94, što je bio kupovni signal, dok je kupovni signal kod oscilatora momentum zakasnio tri dana.



Slika 50: Tehnička analiza redovne dionice poduzeća Hrvatski telekom d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/HT-R-A.html, 05.07.2017.

Na slici 50 prikazana je tehnička analiza redovne dionice poduzeća Hrvatski telekom d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Najnižu cijenu u promatranom dvogodišnjem razdoblju dionica je dosegnula sredinom siječnja 2016. godine, kada je ista iznosila 137,02 kn. Tada je graf tržišne cijene dionice probio donju granicu Bollingerovog pojasa, što je bio kupovni signal, koji je potvrđen kada je istog dana signalna linija probila krivulju MACD s donje strane. Krivulja momentuma nije probila nultu liniju, ali joj se jako približila s donje strane mjesec dana ranije, dok je RSI bio prilično nizak, iznosa 36,48, što se također moglo protumačiti kao kupovni signal. Najvišu cijenu dionica je imala sredinom veljače kada je ista iznosila 191,50 kn. Tržišna cijena je početkom veljače probila gornju

granicu Bollingerovog pojasa, što je bio prodajni signal, koji je potvrđen pomoćnim pokazateljem RSI koji je iznosio 71,79. Oscilator momentum dao je prodajni signal tek krajem veljače, nakon što je već započeo padajući trend, dok je prodajni signal oscilatora MACD izostao.

Promatrajući pak presjek krivulja pomičnog prosjeka EMA može se zaključiti da je sredinom prosinca 2016. godine bio povoljan trenutak za kupnju dionice, što je kratkoročno gledano točno, jer se kupovni signal javio malo prije početka rastućeg trenda, ali promatrajući cjelokupno dvogodišnje razdoblje, bilo je puno povoljnijih trenutaka za kupnju dionice.



Slika 51: Tehnička analiza redovne dionice poduzeća Hrvatski telekom d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Najniža tržišna cijena dionice na slici 51 u promatranom razdoblju pojavila se na samom početku promatranog razdoblja, 29.05.2017. godine i iznosila je 169,00 kn. Iako se grafikon tržišne cijene nije nalazio blizu donje granice Bollingerovog pojasa, sužavanje Bollingerovog pojasa najavilo je početak novog, rastućeg trenda. Osim toga, tog je dana linija kraćeg pomičnog prosjeka presjekla liniju dužeg pomičnog prosjeka s donje strane, što je bio kupovni signal. Pomoćni indikatori dali su kupovni signal s danom zakašnjena (RSI=28,57), odnosno s dva dana zakašnjenja (krivulja momentuma probila je nultu liniju s donje strane), dok se cijena još uvijek održavala gotovo na istoj, niskoj razini. Ako je investitor tada kupio dionicu, mogao je zaraditi njezinom prodajom 29.06.2017. godine po najvišoj cijeni u iznosu od 183,99 kn, kada je grafikon tržišne cijene probio gornju granicu Bollingerovog pojasa, što je bio prodajni signal. RSI je tada iznosio 76,93, što je također bio prodajni signal, dok je na grafikonu momentuma koji je pozitivan vidljiv negativni nagib krivulje koji se kreće u smjeru nulte linije s gornje strane, što znači da će prodajni signal momentuma kasniti nekoliko dana.



Slika 52: Tehnička analiza redovne dionice poduzeća Končar - Elektroindustrija d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/KOEI-R-A.html, 05.07.2017.

Na slici 52 prikazana je tehnička analiza redovne dionice poduzeća Končar – Elektroindustrija d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Najnižu tržišnu cijenu u promatranom dvogodišnjem razdoblju u iznosu od 613,21 kn dionica je imala sredinom siječnja 2016. godine, kada se probijanjem donje granice Bollingerovog pojasa signalizirala kupnja dionice. Prilično nizak RSI pokazatelj (44,20) također se mogao protumačiti kao kupovni signal, dok je MACD pokazao kupovni signal više od mjesec dana ranije, na početku padajućeg trenda. Najvišu cijenu u iznosu od 870,00 kn dionica je imala sredinom veljače 2017. godine, kada je probijanjem gornje granice Bollingerovog pojasa emitiran prodajni signal, koji je potvrđen visokom vrijednosti pomoćnog indikatora RSI u iznnosu od 82,34. Međutim, rastući trend započeo je već početkom siječnja 2017. godine, i to probijanjem

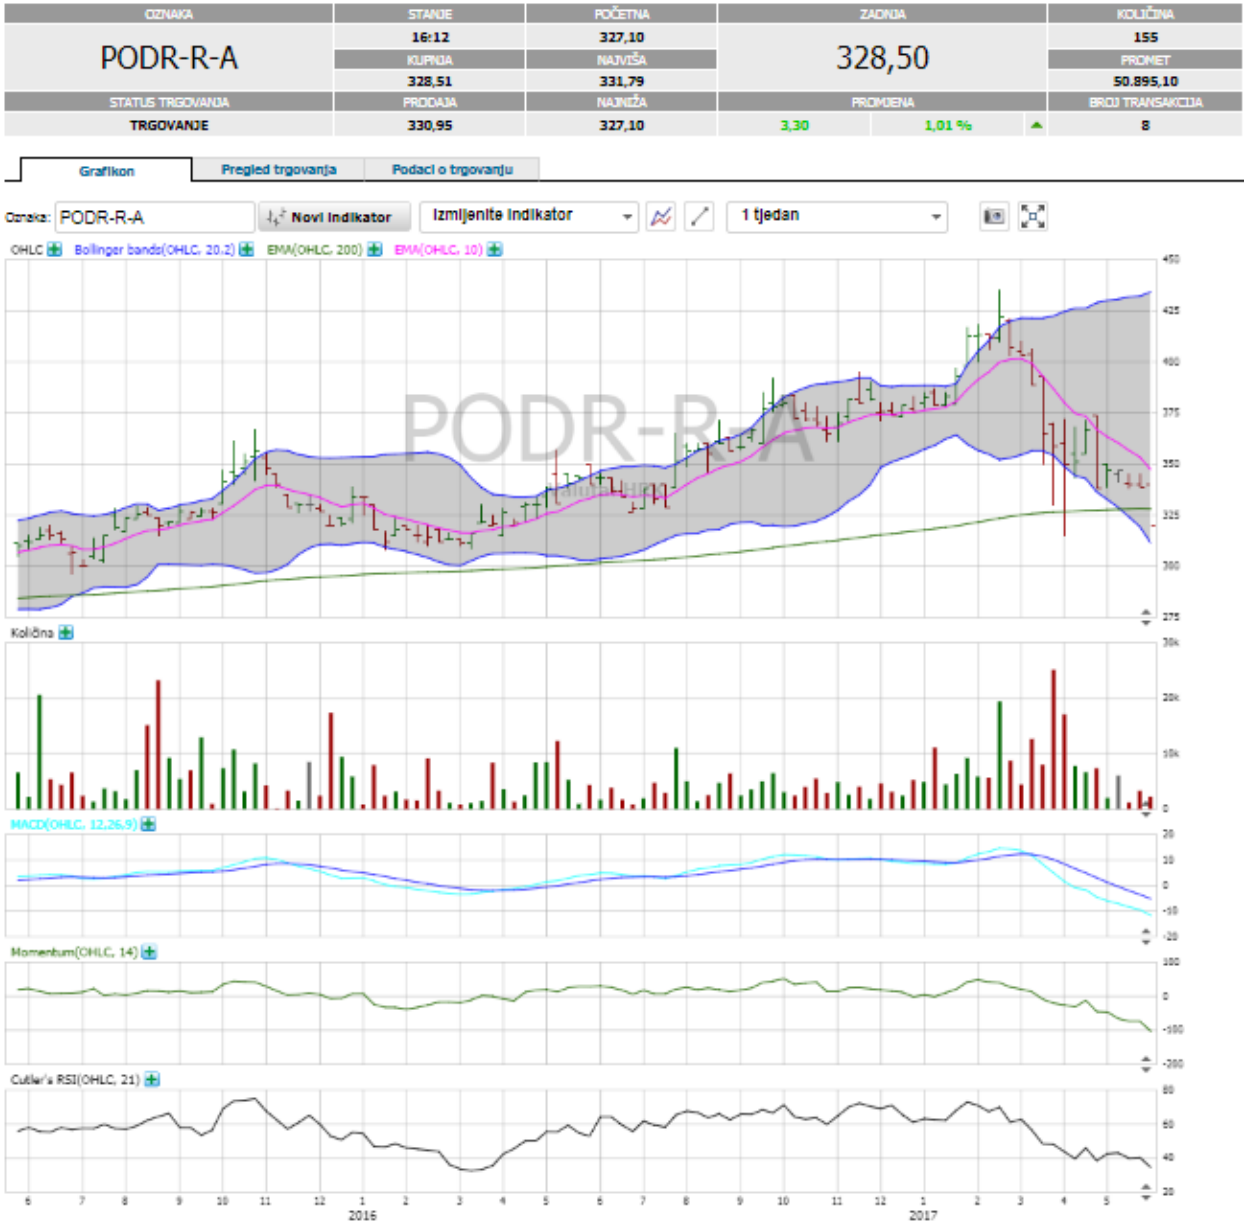
gornje granice Bollingerovog pojasa što je već tada bio prodajni signal, potvrđen i pomoćnim MACD indikatorom, ali iskusni tehničar je mogao uočiti da se širina Bollingerovog pojasa povećava, što je uz probijanje gornje granice Bollingerovog pojasa značilo da će cijena dionice još bar neko vrijeme rasti, prije nego se rastući trend približi kraju. Promatranjem presjeka krivulja pomičnog prosjeka može se primijetiti da i kupovni i prodajni signali značajno kasne, te u ovom slučaju točne signale daju samo unutar kraćeg vremenskog raspona.



Slika 53: Tehnička analiza redovne dionice poduzeća Končar - Elektroindustrija d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Prema grafikonu i indikatorima prikazanim na slici 53, najpovoljniji trenutak za kupnju dionice bio je 12.06.2017. godine, kada je najniža cijena dionice iznosila 724,00 kn. Grafikon tržišne cijene nije probio donju granicu Bollingerovog pojasa, ali je široki raspon pojasa nagovijestio brzi kraj padajućeg trenda, odnosno povoljan trenutak za kupnju dionice. Kupovni signal je potvrđen i niskom vrijednosti pomoćnog indikatora RSI u iznosu od 24,99. Ostali pomoćni indikatori nisu pokazali nikakav signal. Može se uočiti da indikator EMA daje dosta zakašnjeli prodajni signal, gotovo na sredini raspona padajućeg trenda, te je u kratkom vremenskom periodu to ne samo zakašnjeli, nego i suprotni signal.



Slika 54: Tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/PODR-R-A.html, 05.07.2017.

Na slici 54 prikazana je tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Dionica je imala najnižu cijenu u promatranom dvogodišnjem razdoblju krajem lipnja 2015. godine, koja je iznosila 296,00 kn. Međutim, nije bilo jasnog kupovnog signala glavnih ni pomoćnih indikatora, izuzev pokazatelja MACD koji je pokazao kupovni signal. Najvišu cijenu u iznosu od 435,00 kn dionica je postigla sredinom veljače 2017. godine. Međutim, prodajni signal započeo je čak mjesec dana ranije, probijanjem gornje granice Bollingerovog pojasa i prodajnim signalom pomoćnog indikatora MACD. Nedugo nakon prvotnog probijanja gornje granice Bollingerovog pojasa, sekundarni

indikator RSI visokom je vrijednosti od 72,89 također dao prodajni signal, dok je prodajni signal momentuma kasnio čak mjesec dana od postizanja maksimalne cijene dionice.

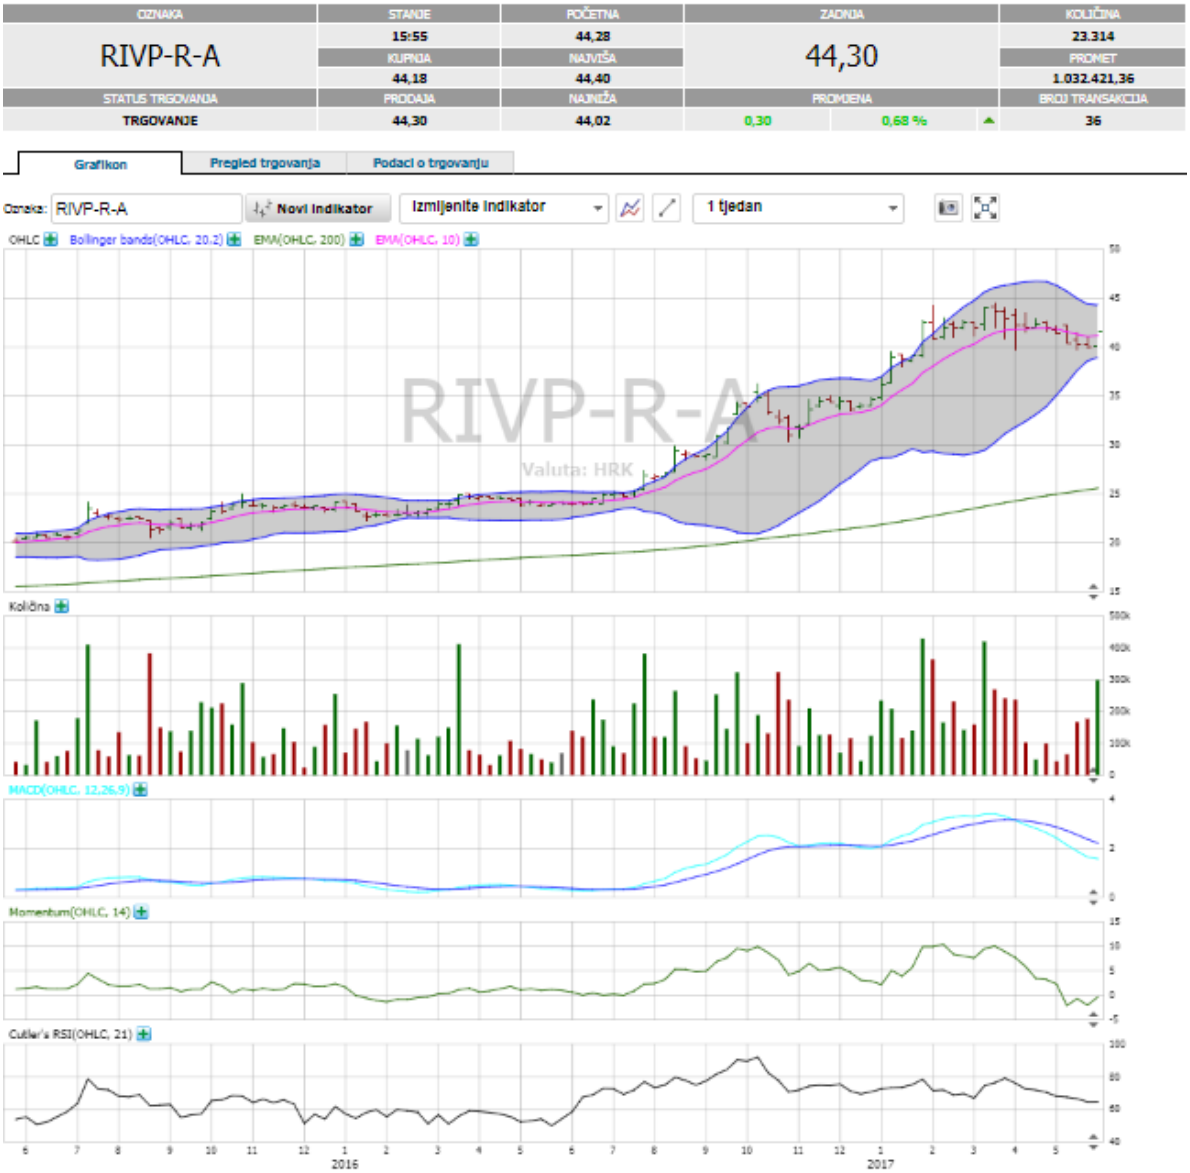


Slika 55: Tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Na slici 55 prikazana je tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje od 29.05.2017. do 03.07.2017. godine. Na grafikonu je vidljivo da je najpovoljniji trenutak u promatranom razdoblju za kupnju dionice bio 07.06.2017. godine, kada je najniža tržišna cijena dionice iznosila 302,01 kn. Iako je do probijanja donje granice Bollingerovog pojasa došlo ranije, dok je cijena dionice još uvijek padala, prema rastućoj širini Bollingerovog pojasa i relativno visokoj vrijednosti pomoćnog RSI indikatora (45,29) moglo se zaključiti da će se padajući trend nastaviti još neko vrijeme. Točno u trenutku postizanja navedene najniže

cijene, oscilator RSI je poprimio prilično nisku vrijednost od 21,29 (kupovni signal). Drugi indikatori nisu davali nikakav signal.



Slika 56: Tehnička analiza redovne dionice poduzeća Valamar Riviera d.d. za razdoblje 29.05.2015.-29.05.2017.

Izvor: http://www.rast.hr/hr/Trziste/Vrijednosnica/RIVP-R-A.html, 05.07.2017.

Na slici 56 prikazana je tehnička analiza redovne dionice poduzeća Valamar Riviera d.d. za razdoblje od 29.05.2015. godine do 29.05.2017. godine. Može se uočiti da je tržišna cijena dionice gotovo kontinuirano rasla tijekom cijelog promatranog razdoblja, uz kraća razdoblja padajućih trendova, te da je snažan porast cijene zabilježen od kraja srpnja 2016. godine skoro do kraja promatranog razdoblja. Prema navedenom, najnižu cijenu dionica je imala na samom početku promatranog razdoblja, kada je najniža tržišna cijena dionice iznosila 20,36 kn. Međutim, niti jedan indikator nije pokazao jasan kupovni signal. Najviša cijena u iznosu od

44,48 kn zabilježena je sredinom veljače 2017. godine, kada je pomoćni idnikator RSI s iznosom od 76,29 davao prodajni signal. Međutim, prodajni signal javio se čak mjesec i pol dana ranije probojem gornje granice Bollingerovog pojasa, pri najvišoj cijeni u iznosu od 36,90 kn, kada su uz primarni indikator i pomoćni indikatori RSI i MACD davali prodajni signal.



Slika 57: Tehnička analiza redovne dionice poduzeća Valamar Riviera d.d. za razdoblje 29.05.2017.-03.07.2017.

Izvor: Ibid

Prema grafikonu na slici 57, najniža cijena dionice bila je na samom početku promatranog razdoblja, 29.05.2017. godine, kada je najniža cijena dionice iznosila 39,90 kn. Kupovni signal pomoćnog indikatora momentum javio se dva dana kasnije, dok je oscilator RSI dan kasnije zabilježio svoju najmanju vrijednost u promatranom razdoblju u iznosu od 32,05, te se to također moglo protumačiti kao kupovni signal. Investitor je mogao zaraditi prodajom dionice 19.06.2017. godine po cijeni od 43,90 kn, nedugo nakon probijanja gornje granice Bollingerovog pojasa, uz prodajni signal pomoćnog indikatora RSI koji je iznosio 74,08. Dan kasnije krivulja pomoćnog indikatora momentum presjekla je nultu liniju prema dolje, što je također bila potvrda prodajnog signala. U promatranom razdoblju cijena dionice je još malo narasla nakon navedenog datuma, ali nije bilo nikakvog prodajnog signala ni jednog od korištenih glavnih i pomoćnih indikatora. Također, imajući na umu da je tržišna cijena dionice, uz povremene periode padajućeg trenda, gotovo kontinuirano rasla u posljednje dvije godine, pa čak i u razdoblju tzv. 'potresa' na burzi početkom 2017. godine, možda investitor ne bi trebao prodavati dionicu još neko vrijeme.

Kod svih analiziranih poduzeća vidljiv je nagli pad tržišne cijene dionica sredinom veljače 2017. godine, te daljnji nastavak padajućeg trenda, što se može povezati s ranije spomenutim financijskim problemima koncerna Agrokor. Naime, u siječnju 2017. godine bankari su prvi put u javnosti izjavili da je njihovo daljnje financiranje koncerna upitno zbog njegovog lošeg poslovanja i negativnih financijskih rezultata. To je, uz svakodnevno dramatično izvještavanje medija, uzrokovalo paniku na burzi, te nagli pad cijene dionica poduzeća u vlasništvu koncerna, kao i brojnih drugih poduzeća čije je poslovanje na bilo koji način povezano s Agrokorom. Kada su bankari krajem ožujka 2017. godine izrazili sumnju u lažiranje financijskih izvještaja Agrokora, također je vidljiv nagli pad cijena dionica svih analiziranih poduzeća, koji se nije zaustavio ni kada su revizori potvrdili da su u prethodnim revizijama pronađene pogreške koje su kasnije ispravljene. Revizija financijskih izvještaja iz 2016. godine obustavljena je krajem travnja 2017. godine zbog promjene revizorske kuće, a trgovanje svim dionicama koncerna privremeno je obustavljeno zbog zaštite ulagača, ‘’do trenutka kada javnost bude potpuno i točno informirana o navedenim okolnostima’’.[96] S obzirom na navedene uzroke nedavnih "potresa" na burzi i mogućnost pojave novih po završetku revizije, investitor bi ipak u ovom trenutku s određenom dozom opreza trebao pristupiti ulaganju u dionice na hrvatskom tržištu kapitala.

[96] http://www.jutarnji.hr/biznis/financije-i-trzista/zagrebacka-burza-zbog-sumnje-u-tocnost-financijskih-izvjestaja-agrokora-i-danas-obustavljeno-trgovanje-dionicama-kompanija-iz-sastava-koncerna/5970591/, 06.07.2017.

5. Zaključak

Ulaganjem u više dionica, odnosno u diverzificirani portfelj investitor nesklon riziku disperzira (raspršuje, odnosno umanjuje) rizik. Fundamentalnom analizom moguće je detektirati podcijenjenu ili precijenjenu dionicu, te ju uključiti u uzorak dionica ili ju iz istog ukloniti, ali nije moguće odrediti optimalni udio pojedine dionice u portfelju, kao ni pravi trenutak za kupnju ili prodaju dionice. Markovitzevim modelom optimizacije portfelja moguće je izračunati optimalni udio pojedine dionice u efikasnom portfelju kako bi se za rizik koji je investitor spreman prihvatiti ostvario maksimalni prinos ili kako bi se određeni očekivani prinos ostvario uz minimalni rizik, ovisno o investitorovoj sklonosti riziku, ali nije moguće dobiti širu sliku o poslovanju analiziranih poduzeća niti odrediti povoljan trenutak za rebalans portfelja. Tehničkom analizom može se odrediti najpovoljniji trenutak za rebalans portfelja, ali nije moguće izračunati fundamentalne pokazatelje, niti dobiti širu sliku o poslovanju poduzeća, kao ni izračunati optimalni udio dionica u portfelju. Provedenom sveobuhvatnom analizom poduzeća vidljivo je da je u svrhu odabira kvalitetnog uzorka dionica i ostvarivanja većih prinosa potrebno kombinirati fundamentalnu i tehničku analizu s Markowitzevim mean – variance (M-V) modelom optimizacije portfelja.

Provedenom fundamentalnom analizom u ovom radu dobivena je šira slika o poslovanju analiziranih poduzeća i njihovoj stvarnoj, fer vrijednosti, te su iz početnog uzorka dionica uvrštenih u CROBEX 10 izbačene redovne dionice poduzeća Ledo d.d., AD Plastik d.d. i Atlantska plovidba d.d. uslijed nezadovoljavanja više zadanih kriterija, odnosno uslijed loših fundamentalnih pokazatelja. Zatim je primjenom Markowitzevog mean – variance (M-V) modela optimizacije portfelja izračunat optimalni udio preostalih dionica u portfelju uz uvjet maksimaliziranja očekivanih profita za pojedine, zadane stupnjeve rizika, te je kombinacija izračunatih očekivanih maksimalnih prinosa i pripadajućih rizika prikazana na krivulji poznatoj pod nazivom efikasna granica. Međutim, nakon odabira efikasnog portfelja (ovisno o svojoj sklonosti riziku), investitor će teško odabrati pravi trenutak za kupnju, odnosno prodaju određene dionice iz svog odabranog portfelja bez primjene tehničke analize, što je prikazano na primjeru svih dionica iz portfelja, u četvrtom poglavlju ovog rada.

Primjenom Markowitzevog modela optimizacije portfelja, između ostalog, pokazalo se da je moguće ostvariti veće očekivane prinose u slučaju kada je dozvoljena kratka prodaja, te da se u tu svrhu također može koristiti tehnička analiza kako bi se 'predvidio' pravi trenutak za kratku prodaju. Tehničkom analizom teško je pogoditi točan trenutak za prodaju dionice po najvišoj cijeni ili za kupnju dionice po najnižoj cijeni, ali iskusni će tehnički analitičar

redovitim praćenjem grafikona tržišnih cijena, indikatora i oscilatora u većini slučajeva na vrijeme uočiti naznaku promjene trenda i pojave kupovnog ili prodajnog signala, te barem približno točno pogoditi pravi trenutak kupnje, odnosno prodaje dionice.

Iako i fundamentalna i tehnička analiza imaju svoje nedostatke, poput određene doze subjektivnosti vršitelja analize koja može utjecati na dobivene rezultate analize ili suprotnih, dvosmislenih signala indikatora koji se mogu javiti kod tehničke analize, kao i izostanka istih, njihova kombinirana primjena s Markowitzevim modelom optimizacije portfelja pokazala se dobrom metodom za formiranje kvalitetnog uzorka dionica, maksimaliziranje prinosa uz određeni stupanj rizika, te procjenu najpovoljnijeg trenutka za rebalans portfelja, a čime su potvrđene hipoteze postavljene u uvodnom dijelu ovog rada. Sve tri navedene metode u analizi koriste povijesne podatke, te se na taj način međusobno isprepliću i nadopunjuju. Potrebno je napomenuti da uvijek postoji mogućnost nepredvidivih događaja koji mogu snažno utjecati na tržišne cijene dionica na burzi, poput nedavnih 'potresa' na burzi uzrokovanih krizom u poslovanju koncerna Agrokor, a koje je bilo teško predvidjeti koristeći bilo koju od navedenih metoda ili njihovu kombinaciju.

Koliko god se netko smatra dobrim analitičarem, bilo da se radi o analitičaru koji koristi fundamentalnu ili tehničku analizu, matematičke modele ili kombinaciju svih navedenih metoda, postoje trenuci kada analitičar zbog nejasnih ili dvosmislenih signala (npr. u fazi konsolidacije) nije siguran što učiniti s dionicom. Poznati špekulant 20. stoljeća Jesse Livermore rekao je da postoji vrijeme za kupovanje, vrijeme za prodavanje, i vrijeme za ići na pecanje (eng. ‘’…there is time to go long, time to go short, and time to go fishing.’’).[97] Drugim riječima, u slučaju kada se javljaju dvosmisleni signali, možda je najbolje ne poduzimati ništa.

[97] Elder, A.: *Come into my trading Room*, John Wiley and Sons Inc, New York 2002., str. 12.

Literatura

Internet izvori:

1. Agram brokeri: Rječnik ekonomskih pojmova- efikasna granica,
   Dostupno na:
   http://www.agram-brokeri.hr/default.aspx?id=27719, 20.05.2017.
2. Agram brokeri, Uvod u tehničku analizu
   Dostupno na:
   hhttp://www.agram-brokeri.hr/UserDocsImages/publikacije/Uvod%20u%20tehni%C4%8Dku%20analizu.pdf, 07.01.2017.
3. Effect d.o.o. za reviziju i ekonomski konzalting - Dubrovnik, rubrika Spektar, Fundamentalna i tehnička analiza
   Dostupno na:
   http://www.effect.hr/, 06.01.2017.
4. Ekonomski Institut Zagreb, Sektorske analize
   Dostupno na:
   http://www.eizg.hr/hr-HR/Sektorske-analize-993.aspx, 20.04.2017.
5. Fima vrijednosnice, *Fima tražilica*
   Dostupno na:
   http://www.fima-vrijednosnice.hr/default.aspx?id=133855, 03.07.2017.
6. Financijska analiza – financijski pokazatelji
   Dostupno na:
   https://www.mathos.unios.hr//, 01.04.2017.
7. Financijski pokazatelji – pokazatelji likvidnosti
   Dostupno na:
   http://profitiraj.hr/financijski-pokazatelji-pokazatelji-likvidnosti/, 07.05.2017.
8. Hrvatska agencija za nadzor financijskih usluga (HANFA)
   Dostupno na:
   http://www.hanfa.hr/, 07.01.2017.
9. Hrvatska Narodna Banka
   Dostupno na:
   http://www.hnb.hr/, 08.01.2017.
10. Investopedia, rubrika Fundamental analysis

Dostupno na:
http://www.investopedia.com/, 08.01.2017.

11. Jutarnji list,
Dostupno na:
http://www.jutarnji.hr/biznis/financije-i-trzista/zagrebacka-burza-zbog-sumnje-u-tocnost-financijskih-izvjestaja-agrokora-i-danas-obustavljeno-trgovanje-dionicama-kompanija-iz-sastava-koncerna/5970591/, 06.07.2017.
12. Kolaković, M.: Poglavlje 23: Poslovna kolebanja
Dostupno na:
http://www.efzg.hr/, 18.03.2017.
13. Metode znanstvenih istraživanja
Dostupno na:
http://www.unizd.hr/, 07.01.2017.
14. MojeDionice
Dostupno na:
http://www.mojedionice.com/, 08.01.2017.
15. Poslovni dnevnik
Dostupno na:
http://www.poslovni.hr/. 08.01.2017.
16. RAST investicijsko društvo d.o.o.
Dostupno na:
http://www.rast.hr/, 08.01.2017.
17. Reuters
Dostupno na:
http://www.reuters.com/, 07.01.2017.
18. Stocktrader, rubrika Free Technical Analysis Education
Dostupno na:
https://www.stocktrader.com/, 08.01.2017.
19. Šarlija, N.: *Predavanja za kolegij 'Analiza poslovanja poduzeća'*
Dotupno na:
https://www.mathos.unios.hr/analizapp/Files/Financijska_analiza.doc.pdf ,
01.04.2017.
20. Šarlija, N.: *Objašnjenje Altman z-score modela*
Dostupno na:

http://www.efos.unios.hr/nsarlija/wp-content/uploads/sites/88/2013/04/Altman-z-score.pdf, 27.04.2017.

21. *Tehnička analiza*
    Dostupno na:
    https://www.fortrade.eu/edukacija/tehnicka-analiza/, 28.06.2017.
22. *Tehnička analiza*,
    Dostupno na:
    http://www.poslovni.hr/media/PostAttachments/179097/Tehnicka%20analiza.pdf, 03.07.2017.
23. *Tehnička analiza (primjeri)*
    Dostupno na:
    http://www.poslovni.hr/media/PostAttachments/179097/TA-Primjeri.pdf, 02.07.2017.
24. Zagrebačka burza
    Dostupno na:
    http://zse.hr/, 07.01.2017.

Knjige i članci:

25. Alihodžić, A.: *Moderna portfolio teorija i diversifikacij*a, Bankarstvo, 11-12 (2010.), str. 64.,
    Dostupno na:
    http://web.efzg.hr/dok/mat/pposedel/Moderna%20teorija%20portfelja.pdf, 20.05.2017.
26. Aljinović, Z., Marasović, B., Šego, B.,: *Financijsko modeliranje*, Zgombić&Partneri, Split - Zagreb, 2008.
27. Babić, M.: *Makroekonomija*, Petnaesto dopunjeno i izmijenjeno izdanje, MATE d.o.o. Zagreb, Tisak ITG, Zagreb, 2007.
28. Baletić, Z. (urednik): *Ekonomski leksikon*, Leksikografski zavod Miroslav Krleža, Zagreb, 1996. (izdanje na CD ROM-u)
29. Belak, V.: *Menadžersko računovodstvo*, RRIF, Zagreb, 1995.
30. Bodie, Z., Kane, A., Marcus, A. J.: *Počela ulaganja*, IV. Izdanje, Mate, Zagreb, 2006.
31. Colby, R.W.: *The Encyclopedia of Technical Market Indicators*, 2nd edition, McGraw Hill, New York, 2002.
32. Elder, A.: *Come into my trading Room*, John Wiley and Sons Inc, New York 2002.
33. Collin, P.H., Joliffe, A.: *Dictionary of Accounting*, Peter Collin Publishing, Middlesex, 1992.

34. HUTA/CTAA – Hrvatska udruga za Tehničku analizu: *FINANCIJSKA TRŽIŠTA- Perspektiva domaćeg tržišta kapitala jučer, danas, sutra*, Bilten br.3, rujan 2016., Zagreb, str. 1.-39.
Dostupno na:
http://huta-ctaa.hr/wp-content/uploads/2016/09/HUTA-Bilten-broj-3-rujan-2016..pdf
35. Irala, L. R., Patil, P.: *Portfolio Size and Diversification*, SCMS Journal of Indian Management, Vol. 4, No. 1, (2007.), str. 1.-6.
Dostupno na:
https://ssrn.com/abstract=977763
36. Iyiola, O., Munirat, Y., Nwufo, C.: *The modern portfolio theory as an investment decision tool*, Journal of Accounting and Taxation Vol. 4 (2), March 2012., str. 19.-28.
Dostupno na:
http://www.academicjournals.org/, 07.01.2017.
37. Jerončić, M., Aljinović, Z.: *Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija*, Ekonomski pregled, god. 62 (2011.), br. 9-10, str. 583.-606.
Dostupno na:
hrcak.srce.hr/file/108472, 08.01.2017.
38. Kulenović, Z., Slišković, M.: *Metodologija znanstvenoistraživačkog rada*, Sveučilište u Splitu, Pomorski fakultet
Dostupno na:
http://www.pfst.unist.hr/ , 07.01.2017.
39. Marasović, B.: *Modeli optimizacije investicijskog portfelja*, magistarski rad, Ekonomski Fakultet Zagreb, 2006.
40. Marasović, B.: *Model za rebalans portfelja s uključenim transakcijskim troškovima i donjom poluapsolutnom devijacijom kao mjerom rizika*, Ekonomska misao i praksa, god. XXV. (2016.), br. 2, str. 515.-534.
41. Maričić, Z., *Forex - karakteristike, trgovanje, tehnička i fundamentalna analiza*, Zbornik radova Međimurskog veleučilišta u Čakovcu, Vol. 2, No.1 (2011.), str. 55.-68.
Dostupno na:
http://hrcak.srce.hr/71323, 08.01.2017.
42. Murphy, J.J.: *Tehnička analiza financijskih tržišta*, Poslovni dnevnik, Masmedia, Zagreb, 2007.

43. Novak, B.: *Mjerenje i upravljanje dodanom ekonomskom vrijednošću tvrtke*, EKONOMSKI PREGLED, 53 (3-4), (2002.), str. 269.-291.
44. Orsag, S., Dedi, L.: *Tržište kapitala*, udžbenik za ekonomske škole, Alka script d.o.o. Zagreb, 2014.
Dostupno na:
http://www.alkascript.hr/, 08.01.2017.
45. Pavić, I., Benić, Đ., Hashi, I.: *Mikroekonomija*, treće izdanje, Sveučilište u Splitu, Ekonomski fakultet Split, Split, 2009.
46. Pervan, I.: *Materijali s predavanja iz kolegija Korporacijsko restrukturiranje*, Ekonomski fakultet Split, 2010.
47. Pervan, I.: *Računovodstvo poslovnih spajanja,* RriF Plus d.o.o., Zagreb, 2012.
48. Prohaska, Z.: *Upravljanje vrijednosnim papirima*, Poslovna knjiga, Infoinvest, Zagreb, 1994.
49. Sabolić, D.: Financijska *tržišta I., Krediti, obveznice, dionice, Bilješke s predavanja*, Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Zagreb, 2013.
Dostupno na:
https://bib.irb.hr, 08.01.2017.
50. Sabolić, D.: *Suvremena teorija portfelja i CAPM model , Bilješke s predavanja*, Sveučilište u Zagrebu, Fakultet elektrotehnike i računalstva Zagreb, 2013.
Dostupno na:
https://bib.irb.hr, 08.01.2017.
51. Tomić – Plazibat, N., Aljinović, Z., Marasović, B.,: *Matematički modeli u financijskom upravljanju*, Ekonomski fakultet Split, Split, 2006.
52. Vidučić, Lj.: *Financijski menadžment*, VIII. izdanje, RRIF plus, Zagreb, 2012.
53. Zelenika, R.: *Metodologija i tehnologija izrade znanstvenog i stručnog dijela*, treće dopunjeno i izmijenjeno izdanje, EF u Rijeci, Rijeka, 1998.

Popis slika

Slika 1: Faze gospodarskog ciklusa 13
Slika 2: Odabrani uzorak dionica – CROBEX 10 27
Slika 3: Dionice s najvećom tržišnom kapitalizacijom 28
Slika 4: Dionice s najvećom free float tržišnom kapitalizacijom 29
Slika 5: Dionice s najvećim prometom 30
Slika 6: Odabrani financijski pokazatelji poslovanja deset vodećih trgovačkih društava u sektoru telekomunikacija u 2015. godini 31
Slika 7: Odabrani pokazatelji poslovanja deset najvećih trgovačkih društava prema prihodima u sektoru turizma u 2015. godini 32
Slika 8: Deset vodećih trgovačkih društava u djelatnosti proizvodnje hrane – odabrani financijski pokazatelji, 2014. 32
Slika 9: HT d.d. 44
Slika 10: Adris grupa d.d. 44
Slika 11: Valamar Riviera d.d. 44
Slika 12: Podravka d.d. 44
Slika 13: Končar - Elektroindustrija d.d. 45
Slika 14: Ledo d.d. 45
Slika 15: Atlantic grupa d.d. 45
Slika 16: Ericsson Nikola Tesla d.d. 45
Slika 17: AD Plastik d.d. 45
Slika 18: Atlantska plovidba d.d. 45
Slika 19: HT d.d. 54
Slika 20: Adris grupa d.d. 54
Slika 21: Valamar Riviera d.d. 54
Slika 22: Podravka d.d. 54
Slika 23: Končar - Elektroindustrija d.d. 54
Slika 24: Ledo d.d. 54
Slika 25: Atlantic grupa d.d. 55
Slika 26: Ericsson Nikola Tesla d.d. 55
Slika 27: AD Plastik d.d. 55
Slika 28: Atlantska plovidba d.d. 55
Slika 29: Skup mogućih portfelja 60

Slika 30: Skup minimalne varijance 60
Slika 31: Efikasna granica 60
Slika 32: Efikasna granica 69
Slika 33: Primjer linijskog grafikona 71
Slika 34: Primjer stupičatog grafikona 72
Slika 35: Primjer jednog intervala 72
Slika 36: Primjer grafikona s Japanskim svijećama 72
Slika 37: Primjer jednog intervala 72
Slika 38: Primjer grafikona krug-križ 73
Slika 39: Primjer formacije zastave i zastavice 76
Slika 40: Primjer simetričnog trokuta 76
Slika 41: Primjer rastućeg trokuta 76
Slika 42: Primjer padajućeg trokuta 76
Slika 43: Primjer simetričnog trokuta s prikazom položaja točke proboja 77
Slika 44: Tehnička analiza povlaštene dionice poduzeća Adris d.d. za razdoblje 29.05.2015.-29.05.2017 83
Slika 45: Tehnička analiza povlaštene dionice poduzeća Adris d.d. za razdoblje 29.05.2017.-03.07.2017 85
Slika 46: Tehnička analiza redovne dionice poduzeća Atlantic grupa d.d. za razdoblje 29.05.2015.-29.05.2017. 87
Slika 47: Tehnička analiza redovne dionice poduzeća Atlantic grupa d.d. za razdoblje 29.05.2017.-03.07.2017. 89
Slika 48: Tehnička analiza redovne dionice poduzeća Ericsson Nikola Tesla d.d. za razdoblje 29.05.2015.-29.05.2017. 90
Slika 49: Tehnička analiza redovne dionice poduzeća Ericsson Nikola Tesla d.d. za razdoblje 29.05.2017.-03.07.2017. 92
Slika 50: Tehnička analiza redovne dionice poduzeća Hrvatski telekom d.d. za razdoblje 29.05.2015.-29.05.2017. 93
Slika 51: Tehnička analiza redovne dionice poduzeća Hrvatski telekom d.d. za razdoblje 29.05.2017.-03.07.2017. 94
Slika 52: Tehnička analiza redovne dionice poduzeća Končar - Elektroindustrija d.d. za razdoblje 29.05.2015.-29.05.2017. 96
Slika 53: Tehnička analiza redovne dionice poduzeća Končar - Elektroindustrija d.d. za razdoblje 29.05.2017.-03.07.2017. 98

Slika 54: Tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje 29.05.2015.-29.05.2017. 99
Slika 55: Tehnička analiza redovne dionice poduzeća Podravka d.d. za razdoblje 29.05.2017.-03.07.2017. 100
Slika 56: Tehnička analiza redovne dionice poduzeća Valamar Riviera d.d. za razdoblje 29.05.2015.-29.05.2017. 101
Slika 57: Tehnička analiza redovne dionice poduzeća Valamar Riviera d.d. za razdoblje 29.05.2017.-03.07.2017. 102

Popis tablica

Tablica 1: Faze životnog ciklusa djelatnosti/poduzeća 14
Tablica 2: Izračun koeficijenta tekuće likvidnosti 33
Tablica 3: Izračun koeficijenta ubrzane likvidnosti 34
Tablica 4: Izračun koeficijenta trenutne likvidnosti 35
Tablica 5: Izračun koeficijenta financijske stabilnosti 35
Tablica 6: Izračun koeficijenta zaduženosti 36
Tablica 7: Izračun koeficijenta vlastitog financiranja 37
Tablica 8: Izračun koeficijenta financiranja 38
Tablica 9: Izračun stupnja pokrića II 38
Tablica 10: Podaci za izračun pokazatelja profitabilnosti ROA i ROE 39
Tablica 11: Izračun pokazatelja profitabilnosti ROA i ROE 39
Tablica 12: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a 40
Tablica 13: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a 41
Tablica 14: Podaci potrebni za izračun korigiranog Altmanovog Z`` score-a 41
Tablica 15: Izračunata vrijednost korigiranog Altmanovog Z`` score-a 42
Tablica 16: Izračun knjigovodstvene vrijednosti poduzeća (2014. godina) 43
Tablica 17: Izračun knjigovodstvene vrijednosti poduzeća (2015. godina) 43
Tablica 18: Izračun knjigovodstvene vrijednosti poduzeća (2016. godina) 44
Tablica 19: Izračun knjigovodstvene vrijednosti poduzeća po dionici (2016. godina) 46
Tablica 20: Izračun EPS-a 47
Tablica 21: Izračun P/E multiplikatora 47
Tablica 22: Vrijednost poduzeća metodom P/E multiplikatora 49
Tablica 23: Vrijednost poduzeća po dionici metodom P/E multiplikatora 49
Tablica 24: Izračun P/B multiplikatora 50
Tablica 25: Izračun vrijednosti poduzeća metodom P/B multiplikatora 51
Tablica 26: Izračun vrijednosti poduzeća po dionici metodom P/B multiplikatora 52
Tablica 28: Odstupanje izračunate cijene dionica od zaključne i prosječne godišnje cijene 53
Tablica 29: Odabrani početni uzorak dionica 63
Tablica 30: Dio korištenih prosječnih dnevnih cijena (za 14 dana) 64
Tablica 31: Dio izračunatih dnevnih prinosa dionica (za 14 dana) 64
Tablica 32: Izračun parametara 65
Tablica 33: Matrica A (prvih 14 redova) 65

Tablica 34: Matrica varijanci i kovarijanci S 66
Tablica 35: Izračun optimalnih udjela i maksimalnog očekivanog prinosa portfelja za rizik 0,0055 67
Tablica 36: Efikasni portfelji bez dozvoljene kratke prodaje za razdoblje od 29.05.2015. do 29.05.2017 68
Tablica 37: Efikasni portfelji s dozvoljenom kratkom prodajom za razdoblje od 29.05.2015. do 29.05.2017 68

Sažetak

Kombiniranom primjenom fundamentalne i tehničke analize, te matematičkih modela omogućuje se dobivanje šire slike o poslovanju i vrijednosti promatranih poduzeća, a tako i izbor "kvalitetnog" uzorka dionica, formiranje optimalnog portfelja koji će uz određeni stupanj rizika maksimalizirati profit, te procjena najpovoljnijeg trenutka za rebalans portfelja. Fundamentalnom analizom moguće je otkriti podcijenjenu i/ili precijenjenu dionicu, Markowitzevim mean – variance (M-V) modelom optimizacije portfelja moguće je izračunati optimalni udio dionica u portfelju kako bi se uz minimalni rizik ostvario određeni prinos, odnosno kako bi se uz rizik koji je investitor spreman prihvatiti ostvario maksimalni prinos, dok je tehničkom analizom moguće procijeniti povoljni trenutak za prodaju ili kupnju dionice.

KLJUČNE RIJEČI: fundamentalna analiza, Markowitzev mean – variance (M-V) model optimizacije portfelja, tehnička analiza.

Summary

It is possible to get a wider picture of company's business performance and its value by combining fundamental and technical analysis along with mathematical models, as well as to choose a "high – quality" stock mixture, to select an optimal portfolio which maximizes profit for a given level of risk, and to predict the right moment for the rebalance of portfolio. While the undervalued or/and overrated stocks can be recognized by using fundamental analysis, the optimal share of each stock in portfolio can be calculated by using Markowitz mean – variance (M-V) model. Markowitz mean – variance (M-V) model can maximize the profit for a given, acceptable level of risk or it can minimize the level of risk for a given, expected profit. The right moment to invest in a stock or to sell it can be predicted by using technical analysis.

KEY WORDS: fundamental analysis, Markowitz mean – variance (M-V) model, technical analysis.