Analiza utjecaja računovodstvenih i makroekonomskih podataka na tržišno kretanje dionica

Skorić Drezga, Franka

Professional thesis / Završni specijalistički

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:124:084145

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET
POSLIJEDIPLOSMKI STUDIJ – FINANCIJSKI MENADŽMENT

SPECIJALISTIČKI ZAVRŠNI RAD

ANALIZA UTJECAJA RAČUNOVODSTVENIH I MAKROEKONOMSKIH PODATAKA NA TRŽIŠNO KRETANJE DIONICA

Mentor:
Prof. dr. sc. Ivica Pervan

Student:
Franka Skorić Drezga, mag. oec.

Split, svibanj 2017.

SADRŽAJ **STR**

1. UVOD **4**

1.1. Postavljanje problema **6**

1.2. Svrha i ciljevi istraživanja **6**

1.3. Metode istraživanja **6**

1.4. Obrazloženje strukture završnog rada **7**

2. MODELI VREDNOVANJA DIONICA **9**

2.1. Vrijednosnice tržišta kapitala: dionice **9**

2.2. Pristupi vrednovanja redovnih dionica **10**

2.2.1. Vrednovanje dionica na temelju dividendi 11

2.2.1.1. Modeli vrednovanja dionica s konstatnim rastom dividendi 12

2.2.1.2. Model vrednovanja dionica s nekonstantnim rastom dividendi 13

2.2.2. Modeli tržišne kapitalizacije 14

2.2.3. Vrednovanje dionica za razdoblje držanja 18

2.2.4. Feltham-Ohlsonov model vrednovanja 19

2.3. Tehnička analiza **20**

2.4. Fundamentalna analiza **22**

2.5. Makroekonomski podaci **26**

2.5.1. Inflacija 26

2.5.2. Industrijska proizvodnja, BDP i gospodarski rast 27

2.5.3. Kamatna stopa 30

2.5.4. Tržišni indeks cijena dionica 31

3. TEORIJE ULOGE INFORMACIJA PRI VREDNOVANJU DIONICA **36**

3.1. Teorija efikasnog tržišta (teorija informacijske efikasnosti) **36**

3.1.1. Hipoteza racionalnih očekivanja 38

3.1.2. Model martingala 39

3.1.3. Hipoteza slučajnog hoda (RW modeli) 39

3.2. Suvremena teorija upravljanja portfeljima **49**
3.3. CAPM model **50**
3.4. Arbitražna teorije procjenjivanja (APT) **55**

4. HRVATSKO TRŽIŠTE KAPITALA I SVJETSKA FINANCIJSKA KRIZA **58**
4.1. Funkcioniranje tržišta kapitala u Hrvatskoj **58**
4.2. Razvoj hrvatskog tržišta kapitala i trgovanje na tržištima kapitala **62**
4.3. Liberalizacija kretanja kapitala u Hrvatskoj **63**
4.3.1. CROBEX 66
4.3.2. CROBIS 68
4.3.3. CROBEX 10 68
4.3.4. CROBEXplus 71
4.4. Integracija hrvatskog tržišta kapitala i svjetska financijska kriza **73**

5. ANALIZA UTJECAJA RAČUNOVODSTVENIH I MAKROEKONOMSKIH PODATAKA NA TRŽIŠNO DJELOVANJE DIONICA **78**
5.1. Oblikovanje modela za ocjenu utjecaja makroekonomskih podataka na tržišno vrednovanje dionica **80**
5.2. Oblikovanja modela za ocjenu utjecaja financijskih informacija na tržišno vrednovanje dionica **85**

6. ZAKLJUČAK **93**
SAŽETAK **94**
LITERATURA **95**
POPIS TABLICA I SLIKA **102**
DODATAK **103**

1. UVOD

1.1. Postavljanje problema (s predmetom istraživanja i radnom hipotezom)

Predmet istraživanja završnog rada je utjecaj financijskih i makroekonomskih podataka na hrvatsko tržište kapitala. Od početka istraživanja računovodstvenih vrsta informacija koje bi utjecale na kretanje na tržišta kapitala znanstvenici su pokušali ustanoviti koje informacije mogu utjecati na kretanje cijena na tržištu kapitala. Međutim, ne postoji jedinstvena formula ili jednadžba na koju bi se investitori mogli osloniti prilikom donošenja odluka o investiranju i u njihovim odlukama uvijek postoji rizik.
Hipotezu efikasnih tržišta, kao jednu od najkontroverznijih tema ekonomskih znanosti u posljednjih dvadeset godina, postavio je u svojoj doktorskoj disertaciji 1965 godine Eugene Fama. Poznata hipoteza u biti pretpostavlja da trenutno tržišno vrednovanje financijske imovine odgovara intrizičoj vrijednosti imovine. Odnosno da su sve javno dostupne informacije već ugrađene u cijenu te se nove javne informacije koje dolaze na tržište konstantno ugrađuju u trenutno vrednovanje. Pritom ne ostavljajući prostora za nadprosječne profite koji bi bili rezultat trgovanja temeljem tih novih informacija.

Efikasnost na tržištima kapitala od velike je važnosti za ulagače i menadžere. Ulagači više trguju na tržištu koje jamči pravedno vrednovanje dionica. S druge strane, menadžerima je bitno da se njihove odluke reflektiraju kroz promjenu cijenu na tržištu kapitala. Paralelno s razvojem klasične teorije u računovodstvu, čiji je glavni nedostatak zanemarivanje reakcije korisnika na informacije prezentirane javnosti, razvija se fundamentalna analiza koja koristi tekuće i povijesne informacije iz financijskih izvještaja.

Ukoliko se pretpostavi da cijene dionica reagiraju na objavu o zaradi tada bi se cijena dionica smanjila kod poduzeća koja su ostvarila lošiji rezultat od očekivanja ulagača. S druge strane bi investitori ostvarili bolji rezultat ukoliko poduzeće objavi da je u prethodnoj godini poslovalo s dobitkom. Pokazatelj knjigovodstvene vrijednosti po dionici računa se dijeljenjem tržišne cijene po dionici s knjigovodstvenom vrijednošću po dionici. Knjigovodstvena vrijednost glavnice i dobiti koju poduzeća objavljuju u financijskim izvješćima utječu na kretanje cijena dionica na tržištu kapitala. Pervan, Malčak i Arnerić (2011) donose zaključak da uzimajući u obzir kako investitori prilikom analiziranja financijskih izvješća više pozornosti pridaju dobiti može se

zaključiti da bi ta računovodstvena varijabla trebala imati više utjecaja na kretanje cijena dionica od knjigovodstvene vrijednosti glavnice.
Također, na kretanje cijena dionica utječe i informacije iz makroekonomskog okruženja. Pad ekonomske aktivnosti dovodi do niza negativnih trendova u gospodarstvu među kojima je i niže cijene dionica i tržišnih indeksa. Globalna gospodarska kriza svoje izvore ima u gospodarskom sustavu SAD-a te je prešla njene granice i prerasla u svjetsku gospodarsku krizu. Pod utjecajem teške gospodarske situacije u RH te dodatnih negativnih djelovanja svjetske gospodarske krize u Hrvatskoj zabilježen je pad BDP-a te svih ostalih makroekonomskih pokazatelja. Pad BDP-a praćen je padom uvoza i izvoza, padom industrijske proizvodnje, padom zaposlenosti, padom trgovine na malo te, porastom unutarnjeg i vanjskog duga. Negativne posljedice gospodarske krize osjetile su se i na financijskim tržištima RH, a pogotovo tržištu kapitala tj. Zagrebačkoj burzi u vidu pada prometa i tržišnih cijena dionica. U sublimaciji svih negativnih utjecaja investitori na tržištu kapitala nastojali su očuvati vrijednost svoje imovine te optimalno ulagati radi njenog ostvarenja prinosa.

Kao temeljni problem ovog rada postavlja se da li cijene dionica u Hrvatskoj su u zavisnosti s ekonomskim informacijama. Drugim riječima postavlja se pitanje, kakav utjecaj i u kojem smjeru djeluju makro i mikro ekonomske varijable na cijene dionica. Također, potrebno je definirati koje informacije, odnosno varijable dovode do promjena cijena dionica kao i njihove jakosti te da li na temelju tih informacija ulagači mogu predvidjeti kretanje cijena dionica a samim time i odluke o ulaganju. Posljedično, problem rada je istražiti da li je i u kojoj mjeri hrvatsko tržište kapitala efikasno.

U radu će se teorijski i empirijski istraživati i analizirati utjecaj računovodstvenih i makroekonomskih informacija na tržišno vrednovanje dionica koje kotiraju na burzi u Hrvatskoj.

Na temelju opisanog problema i navedenog predmeta istraživanja postavljaju se **temeljene radne hipoteze:**

H1: Računovodstvene informacije statistički su značajno povezane s kretanjem cijena dionica.

H2: Kretanje cijena na tržištu kapitala u ovisnosti je s makroekonomskim pokazateljima (inflacija, kamatna stopa i industrijska proizvodnja).

1.2. Svrha i ciljevi istraživanja

U skladu sa uočenim problemom, predmetom istraživanja, i postavljenim radnim hipotezama ciljevi i svrha ovog magistarskog rada su:

1. Analizirati vrijednosnu važnost i pouzdanost računovodstvenih informacija, prije svega dobiti i knjigovodstvene glavnice, izračunatih iz financijskih izvještaja, na kretanje cijena dionica na hrvatskom tržištu kapitala (Zagrebačkoj burzi) u zadnjih četiri godine prema F-O modelu Feltham i Ohlsonov (1995). Također, analizom ćemo se pokušati dati odgovor na pitanje koja je računovodstvena varijabla bolje objašnjava kretanje cijene dionica, dobit ili glavnica. Empirijsko istraživanje poslužit će u svrhu potvrđivanja ili opovrgavanja utjecaja računovodstvenih informacija iz financijskih izvješća na cijenu dionica i usporedbe intenziteta utjecaja na cijenu dionica.
2. Analizirati utjecaj makroekonomskih podataka (inflacija, kamatna stopa i industrijska proizvodnja) na kretanje cijena dionica na tržištu kapitala u Hrvatskoj. Podaci će biti uzeti mjesečno za posljednjih 5 godine (2011-2015). Svrha ovog empirijskog istraživanja je potvrditi koliko stanje Hrvatskog gospodarstva utječe na kretanje cijena dionica na tržištu kapitala.

1.3. Metode istraživanja

Izrada rada temeljena je na metodama primjerenim istraživanjima u društvenim znanostima kao što su metoda deskripcije stanja i procesa, induktivna i deduktivna metoda zaključivanja, metoda analize i sinteze podataka, metoda apstrakcije i konkretizacije, metoda klasifikacije i komparacije podataka te metoda generalizacije.

U svrhu analiziranja utjecaja računovodstvenih informacija (dobiti i knjigovodstvene vrijednosti glavnice) te makroekonomskih podataka na cijenu dionica koristiti će se VAR (vektorska autoregresija), Grangerova kauzalnost, PANEL analiza te uobičajena regresijska analiza. Korigirani koeficijent determinacije, odnosno analiza inkrementalne eksplanatorne moći računovodstvenih varijabli pokazati će koja varijabla bolje objašnjava kretanje cijene dionica.

1.4. Obrazloženje strukture završnog rada

Rad zajedno sa uvodom i zaključkom ima šest poglavlja.

U prvom, uvodnom dijelu rada, bit će precizno definiran problem istraživanja, s naglaskom na aktualnost predmetnog problema na svjetskoj razini. U nastavku uvodnog dijela predstavit će se osnovni znanstveni ciljevi istraživanja. Ciljevi su detaljnije predstavljeni putem definiranih hipoteza. Uvodni dio također sadrži popis i obrazloženje osnovnih metoda istraživanja koje će se koristiti u završnom radu, kao i detaljan sadržaj i strukturu rada.

Drugi dio rada, pod nazivom „modeli vrednovanja dionica“ analizirati će se pojam dionica, vrijednost dionica, te različite pristupe vrednovanja dionica. Također će se osvrnuti na tehničku i fundamentalnu analizu kao na jednu od najviše upotrebljavanih analiza dionica danas te će se usredotočiti na makroekonomske podatke koje mogu utjecati na kretanje cijene dionica.

U trećem dijelu rada, pod nazivom „teorije uloge informacija pri vrednovanju dionica“, opisati će se teorija efikasnog tržišta odnosno teorija informacijske efikasnosti koju je definirao Fama (1970). Detaljnije će se opisati oblici hipoteze efikasnog tržišta (hipoteza racionalnih očekivanja, hipoteza martingnala, hipoteza slučajnog hoda). Zatim će detaljno biti objašnjena Markowitzeva teorija suvremenog upravljanja portfeljom, nakon koje slijedi njezina nadogradnja, odnosno CAPM model.

Četvrti dio rada, pod nazivom „Hrvatsko tržište kapitala i svjetska financijska kriza“, sadrži kratki pregled razvoja Hrvatskoj tržišta kapitala i način njegovog funkcioniranja. Nadalje, daje se prikaz trenutačnog stanja Zagrebačke burze s obzirom na svjetsku financijsku krizu. Na kraju poglavlja promatra se utjecaj liberalizacije kretanja kapitala u procesu integracije tržišta kapitala.

U petom dijelu rada će biti sadržana metodologija istraživanja vezana uz oblikovanje modela kojega se testiramo na tržištu kapitala. Prije iznošenja rezultata ekonometrijskoga testiranja modela objašnjeni su priroda i izvori korištenih podataka, te način prikupljanja i selekcija uzorka. Istraživački dio rada završava testiranjem podataka, prikazivanjem rezultata u tablicama, te analizom tako dobivenih rezultata.

U posljednjem, šestom dijelu rada, iznijet će se zaključna razmatranja kao sistematizacija prethodnih teorijskih spoznaja i empirijskih rezultata. Ovaj dio će istaknuti važnost i svrhu predmetnog istraživanja i predstavit će smjernice za daljnja znanstvena istraživanja.

2. MODELI VREDNOVANJA DIONICA

2.1. Vrijednosnice tržišta kapitala: dionice

Vrijednosnice mogu biti vlasničke, s fiksnim prinosom i nosioci prava. Vlasničke vrijednosnice su dionice, te investicija u njih ima karakter kupovine realnog kapitala koji je podloga vrijednosti dionice. Kupovina redovne dionice je poduzetnička investicija, budući da vlasnik sudjeluje u upravljanju dioničkim društvom. Kupnjom povlaštene dionice se polazi od pretpostavke da dionički ulog donosi veću dobit nego alternativno ulaganje.

Vrijednost bilo kojeg dobra, tako i dionice, ovisi o značenju koje joj pojedinac pridaje, odnosno ovisi o činjenici kolika je korisnost tog dobra za pojedinca. S obzirom da je vrijednost za svakog ima drugačije značenje, može se reći da je karakterizira subjektivnost. Svako dobro je moguće zamijeniti za neko drugo, preko tržišta, pa se može govoriti i o tržišnoj vrijednosti dobara, odnosno dionica. Vrijednost dionice je njezina unutarnja korisnost, a cijena je samo svota koju je kupac spreman primiti za ustupanje, a prodavalac suglasan platiti za stjecanje dionice. Potraživanje običnog dioničara je po rangu prioriteta rezidualno, budući da drugi zainteresirani imaju prioritet pri isplati dividendi i/ili likvidacijske mase u slučaju likvidacije tvrtke (imaoci obveznica, prioritetni dioničari, zaposleni, država, dobavljači). Obični dioničari dobivaju gotovinske tijekove od dividendi i kapitalnih dobitaka. Dividenda predstavlja dio neto dobitka koji je kompanija odlučila podijeliti dioničarima, a kapitalni dobitak predstavlja razliku između niže kupovne i više prodajne cijene koju ostvari dioničar pri prodaji dionice.[1]

Vrijednosnice predstavljaju financijsku imovinu koju definiramo kao potraživanje na gotovinske tijekove od realne imovine - poslovnih i proizvodnih objekata, zemljišta i opreme i sl. realne imovine. Prema općem pravilu vrednovanja vrijednost neke imovine rezultat je očekivanih gotovinskih tijekova od te imovine tijekom njenog životnog vijeka. Stoga se vrijednost neke imovine može izračunati kao sadašnja vrijednost očekivanih gotovinskih tijekova diskontiranih odgovarajućom stopom - traženom stopom povrata investitora koja u sebi uključuje naknadu za čekanje, kao odraz vremenske vrijednosti novca i naknadu za procijenjeni rizik inherentan gotovinskim tijekovima koje obećava vrijednosnica. Na efikasnim tržištima pojedinačni investitor nema utjecaj na cijenu vrijednosnice, već se ona uspostavlja pod zajedničkim

[1] Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split, str. 15-23.

utjecajem svih investitora, odnosno utjecajem tržišta. Sadašnja vrijednost vrijednosnice funkcija je, dakle, iznosa, dinamike i neizvjesnosti gotovinskih tijekova. Proces vrednovanja se može prikazati putem slijedećih faza:

1. Odrediti tijek gotovine - iznos očekivanih gotovinskih tijekova, rizičnost i vrijeme kad će se pojaviti.

2. Utvrditi traženu stopu povrata za gotovinske tijekove na temelju njihove rizičnosti i oportunitetnog troška.

3. Izračunati sadašnju vrijednost svakog toka diskontiranjem traženom stopom povrata.

4. Zbrojiti sadašnje vrijednosti.[2]

2.2. Pristupi vrednovanja redovnih dionica

Fundamentalni analitičari se koriste informacijama o sadašnjoj i budućoj profitabilnosti poduzeća kako bi procijenili fer tržišnu vrijednost. Obične dionice predstavljaju vlasničku vrijednosnicu koja običnom dioničaru daje pravo idealnog vlasništva nad kompanijom emitenta i pravo upravljanja kompanijom. Unutarnja vrijednost je ona prava vrijednost i bilo bi idealno kada bi bila jednaka tržišnoj odnosno burzovnoj cijeni dionice. Na ovaj način fundamentalna analiza opskrbljuje tržište s informacijama koje doprinose konkretnijoj tržišnoj procjeni vrijednosti dionica pa prema tome i njihovih izdavatelja. Tržišna vrijednost dionice jest vrijednost dionice ostvarena kupoprodajom na tržištu vrijednosnih papira.

Osim tržišne i unutarnje vrijednosti dionica, često se spominju i vrijednosti poput nominalne, emisijske, likvidacijske i knjigovodstvene (matematička) vrijednosti dionica. Nominalna vrijednost dionice jest nazivna vrijednost, odnosno vrijednost dionice koja je naznačena na samoj dionici. Nominalna vrijednost dionice može se promijeniti i nakon njenog izdavanja. Ukoliko je nominalna vrijednost previsoka, a tržišna cijena osjetno poraste, dioničko društvo može obaviti dijeljenje svojih dionica u nekom omjeru. Ona označava knjigovodstvenu vrijednost dionice u trenutku njenog izdavanja.

[2] Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 124 -125.

Knjigovodstvena ili matematička vrijednost predstavlja neto bilančnu aktivu umanjenu za dugove poduzeća. Kada se knjigovodstvena vrijednost poduzeća podijeli sa brojem dionica, dobije se knjigovodstvena vrijednost dionice. Procjena knjigovodstvene vrijednosti se temelji na povijesnim podacima dobivenih iz bilance te ne uzima u obzir nematerijalne sadržaje koji danas određuju sposobnost poduzeće u stvaranju profita. Iz navedenog se može zaključiti da knjigovodstvena vrijednost nije i unutarnja vrijednost dionice. Nakon što se utvrdi neto vrijednost poduzeća ili dionice na temelju materijalnih elemenata, dobivenoj vrijednosti je potrebno priključiti i vrijednost nematerijalnih elemenata koji utječu na rast dobiti poduzeća poput zaštitnog trgovačkog znaka, znanja uprave i osoblja (know-how), patenata, licenci, rezultate provedenih istraživanja. Ovaj višak vrijednosti možemo svesti pod zajednički naziv goodwill.

Potraživanje običnog dioničara je po rangu prioriteta rezidualno, budući da drugi zainteresirani imaju prioritet pri isplati dividendi i/ili likvidacijske mase u slučaju likvidacije tvrtke (imaoci obveznica, prioritetni dioničari, zaposleni, država, dobavljači). Obični dioničari dobivaju gotovinske tijekove od dividendi i kapitalnih dobitaka. Dividenda predstavlja dio neto dobitka koji je kompanija odlučila podijeliti dioničarima, a kapitalni dobitak predstavlja razliku između niže kupovne i više prodajne cijene koju ostvari dioničar pri prodaji dionice.[3]

2.2.1. Vrednovanje dionica na temelju dividendi

Teorija smatra da su dividende osnova za vrednovanje dionica. Predstavljaju jedine gotovinske tijekove koje dioničari mogu očekivati od dionice (osim u slučaju likvidacije ili prodaje). Stoga se i vrijednost dionice računa kao sadašnja vrijednost očekivanog tijeka dividendi. Jednadžba koja daje opći model vrednovanja običnih dionica glasi:

$$\text{Sadašnja vrijednost dionice} = \sum_{t=1}^{n} \frac{D_t}{(1+k)^t} \qquad (1)$$

Gdje je:

D_t dividenda u razdoblju t,

[3] Orsag, S. (2001): Dionice, Priručnik za polaganje ispita za obavljanje poslova investicijskog savjetnika, Hrvatska udruga financijskih analitičara, Zagreb.

k očekivani prinos.

Diskontna stopa kojom se dividende svode na sadašnju vrijednost predstavlja oportunitetni trošak ulaganja u obične dionice odnosno tržišnu stopu kapitalizacije za istu rizičnu skupinu ulaganja. Osnovnu formulu vrednovanja dionica na temelju sadašnje vrijednosti dividendi, treba korigirati s obzirom na to kako se kreće vrijednost dividendi. U praksi su uočena tri različita tipa dividendi: konstantne dividende, dividende koje rastu po konstantnoj stopi te dividende koje imaju varijabilnu stopu rasta.

2.2.1.1. Modeli vrednovanja dionica s konstatnim rastom dividendi

Shema dividendi gdje su dividende jednake zauvijek nije čest slučaj u praksi već se obično mijenjaju iz razdoblja u razdoblje, po nekoj stopi rasta. Za vrednovanje ovakvih dionica najčešće se koristi Gordonov model, čija je formula: [4]

$$\text{Sadašnja vrijednost dionice} = \frac{\mathrm{D}}{\mathrm{k-g}} \qquad (2)$$

Gdje je:

d – dividenda,

g - normalni rast dividendi u promatranom razdoblju,

k - tražena stopa povrata.

Kod Gordonovog modela rasta procjena se svodi na procjenu očekivanih dividendi za godinu koja slijedi, zatiom o stopi rasta dividendi iz povijesnih prosjeka na temelju povijesnih podataka o stopi isplate dividendi te stopi zadržavanja zarada te procjeni zahtijevanog prinosa, tj. diskontne stope.

Ukoliko se prilagodi Gordonov model tako da se odredi cijena kapitalne imovine kao zbroj sadašnje vrijednosti budućih (očekivanih) slobodnih novčnih tokova, slijedi sljedeća funkcija:

$$\mathrm{P} = \frac{\mathrm{FCF}\ (1+\mathrm{g})}{\mathrm{ks}-\mathrm{g}} \qquad (3)$$

[4] Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 124. -125.

Gdje je:

P – cijena,

FCF – "Free cash Flow" – slobodni novčani tok,

ks – trošak kapitala,

g – dugoročna stopa rasta slobodnih novčanih tokova.

Nedostatak Gordonovog modela je što njegova ispravna primjena odgovara relativno malom broju dionica za koje vrijedi da imaju "normalnu" stopu rasta, da isplaćuju dividende i da pokazuju konstantni rast dividendi. Drugi problem je nedostatak objektivne procjene stope rasta dividendi zbog njezinog velikog utjecaja na vrijednost dionice i na očekivanu stopu povrata. Svakako stopa rasta dividendi mora biti niža od tražene stope povrata. [5]

2.2.1.2. Model vrednovanja dionica s nekonstantnim rastom dividendi

Cijena dionice po modelu dividendi s nekonstantnim (iznadnormalnim) rastom računa se kao zbroj sadašnje vrijednosti dividendi u pojedinim fazama. Zarade poduzeća pa tako i dividende nakon perioda s iznadnormalnim rastom, prelaze u fazu s konstantnim rastom dividendi. S obzirom na tu pretpostavku, cijena dionice se može utvrditi kao zbroj sadašnje vrijednosti dividendi u prvim (nekonstantnim) fazama te sadašnje vrijednosti očekivane vrijednosti dionice na kraju zadnje faze nekonstantnog rasta. U tom slučaju za izračun cijene dionice se koristi model vječnog rasta. Jedno od najčešće korištenih modela je model vrednovanja super normalnog rasta poduzeće. Ovaj model se zasniva na detaljnoj procjeni dividendi u sagledivoj budućnosti od prvih t godina, dok se cijena dionica na kraju razdoblja t utvrđuje primjenom raznih modela. Pretpostavka na kojoj se model zasniva jest da poduzeće ostvaruje super normalni rast zbog usvajanja nove tehnologije, ulaska u nove industrije i slično, te se može očekivati da će nakon razdoblja super normalnog rasta, kada dođe do utjecaja konkurencije, poduzeće ući u normalno razdoblje rasta, odnosno rasta dividendi po konstantnim stopama. Zbog toga se vrlo često za utvrđivanje cijena na kraju razdoblja t koristi Gordonov model. Na taj se način povećava preciznost procjene, ali i omogućava upotreba modela super normalnog rasta i

[5] Mihalina, E. (2010): Model odnosa cijena i zarada kroz dividendni prinos i zahtjevani prinos iznad očekivane inflacije, 336.761(497.5), str. 3-4.

u situacijama kada poduzeće privremeno prekida sa isplatom dividendi. [6]

2.2.2. Modeli tržišne kapitalizacije

Zadatak modela tržišne kapitalizacije je analizirati opravdanost cijena po kojima se vrijednosni papiri nude potencijalnim ulagateljima. Modeli tržišne kapitalizacije svoju osnovu imaju u fundamentalnoj analizi, a naglasak je na pronalaženju načina kojima se ulagatelji mogu zaštititi od nepovoljnih događaja. Podaci koji se koriste u ovim modelima osigurava računovodstvo u objavljenim financijskim izvještajima.
Kod pokazatelja zarade po dionici, godišnji neto dobitak se dijeli sa prosječnim brojem redovnih dionica u prometu. Računa se prema formuli:

$$\text{Pokazatelj zarade po dionici} = \frac{\text{Neto dobitak} - \text{Prioritetne dividende}}{\text{Broj redovnih dionica u prometu}} \qquad (4)$$

Koncept izračuna ovoga pokazatelja se koristi samo za redovne dionice jer povlaštene dionice nemaju prava na zaradu iznad ugovorenog iznosa povlaštenih dividendi. Ovaj pokazatelj je jednostavan kada poduzeće emitira samo redovne dionice, a broj dionica u prometu se u toku godine ne mijenja. Međutim u praksi je često slučaj da se broj dionica u prometu mijenja tijekom godine i tada se vrijednost pokazatelja računa na temelju ponderiranog prosječnog broja dionica u prometu.

Pokazatelj zarade po dionici je dobar putokaz sudionicima na tržištu kapitala za predviđanje budućih poslovnih rezultata. Ipak treba imati na umu da porast zarada po dionici može biti iskrivljen primjenom različitih politika raspodjele dividendi i politika financiranja. Tako će poduzeće koje ima niži stupanj isplate dividendi imati veći pokazatelj zarade po dionici od poduzeća koji veći dio ostvarene zarade isplaćuje dioničarima u obliku dividende. Da bi se izbjegle ove zamke, alternativa je korištenje novčanog toka iz poslovanja umjesto kategorije dobitka. Računa se prema formuli:

[6] Mihalina, E. (2010): Model odnosa cijena i zarada kroz dividendni prinos i zahtjevani prinos iznad očekivane inflacije, 336.761(497.5), str. 116-118.

$$\text{Novčani tok po dionici} = \frac{\text{Novčani tok iz operativnih aktivnosti}}{\text{Ponderirani prosječni broj redovnih dionica u prometu}} \qquad (5)$$

Odnos cijene i zarade pokazuje u kojoj mjeri tržište kapitalizira zarade poduzeća. Ovaj pokazatelj služi za prvu selekciju vrijednosnih papira u koje se želi ulagati. Računa se po formuli:

$$\text{Odnos cijene i zarade (P/E ratio)} = \frac{\text{Tržišna cijena po dionici}}{\text{Zarada po dionici}} \qquad (6)$$

Promjene pokazatelja P/E odražavaju volju ulagatelja za investiranjem u neki vrijednosni papir u skladu sa budućim očekivanjima. Poduzeća koja imaju veliki potencijal rasta imat će i visok odnos cijene i zarade, dok za poduzeća s ograničenim mogućnostima rasta vrijedi suprotno. Nadalje, "uz pretpostavku da nema velikih varijacija u zaradama ili promjene računovodstvenih politika, postoji inverzna povezanost između ovog troška i troška trajnog kapitala poduzeća".[7] Empirijska istraživanja su pokazala da poduzeća sa nižim odnosom cijene i zarade imaju tendenciju ostvarivanja natprosječnog povrata na tržištu, čak i kad su ostvareni povrati u potpunosti adekvatni riziku, jer je trošak trajnog kapitala visok. To znači da je stopa povrata za ulagatelje visoka, što ukazuje na podcijenjenost dionica.

Odnos cijene i knjigovodstvene vrijednosti zajedno sa faktorom veličine poduzeća pokazuje najbolju mjeru budućih povrata na dionicu računa se po formuli:

$$\text{Odnos cijene i knjigovodstvene vrijednost} = \frac{\text{Tržišna cijena po dionici}}{\text{Knjigovodstvena vrijednost po dionici}} \qquad (7)$$

Knjigovodstvena vrijednost se još naziva i teoretska vrijednost i obično se računa za redovne dionice. Osnovna formula za izračun je:

[7] Vidučić, Lj. (2008): Financijski menadžment, VI. nepromjenjeno izdanje, RRIF-plus, Zagreb, str. 416.

$$\text{Knjigovodstvena vrijednost po dionici} = \frac{\text{Dioničarska glavnica}}{\text{Broj redovnih dionica u prometu}} \quad (8)$$

Knjigovodstvena vrijednost predstavlja iznos koji su dioničari uložili, uvećan za iznos koji je poduzeće zaradilo i zadržalo za daljnje poslovanje. Ako se dionice prodaju po cijeni koja je iznad knjigovodstvene vrijednosti, ulagatelji vjeruju da je menadžment svojim radom stvorio poduzeće koje vrijedi mnogo više od povijesnog troška sredstava koja su uložena u njega. Ako je razlika između knjigovodstvene i tržišne vrijednosti postane vrlo velika tada ulagatelji moraju razmisliti da li će buduće poslovanje poduzeće opravdati tržišnu cijenu. U slučaju kada je tržišna cijena manja od knjigovodstvene vrijednosti dionice tada ulagatelji vjeruju da sredstva poduzeća vrijede manje od njihovog troška. U tom kontekstu se odnos tržišne i knjigovodstvene vrijednosti može smatrati svojevrsnom mjerom povjerenja ulagatelja u menadžment poduzeća.

Pokazatelj prinosa od dividendi je posebno značajan za sudionike na tržištu kapitala čiji je cilj maksimizirati prihod od dividendi. Naime, neki dioničari ulažu da bi imali redovni prihod od dividendi, dok drugi ulažu jer se nadaju da će promjenom tržišnih cijena ostvariti kapitalne dobitke. Ako je poduzeće profitabilno i zadržava svoje zarade za proširenje poslovanja, novim aktivnostima će ostvarivati rast neto dobiti i na taj način uvjetovati da svaka dionica više vrijedi. Formula za izračun prinosa je:

$$\text{Prinos od dividendi} = \frac{\text{Dividenda po dionici}}{\text{Tržišna cijena po dionici}} \quad (9)$$

Pokazatelj isplate dividendi pokazuje koliki dio ostvarene dobiti će se isplatiti dioničarima na ime dividendi, a koliko se zadržava za reinvestiranje. Ulagatelji kojima je cilj maksimizirati prihod od dividendi, ulagati će u dionice sa visokim pokazateljem isplate dividendi. Ulagatelji kojima je interes zarada na razlici u cijeni, žele da poduzeće što veći dio svojih zarada reinvestira, očekujući da će to dovesti do porasta tržišne cijene dionice, te će za ulaganje odabrati dionice koje imaju nizak pokazatelja isplate dividendi. Računa se prema formuli:

$$\text{Pokazatelj isplate dividendi} = \frac{\text{Dividenda po dionici}}{\text{Zarada po dionici}} \qquad (10)$$

Općenito se pokazalo da rastuća poduzeće imaju niži pokazatelj isplate dividendi, jer većinu dobitka zadržavaju za financiranje buduće ekspanzije. Stabilna, renomirana poduzeća imaju viši pokazatelj isplate dividendi jer su prošli fazu velikih investicijskih pothvata za širenje poslovanja.

Pokazatelji vrijednosti dividendi po dionici (DPS) ovisi o, ponajviše, politici dividendi i s aspekta dioničara poželjna je što veća vrijednos. Investitori koji teže zaradi na razlici u cijeni moraju biti na oprezu jer visoke isplate dividendi smanjuju sredstva koja se mogu uložiti u napredak tvrtke koja bi takvom politikom mogla prouzročiti probleme s likvidnošću ili nedostatkom sredstava te smanjenjem kapaciteta zaduživanja i sl.

$$\text{Dividenda po dionici (DPS)} = \frac{\text{Isplaćeno za dividende}}{\text{Broj dionica}} \qquad (11)$$

Povrat na dioničku glavnicu, odnosno profitabilnost glavnice redovnih dioničara pokazuje potencijal glavnice za ostvarivanje zarada. Računa se po formuli:

$$\text{Povrat na dioničku glavnicu (ROE)} = \frac{\text{Neto dobitak} - \text{Prioritetne dionice}}{\text{Prosječna glavnica redovnih dioničara}} \qquad (12)$$

ROE predstavlja snagu zarade u odnosu na ulaganje dioničara. Poželjna što veća vrijednost pokazatelja.

$$\text{Povrat na ukupnu imovinu (ROA)} = \frac{\text{Neto dobitak} - \text{Dividende prioritetnih}}{\text{Ukupna imovina}} \qquad (13)$$

Pokazatelj povrata na imovinu pokazuje sposobnost tvrtke da korištenjem raspoložive imovine ostvari dobit, odnosno predstavlja mjeru snage zarade tvrtke. Poželjna je što veća vrijednost pokazatelja.[8]

2.2.3. Vrednovanje dionica za razdoblje držanja

Koncept izračuna vrijednosti dionice za razdoblje držanja polazi od pretpostavke da investitor kupuje dionicu sa namjerom da je drži određeno vrijeme i pri tom ostvari novčane primitke na ime dividende i od tržišne vrijednosti prodaje u trenutke prodaje. Kako bi se izračunala vrijednost dionice za razdoblje držanja potrebno je izračunati njenu sadašnju vrijednost diskontiranjem svih očekivanih novčanih primitaka od dionice. Za to vrijeme, od dionice će primiti tekuće novčane dohotke-dividende, a istekom razdoblja držanja, prodajom dionice, će realizirati njenu tržišnu cijenu. Model se može zapisati kao:

$$\text{Sadašnja vrijednost dionice} = \sum_{t=1}^{n} \frac{D_t}{(1+k)} + \frac{P_t}{(1+k)^t} \qquad (14)$$

Gdje je:

D_t – dividenda kroz *t* razdoblja,

P_t - cijena dionice krajem razdoblja,

k - zahtijevani prinos.

Model vrijednosti dionice za razdoblje držanja je jednostavna varijanta koncepta ekonomske vrijednosti primijenjenog na vrijednost dionice. Problem je u tome što se sadašnja vrijednost dionice procjenjuje na temelju buduće očekivane, ali nepoznate vrijednosti, a to znači da se sa stajališta vremena sigurnija vrijednost procjenjuje na temelju one nesigurnije. Činom prodaje dionice istekom razdoblje držanja ne prestaje njen životni vijek. Novom držatelju će također donositi dohodak u obliku dividendi što dovodi do zaključka da se vrijednost dionice može procjenjivati kao sadašnja vrijednost dividendi. Upravo zbog toga što su dividende jedini

[8] Vidučić, Lj. (2206): Financijski menadžment, V. izdanje, RRiF, Zagreb, 2006., str. 30-56.

izvjesni novčani primitak od dionice, model vrednovanje dionice za razdoblje držanja nije u učestaloj upotrebi, već se mnogo češće koristi model procjene dionica vrednovanjem dividendi. [9]

2.2.4. Feltham-Ohlsonov model vrednovanja

Financijski izvještaji kao nosioci računovodstvenih informacija bi trebali prikazivati informacije koje su korisne u poslovnom odlučivanju potencijalnim investitorima, kreditorima te ostalim, jednako internim kao i eksternim korisnicima tih informacija. Korisne računovodstvene informacije su one informacije koje imaju mogućnost utjecaja na proces odlučivanja korisnika financijskih izvještaja. Da bi bile korisne moraju biti važne i pouzdane. Početkom 90-ih godina prošlog stoljeća u računovodstvenim istraživanjima orijentiranim prema tržištu kapitala javlja se tzv. pristup vrednovanja. Ovom smjeru istraživanja cilj je utvrditi vezu između računovodstvenih informacija i cijena dionica, istovremeno objašnjavajući kako se računovodstvene informacije transformiraju u cijene. Pristup vrednovanja podrazumijeva korištenje modela vrednovanja glavnice, a teorijsku razradu tog modela su napravili Ohlson (1991), te Feltham i Ohlson (1995). Feltham-Ohlsonov model se temelji na knjigovodstvenoj vrijednosti glavnice korporacije i računovodstvenom dobitku, koji predstavlja dinamičku mjeru vrijednosti. Prema konačnoj verziji modela, tržišna vrijednost glavnice korporacije jednaka je knjigovodstvenoj vrijednosti glavnice uvećanoj za sadašnju vrijednost neočekivanih dobitaka (budućih dobitaka koji prelaze trošak glavnice).

$$P_{it} = a_0 + a_1 E_{it} + a_2 BV_{it} + e_{it} \quad (15)$$

$$P_{it} = b_0 + b_1 E_{it} + e_{it} \quad (16)$$

$$P_{it} = c_0 + c_1 BV_{it} + e_{it} \quad (17)$$

Gdje su:

P_{it} - cijena dionice tri mjeseca nakon kraja fiskalne godine t,

E_{it} - dobit po dionici u godini t,

BV_{it} - knjigovodstvena vrijednost glavnice po dionici na kraju godine t,

[9] Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 124. - 125.

e_{it} - ostale vrijednosno važne informacije u godini t. [10]

Feltham-Ohlsonov model je najčešće korišteni model u istraživanjima vrijednosne važnosti, na razvijenim kao i na tranzicijskim tržištima kapitala. Dakle, provedena su brojna empirijska istraživanja u okviru kojih su se razmatrali različiti aspekti vrijednosne važnosti računovodstvenih informacija (primjerice Collins et al., 1997, Gjerde et al. 2010, Goncharov i Hogson, 2012, Jones et al., 2011, Mechelli i Cimini, 2014, Ernset i Oscar, 2014 Lee i Park 2015), a općenito promatrano rezultati istraživanja pokazuju da su računovodstvene informacije (prije svega dobit i glavnica) značajni čimbenici u vrednovanju korporacija te da su spomenute varijable značajno povezane s cijenama dionica. [11]

U kontekstu hrvatskog tržišta kapitala rezultati istraživanja koje su proveli Pervan i Bartulović (Pervan i Vasilj, 2009; Pervan i Bartulović 2012; Pervan i Bartulović 2014) pokazuju da su računovodstvene informacije vrijednosno važne, međutim, autori također ukazuju na velike oscilacije u vrijednosnoj važnosti tijekom vremena.

Dakle, kroz prvi regresijski model se testira povezanost cijene dionice sa dobiti i glavnicom istovremeno. U drugom modelu se analizira postoji li pozitivna i značajna veza između kretanja cijena dionica i dobiti, dok se u trećem modelu testira povezanost cijena dionica i glavnice. F-O model je korišten u empirijskoj analizi vrijednosne važnosti računovodstvenih informacija na hrvatskom tržištu kapitala.[12]

2.3. Tehnička analiza

Tehnička analiza pokriva područje proučavanja unutarnjih procesa tržišta uz pomoć statističkih metoda, najčešće grafikona. Otuda joj još i naziv „grafička analiza“ ili „analiza čartista“. Koncentrira se na analizu kretanja cijena vjerujući da tržišna psihologija diktira cijene, a ne

[10] Feltham, G., Ohlson. J., A. (1995): Valuation and Clean Surplus Accounting for Operating and Financial Activities, Contemporary Accounting Research, str. 689-731.
[11] Pervan, I., Vasilj, M. (2009): Vrijednosna važnost glavnice i dobiti - empirijska analiza za hrvatske korporacije sa zagrebačke burze, Ekonomska istraživanja: znanstveno-stručni časopis.- Pula: Sveučilište "Jurja Dobrile" u Puli, Vol. 22, 4, str. 41-51.
[12] Bartulović, M. (2015): Trendovi u vrijednosnoj važnosti računovodstvenih informacija: empirijska analiza za korporacije sa zagrebačke burze, Sveučilišni odijel za forezničnе znanosti Split.

vrijednost dionica. Iz dosadašnjeg kretanja cijena dionica pokušava prepoznati trendove i obrasce kretanja, pa temeljem toga predvidjeti buduće kretanje cijena dionica.[13]

Tri su pretpostavke na kojima se temelji tehnički pristup:

1. Tržišna kretanja uzimaju u obzir sve dostupne informacije (ova pretpostavka ujedno i predstavlja i jednu od većih kritika tehničke analize). Tehničar vjeruje da se sve što potencijalno može utjecati na cijenu – fundamentalno, politički, psihološki ili na bilo koji drugi način – već se odražava u tržišnoj cijeni.
2. Cijene slijede trendove. Cijeli smisao prikazivanja kretanja cijena na grafikonima je identificirati trendove u ranoj fazi razvoja u svrhu trgovanja u smjeru tih trendova. Većina tehnika koje se koriste u ovom pristupu po svojoj prirodi slijedi trendove što znači da je njihova namjera prepoznati i slijediti postojeće trendove.
3. Povijest se ponavlja. Veliki dio tehničke analize i analize tržišnih kretanja odnosi se na proučavanje ljudske psihologije. Primjerice, obrasci koji se pojavljuju na grafikonima, koji su identificirani i kategorizirani u nekoliko godina, odražavaju određene slike koje se stalno pojavljuju na cjenovnim grafikonima. Te slike otkrivaju rastuće ili padajuće psihološko raspoloženje tržišta. [14]

Iz analize tečajeva dionica iz prošlosti posebnim se metodama tehničke analize pokušavaju izvoditi zaključci o njihovom kretanju u budućnosti. Razlozi da se u obzir uzmu samo tečajevi i volumen prodaje dionica jesu u sljedećim pretpostavkama:

- Kako svi faktori, racionalni i iracionalni, koji utječu na formiranje tečajeva dionica i sami odražavaju u tim tečajevima, onda se oni obrnuto gledano mogu i očitavati iz tih istih tečajeva dionica.
- Tečaj i volumen prodaje dionica na tržištu jedini su objektivni pokazatelji ponude i potražnje dionica.
- Za razliku od knjigovodstvenih podataka iz bilanci poduzeća koje koristi fundamentalna analiza (poglavlje 2.4), podaci o tečajevima i volumenima prodaje dionica na burzama širom svijeta dostupni su svima u kratkom roku.[15]

[13] Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split, str. 164.
[14] Murphy, J.J. (2007): Tehnička analiza financijskog tržišta, Masmedia, str. 25-28.
[15] Prohaska, Z. (1996): Analiza vrijednosnih papira, Infoinvest, Zagreb, str. 87.

Cilj je, dakle, tehničke analize prognoziranje tečajeva dionica sa svrhom da se ustvrde povoljni trenuci za kupovinu odnosno prodaju dionica.

2.4. Fundamentalna analiza

Metoda fundamentalne analize polazi sa stajališta da vrijednost dionica ovisi o očekivanoj budućoj dobiti ili dividendi tj. prihodu dioničkog društva. Ona usmjerava pažnju na promjene ponude i potražnje koje uzrokuju rast ili pad cijena dionica, ili pak ostanak na istoj razini. Fundamentalni pristup proučava sve relevantne čimbenike koji utječu na cijenu kako bi se odredila unutarnja vrijednost dionice. Ako je unutarnja vrijednost ispod trenutačne tržišne cijene, dionica je precijenjena i trebalo bi je prodati. Ako je tržišna cijena ispod unutarnje vrijednosti, dionica je podcijenjena i trebalo bi je kupiti. Cilj je, dakle, fundamentalne analize ustanoviti odgovara li cijena pojedine dionice u određenom trenutku njezinoj stvarnoj vrijednosti ili ne. Drugim riječima, osnovni cilj fundamentalne analize je pronaći odgovor na pitanje: „Hoće li sudionik na tržištu kapitala kupiti vrijednosni papir po cijeni p u trenutku t, što ujedno definira i ključne elemente fundamentalne analize: sudionika, cijenu, vrijeme i vrijednosnicu." [16]
U teoriji se fundamentalna analiza dijeli na opću i pojedinačnu. Općom ili globalnom analizom pokušava se utvrditi stanje na burzi, odnosno sekundarnom tržištu vrijednosnih papira, i u privredi uopće. Pokazatelji koji se prema tome uzimaju u obzir su, s jedne strane, društveni proizvod, nacionalni dohodak i sl., a s druge strane, količina novca u opticaju, odnosno novčana masa, likvidnost nacionalne privrede i eskontna stopa. U osnovi fundamentalna analiza se bazira na tzv. trostrukom konceptu: adekvatni i stabilni povrat, adekvatna i stabilna zarada te odgovarajuća imovina poduzeća. Ulaganja koja nisu u skladu sa ovim konceptom imaju karakter špekulacije i nisu predmet fundamentalne analize. Međutim kretanja na tržištu kapitala preusmjerila su fokus fundamentalne analize sa trostrukog koncepta na koncept analize zarada koja se zasniva na načelu aktualizacije očekivanih prihoda od dividendi dioničara te dobiti poduzeća. [17]

Fundamentalna analiza se može promatrati kao dio računovodstvenih istraživanja i obrnuto. Ova tvrdnja se zasniva na usporedbi seta informacija koje sadrže financijski izvještaji i seta

[16] Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split, str. 160.
[17] Prohaska, Z. (1996): Analiza vrijednosnih papira, Infoinvest, Zagreb, str. 77-87.

informacija inkorporiranih u tržišnoj vrijednosti. Kako je tržišna vrijednost sadašnja vrijednost diskontiranih očekivanih novčanih tokova, predviđanje budućih prihoda, troškova, zarada i novčanih tokova osnova je vrednovanja. Fundamentalna analiza zahtijeva korištenje informacija iz tekućih i povijesnih objavljenih financijskih izvještaja kako bi se u zavisnosti od industrije i makroekonomskih podataka utvrdila unutarnja vrijednost poduzeća.

Pojedinačna analiza je sinonim za izbor najatraktivnijih dionica tj. onih dionica koje obećavaju najvišu stopu povrata u budućnosti. Do takvih se dionica dolazi analizirajući „ex post, slabu i jaku stranu pojedinog poduzeća, odnosno dioničkog društva koje je emitiralo dionice. Pokazatelji koji se najčešće koriste za izbor najperspektivnijeg poduzeća su skup indikatora odnosno knjigovodstvenih podataka iz bilance promatranog poduzeća. Kod analize tj. izračuna pokazatelja fundamentalne analize koriste se sljedeći pokazatelji koji se dijele u šest grupa eksterni pokazatelji, pokazatelji profitabilnosti, pokazatelji pokrića, izvori sredstava, pokazatelji likvidnosti i pokazatelji zaduženosti. Eksterni pokazatelji su objašnjeni u dijelu rada modeli tržišne kapitalizacije.

Pokazatelji profitabilnosti izražavaju snagu zarade tvrtke, pokazuju ukupni efekt likvidnosti, upravljanja imovinom i dugom na mogućnost ostvarenja profita. Najčešće korišteni pokazatelji profitabilnosti su: bruto profitna marža, neto profitna marža, povrat na ukupnu imovinu i povrat na ukupni kapital.

$$\text{Bruto profitna marža} = \frac{\text{Prodaja} - \text{Troškovi za prodano}}{\text{Prodaja}} \qquad (18)$$

Ovaj pokazatelj odražava kako politiku cijena koju tvrtka provodi, tako i efikasnost proizvodnje, odnosno kontrolu troškova. Poželjna je što veća vrijednost pokazatelja.

$$\text{Neto profitna marža} = \frac{\text{Neto dobitak} - \text{Dividende prioritetnih dioničara}}{\text{Prodaja}} \qquad (19)$$

Neto profitna marža pokazuje kako menadžment kontrolira troškove, rashode i prihode pa se još i naziva pokazatelj efikasnosti menadžmenta. Poželjna što veća vrijednost pokazatelja.

Povrat na ukupnu imovinu (ROA) i povrat na vlastiti kapital (ROE), koji su objašnjeni u prethodnom dijelu rada, također spadaju u skupinu pokazatelja profitabilnosti.

S vrijednostima ovih pokazatelja valja biti oprezan jer prevelik pokazatelj znači da se drže premale količine sredstava nužnih za realizaciju prihoda, a premale da se previše likvidnih sredstava veže za sredstva koja se koriste za realizaciju prihoda. Iako je poželjno da je pokazatelj veći jer upućuje na to da jedinica aktive ili fiksne imovine stvara više od jedne jedinice prihoda.[18]

$$\text{Koeficijent obrtaja fiksne imovine} = \frac{\text{Prihod od prodaje}}{\text{Fiksna imovina}} \qquad (20)$$

$$\text{Koeficijent obrta ukupne imovine} = \frac{\text{Prihodi od prodaje}}{\text{Ukupna aktiva}} \qquad (21)$$

Također se promatra kretanje ukupne aktive kao i neto dobiti te kreditni potencijal koji čine četvrtu grupu pokazatelja.

Pokazatelji likvidnosti se koriste za procjenu tvrtke da udovolji kratkoročnim obvezama kratkotrajnom imovinom. Pokazatelji koji se najčešće koriste su pokazatelj tekuće i ubrzane likvidnosti.[19]

$$\text{Pokazatelj tekuće likividnosti} = \frac{\text{Kratkotrajna imovina}}{\text{Kratkotrajne obveze}} \qquad (22)$$

Najbolji je pojedinačni indikator likvidnosti. Standardna mjera ovog pokazatelja je da bude barem jednak 1, ali isto tako valja naglasiti da se pri razmatranju ovaj pokazatelj mora usporediti s industrijom.

[18] Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 58.
[19] Ibid, str. 61-62.

$$\text{Pokazatelj ubrzane likvidnosti} = \frac{\text{Tekuća imovina} - \text{Zalihe}}{\text{Kratkoročne obveze}} \quad (23)$$

Koristi za procjenu da se vidi može li poduzeće udovoljiti svojim kratkoročnim obvezama upotrebom svoje najlikvidnije imovine. Ovaj pokazatelj bi trebao iznositi minimalno 1 ili više, ali isto tako valja naglasiti da se pri razmatranju ovaj pokazatelj mora usporediti s industrijom.

Pokazatelji zaduženosti koriste se za procjenu financijskog rizika tvrtke.[20]

$$\text{Omjer duga i glavnice} = \frac{\text{Ukupne obveze}}{\text{Glavnice}} * 100 \quad (24)$$

Pokazatelj nam pokazuje koliki udio sredstava su osigurali vjerovnici, odnosno daje informaciju o tome kontrolira li društvo svoje dugove, što je važno i za vjerovnike, ali i za dioničare. Poželjna vrijednost je 100.

$$\text{Omjer duga i imovine} = \frac{\text{Ukupne obveze}}{\text{Aktiva}} * 100 \quad (25)$$

Poželjna vrijednost vrijednost je 50%. Pokazuje koliki se dio aktive financira dugom.[21]

[20] Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 64-66.
[21] Ibid, str. 66-70.

2.5. Makroekonomski podaci

Poslovanje poduzeća ovisi o stanju cjelokupnog gospodarstva pa analitičar mora voditi računa o poslovnom okruženju u kojem djeluje poduzeće. U procjeni budućih rezultata poslovanja često ima smisla početi s širim ekonomskim okruženjem, ispitujući stanje cjelokupne domaće i međunarodne ekonomije. Stoga se nastoji procijeniti utjecaj vanjskog okruženja na djelatnost u kojoj se nalazi poduzeće.

2.5.1. Inflacija

Inflacija, opće povećanje cijena, smanjuje stvarnu vrijednost novca te posljedično reducira očekivanu količinu novaca u opticaju. Indeks cijena u Hrvatskoj izračunava se na temelju reprezentativne košarice koju čini oko 869 proizvoda. Svakog mjeseca prikuplja se oko 36.700 cijena na unaprijed definiranu uzorku prodajnih mjesta na devet geografskih lokacija.
Investitori koji posjeduju imovinu izloženi su promjenama u inflaciji te njihova plaćanja na kraju mjeseca ovise o inflaciji tijekom tog perioda. Slijedom toga, inflacija ima negativni utjecaj na cijenu dionice. Pritisak inflacije na cijene stvara opću nesigurnost i gubljenje vjere u budućnost, a smanjuje profite te cijene redovnih dionica. Jedan od primjera utjecaja inflacije: tzv. P/E se smatra indikatorom stupnja optimizma. Kada je nizak prevladava nesigurnost i nedostatak povjerenja. Kada je visok pokazuje povjerenje investitora u budućnost. Zajedno s ostvarivanjem pune zaposlenosti, održavanje niske stope inflacije je glavni ekonomski zadatak u većini država. Nominalna kamatna stopa je jednaka zbroju realne kamatne stope i stope inflacije. Realna kamatna stopa je neto stopa povrata koje se očekuju od investicije. Realna kamatna stopa, određenog datuma, izvodi se odbijanjem stope inflacije od nominalne kamatne stope.
Za istraživanje korišteni su podaci s Državnog zavoda za statistiku. [22] Mjesečne promjene inflacije dane su sljedećom formulom:

$$I_t = \log CPI_t - \log CPI_{t-1}, \qquad (26)$$

[22] http://www.dzs.hr, 12.09.2016

Gdje je :

I_t - mjesečna promjene inflacije,
CPI_t - je CPI u mjesecu t,
CPI_{t-1} - je CPI prethodnog mjeseca.

2.5.2. Industrijska proizvodnja, BDP i gospodarski rast

Pojedine studije dovede u vezu BDP i cijenu dionicu, odnosno prognostičke vrijednost BDP-a i cijena dionica. Nominalni bruto domaći proizvod, BDP, je ukupna vrijednost robe i usluga proizvedenih u gospodarstvu tokom određenog razdoblja. Bruto domaći proizvod je makroekonomski indikator koji pokazuje vrijednost finalnih dobara i usluga proizvedenih u zemlji tijekom dane godine, izraženo u novčanim jedinicama. BDP se izračunava kao tijek proizvodnje:

$$BDP = C + I + G + X, \quad (27)$$

Gdje je:

C = osobna potrošnja,
I = investicije,
G = državna potrošnja i
X = razlika izvoza i uvoza ili kao tijek prihoda odnosno troškova.

Želi li se izmjeriti gospodarska aktivnost neke zemlje, potrebno je izmjeriti koliko je robe i usluga proizvedeno u tom gospodarstvu u nekom razdoblju. To mjeri realni BDP. Realni BDP je koncipiran kao suma količine svih finalnih dobara puta njihove konstantne (stalne) cijene.

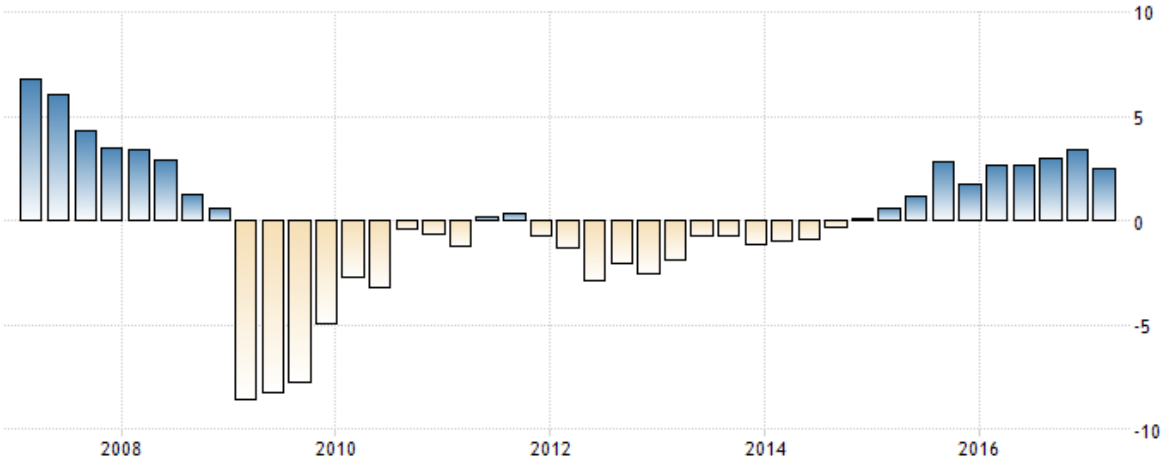
$$\text{Realni BDP} = \frac{\text{Nominalni BDP}}{\text{Razina cijene}} \quad (28)$$

Pod gospodarskim rastom se podrazumijeva porast proizvodnje, proizvodnih kapaciteta i svih drugih sastavnica jednog gospodarstva. Ekonomski rast je porast ukupnog outputa gospodarstva. Do rasta gospodarstva dolazi zbog rasta radne snage ili kapitalnih dobara,

tehnologije i proizvodnosti po radniku. U radu je korištena kvartalna stopa gospodarskog rasta pomoću formule:

$$\text{Stopa rasta BDP } Q_t = \frac{(\text{BDP Qt} - \text{BDP Qt}-1)}{\text{BDP Qt}-1} * 100 \qquad (29)$$

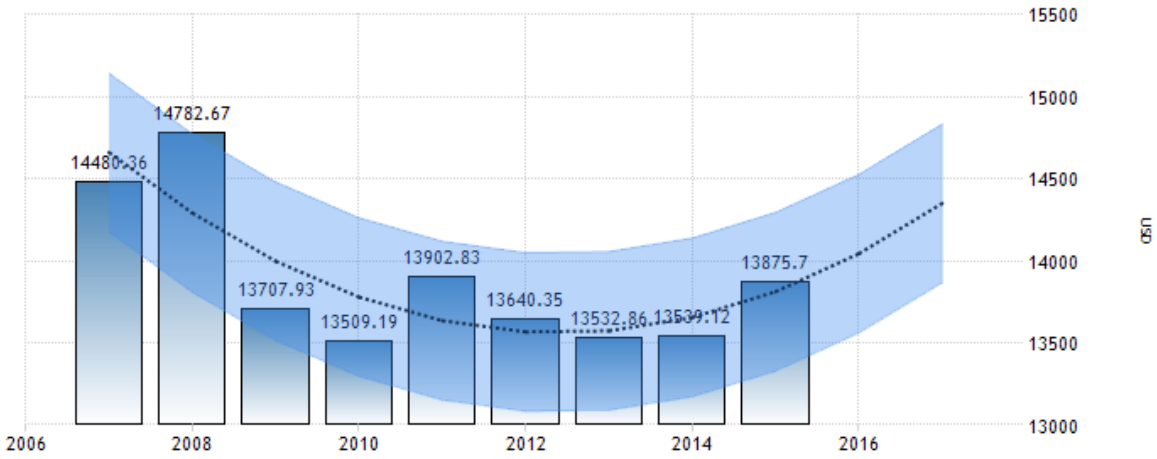
Slika 1. Stope rasta BDP-a u Hrvatskoj



Izvor. dzs.hr, 01.06.2017.

Iz prethodne slike se vidi da su stope rasta BDP-a bile negativne od 2009 do 2015 godine s iznimkom od dva kvartala u 2011 godini. U prvom kvartalu 2015 godine stopa rasta BDP-a je pozitivna te je iznosila 1,1%. Nakon svjetske financijske krize hrvatsko gospodarstvo još nije doseglo razinu iz 2007 godine.

Slika 2. Stvarni i očekivani BDP po stanovniku za razdoblje od 2006 do 2016 godine



Izvor: tradingeconomics.com, World Bank

Prethodna slika pokazuje stvarne i očekivane vrijednosti BDP-a po stanovniku u Hrvatskoj gdje je najveća vrijednost zabilježena u 2008 godini, 12.782,67 USD nakon čega se njegova vrijednost smanjuje s iznimkom u 2011 godini. Njegova prognostička vrijednost se postepeno smanjuje od 2007 godine te u 2012 godini nalazi se na svojoj najnižoj vrijednosti koja kasnije nastavlja svoj eksponencijalni rast.

Zajedno s bruto domaćim proizvodom (BDP), industrijska proizvodnja je najraširenija mjera ekonomske aktivnosti. S obzirom da se BDP izračunava i objavljuje kvartalno, industrijska proizvodnja je prikladnija mjera ekonomske aktivnosti s obzirom da su podaci o industrijskoj prozvodnji dostupni na mjesečnoj bazi. Indeks industrijske proizvodnje razlikuje se od BDP, koji mjeri kvartalne serije tržišnih vrijednosti dobara i usluga, te mjeri:

- outpute u fizičkim jedinicama te
- inpute upotrebljene za industrijske procese.

Zbog razlike u definiciji BDP i indeksa industrijske proizvodnje njihove vrijednosti nisu jednake.

Podaci o industrijskoj proizvodnju za potrebe ovog istraživanja su uzeti s EUROSTAT-a koristeći sljedeću formulu za analizu mjesečne promjene industrijske proizvodnje: [23]

$$AIP_t = \log IP_t - \log IP_{t-1}, \qquad (30)$$

Gdje je:

AIP_t – mjesečna promjena industrijske proizvodnje u mjesecu t,
IP_t - industrijski indeks proizvodnje u mjesecu t,
IP_{t-1} - je industrijski indeks proizvodnje u prethodnom mjesecu.

2.5.3. Kamatna stopa

Kamata je naknada u novcu za posuđena sredstva koje zajmoprimac plaća zajmodavcu. Kamatna stopa se pak izražava u postotku i smatra se cijenom novca ili kapitala koju zajmoprimac ili dužnik plaća zajmodavcu ili banci za privremeno korištenje ustupljenog novca ili kapitala. Visoka kamatna stopa dovodi do smanjenja buduće novčane mase u opticaju te smanjuje atraktivnost ulaganja. Stoga, prema ekonomskoj teoriji, povećanje kamatne stope dovodi do smanjenje u cijena dionica. Zbog toga je za svakoga ulagača iznimno važno točno predviđanje kamatnih stopa kako bi se imovina mogla alocirati na najbolji mogući način. Fundamentalni faktori koji određuju razinu kamatnih stopa dobro su poznati: štednja (prvenstveno stanovništva), potražnja poduzeća za sredstvima radi ulaganja u materijalnu imovinu (tvornice, postrojenja, zalihe), ponuda i potražnja za sredstvima od države (koja se određuje mjerama središnje banke) te očekivana stopa inflacije. Pri tome visoka eskontna stopa centralne banke ima, kao temeljna kamatna stopa u sklopu mjera monetarne politike, dvostruko djelovanje na burzu, a time i na dionice. Visoka eskontna stopa uvjetuje visoke kamatne stope na tržištu kapitala i ima za posljedicu preorijentaciju ulaganja, posebno velikih financijskih institucija od dionica, dakle vrijednosnih papira s varijabilnim prihodom k vrijednosnim papirima s fiksnim prihodom, tj. obveznicama. Tako, s jedne strane, povećanje ponude dionica na tržištu kapitala dovodi do pada njihovih tečajeva, a s druge strane, sve skuplji krediti povećavaju troškove

[23] http://ec.europa.eu/eurostat/web/short-term-business-statistics/methodology, 12.09.2016

poslovanja i smanjuju očekivanu dobit poduzeća koje kotiraju na burzi. To može zbog prodaje dionica i preorijentacije na druge vidove ulaganja dovesti do daljnjeg pada dotičnih tečajeva dionica na tržištu.

ZIBOR kamatne stope su jedinstvene kamatne referentne stope na hrvatskom međubankarskom tržištu. Službeni izračun ZIBOR-a po dospijećima provodi se temeljem izračuna prosječnih vrijednosti kamatnih stopa 8 najvećih hrvatskih banaka iskotiranih na Reuters sustavu dnevno točno u 11.00 sati. Službeni izračun ZIBOR-a vrši se na temelju istaknutih kotacija referentnih banaka za ponudbene i potražne kamatne stope (izračunate na bazi 360 dana u godini proporcionalnom metodom) za kunska sredstva prema ostalim referentnim bankama. Banke kotiraju svoje vrijednosti na dvije decimale svakoga radnog dana uz izuzetak subota, nedjelja i državnih blagdana. Način izračunavanja prosjeka je sljedeći: izuzimaju se najviša i najniža kamatna stopa na taj dan po određenom dospijeću. Od sume preostalih kamatnih stopa izračunava se aritmetička sredina, koja predstavlja referentnu kamatnu stopu za određeno dospijeće.

Kamatna stopa korištena u ovom radu je tromjesečna ZIBOR (Zagreb Interbank Offered Rates), referentna kamatna stopa u hrvatskom međubankarskom tržištu. Službena kalkulacija ZIBOR-a svakodnevno se obavljuje na Reuters system kao aritmetička sredina kamatnih stopa osam najvećih hrvatskih banaka. Mjesečna kamatna stopa računa se pomoću prosjeka dnevnih kamatnih stopa:

IR_t = 3-month ZIBOR u mjesecu t. [24] (31)

2.5.4. Tržišni indeks cijena dionica

Smatra se kako makroekonomske varijable ne obuhvaćaju sve raspoložive informacije o tržištu kapitala dok cijene dionica brzo reagiraju na obavljene informacije. Slijedom toga, preporučava se da model ne sadrži samo makroekonomske varijable već i financijske varijable pojedinog tržišta.

Tržišni indeks korišten za potrebe ovog istraživanja je CROBEX, službeni indeks Zagrebačke burze, koji sadrži 25 dionica. Mjesečni tržišni indeks izračunat je prema sljedećoj formuli:

$$MI_t = \log CROBEX_t - \log CROBEX_{t-1}, \quad (32)$$

[24] http://reuters.hr/tr/hr/index.action,13.09.2016.

Gdje je:

MI_t - mjesečna promjena tržišnog indeksa u mjesecu t,
$CROBEX_t$ - tržišni indeks u mjesecu t i
$CROBEX_{t-1}$ - tržišni indeks prethodnog mjeseca. [25]

Prilikom odabira dionica koje će ući u sastav indeksa CROBEX, u obzir se uzimaju samo dionice uvrštene na uređeno tržište kojima se trgovalo više od 90% ukupnog broja trgovinskih dana u šestomjesečnom razdoblju koje prethodi reviziji.
Indeks CROBEX se računa kao omjer free float tržišne kapitalizacije i free float tržišne kapitalizacije na bazni datum. Free float tržišna kapitalizacija određene dionice računa se kao umnožak broja izdanih dionica, free float faktora i zadnje cijene dionice. Udjel free float tržišne kapitalizacije pojedine dionice u ukupnoj tržišnoj kapitalizaciji indeksa CROBEX, na dan redovne revizije, ne može preći 15%.
Indeks se računa kontinuirano tijekom trgovine prema sljedećoj formuli:

$$I_t^j = \frac{\sum p_{i,t}^{j} * q_{i,T} * f_{i,T}}{K_T * \sum p_{i,t}^{j} * q_{i,T} * f_{i,T}} * B \qquad (33)$$

Gdje je:

I_t^j - vrijednost indeksa CROBEX na dan t i vrijeme j,
$p_{i,t}^{j}$ - zadnja cijena dionica i na dan t i vrijeme j,
$q_{i,T}$ - broj izdanih dionica i ili njihov dio na dan revizije T,
$f_{i,T}$ - free float faktor dionica i na zadnji dan mjeseca koji prethodi danu revizije T,
B bazna vrijednost indeksa, iznosi 1000 na dan 1. srpnja 1997,

$p_{i,T}$ - zadnja cijena dionica i na bazni datum ili na dan koji prethodi uključenju u indeks CROBEX (u slučaju da su uključene kasnije) i

K_T - koeficijent prilagođavanja baze indeksa na dan revizije T.

[25] Benaković, D., Posedel P. (2010): Do macroeconomic factors matter for stock returns? Evidence from estimating a multifactor model on the Croatian market", Business Systems Research, Vol.01, No.1-2, 1-50., str. 4-13.

Do prilagođavanja baze indeksa CROBEX dolazi u slučaju uključivanja novih dionica u indeks, odnosno isključivanja postojećih dionica iz indeksa, promjene free float faktora te zbog promjene broja izdanih dionica koje ulaze u sastav indeksa, čime se osigurava vremenska usporedivost indeksa. Koeficijent prilagođavanja baze indeksa CROBEX računa se na sljedeći način:

$$K_{T+1} = K_t * \frac{I(T')}{I(T)} \qquad (34)$$

Gdje je:

I(T') - vrijednost indeksa CROBEX nakon promjene na dan T,
I(T) - vrijednost indeksa CROBEX prije promjene na dan T te
T - dan revizije.[26]

Većina prethodnih istraživanja povezanosti financijskog i gospodarskog sektora odnosila se na utvrđivanje veze između performansi tržišta kapitala i makroekonomskih varijabli u razvijenim zemljama. Fama i French (1989),[27] te Chen, Roll i Ross (1986)[28] istražujući tržište kapitala SAD-a utvrdili su da postoji pozitivna povezanost tržišnih cijena dionica s rastom proizvodnje i odabranim financijskim varijablama, a negativna povezanost s inflacijom i porastom novčane mase. Bodurtha, Cho i Senbet (1989)[29] proširili su rad od Chena, Roll i Rossa uključujući međunarodne faktore, međutim jedino industrijska proizvodnja se pokazala signifikantnom. Ipak uključujući međunarodne varijable (rast industrijske proizvodnje u ostatku svijeta ili cijena nafte) domaće makroekonomske varijable pokazale su veću signifikantnost. McEloroy i Burmeister (1991)[30] uključili su četiri makroekonmske varijable (riskatne premije, neočekivanu deflaciju, neočekivani rast prodaje te ostale tržišne faktore) u multivarijantni nelinerani regresijski model gdje su se sve varijable pokazale signifikantnima u objašnjavanju povrata

[26] Zagrebačka burza d.d. (2013), Odluka br. 393 o indeksu CROBEX, http://zse.hr/UserDocsImages/dokumenti_indeksi/CROBEX_20130823153518-2013-08-Odluka-o-indeksu-CROBEX.pdf
[27] Fama, E.F., French K.R (1989): Business Conditions and Expected Returns on Stocks and Bonds, Journal of Financial Economics 25, str. 23-49.
[28] Chen, N., Roll R. i Ross S. (1986): Economic Forces and the Stock Market, The Journal of Business. Vol. 59, No. 3, str. 383-403.
[29] Bodurtha, Jr., Cho, J. i Senbet, W. (1989): Economic forces and the stock market: An international perspective, Global Finance Journal Vol. 1, str. 21-46.
[30] Burmeister, E. i McElroy, M.B. (1991): The residual market factor, the APT, and mean-variance efficiency, Review of Quantitative Finance and Accounting, Vol. 1, str. 27-49.

dionica. Abdullah i Hayworth (1993)[31] utvrdili su upravo suprotno da prinosi američkih dionica pokazuju pozitivnu korelaciju s inflacijom i porastom novčane mase, a negativnu s trgovinskim deficitom, proračunskim deficitom, te kratkoročnim i dugoročnim kamatnim stopama. Dalje, istražujući američko tržište kapitala, Ratanapakorn i Sharma (2007)[32] utvrđuju da na burzovni indeks S&P 500 pozitivan utjecaj ima industrijska proizvodnja, stopa inflacije, ponuda novca, stopa prinosa državnih blagajničkih zapisa i tečaj japanskog jena prema US dolaru, dok stopa prinosa državnih obveznica ima negativan utjecaj. Nadalje, Humpe i Macmillan (2009)[33] utvrđuju da će na porast cijena američkih dionica utjecaj imati porast industrijske proizvodnje, smanjenje indeksa potrošačkih cijena i smanjenje dugoročne kamatne stope.

Benaković i Posedel (2010)[34] uključuju pet makroekonomski faktora u višestruku regresiju na primjeru Hrvatske iz koje proizlazi signifikantan utjecaj kamatne stope, cijena nafte i industrijske proizvodnje na 16 odabranih dionica CROBEX-a u razdoblju od 2004 do 2008 godine. Ivanov i Lovrinović (2008)[35] dokazuju kako CROBEX negativno utječe na ponudu novca, kamatnu stopu te alocirane rezerve. Hsing (2011) zaključuje kako je hrvatski burzovni indeks pozitivno povezan s realnim BDP-om, omjerom M1/BDP, njemačkim burzovnim indeksom i prinosom državnih obveznica, dok negativno na njega utječe omjer državnog deficita i BDP-a, domaća stvarna kamatna stopa, tečaj HRK/USD i očekivana stopa inflacije.

Temeljem prethodnih istraživanja može se definirati ekonometrijski model sljedećom jednadžbom:

$$P_{i,t} = \alpha_i + \beta_{i,1}F1_{,t} + \beta_{i,2}F2_{,t} + \ldots \beta_{i,k}F_{k,t} + \varepsilon_{i,t}\,, \qquad (35)$$

[31] Abdullah, D.A. i Hayworth, S.C. (1993): Macroeconomics of Stock Price Fluctuations. Quarterly Journal of Business and Economics, Vol. 32, str. 50-67.
[32] Ratanapakorn, O. i Sharma, S. C. (2007): Dynamics analysis between the US Stock Return and the Macroeconomics Variables, Applied Financial Economics, Vol. 17, str. 369-377.
[33] Humpe, A. i Macmillian, P. (2009): Can macroeconomic variables explain long-term stock market movements? A comparison of the US and Japan, Applied Financial Economics, Vol. 19, str. 111-119.
[34] Benaković, D., Posedel P. (2010): Do macroeconomic factors matter for stock returns? Evidence from estimating a multifactor model on the Croatian market, Business Systems Research, Vol.01, No.1-2, 1-50., str. 4-13.
[35] Ivanov, M. i Lovrinović, I (2008): Monetary transmission mechanism and behaviour of asset prices: The case of Croatia, Review of Business Research, March 2008., str. 1-17.

Gdje je:

P_i - cijena dionica,

α_i - konstanta,

β_i - osjetljivost dionica *i* na skup makroekonomskih varijabli *k,*

F_n - ekonomski faktori, $n=1,2...,k$

ε_i - slučajna greška kada je očekivana vrijednost jednaka nuli.

3. TEORIJE ULOGE INFORMACIJA PRI VREDNOVANJU DIONICA

U ovom dijelu rada opisati će se teorija efikasnog tržišta odnosno teorija informacijske efikasnosti koju je definirao Fama (1970). Detaljnije će se opisati oblici hipoteze efikasnog tržišta (hipoteza racionalnih očekivanja, hipoteza martingnala, hipoteza slučajnog hoda). Zatim će detaljno biti objašnjena Markowitzeva teorija suvremenog upravljanja portfeljom, nakon koje sljedi njezina nadogradnja, odnosno CAPM model.

3.1. Teorija efikasnog tržišta (teorija informacijske efikasnosti)

Ideja da tržišta dobro rade svoj posao tako da cijene vrijednosnica pravedno održavaju sve dostupne informacije, naziva se hipotezom o efikasnom tržištu.
Tržište kapitala smatra se efkasnim ukoliko cijene dionica odražavaju sve dostupne informacije zbog čega sudionici efkasnih tržišta nemaju mogućnost ostvariti iznadprosječne prinose koristeći tehničku analizu. Ideja o efkasnim tržištima se odnosi na informacijsku efkasnost tržišta i počiva na hipotezi efkasnih tržišta koju je oblikovao Fama (1970). Osnovne postavke ovoga koncepta su:

- Investitor ili kupac dionica ponaša se racionalno i opredjeljuje se za onu investiciju kod koje postoji balansirani odnos između prinosa i rizika.

- Odluka o investiciji temelji se na relevatnim informacijama o tekućoj vrijednosti i cijeni aktive.

- Promjenama koje će nastupiti u vrijednosti i cijenama u narednome periodu.

- Svaka nova relevatna informacija dovodi do brzih promjena u cijenama vrijednosnica i dionica.

Treba napomenuti da je Roberts (1967)[36] uveo termin hipoteze efikasnog tržišta. On je ujedno utvrdio razliku između testova slabe i jake tržišne efikasnosti koji su postali standardna sredstva u daljnjem radu Eugenea Fame. Potonji je ekonomist u svojim radovima dao pregled teorije i empirijskih dokaza tržišne efikasnosti. Također, definirao je efikasno tržište, kao i oblike tržišne efikasnosti te pružio snažne dokaze u korist slabog oblika tržišne efikasnosti.

[36] Roberts, H. (1967): Statistical versus Clinical Prediction in the Stock Market, unpublished manuscript, Center for Research in Security Prices, University of Chicago.

Prema Fami razlikuju se tri razine informacijske efkasnosti: slaba, polujaka i jaka. Testovi koji ispituju slabi oblik efkasnosti tržišta kapitala analiziraju povijesne cijene. Testiranje jačih oblika efkasnosti podrazumijeva ispitivanje i svih javno dostupnih informacija (polu-jaki oblik), kao i informacija koje su dostupne isključivo odabranim pojedincima (jaki oblik).[37]

Slabi oblik efikasnosti tržišta implicira da nijedan sudionik na tržištu nije u mogućnosti ostvariti iznadprosječne prinose u kratkom roku trgujući na osnovi povijesnih cijena. Ovaj oblik hipoteze efikasnog tržišta pobija mogućnost pobjeđivanja tržišta korištenjem tehničke analize. Kod polujakog oblika efikasnosti pretpostavka je da investitori ne mogu ostvariti iznadprosječne prinose koristeći javno dostupne informacije. U slučaju najjačeg oblika efikasnog tržišta, investitor ne može ostvariti iznadprosječne doprinose čak i ako posjeduju privilegirane informacije. Slabo efikasna tržišta su tržišta na kojima cijene dionica reflektiraju informacije o stanju ponude i potražnje na tržištima kapitala - najčešće burzama. Tržište je efikasno u odnosu na određeni informacijski skup ukoliko otkrivanje tog informacijskog skupa svim sudionicima tržišta ne dovodi do promjene cijena vrijednosnica. Nadalje, efikasnost u odnosu na informacijski skup ukazuje na nemogućnost ostvarivanja ekonomskih zarada od trgovanja na osnovi informacijskog skupa.[38]

Samoregulirajuća efikasna tržišta su tržišta na kojima cijena dionica reflektira ne samo informacije o stanju ponude i potražnje na tržištu, već i informacije o poslovanju i razvoju emitenta.

Visoko efikasna tržišta su tržišta na kojima cijene dionica reflektiraju: tržišne informacije, informacije o emitentu dionica i informacije o stanju i promjenama u ekonomskom, političkom i društvenom okruženju emitenata dionica i konkretnih tržišta vrijednosnica.

Čvršći stav o efikasnosti tržišta ima nekoliko važnih implikacija u akademskom području financija. Prvenstveno, da je efikasnom tržištu kapitala, svaka intervencija jednako dobra, budući da su cijene svih vrijednosnica točne. Kao drugo implicira da cijena određene dionice odražava sve dostupne podatke o fundamentalnoj vrijednosti vrijednosnice. Treće, implicira da cijene vrijednosnica mogu koristiti menadžeri financijskih i ne financijskih tvrtki da bi točno odredili svoj trošak kapitala (trošak financiranja svojih ulaganja) i da se s toga cijena

[37] Fama, E. F. (1970) Efacient Capital Markets: A Review of Theory and Empirical Work, Journal of Finance, str. 383 – 417.

[38] Malkiel, Burton G. (1992): Efficient Market Hypothesis, New Palgrave Dictionary of Money and Finance, str. 739-744.

vrijednosnica može koristiti da im pomogne donijeti ispravne odluke je li određena investicija vrijedna ili ne. Jača verzija efikasnosti tržišta je osnovna postavka većine analiza u financijskom području. [39]

3.1.1. Hipoteza racionalnih očekivanja

Muth (1961)[40], osnivač doktrine racionalnih očekivanja, ističe da se racionalnost očekivanja može osigurati ukoliko očekivanja su konzistetna s modelima kojima se objašnjava ponašanje ekonomskih subjakta na tržištu. Drugim riječima, očekivanja su racionalna ukoliko se uz zadani ekonomski model formiraju stvarne vrijednosti varijabli koje će u prosjeku odgovarati modelu. Isti autor ističe primjenjivost teorije racionalnih očekivanja na financijskom tržištu zbog arbitraže koja se odvija nesmetano i bez popratnih troškova, omogućujući da ukupno tržište reagira racionalno unatoč tome što su pojedini investitori pasivni.
Elementi racionalnih očekivanja sastavni su dijelovi hipoteze efikasnog tržišta te se izražavaju sljedećim jednadžbama:

$$P_{t+1} = E_t P_{t+1} + \varepsilon_{t+1} \qquad (36)$$

$$E_t(P_{t+1} - E_t P_{t+1}) = E_t \varepsilon_{t+1} = 0 \qquad (37)$$

Gdje je:

P_{t+1} - cijena dionice u vremenu t+1,

E_t - očekivana vrijednost,

ε_{t+1} - prognostička pogreška.

U skladu s racionalnim očekivanjima, prognostička pogreška u prosjeku je jednaka nuli i nije u korelaciji s informacijama koje su dostupne u trenutku prognoziranja. Hipoteza efikasnog tržišta podrazumijeva da su neočekivani prinosi u prosjeku jednaki nuli.[41]

---

[39] Stanivuk, T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktorska disertacija, Sveučilište u Splitu, str. 53.
[40] Muth. J. (1961): Rational Expectations and the Theory of Price Movements, The Econometric Society, Vol. 29. No.3.
[41] Barbić, T. (2010): Pregled razvoja hipoteze efikasnog tržišta, Znanstveni rad, Privredna kretanja i ekonomska politika, str. 124.

3.1.2. Model martingala

Model martingala predstavlja najranije pokušaje modeliranja prinosa na financijskim tržištima te svoje korijene vuče iz igara na sreću i začetaka teorije vjerojatnosti. U osnovi modela je ideja korektne igre (fair play) koja ne donosi posebnu korist nijednom sudioniku igre. Takav stohastični proces može se opisati sljedećom jednadžbom:

$$E(P_{t+1}, P_t, P_{t-1}) = P_t \qquad (38)$$

Gdje je:

P_{t+1} - cijena dionice u vremenu t+1,

E_t - očekivana vrijednost.

Ukoliko se pretpostavi da P_t predstavlja kumulativne dobitke ili bogatstvo ostvareno u vremenu t od igara na sreću, tada korektnom igrom smatramo onu koja u sljedećem razdoblju rezultira dobitkom jednakim onom iz prethodnog razdoblja. Drugim riječima, igra je korektna ukoliko je očekivani inkrementalni dobitak, uzimajući u obzir povijest same igre, u svakoj fazi jednak nuli.[42]

Kada se ova terminologija prilagodi rječniku financijskog tržišta, model martingala upućuje na jednakost sutrašnje cijene dionica onoj prethodnoj, uzimajući u obzir prethodne cijene vrijednosnih papira.

3.1.3. Hipoteza slučajnog hoda (RW modeli)

Slučajan hod je onaj kod kojeg se sljedeći korak ili smjer ne može predvidjeti na osnovi prethodnih aktivnosti. Kada se termin prenese na primjer financijskog tržišta, možemo zaključiti nemogućnost predviđanja kratkoročnih promjena cijena vrijednosnica na temelju cijena iz

[42] Campbell, J., Lo, A. i MacKinlay, A. (1996): The Econometrics of Financial Markets, Princeton University Press, str. 45-78.

prethodnog razdoblja. Buduća kretanja cijena vrijednosnica su predvidljiva kao i kretanje slučajnih brojeva. Dakle, ukoliko su tržišta efikasna, ne postoji mogućnost da investitori iskoriste informaciju kako bi ostvarili višak prinosa tokom neprekidnog vremenskog perioda. „Višak" označava nivo iznad ekvilibrijuma ili zahtijevane stope prinosa, bez obzira na način determiniranja.

Kod hipoteze slučajnog hoda, tržište je efikasno ukoliko tekuća cijena dionica sadrži sve dostupne informacije te da dolazi do promjene cijene vrijednosnica ukoliko se pojave nove informacije na tržištu. S obzirom da su te informacije međusobno nepovezane, promjene cijene dionica su neovisne.

Verzija hipoteza slučajnog hoda je (RWI) je najjednostavnija jer su progreške neovisne i slučajno distribuirane u kojem se kretanje cijene dionica P_t objašnjeno sljedećom jednaždbom:

$$P_t = \mu + P_{t-1} + \varepsilon_t \approx IID\ (0,\sigma^2) \qquad (39)$$

Gdje je:

μ - očekivana promjena cijene dionice,

ID $(0,\sigma^2)$ - slučajna pogreška ε_t neovisna i identično distribuirana s očekivanom vrijednošću 0 i varijancom σ^2.[43]

Nešto složenija i realnija verzija hipoteze slučajnog hoda pretpostavlja da su slučajne pogreške neovisne, ali ne i identično distribuirane (RW2). Naime, pretpostavka o identičnoj distribuciji slučajnih pogrešaka neodrživa je za cijene financijske imovine u dužem vremenskom razdoblju. Takva izmijenjena varijanta koja dozvoljava heteroskedastičnost slabija je u odnosu na početne pretpostavke. Najopćenitija varijanta hipoteze slučajnog hoda (RW3) obuhvaća procese s ovisnim i nekoreliranim slučajnim pogreškama. To je ujedno najslabiji i najčešće testirani oblik hipoteze slučajnog hoda u novijoj empirijskoj literaturi.

[43] Campbell, J., Lo, A. i MacKinlay, A. (1996): The Econometrics of Financial Markets, Princeton University Press, 1996., str. 167-189.

Tablica 1. Testiranje varijanti hipoteze slučajnog hoda

Varijanta RW	Predmet ispitivanja	Testovi	Provedena istraživanja
RW1	Slučajni hod	Statistički testovi slijedovi, obrade i runs tesstovi	Cowles i Jones (1937) Fama (1965)
RW2	Interes investitora	Pravila filtra Tehnička analiza	Alexander (1961) Fama (1965) Fama i Blume (1966)
RW3	Serijska korelacija	Autokorelacija Portmanteau Statistika	Lo i MacKinlay (1988) Box i Pierce (1870) Ljung i Bix (1978)

Izvor: Barbić, T. Pregled razvoja hipoteze efikasnog tržišta, Privredna kretanja i ekonomska politika 124, 2010, str. 38.

RW1 je nerealan, prvenstveno teorijski koncept. Za njegovo testiranje koriste se tradicionalni statistički testovi. S obzirom na to da je riječ o varijanti hipoteze slučajnog hoda s neovisnim i identično distribuiranim slučajnim pogreškama, većina testova spada u neparametarske i poluparametarske testove. Testiranje varijante RW2 predstavlja izazov istraživačima s obzirom na to da je ispitivanje neovisnosti vremenskih serija izuzetno otežano neuvažavanjem pretpostavke o identičnoj distribuciji slučajnih pogrešaka. RW3 se ispituje testirajući nultu hipotezu da su autokorelacijski koeficijenti prvih diferencija različitih pomaka jednaki nuli.[44]

Dokazi koji govore u korist efikasnosti tržišta temeljili su se na ispitivanju uspješnosti analitičara i fondova. Odnosno, istraživanju održavaju li cijene javnosti dostupne informacije, usporedbi ponašanja cijena dionica s modelom slučajnog hoda te na analizi uspješnosti takozvane tehničke analize.[45]

1. *Uspješnost investicijskih analitičara i investicijskih fondova.* Smatra se da je jedna posljedica hipoteze o efikasnom tržištu kako se ne može očekivati izuzetno visoka zarada, veća od ravnotežnog povratka kada se kupuje vrijednosnica. Mnoge studije su razjasnile pobjeđuju li savjetnici za ulaganje i investicijski fondovi (od kojih neki naplaćuju visoke ulazne naknade osobama koje kupuju udjele) tržište. Međutim, to što ima sreće ne znači da prognozer u

[44] Barbić, T. (2010): Pregled razvoja hipoteze efikasnog tržišta, Privredna kretanja i ekonomska politika, str. 124.

[45] Stanivuk, T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktorska disertacija, Sveučilište u Splitu, str. 77-82.

stvarnosti ima sposobnost da pobijedi tržište. U skladu s hipotezom o efikasnom tržištu, investicijski fondovi se također ne ističu pobjedama nad tržištem. Ne samo da ne nadmašuju tržište u prosjeku, nego kada su razdvojeni u grupe prema najvišoj ili najnižoj dobiti u odabranom razdoblju, fondovi koji su dobro poslovali u prvom razdoblju u drugom ne pobjeđuju tržište.

2. *Održavaju li cijene dionica javnosti dostupne informacije.* Rani empirijski dokazi su također potvrdili vezu iz hipoteze o efikasnom tržištu: povoljne objave o zaradi ili objave dijeljenja (cijepanja) dionica (cijepanje dionica na manje dijelove, nakon čega često slijede veće zarade) u prosjeku ne uzrokuje porast cijena dionica.

3. *Slučajni hod cijena dionica.* Pojam slučajnog hoda opisuje kretanja varijable kojoj se buduće promjene ne mogu predvidjeti, jer varijabla može pasti jednako kao što može i porasti u odnosu na trenutnu vrijednost. Financijski ekonomisti su koristili dva tipa testova da bi istražili hipotezu prate li cijene dionica slučajni hod. Isprva su ispitivali arhive tržišta dionica da vide jesu li cijene dionica sustavno povezane s prošlim promjenama i mogu li se na temelju njih predvidjeti.

4. *Tehnička analiza.* Hipoteza o efikasnom tržištu sugerira da je tehnička analiza gubitak vremena. Najjednostavniji način da se razumije zašto je tako, jest korištenje rezultata slučajnog hoda, izvedenog iz hipoteze o efikasnom tržištu. Prema njemu prošlogodišnje cijene dionica ne mogu pomoći u predviđanju budućih promjena. Stoga tehnička analiza, koja se oslanja na takve podatke da bi proizvela prognoze, ne može uspješno predvidjeti promjene u cijeni dionica.

Provedena empirijska istraživanja oblika efikasnosti ponudila su različte rezultate ovisno o stupnju razvoja analiziranog tržišta i korištenim tehnikama analize. Solnik (1987)[46] je na uzorku od 234 dionice s 8 najvećih europskih tržišta potvrdio da su ista efikasna, ali manje od američkih tržišta. Hudson, Dempsey i Keasey[47] su analizirali prinose na tržištu kapitala Velike Britanije u razdoblju od 1936. do 1994. godine te su otkrili da modelirano pravilo trgovanja ima moć predviđanja razvoja na tržištu kapitala, ali korištenje istog ne ostvaruje iznadprosječne prinose.

[46] Solnik, B. (1987): Using Financial Prices to Test Exchange Rate Models: A Note, Journal of Finance, 42, 141-149.

[47] Hudson, R., Dempsey, M. i Keasey, K. (1996): A note on the weak form efficiency od capital markets: The application of simple technical trading rules to UK stock prices – 1935-1994, Journal of Banking & Finance, Vol. 20, str. 1121-1132.

Grossman i Stiglitz (1980)[48] dokazuju u svom radu da je nemoguće da tržište bude u potpunosti informacijski efikasno. Također LeRoy i Porter (1981)[49] odbacuju tržišnu efikasnost. Poterba i Summers (1988) dokazuju pozitivnu autokorelaciju prinosa unutar kraćeg vremenskog razdoblja te negativnu tijekom dužeg vremenskog razdoblja. Laffont i Maskin (1990)[50] dokazuju nepostojanost hipoteze efikasnog tržišta u slučaju nesavršene konkurencije. Lehmann (1990)[51] odbacuje hipotezu efikasnog tržišta. Rezultati studije koju su proveli Campbell, Andrew i Mackinlay (1997)[52] ne odbacuju hipotezu slučajnog hoda u slučaju tjednih prinosa na portfelj ponderiran na osnovi vrijednosti.

Nivet (1997) ispituje događanja na Varšavskoj burzi na temelju dnevnih i tjednih prinosa WIG indeksa za vremensko razdoblje od 1991 do 1994 godine, te na osnovi vrijednosti autokorelacijskih koeficijenata zaključuje da se hipoteza slučajnog hoda odbacuje. Worthington i Higgs su ispitali hipotezu slučajnog hoda na dnevnim prinosima sa 16 razvijenih (Austrija, Belgija, Danska, Finska, Francuska, Njemačka, Grčka, Irska, Italija, Nizozemska, Norveška, Portugal, Španjolska, Švedska, Švicarska i Velika Britanija) te 4 tržišta u razvoju (Češka, Mađarska, Poljska i Rusija). Slaba efikasnost potvrđena je na njemačkom, irskom, portugalskom, švedskom, britanskom i mađarskom tržištu. Malkiel (2003)[53] testira navode prijašnjih znanstvenika i njihove zaključke te pronalazi da su tržišta kapitala znatno efikasnija te znatno manje predvidljiva nego što znanstveni članci tvrde. Isti znanstvenik 2005 godine dokazuje da cijene dionica održavaju sve dostupne informacije.

Dadić (2009)[54] prvi put ispituje efikasnost hrvatskog tržišta te odbacuje hipotezu i slučajnom hodu prinosa na indekse iz uzorka. Barbić (2010)[55] na temelju indeksa CROBEX u razdoblju od 1997-2007 godine potvrđuje hipotezu slučanog hoda pomoću ADF testa jediničnih korijena te testa autokorelacije.

---

[48] Grossman, S. J. i Stiglitz, J. (1980): On the Impossibility of Informationally Efficient Markets, The American Economic Review, 70(3), str. 393-408.
[49] LeRoy, S. F. (1989): Efficient Capital Markets and Martingales, Journal of Economic Literature, 27(4), str. 1583-1621.
[50] Laffont, J. i Maskin, E. (1990): The Efficient Market Hypothesis and Insider Trading on the Stock Market, The Journal of Political Economy, 98(1), str. 70-93.
[51] Lehmann, B. (1990): Fads, Martingales, and Market Efficiency, Quarterly Journal of Economics, 105(1), str. 1-28.
[52] Campbell, J.Y., Andrew W. Lo i MacKinlaly A. (1997): The Econometrics of Financial Markets, Princeton, NJ: Princeton University Press.
[53] Malkiel, Burton G. (2003): The Efficient Market Hypothesis and Its Critics, Journal of Economic Perspectives, 17(1), str. 59-82.
[54] Dadić, T. (2009): Testiranje efikasnosti tržišta kapitala odabranih zemalja srednje i istočne Europe, magistarski rad, Zagreb: Ekonomski fakultet, Sveučilište u Zagrebu.
[55] Barbić, T. (2010): Pregled razvoja hipoteze efikasnog tržišta, Znanstveni rad, Privredna kretanja i ekonomska politika, str. 124-135.

3.2. Suvremena teorija upravljanja portfeljima

Portfelj je skup financijskih instrumenata različitih vrsta i karakteristika, odnosno skup investicija u više različitih oblika financijske aktive, najčešće različite vrijednosnice u posjedu individualnoga investitora ili institucije.

Nastanak suvremene financijske ekonomije vezuje se za ožujski broj Journal of Finance iz 1952 godine, u kojem je Harry Markowitz predstavio svoj rad "Portfolio Selection". Moderna teorija portfelja pomaže investitorima izabrati skup vrijednosnica koji daje što veću dobit portfelja uz željeni nivo rizika.

Markowitzev model koristi varijancu stope prinosa kao mjeru rizika uz nekoliko pretpostavki o ponašanju individualnoga investitora. Formula za računanje rizika portfelja ukazuje na važnost diverzifikacije investicija radi smanjenja nesistemskoga rizika, ali i na načine efikasne diverzifikacije. Nasuprot tome, koncept diverzifikacije ulaganja zasnovane na intuitivnoj percepciji investitora s ciljem smanjenja rizika, ima ozbiljan nedostatak: opadajuću efikasnost s povećanjem broja vrijednosnica koje ulaze u sastav portfelja.

U članku iz 1991 godine, Markowitz je iskazao tri najvažnije razlike između teorije portfelja, teorije poduzeća (Theory of the Firm) i teorije ponašanja potrošača (Theory of the Consumer Behaviour). Prvo, teorija portfelja se odnosi na investiture, a ne na potrošače i proizvođače. Drugo, teorija portfelja se bavi ekonomskim agentima koji djeluju u uvjetima neizvjesnosti. Naime, pri analizi optimalnog ponašanja investitora, neizvjesnost se ne može zanemariti, kao što je to slučaj s teorijom proizvođača (Theory of the Producer). Treće, teorija portfelja se može direktno primijeniti (posebno veliki institucijski investitori koji imaju na raspolaganju odgovarajuće resurse) i odnosi se na cijene, a ne na količinu ponuđenih proizvoda na tržištu. Markowitzev model ponašanja investitora služi portfelj investitorima za konstrukciju efikasne granice uzimajući u obzir trade-off između prinosa i rizika.[56]

Moderna teorija portfelja oslanja se na nekoliko pretpostavki koje predstavljaju simplifikacije koje su omogućile njezin razvoj. Model pretpostavlja sljedeće:

- Svi investitori imaju averziju prema riziku i nastoje maksimizirati očekivanu korisnost bogatstva na kraju vremenskoga perioda. Za dani nivo rizika investitor će, između više vrijednosnica, izabrati one s većim prinosom, i za dani nivo očekivanoga prinosa investitor će se, između više vrijednosnica, opredijeliti za one s manjim rizikom.

[56] Markowitz, H. M., Jun. (1991): Foundations of Portfolio Theory, The Journal of Finance 46, No.2, str. 469-477.

- U uvjetima postojanja neizvjesnosti, investitor s averzijom prema riziku, odluke o izboru dionica, tj. pronalaženje optimalnih udjela financijske aktive, donosi na osnovu očekivane funkcije korisnosti investicije. Investitor maksimizira očekivanu korisnost tijekom jednog perioda. Tada krivulja korisnosti investicije ima oblik određen padajućom marginalnom korisnosti koju generira investicija tijekom investicijskog perioda.
- Investitori se ponašaju racionalno birajući onaj portfelj iz skupa investicijskih mogućnosti kojim maksimiziraju svoju funkciju korisnosti. Investitor najprije pronalazi efikasni skup portfelja koji dominira nad drugim portfeljima iz skupa mogućih ulaganja u rizičnu financijsku aktivu. Zatim iz danoga skupa bira portfelj u skladu s individualnim preferencijama prema riziku. [57]

Rizik ulaganja u pojedinu vrijednosnicu izražavamo varijancom prinosa σ_i^2. Ako je $\sigma_i^2 = 0$, onda je vrijednosnica bezrizična. U protivnom, vrijednosnica je rizična. Varijanca je relativna mjera disperzije a predstavlja sumu ponderiranih kvadrata odstupanja mogućih povrata oko očekivane srednje vrijednosti:

$$\sigma_i^2 = \sum(R_i - R)^2 * p_i \qquad (39)$$

Gdje je:

σ_i^2 - varijanca,

R_i - moguća odstupanja oko srednje vrijednosti,

R - očekivana srednja vrijednost te

p_i - vjerojatnost nastupa određene vrijednosti. [58]

Koeficijent korelacije $p_{ij} = \frac{Cov_{i,j}}{\sigma_i \sigma_j}$ pokazuje korelaciju povrata na vrijednosnice i i j. To je standardizirana statistička mjera linearne veze između dvije varijable. Njegov raspon se može kretati u intervalu od -1 do +1, što govori o smjeru i intenzitetu povezanosti između varijabli.

[57] Stanivuk, T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktorska disertacija, Sveučilište u Splitu, str. 77-82.
[58] Tiković, S. (2005): Formiranje optimalnog portfelja hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Magistarski rad, Ljubljana, str. 7-8.

Pozitivan predznak koeficijenta ukazuje na pozitivnu korelaciju varijabli (varijable se kreću u istom smjeru) dok negativan predznak ukazuje na negativnu korelaciju (varijable se kreću u suprotnim smjerovima). Što je veza jača, koeficijent korelacije je bliži jednoj od ekstremnih vrijednosti. Koeficijent korelacije 0 pokazuje da su varijable nekorelirane. One ne pokazuju tendenciju zajedničkog variranja bilo linearno pozitivnog ili negativnog. Većina prinosa na dionice ima tendenciju zajedničkog kretanja, ali ne savršenog. Zbog toga je koeficijent korelacije između dviju dionica u pravilu pozitivan, ali manji od 1.[59]

Korisnost investicije – U (utility), odnosno funkciju preferencije bogatstva, možemo zapisati u sljedećem obliku:

$$U = W_o + R \cdot W_0 \qquad (38)$$

Gdje je:

W_0 – početna vrijednost bogatstva te

R – stopa prinosa početnog bogastva (koja se smatra slučajnom varijablom).

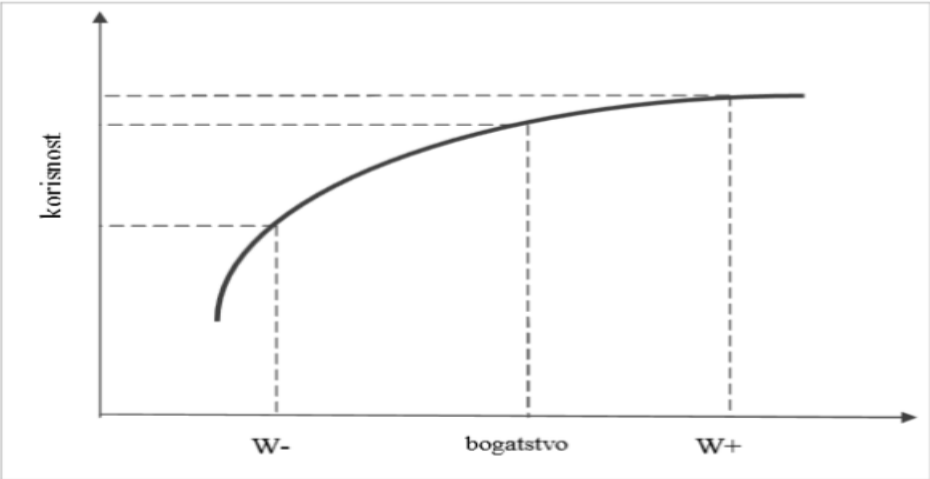
Pri izboru vrijednosnica u portfelj investitor će uvijek gledati korisnost koju ima od pojedine vrijednosnice. Korisnost za investitora je ostvareni prinos. Cilj je postići veći prinos uz preuzimanje manjeg rizika. Investitor će prednost dati onoj vrijednosnici koja za isti ili slični prinos nosi manji rizik.

Funkcija korisnosti $U_{(W)}$ trebala bi biti rastućeg oblika, odnosno investitor će u svakom slučaju izabrati situaciju u kojoj može ostvariti veći prinos naspram one u kojoj će ostvariti manji prinos uz pretpostavku da su opcije jednako vjerojatne.

Oblik funkcije korisnosti ovisi o sklonosti investitora prema riziku. Ukoliko investitor nije spreman preuzeti rizik tada u situaciji kada je vjerojatnost dobitka i vjerojatnost gubitka jednaka odnosno 50-50 on neće investirati. Funkcija korisnosti pojedinca koji izbjegava rizik izgleda na sljedeći način.

[59] Van Horne, J.C., Wachowich, J.M. (2012): Financijsko upravljanje i politika (financijski menadžment), deveto izdanje, Mate, Zagreb, str. 98-109.

Slika 3. Funkcija korisnosti investitora koji izbjegava rizik



Izvor: Tomić-Plazibat. N., Aljinović, Z. i Marasović B. (2006): Matematički modeli u financijskom upravljanju, Svučilište u Splitu, Ekonomski fakultet Split, str. 11.

Investitor će izabrati ulaganja koja maksimiziraju očekivanu vrijednost korisnosti bogatstva na kraju perioda. Budući da je svaki investitor različit, odnosno individualni investitori imaju različitu korisnost ulaganja, različitim investitorima su privlačne različite kombinacije prinosa i rizika. Takve kombinacije izbora prinosa i rizika predstavljaju krivulju indiferencije, a tako dobivenu funkciju zovemo funkcija korisnosti.

Kada su ishodi investicija neizvjesni, investitor maksimizira korisnost mogućih ishoda pomnoženih s vjerojatnosti pojavljivanja.

$$U = \sum W P_W \qquad (40)$$

Gdje je:

W - vrijednost ishoda ulaganja te

P_W - vjerovatnost ostvarenja željenog ishoda.

Moguće prihode investitor promatra u terminima vjerojatnosti te procjenjuje očekivanu vrijednost i standardnu devijaciju. Iz čega slijedi da korisnost investicije predstavlja funkciju prinosa i rizika.

$$U = f(E_W; \sigma_W) \qquad (41)$$

Gdje je:

E_W – očekivana vrijednost bogatstva u budućnosti te

σ_W – predviđeno prosječno odstupanje bogatstva u budućnosti od očekivane vrijednosti.

Pretpostavlja se da su investitori zainteresirani za veći iznos očekivanoga bogatstva u budućnosti, uz c.p.

$$dU / dE_W > 0$$

Investitori s averzijom prema riziku biraju investicije s nižom vrijednosti standardne devijacije za dani nivo očekivane vrijednosti bogatstva u budućnosti.

$$dU / d\sigma_W < 0$$

Navedene pretpostavke nam navješćuju pozitivan nagib krivulja indiferencije (Ew, σ_W). Moderna teorija portfelja otklonila je nedostatak naivne diverzifikacije, koja se manifestira opadanjem efikasnosti s povećanjem broja elemenata portfelja. Markowitz je ukazao na to da ukoliko želimo smanjiti varijancu, nije dovoljno samo investirati u više različitih vrijednosnica već je potrebno izbjeći ulaganje u vrijednosnice koje imaju visoku kovarijancu. Model ukazuje ne samo na važnost diverzifikacije investicija radi smanjenja ukupnoga rizika portfelja, već i na efikasni način izvođenja diverzifikacije.[60]

Kako bi ispitali pretpostavku o random walk kretanju cijena dionica (hipoteza slučajnog hoda), McQueen i Thorley (1991)[61] u svojem se radu koriste upravo Markovljevim lancima. Razmatrali su dulji period, od 1947. do 1987. godine za NYSE burzu i zaključili da godišnji realni prinosi ipak ne slijede njihovu hipotezu.

[60] Tomić, B. (2012): The application of the capital asset pricing model on the Croatian capital market, Effectus College for Law and Finance, str. 112.
[61] Mcqueen, G. i Thorley, S (1991): Are Stock Returns Predictable? A Test Using Markov Chains, The Journal of The American Finance Association, Vol. 46, str. 239-262.

Sundberg i Klacksell (2012)[62] u svojem radu rabe ovu metodu za predviđanje kretanja cijena na tržištu kapitala. U radu je dan i kod programa za takvo predviđanje koji je napisan koristeći program Matlab. Međutim, autori zaključuju kako je osim podataka o kretanju indeksa ili cijena dionica potrebno u analizu uključiti i podatke o dividendama, očekivanjima investitora, financijskim izvještajima, itd. Dai, Han i Dai (2014)[63] uspoređuju neuronske mreže i Markovljeve lance kao metode prognoziranja prinosa na kineskom tržištu i zaključuju kako su primjerene za prognoze.

Tomić-Plazibat, Aljinović i Marasović (2006)[64] dale su teorijski prikaz Markowitzevog modela optimizacije portfelja i njegovu primjenu na hrvatskom tržištu kapitala, kao i što su Aljinović, Marasović i Šego (2008, 2011)[65] prikazali model na jednostavan način uz primjere njegovog korištenja u softwareu Excel i Matlab. Aljinović, Marasović i Tomić-Plazibat (2005)[66] uz originalni model, bave se i višekriterijskim programiranjem kako bi uključile dodatne tržišne uvjete u analizu. Usporedbom rezultata Markowitzevog modela i metode multivarijatne analize Bahovec i Škrinjarić (2013)[67] su utvrdile da modeli oblikovani uz pomoć multivarijatnih metoda ostvaruju jednako dobre performanse u odnosu prema Markowitzevom modelu. Pri analizi su koristile i određene mjere diverzifikacije.

Moderna teorija portfelja predstavlja jednu od najvažnijih inovacija 20. stoljeća na području investiranja i upravljanja portfeljem vrijednosnih papira.[68]

[62] Sundberg, J., Klacksell, G. (2012): Markov chain - Can you describe the stock index with a Markov chain?, KTH Royal Institute of Technology at Campus Valhallavägen.
[63] Dai, Y., Han, D., Dai, W. (2014): Modeling and Computing of Stock Index Forecasting Based on Neural Network and Markov Chain, The Scientific World Journal, Vol. 2014, str. 1-10.
[64] Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): Matematički modeli u financijskom upravljanju, Svučilište u Splitu, Ekonomski fakultet Split, str. 11.
[65] Aljinović, Z., Marasović, B., Šego, B. (2008): Financijsko modeliranje, Zgombić & partneri, Zagreb.
[66] Aljinović, Z., Marasović, B. Tomić-Plazibat, N. (2005): Multi-criterion approach versus Markowitz in selection of the optimal portfolio, Proceedings of the 8th International Symposium on Operational Research, Ljubljana, str. 261-266.
[67] Bahovec, V., Škrinjarić, T. (2013): Mogućnosti optimizacije portfelja na Zagrebačkoj burzi uz pomoć odabranih metoda multivarijantne analize, Ekonomski pregled, Vol.64, No. 1, str. 3-29.
[68] Jerončić M., Aljinović Z. (2011): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Stručni članak, Ekonomski pregled 62 (9-10), str. 587.

3.3. CAPM model

CAPM (engl. Capital Asset Pricing Model) odnosno model za procjenu kapitalne imovine je razvijen u 1960-im godinama kao rezultat paralelnog rada William F. Sharpea (1963 i 1964)[69] te John Lintnera (1965)[70]. Smatra se nadogradnjom Markowitzeve Moderne portfolio teorije, a predstavlja središnji dio modernih financija i osnovni model za mjerenje sustavnog rizika. Pojavom modela s jednim indeksom (single-index model), u kojem je prinos neke dionice povezan linearno s prinosom tržišta, došlo je do značajnog pojednostavljenja u odabiru portfelja. Kao i svaki drugi model, i ovaj model predstavlja pojednostavljenu sliku realnosti, i polazi od nekoliko pretpostavki o ponašanju investitora i uvjetima na tržištu kapitala:

- Investitori imaju averziju prema riziku i nastoje maksimizirati očekivanu korisnost bogatstva na kraju perioda.
- Pri izboru portfelja, investitori promatraju prva dva momenta distribucije prinosa: očekivani prinos i varijancu.
- Investitori promatraju isključivo jedan investicijski period, isti za sve investitore.
- Na tržištu kapitala postoji bezrizična aktiva, a investitori se mogu po bezrizičnoj kamatnoj stopi zaduživati u neograničenim količinama.
- Informacije su besplatne i podjednako, simultano dostupne svim investitorima, pa su očekivanja investitora na tržištu kapitala po pitanju stopa prinosa, rizika i korelacija homogena.
- Tržišta kapitala su u stanju ravnoteže, perfektna i efikasna.

Tržišta su perfektna, jer ne postoje transakcijski troškovi, različita porezna opterećenja, inflacija i promjene kamatnih stopa. Tržišta su efikasna u smislu da svaki investitor posjeduje efikasan portfelj, pa je i njihova suma, koja predstavlja tržišni portfelj, efikasna. Sva financijska aktiva je utrživa i perfektno djeljiva.

Ukoliko svi investitori maksimiziraju korisnost uz dani nivo rizika za identični skup investicija, i u istom vremenskom periodu, moraju doći do identičnoga optimalnog rizičnoga portfelja, koji zovemo tržišni portfelj, a obuhvaća sve aktive na tržištu.

---

[69] Sharpe, J. (1963): Capital asset prices: A theory of market equilibrium under conditions of risk, Journal of Finance 19, No. 4.

[70] Lintner, J. (1965): The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets, The review of Economics and Statistics, Vol. 47, No.1.

Prema CAPM modelu, postoji pozitivna linearna veza. Odnosno ravnotežni tržišni odnos između očekivane stope povrata i pripadajućeg rizika u portfelj kontekstu. On objašnjava prinose iznad nerizične stope pomoću kovarijanci prinosa na pojedine investicije jedino kroz njihove kovarijance s cjelokupnim trtžištem – bete. Model utvrđuje vezu između prinosa i rizika, te pokušava izraziti tržišni rizik u jednom jedinstvenom pokazatelju - beti.[71]

Betu računamo kao relativnu kovarijancu promjene između dionice i tržišnog portfelja:

$$\beta_j = \frac{Cov(R_j, R_m)}{\sigma^2 (R_m)} \qquad (42)$$

Gdje je:

$Cov(R_j, R_m)$ - kovarijanca između stope prihoda od konkretne vrijednosnice R_j, i stope prihoda od tržišnog portfelja R_m,
R_m- varijanca stope prihoda tržišnog portfelja.[72]

Ukupni rizik portfelja sastoji se od dvije komponente. Prva je sustavni rizik, koji nastaje zbog rizičnih faktora koji utječu na cijelo tržište, a to su promjene u svjetskoj i nacionalnoj ekonomiji, tehnološke promjene, promjene u poreznoj politici i slični čimbenici. Ovi rizici utječu na sve vrijednosnice i zato se ne mogu diverzificirati. Drugim riječima, čak i onaj investitor koji posjeduje dobro diverzificirani portfelj, izložen je ovoj vrsti rizika.
Druga komponenta rizika je nesustavni rizik. Takav rizik je vezan uz pojedino poduzeće ili djelatnost i može se smanjiti ili čak eliminirati diverzifikacijom. Nastaje kao posljedica promjena u uspješnosti poslovanja pojedinih poduzeća koja emitiraju dionice kao rezultat štrajka, jačanja konkurencije, zastarjevanja proizvoda i sl.

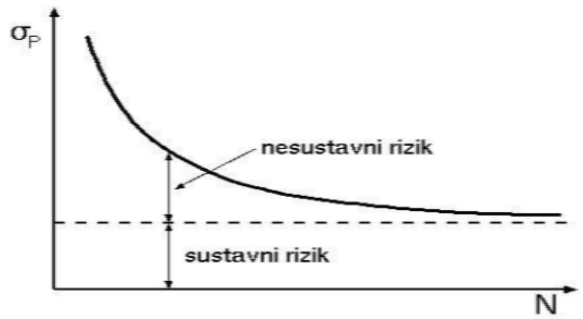
Uvođenje nerizične investicije implicira da svaki investitor odabire linearnu kombinaciju tržišnog portfelja i nerizične investicije ovisno o njegovim preferencijama prema riziku. Tako investitori skloniji većem riziku (ali i prinosu) nego što nudi tržišni portfelj, mogu posuditi dodatni iznos po nerizičnoj kamatnoj stopi. Nerizična investicija nosi unaprijed poznat i

[71] Aljinović, Z., Marasović, B., Šego, B. (2008): Financijsko modeliranje, Zgombić & partneri, Zagreb.
[72] Vidučić, Lj. (2008): Financijski menadžment, VI. Nepromijenjeno izdanje, RRIF-plus, Zagreb, str. 89.

zagarantiran prinos investitoru. Generalno ga izdaje vlada, pa je u tom smislu optimalan reprezentant nerizične investicije kratkoročna državna obveznica.
Tako prema teoremu odvojenosti, investitor prilikom izbora ulaganja donosi dvije odluke. Prva se odnosi na izbor rizičnog portfelja (tržišnog portfelja), a druga na izbor udjela kombinacije izabranog rizičnog portfelja i nerizične imovine, ovisno o stavu prema riziku. Investitori s većom averzijom prema riziku ulagat će vise u bezrizičnu aktivu, i obratno.

Ova teorija kaže da je ukupan rizik svakog pojedinačnog vrijednosnog papira nebitan. Za vrednovanje je značajna samo sistematska komponenta ukupne nestabilnosti. Budući da vrijednosnice mogu biti različito kombinirane u portelju kako bi otklonile pojedinačni rizik, samo će nediverzificiran ili sistematski rizik diktirati premiju na rizik. Investitori neće biti zaštićeni od rizika koji mogu biti otklonjeni diverzifikacijom. Ovo je temeljna postavka na kojoj se zasniva model procjenjivanja kapitalne imovine.
Studije su proučavale što se događa s rizikom portfelja ako se kombiniraju slučajno izabrane vrijednosnice koje onda tvore jednako ponderirane portfelje (npr. Fama, 1976). Kada uvrstimo samo jednu dionicu, tada je rizik portfelja jednak standardnoj devijaciji te jedne dionice. Kako se broj slučajno izabranih dionica u portfelju povećava, ukupni rizik portfelja se smanjuje. Takvo smanjenje se događa po opadajućoj stopi. Na ovaj način, može se eliminirati značajan dio rizika portfelja uz relativno umjereni iznos diverzifikacije.[73]

Slika 4. Prikaz ukupnog rizika ulaganja i smanjenje rizika portfelja dodavanjem sve većeg broja dionica

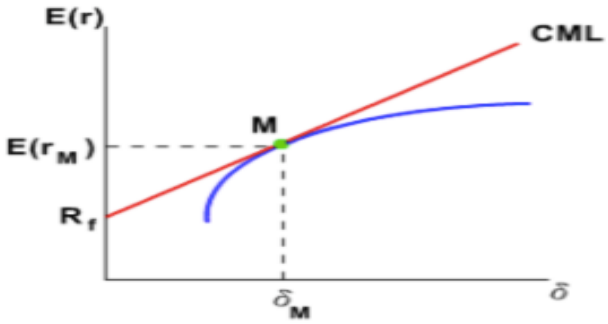


Izvor: Tomić, B. (2012): The application of the capital asset pricing model on the Croatian capital market, Effectus College for Law and Finance, str. 112.

[73] Van Horne, J.C., Wachowich, J.M. (2012): Financijsko upravljanje i politika (Financijski menadžment), deveto izdanje, Mate, Zagreb, str. 98-109.

Investitor dijeli sredstva za investiranje na dio koji ulaže u rizičnu imovinu u jednakim proporcijama (koja se nalazi na efikasnoj granici), dodajući potom posuđivanje po stopi povrata bez rizika radi postizanja osobno preferirane kombinacije rizika i povrata. Takav linearni skup investicijskih mogućnosti naziva se linija tržišta kapitala - CML (engl. Capital Market Line) koji za danu situaciju predstavlja efikasan skup portfelja. Koeficijent (nagib) smjera CML pravca zove se Sharpeov omjer, a označava omjer premije u odnosu na rizik. Kvantificira se kao prinos iznad bezrizične stope i rizika koji se mjeri standardnom devijacijom (prinos iznad nerizične investicije po jedinici preuzetog rizika). Pravac s većom vrijednosti koeficijenta smjera predstavlja veći očekivani prinos za određenu razinu rizika. Stopa povrata na određeni portfelj izračunava se kao ponderirani prosjek beta – veličina svih vrijednosnih papira koje sačinjavaju taj portfelj. Dakle, što je nagib karakterističnog pravca za dionicu, opisan njezinom betom, veći, neizbježivi rizik je veći. Dok je neizbježivi (sustavni rizik) prikazan nagibom karakterističnog pravca, izbježivi (nesustavni) rizik prikazan je udaljenošću podataka (točaka) od pravca. Što je veća disperzija (udaljenost točaka od pravca), veći je i nesustavni rizik.

Slika 5. Linija tržišta kapitala (CML)



Izvor: Van Horne, J.C., Wachowich, J.M. (2202): Financijsko upravljanje i politika (Financijski menadžment), deveto izdanje, Mate, Zagreb, str. 109.

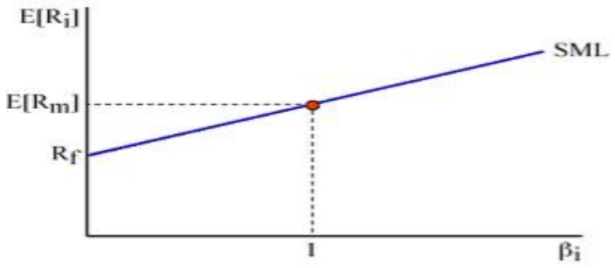
Točka R_f predstavlja bezrizičnu imovinu čiji je rizik jednak nuli i ima neki svoj prinos. Pravac koji prolazi točkom (0, R_f) i koji je ujedno tangenta efikasne granice u točki M, je linija tržišta kapitala (CML). To je ujedno i pravac koji ima najveći Sharpov koeficijent smjera.

Veza između očekivanog prinosa pojedinačne vrijednosnice i njezinog sistemskog rizika, mjerenog betom, naziva se linija tržišta vrijednosnica – SML (engl. Security Market Line).

Nagib ove krivulje odražava investitorovu averziju prema riziku. Što je veća averzija, veća je riziko premija ali i očekivana stopa povrata, a nagib linije je oštriji.[74]
Dakle, SML definira da tražena stopa povrata na vrijednosnicu ovisi o:

- beti vrijednosnice (tržišnom riziku vrijednosnice),
- stopi povrata bez rizika,
- tržišnoj riziko premiji.

Slika 6. Linija tržišta vrijednosnica (SML)



Izvor: Van Horne, J.C., Wachowich, J.M. (2002): Financijsko upravljanje i politika (Financijski menadžment), deveto izdanje, Mate, Zagreb, str. 109.

Uz rizik jednak nuli, linija tržišta vrijednosnica sječe vertikalnu os u bezrizičnoj stopi. To znači da i onda kada ne postoji rizik, investitori će ipak biti kompenzirani za vremensku vrijednost novca. Kako raste rizik, raste i očekivani prinos.
Kod linije tržišta kapitala (CML) rizik je ukupni rizik portfelja, a mjeri se standardnom devijacijom, jer se radi o izboru između rizika i povrata za efikasna portfelja. Kod linije tržišta vrijednosnica (SML) radi se o izboru između rizika i povrata za pojedinačnu vrijednosnicu koji imaju neki elementi izbježivog rizika. Stoga se nalaze ispod granice efikasnosti, a kao odgovarajuća mjera rizika se upotrebljava beta, a ne standardna devijacija.

CAPM je jednostavan model i traži malo ulaznih parametara pa se zato smatra uobičajenim alatom za procjenu rizika. Iako ne zadovoljava u potpunosti empiriske testove, on se često koristi zbog svoje jednostavnosti i zadovoljavajuće točnosti u većini primjena. CAPM se primjenjuje u praksi pri vrednovanju prinosa neke tržišne imovine, odnosno vrijednosnog

[74] Vidučić, Lj. (2008): Financijski menadžment, VI. Nepromijenjeno izdanje, RRIF-plus, Zagreb, str. 89.

papira, projekta ili samog poduzeća. Primjenjiv je i u određivanju cijene kod prve javne ponude.

Osnovni nedostatak CAPM modela jesu teškoće prilikom procjenjivanja njegovih parametara, što umanjuje njegovu objektivnost i primjenjivost. U praksi je teško doći do zadovoljavajuće informacije o beti za vrijednosnice s fiksnim dohotkom zbog čega se CAPM većinom bavi običnim dionicama.

Unatoč svim kritikama, CAPM ostaje praktičan vodič za određivanje rizika i prinosa koji se mogu očekivati na tržištima kapitala. On služi kao opći okvir za razumijevanje neizbježnog (sustavnog) rizika, diverzifikacije i premije za rizik iznad bezrizične stope, koja je neophodna za privlačenje kapitala. Taj okvir je primjenjiv na sve modele procjene vrijednosti u financijama.[75]

3.4. Arbitražna teorije procjenjivanja (APT)

U odnosu na CAPM teorija arbitražnog procjenjivanja razvijena je kao alternativni model određivanja cijena na tržištu kapitala koji će biti fleksibilniji od CAPM modela. Teorijom arbitražnog procjenjivanja htjelo se ukloniti glavne prepreke koje obilježavaju CAPM model a to je teza o lineranosti rizika i prinosa. APT polazi od toga da je sistematski rizik ono što utječe na cijene vrijednosnica na tržištu. Za razliku od CAPM modela, ATP model prihvaća mogućnost postojanja nekoliko faktora sistemskog rizika koji posredstvom stupnja osjetljivosti vrijednosnice ili portfelja utječu na nivo sistemskog rizika vrijednosnica i posljednično, njihovih prinosa. Koristeći više sistemtski rizika, u ATP modelu, objašnjavamo stope prinosa vrijednosnica ili portfelja. Međutim, problem predstavlja što nije definirano koji su to faktori i koliko ih ima.[76]

Teorija arbitražnog procjenjivanja polazi od zakona jedne cijene koja kaže da jedna aktiva može imati samo jednu cijenu koja će dovesti do poravnanja cijena na njihovom ravnotežnom nivou. Iz čega slijedi da je arbitražni portfelj ima nulti rizik, ne zahtjeva kapitalne investicije i zarađuje pozitivan prinos.

Jednadžba teorije arbitražnog procjenjivanja glasi:

[75] Van Horne, J.C., Wachowich, J.M. (2012): Financijsko upravljanje i politika (financijski menadžment), deveto izdanje, Mate, Zagreb, str. 98-109.

[76] Frankfurter, G. M. (1993): The End of Modern Finance?, The Journal of Investing 2, str. 4.

$$O(_{P_1}) = P_f + \beta_1 \lambda \qquad (43)$$

Gdje je:

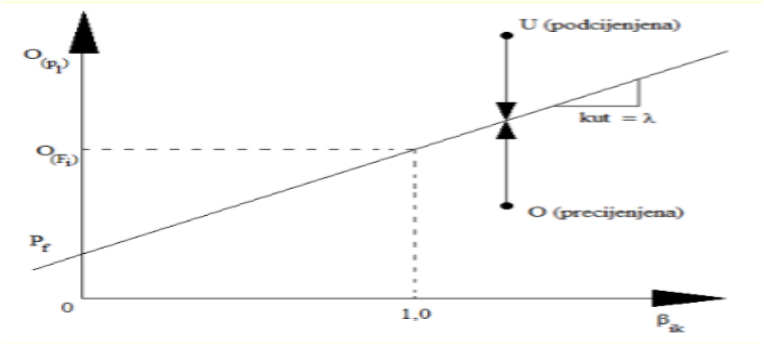
Pf - bezrizična aktiva,

β - garantirani minimalni rizik portfelja te

λ - riziko premija rizične aktive.

Jednadžba predstavlja liniju arbitražnog procjenjivanja.

Slika 7. Pravac arbitražnog procjenjivanja



Izvor: Stanivuk, T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktorska disertacija, Sveučilište u Splitu, str. 127.

Faktorska riziko premija λ se u ovoj jednadžbi može tumačiti i kao riziko premija rizične aktive ako je njen β koeficijent jednak jedinici, tj. ako se kreće identično kao i faktor sistemskoga rizika. Gornja jednadžba, na jednostavnom primjeru jednog faktora sistemskoga rizika, objašnjava bit teorije arbitražnoga procjenjivanja. Poanta je u tome da će, ako nema arbitražnih prilika, očekivana vrijednost stope prinosa rizične vrijednosnice biti jednaka stopi prinosa stupnja osjetljivosti promatrane rizične vrijednosnice na kretanje sistemskoga faktora i faktorske riziko premije λ.

Dosadašnja testiranja APT nisu donijela jasne zaključke o njenoj realnosti. Kod APT se ispostavilo da je veliki problem odrediti relevantne faktore koji u cjelini objašnjavaju cjenovne varijabilitete na tržištu kapitala. APT ne daje nikakve smjernice oko izbora faktora i njihova broja. Zbog toga su mnogi smatrali da APT zamjenjuje problem identificiranja tržišnog portfelja

iz CAPM, podjednako teškim problemom odabira i mjerenja faktora modela, te da zbog toga ni APT nije moguće empirijski testirati. [77]

McElroy i Burmeister (1988) [78] su pomoću ATP modela analizirali su makroekonomske varijable: premiju rizika, neočekivanu deflaciju, neočekivani porast prodaje i rezidualni tržišni faktor te su pomoću multivarijantne regresije dokazali signifikantnost svih makroekonomskih pokazatelja na objašnjenje povrata na dionice.

Ball, Brown i Officer (1975)[79] potvrdili su navedeni CAPM odnos. Međutim, Ramsey, Lau i Quay (1975)[80] pokazuju da linija tržišta vrijednosnica (SML) ima drugačije kretanje od onog predviđenog CAPM modelom.

Prilikom istraživanja beta kao mjeri rizika koja je ključni element modela Fama i Macbeth (1973)[81], Jensen i Schloes (1972) pokazale su prihvatljivu moć predviđanja u odnosu na prinos na portfelj običnih dionica. S druge strane, kasnije istraživanja Reinganum (1981)[82], Lakonishok i Shapiro (1986)[83], te Fama i French (1992)[84] odbacuju vezu između rizika i očekivanog povrata. Roll (1977) [85] odbacuje CAPM pristup zbog nemogućnosti identificiranja pravog tržišnog portfelja koji bi osim dionica trebao obuhvatiti i ostale vrijednosne papire. Fruk i Huljak (2003)[86] zaključuju, za Hrvatsko tržište u razdoblju 1998 do kolovoza 2003, da sigurno postoji pozitivna veza između prinosa i beta-koeficijenta no ostaje otvoreno pitanje da li se ista može koristiti prilikom donošenja odluka o investiranju. Tomić (2013)[87] u svom istraživanju potvrđuje vezu između rizika i očekivanog povrata, odnosno beta koeficijenta na temelju istraživanja hrvatskih tržišta za razdoblje od 2009-2013.

---

[77] Stanivuk, T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktroska disertacija, Sveučilište u Splitu. str. 124-133.

[78] Burmeister, E. i McElroy, M.B. (1991): The residual market factor, the APT, and mean-variance efficiency, Review of Quantitative Finance and Accounting, Vol. 1, str. 27-49.

[79] Ball, R., Brown, P. and Officer, R.R. (1975): Toward Unverstanding the Share Market, Alumni News, Alumni Association of the University of Queensland 7 (2), 10-14.

[80] Lau, S., Quay, S i Ramsey, C. (1975): The Tokyp Stock Exchange and the capital asset pricing model, Journal of Finance 30, str. 507-513.

[81] Fama, E. F i MacBeth, J. (1973): Risk, return and equlibirum: empirical test, Journal od Political Economy 71, str. 607-636.

[82] Reinganum, M. (1981): Misspecification od capital asset pricing: Empirical anomalies based on earning yields and market values, Journal of Financial Economics 9, str. 19-46.

[83] Lakoinishok, J. i Shapiro, A. (1985): Systematic risk, total risk and size as determinants of stock market returns, Journal of Banking and Finance 10, str. 115-132.

[84] Fama, E.F., French K.R (1989): Business Conditions and Expected Returns on Stocks and Bonds, Journal of Financial Economics 25, str. 23-49.

[85] Roll, R. (1977): A critique of the asset pricing theory's test, Journal of Financial Economics 4, str. 129-176.

[86] Fruk, M. i Huljak, I. (2004): Testiranje Sharpe-Linterova modela na Zagrebačkoj burzi Financijska teorija i praksa 28, str. 77-91.

[87] Tomić, B. (2013): The application of the capital asset pricing model on the Croatian capital market, Effectus College for Law and Finance, str. 105-123.

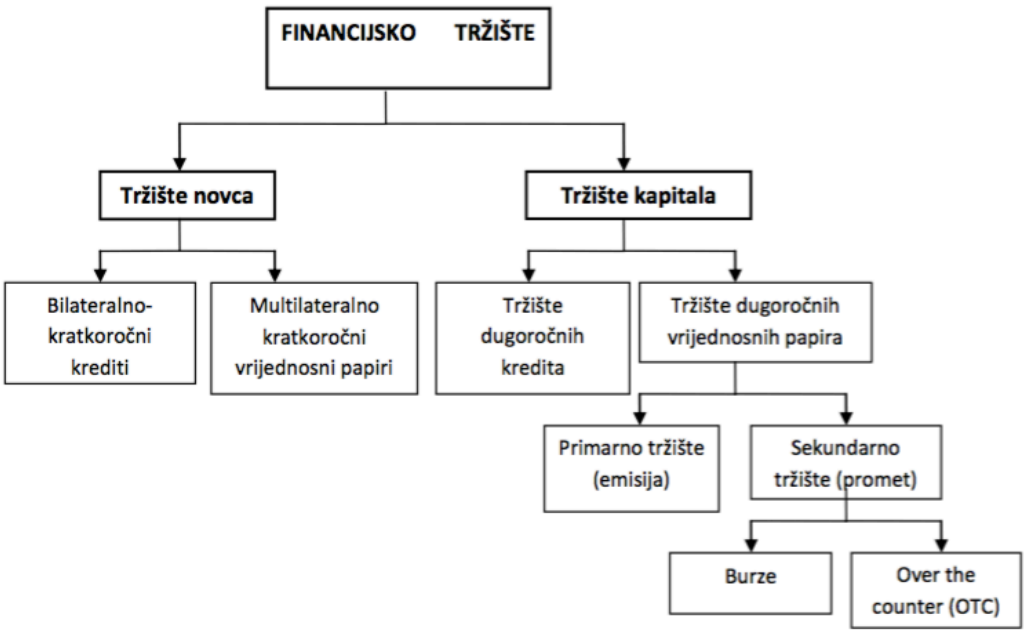
4. HRVATSKO TRŽIŠTE KAPITALA I SVJETSKA FINANCIJSKA KRIZA

Ovo poglavlje sadrži kratki pregled razvoja Hrvatskoj tržišta kapitala i način njegovog funkcioniranja. Nadalje daje se prikaz stanja Zagrebačke burze s obzirom na posljednju svjetsku financijsku krizu. Na kraju poglavlja promatra se utjecaj liberalizacije kretanja kapitala u procesu integracije tržišta kapitala.

4.1. Funkcioniranje tržišta kapitala u Hrvatskoj

Financijsko tržište je mjesto uređenog (organiziranog, normiranog) protoka novčanih sredstava. Poduzeće je u stalnoj interakciji s financijskim tržištima i institucijama, jer koristeći njihove usluge dobavlja novac potreban za sve svoje operacije, od dnevnog poslovanja, do velikih investicijskih poduhvata. Tako da ne postoji način da se poduzeće odvoji od financijskog sustava i njegovih zakonitosti.

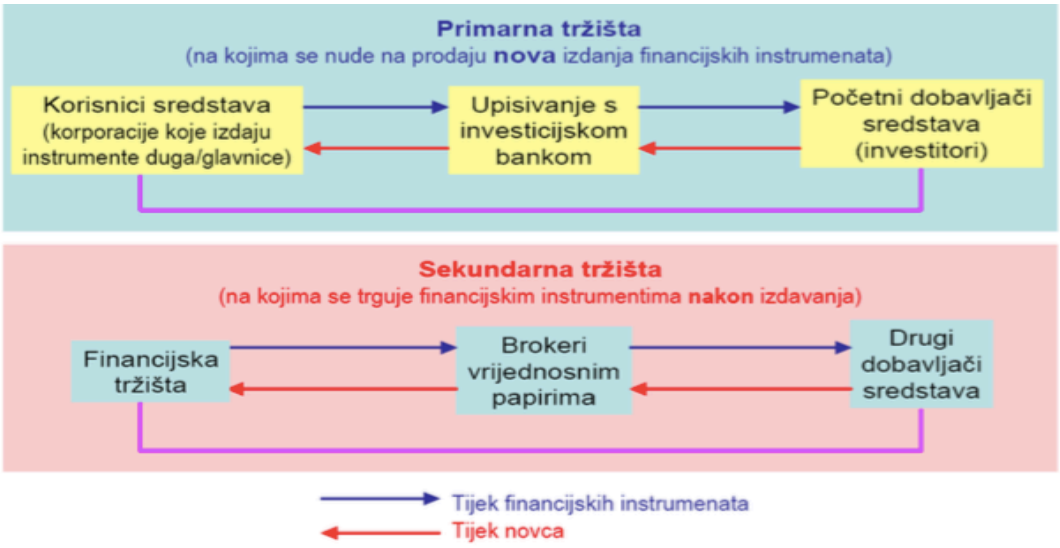
Slika 8. Struktura financijskog tržišta



Izvor: Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split, str. 12.

Financijska tržišta mogu biti primarna i sekundarna. Primarna financijska tržišta su ona, na kojima korisnici sredstava (korporacije) dobavljaju sredstva emitirajući nove financijske instrumente (npr. dionice, korporacijske obveznice). Osnovni razlog zbog kojeg poduzeća prikupljaju kapital emisijom dionica je u tome, što takav način često puta omogućuje postizanje manjeg troška kapitala, što u načelu znači da kupci dionica očekuju dividendu koja je manja od kamate koju zahtijevaju banke. Jedan od temeljnih razloga za to jest činjenica, da pojedinačni ulagač u isti projekt trpi manji rizik, ako je broj ulagača u njemu veći, tj. ako je iznos njegovog ulaganja zbog toga manji. Na sekundarnim financijskim tržištima trguje se već izdanim vrijednosnim papirima. Naime, svaki vrijednosni papir ima neku tržišnu cijenu, i on kao takav predstavlja imovinu u rukama njegovoga vlasnika. Vlasnici financijskih instrumenata mogu ih prodavati, a zainteresirani kupci kupovati, na sekundarnim tržištima.[88]

Slika 9. Razlika između primarnog i sekudarnog tržišta



Izvor: Sabolić, D. (2013): Financijska tržišta II – Organizacija financijskih tržišta, Sveučilište u Zagrebu, str. 263.

[88] Sabolić, D. (2013): Financijska tržišta II – Organizacija financijskih tržišta, Sveučilište u Zagrebu, str. 263-275.

Institucije tržišta kapitala u Republici Hrvatskoj su:

- Središnja depozitarna agencija - institucija kod koje se pohranjuju nematerijalizirani vrijednosni papiri i vode računi imatelja vrijednosnih papira.
- Hrvatska agencija za nadzor financijskih usluga (HANFA) - državna institucija koja nadzire zakonitost postupanja sudionika na tržištu kapitala.
- Agencija za zaštitu tržišnog natjecanja - nadzorno tijelo u čijem je djelokrugu i nadležnosti nadzor financijskoga tržišta, subjekata nadzora i financijskih usluga koje pružaju.
- Direkcija za nadzor društava za osiguranje - institucija koja pruža zaštitu osiguranicima od posljedica nastupanja najraznovrsnijih rizika.
- HNB - centralna institucija bankarskog sustava koja svojim egzistiranjem i djelovanjem čini temelj stabilnosti bankarskog sustava u RH, a svojim zakonom propisanim aktivnostima ostvaruje osnovni cilj - postizanje i održavanje stabilnosti cijena.
- Burza i burzovno poslovanje – ovdje ističemo Zagrebačku burzu kao instituciju posredstvom koje se na organiziran i uređen način, elektronskim putem, spajaju ponuda (prodaja) i potražnja (kupnja) vrijednosnih papira.

U Hrvatskoj su do 2007 godine postojale dvije glavne burze Zagrebačka i Varaždinska burza. U 2007 godini proces spajanja Varaždinske i Zagrebačke burze je priveden kraju i ovom odlukom u Hrvatskoj danas postoji samo jedna burza i to Zagrebačka burza. Burze moraju raspolagati osobljem, opremom, tehničkim uvjetima i organizacijom koja omogućuje:

- da svi sudionici u trgovini na burzi mogu istovremeno, ravnopravno i pod jednakim uvjetima davati i prihvaćati ponude za kupnju i prodaju vrijednosnih papira,
- da svi sudionici u trgovini na burzi imaju u istom trenutku jednaki pristup tržišnim informacijama o vrijednosnim papirima kojima se trguje i da svi mogu prodavati, odnosno kupovati vrijednosne papire pod jednakim uvjetima.

Zakon o tržištu kapitala stupio je na snagu 1. siječnja 2009 godine a uređuje uvjete za osnivanje, poslovanje, nadzor i prestanak postojanja investicijskog društva, tržišnog operatera i operatera sustava prijeboja i namire u RH; uvjete za pružanje investicijskih usluga i obavljanje investicijskih aktivnosti i s tim povezanih pomoćnih usluga; pravila trgovanja na uređenom tržištu; uvjete za ponudu vrijednosnih papira javnosti i uvrštenje vrijednosnih papira na uređeno tržište; obveze u vezi s objavljivanjem informacija koje se odnose na vrijednosne papire

uvrštene na uređeno tržište; zlouporabu tržišta; pohranu financijskih instrumenata i namiru poslova s financijskim instrumentima; ovlasti i postupanje Hrvatske agencije za nadzor financijskih usluga (Agencija) pri provođenju Zakona.

Ovim se Zakonom u pravni sustav RH prenose određene direktive Europske unije i detaljnije uređuje provođenje uredbi Europske zajednice. Zakon precizira poslovanje uređenog tržišta u RH kojim može upravljati samo burza sa sjedištem u RH, kao tržišni operater, na temelju odobrenja Agencije.

Promjenama na temelju Zakona o tržištu kapitala biti će izložena trenutno ovlaštena društva (MiFID investicijska društva (ID) + kreditne institucije), društva za upravljanje otvorenim investicijskim fondovima, Zagrebačka burza i Središnja depozitarna agencija, izdavatelji, ulagatelji, osobe koje izrađuju i/ili distribuiraju preporuke za ulaganje.

Na tržištu financijskih instrumenata se koriste 3 propisa i to Direktiva o tržištima financijskih instrumenata (MiFID), provedbena direktiva i provedbena uredba. Regulativa na ovim tržištima se temelji na „principles based approach“, odnosno to znači da se umjesto određenih pravila postavljaju jasni standardi i ciljevi koje su investicijska društva dužna ostvariti. Prednost ovog pristupa je fleksibilnost koja je nužna za reguliranje raznih subjekata i aktivnosti kojima se oni bave, dok je u isto vrijeme to velika odgovornost za sudionike. [89]

Zakon o tržištu kapitala mijenja definiciju povlaštene informacije i po njemu povlaštena informacija je:

- precizne naravi i nije dostupna javnosti,
- posredno ili neposredno se odnosi na izdavatelja ili financijski instrument,
- ima vjerojatnost značajnog utjecaja na cijenu.

ZTK se također razlikuju primarni insideri i sekundarni insideri, te se predviđa stroži zakon za primarne insidere u odnosu na sekundarne insidere. Uvodi se pojam prihvaćenih tržišnih praksi. One predstavljaju specifičnost svakog pojedinog tržišta. Postavlja se i visok standard za zabranu insiderskog trgovanja, na način da se isto zabranjuje svakoj osobi, ako ista zna ili je trebala znati da je riječ o povlaštenoj informaciji.

[89] Narodne novine (2008): Zakon o tržištu kapitala, Narodne novine d.d. Zagreb, broj 88.

Objavljivanje propisanih informacija se primjenjuje kod izdavatelja čiji su vrijednosni papiri uvršteni na uređeno tržište. ZTK se mijenja obveza izdavatelja ili osobe koja je bez odobrenja izdavatelja uvrstila vrijednosne papire izdavatelja na uređeno tržište. Kod ponude vrijednosnih papira ZTK drugačije definira prospekt i to kao dokument koji sadrži informacije o izdavatelju i vrijednosnim papirima. Objavljuje se u svezi javne ponude vrijednosnih papira ili kod uvrštenja vrijednosnih papira na uređeno tržište. Težište je stavljeno na sadržaj i formu prospekta, dok su detalji javne ponude ostavljeni na slobodnu volju osobama koje tu javnu ponudu provode.

4.2. Razvoj hrvatskog tržišta kapitala i trgovanje na tržištima kapitala

Hrvatska je tranzicijska zemlja čija je najznačajnija karakteristika promjenjivost okoline, što se očituje u svim aspektima gospodarskog života države, pa tako i na financijskim tržištima. Hrvatska je od početka samostalnosti prošla kroz značajne strukturne promjene kao što su proces privatizacije, zamjena socijalizma kapitalizmom i tržišnom ekonomijom kao i osnivanje i nastanak novih financijskih institucija i oblika ulaganja. Slaba razvijenost tržišta kapitala posljedica je političkih, sociooloških i ekonomskih čimbenika. Glavni razlozi slabe razvijenosti tržišta kapitala, kao i cijelog gospodarstva su: Domovinski rat, loše proveden proces privatizacije, svojevrsna izoliranost od nekih dijelova međunarodne zajednice.
U svijetu se smatra da su ulaganja i tranzicijske zemlje veoma rizične, ali potencijalno veoma isplativa, koje nude prednosti diverzifikacije. Investitori u tranzicijske zemlje posebno se oprezni zbog neprevidljvih i brzih promjena političkih situacija, zakona uz zaštitu vjerovnika i ulagača, regulatornih ograničenje, te promjena u valutnim tečajevima. Ostali bitni čimbenici za inozemne investiture jesu: upitno funkcioniranje pravne države, korumpiranost, nepouzdanost informacija, plitko i nelikvidno tržište.

Zagrebačka burza je otvorena nakon prvog svjetskog rata, 4. lipnja 1919 godine i to je otvoren prvo njen Efektni odjel, dok je Robni odjel počeo s radom 1. kolovoza 1919 godine. U početku je bila podređena Ministarstvu trgovine i industrije, međutim imala je sva prva korporacije i sama je donosila neke važne odluke. Nadzor nad burzom je imao povjerenik kojeg ja postavilo Ministarstvo trgovine i industrije. Burzom je upravljalo burzovno vijeće koje se sastojalo od 24 člana, a njih je birala Glavna skupština burze na tri godine. Kao posrednike burza je postavljala burzovne mešetare. Utvrđivanje tečajeva domaćih vrijednosnih papira je vršila posebna komisija, dok je promet stranim vrijednosnim papirima ovisio o odobrenju Ministarstva trgovine i

industrije. Promet na burzi je 1920 godine iznosio 2 400 000 000 kruna, nakon čega se ta vrijednost stalno smanjivala. Ova Zagrebačka burza je prestala s radom 1945 godine. Obnova Burze u Hrvatskoj uslijedila je tek 1991 godine, kada je 25 banaka i 2 osiguravajuća društva utemeljilo Zagrebačku burzu kao centralno mjesto trgovine vrijednosnim papirima u Republici Hrvatskoj.

Zagrebačka burza započela je s izračunom CROBIS-a, službenog obvezničkog indeksa Zagrebačke buzre od 01. listopada 2002. Bazna vrijednost indeksa iznosi 100 bodova i predstavlja cjenovni indeks ponderiran tržišnom kapitalizacijom. Obujam trgovanja u prošlosti bio je veoma slab zbog velike nelikvidnosti, a od tada volumen trgovanja kontinuirano raste. Najviše se trguje državnim obveznicama Republike Hrvatske.

Zagrebačka burza vrlo je aktivna i na međunarodnom planu: osnivač je i član Federacije Euro-Azijskih burzi i dopisni član Federacije Europskih burzi. Značajnu suradnju u domeni izrade načela korporativnog upravljanja ostvarila je s Organizacijom za ekonomsku suradnju i razvoj (OECD), a u pojedinim projektima Zagrebačke burze sudjelovali su ili bili konzultirani djelatnici Londonske i Pacifičke burze te stručnjaci američkog SEC-a.

4.3. Liberlizacija kretanja kapitala u Hrvatskoj

Schmukler, Yeyati i Van Horen (2007)[90] kao definiciju likvidnog tržišta ističu "tržište na kojemu sudionici mogu brzo obaviti velike transakcije bez većeg utjecaja na cijenu".

Kriterij likvidnosti važan je faktor svim sudionicima na tržištu kapitala pri donošenju investicijskih odluka. Likvidnost im pruža sigurnost i umanjuje rizik da neće biti u mogućnosti zatvoriti svoje pozicije bez velikoga gubitka vrijednosti uložene financijske imovine prema C.W. Stahel (2004)[91] ističe da zbog integracije tržišta kapitala investitori usmjeravaju svoja sredstva na ona tržišta na kojima očekuju veće prinose na ulaganja. Dokaz liberalizacije i integracije tržišta kapitala jest velik porast u kretanju kapitala između različitih tržišta u posljednjih 30 godina. Iz perspektive likvidnosti, manje likvidno tržište omogućuje veće stope prinosa zbog volatilnosti cijena, ali podrazumijeva i veći rizik.

[90] Yeyati, E., Schmukler, Sergio L., Van Horen. N. (2007): Emerging market liquidity and crises, Policy Research Working Paper Series 4445, The World Bank.
[91] Stahel, C. W. (2004): Is there a global liquidity factor?, Doctoral dissertation, Ohio State University.

Moguće je definirati sljedeća četiri aspekta ili dimenzije likvidnosti na financijskim tržištima.

- Vrijeme trgovanja - definirano je kao sposobnost da se transakcija izvrši odmah i po prevladavajućoj cijeni odnosno da omogućuje trenutačno trgovanje.
- Gustoća/zbijenost - istodobna sposobnost kupnje i prodaje po približno jednakoj cijeni. Hasbrouck (2003) [92] utvrđuje da gustoća izravno pokazuje troškove trenutačnog izvršavanja transakcije.
- Dubina - mogućnost kupnje ili prodaje određene količine imovine bez utjecaja na cijenu. Dokaz nelikvidnosti bio bi slučaj značajnog utjecaja investitora na cijenu. Dubina se očituje u postojanju velikog broja kupovnih i prodajnih naloga s malim razlikama u cijeni.
- Elastičnost/otpornost - sposobnost istodobne kupnje ili prodaje određene količine imovine bez većeg utjecaja na kotiranu cijenu. Dok se sa stajališta dubine tržišta promatra samo volumen najboljih kupovnih i potražnih naloga, dimenzija elastičnosti/otpornosti uzima u obzir elastičnost ponude i potražnje.

Spomenute dimenzije likvidnosti mogu se predočiti s pet različitih razina likvidnosti.

- Mogućnost trgovanja. Ta prva razina likvidnosti pretpostavlja da na tržištu nema trgovanja ako nema likvidnosti. Na likvidnom tržištu postoji barem jedan nalog za kupnju i prodaju koji omogućuje da se trgovina i ostvari.
- Mogućnost kupnje ili prodaje određenog volumena vrijednosnice s utjecajem na cijenu. Ako postoji mogućnost trgovanja, sljedeće je pitanje utjecaj te trgovine na cijenu. Na likvidnom tržištu trgovanje je moguće bez većeg utjecaja na cijenu.
- Mogućnost kupnje ili prodaje određenog volumena vrijednosnice bez utjecaja na cijenu. Kako tržište postaje likvidnije, utjecaj na cijene je sve manji. S povećanjem likvidnosti tržište će u konačnici dosegnuti razinu na kojoj više nije moguć utjecaj protrgovane količine vrijednosnica na njihovu cijenu.
- Mogućnost istodobne kupnje i prodaje imovine prema gotovo jednakoj cijeni.
- Mogućnost trenutačnog trgovanja, odnosno mogućnost izvršavanja transakcija.[93]

Razlozi loše likvidnosti i niskog volumena na Hrvatskoj burzi mogu se objasniti kombiniranim utjecajem nekoliko čimbenika:

[92] Hasbrouck. J. (2003): Intraday Price Formation in the Market for U.S. Equity Indexes, Journal of Finance, 58, str. 2375-2400.
[93] Benić, V., Franić, I. (2008): Komparativna analiza likvidnosti tržišta kapitala Hrvatske i zemalja regije, Zagreb.

- Tvrtke mogu dobiti jeftinije kredite nego što ih košta proces izdavanje obveznica.
- Država nije uspjela u poticaju da se dionička društva uvrste u kotacije burzi.
- Uprave tvrtki ne žele javno objavljivati svoja poslovna izvješća, kako bi od države, zaposlenika i poslovnih partnera skrivali svoje poslovne rezultate.[94]

Osnovna karakteristika Hrvatskog financijskog tržišta kao i financijskih tržišta ostalih zemalja u tranziciji je slaba razvijenost i nelikvidnost, snažna premoć banaka i institucija kredita i oročenih depozita nad svim ostalim financijskim institucijama i oblicima zaduživanja ili investiranja. To znači da je i dalje osnovni oblik zaduživanja poslovnih subjekata u Hrvatskoj bankovni kredit, a stanovništvo ne ulaže u vrijednosne papire, pa čak niti u državne obveznice, nego svoju štednju plasira u obliku depozita na bankovne račune.
Trgovina vrijednosnim papirima (dionicama i obveznicama) na Zagrebačkoj burzi odvija se putem elektroničkog trgovinskog sustava. Brokerske kuće, članice Burze, povezane su posebnim telekomunikacijskim vezama sa sjedištem Burze i unose naloge za kupnju ili prodaju izravno iz svojih ureda te zaključuju transakcije s ostalim brokerima. Dakle, ne postoji jedno fizičko mjesto (tradicionalni floor) gdje se odvija trgovina vrijednosnim papirima, već ona teče putem elektronički povezanih trgovaca. Svi brokeri članovi imaju pristup trgovinskom sustavu u realnom vremenu (bez vremenskog kašnjenja/pomaka) kako bi bili u jednakom položaju glede istodobnog primanja informacija o trenutačnoj ponudi vrijednosnih papira.

Trgovina je otvorena svakim radnim danom od 10:00 do 16:00 sati, osim praznicima koji su navedeni na internetskim stranicama Burze, a rezultati trgovine i dnevne cijene dionica dostupni su svim zainteresiranima putem dnevnog tiska, specijaliziranih kuća za distribuciju financijskih informacija kao i na Burzinim internetskim stranicama te pomoću specijaliziranog sustava za distribuciju burzovnih informacija ZSE Monitor.

Od početka 1995 godine, zahvaljujući podršci CARNET-a, prvog davatelja internetskih usluga u Hrvatskoj, Zagrebačka burza predstavlja svoje službene internetske stranice, na kojima su se mogli naći osnovni podaci o Burzi te redovita dnevna izvješća o trgovanju i kretanju cijena. U to vrijeme, Zagrebačka burza bila je prva burza u Europi i jedna među prvima na svijetu s vlastitim službenim internetskim stranicama.

[94] Olgić Draženović, B., Prohaska, Z. (2003): Foreign Portfolio Investments in the Republic of Croatia, in 4th International Conference Economic System of European Union and Accession of the Republic of Croatia "Theory and Practice of Transition and Accession to the EU". Ljubljana: Faculty of Economics, str. 300.

2006-u godinu su obilježila dva važna događaja koja su značajno pridonijela rastu interesa za dioničko burzovno trgovanje: proces javnog preuzimanja PLIVE od strane američkog Barra i javna ponuda i uvrštenje na Službeno tržište dionica najveće hrvatske naftne kompanije INE (paralelno je uvrštena na Zagrebačkoj i Londonskoj burzi). Javna ponuda dionice INE je naročito značajna jer je pokrenula veliki interes domaćih ulagača za domaće tržište kapitala. U svega 20-tak dana po uvrštenju (1. prosinca 2006) uspjela je postati četvrta najtrgovanija dionica 2006 godine, s 400-tinjak kuna prometa, približno koliko je u cijeloj godini ostvarila najatraktivnija dionica tadašnje Varaždinske burze Ericsson Nikola Tesla.

Sustavi na kojima se trgovina na Zagrebačkoj burzi odvijala do jeseni 2007 bili su i više nego zadovoljavajući za tadašnji stupanj razvoja hrvatskog tržišta kapitala. Godine 2007 došlo je do konsolidacije hrvatskog tržišta kapitala i pripajanja Varaždinske burze Zagrebačkoj. Novonastale okolnosti, koje su rezultirale velikim brojem uvrštenih vrijednosnih papira, kao i povećanim volumenom trgovanja, ali i prirodan razvoj tržišta kapitala, jačanje investicijske klime i velik interes svih sudionika tržišta za novim financijskim proizvodima ukazali su na potrebu implementiranja novog sustava koji će moći zadovoljiti potrebe mladog, ali izuzetno brzo rastućeg hrvatskog tržišta. Od jeseni 2007 Zagrebačka burza koristi X-Stream trgovinsku platformu NASDAQ OMX-a.

Indeks se računa na kraju svakog trgovinskog dana uzimajući u obzir isplaćenu, odnosno stečenu kamatu. Prilikom izračuna indeksa koristi se prosječna dnevna cijena ponderirana količinom za sve obveznice koje se nalaze u sastavu indeksa pri čemu se u obzir uzimaju redovne transakcije, blok transakcije i OTC transakcije. U slučaju da s nekom obveznicom koja je uključena u indeks nije bilo transakcija, za izračun indeksa se uzima prosječna dnevna cijena od prethodnog dana, odnosno od zadnjeg dana kada je obveznicom trgovano.

4.3.1. CROBEX

Službeni indeks Zagrebačke burze je CROBEX. Počeo se objavljivati 1. rujna 1997 godine. Bazni datum je 1. srpnja 1997 godine, a bazna vrijednost 1000. CROBEX je indeks vagan na osnovi „free float“ tržišne kapitalizacije, odnosno prema dijelu tržišne kapitalizacije koja je tržištu raspoloživa i dostupna. Pri tom je težina pojedine dionice ograničena na 15%. CROBEX se računa kontinuirano tijekom trgovine koristeći zadnje cijene.

Index CROBEX se računa na sljedeći način: [95]

$$I_t^j = \frac{M^{j(t)}}{K_T * M(0)} * 1000 \qquad (44)$$

Gdje je:

M^j (t) – free float tržišna kapitalizacija dionica koje ulaze u CROBEX na dan t i vrijeme j,

M(0) – free float tržišna kapitalizacija na bazni datum, K_t – faktor prilagođavanjaa baze indeksa na dan revizije T.

Da bi dionice bile uključene u CROBEX, trebaju zadovoljiti određene uvjete:

- trgovanje u više od 90% dana ukupnog broja trgovinskih dana u promatranom razdoblju,
- free float tržišna kapitalizacija među prvih 20% dionica poredanih prema free float tržišnoj kapitalizaciji na zadnji dan promatranog razdoblja,
- promet veći od 0,5% ukupnog prometa dionica u promatranom razdoblju.

Tablica 2. Sastav CROBEX-a na dan 27.08.2016.

Simbol	Izdavatelj	Broj dionica	Zadnja cijena (kn)
ADPL-R-A	AD Plastik d.d.	2.729.730	119,0
ADRS-P-A	Adris grupa d.d.	4.014.594	404,1
ARNT-R-A	Arenaturist d. d.	654.750	408,0
ATGR-R-A	Atlantic Grupa d.d.	1.333.720	816,1
ATPL-R-A	Atlantska plovidba d.d.	1.116.416	181,7
BLJE-R-A	Belje d.d. Darda	3.696.969	22,0
DDJH-R-A	Đuro Đaković Holding d.d.	3.038.674	52,9
DLKV-R-A	Dalekovod d.d.	9.887.722	13,0
ERNT-R-A	Ericsson Nikola Tesla d.d.	732.408	1.040,0
HT-R-A	HT d.d.	10.302.628	146,1

[95] www.zse.hr

INA-R-A	INA d.d.	616.433	2.955,0
INGR-R-A	Ingra d.d.	12.867.940	2,5
KOEI-R-A	Končar - Elektroindustrija d.d.	2.057.695	669,9
KRAS-R-A	Kraš d.d.	686.811	515,0
LEDO-R-A	Ledo d.d.	156.960	10.699,8
LKRI-R-A	LUKA RIJEKA d.d.	6.740.238	48,9
MAIS-R-A	Maistra d.d.	1.203.877	234,3
OPTE-R-A	OT-OPTIMA TELEKOM d.d.	28.600.564	1,8
PODR-R-A	Podravka d.d.	4.533.296	365,0
RIVP-R-A	VALAMAR RIVIERA d.d.	60.380.156	29,1
TPNG-R-A	TANKERSKA NEXT GENERATION d.d.	4.366.673	70,0
VART-R-1	Varteks d.d.	1.110.404	18,0
ZABA-R-A	Zagrebačka banka d.d.	12.809.678	42,0

Izvor: www.zse.hr

Revizija indeksa obavlja se po završetku trgovine, svakog trećeg petka u mjesecu ožujku i rujnu te se primjenjuje od sljedećeg trgovinskog dana. U slučaju izvanrednih događaja koji mogu utjecati na realnost i vjerodostojnost indeksa CROBEX u razdoblju između dviju redovitih revizija, Komisija za indeks može izvršiti izvanrednu reviziju načina izračuna indeksa CROBEX, na način da se nekoj dionici u indeksu smanji težina ili da dionicu isključi iz indeksa.

4.3.2. CROBIS

Zagrebačka burza započela je s izračunom CROBIS-a, službenog obvezničkog indeksa Zagrebačke burze 1. listopada 2002 godine. Kao bazni datum utvrđen je 30. rujna 2002 godine, a bazna vrijednost indeksa postavljena je na 100 bodova. CROBIS predstavlja cjenovni indeks ponderiran tržišnom kapitalizacijom, pri čemu težina pojedine obveznice u indeksu ne smije prijeći 35%. Volumen trgovanja u prošlosti bio je veoma slab zbog velike nelikvidnosti, a od tada volumen trgovanja kontinuirano raste. Najviše se trguje državnim obveznicama Republike Hrvatske.

Indeks se računa na kraju svakog trgovinskog dana na način da se koristi prosječna dnevna cijena ponderirana količinom za sve obveznice koje se nalaze u indeksu. U slučaju da se s nekom obveznicom koja je uključena u indeks nije trgovalo tog dana, za izračun indeksa koristi se prosječna dnevna cijena prethodnoga dana odnosno zadnjeg dana kada se tom obveznicom

trgovalo. Matematički prikazano izračun je slijedeći:

$$I_t = I_{t-R} \frac{\sum P_{i,t} * N_{i,t-R}}{\sum P_{i,t-R} * N_{i,t-R}} \qquad (45)$$

Gdje je:

I_t - vrijednost indeksa na dan t,

I_{t-R} - vrijednost indeksa na dan posljednje revizije t-R,

$P_{i,t}$ - čista cijena obveznice i na dan t u %,

$P_{i,t-R}$ - čista cijena obveznice i na dan posljednje revizije t-R,

$N_{i,tR}$ - nominalni iznos izdanja obveznice i dan posljednje revizije t-R ,

n - broj obveznica u indeksu,

R - broj dana od prethodne revizije.

Tablica 3. Sastav CROBIS-a na dan 27.08.2016

Simbol	Nominalni iznos	Valuta	Dospijeće	Kamata	Cijena (kn)
RHMF-O-17BA	4.000.000.000	HRK	25/11/17	6,25	106,54
RHMF-O-187A	6.000.000.000	HRK	10/07/18	5,25	106,73
RHMF-O-19BA	1.000.000.000	EUR	29/11/19	5,38	112,52
RHMF-O-203A	5.000.000.000	HRK	05/03/20	6,75	115,50
RHMF-O-203E	1.000.000.000	EUR	05/03/20	6,50	117,70
RHMF-O-227E	1.000.000.000	EUR	22/07/22	6,50	118,70
RHMF-O-247E	1.400.000.000	EUR	10/07/24	5,75	116,90
RHMF-O-257A	6.000.000.000	HRK	09/07/25	4,50	106,80
RHMF-O-26CA	10.000.000.000	HRK	14/12/26	4,25	105,69

Izvor: www.zse.hr

4.3.3. CROBEX 10

Uz postojeće indekse CROBEX i Crobis, Zagrebačka burza je 2009 godine uvela i novi specijalizirani pokazatelj tržišnog trenda, indeks CROBEX 10. Ovaj indeks je mnogo uži od standardnog CROBEX-a. Indeks CROBEX10 počeo se objavljivati 7. rujna 2009 godine. Bazni datum je 31. srpnja 2009 godine, a bazna vrijednost iznosi 1.000.

Ovaj indeks je vagan na osnovi free float tržišne kapitalizacije, pri čemu je težina pojedine dionice ograničena na 20%. Ukoliko se nekom od dionica koje sačinjavaju CROBEX10 nije trgovalo predmetnog dana, uzima se prethodna zadnja cijena.

Tablica 4. Sastav CROBEX-a 10 na dan 27.08.2016

Simbol	Izdavatelj	Broj dionica	Zadnja cijena (kn)
ADRS-P-A	Adris grupa d.d.	6.444.895	404,10
ATGR-R-A	Atlantic Grupa d.d.	1.333.720	816,10
ERNT-R-A	Ericsson Nikola Tesla d.d.	732.408	1040,00
HT-R-A	HT d.d.	22.317.713	146,10
INA-R-A	INA d.d.	700.000	2955,00
KOEI-R-A	Končar - Elektroindustrija d.d.	2.057.695	669,89
KRAS-R-A	Kraš d.d.	686.811	515,00
LEDO-R-A	Ledo d.d.	156.960	10699,77
PODR-R-A	Podravka d.d.	5.340.002	365,00
RIVP-R-A	VALAMAR RIVIERA d.d.	75.616.525	29,05

Izvor: www.zse.hr

Benić i Franić (2008) dokazali su da je hrvatsko tržište suočeno s viskom razinom nelikvidnosti. Takva nelikvidnost sprečava veći dotok kapitala te čini prepreku u daljnjem razvoju tržišta, što potvrđuje da je likvidnost temeljni čimbenik razvoja tržišta kapitala. Nelikvidnost tržišta očituje se ponajprije u značajnim promjenama cijena dionica, što je sa stajališta transakcijskih troškova velik rizik za investitore.

4.3.4 CROBEXplus

Zagrebačka burza dana 22. veljače 2013 počinje s objavljivanjem novih dioničkih indeksa, a riječ je o indeksu CROBEXplus te ukupno pet sektorskih indeksa.

Indeks CROBEXplus predstavlja tzv. equal weight indeks, u kojem će sve uključene dionice imati jednak udio. Broj dionica bit će neograničen, a u obzir će se uzimati dionice uvrštene na uređeno tržište kojima je broj trgovinskih dana veći od 70% ukupnog broja trgovinskih dana u prethodnom šestomjesečnom razdoblju te free-float tržišna kapitalizacija veća od 10 milijuna kuna.

U sastav sektorskih indeksa moći će ući samo dionice uključene u indeks CROBEXplus, a prvih pet sektorskih indeksa obuhvaćat će sljedeće sektore:

• CROBEXnutris – Proizvodnja i prerada hrane,

• CROBEXindustrija – Industrijska proizvodnja,

• CROBEXkonstrukt – Građevinarstvo,

• CROBEXtransport – Transport,

• CROBEXturist – Turizam.

Tablica 5. Sastav CROBEX-a plus na dan 27.08.2016

Simbol	Izdavatelj	Zadnja cijena (kn)
CROBEXturist		
ARNT-R-A	Arenaturist d. d.	408,00
HIMR-R-A	Imperial d.d.	795,00
MAIS-R-A	Maistra d.d.	234,34
RIVP-R-A	VALAMAR RIVIERA d.d.	29,05
SUNH-R-A	Sunčani Hvar d.d.	24,00
CROBEXindustrija		
ADPL-R-A	AD Plastik d.d.	119,00
DDJH-R-A	Đuro Đaković Holding d.d.	52,90
ERNT-R-A	Ericsson Nikola Tesla d.d.	1040,00
INA-R-A	INA d.d.	2955,00
KOEI-R-A	Končar - Elektroindustrija d.d.	669,89
PTKM-R-A	Petrokemija d.d.	20,00
RIZO-R-A	RIZ-odašiljači d.d.	85,05
VART-R-1	Varteks d.d.	17,99
CROBEXkonstrukt		
DLKV-R-A	Dalekovod d.d.	13,00
INGR-R-A	Ingra d.d.	2,51
CROBEXnutris		
ATGR-R-A	Atlantic Grupa d.d.	816,10
BLJE-R-A	Belje d.d. Darda	22,00
KRAS-R-A	Kraš d.d.	515,00
LEDO-R-A	Ledo d.d.	10699,77
PODR-R-A	Podravka d.d.	365,00
VPIK-R-A	Vupik d.d.	35,99

CROBEXtr		
ADPL-R-A	AD Plastik d.d.	131,00
ADRS-P-A	Adris grupa d.d.	419,10
ARNT-R-A	Arenaturist d. d.	408,00
ATGR-R-A	Atlantic Grupa d.d.	829,60
ATPL-R-A	Atlantska plovidba d.d.	181,70
BLJE-R-A	Belje d.d. Darda	22,00
DDJH-R-A	Đuro Đaković Holding d.d.	52,90
DLKV-R-A	Dalekovod d.d.	13,00
ERNT-R-A	Ericsson Nikola Tesla d.d.	1140,00
HT-R-A	HT d.d.	152,10
INA-R-A	INA d.d.	2955,00
INGR-R-A	Ingra d.d.	2,51
KOEI-R-A	Končar - Elektroindustrija d.d.	681,89
KRAS-R-A	Kraš d.d.	515,00
LEDO-R-A	Ledo d.d.	10699,77
LKRI-R-A	LUKA RIJEKA d.d.	48,90
MAIS-R-A	Maistra d.d.	234,34
OPTE-R-A	OT-OPTIMA TELEKOM d.d.	1,77
PODR-R-A	Podravka d.d.	372,00
RIVP-R-A	VALAMAR RIVIERA d.d.	29,65
TPNG-R-A	TANKERSKA NEXT GENERATION d.d.	73,97
VART-R-1	Varteks d.d.	17,99
ZABA-R-A	Zagrebačka banka d.d.	42,00
CROBEXtransport		
ATPL-R-A	Atlantska plovidba d.d.	181,70
LKPC-R-A	Luka Ploče d.d.	581,26
LKRI-R-A	LUKA RIJEKA d.d.	48,90
TPNG-R-A	TANKERSKA NEXT GENERATION d.d.	70,02
ULPL-R-A	Uljanik Plovidba d.d.	126,60

Izvor: zse.hr

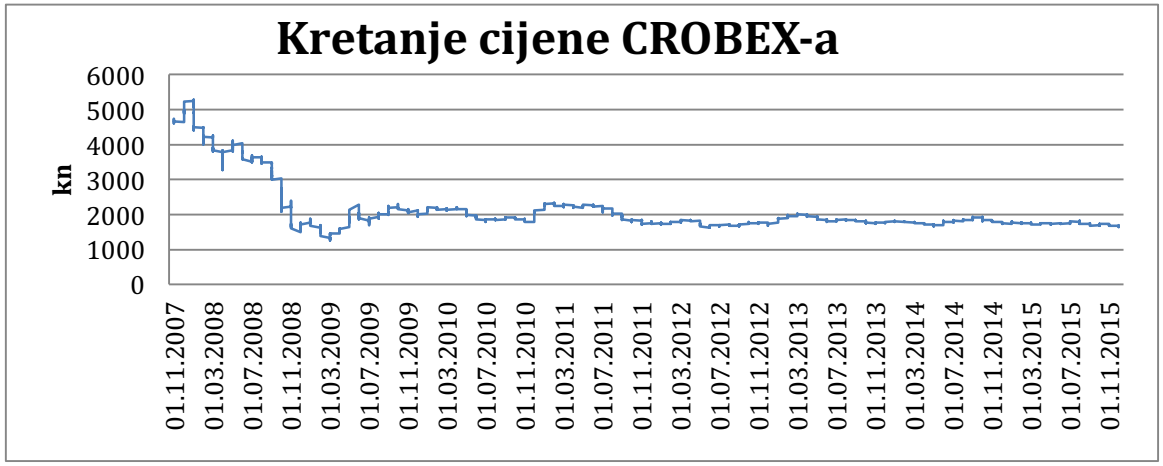
O raspodjeli dionica u sektore odlučuje Odbor za indekse Zagrebačke burze prema Nacionalnoj klasifikaciji djelatnosti (NKD), osim u slučaju procjene kada poslovanje društva primjerenije opisuje sektor drugačiji od onog određenog NKD-om. Temelj za uvođenje sektorskih indeksa

postavljen je s početkom objave podataka o sektorskoj klasifikaciji društava na internetskim stranicama Zagrebačke burze, uz podatke o prometu te tržišnoj kapitalizaciji pojedinog sektora.[96]

4.4. Integracija hrvatskog tržišta kapitala i svjetska financijska kriza

Globalna financijska kriza uvelike je utjecala i na kretanja CROBEX-a. Dinamičnost kretanja hrvatskog tržišta kapitala očituje se ponajviše kroz pad redovitog prometa dionicama koji je 2009 godine prepolovljen u odnosu na 2008 godinu, te kroz pozitivno kretanje cijena najlikvidnijih dionica. Tada je došlo do naglog hlađenja i povlačenja kapitala značajnijih iznosa s Burze i otvorenih investicijskih fondova, što je imalo za rezultat smanjenje prometa na Zagrebačkoj burzi.[97]

Slika 10. Kretanje cijena CROBEX-a od 01.01.2007 do 31.12.2015



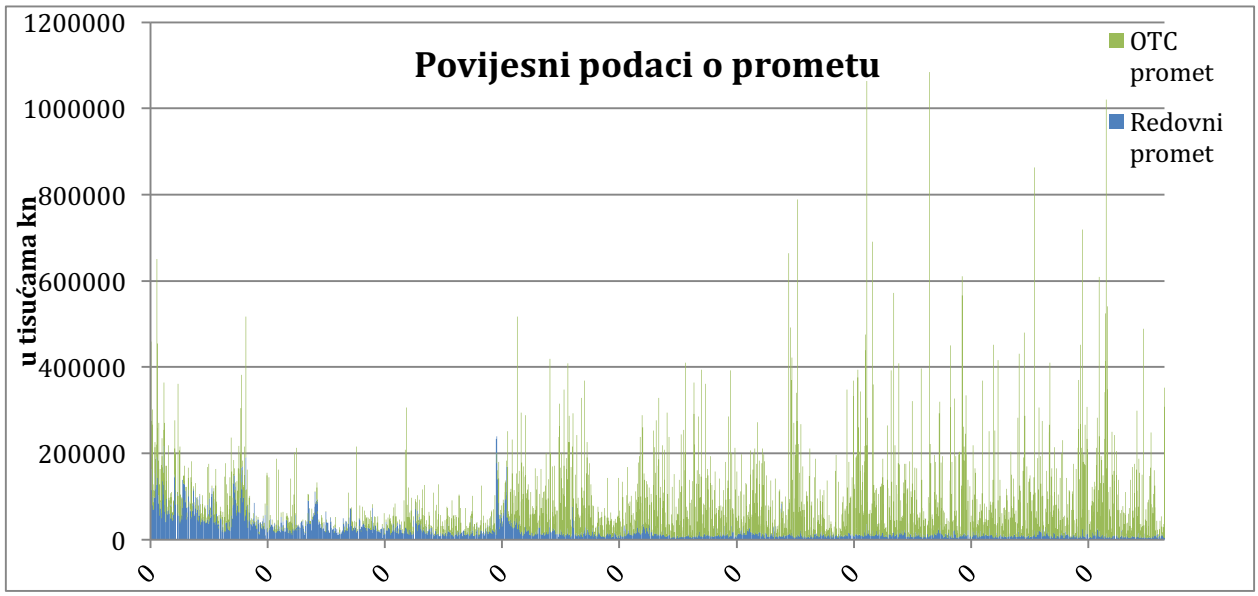
Izvor. zse.hr

Iako je opća percepcija da su cijene dionica zabilježile pad, na kraju godine se pokazalo kako su najlikvidnije dionice od početka 2009 godine porasle sa 16,4%. Promjene cijena i visoka volatilnost CROBEX-a uočljiva je iz činjenice da se CROBEX od najniže do najviše točke kretao u rasponu od gotovo 90%, odnosno između 1.079 i 2.318 bodova (Zagrebačka burza - pregled trgovine, 2009).

[96] www.zse.hr, 20.09.2016.
[97] Sladojević, K. (2010): Model vrednovanja i trgovina izvedenicama i njihova perspektiva u RH, Magistarski rad, Ekonomski fakultet Split, str. 106.

Velik utjecaj na kretanja CROBEX-a, te na likvidnost imao je razvoj otvorenih investicijskih fondova i jačanje uloge mirovinskih fondova. Na tržištu djeluju i četiri obvezna mirovinska fonda te četiri društva za upravljanje dobrovoljnim mirovinskim fondovima, pod čijim je upravljanjem 15 zatvorenih dobrovoljnih mirovinskih fondova i šest otvorenih.[98]

Slika 11. Povijesni podaci o prometu na Zagrebačkoj burzi



Izvor: zse.hr

Uspoređujući podatke od osam godina na Hrvatskoj burzi vidimo da je 2008 godine bio najveći ukupan promet na Zagrebačkoj burzi u iznosu od oko 67 milijarde kn. Trend rasta ukupnog prometa na Zagrebačkoj burzi počeo je 2004 godine, no taj trend je zaustavljen 2008 godine zbog svjetske financijske krize koja se proširila po Europi i Americi te došla i do Republike Hrvatske. Uzroke pada cijena dionica na hrvatskom tržištu kapitala ne možemo tražiti samo u vanjskim čimbenicima poput gospodarskih šokova iz drugih zemalja, već i u unutarnjim čimbenicima kao što su: loša fiskalna politika aktualne vlade, nedovoljne recesijske mjere i općenito nestabilnost gospodarskog sustava.

Recentna literatura suglasna je u mišljenju kako je glavni okidač naglih promjena na razvijenim tržištima kapitala (očekivana) promjena agregatne realne aktivnosti. Uz pretpostavku da cijena dionice reflektira sadašnju vrijednost očekivanih isplata svih budućih novčanih tokova vezanih uz dionicu (tj. dividendi), jasno je da tržišta reagiraju na promjene u realnom poslovnom ciklusu.

[98] Pečarić, M., Arnerić J. Radić M (2012): Komparativna analiza stupnja financijske integracije tržišta kapitala Hrvatske i zemalja CEE s tržištem EU-a Financijska tržišta i institucije Republike Hrvatske u procesu uključivanja u Europsku uniju, Rijeka.

Na primjer, u slučaju kada tržište očekuje pad realne aktivnosti u skoroj budućnosti, očekuje i slabije poslovne rezultate kompanija na burzi te u konačnici i niže profite u vidu smanjenih dividendi. Krajnja posljedica ovog očekivanog pada realne aktivnosti je tako i pad cijene dionice. Iz tog razloga su indeksi burzi često dobri prethodeći indikatori ukupne realne gospodarske aktivnosti.

U prošlosti je dinamika na tržištima kapitala prethodila realnim kretanjima i do nekoliko kvartala unaprijed, dok je posljednjih nekoliko godina sinhroniziranost realnog i financijskog sektora dodatno povećana. Na globalnoj razini, ova veza između realne aktivnosti i tržišta kapitala je postojana dok se na razini pojedine zemlje ona ipak teže utvrđuje. Posebice je to slučaj za mala otvorena gospodarstva, poput hrvatskog, gdje relacije sa vanjskim faktorima u velikoj mjeri utječu na dinamiku domaćih ekonomskih indikatora, kako onih iz realnog sektora tako i na sama financijska tržišta. [99]

Vrlo bitna tržišta kapitala u svijetu u prethodnoj teškoj globalnoj gospodarskoj krizi također prolaze kroz financijske šokove a to su tržišta kapitala tranzicijskih zemalja. Naime, tranzicijske zemlje posjeduju tržišta kapitala koja su još u razvoju i nastoje kroz ova nestabilna ekonomska razdoblja nastaviti s razvojem. Za njih je od egzistencijalne važnosti da liberaliziraju kapitalne tijekove, te olakšaju pristupa stranih financijskih institucija na domaća tržišta i naravno uspostave institucionalna tijela za razvoj financijskog sektora. Neminovno je da zemlje koje su također proizašle iz socijalističkog uređenja gospodarskog sustava a danas su u integraciji s svjetskom trgovačkom silom – Europskom unijom, mogu lakše napredovati upravo zbog toga što je njihovo tržište sada puno veće, te je financijsko pravo usklađeno s onim Europske unije.

Upravo zbog razmjerno loše strategije razvoja hrvatskoga gospodarstva (ili nedostatka strategije) hrvatska je industrija s vremenom postala nekonkurentna i oslonjena na zastarjelu tehnologiju. Veliki su pogoni uglavnom funkcionirali uz potporu države, a uspjeh su ostvarivala manja trgovačka društva, koja su uspjela pronaći tržište za svoje proizvode u inozemstvu. Nebriga nositelja ekonomske politike za razvoj domaće industrije rezultirala je činjenicom da se struktura domaćega robnog izvoza, kao i udio u BDP-u, gotovo i nisu promijenili u posljednjih desetak godina.

Usprkos ponekim, gore navedenim, podacima koji pokazuju oporavak, ipak postaje upitno može li se taj oporavak dugoročno održati, odnosno jesu li programi prilagodbe, prije i za vrijeme

[99] Kunovac, D. (2011): Asimetrične informacije na tržišu kapitala u Hrvatskoj, Institut za javne financije, str. 2-4.

krize, i institucije u Hrvatskoj stvorili čvrstu osnovu ekonomskog rasta. Treba uzeti nekoliko stvari u razmatranje. Prvo, u globalnim okvirima realni i financijski sektor rasti će vrlo sporo, stoga ne treba očekivati da će vanjski šokovi utjecati na Hrvatsko gospodarstvo. Drugo, Hrvatsko gospodarstvo pati od dugoročne strukturne neravnoteže koja, prema svemu sudeći, neće uskoro biti ispravljena. Treće, institucionalne reforme i jaka ekonomska politika predstavljaju preduvjet ekonomskog rasta, stabilnosti i povećanja zaposlenosti neke države.

Konačno, državna liberalna politika bez intervencije u ekonomska pitanja u bliskoj budućnosti neće smanjiti već će stvorit još veću neravnotežu. Tijekom prijašnjih istraživanja petnaestogodišnje makroekonomske problematike u Hrvatskoj i efikasnosti korištenih ekonomskih politka, ekonomisti su predvidjeli da programi prilagodbe sadrže stabilizacijsku komponentu koja nije dovoljni preduvjet ekonomskog rasta, što će primorati Hrvatsku da se suoči sa negativnim poslovnim ciklusima. Uvjeravanja da su programi prilagodbe preduvjet ekonomskog rasta u budućnosti i uspješne tržišne tranzicije nisu točna. Kreatori ekonomskih politika zaboravljaju da stabilizacijski programi moraju sadržavati konzistentne strukturne reforme. Samo na taj način se zemlja, nakon procesa zaustavljanja inflacije, može vratiti na putanju ekonomskog rasta. U Hrvatskoj, strukturne reforme nisu bile sastavni dio stabilizacijskog procesa što je ograničilo mogućnost budućeg ekonomskog razvoja. Nekoliko godina nakon implementacije stabilizacijskog programa država nije mogla zaustaviti odljev sredstava iz proračuna namijenjen za poduzetništvo, pomoć riješavanja problema u bankarskom sektoru i ostaloj neprioritnoj javnoj potrošnji. Fiskalna disciplina bila je zapostavljena rezultirajući nekontroliranom povećanju javnih izdataka. Povećanje javnih izdataka bilo je praćeno smanjenjem javnih kapitalnih investicija što predstavlja potpuno zapostavljanje proračunskog zlatnog pravila. Uvođenjem visokih poreznih obveza s ciljem podmirenja javne potrošnje uzrokovalo je nesolventnost realnog sektora. Iz navedenih razloga, pokušaji provođenja strukturnih reformi u Hrvatskoj nisu doprinijeli izgradnji institucija koji potiču tržišni mehanizam. To je stvorilo ekonomsku klimu u kojem je izgradnja i upravljanje uspješnih poduzeća postala teška zadaća.

5. ANALIZA UTJECAJA RAČUNOVODSTVENIH I MAKROEKONOMSKIH PODATAKA NA TRŽIŠNO DJELOVANJE CIJENE DIONICA

U ovom dijelu rada će biti sadržana metodologija istraživanja vezana uz oblikovanje modela kojeg testiramo na tržištu kapitala. Prije iznošenja rezultata ekonometrijskog testiranja modela objašnjeni su priroda i izvori korištenih podataka, te način prikupljanja i selekcija uzorka. Istraživački dio rada završava testiranjem podataka, prikazivanjem rezultata u tablicama, te analizom tako dobivenih rezultata.

5.1. Oblikovanje modela za ocjenu utjecaja makroekonomskih podataka na tržišno vrednovanje dionica

Investicijski rizik može se promatrati kroz dvije komponente: sistemski tržišni rizik, koji ovisi o promjenama u makroekonomskom okruženju, i nesistemstki rizik koji može biti smanjen ili čak eliminiran.

Modeli koji su temeljni na APT teoriji, za razliku od CAPM modela, polazi od toga da sistemski rizik je ono što utječe na cijene vrijednosnica na tržištu. Za razliku od CAPM modela, ATP model prihvaća postojanje nekoliko sistemskih rizika koji mogu utjecati na vrijednost dionice. Međutim, jedan od glavnih nedostataka ATP modela je što nije unaprijed definirano koji su faktori koji utječu na sistemski rizik i koliko ih ima.

Pri odabiru makroekonomskih varijabli koje su korištene u empirijskom istraživanju korištene su varijable iz sličnih studija (Benaković i Posedel (2010), Hsing (20122), Chen, Roll i Ross (1986).

CROBEX, kao nezavisna varijabla, je reprezentativni indeks cijena dionica. Podaci su mjesečni u razdoblju od siječnja 2011 do studenog 2015. CROBEX, službeni indeks Zagrebačke burze, koji sadrži 25 dionica. Mjesečni tržišni indeks izračunat je prema sljedećoj formuli:

$$\mathrm{MI_t} = \log \mathrm{CROBEX_t} - \log \mathrm{CROBEX_{t-1}} \quad (47)$$

Gdje je:

$\mathrm{MI_t}$ - mjesečna promjena tržišnog indeksa u mjesecu *t*,
$\mathrm{CROBEX_t}$ - je tržišni indeks u mjesecu *t* i
$\mathrm{CROBEX_{t-1}}$ - je tržišni indeks prethodnog mjeseca.

Kamatna stopa korištena u ovom radu je tromjesečna ZIBOR (Zagreb Interbank Offered Rates), referentna kamatna stopa u hrvatskom međubankarskom tržištu. Službena kalkulacija ZIBOR-a svakodnevno se objavljuje na Reuters system kao aritmetička sredina kamatnih stopa osam najvećih hrvatskih banaka. Mjesečna kamatna stopa računa se pomoću prosjeka dnevnih kamatnih stopa:

$$\mathrm{IR_t} = 3 - \text{month ZIBOR u mjesecu } t \quad (48)$$

Podaci o industrijskoj proizvodnji za potrebe ovog istraživanja su uzeti s EUROSTAT-a koristeći sljedeću formulu za analizu mjesečne promjene industrijske proizvodnje:

$$\mathrm{IP_t} = \log \mathrm{IP_t} - \log \mathrm{IP_{t-1}} \quad (49)$$

Gdje je:

$\mathrm{IP_t}$ - industrijski indeks proizvodnje u mjesecu *t* i
$\mathrm{IP_{t-1}}$ - industrijski indeks proizvodnje u mjesecu *t* u odnosu na prethodni mjesec.

Za istraživanje inflacije upotrebljeni su podaci o harmoniziranom indeksu potrošačkih cijena s Državnog zavoda za statistiku. Mjesečne promjene u HICP dane su sljedećom formulom:

$$\mathrm{HICP_t} = \log \mathrm{HICP_t} - \log \mathrm{HICP_{t-1}} \quad (50)$$

Gdje je:

$HICP_t$ - harmonizirani indeks potrošačkih cijena u mjesecu t i
$HICP_{t-1}$ - harmonizirani indeks potrošačkih cijena u mjesecu t u odnosu na prethodni mjesec.

Metodologija koja će se koristi za analizu utjecaja makroekonomskih varijabli na kretanje cijena dionica (CROBEX-a) je vektorska autoregresijska analiza (VAR) i Grangerova kauzalnost, te PANEL analiza. Glavni cilj navedenih metoda je utvrditi da li promjena makroekonomskih varijabli dovodi do promjena u cijenama dionica. Također, želi se utvrditi s kojim pomakom makroekonomske varijable imaju najjači utjecaj na nezavisne varijable.

Model vektorske autoregresije (VAR) može se promatrati kao generalizacija autoregresijskih modela. Ukoliko pođemo od pretpostavke da se vektorska vremenska serija X_t može predstaviti pomoću VAR modela dimenzije m i reda k na sljedeći način:

$$X_t = \beta_1 X_{t-1} + \beta_2 X_{t-2} + \cdots + \beta_k X_{k-t} + e_t \qquad (51)$$

pri čemu su sa β_1 , β_2 ,..., β_k označene matrice parametara dimenzije m×m dok e_t predstavlja vektorski slučajni proces (bijeli šum). Prema prethodnoj generalnoj jednadžbi VAR modela za potrebe ovog istraživanja koristi će se sljedeća jednadžba:

$$MI_{it} = a_0 + a_1 HICP_{it} + a_2 IP_{it} + a_3 ZIBOR_{it} + e_t \qquad (52)$$

Gdje je:

MI_{it} - prosječni iznos CROBEX-a u mjesecu *t*,
$HICP_{it}$ - harmonizirani potrošački indeks cijena u mjesecu *t*,
IP_{it} - industrijska proizvodnja u mjesecu *t*,
$ZIBOR_{it}$ - mjesečna kamatna stopa u mjesecu *t* i
e_t - ostale vrijednosno važne informacije u mjesecu *t*.

U empirijskom dijelu rada biti će korišteni modeli i metode analize vremenskih nizova, jer su vrijednosti varijabli opažene u domeni vremena, i to u jednako udaljenim vremenskim točkama. Naime, modeli koji se analiziraju u vremenskoj domeni su najčešće linearni stohastički modeli,

kojima se opisuju stacionarni procesi, tj. stacionarni vremenski nizovi. Vremenski niz je stacionaran ako ima konstantno očekivanje, konstantnu i konačnu varijancu, a kovarijanca između razmaknutih članova niza je funkcija samo njihove vremenske udaljenosti (pojam stacionarnosti u širem smislu). Dakle, važno je ispitati da li je vremenski niz stacionaran ili nestacionaran.

Vremenski niz koji slijedi proces slučajnog pomaka (engl. random walk) je tipičan primjer nestacionarnog vremenskog niza. Takav vremenski niz je nestacionaran i kaže se da isti sadrži tzv. stohastički trend. Stoga, da bi se postigla stacionarnost vremenskog niza najčešće se koriste prve diferencije ili ponekad i diferencije višeg reda. Ako se prvim diferencijama može postići stacionarnost niza tada se kaže da je vremenski niz integriran reda jedan, a ako se stacionarnost niza postiže drugim diferencijama tada se kaže da je vremenski niz integriran drugog reda. Dakle, u radu su korištene varijable u prvim diferencijama.

U nastavku donosimo pregled deskriptivne statističke analize varijabli.

Tablica 6. Deskriptivna statistička analiza

Varijable	**N**	**Aritmetička sredina**	**Standardna devijacija**
Inflacija	59	0,12	0,46
ZIBOR	59	5,89	0,55
Industrijska proizvodnja	59	94,34	3,04
CROBEX	59	1.844,65	167,12

Izvor: autor

Za specificiranje VAR modela potrebno je utvrditi odgovarajući broj pomaka. Uobičajeno postoji preporuka u literaturi da se kod specificiranja broja vremenskih pomaka odabire onaj broj pomaka koji je potreban da bi reziduali slijedili u potpunosti slučajan proces. Postoje različite metode koje se koriste za odabir vremenskih pomaka, a u ovom slučaju korišten je Akaike kriterij.[100] Na temelju testova o primjerenosti modela s različitim vrijednostima pomaka vrijednost pomaka k = 2 (najmanja vrijednost AIC-a), dobivena AIC kriterijem,

[100] Za više vidi Bahovec, V. i Erjavec, N. (2009): Uvod u ekonometrijsku analizu, Elemental d.o.o., Zagreb., I. izdanje, str. 339.

pokazala se optimalnom. Vrijednosti Akaike kriterija za različite vrijednosti vremenskih pomaka prikazane su u tablici br. 7.

Tablica 7. Određivanje vremenskih pomaka u VAR modelu

Vremenski pomaci	**AIC**
0	24,99321
1	20,22989
2	20,28816
3	20,43086
4	20,68068

Izvor: autor

Pojam uzročnosti (Grangerov test) podrazumijeva mogućnost jedne varijable da predvidi dinamiku druge varijable. Naime, ako se želi ispitati uzrokuje li pojava X pojavu Y, problem se svodi na ispitivanje koliki se dio dinamike varijable Y u tekućem razdoblju može objasniti dinamikom same varijable u prethodnim razdobljima i hoće li dinamika pojave Y bolje objasniti ako se u analizu dodaju prethodne vrijednosti varijable X. Naime, kaže se da X uzrokuje Y ako varijabla X poboljšava predikciju varijable Y. Sa statističkog gledišta tvrdnja je ekvivalentna statističkoj značajnosti svih pomaka varijable X u jednadžbi dinamike varijable Y. Ovaj oblik uzročnosti naziva se uzročnost u Grangerovom smislu.

Tablica 8. Grangerov test kauzalnosti
Uzorak 2011M1 – 2015M11
Broj ospervacija 59

Varijable	Inflacija	ZIBOR	Industrijska proizvodnja	CROBEX
Inflacija			2,963	
ZIBOR			1,172	
Industrijska proizvodnja	2,77			6,187
CROBEX		0,675	1,542	

Izvor: autor

*Crvena boja označava signifikantnost pri razini od 1%, plava pri razini od 5%, a crna pri razini od 10%.

Pri razini od 1% signifikantnosti promjena indeksa cijena CROBEX-a utječe na promjenu industrijske proizvodnje. Smanjenje ili povećanje industrijske proizvodnje utječe na promjenu potrošačkog indeksa cijena pri razini od 5% signifikantnosti. Također ista razina značajnosti vrijedi i u suprotnom smjeru djelovanja, odnosno promjena vrijednosti inflacije utječe na promjenu industrijske proizvodnje. Na razini od 10% značajnosti u analizu ulaze slabije veze, ali još uvijek snažne kauzalnosti između varijablama. Promjena kamatne stope ZIBOR-a i industrijske proizvodnje utječu na promjenu indeksa cijena dionica CROBEX-a pri razini od 10%.

Tablica 9. Dekompozicija varijance modela

		Razdoblje (mjeseci)	
		1	2
Utjecaj na CROBEX	Inflacija	-2,4399	-0,4365
	ZIBOR	90,4769	74,9191
	Industrijska proizvodnja	7,8290	18,4530

Izvor: autor

Na temelju prethodne tablice možemo može se primijetiti kako utjecaj kamatne stope ZIBOR nakon jednog mjeseca objašnjava čak 90,47% varijacije prognostičke varijable CROBEX-a, dok je taj postotak nakon dva mjeseca nešto manji ali i dalje visokih 74,92%. Industrijska proizvodnja nakon mjesec dana objašnjava 7,83% promjene indeksa CROBEX-a, dok veći utjecaj ima nakon dva mjeseca odmaka (18,45%). Makroekonomska varijabla harmonizirani indeks potrošačkih cijena (HICP) gotovo nema nikakav utjecaj na CROBEX u promatranom razdoblju od 2011-2015 godine.

Popularnost panel analize nije začuđujuća zbog toga što istovremeno uzima u obzir vremensku i prostornu komponentu. U panel analizi korišten je model statički združeni panel model.[101] Za analizu su korištene identične varijable kao i za vektorsku autoregresiju.

$$CROBEX= 145,89 +15,945Q – 68,636ZIBOR_{it} \quad (50)$$

[101] Za više vidi Škrabić Perić, B. (2012): Utjecaj stranog vlasništva banke na njezin kreditni rizik u zemljama srednje i istočne Europe: dinamički panel modeli, Ekonomski fakultet u Splitu.

Regresijski koeficijent industrijske proizvodnje β1= 15,945 tumači se na način ako se industrijska proizvodnja poveća za jedan posto, indeks cijena dionica će se povećati za 15,945%. Ukoliko kamatna stopa ZIBOR poraste za jedan posto, indeks cijena dionica CROBEX smanjit će se za 68,636%. Industrijska proizvodnja i ZIBOR za analizirano razdoblje su statistički značajni pri razini od 1%. Makroekonomska varijabla inflacija u Panel analizi nije statistički značajna. Koeficijent determinacije iznosi 0,609 te se tumači da je 60,9% promjene zavisnih varijabli objašnjeno promjenom CROBEX-a.

U analizu Pearsonove korelacije analiziane se slijedeće varijable: cijena CROBEX-a, stopa rasta BDP-a, realni BDP (2010=100) i prognostički BDP. Podaci su analizirani kvartalno od 2011 do 2015 godine te su podaci o BDP-u preuzeti su s Državnog zavoda za statistiku te za CROBEX s Zagrebačke burze. Jedinu pozitivnu korelaciju pokazuje veza između stope rasta BDP-a i prognostički BDP (0,62) pri signifikantnosti od 1%.

S istim podacima analizirana je regresije pri čemu je zavisna varijabla indeks cijena dionica CROBEX. Dobivena jednadžba glasi:

CROBEX = 12.136,13 – 5,04 realniBDP + 0,07 prognostičkiBDP +48,91 stopa rastaBDP-a

Pri čemu treba naglasiti da od svih nezavisnih varijabli samo prognostički BDP je statistički signifikantan pri razini od 10%, te možemo zaključiti kako povećanje prognostičkog BDP-a po stanovniku za jedan dolar dovodi do povećanja tržišnog indeksa cijena CROBEX za 0,07 kn.

Razlog što ostale analizirane varijable su statistički nesignifikantne može se nalaziti u tome da tromjesečne podatke o BDP-u Državni zavod za statistiku objavljuje uz značajan vremenski pomak. Primjerice, prva se procjena objavljuje tek dva mjeseca nakon isteka tromjesečja i stoga je teško u realnom vremenu precizno ocijeniti stanje u kojem se gospodarstvo zaista nalazi. Nadalje, drugi razlog je mala tržišna kapitalizacija te provedba ovakvih istraživanja na Zagrebačkoj burzi jer je sastav indeksa heterogen koji otežava donošenje zaključka. Kao rezultat spomenute heterogenosti, dobiveni koeficijent determinacije modela je nizak i pojedine varijable nisu statistički značajne.

5.2. Oblikovanja modela za ocjenu utjecaja financijskih informacija na tržišno vrednovanje cijene dionica

Pri definiranju uzorka za istraživanje u Hrvatskoj korištene su računovodstvene informacije bazirane na uzorku korporacija koje kotiraju na burzama kao što je primijenjeno i u prethodnim istraživanjima.[102] Sukladno s time, u istraživanje u obuhvaćena samo one dionice koje kotiraju na Zagrebačkoj burzi. Zagrebačka burza obuhvaća različita tržišta dionica. Krajem 2014 godine tržište su sačinjavala: službeno tržište (23 dionice), tržište javnih dioničkih društava (150 dionica) te usporedno tržišta (30 dionica).

Premda je krajem 2014 godine na Zagrebačkoj burzi bilo uvršteno 203 vrijednosna papira[103] velikim dijelom tih dionica se nije trgovalo. Kako bi analizu napravili s što kvalitetnijim podacima osnovni skup ograničen je na samo ona trgovačka društva s kojima se aktivno trgovalo tijekom 2014 godine. U istraživanje uzeta su samo one dionice s kojima se trgovalo svake godine između 2010 i 2014 godine. Radi selekcije korišten je jednostavan kriterij – promet dionicama na Zagrebačkoj burzi tijekom zadnje analizirane godine 2014. Subjektivnom analizom autora istraživanja u uzorak su uključeno samo one dionice korporacija koje su tijekom 2014 godine ostvarili promet minimalno 20.000.000 kuna. Prilikom intrepretiranja rezultata i donošenja zaključka bitno je voditi računa bi drugačiji kriterij možda doveli do drugačijih zaključaka. Formiranje uzoraka prema navedenom načeli selekcije prikazano je sljedećom tablicom:

Tablica 10. Formiranje uzorka iz osnovnog skupa

	ZSE - 2014
Broj dioničkih društava na službenom tržištu	23
Broj dioničkih društava na ostalim tržištima	180
Ukupan broj dioničkih društava na burzi	203
Dionička društva s prometom višim od 20.000.000 kn	34
Postotak osnovnog skupa	17%

Izvor: www.zse.hr

[102] Pervan, I., Vasilj, M. (2009): Vrijednosna važnost glavnice i dobiti - empirijska analiza za hrvatske korporacije sa zagrebačke burze, Ekonomska istraživanja : znanstveno-stručni časopis - Pula : Sveučilište "Jurja Dobrile" u Puli, Vol. 22, 4, str. 41-51.

[103] Zagrebačka burza (2015): Pregled trgovine u 2014. godini, Zagrebačka burza, str. 3-22.

Tablica prikazuje da odabrani uzorak obuhvaća 17% populacije svih korporacija koje su kotirala na Zagrebačkoj burzi tijekom 2014 godine. U 2014 godini na ZSE su kotirale 34 dionica koji su zadovoljile kriterij. Konačan broj analiziranih dionica je umanjen za dodatnih četiri dionice budući da se s njima nije trgovalo u razdoblju od 2010 do 2013 godine.

U istraživanje se kao model vrednovanja korporacije primjenjuje F-O model koji je korišten u većini studija opisanih u poglavlju 2 ovog rada. Prema navedenom modelu vrijednost korporacije se izražava kao funkcija knjigovodstvene glavnice i diskontiranih očekivanih abnormalnih dobitaka, pri čemu se abnormalni dobiti definiraju kao dobitci koji premašuju zahtijevani povrat na glavnicu. Stoga, F-O model izražava vrijednost korporacije kao funkciju dobiti i glavnice:[104]

$$P_{it} = a_0 + a_1 E_{it} + a_2 BV_{it} + e_{it} \quad (53)$$

$$P_{it} = b_0 + b_1 E_{it} + e_{it} \quad (54)$$

$$P_{it} = c_0 + c_1 BV_{it} + e_{it} \quad (55)$$

Gdje su:

P_{it} - cijena dionice tri mjeseca[105] nakon kraja fiskalne godine t,
E_{it} - dobit po dionici u godini t,
BV_{it} - knjigovodstvena vrijednost glavnice po dionici na kraju godine t i
e_{it} - ostale vrijednosno važne informacije u godini t.

U ovom radu primjeniti će se metodu koju su koristili Collins et al. (1997) za usporedbu eksplanatorne moći glavnice i dobiti, gdje se ukupna eksplanatorna moć glavnice i dobiti mjerena koeficijentom determinacije (R^2) dijeli na sljedeće tri komponente:

- inkrementalna eksplanatorna moć dobiti
- inkrementalna eksplanatorna moć glavnice.
- inkrementalna eksplanatorna moć zajedno dobiti i glavnice.

[104] Feltham, G., Ohlson. J.,A. (1995): Valuation and Clean Surplus Accounting for Operating and Financial Activities, Contemporary Accounting Research, str. 689-731.
[105] Cijene dionica se u studijama vrijednosne važnosti uzimaju na zadnji dan kada se izvještaji moraju prezentirati ulagačima na burzi, te je u Hrvatskoj riječ o koncu ožujak (31.03.). Cijene dionica uzete u ovom radu su na onaj dan kada su financijski rezultati korporacije obvaljeni na Internet stranici Zagrebačke burze.

U radu se analizira vrijednosna važnost glavnice i dobiti u tržišnom vrednovanju korporacija, što znači da su glavnica i dobit nezavisne varijable dok je cijena dionica zavisna varijabla. Sve varijable su mjerene po dionici, a podaci o dobiti i vrijednosti glavnice su preuzeti iz godišnjih financijskih izvještaja dioničkih društava za 2010, 2011, 2012, 2013 i 2014 godinu. Zavisna varijabla cijena dionica preuzeta je s Zagrebačke burze. Deskriptivna statistika za varijable prikazana je u narednoj tablici.

Tablica 11. Deskriptivna statistika za varijable iz uzorka

Deskriptivna statistika - aritmetička sredina						
Varijable	2010.	2011.	2012.	2013.	2014.	Prosjek
Cijena dionice (P)	2.583,56	2.163,83	2.872,17	3.257,24	4.234,57	3.022,27
Dobit (E)	30,56	17,54	11,37	5,83	6,34	14,33
Knjigovodstvena vrijednost glavnice (BV)	2.114,66	2.204,30	2.591,31	3.140,15	3.303,65	2.670,81

Izvor: autor

P - cijena dionice na dan 31.03. odnosno 3 mjeseca nakon završetka fiskalne godine.
E - dobit po dionici u godini t, izračunate kao omjer neto dobiti i broja dionica.
BV - knjigovodstvena vrijednost glavnice, izračunata kao omjer ukupne glavnice i broja dionica.

Za specificiranje Grangerove kauzalnosti modela potrebno je utvrditi odgovarajući broj pomaka.[106] Na temelju Akaike kriterija o primjerenosti modela s različitim vrijednostima pomaka vrijednost k = 1, dobivena AIC kriterijem, pokazala se optimalnom za računovodstvene varijable.

[106] Za više vidi Bahovec, V. i Erjavec, N. (2009): Uvod u ekonometrijsku analizu, Elemental d.o.o., Zagreb., I. izdanje, str. 339.

Tablica 12. Grangerov test kauzalnosti

Uzorak 2010-2014.

Broj opservacija 30

Godine	2010			2011			2012			2013			2014		
Varijable	**Cij. dionica**	**Dobit**	**Knjigov. vrijed.**	**Cij. dionica**	**Dobit**	**Knjigov. vrijed.**	**Cij. dionica**	**Dobit**	**Knjigov. vrijed.**	**Cij. dionica**	**Dobit**	**Knjigov. vrijed.**	**Cij. dionica**	**Dobit**	**K**
Cij. dionica					4,31819	7,36723			8,84403			1,77306			
Dobit	2,36388			8,80415			5,0023			1,17380					
Knjigov. vrijed.	4,82619			5,45345				2,58570					1,48174	0,29890	

Izvor: autor

*Crvena boja označava signifikantnost pri razini od 1%, plava pri razini od 5%, a crna pri razini od 10%.

Rezultat Grangerove analize su standardni F-testovi koji označavaju odbacivanje nulte hipoteze pri razinama empirijske signifikantnosti od 1, 5 i 10%. U 2010 godine pri razini od 5% signifikatnosti cijena dionice utječe na dobit i knjigovodstvenu vrijednost. U sljedećoj analiziranoj godini, 2011 cijena dionica pri značajnosti od 1% implicira promjenu dobiti. Također odnos u 2011 godini je obostran, te i dobit utječe na cijenu dionica. U istoj analiziranoj godini imamo još jedan obostrani utjecaj dvaju varijabli, knjigovodstvene vrijednosti i cijene dionica koje su u oba slučaja značajne pri razini od 10%. U 2012 godini promjena knjigovodstvene vrijednosti dionica korporacije značajno implicira promjenu cijene dionica. Cijena dionice u 2012 godini utječe na promjenu dobiti pri razini od 5%. U istoj analiziranoj godini imamo također i vezu između dobiti i knjigovodstvene vrijednosti. U 2013 godini veza između knjigovodstvene vrijednosti i cijena dionica je značajna pri razini od 5% te cijena dionica pri razini od 10% utječe na dobit. Promjena dobiti u 2014 godini utječe na promjenu knjigovodstvene vrijednosti pri razini od 5% statističke značajnosti, dok pri razini od 10% signifikatnosti cijena dionica implicira promjenu knjigovodstvene vrijednosti.

Tablica 13. Rezultati analize vrijednosti dobiti za uzorak dionica listanih na ZSE

Godina	b_1	R^2_E	t- omjeri	Signifikantnost
2010.	0,988	0,678	78,656	0,000
2011.	0,269	0,657	1,481	0,100
2012.	0,060	0,774	0,319	0,001
2013.	0,026	0,543	0,137	0,345
2014.	0,175	0,583	0,943	0,354

Izvor: autor

**Regresijski model:* $P_{it} = b_0 + b_1 E_{it} + e_{it}$

Kao što je prikazano u prethodnoj tablici, regresijski koeficijenti su pozitivni i signifikantni u svih pet promatranih godina što znači da dobit ima informacijski sadržaj i da je značajno povezan s dionicama. Koeficijenti determinacije tj. eksplanatorna moć modela je u svim godinama veća od 50%, što znači da dobit objašnjava cijenu dionica u promatranom razdoblju i uzorku. Najviši postotak je u 2012 godini kada iznosi 77%. Regresijski model je signifikantan pri razini od 1% u 2010 i 2013 godini, u 2011. godini pri razini od 10% dok u posljednjim dvjema analiziranim godinama model nije statistički značajan.

Tablica 14. Rezultati analize vrijednosne važnosti glavnice za uzorak dionica listanih na ZSE

Godina	b_1	R^2_E	t- omjeri	Signifikantnost
2010.	1,125	0,765	0,149	0,001
2011.	0,026	0,580	0,538	0,050
2012.	0,082	0,778	0,434	0,050
2013.	0,341	0,683	1,920	0,065
2014.	0,089	0,890	0,473	0,000

Izvor: autor

*Regresijski model: $P_{it}= c_0 + c_1BV_{it} + e_{it}$

Kod knjigovodstvene vrijednosti rezultati su statistički značajniji u odnosu na dobit. Eksplanatorna moć knjigovodstvene vrijednosti glavnice u svim analiziranim godinama je više od 55%. Oko 58% knjigovodstvene vrijednosti glavnice u 2011 godini objašnjava cijenu dionica u uzorku, što je ujedno i najmanji postotak. U posljednjoj analiziranoj godini, 2014 taj postotak iznosi 89%. Promatrani model je statistički značajan pri razini od 1% u 2010 i 2014 godini. U ostalim godinama statistički signifikantnost je slabija ali model ipak dokazuje povezanosti među varijablama.

Tablica 15. Rezultati analize vrijednosne važnosti dobiti i glavnica za uzorak dionica listanih na ZSE

Godina	a1	a2	R^2_E	VIF
2010.	0,872	1,091	0,653	3,899
2011.	0,675	0,234	0,678	2,131
2012.	0,547	0,629	0,587	3,231
2013.	0,254	0,481	0,428	4,871
2014.	0,643	0.585	0,769	2,160

Izvor: autor

*Regresijski model: $P_{it}= a_0 + a_1E_{it} + a_2BV_{it} + e_{it.}$

**Regresijski koeficijenti su u prve tri godine statistički značajni na razini od 5%, te u 2014. godini od 1%.

Iz prethodne tablice možemo zaključiti da su dobit i glavnica, zajedno analizirajući, povezane s kretanjima cijena dionica na tržištu kapitala. Naime, rezultati analize regresijskog modela koji kombinira obje varijable pokazuju pozitivnu i značajnu vezu između računovodstvenih varijabli i cijena dionica u promatranom razdoblju. Korigirani koeficijent determinacije pokazuje da dobit i glavnica tijekom petogodišnjeg razdoblja imaju

visoki postotak objašnjavanja promjene cijena dionica. Koeficijent je najviši u 2014 godini (76,9%) a najniži u 2013 godini koja jedina nije statistički značajna. Rezultati, dakle, ukazuju na visoku objašnjenost modela, a model je signifikantan na razini od 5% u periodu od 2010 - 2012 godine te na razini od 1% u 2014 godine. Naime, budući da nijedan VIF nije veći od 5 (za 2006 godinu VIF[107] iznosi 2,397, a za 2007 - 2,773), može se zaključiti da multikolinearnost u promatranom regresijskom modelu nije značajan problem.

[107] Ako su VIF-ovi manji od 5 može se zaključiti da problem multikolinearnosti nije značajan.

6. ZAKLJUČAK

Svrha ovog istraživanja je potvrditi koliko stanje Hrvatskog gospodarstva utječe na kretanje cijena dionica na tržištu kapitala. Rezultati znanstvenih istraživanja prezentirani u ovom radu impliciraju doprinos u praktičnom smislu. U dijelu rada koji ispituje utjecaj makroekonomskih podataka na rezultate kretanja cijene dionice uzeto je razdoblje na mjesečnoj bazi od siječnja 2011 godine do studenog 2015.godine i to za 15 dionica CROBEX-a čije su prosječne cijene dionica bile listane na Zagrebačkoj burzi. Prilikom formiranja uzorka kod istraživanja utjecaja računovodstvenih informacija na kretanje cijena dionica uzete su dionci kojima se trgovalo svake godine između 2010 i 2014 godine te je kao kriterij selekcije bio 20.000,00 kn minimalnog godišnjeg prometa. Konačan broj dionica na kraju selekcijskog postupka iznosio je 34.

Primjena rezultata istraživanja širokih je razmjera. Rezultati istraživanja prikazani u ovom radu mogu biti od koristi brojnim institucijama te individualnim ulagačima, koji bi htjeli ostvariti bolje rezultate na tržištu kapitala. Značaj predviđanja kretanje cijene dionice izražen je u svim financijskim institucijama uključivši banke, investicijske i mirovinske fondove, osiguravajuća društva i brokerske kuće. Svi ulagači svjesni su činjenice koliko im je za uspješno i kvalitetno poslovanje, te ostvarivanje što veće dobiti, potreban model koji će im bar donekle predvidjeti kretanje cijena pojedinih vrijednosnica.

Uz Garnegerovu kauzalnost, testirana su tri modela i to utjecaj dobiti na cijenu dionica, utjecaj knjigovodstvene vrijednosti na kretanje cijene dionica i zajednički utjecaj dobiti i knjigovodstvene vrijednosti na cijenu dionica. Dobit je utjecala na cijenu dionica u 2010, 2011, te posebno 2012 godine, dok su knjigodovodstvene vrijednosti statistički znjačajno utjecale na cijenu dionica u svim analiziranim godinama. Obostrani utjecaj dobiti i knjigovodstvene vrijednosti jedino nije signifikantan u analiziranoj 2013 godini. Sukladno tome u ovom dijelu istraživanja može se kao istinita prihvatiti hipoteza da su računovodstvene informacije statistički značajno povezane s kretanjem cijena dionica može potvrditi.

Makroekonomski pokazatelji kamatna stopa ZIBOR, industrijska proizvodnja te inflacija analizirane su kao zavisne varijable koje utječu na kretanje cijene dionica CROBEX-a na osnovi mjesečnih podataka u razdoblju od siječnja 2011 godine do studenog 2015 godine. Temeljem provedenih triju različitih testova, dva testa pokazuju kako promjene kamatne stope ZIBORA-a i industrijske proizvodnje statistički značajno utječu na promjenu cijene dionica CROBEX-a te stopa može se prihvatiti i drugu radnu hipotezu, odnosno da je kretanje cijene

na tržištu kapitala u ovisnosti s makroekonomskim pokazateljima.

Kao i svako empirijsko istraživanje provedeno na financijskim tržištima u razvoju, tako ni ovo nije lišeno određenih nedostataka koji dijelom proizlaze iz karakteristika takvih tržišta, a dijelom i uslijed potrebe prilagodbe uobičajene metodologije istraživanja. Glavni nedostatak vezan je uz formiranje uzorka. Provedba ovakvih istraživanja na Zagrebačkoj burzi ograničena je uglavnom na dionice u sastavu burzovnog indeksa koji je po svojoj definiciji heterogen jer se regresijskom analizom svim dionicama pripadaju jednaki ponderi važnosti. Međutim, neovisno o navedenim nedostatcima ovo istraživanje utjecaja mikroekonomskih i makroekonomskih varijabli na cijenu dionica može predstavljati novi utjecaj za daljnja istraživanja.

SAŽETAK

Cilj ovog istraživanja bilo je testiranje veze između računovodstvenih informacija i makroekonomskih podataka s cijenom dionica na hrvatskom tržištu. Istraživanje je provedeno na uzorku korporacija sa Zagrebačke burze, koji je obuhvatio 34 korporacije u razdoblju od 2011-2015 te CROBEX, ZIBOR, inflaciju i BDP za makroekonomsko istraživanje. Rezultati istraživanja pokazuju da su računovodstvena dobit i glavnica promatrani skupno i pojedinačno statistički značajno i pozitivno povezani s cijenama dionica u svim analiziranim godinama s izuztekom 2013. Na tržišni indeks CROBEX najznačajniji utjecaj ima ZIBOR, industrijska proizvodnja i predviđeni BDP. Rezultati istraživanja pokazuju da su računovodstvene informacije i makroekonomski podaci na hrvatskom tržištu kapitala vrijednosno važne, a dobiveni podaci su usporedivi s rezultatima istraživanja iz razvijenih i tranzicijskih zemalja.

Ključne riječi: glavnica, dobit, cijena dionica, BDP

ABSTARCT

The aim of this research was analyzing relationship between accounting information and macroeconomic data with share prices on Croatian capital market. The research was conducted on a sample of corporations from Zagreb Stock Exchange, which consisted of 34 corporations between 2011-2015 and CROBEX, ZIBOR, inflation and GDP for macroeconomic research. The research results show that accounting earnings and book values, observed jointly and individually, are significantly and positively related to share prices in every year with the exception of 2013. To the market index CROBEX the most significant impact has ZIBOR, industrial production and GDP forecast. The research results indicate that accounting information and macroeconomic data on Croatian capital market are value relevant, and results are comparable to research results from developed and transition countries.

Key words: book value, earnings, share prices, GDP

LITERATURA

1. Abdullah, D.A. i Hayworth, S.C. (1993): Macroeconomics of Stock Price Fluctuations. Quarterly Journal of Business and Economics, Vol. 32, str. 50-67.
2. Aljinović, Z., Marasović, B. Tomić-Plazibat, N. (2005): Multi-criterion approach versus Markowitz in selection of the optimal portfolio, Proceedings of the 8th International Symposium on Operational Research, Ljubljana, str. 261-266.
3. Aljinović, Z., Marasović, B., Šego, B. (2008): Financijsko modeliranje, Zgombić & partneri, Zagreb.
4. Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, drugo izmijenjeno i dopunjeno izdanje, Ekonomski fakultet u Splitu, Split.
5. Bahovec, V., Škrinjarić, T. (2013): Mogućnosti optimizacije portfelja na Zagrebačkoj burzi uz pomoć odabranih metoda multivarijantne analize, Ekonomski pregled, Vol.64, No. 1, str. 3-29.
6. Ball, R., Brown, P. and Officer, R.R. (1975): Toward Unverstanding the Share Market, Alumni News, Alumni Association of the University of Queensland 7 (2), 10-14.
7. Barbić, T. (2010): Pregled razvoja hipoteze efikasnog tržišta, Znanstveni rad, Privredna kretanja i ekonomska politika, str. 124-135.
8. Bartulović M. (2015): Trendovi u vrijednosnoj važnosti računovodstvenih informacija: empirijska analiza za korporacije s zagrebačke burze, Sveučilišni odijel za forezničnе znanosti Split.
9. Benaković, D., Posedel P. (2010): Do macroeconomic factors matter for stock returns? Evidence from estimating a multifactor model on the Croatian market, Business Systems Research, Vol.01, No.1-2, 1-50., str. 4-13.
10. Benić, V., Franić, I. (2008): Komparativna analiza likvidnosti tržišta kapitala Hrvatske i zemalja regije, Zagreb.
11. Bodurtha, Jr., Cho, J. i Senbet, W. (1989): Economic forces and the stock market: An international perspective, Global Finance Journal Vol. 1, str. 21-46.
12. Burmeister, E. i McElroy, M.B. (1991): The residual market factor, the APT, and mean-variance efficiency, Review of Quantitative Finance and Accounting, Vol. 1, str. 27-49.

13. Campbell, J., Lo, A. i MacKinlay, A. (1996): The Econometrics of Financial Markets, Princeton University Press.
14. Campbell, J.Y., Andrew W. Lo i MacKinlaly A. (1997): The Econometrics of Financial Markets, Princeton, NJ: Princeton University Press.
15. Chen N., Roll R. i Ross S. (1986): Economic Forces and the Stock Market, The Journal of Business. Vol. 59, No. 3, str. 383-403.
16. Collins, D.W., Maydew E., Weiss I. (1997): Changes in the value-relevance of earnings and book values over the past forty year, Journal of Accounting and Economics, str. 39-68.
17. Cowles, A., Herbert E. (1937): Some A Posteriori Probabilities in Stock Market Action, Econometrica, 5(3), str. 280-294.
18. Dadić, T. (2009): Testiranje efikasnosti tržišta kapitala odabranih zemalja srednje i istočne Europe, magistarski rad, Zagreb: Ekonomski fakultet, Sveučilište u Zagrebu.
19. Dai, Y., Han, D., Dai, W. (2014): Modeling and Computing of Stock Index Forecasting Based on Neural Network and Markov Chain, The Scientific World Journal, Vol. 2014, str. 1-10.
20. Ernest, O., Oscar, M.C. (2014): The comparative study of value relevance of financial information in the Nigeria banking and petroleum sectors, Journal of Business Studies Quarterly, 6(1), str. 42-54.
21. Fama, E. F. (1970): Efficient Capital Markets: A Review of Theory and Empirical Work, Journal of Finance, str. 383. - 417.
22. Fama, E.F., French K.R (1989): Business Conditions and Expected Returns on Stocks and Bonds, Journal of Financial Economics 25, str. 23-49.
23. Fama, E. F., Marshall E. B. (1966): Filter Rules and Stock Market Trading Profits, Journal of Business, 39(1), str. 226-241.
24. Fama, E. F i MacBeth, J. (1973): Risk, return and equlibirum: empirical test, Journal od Political Economy 71, str. 607-636.
25. Feltham, G., Ohlson. J., A. (1995): Valuation and Clean Surplus Accounting for Operating and Financial Activities, Contemporary Accounting Research, str. 689-731.
26. Frankfurter, G. M. (1993): The End of Modern Finance?, The Journal of Investing 2, str. 4.
27. Fruk, M. i Huljak, I. (2004): Testiranje Sharpe-Linterova modela na Zagrebačkoj burzi Financijska teorija i praksa 28, str. 77-91.
28. Goncharov, I., Hodgson, A. (2011): Measuring and reporting income in Europe.

Journal of International Accounting Research, 10(1), str. 27-59.
29. Grossman, S. J. i Stiglitz, J. (1980): On the Impossibility of Informationally Efficient Markets, The American Economic Review, 70(3), str. 393-408.
30. Hasbrouck. J. (2003): Intraday Price Formation in the Market for U.S. Equity Indexes, Journal of Finance, 58, str. 2375-2400.
31. Hudson, R., Dempsey, M. i Keasey, K. (1996): A note on the weak form efficiency od capital markets: The application of simple technical trading rules to UK stock prices – 1935-1994, Journal of Banking & Finance, Vol. 20, str. 1121-1132.
32. Humpe, A. i Macmillian, P. (2009): Can macroeconomic variables explain long-term stock market movements? A comparison of the US and Japan, Applied Financial Economics, Vol. 19, str. 111-119.
33. Hsing, Y. (2011): Macroeconomic Variables and The Stock Market: The Case of Croatia, Economic research, Vol.24 No.4, str. 41-50.
34. Ivanov, M. i Lovrinović, I (2008): Monetary transmission mechanism and behaviour of asset prices: The case of Croatia, Review of Business Research, March 2008., str. 1-17.
35. Jensen, M. i Scholes, M. (1972): The Capital Asset Pricing Model: Some Empirical Tests, Studies in the Theory of Capital Markets, Praeger Publishers Inc.
36. Jerončić M., Aljinović Z. (2011): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Stručni članak, Ekonomski pregled 62 (9-10), str. 587.
37. Jones, D.A., Smith, K. J. (2011): Comparing the value relevance, predictive value, and persistence of other comprehensive income and special items. Accounting Review, Vol. 86, No. 6, str. 2047-2073.
38. Kunovac, D. (2011): Asimetrične informacije na tržistu kapitala u Hrvatskoj, Institut za javne financije.
39. Lau, S., Quay, S i Ramsey, C. (1975): The Tokyp Stock Exchange and the capital asset pricing model, Journal of Finance 30, str. 507-513.
40. Lee, C., Park, M.S. (2013): Subjectivity in fair-value estimates, audit quality, and informativeness of other comprehensive income, Advances in Accounting, Incorporating Advances in International Accounting, 29(2).
41. Laffont, J. i Maskin, E. (1990): The Efficient Market Hypothesis and Insider Trading on the Stock Market, The Journal of Political Economy, 98(1), str. 70-93.
42. Lakoinishok, J. i Shapiro, A. (1985): Systematic risk, total risk and size as

determinants of stock market returns, Journal of Banking and Finance 10, str. 115-132.

43. Lehmann, B. (1990): Fads, Martingales, and Market Efficiency, Quarterly Journal of Economics, 105(1), str. 1-28.
44. LeRoy, S. F. (1989): Efficient Capital Markets and Martingales, Journal of Economic Literature, 27(4), str. 1583-1621.
45. Lintner., J. (1965): The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets, The review of Economics and Statistics, Vol. 47, No.1.
46. Malkiel, Burton G. (1992): Efficient Market Hypothesis, New Palgrave Dictionary of Money and Finance, str. 739-744.
47. Malkiel, Burton G. (2003): The Efficient Market Hypothesis and Its Critics, Journal of Economic Perspectives, 17(1), str. 59-82.
48. Markowitz, H., (1952): The utility of wealth, Journal of Political Economy 60, str. 151–158.
49. Markowitz, H. M., Jun. (1991): Foundations of Portfolio Theory, The Journal of Finance 46, No.2, str. 469-477.
50. McElroy, M.B., Burmeister, E. (1988). Arbitrage Pricing Theory as a Restricted Nonlinear Multivariate Regression Model: Iterated Nonlinear Seemingly Unrelated Regression Estimates. Journal of Business & Economic Statistics, 29-42.
51. Mcqueen, G. i Thorley, S (1991): Are Stock Returns Predictable? A Test Using Markov Chains, The Journal of The American Finance Association, Vol. 46, str. 239-262.
52. Mechelli, A., Cimini, R. (2014): Is comprehensive income value relevant and does location matter? A European study. Accounting in Europe, Vol.11.
53. Mihalina E. (2010): Model odnosa cijena i zarada kroz dividendni prinos i zahtjevani prinos iznad očekivane inflacije, 336.761(497.5), str. 3-4.
54. Murphy J.J. (2007): Tehnička analiza financijskog tržišta, Masmedia, str. 25.-28.
55. Muth. J. (1961): Rational Expectations and the Theory of Price Movements, The Econometric Society, Vol. 29. No.3.
56. Ljung, Greta M., George E. P. (1978): On a Measure of Lack of Fit in Time Series Models, Biometrika, 65(2), str. 297-303.
57. Ohlson, J. (1995): Earnings, Book Values, and Dividends in Equity Valuation," Columbia University, Contemporary Accounting Research, Vol. 11, No. 2, Str, 661-

687.

58. Olgić Draženović, B., Prohaska, Z. (2003): Foreign Portfolio Investments in the Republic of Croatia, in 4th International Conference Economic System of European Union and Accession of the Republic of Croatia "Theory and Practice of Transition and Accession to the EU". Ljubljana: Faculty of Economics, str. 300.
59. Orsag S. (2001): Dionice, Priručnik za polaganje ispita za obavljanje poslova investicijskog savjetnika, Hrvatska udruga financijskih analitičara, Zagreb.
60. Pečarić, M., Arnerić J. Radić M (2012): Komparativna analiza stupnja financijske integracije tržišta kapitala Hrvatske i zemalja CEE s tržištem EU-a , Financijska tržišta i institucije Republike Hrvatske u procesu uključivanja u Europsku uniju, Rijeka.
61. Pervan, I., Vasilj, M. (2009): Vrijednosna važnost glavnice i dobiti - empirijska analiza za hrvatske korporacije sa zagrebačke burze, Ekonomska istraživanja: znanstveno-stručni časopis- Pula: Sveučilište "Jurja Dobrile" u Puli, Vol. 22, 4, str. 41-51.
62. Pervan I., Bartulović, M (2013): Determinants of value relevance of accounting information: comparative analysis for listed companies from South East Europe, Recent Researches in Business and Economics, str. 146-151.
63. Pervan, I. M. i Bartulović, M. (2014): Determinants of voluntary Internet Financial Reporting: analysis for selected CEE countries, International journal of economics and statistics, (2), str. 32-39.
64. Pojatina, D. (2000): Tržište kapitala, Ekonomski fakultet Split, Split, str. 15-160.
65. Prohaska, Z. (1996): Analiza vrijednosnih papira, Infoinvest, Zagreb, str. 77-87.
66. Ratanapakorn, O. i Sharma, S. C. (2007): Dynamics analysis between the US Stock Return and the Macroeconomics Variables, Applied Financial Economics, Vol. 17, str. 369-377.
67. Reinganum, M. (1981): Misspecification od capital asset pricing: Empirical anomalies based on earning yields and market values, Journal of Financial Economics 9, str. 19-46.
68. Roberts, H. (1967): Statistical versus Clinical Prediction in the Stock Market, unpublished manuscript, Center for Research in Security Prices, University of Chicago.
69. Roll, R. (1977): A critique of the asset pricing theory's test, Journal of Financial Economics 4, str. 129-176.
70. Sabolić, D. (2013): Financijska tržišta II – Organizacija financijskih tržišta, Sveučilište u

Zagrebu, str. 263.

71. Schmukler, E., Yeyati, L i Van Horen, L. (2007): Emerging market liquidity and crises, Policy Research Working Paper Series 4445, The World Bank.
72. Sharpe, J. (1963): Capital asset prices: A theory of market equilibrium under conditions of risk, Journal of Finance 19, No. 4.
73. Sidney, S. (1961): Price Movements in Speculative Markets: Trends or Random Walks, Industrial Management Review, 2(2), str. 7-26.
74. Sladojević, K. (2010): Model vrednovanja i trgovina izvedenicama i njihova perspektiva u RH, Magistarski rad, Ekonomski fakultet Split, str. 106.
75. Sundberg, J., Klacksell, G. (2012), Markov chain - Can you describe the stock index with a Markov chain?, KTH Royal Institute of Technology at Campus Valhallavägen.
76. Solnik, B. (1987): Using Financial Prices to Test Exchange Rate Models: A Note, Journal of Finance, 42, 141-49.
77. Stahel, C. W. (2004): Is there a global liquidity factor?, Doctoral dissertation, Ohio State University.
78. Stanivuk., T. (2012): Bihevioralne financije u analizi predvidljivosti kretanja cijena dionica, Doktroska disertacija, Sveučilište u Splitu.
79. Šoškić, D.B. (2009): Hartije od vrednosti: upravljanje portfeljm i investicioni fondovi, Centar za izdavaču djelatnost Ekonomskog fakulteta u Beogradu.
80. Tiković, S. (2005): Formiranje optimalnog portfelja hrvatskih dionica i mjerenje trtžišnog rizika primjenom VaR metode, Magistarski rad, Ljubljana, str. 7-8.
81. Tomić, B. (2013): The application of the capital asset pricing model on the Croatian capital market, Effectus College for Law and Finance, str. 105.123.
82. Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): Matematički modeli u financijskom upravljanju, Svučilište u Splitu, Ekonomski fakultet Split, str. 11.
83. Yeyati, E., Schmukler, Sergio L., Van Horen. N. (2007): Emerging market liquidity and crises, Policy Research Working Paper Series 4445, The World Bank.
84. Van Horne, J.C., Wachowich, J.M. (2012): Financijsko upravljanje i politika (financijski menadžment), deveto izdanje, Mate, Zagreb, str. 98-109.
85. Vidučić, Lj. (2006): Financijski menadžment, V. izdanje, RriF, Zagreb, str. 124. -125.
86. Vidučić, Lj. (2008): Financijski menadžment, VI. nepromijenjeno izdanje, RRIF-plus, Zagreb, str. 89.

87. Zagrebačka burza d.d. (2013), Odluka br. 393 o indeksu CROBEX, http://zse.hr/UserDocsImages/dokumenti_indeksi/CROBEX_20130823153518-2013-08-Odluka-o-indeksu-CROBEX.pdf
88. Narodne novine (2008): Zakon o tržištu kapitala, Narodne novine d.d. Zagreb, broj 88.

Internet stranice

1. Državni zavod za statistiku - http://www.dzs.hr, 12.09.2016
2. Eurostat - http://ec.europa.eu/eurostat, 12.09.2016
3. Reuters Croatia, http://reuters.hr/tr/hr/index.action, 13.09.2016.
4. Zagrebačka burza, www.zse.hr, 20.09.2016.

Popis tablica str.

Tablica 1. Testiranje varijanti hipoteze slučajnog hoda 41
Tablica 2. Sastav CROBEX-a na dan 27.08.2016 67
Tablica 3. Sastav CROBIS-a na dan 27.08.2016 70
Tablica 4. Sastav CROBEX-a 10 na dan 27.08.2016 71
Tablica 5. Sastav CROBEX-a plus na dan 27.08.2016 72
Tablica 6. Deskriptivna statistička analiza 81
Tablica 7. Određivanje vremenskih pomaka u VAR modelu 82
Tablica 8. Grangerov test kauzalnosti 83
Tablica 9. Dekompozicija varijance modela 83
Tablica 10. Formiranje uzorka iz osnovnog skupa 85
Tablica 11. Deskriptivna statistika za varijable iz uzorka 87
Tablica 12. Grangerov test kauzalnosti 88
Tablica 13 . Rezultati analize vrijednosti dobiti za uzorak dionica listanih na ZSE 89
Tablica 14. Rezultati analize vrijednosne važnosti glavnice za uzorak dionica listanih na ZSE 90
Tablica 15. Rezultati analize vrijednosne važnosti dobiti i glavnica za uzorak dionica listanih na ZSE 90

Popis slika

Slika 1. Stope rasta BDP-a u Hrvatskoj 28
Slika 2. Stvarni i očekivani BDP po stanovniku 29
Slika 3. Funkcija korisnosti investitora koji izbjegava rizik 47
Slika 4. Prikaz ukupnog rizika ulaganja i smanjenje rizika portfelja dodavanjem sve većeg broja dionica 52
Slika 5. Linija tržišta kapitala (CML) 53
Slika 6. Linija tržišta kapitala (SML) 54
Slika 7. Pravac arbitražnog procjenjivanja 56
Slika 8.Struktura financijskog tržišta 58

Slika 9. Razlika između primarnog i sekudarnog tržišta 60
Slika 10. Kretanje cijena CROBEX-a od 01.01.2007 do 31.12.2015 74
Slika 11. Povijesni podaci o prometu na Zagrebačkoj burzi 75

DODATAK

Popis dionica uvrštenih u uzorak za testiranje hipteze H1

Simbol	Poduzeće	Simbol	Poduzeće
ADPL-R-A	AD Plastik d.d.	BLJE-R-A	Belje d.d. Darda
ATGR-R-A	Atlantic Grupa d.d.	CKML-R-A	Čakovečki mlinovi d.d.
CROS-R-A	Croatia osiguranja d.d.	DDJH-R-A	Đuro Đaković holding d.d.
HT-R-A	HT d.d.	ERNT-R-A	Ericsson Nikola Tesla d.d.
INA-R-A	Ina d.d.	HIMR-R-A	Imperial d.d.
KOEI-R-A	Končar - elektroindustrija d.d.	HMST-R-A	Hoteli Maestral d.d.
LEDO-R-A	Ledi d.d.	HUPZ-R-A	HUP - Agreb d.d.
LKPC-R-A	Luka Ploče d.d.	JDPL-R-A	Jadropolov d.d.
PODR-R-A	Podravka d.d.	JMNC-R-A	Jamnica d.d.
PTKM-R-A	Petrokemija d.d.	PBZ-R-A	PBZ d.d.
RIVP-R-A	Valmar Riviera d.d.	TUHO-R-A	Turisthotel d.d.
ADRS-P-A	Adris grupa d.d.	VPIK-R-A	Vupik d.d.
ADRS-R-A	Adris grupa d.d.	ZABA-R-A	Zagrebačka banka d.d.
ARNT-R-A	Arenaturist d.d.	OPEK-R-A	Opeka d.d.
ATPL-R-A	Atlanska plovidba d.d.	SNHO-R-A	SN holding d.d.