Višekriterijska optimizacija investicijskog portfelja uključivanjem alternativnih oblika ulaganja

Škunca, Filip

Doctoral thesis / Disertacija

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:956168

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

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



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Sveučilište u Zagrebu

Ekonomski fakultet

Filip Škunca

VIŠEKRITERIJSKA OPTIMIZACIJA INVESTICIJSKOG PORTFELJA UKLJUČIVANJEM ALTERNATIVNIH OBLIKA ULAGANJA

DOKTORSKI RAD

Zagreb, 2023.



Sveučilište u Zagrebu

Ekonomski fakultet

Filip Škunca

VIŠEKRITERIJSKA OPTIMIZACIJA INVESTICIJSKOG PORTFELJA UKLJUČIVANJEM ALTERNATIVNIH OBLIKA ULAGANJA

DOKTORSKI RAD

Mentor:

Izv. prof. dr. sc. Mihovil Anđelinović

Zagreb, 2023.



University of Zagreb

Faculty of Economics and Business

Filip Škunca

MULTICRITERIA INVESTMENT PORTFOLIO OPTIMIZATION USING ALTERNATIVE INVESTMENTS

DOCTORAL DISSERTATION

Supervisor:

Izv. prof. dr. sc. Mihovil Anđelinović

Zagreb, 2023

Filip Škunca

Ime i prezime doktoranda

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je **DOKTORSKI RAD** isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Zagreb, 22.2.2023. godine

(mjesto i datum)

Filip Škunca

(vlastoručni potpis studenta)

SAŽETAK

Investicijski portfelji društava za osiguranje najčešće se sastoje od tradicionalnih oblika ulaganja od kojih u najvećem udjelu dominiraju obveznice. Čimbenici koji utječu na kretanje prinosa ovih financijskih instrumenata odnose se primarno na makroekonomsko okruženje i razinu kamatnih stopa na financijskim tržištima. Veći dio analiziranog razdoblja ovog istraživanja karakterizira okruženje povijesno niskih kamatnih stopa koje su dovele do značajnog pada prinosa na ulaganja osiguratelja.

Glavni cilj ove doktorske disertacije bio je analizirati utjecaj uključivanja nisko koreliranih alternativnih oblika ulaganja u investicijski portfelj, koji se isključivo sastoji od tradicionalnih oblika ulaganja, kao moguće rješenja problema niskih kamatnih stopa u analiziranom razdoblju. Tradicionalni oblici odnose se na hrvatske obveznice, dionice i novčane instrumente dok alternativne oblike predstavljaju hedge fondovi i upravljane ročnice (eng. *managed futures*). Postavljene hipoteze o koristi uključivanja alternativnih oblika ulaganja testirane su primjenom Markowitzevog i višekriterijskog modela optimizacije. Rezultati testiranja u analiziranom razdoblju, prema oba modela, potvrđuju hipoteze o pozitivnom utjecaju uključivanja alternativnih oblika ulaganja na prinos i rizik odnosno efikasnost investicijskog portfelja mjerenu Sharpe, Sortino i Omega omjerom. Dodatno je pomoću vektorskog autoregresijskog modela testirana i hipoteza o jačini utjecaja promjene kamatnih stopa na prinose domaćih dionica i obveznica, te hedge fondova i ročnica. Unatoč teorijskoj pretpostavci o jačem utjecaju promjene kamatnih stopa na promjenu prinosa obveznica i dionica, predmetnu hipotezu nije bilo moguće u potpunosti potvrditi, ali niti odbaciti. Svi izračuni i optimizacije u testiranju hipoteza izvedeni su u R programskom jeziku.

Ključne riječi: društva za osiguranje, investicijski portfelj, višekriterijska optimizacija, Omega omjer, korelacija, alternativni oblici ulaganja, kamatne stope, obveznice, dionice, hedge fondovi, upravljane ročnice, opći VAR model, R programski jezik

PROŠIRENI SAŽETAK NA ENGLESKOME JEZIKU

Investment portfolios of insurance companies usually consist of traditional investments, the largest share of which is dominated by bonds. Factors that affect the returns of these financial instruments refer primarily to the macroeconomic environment and the level of interest rates on the financial markets. Most of the analyzed period of this research is characterized by an environment of historically low interest rates, which led to a significant decrease in the return of insurers' investments.

The main goal of this doctoral dissertation was to analyze the impact of including low-correlated alternative assets in an investment portfolio, which exclusively consists of traditional assets, as a solution to the problem of low interest rates in the analyzed period. Alternative investments, due to their low correlation with the returns of traditional asset classes, can have a major positive effect on risk diversification and attaining higher investment returns. Traditional assets refer to Croatian bonds, stocks and money market instruments, while alternative assets are represented by hedge funds and managed futures. Hypothesis about the benefits of including alternative investments were tested using the Markowitz and multicriteria optimization models.

The test results in the analyzed period, according to both models, confirm the hypotheses about the positive impact of the inclusion of alternative assets on return, risk, and the efficiency of the investment portfolio measured by the Sharpe, Sortino and Omega ratio.

In Hypothesis 1, the aim was to test whether the inclusion of alternative assets in the investment portfolio, which only contains traditional assets on the Croatian financial market (bonds, shares, money market instruments), has a stronger positive impact than the inclusion of additional foreign traditional assets (e.g., EU, USA, emerging markets bonds and stocks). The results of testing the hypothesis H1 in the analyzed period indicated that alternative assets have a stronger positive impact on the efficiency of the portfolio measured by the Sharpe and Sortino ratio in almost all tested combinations of weights of the observed assets.

Hypothesis H2 tested whether the use of a multicriteria optimization model would give a more efficient portfolio compared to the use of the Markowitz model. With the aim of representative comparison of simulated and optimized portfolios, equal weights restrictions were used for the included assets classes. The Omega ratio was used as an efficiency measure for portfolio evaluation since, in addition to expected return and variance, it considers higher portfolio

moments related to the coefficients of asymmetry and kurtosis, which are also optimized in a multicriteria model. A portfolio with a higher Omega measure is considered more efficient. The results of testing H2 also confirm the hypothesis, which enables better creation and selection of available assets in the investment portfolio. Findings show the benefit of the multicriteria model, which is coded in the R programming language, and that further facilitates the application to interested investors and other stakeholders.

As previously mentioned, this scientific paper also presents the characteristics of the multicriteria optimization model where conflict of objective function occurs. In this paper, the model is used to optimize central portfolio moments, respectively expected return, variance and coefficients of asymmetry and kurtosis which are often referred to as higher central moments. In other words, the return distribution first and third moment (return and asymmetry) are maximized and the second and fourth moment (variance and kurtosis) are minimized simultaneously. The use of the multicriteria model brings several advantages. First, investors can arbitrarily choose preferences regarding certain central moments in the optimization itself, which then affects the higher or lower value of these moments depending on the preference. Multicriteria optimization is suitable for use in situations where time series of the observed variables do not follow the shape of a normal distribution, which makes it possible to overcome the normality assumption from the Markowitz optimization model. Numerous empirical papers have already pointed out that time series return distributions of many traditional and alternative assets do not hold the normality assumption.

In addition to previously mentioned, using the unrestricted vector autoregression model (VAR model), the hypothesis H3 about the strength of interest rate changes impact on the returns of domestic stocks and bonds, as well as hedge funds and managed futures, was tested. The theoretical assumption that forms the basis of H3 is that the change in the level of interest rates, regardless of whether they are rising or falling, has an expected stronger effect on the change in bond and stock returns than on the returns of hedge funds and managed futures. Accordingly, investors whose investment portfolios include bonds and stocks can reduce exposure to the risk of interest rate changes through the inclusion of hedge funds and futures, i.e., reducing the share of bonds and stocks. Despite the theoretical assumption of a stronger impact of the change in interest rates on the change in the return of bonds and stocks, it was not possible to fully confirm the hypothesis, nor to reject it.

All calculations and optimizations in hypothesis testing were performed in R programming language.

Key words: insurance companies, investment portfolio, multi-criteria optimization, Omega ratio, correlation, alternative investments, interest rates, bonds, stocks, hedge funds, managed futures, unrestricted VAR model, R programming language

SADRŽAJ

SAŽETAK I
PROŠIRENI SAŽETAK NA ENGLESKOME JEZIKU II
1. UVOD 1
1.1. Problem istraživanja 2
1.2. Ciljevi istraživanja 3
1.3. Pregled dosadašnjih istraživanja 5
1.4. Hipoteze rada 8
1.5. Metode znanstvenog istraživanja 11
1.6. Očekivani znanstveni i aplikativni doprinos 13
1.7. Struktura rada 16
2. TEORIJE I MODELI OBLIKOVANJA INVESTICIJSKOG PORTFELJA 18
2.1. Tradicionalni portfelj institucionalnih investitora 18
2.1.1. Tradicionalni portfelj i oblici ulaganja 19
2.1.2. Alternativni oblici ulaganja 24
2.2. Upravljanje investicijskim rizicima 24
2.2.1. Vrste investicijskih rizika 25
2.2.2. Regulacija investicijskih rizika 29
2.3. Markowitzev model optimizacije i njegove alternative 30
2.3.1. Markowitzev model optimizacije 30
2.3.2. Kritike modela 34
2.3.3. Alternativni modeli optimizacije 35
2.4. Uloga i značenje modela optimizacije uz više momente distribucije 37
2.5. Pregled mjera efikasnosti portfelja 43
2.5.1. Sharpeov omjer 43
2.5.2. Sortinov omjer 44
2.5.3. Rizična vrijednost 45
2.5.4. Uvjetna rizična vrijednost (Cvar) 45
2.5.5. Omega omjer 46
3. ALTERNATIVNI OBLICI ULAGANJA I NJIHOV UTJECAJ NA EFIKASNOST INVESTICIJSKOG PORTFELJA 48
3.1. Pojam, vrste i odrednice hedge fondova 50
3.1.1. Vrste hedge fondova 52
3.1.2. Glavne odrednice Hedge fondova 55
3.1.3 Alternativni fondovi u Republici Hrvatskoj 59

3.2. Pojam i odrednice ročnica 60
3.2.1. Glavne odrednice ročnica 62
3.2.2. Strategije trgovanja upravljanim ročnicama 64
3.2.3. Prednosti ulaganja u ročnice za institucionalne investitore 66
3.3. Korelacija hedge fondova s tradicionalnim oblicima ulaganja i utjecaj na investicijski portfelj 68
3.4. Korelacija upravljanih ročnica s tradicionalnim oblicima ulaganja i utjecaj na investicijski portfelj 70
3.5. Ostali alternativni oblici ulaganja 72
3.5.1. Nekretnine 72
3.5.2. Privatni kapital 75
3.5.3. Robe 78
3.6. Pregled upravitelja alternativnih fondova na globalnom i EU financijskom tržištu 80
3.6.1. Dubinska analiza upravitelja hedge fondova i fondova ročnica 80
3.6.2. Pregled upravitelja alternativnih fondova 83
3.7. Regulacija alternativnih ulaganja 87
4. SEKTOR OSIGURANJA I REGULATIVA SOLVENTNOST II 90
4.1. Pregled i struktura investicijskog portfelja društava za osiguranje 91
4.1.1. Ulaganja društava za osiguranje na tržištu RH 92
4.1.2. Struktura ulaganja stranih osiguratelja u EU 95
4.2. Glavna obilježja regulative Solventnost II 97
4.2.1. Pojmovno određenje ekonomskog i solventnog kapitala 99
4.2.2. Vrste i regulacija tržišnih rizika 102
4.2.3. Utjecaj kapitalnih zahtjeva na odabir oblika ulaganja 103
4.2.4. Utjecaj uključivanja alternativnih oblika ulaganja na solventnost osiguratelja 107
4.3. Analiza okruženja niskih kamatnih stopa u analiziranom razdoblju 110
5. OPTIMIZACIJA I EMPIRIJSKA ANALIZA UTJECAJA ALTERNATIVNIH OBLIKA ULAGANJA NA INVESTICIJSKI PORTFELJ 117
5.1. Pregled varijabli 117
5.2. Oblikovanje modela optimizacije 123
5.3. Optimizacija pomoću Markowitzevog modela (Hipoteza 1) 125
5.4. Optimizacija pomoću Višekriterijskog modela (Hipoteza 2) 131
5.5. Utjecaj promjene kamatnih stopa na tradicionalne i alternativne oblike ulaganja (Hipoteza 3) 139
5.6. Rezultati istraživanja i testiranja hipoteza 150
5.6.1. Hipoteza 1 150
5.6.2. Hipoteza 2 151

5.6.3. Hipoteza 3 151
6. ZAKLJUČAK 153
6.1. Ograničenja istraživanja 157
6.2. Prijedlozi za buduće znanstvene radove 158
POPIS LITERATURE 160
POPIS TABLICA 176
POPIS SLIKA 177
POPIS SHEMA 178
POPIS GRAFOVA 178
ŽIVOTOPIS 180

1. UVOD

Investicijski portfelji društava za osiguranje najčešće se sastoje od tradicionalnih oblika ulaganja od kojih u najvećem udjelu sudjeluju obveznice. Čimbenici kretanja prinosa ovih financijskih instrumenata odnose se primarno na makroekonomsko okruženje odnosno razinu kamatnih stopa na financijskim tržištima. U ovom radu se analizira razdoblje od 2006.-2020. godine. Ekonomsko okruženje u EU, ali i šire, u analiziranom razdoblju karakterizirao je prolongirani period povijesno niskih kamatnih stopa koji je induciran ekspanzivnom monetarnom politikom Europske Središnje banke.

Značajni institucionalni investitori u Republici Hrvatskoj i EU, prije svega društva za osiguranja i društva za upravljanje mirovinskim fondovima, u imovini sadrže značajan udio državnih obveznica čija vrijednost ovisi o kretanju kamatnih stopa. U slučaju životnih osiguratelja, isti princip se odnosi i na obveze čija je vrijednost također izložena promjeni kamatnih stopa. Na taj način se izloženost riziku nepovoljnog kretanja vrijednosti imovine i obveza međusobno može anulirati kroz strategiju kamatne imunizacije. S padom kamatnih stopa, prinos na ulaganja osiguratelja se značajno smanjuje obzirom da se dospjele obveznice reinvestiraju po sve nižim kamatnim stopama. Prolongirani trend niskih kamatnih stopa, u analiziranom razdoblju, zahtijevao je od osiguratelja da ulažu u rizičnije oblike ulaganja kako bi povećali prinose investicijskih portfelja. Dodatno se nameće pitanje na koji način se osiguratelji i drugi investitori mogu u budućnosti zaštititi od rizika promjene kamatnih stopa i nedostatnosti investicijskih prinosa. Jedno od rješenja je uključivanje nisko koreliranih alternativnih oblika ulaganja u investicijski portfelj što je ispitano i analizirano u ovom doktorskom istraživanju.

Predložena tema doktorskog rada je „**Višekriterijska optimizacija investicijskog portfelja uključivanjem alternativnih oblika ulaganja**“ obzirom da je predmet istraživanja uključivanje alternativnih oblika ulaganja u investicijski portfelj društva za osiguranje, a u cilju rješavanja problema niskih kamatnih stopa u analiziranom razdoblju. Predmet istraživanja se dodatno svodi na utvrđivanje optimalnog udjela alternativnih oblika ulaganja što će se ispitati putem višekriterijskog modela optimizacije. Osnovni razlog korištenja višekriterijske optimizacije je očekivana nenormalna distribuiranost vremenskih serija alternativnih oblika ulaganja, a što je detaljnije obrazloženo u nastavku disertacije.

1.1. Problem istraživanja

Problem povijesno niskih kamatnih stopa u analiziranom razdoblju od iznimne je važnosti za društva za osiguranje, posebna ona koja se bave životnim osiguranjima. U kontekstu problema istraživanja, iz tog razloga je sektoru osiguranja posvećeno cijelo poglavlje (poglavlje 4) u dispoziciji doktorske disertacije. Naime, pad prinosa uslijed niskih kamatnih stopa doveo je do strukturne nemogućnosti društava za osiguranje da prinosom iz ulaganja podmire garancije po policama životnih osiguranja. Takva vrsta proizvoda bila je osobito povoljna za osiguranike (i osiguratelje) u vremenima kada su kamatne stope bile znatno više. Prinosi koji su tada ostvareni bili su dostatni za pokriće garancija, no s druge strane, takva osiguranja iznimno su dugoročnog karaktera. Problem je nastao kada su kamatne stope počele padati, te se reinvestiranje imovine moralo provoditi po nižim stopama, dok su garancije osiguranicima ostale fiksne (CRO forum, 2016). Time se pojavio visok rizik u nastajanju koji se počeo materijalizirati, a to je da društva za osiguranje trebaju manjak prinosa financirati iz drugih izvora (kapital, zaduživanje i sl.) kako bi bila u mogućnosti podmiriti obveze prema osiguranicima životnih osiguranja.

Uključivanje alternativnih oblika ulaganja u investicijski portfelj u analiziranom razdoblju istraživanja može smanjiti utjecaj okruženja niskih kamatnih stopa na pad prinosa društava za osiguranje radi niske korelacije sa tradicionalnim oblicima (obveznice, dionice). Hedge fondovi i ročnice (eng. *managed futures*) kao alternativni oblici ulaganja imaju danas široku prihvaćenost, posebno kod institucionalnih investitora (Schneeweis et al., 2011). Ova teorija je osnažena s dugoročnim koeficijentima korelacije između *Credit Suisse Hedge Fund Index*-a, koji je jedan od reprezentativnih indeksa industrije Hedge fondova, i tipičnog usporedivog indeksa dioničkog i obvezničkog tržišta, što je vidljivo u tablici 1.

Tablica 1 – Korelacija prinosa *hedge* fondova s tradicionalnim oblicima ulaganja (1994-2015)

Financijski indeksi	*Credit Suisse Hedge Fund Index*	*MSCI AC World GR* (globalno dioničko tržište)	*Barclays Global Aggregate TR* (globalno tržište obveznica)
Credit Suisse Hedge Fund Index	1		
MSCI AC World GR	0.5677	1	
Barclays Global Aggregate TR	0.2776	-0.0059	1

Izvor: Obrada autora prema (Basile, 2016)

Iz prethodno navedenog proizlazi **glavni problem doktorskog istraživanja** – istražiti i analizirati utjecaj uključivanja alternativnih oblika ulaganja u investicijski portfelj institucionalnih investitora, u prvom redu društava za osiguranje, kao moguće rješenje problema povijesnog okruženja niskih kamatnih stopa u analiziranom razdoblju.

Dodatan problem istraživanja odnosi se na pitanje optimalne kombinacije udjela tradicionalnih i alternativnih oblika ulaganja u investicijskom portfelju. Ovaj problem će se riješiti kroz definiranje i upotrebu višekriterijskog modela optimizacije jer se smatra da vremenske serije prinosa promatranih varijabli ne slijede oblik normalne distribucije, a koja je jedna od glavnih pretpostavki te ujedno i nedostataka Markowitzevog modela. Višekriterijski model zaobilazi ovu pretpostavku obzirom da se u njemu ne pretpostavlja oblik distribucije[1].

Uz navedene probleme istraživanja, bitno je istaknuti i nedovoljnu istraženost utjecaja promjene kamatnih stopa na tradicionalne (domaće dionice i obveznice) i alternativne oblike ulaganja kao podloge za bolje razumijevanje i podizanje svijesti o koristi uključivanja alternativnih oblika ulaganja u investicijski portfelj. U tom kontekstu, utvrđen je oskudan broj domaćih radova koji se bave ovom problematikom. Istraživanje ovog utjecaja na tradicionalne oblike ulaganja tržišta kapitala Republike Hrvatske ima dodatan značaj uzimajući u obzir izvjesni ulazak u Eurozonu čime će se ukinuti valutni rizik prema valuti EUR i olakšati domaćim investitorima pristup inozemnim financijskim tržištima.

1.2. Ciljevi istraživanja

Na temelju navedenih problema istraživanja, u nastavku su formirana sljedeća istraživačka pitanja:

- Koliki je okvirni kvantitativni utjecaj okruženja povijesno niskih kamatnih stopa na prinose investicijskog portfelja društava za osiguranje u analiziranom razdoblju?
- Postiže li se uključivanjem alternativnih oblika ulaganja u investicijski portfelj bolja kombinacija prinosa i rizika, valorizirana preko relevantne mjere rizika, u odnosu na portfelj koji se sastoji isključivo od tradicionalnih oblika ulaganja?
- Kolika je empirijska korelacija domaćih i ostalih tradicionalnih oblika ulaganja s odabranim alternativnim oblicima?

[1] U modelu se uključuju prva 4 središnja momenta distribucije prinosa (očekivani prinos, standardna devijacija, koeficijent asimetrije i koeficijent zaobljenosti

- Slijede li vremenske serije promatranih oblika ulaganja oblik normalne distribucije?
- Koja je optimalna kombinacija udjela tradicionalnih i alternativnih oblika ulaganja u investicijskom portfelju?
- Kako ulaganja u alternativne oblike imovine utječu na solventnost društava za osiguranje?
- Koja su glavna obilježja hedge fondova i ročnica kao alternativnih oblika ulaganja te na koji način njihovo uključivanje u investicijski portfelj utječe na središnje momente distribucije prinosa?
- Na koje oblike ulaganja (obveznice, dionice, hedge fondovi, ročnice) promjena kamatnih stopa ima jači utjecaj?

Postavljanjem istraživačkih pitanja određuju se znanstveni i aplikativni ciljevi ovog istraživanja. **Znanstveni ciljevi** istraživanja su sljedeći:

1. Provesti optimizaciju investicijskog portfelja uključivanjem alternativnih oblika ulaganja te izložiti koristi takvog pristupa za investitore u analiziranom razdoblju niskih kamatnih stopa (2006.-2020.).
2. Kreirati robustan višekriterijski model optimizacije putem kodiranja u programskom rješenju R, a kojim će se premostiti pretpostavka normalne distribuiranosti vremenskih serija i omogućiti aplikativna primjena rezultata istraživanja i definiranog modela.
3. Ispitati jačinu utjecaja promjene kamatnih stopa na odabrane tradicionalne i alternativne oblike ulaganja u kontekstu analize problema istraživanja.

Aplikativni ciljevi istraživanja su sljedeći:

1. Prezentirati odrednice odabranih alternativnih oblika ulaganja i analizirati njihovu korelaciju s domaćim i stranim tradicionalnim oblicima ulaganja u promatranom periodu istraživanja od 2006.-2020. godine.
2. Izložiti suvremene teorije i modele upravljanja portfeljem koji uključuju alternativne oblike ulaganja.
3. Prikazati specifičnosti poslovanja društava za osiguranje u regulatornom režimu Solventnost II i okruženju povijesno niskih kamatnih stopa te analizirati utjecaj niskih kamatnih stopa na prinose investicijskog portfelja osiguratelja.
4. Analizirati utjecaj investiranja u alternativne oblike ulaganja na solventnost društava za osiguranje.

Obzirom da društva za osiguranje nemaju zakonske limite investiranja u alternativne oblike ulaganja, dodatno će se provesti i kvantifikacija izloženosti riziku u slučaju takve poslovne

odluke. Svrha kvantifikacije je analizirati utjecaj rezultata optimizacije na solventnost društava za osiguranje. Naime, osigurateljni regulatorni režim Solventnost II tolerira ulaganja u sve oblike imovine, no nalaže osigurateljima izdvajanje kapitalne rezerve ovisno o rizičnosti investicije. Ovaj koncept detaljnije će se izložiti u poglavlju 4. sukladno dispoziciji disertacije. Svrha rada je također prezentirati suvremene teorije i modele upravljanja portfeljem koji uključuju više momente. Takvi modeli nadograđuju klasične modele optimizacije poput Markowitzevog koji uključuje samo prva dva momenta distribucije (očekivani prinos i varijancu), te umanjuju nedostatke pretpostavke normalne distribucije. Uz spomenute modele, ekstenzivno će se obraditi odabrane vrste alternativnih oblika ulaganja odnosno *hedge* fondovi i ročnice (eng. *managed futures*).

1.3. Pregled dosadašnjih istraživanja

Pregled dosadašnjih znanstvenih radova u području optimizacije investicijskog portfelja uključivanjem alternativnih oblika ulaganja može krenuti s radom Kat (2004) u kojem je testiran utjecaj uključivanja hedge fondova i ročnica, kao alternativnih oblika, na prinos i rizik investicijskog portfelja sastavljenog isključivo od dionica i obveznica. Rezultati rada ukazuju da ukoliko ročnice čine minimalno 50% udjela u strukturi alternativnih oblika ulaganja, neće doći do negativnih učinaka uključivanja alternativnih oblika u investicijski portfelj. Amin i Kat (2003) analiziraju utjecaj uključivanja hedge fondova u investicijski portfelj s dionicama te zaključuju da, radi niske korelacije, hedge fondovi imaju pozitivan utjecaj na portfelj u kombinaciji s dionicama. Otruba et al. (2006) i Steenkamp et al. (2008) također ukazuju na prethodni zaključak. Bacmann et al. (2008) provode analizu korelacije različitih vrsta hedge fondova s tradicionalnim oblicima ulaganja te opovrgavaju hipotezu da hedge fondovi nemaju više svojstva potrebna za učinke diversifikacije.

U ovom kontekstu izdvaja se i rad Jaggi et al. (2011) u kojem su utvrđeni pozitivni učinci hedge fondova na odnos prinosa i rizika investicijskog portfelja, kao i pozitivan utjecaj na koeficijente asimetrije i zaobljenosti.. U kontekstu industrije osiguranja, Davó et al. (2013) ukazuju na pozitivne diversifikacijske učinke uključivanja fondova koji ulažu u police životnih osiguranja s doživljenjem. Carayannopoulos i Perez (2015) analiziraju obveznice za katastrofu (eng. *CAT bonds*) te zaključuju da je navedeni oblik pogodan za diversifikaciju samo u periodima bez krize.

Većina spomenutih radova naglašava činjenicu da prinosi promatranih oblika ulaganja ne slijede oblik normalne distribucije, posebice kada je riječ o alternativnim oblicima poput hedge fondova. Sukladno tome, metode koje se koriste u analizi i optimizaciji investicijskog portfelja moraju uzeti u obzir nenormalnu distribuiranost varijabli. Ako promatramo radove koji se bave višekriterijskom optimizacijom portfelja uzimajući u obzir više momente distribucije, oni su se počeli pojavljivati krajem 1990-ih i 2000-ih, a danas ih i dalje nema mnogo. Među prvima koji su analizu portfelja proširili višim momentima bili su Jean (1971 i 1973) te Lai (1991) koji je empirijski procijenio odabir efikasnog portfelja koristeći više momente i predstavio pristup polinomnog ciljnog programiranja u rješavanju problema optimizacije portfelja. U radu je optimizirao portfelj uzimajući u obzir prva tri središnja momenta distribucije odnosno očekivani prinos, varijancu i koeficijent asimetrije, te je u analizu uzeo samo nekoliko dionica.

Nakon toga, određeni autori procjenjivali su međunarodne portfelje dionica uključivanjem viših momenta distribucije u optimizaciju. Prakash et. al. (2003) primijenili su model iz (Lai, 1991) te optimizirali portfelj dionica na međunarodnim tržištima kapitala inkorporiranjem asimetrije kao trećeg momenta distribucije u investicijski portfelj. Takav pristup u optimizaciji doveo je do značajne promjene u konačnom optimalnom portfelju te autori ukazuju da investitori rade kompromis na način da prihvaćaju niži prinos u zamjenu za višu asimetriju. Jondeau i Rockinger (2006) koriste pristup ekspanzije očekivane koristi pomoću Taylorove serije uz korištenje viših momenata. Yang i Hung (2010) proširili su Markowitzevu optimizaciju portfelja s 5 dionica dodavanjem asimetrije i zaobljenosti te ukazali na promjenu efikasne granice kada se u model uključe viši momenti. Kemalbay et al. (2011) provode višekriterijsku optimizaciju primjenom polinomnog ciljnog programiranja na portfelju s 26 dionica turskog tržišta kapitala. Na osnovi dobivenih rezultata ukazuju na značaj uključivanja viših momenata odnosno asimetrije i zaobljenosti distribucije prinosa u proces optimizacije.

Od domaćih autora koji su koristili model s višim momentima na portfelju dionica izdvaja se rad (Škrinjarić, 2013) gdje su korišteni dnevni prinosi 10 dionica tijekom 2012. godine te je provedena Markowitz i višekriterijska optimizacija. Usporedbom rezultata korištenih modela utvrđeno je da se udjeli dionica znatno razlikuju. Portfelji optimizirani višekriterijskim modelom imali su pozitivnije vrijednosti centralnih središnjih momenata od onih iz Markowitzeve optimizacije.

Obzirom da se u ovom doktorskom istraživanju provodi višekriterijska optimizacija različitih oblika ulaganja, a posebno uključivanjem alternativnih (hedge fondovi i ročnice), u pregled

dosadašnjih istraživanja izdvajaju se i radovi iz predmetnog područja. Davies et al. (2009) koriste višekriterijsku optimizaciju, na temelju polinomnog ciljnog programiranja, u ispitivanju alokacije kapitala na različite strategije hedge fondova i tradicionalne oblike ulaganja (dionice i obveznice). Rezultati optimizacije pokazuju da udio hedge fondova, radi visoke koasimetrije s dionicama, istiskuje udio dionica stoga takav portfelj ima veći udio alokacije sredstava u obveznice. Jedan od zaključaka navedenog rada je da hedge fondovi kao alternativni oblik promatran zasebno nije toliko superioran te ga je potrebno kombinirati s tradicionalnim oblicima u cilju postizanja pozitivnog učinka na performanse investicijskog portfelja. Anson et al. (2007) u svojem se radu također naslanjaju na Davies et al. (2009) gdje ukazuju na nenormalnost distribucije hedge fondova i probleme korištenja klasične tzv. *mean-variance* optimizacije u tom slučaju.

Bergh i Rensburg (2008) u svom su radu isto ukazali na nenormalnu distribuiranost prinosa hedge fondova. Pored zasebne optimizacije indeksa pojedinih vrsta hedge fondova kao reprezentanta alternativnih oblika, u radu su korišteni i financijski indeksi tradicionalnih oblika ulaganja koje se odnose na dionice, obveznice i novčano tržište. Rezultati ukazuju da višekriterijska optimizacija portfelja daje bolje rezultate od Markowitzeve optimizacije na osnovi Omega mjere efikasnosti portfelja koja je primjerena za uporabu u slučajevima kada distribucija prinosa ne slijedi normalni oblik (Keating i Shadwick, 2002; Bhaduri i Kaneshige, 2005; Abrams et al. 2012). Uslijed pretpostavke normalne distribucije, Markowitzev model značajnu alokaciju daje hedge fondovima radi visokog prinosa, no njihova negativna asimetrija i visoka zaobljenost dovodi do neoptimalnog portfelja u pogledu izloženosti riziku negativnih ekstremnih prinosa (tzv. rizik viših momenata[2]).

Osim hedge fondova, u ovom doktorskom istraživanju uključuju se i ročnice kao alternativni oblik ulaganja koji se pokazao kao potencijalno odličan diverzifikator. Abrams et al. (2012) testirali su utjecaj uključivanja indeksa ročnica u investicijski portfelj s financijskim indeksima hedge fondova, američkih dionica i globalnog tržišta obveznica. Autori su ukazali na koristi uključivanja ročnica u investicijski portfelj što se prije svega odnosi na bolju diversifikaciju, likvidnosti i transparentnost, ali i učinkovitu upotrebu slobodnih novčanih sredstava što je poželjno za institucionalne investitore poput društava za osiguranje. U već ranije spomenutom radu, (Kat, 2004) je testirao utjecaj uključivanja ročnica u investicijski portfelj te ukazao na

[2] Athayde i Flores (2004) ukazuju da investitori preferiraju veće vrijednosti neparnih momenata portfelja (tj. očekivani prinos i asimetričnost), dok teže manjim vrijednostima parnih momenata portfelja (rizik očitovan u varijanci/standardnoj devijaciji te zaobljenosti)

njihov značajan pozitivan učinak na diversifikaciju, a posebno na više momente distribucije (asimetriju i zaobljenost).

U području uključivanja alternativnih oblika u investicijski portfelj, od domaćih radova izdvaja se (Štimac, 2012) gdje je provedena klasična Markowitzeva optimizacija na portfelju koji primarno uključuje indekse prinosa obveznih i dobrovoljnih mirovinskih fondova (MIREX i otvoreni fondovi A, B i C) te novca. Navedeni oblici ulaganja se kombiniraju s alternativnim oblicima koje čine nekretnine, burzovne robe, privatni vlasnički kapital i hedge fondovi u periodu 2002.-2010. a njihovi udjeli određeni su naivnom metodom alokacije. U radu je testirana primjerenost regulacije ulaganja imovine mirovinskih fondova u smislu opravdanosti drakonskih limita ulaganja te je potvrđeno da su limiti ipak potrebni u određenoj mjeri. Dodatno je testirano i potvrđeno da bi uključivanje alternativnih oblika ulaganja u MIREX, obzirom na promatrani period, dovelo do višeg prinosa i manjeg rizika ulaganja mirovinskih fondova. U navedenom istraživanju nije korištena višekriterijska optimizacija kao niti viši momenti distribucije odnosno asimetrija i zaobljenost.

Daljnje navođenje radova iz navedenih područja bilo bi preopširno u ovom dijelu rada te izvan dosega uvoda, stoga će se pregled dosadašnjih istraživanja proširiti u nastavku disertacije.

1.4. Hipoteze rada

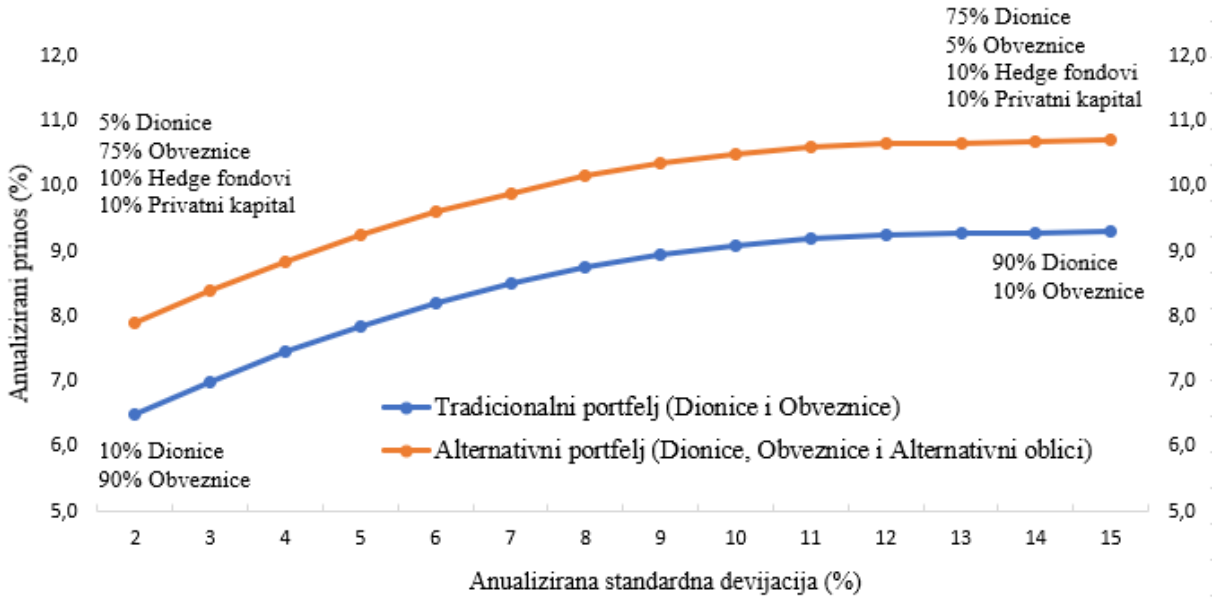
Na temelju definiranog problema i ciljeva postavljaju se hipoteze istraživanja. Svaka od hipoteza je u nastavku rada ukratko obrazložena, te su u sljedećem poglavlju navedene znanstvene metode kojima će se pokušati dokazati istinitost pojedine hipoteze.

H1: Uključivanje alternativnih oblika ulaganja u investicijski portfelj ima jači pozitivni utjecaj na prinos i rizik investicijskog portfelja u odnosu na uključivanje dodatnih tradicionalnih oblika ulaganja.

Cilj hipoteze H1 je dokazati da uključivanje alternativnih oblika ulaganja ne unapređuje investicijski portfelj samo na način da smanjuje rizik ili povećava očekivani prinos, već se takav efekt postiže istovremeno. Drugim riječima, uključivanje alternativnih oblika ulaganja u potpunosti pomiče efikasnu granicu portfelja prema gore. Nesporno je da se uključivanjem dodatnih tradicionalnih oblika ulaganja (npr. novac, strane obveznice, strane dionice, depoziti i sl.) također postižu pozitivni efekti na performanse investicijskog portfelja. No, takvim pristupom se u pravilu povećava samo broj mogućih portfelja na istoj ili približnoj efikasnoj

granici. Sukladno tome, očekuje se da uključivanje alternativnih oblika ima jači pozitivni utjecaj na investicijski portfelj od uključivanja dodatnih tradicionalnih oblika ulaganja. Na grafu 1 vidljiv je pomak efikasne granice kada se uključe alternativni oblici ulaganja (u ovom primjeru hedge fondovi i fondovi privatnog kapitala).

Graf 1 – Efikasna granica sa i bez uključivanja alternativnih oblika ulaganja



Izvor: Obrada autora prema Wells Fargo Investment Institute (podaci od 1.1.1990. – 30.6.2018.)

Testiranje ove hipoteze povezano je s jednim od znanstvenih ciljeva rada, a to je dokazivanje pozitivnog učinka uključivanja alternativnih ulaganja u portfelj sastavljen isključivo od tradicionalnih oblika.

H2: Korištenjem višekriterijskog modela optimizacije koji uključuje više momente distribucije dobiva se efikasniji investicijski portfelj od onog koji je optimiziran Markowitzevim modelom optimizacije.

Predmetnom hipotezom testirati će se efikasnost portfelja uz korištenje Markowitzevog modela i višekriterijskog modela optimizacije koji uključuje više momente. Efikasnost će se mjeriti pomoću relevantne mjere učinkovitosti portfelja kada distribucija ne slijedi normalni oblik. Radi se o Omega mjeri efikasnosti koja je korištena u (Keating i Shadwick, 2002; Bhaduri i Kaneshige, 2005; Abrams et al. 2012). Portfelj koji će imati višu vrijednost Omega mjere smatrati će se efikasnijim. Kao model višekriterijske optimizacije uz više momente koristiti će se metoda nelinearnog programiranja, tzv. polinomno ciljno programiranje, kao često korišten

pristup u optimizaciji portfelja gdje se javlja konfliktnost funkcije cilja[3] (Lai, 1991; Lai et al., 2006; Xu et al., 2007; Mhiri i Prigent, 2010; Kemalbay et al., 2011; Harvey et. al., 2010; Aracioglu et al., 2011; Glawischnig i Seidl, 2013; Škrinjarić, 2013; Saranya i Prasanna, 2014; Bahna, 2016; Naqvi et al., 2017; Khan et al., 2020; Siew et al., 2021), te u situaciji kada se u investicijski portfelj uključuju alternativni oblici ulaganja (Buckley et al. 2008; Davies et al., 2009; Fischeri Lind-Braucher, 2010; Hitaj i Mercuri, 2013; Flifel, 2014; Gautefall i Chen, 2017).

U pogledu hipoteze H2, teorijsko opravdanje hipoteze je da prinosi financijskih vremenskih serija u pravilu ne slijede oblik normalne distribucije. Iz tog razloga je potrebno primijeniti višekriterijski model optimizacije koji se koristi u referenciranim znanstvenim radovima iz popisa literature. Predmetni model u optimizaciju uključuje više momente distribucije, odnosno koeficijente asimetrije i zaobljenosti čime se mogu premostiti ograničenja pretpostavke normalnosti. U višekriterijskoj metodi se provodi maksimizacija 1. i 3. momenta (prinos i asimetrija) te minimizacija 2. i 4. momenta (varijanca/standardna devijacija i zaobljenost) obzirom na teorijsku preferenciju investitora (Athayde i Flores, 2004; Bergh i Rensburg, 2008). U ovakvom problemu optimizacije javlja se konfliktnost funkcije cilja. Za razliku od višekriterijskog modela, Markowitzev model koristi samo prva dva središnja momenta distribucije te zanemaruje preostala 2 relevantna momenta (asimetriju i zaobljenost) koji su danas itekako važni obzirom na ograničenja pretpostavke normalnosti.

H3: Promjena kamatnih stopa jače utječe na promjenu prinosa tradicionalnih oblika ulaganja nego na promjenu prinosa alternativnih oblika ulaganja.

U pogledu hipoteze H3, teorijsko opravdanje bilo bi da promjena kamatnih stopa, bez obzira radi li se o njihovom rastu ili padu, očekivano jače utječe na promjenu prinosa obveznica i dionica nego što utječe na prinose alternativnih oblika ulaganja, konkretno hedge fondova i ročnica. Sukladno tome, očekuje se da će nastavak okruženja povijesno niskih kamatnih stopa (ili njihov rast) jače utjecati na prinose obveznica i dionica nego na prinose hedge fondova i ročnica. Iz tog razloga, investitori čiji investicijski portfelji dominantno uključuju obveznice i

[3] Uz pretpostavku da investitori preferiraju veće vrijednosti neparnih momenata portfelja (tj. očekivani prinos i asimetričnost), dok teže manjim vrijednostima parnih momenata portfelja (rizik očitovan u varijanci/standardnoj devijaciji te zaobljenosti) potrebno je u modelu optimizacije maksimizirati prinos i koeficijent asimetrije te istovremeno minimizirati varijancu/standardnu devijaciju i koeficijent zaobljenosti.

dionice mogu smanjiti izloženost riziku promjene kamatnih stopa kroz uključivanje hedge fondova i ročnica odnosno smanjenje udjela obveznica i dionica.

Jači utjecaj na prinos definira se kao veći apsolutni i/ili relativni iznos promjene prinosa promatranog tradicionalnog oblika ulaganja u odnosu na promatrani alternativni oblik ulaganja.

1.5. Metode znanstvenog istraživanja

H1: Uključivanje alternativnih oblika ulaganja u investicijski portfelj ima jači pozitivni utjecaj na prinos i rizik portfelja u odnosu na uključivanje dodatnih tradicionalnih oblika ulaganja.

Za testiranje hipoteze će se koristiti Markowitzev model optimizacije uz izračun relevantne mjere efikasnosti portfelja (Sharpeov i Sortinov omjer) prije i poslije uključivanja alternativnih oblika ulaganja te nakon uključivanja dodatnih tradicionalnih oblika ulaganja (strane i domaće obveznice i dionice). Dakle, ukoliko se uključivanjem alternativnih oblika ulaganja postigne bolja vrijednost odabranih mjera efikasnosti investicijskog portfelja, testirana hipoteza će se smatrati prihvaćenom. Ovakav model posebice bi bio primjenjiv za investitore koji imaju izražene preferencije isključivo prema prva dva momenta distribucije odnosno očekivanom prinosu i riziku.

Testiranje hipoteze i optimizacije će krenuti od portfelja koji se 100% sastoji od tradicionalnih oblika ulaganja te će se udio alternativnih oblika dodavati u inkrementima od 5-10% čime će se simulirati veći broj portfelja sa i bez alternativnih oblika ulaganja uz variranje udjela istih. Isti postupak će se primijeniti i kod uključivanja dodatnih tradicionalnih oblika ulaganja.

U hipotezi H1, za mjerenje jačine pozitivnog utjecaja, **se koriste Sharpeov i Sortinov omjer** jer se hipoteza H1 testira primjenom Markowitz modela optimizacije radi čega u model i mjere nije potrebno uključivati više momente (asimetriju i zaobljenost). Drugim riječima, za evaluaciju efikasnosti dovoljno je koristiti navedene omjere obzirom da njihova vrijednost ovisi samo o prva dva momenta distribucije prinosa (očekivanom prinosu i varijanci/standardnoj devijaciji).

H2: Korištenjem višekriterijskog modela optimizacije koji uključuje više momente distribucije dobiva se efikasniji investicijski portfelj od onog koji je optimiziran Markowitzevim modelom optimizacije.

Pri testiranju hipoteze H2 koristiti će se optimizacija na osnovi Markowitzevog modela i višekriterijski model optimizacije koji uključuje više momente, tzv. polinomno ciljno programiranje kao često korištena metoda u optimizaciji s višim momentima te kod uključivanja alternativnih oblika ulaganja u investicijski portfelj (Lai, 1991; Škrinjarić, 2013; Kemalbay et al., 2011; Davies et al., 2009). Dakle, prvo će se metodama optimizacije odrediti optimalan udio alternativnih oblika ulaganja u portfelju te će se utvrditi vrijednosti svih momenata distribucije u dobivenim portfeljima. Potom će se za usporedbu efikasnosti portfelja koristiti Omega mjera efikasnosti portfelja koja je primjerena u slučajevima kada distribucija prinosa portfelja ne slijedi normalni oblik. Mjera je obrazložena i korištena u (Keating i Shadwick, 2002; Bhaduri i Kaneshige, 2005; Abrams et al. 2012).

U hipotezi H2 se za mjerenje efikasnosti investicijskog portfelja koristi Omega mjera obzirom da se radi o relevantnoj mjeri učinkovitosti portfelja kada distribucija ne slijedi normalni oblik. Višekriterijski model optimizacije, kojim će se testirati hipoteza H2, uključuje više momente gdje se istovremeno maksimizira 1. i 3. moment i minimizira 2. i 4. moment. Iz tog razloga se takav model smatra višekriterijskim što implicira da mjera kojom se uspoređuju portfelji optimizirani takvim modelom također treba uzimati u obzir više momente kao što je to slučaj kod Omega mjere.

Viši momenti distribucije koriste se jer se smatra da vremenske serije promatranih varijabli ne prate oblik normalne distribucije koja pretpostavlja koeficijent asimetrije 0 i koeficijent zaobljenosti 3. Korištenjem viših momenata istraživanje dobiva veću reprezentativnost obzirom da model višekriterijske optimizacije ne pretpostavlja unaprijed oblik distribucije, kao što je slučaj kod Markowitzevog i sličnih modela koji ne uključuju više momente distribucije. Viši momenti važni su faktori za uzimanje u obzir u određivanju cijena vrijednosnih papira i vrednovanju portfelja koji se sastoje od tih vrijednosnih papira (Bhandari i Sanjiv, 2009).

Brojna referencirana znanstvena istraživanja su testirala normalnost distribucija prinosa dionica, obveznica, hedge fondova i ročnica pomoću metode Jarque-Bera testa obzirom da isti koristi koeficijent asimetrije i zaobljenosti distribucije za provedbu testa. Činjenica da se radi o

asimptotskom testu daje smisao primjene na velikim uzorcima (Bahovec i Erjavec, 2009) što je slučaj i u analiziranom razdoblju istraživanja od 2006.-2020. s ukupno 180 mjesečnih opažanja.

H3: Promjena kamatnih stopa jače utječe na promjenu prinosa tradicionalnih oblika ulaganja nego na promjenu prinosa alternativnih oblika ulaganja.

Za testiranje hipoteze H3 koristiti će se relevantna ekonometrijska metoda. Modeliranje utjecaja promjene kamatnih stopa na odabrane oblike tradicionalnih i alternativnih oblika ulaganja provesti će se VAR metodologijom. Tijekom istraživanja literature utvrđeno je da se VAR modeli često koriste u formalnom testiranju ekonomskih teorija koje pretpostavljaju povezanost ekonomskih varijabli, te u analizi dinamike pojava u prethodnim periodima (Bahovec i Erjavec, 2009). Prema potrebi, hipotezu je moguće dodatno testirati i regresijskom analizom.

Osim navedenih metoda dokazivanja pojedine hipoteze, u istraživanju će se koristiti i ostale uobičajene metode poput:

- metoda indukcije i dedukcije za donošenje zaključaka
- metoda analize i sinteze za povezivanje tvrdnji i zaključaka u složene koncepte
- metoda klasifikacije za podjelu složenijih entiteta na jednostavnije kako bi se stvorio prostor za korištenje metode analize, tj. raščlanjivanja već poznatih tvrdnji i modela na njihove sastavne elemente
- metoda komparacije za usporedbu različitih mjera, metoda i postupaka
- metoda deskripcije
- statističke i matematičke metode.

1.6. Očekivani znanstveni i aplikativni doprinos

Znanstveni doprinos ovog doktorskog rada proizlazi iz sljedećeg:

- U radu će se detaljno istražiti problematika povijesnog okruženja niskih kamatnih stopa u analiziranom razdoblju te empirijski analizirati utjecaj istog na prinose investicijskog portfelja društava za osiguranje.
- Dobivanje kvalitetnog uvida i jasnog razumijevanja dobrobiti uključivanja alternativnih oblika ulaganja u strukturu investicijskog portfelja institucionalnih investitora. Pod investitorima se u prvom redu smatraju društva za osiguranje. Shodno tome, dodatno će se ispitati utjecaj ulaganja u alternativne oblike na solventnost osiguratelja obzirom na zahtjeve važećeg regulatornog režima Solventnost II.

- Istraživanjem će se definirati višekriterijski model optimizacije koji će omogućiti utvrđivanje optimalnog udjela alternativnih i tradicionalnih oblika ulaganja kao prijedlog rješenja na problem okruženja povijesno niskih kamatnih stopa u analiziranom razdoblju. Model optimizacije će se kodirati u programskom rješenju R što će omogućiti zainteresiranim dionicima upotrebu definiranog modela.
- Uzimajući u obzir nenormalnu distribuiranost vremenskih serija korištenih varijabli, ispitati će se efikasnost investicijskog portfelja dobivenog korištenjem višekriterijskog i Markowitzevog modela optimizacije.
- Ispitivanje utjecaja promjene kamatnih stopa na cijenu odnosno prinose alternativnih i tradicionalnih oblika ulaganja.

Znanstveni doprinos ove doktorske disertacije u najvećem dijelu predstavlja prijedlog rješenja na problem povijesnog okruženja niskih kamatnih stopa koje je u analiziranom razdoblju prisutno u Republici Hrvatskoj. Prijedlog rješenja daje se kroz ispitivanje utjecaja uključivanja alternativnih oblika ulaganja u strukturu investicijskog portfelja pomoću definiranog višekriterijskog modela optimizacije. Navedeni oblik modela se koristi jer se smatra da vremenske serije promatranih varijabli ne slijede oblik normalne distribucije, a radi čega su u optimizaciju uključeni i viši momenti distribucije (asimetrija i zaobljenost). Navedeno će se testirati kroz hipotezu H2.

Investitor bi primjenom višekriterijskog modela premostio ograničenja pretpostavke normalne distribucije. Također, potencijalno bi smanjio izloženost riziku promjene kamatnih stopa jer bi u portfelj uključio alternativne oblike ulaganja čiji su prinosi pod slabijim utjecajem promjena kamatnih stopa nego što je to slučaj kod tradicionalnih oblika (dionice, obveznice). Navedeno se dokazuje odnosno testira putem hipoteze H3.

U ekstenzivnom istraživanju literature, autor je naišao na visoku oskudnost domaćih radova iz područja istraživanja. Posebice se to odnosi na radove koji, na temelju Markowitzeve metode optimizacije, eksplicitno optimiziraju investicijski portfelj uključivanjem referentnih alternativnih oblika ulaganja (hedge fondovi, ročnice) u portfelj koji se sastoji isključivo od tradicionalnih oblika ulaganja (domaćih i/ili stranih dionica i obveznica). Većina domaćih radova u kojima se primjenjuje Markowitzev model optimizacije koristi dionice i njihov broj u portfelju kao osnovu za optimizaciju odnosno izvor diversifikacije. Woerheide i Persson (1993) pružaju pregled načina mjerenja razine diversifikacije portfelje te izdvajaju Herfindahlov indeks kao najbolju opciju.

Znanstveni doprinos u dijelu korištenja Markowitzevog modela optimizacije je da uključivanje alternativnih oblika ulaganja ne unapređuje portfelj samo na način da smanjuje rizik ili povećava očekivani prinos kao što se to postiže uključivanjem ostalih tradicionalnih oblika (npr. novac, depoziti, strane obveznice i dionice i sl.), već u potpunosti pomiče efikasnu granicu prema gore. Drugim riječima, uključivanjem alternativnih oblika ulaganja moguće je istovremeno postići i bolji očekivani prinos i niži rizik (tj. varijancu/standardnu devijaciju) radi njihove iznimno niske, u nekim slučajevima i negativne, koreliranosti s tradicionalnim oblicima ulaganja. S druge strane, uključivanje dodatnih tradicionalnih oblika uglavnom povećava samo diversifikaciju odnosno smanjuje rizik te samim time i povećava broj efikasnih portfelja na istoj ili približnoj efikasnoj granici. Sukladno navedenom, **znanstveni doprinos hipoteze H1** je ispitivanje mogućnosti i analiza perspektive dobrobiti uključivanja alternativnih oblika ulaganja u investicijski portfelj za hrvatske investitore.

U pogledu pregledavanja literature o utjecaju kamatnih stopa na odabrane oblike ulaganja, također je utvrđena oskudnost domaćih radova koji se bave ovom problematikom, a koja je obzirom na okruženje niskih kamatnih stopa u analiziranom razdoblju te izvjesni ulazak RH u eurozonu u današnje vrijeme iznimno relevantna.

Znanstveni doprinos hipoteze H2 i H3 proizlazi iz definiranja višekriterijskog modela optimizacije koji će imati pristupačnu aplikativnu primjenu obzirom da će biti kodiran u programskom paketu R, kao i dobivanje spoznaje o intenzitetu utjecaja promjene kamatnih stopa na prinose promatranih oblika ulaganja.

Hipoteza H1 predstavlja uvodni dio doktorskog istraživanja gdje se na primjeru tradicionalnog portfelja, koji se sastoji i od hrvatskih dionica i obveznica, kroz primjenu Markowitzevog modela optimizacije želi testirati prednosti uključivanja alternativnih oblika ulaganja u investicijski portfelj. Hipoteze H2 i H3 idu dublje u problem istraživanja te podižu razinu kompleksnosti testiranja hipoteza.

Aplikativni doprinos disertacije očituje se u definiranju znanstveno utemeljenog modela optimizacije koji je razvijen na osnovi empirijskih podataka. Takav kreirani model može poslužiti širokom spektru institucionalnih investitora, prije svega društvima za osiguranje i mirovinskim fondovima u prilagodbi strukture investicijskih portfelja s ciljem ostvarivanja viših prinosa u analiziranom razdoblju niskih kamatnih stopa. Činjenica da će model biti kodiran u programskom paketu R omogućiti će relativno jednostavan pristup i dostupnost modela i drugim dionicima u budućim znanstvenim i inim istraživanjima i primjenama.

Dodatan značaj očekivanom doprinosu ove disertacije daje i sljedeće:

- **Relevantnost problema istraživanja** – Problem povijesnog okruženja niskih kamatnih stopa u analiziranom razdoblju istraživanja od 2006.-2020. godine je fenomen koji je potrebno ekstenzivno istraživati kako bi ga se bolje razumjelo.
- **Duljina vremenske serije** – Vremenska serija mjesečnih opservacija u periodu 2006.-2020. godine daje ukupno 180 opažanja te omogućava visoku razinu reprezentativnosti rezultata istraživanja**.**

1.7. Struktura rada

Uvodno poglavlje prezentira opseg i kontekst istraživanja uz definiranje problema istraživanja. Potom su ukratko obrazloženi objektivni razlozi odabira i relevantnosti teme nakon čega se navode primarni i sekundarni ciljevi istraživanja. Dalje u uvodnom dijelu rada slijedi pregled dosadašnjih mjerodavnih empirijskih istraživanja s ciljem boljeg razumijevanja dosega prethodnih radova iz područja istraživanja. U nastavku rada se izlažu hipoteze i metode njihovog dokazivanja što zajedno predstavlja osnovu za kreiranje očekivanog znanstvenog i aplikativnog doprinosa istraživanja. U zadnjem dijelu uvodnog poglavlja obrazlaže se struktura doktorske disertacije.

U drugom poglavlju, pod naslovom *Teorije i modeli oblikovanja investicijskog portfelja,* iznosi se teorijska pozadina osnovnih modela upravljanja i oblikovanja investicijskog portfelja. Početak poglavlja sadrži pregled strukture tradicionalnog portfelja institucionalnih investitora koji se sastoji većinom od obveznica i dionica, s time da struktura predmetnih oblika ulaganja ovisi o preferencijama investitora. U ovom dijelu se ukratko prezentira model moderne teorije portfelja (tzv. Markowitzev model). Obzirom na prednosti, ali i utvrđene nedostatke predmetnog modela, odmah se u nastavku prezentiraju i modeli koji ga nadograđuju, posebice oni koji u optimizaciji koriste više momente distribucije. Na kraju poglavlja se izlažu glavne mjere efikasnosti portfelja, s naglaskom na one koje će se primjenjivati u testiranju hipoteza.

Treće poglavlje, s naslovom *Alternativni oblici ulaganja i njihov utjecaj na efikasnost investicijskog portfelja*, obuhvaća detaljan pregled glavnih oblika alternativnih ulaganja te predstavlja istraživanja o njihovom utjecaju na performanse investicijskog portfelja. Oblici alternativnih ulaganja koja su primarno u fokusu istraživanja su hedge fondovi i ročnice. Smatra se da njihov doprinos investicijskom portfelju nije dostatno istražen, barem u kontekstu institucionalnih investitora u Republici Hrvatskoj, a u čemu se također reflektira jedan od

znanstvenih doprinosa ovog rada. U poglavlju se također daje pregled najvećih upravitelja fondova alternativnih oblika ulaganja, mjerenim prema visini imovine pod upravljanjem te primarno lociranih u EU kako bi istraživanje imalo značajniji aplikativni doprinos. Pored pregleda upravitelja, u ovom poglavlju predstavljen je i trenutno važeći regulatorni okvir koji regulira segment alternativnih ulaganja.

Naslov četvrtog poglavlja je *Sektor osiguranja i regulativa Solventnost II*. Cilj ovog poglavlja je predstaviti problematiku istraživanja u kontekstu društava za osiguranja kao institucionalnih investitora. Industrija osiguranja će u ovom poglavlju poslužiti kao primjer kako alternativni oblici ulaganja mogu doprinijeti investicijskim portfeljima osiguratelja u povijesnom okruženju niskih kamatnih stopa. Sukladno tome, u početku poglavlja će se prezentirati prosječna struktura investicijskog portfelja društava za osiguranje dok će se u nastavku izložiti glavne odrednice regulative Solventnost II. To uključuje koncept omjera solventnosti i potrebnog solventnog kapitala kao glavnog indikatora sigurnosti poslovanja osiguratelja. U zadnjem dijelu poglavlja ja analizirano okruženje niskih kamatnih stopa u analiziranom razdoblju.

Peto poglavlje, pod naslovom *Optimizacija i empirijska analiza utjecaja alternativnih oblika ulaganja na investicijski portfelj*, predstavlja glavno poglavlje doktorske disertacije. U ovom dijelu rada se iznose rezultati korištenih statističkih i ekonometrijskih metoda putem kojih su testirane hipoteze istraživanja. Na osnovi testiranja hipoteza, utvrđene su nove empirijske spoznaje iz kojih proizlazi konkretan znanstveni i aplikativni doprinos rada. Također, u ovom se poglavlju iznose i interpretiraju rezultati provedenih (višekriterijskih) optimizacija. Nakon predstavljanja rezultata, diskutiraju se daljnje praktične aplikacije definiranog modela optimizacije.

Šesto i posljednje poglavlje čini zaključak cijele doktorske disertacije odnosno sintezu glavnih nalaza istraživanja. U okviru poglavlja navedena su i ograničenja doktorskog istraživanja te su izneseni prijedlozi i smjernice za buduća znanstvena istraživanja.

2. TEORIJE I MODELI OBLIKOVANJA INVESTICIJSKOG PORTFELJA

U ovom poglavlju izlažu se neke osnovne teorije i modeli upravljanja investicijskim portfeljem. Obzirom da je pregled modernih teorija poput Markowitzeve dostupan u brojnim prethodnim znanstvenim radovima, u ovom radu samo će se kratko ponoviti osnovne značajke predmetnog modela, kao i njegove prednosti i nedostatke. Potom će se dati pregled modela koji nadopunjuju Markowitzev model uz pregled višekriterijskog modela optimizacije. Prije pregleda modela oblikovanja portfelja, navode se definicije i karakteristike tradicionalnog portfelja institucionalnih investitora kao i obrazloženje koncepta upravljanja tržišnim rizicima.

2.1. Tradicionalni portfelj institucionalnih investitora

Institucionalnim investitorima možemo smatrati sljedeće entitete prema (Basile i Ferrari, 2016):

- subjekti za zajednička ulaganja (tj. društva za upravljanje investicijskim fondovima)
- individualno upravljanje portfeljem, temeljeno na mandatima dobivenim od klijenata na diskrecijskoj osnovi
- društva za osiguranje
- mirovinski fondovi
- zaklade
- investicijske banke, ukoliko se pretpostavi opsežnija definicija investitora.

Društva za osiguranje razlikuju se od ostalih navedenih investitora obzirom da je njihova uloga sistematično preuzimanje i upravljanje rizicima od drugih kompanija i pojedinaca. Usluga koju pružaju osiguratelji naplaćuje se putem osigurateljne premije čija visina ovisi o vjerojatnosti nastanka događaja s kojima su preuzeti rizici povezani. U tablici 2 je prikaz investicijske strategije društava za osiguranje.

Pružajući financijsku zaštitu, osiguratelji imaju ključnu ulogu u gospodarskom rastu i razvoju zemlje. Zbog rizičnih aspekata poslovanja i ugovornih obveza prema osiguranicima, tradicionalne prakse investiranja društava za osiguranje mogu se okarakterizirati kao konzervativne.

Tablica 2 – Investicijska strategija društava za osiguranje

Cilj	Apetit za rizikom	Vremenski horizont	Financijski profil	Ograničenja upravljanja portfeljem	Pristup upravljanju
Investiranje unaprijed dobivene premije s ciljem generiranja financijskih izvora za podmirenje budućih obveza i šteta prema osiguranicima	Srednji-Nizak	Kratkoročni, Srednjoročni i Dugoročni horizont ovisno o profilu osiguranjih obveza i vrsti društva za osiguranje	Predvidljive potrebe za likvidnosti	Kapitalni zahtjevi ovisno o specifičnom obliku ulaganja (npr. obveznice, dionice, nekretnine i dr.)	Upravljanje imovinom i obvezama

Izvor: (Basile i Ferrari, 2016)

2.1.1. Tradicionalni portfelj i oblici ulaganja

Koncept tradicionalnog portfelja povezan je s činjenicom da takav portfelj sadrži isključivo tradicionalne oblike ulaganja. U klasičnom smislu radi se o portfelju koji sadrži određeni udio obveznica i dionica kao glavnih tradicionalnih oblika ulaganja. Odabir oblika ulaganja koji će se uključiti u investicijski portfelj kao i raspodjela sredstava između različitih oblika su glavne investicijske odluke. Primjerice, portfelj dionica i obveznica u omjeru 60/40 ima drugačiji očekivani prinos i rizik od portfelja u omjeru 40/60. Alokacija omjera odabranih oblika ulaganja ovisi o vrsti i preferenciji investitora, a u čestom slučaju i o profilu njegovih obveza (Sharpe et al., 2007).

Prije detaljnijeg ulaska u vrste oblika ulaganja, potrebno je ukratko obrazložiti koncept alokacije sredstava na raspoložive oblike ulaganja. Alokacija sredstava u pravilu se dijeli na strateški i taktičku alokaciju. **Strateška alokacija** definira investitorove ciljeve po pitanju prinosa, tolerancije na rizike i ograničenja ulaganja u pogledu prihvatljivih oblika ulaganja gdje kao konačan rezultat proizlaze njihovi definirani udjeli u ukupnom investicijskom portfelju. S druge strane, **taktična alokacija** uključuje donošenje kratkoročnih prilagodbi u udjelu oblika ulaganja s obzirom na očekivanja u pogledu kretanja prinosa pojedinog oblika. U tablici 3 je dan primjer strateške alokacije portfelja gdje se vidi ciljani postotni udio svakog oblika ulaganja i raspon dozvoljenih odstupanja od ciljanog udjela, a koji proizlazi iz procesa upravljanja tržišnim rizikom. Budući da alokacije izvan dozvoljenog raspona mogu sa sobom nositi značajno različite implikacije na dozvoljenu razinu rizika, investicijski portfelj je potrebno rebalansirati ukoliko udio pojedinog oblika ulaganja prijeđe izvan dozvoljenog raspona (Sharpe et al., 2007).

Tablica 3 – Primjer strateške alokacije investicijskog portfelja

	Oblik ulaganja	Ciljana alokacija	Dozvoljeni raspon
1	Domaće državne obveznice RH	50%	45-55%
2	Korporativne obveznice RH i EU (investicijski rejting)	10%	8-12%
3	Inozemne i globalne obveznice (EU, SAD i dr.)	10%	5-15%
4	Novčani oblici RH (npr. kratkoročni depoziti)	5%	0-10%
5	Domaće dionice RH	15%	12-18%
6	Inozemne dionice (EU, SAD i dr.)	10%	7-13%

Izvor: Rad autora

Alokacija oblika ulaganja ovisi primarno o ciljevima investitora u pogledu prinosa i rizika, a čije granice proizlaze najčešće iz profila obveza prema osiguranicima kada se radi o društvima za osiguranje. Dva glavna pristupa u strateškoj alokaciji čine onaj koji se bazira samo na imovini (eng. *Asset-Only*) i pristup istovremenog upravljanja imovinom i obvezama (eng. *Asset&Liability Management*). Potonji pristup koriste društva za osiguranje gdje je glavni prioritet kontrola rizika vezanih uz financiranje budućih financijskih obveza prema osiguranicima koje se odnose na štete po policama (ne)životnih osiguranja.

Oblik ulaganja odnosno imovinska klasa je skupina imovine sa sličnim atributima. Odabir oblika ulaganja kao inputa za stratešku alokaciju imovine važna je odluka, s dugoročnim učincima na prinos i rizik portfelja. Odabir mora biti u skladu s dozvoljenim klasama imovine u investicijskoj politici što u praksi može imati značajne varijacije, odražavajući regulatorna i druga ograničenja koja utječu na strukturu portfelja. Primjerice, društva za osiguranje su prije stupanja na snagu regulative Solventnost II bila podložna regulatornim ograničenjima ulaganja u pojedine oblike (npr. ulaganja u dionice i inozemne financijske instrumente).

2.1.1.1 Kriteriji za specifikaciju oblika ulaganja

Osnovno načelo je da specifikacija oblika ulaganja treba podržavati cilj strateške alokacije imovine. U nastavku su navedeni kriteriji pomoću kojih se učinkovito može odrediti oblik ulaganja (Sharpe et al., 2007):

- **Imovina unutar oblika ulaganja trebala bi biti relativno homogena i imati slične atribute**. Primjerice, definiranje dionica koje uključuju i nekretnine i obične dionice rezultiralo bi nehomogenim oblikom ulaganja.

- **Oblici ulaganja trebali bi se međusobno isključivati**. Preklapanje oblika može smanjiti učinkovitost strateške alokacije imovine u kontroli rizika i uvesti probleme u razvoju očekivanja prinosa na odabrani oblik. Primjerice, ako su jedan oblik ulaganja za europskog ulagača domaće dionice, tada su svjetske dionice (izvan EU) prikladniji izbor.

- **Oblici ulaganja trebali bi imati diversifikacijska svojstva**. Za potrebe kontrole rizika, uključeni oblik ulaganja ne bi trebao imati izrazito visoke očekivane korelacije s drugim oblicima. U suprotnom, uključeni oblik ulaganja biti će suvišan u portfelju jer će duplicirati već prisutne izloženosti riziku. Općenito, korelacija između 2 oblika iznad 0,95 je nepoželjna.

- **Oblici ulaganja kao grupa trebali bi činiti prevlast svjetskog bogatstva koje se može uložiti**. Iz perspektive teorije portfelja, odabir raspodjele imovine iz grupe oblika ulaganja koje zadovoljavaju ovaj kriterij trebao bi težiti povećanju očekivanog prinosa za danu razinu rizika. Nadalje, uključivanje više svjetskih tržišta proširuje mogućnosti za primjenu aktivnih strategija ulaganja.

- **Oblik ulaganja treba imati kapacitet da može predstavljati značajan dio investicijskog portfelja investitora bez ozbiljnog utjecaja na likvidnost portfelja**. U praksi većina investitora želi biti u mogućnosti rebalansirati portfelj na stratešku alokaciju bez utjecaja na cijenu imovine ili stvaranja visokih transakcijskih troškova.

Tradicionalni oblici ulaganja uključuju sljedeće**:**

- **Domaće dionice**. Tržišna kapitalizacija ponekad se koristila kao kriterij za razlikovanje velikih, srednjih i malih domaćih dionica kao pojedinih (pod)oblika ulaganja.

- **Domaći instrumenti s fiksnim prinosom (npr. domaće državne obveznice).** Dospijeće se ponekad koristilo za razlikovanje između srednjoročnih i dugoročnih domaćih obveznica kao (pod)oblika ulaganja. Obveznice zaštićene od inflacije također mogu biti zaseban oblik.

- **Strane dionice**. Status razvijenosti tržišta ponekad se koristi za razlikovanje dionica razvijenih tržišta i dionica tržišta u nastajanju kao odvojenih oblika.

- **Strani instrumenti s fiksnim prinosom (npr. strane državne obveznice).** Status razvijenosti tržišta ponekad se koristi se razlikovanje obveznica razvijenih tržišta i obveznica tržišta u nastajanju kao odvojenih oblika.

- **Nekretnine**. Termin alternativna ulaganja danas se često koristi za označavanje svih rizičnih oblika ulaganja osim prethodno navedenih. Alternativni oblici mogu uključivati nekretnine, privatni kapital (eng. *private equity*), prirodne resurse, robe (eng. *commodities*), valute i strategije ulaganja koju provode hedge fondovi. Ovakva generalizacija je pragmatična, ali takve grupe treba izdvojiti kao zasebne oblike ulaganja uz nekretnine jer alternativni oblici nemaju visoku razinu homogenosti.

- **Novac i novčani ekvivalenti**.

2.1.1.2 Uključivanje stranih oblika ulaganja (Razvijena i tržišta u razvoju)

U prethodnom dijelu navedeno je da bi oblici ulaganja kao grupa trebali činiti prevlast svjetskog bogatstva koje se može uložiti. Prema tom kriteriju, strana (međunarodna) imovina ima mjesto u skupu dopuštenih oblika imovine za mnoge investitore.

Objektivni kriterij temeljen na analizi prinosa i varijance može pomoći investitoru u odluci može li poboljšati svoj postojeći portfelj uključivanjem pozitivnog udjela stranih dionica, obveznica ili bilo kojeg drugog oblika imovine.

Neka se pretpostavi da investitor drži portfelj p s očekivanim prinosom $E(Rp)$ i standardnom devijacijom prinosa σp. Investitor tada dobiva priliku uključiti još jedan oblik ulaganja u svoj portfelj. Može li investitor postići poboljšanje vrijednosti prinosa i varijance proširenjem svog portfelja kako bi uključio pozitivan udjel u obliku ulaganja? Da bismo odgovorili na ovo pitanje, potrebna su nam tri ulazna parametra (Sharpe et al., 2007):

1. Sharpeov omjer oblika ulaganja
2. Sharpeov omjer postojećeg portfelja
3. Korelacija između prinosa oblika ulaganja koji se razmatra za uključivanje i prinosa portfelja p, Corr($R_{new,}$ R_p).

Uključivanje oblika ulaganja (označenog kao *new*) u portfelj je optimalno ako je sljedeći uvjet ispunjen:

$$\frac{E(R_{new}) - R_F}{\sigma_{new}} > \left(\frac{E(R_p) - R_F}{\sigma_p}\right) \mathrm{Corr}(R_{new}, R_p) \qquad (2.1)$$

Izraz (2.1) kaže da kako bi investitor dobio uključivanjem oblika ulaganja, Sharpeov omjer tog oblika imovine mora biti viši od umnoška Sharpeovog omjera postojećeg portfelja i korelacije prinosa oblika ulaganja s prinosom trenutnog portfelja. Ako je (ne)jednadžba (2.1) zadovoljena, investitor može kombinirati novi oblik sa svojim prethodnim udjelima kako bi postigao superiorniju efikasnu granicu raspoloživih portfelja.

Navedeni izraz ukazuje da se može utjecati na poboljšanje odnosa prinosa i varijance uključivanjem pozitivne vrijednosti novog oblika, ali ne nudi informacije o tome koliko novog oblika uključiti. Za bilo koji portfelj, uvijek se može postići poboljšanje odnosa prinosa i varijance uključivanjem oblika ulaganja s višim Sharpeovim omjerom od postojećeg portfelja. Takav rezultat je intuitivan odnosno ulaganje s višim Sharpeovim omjerom dominirati će nad postojećim portfeljem u pogledu omjera prinosa i varijance. Prije korištenja kriterija izraza (2.1), investitor treba provjeriti je li distribucija prinosa predloženog oblika ulaganja izrazito nenormalna jer ukoliko to jest slučaj, tada opisani kriterij nije primjenjiv.

Investitori bi trebali uzeti u obzir sljedeće posebnosti kada ulažu u međunarodnu imovinu,:

- **Valutni rizik**. Valutni rizik je posebno pitanje za inozemne oblike ulaganja gdje fluktuacije tečaja utječu i na ukupan prinos i volatilnost. Investitori na nedomicilnim tržištima moraju formirati očekivanja o tečajevima ako odluče ne zaštititi se od valutne izloženosti.
- **Povećane korelacije u stresnim razdobljima**. Investitori bi trebali biti svjesni da se korelacije između tradicionalnih oblika ulaganja na međunarodnim financijskim tržištima povećavaju u stresnim vremenima što rezultira značajnim padom cijena i/ili krizom (Baesel et al., 2013).
- **Tržišta u razvoju** (eng. *Emerging markets*). Kod ovakvih oblika uvijek se otvara pitanje ograničenog broja dionica u optjecaju, ograničenja udjela stranog vlasništva, kvaliteta informacija o kompaniji i izražena nenormalnost distribucije prinosa.

Mnogi istraživači vjeruju da američki investitori premalo ulažu u nedomicilna tržišta, što je fenomen koji se naziva pristranost matične zemlje. Jedno objašnjenje predloženo za ovu tendenciju je relativno nepoznavanje stranih tržišta od strane investitora. Indeksiranje oblika ulaganja pruža učinkovit način rješavanja bilo kakvog nedostatka poznavanja određenog tržišta (Sharpe et al., 2007).

2.1.2. Alternativni oblici ulaganja

Alternativni oblici ulaganja odnose se na bilo koju netradicionalnu imovinu s perspektivom rasta ekonomske vrijednosti koja se ne može naći u klasičnom investicijskom portfelju. Opseg ovog pojma značajno se povećao tijekom posljednja dva desetljeća, ali alternativna ulaganja još uvijek moraju dobiti potpuno prihvaćanje od institucionalnih i privatnih investitora, ali i od regulatora. Neki marginalni ulagači smatraju ih špekulativnim ulaganjima, od kojih su mnogi bogati pojedinci spremni preuzeti veći rizik kako bi ostvarili veći prinos. Ipak, razmatranje "tradicionalne" ili "alternativne" imovine varira ovisno o organizaciji i promjenama tijekom vremena (Anson, 2006). Primjerice, domaće dionice i obveznice kojima se aktivno upravlja, koje su 1960-ih smatrane alternativnim ulaganjima, sada su dio većine tradicionalnih investicijskih portfelja. Isto vrijedi i za međunarodne dionice ili derivate u 1970-ima i za nekretnine i dionice tržišta u nastajanju u 1980-ima. Trenutni primjeri alternativnih oblika ulaganja su privatni dionički kapital (eng. *private equity*), rizični kapital (eng. *venture capital*), robe (eng. *commodities*), plemeniti metali, umjetnost, antikviteti, hedge fondovi, kriptovalute. Hedge fondovi se mogu smatrati jednim od najzastupljenijih alternativnih oblika ulaganja. Doživjeli su ogroman rast tijekom 1990-ih, u početku na američkim tržištima, a ubrzo nakon toga na tržištima diljem svijeta, dok su danas važna karakteristika svih svjetskih financijskih tržišta (Molyboga, 2017).

Primjerice, početkom 1990-ih godina, nekretnine su bile treći značajan oblik ulaganja osim obveznica i dionica koju bi investitori naveli kao imovinu za investicijski portfelj. Mnogi investitori danas grupiraju nekretnine zajedno s nizom različitih netradicionalnih ulaganja, kao što su privatni kapital (eng. *private equity*) i hedge fondovi, kao alternativna ulaganja.

2.2. Upravljanje investicijskim rizicima

U ovom poglavlju koncizno će se obraditi upravljanje investicijskim rizicima. U izlaganju koncepta koristi se naziv investicijski rizici jer se time misli na rizike koji proizlaze iz investicijskog procesa. Navedeni rizici mogu se podijeliti na tri homogene kategorije: tržišni rizici, rizik likvidnosti i kreditni rizik (Doff, 2011). Činjenica da je investicijski portfelj najveći dio aktive osiguratelja potvrđuje prethodno, no specifičnost je da se ovi rizici mogu nalaziti ne samo u imovini, već i obvezama osiguratelja (primjerice kamatni i valutni rizik).

Kada se govori o definiciji rizika, posebice u području osiguranja, rizik se može definirati kao odstupanje od očekivanog ishoda. Uzimajući u obzir da je rizik financijskog gubitka od

nastanka štete ukalkuliran u premiju osiguranja, rezidualni rizik se onda javlja u obliku odstupanja od očekivanog gubitka odnosno fenomena neočekivanog gubitka. Ista logika se odnosi i na segment investiranja. Upravljanje rizicima, pa tako i onim investicijskim, bavi se time da se neočekivane gubitke svede na najmanju moguću razinu, vodeći pritom obzira o ciljevima u pogledu očekivanog prinosa (Škunca, 2016).

2.2.1. Vrste investicijskih rizika

Investicijski rizici inherentni su za investicijski portfelj osiguratelja i nakon rizika osiguranja može ih se smatrati najznačajnijim rizicima kojima su osiguratelji izloženi putem svojih investicijskih procesa.

2.2.1.1. Tržišni rizik

U fokusu doktorskog istraživanja primarno će biti ova vrsta rizika obzirom da se pojavnost različitih oblika ulaganja korištenih u optimizaciji najvećim dijelu reflektira kroz izloženost tržišnim rizicima. Drugim riječima, tržišni rizik je najznačajniji rizik u pogledu utjecaja na solventnost prema regulativi Solventnost II, nakon rizika osiguranja.

Tržišni rizik može se smatrati najznačajnijom kategorijom investicijskih rizika. Najčešće se definira kao rizik od pada vrijednosti imovine uslijed promjene tržišnih varijabli, poput kamatnih stopa, cijene vlasničkih vrijednosnih papira, deviznog tečaja, cijene nekretnina i sl., a također uključuje i rizik upravljanja imovinom i obvezama (Doff, 2011). Specifičnost ove vrste rizika je u tome što se može biti prisutan i u imovini i u obvezama osiguratelja uslijed čega se uvijek naglašava važnost simultanog upravljanja imovinom i obvezama. Takav pristup posebno je važan kod društava za životna osiguranja čija visina obveza uvelike ovisi o razini kamatnih stopa.

Važnost kvalitetnog upravljanja tržišnim rizicima proizlazi iz činjenice da je vrijednost ulaganja podložna fluktuacijama na financijskim tržištima. Iz tog razloga, društva za osiguranje nastoje maksimalno uskladiti imovinu i obveze u pogledu ročnosti (dospijeća) i valute, u kojem slučaju promjene na financijskim tržištima ne bi imale gotovo nikakve posljedice na poslovni rezultat. Drugim riječima, promjene imovine i obveza uslijed promjene tržišnih uvjeta imaju gotovo potpuno pozitivnu korelaciju (1). Ukoliko postoji neusklađenost (eng. *mismatch*), što je realnije stanje u poslovnoj praksi, tada se osiguratelj izlaže tržišnim rizicima.

Tablica 4 – Glavne vrste tržišnih rizika

Vrsta rizika	Opis i definicija
Kamatni rizik	Specifičnog ovog rizika je što se pojavljuje u imovini (npr. ulaganje u obveznice) i obvezama (npr. matematička pričuva), gdje se njegova pojavnost povećava uslijed nepovoljnih promjena u visini kamatnih stopa koje negativno utječu na vrijednost imovine i obveza. Klasičan primjer materijalizacije kamatnog rizika bio bi da se dugoročne obveze pokrivaju s kratkoročnom imovinom. U kontekstu osiguratelјne djelatnosti, takav slučaj bi nastao kada bi se obveze po policama mješovitog životnog osiguranja u potpunosti ili većim dijelom pokrivale ulaganjima u novčana sredstva, kratkoročne fondove i sl. Također, uzimajući u obzir da najveći udio investicijskog portfelja čine obveznice odnosno instrumenti s fiksnim prinosom, kamatni rizik je jedan od najizraženijih rizika investicijskog portfelja društava za osiguranje. Posebno je naglašen kod društava koji se bave životnim osiguranjima obzirom na dugoročnost njihovih obveza. Kamatni rizik se zakonski definira kao osjetljivost vrijednosti imovine, obveza i financijskih instrumenata na promjene u vremenskoj strukturi kamatnih stopa ili volatilnosti kamatnih stopa (Zakon o osiguranju, 2015.).
Rizik promjene cijena vlasničkih instrumenata	Ovaj rizik može se definirati kao vjerojatnost da će dionički portfelj zbog volatilnosti cijena dionica koje ga čine izgubiti na vrijednosti. Udio vlasničkih ulaganja, posebno dionica, u investicijskom portfelju u pravilu nije visok. Uslijed volatilne naravi cijene dionica, društva za osiguranja oprezno razmatraju uključivanje odnosno razinu udjela ovog oblika ulaganja u portfelj.
Rizik promjene cijena nekretnina	Predstavlja rizik smanjenja vrijednosti imovine osiguratelja uslijed (nepovoljnih) promjena cijena nekretnina. Ovaj rizik ima specifičnost u tome što se ulaganje u nekretnine u nekim slučajevima smatra alternativnim ulaganjem čija je likvidnost manja u odnosu na primjerice obveznice, dionice i fondove. Iz tog razloga, ulaganja u nekretnine imaju visoku penalizaciju u smislu visine kapitalnih zahtjeva po regulativi Solventnost II.
Valutni rizik	Valutni rizik je, uz kamatni rizik, također prisutan u imovini i obvezama osiguratelja i utječe na sve aspekte elemenata korporativnih financija: novčani tok, prihode, imovinu i obveze (Myint i Famery, 2012). Valutni rizik je i dalje jedan od značajnijih rizika investicijskog portfelja osiguratelja na RH tržištu uslijed visokog udjela državnih obveznica denominiranih u EUR. Republika Hrvatska je visokoeuroizirana zemlja čija gospodarska i

Vrsta rizika	Opis i definicija
	monetarna stabilnost primarno ovisi o stabilnosti cijena, a time i kretanju deviznog tečaja HRK/EUR. Sukladno tome, jedan od glavnih ciljeva Hrvatske Narodne Banke je održavanje stabilnosti tečaja EUR/HRK te ograničavanje njegove fluktuacije. Jedna od pozitivnih promjena uvođenja EUR-a početkom 2023. godine biti će nestanak valutnog rizika EUR/HRK koji čini najveću valutnu izloženost većine društava za osiguranje.
Rizik (kreditnih) raspona	Rizik kreditnih raspona (eng. *Credit spread risk*) predstavlja rizik smanjenja vrijednosti financijskog instrumenta uslijed promjena u kreditnom rasponu. Kreditni raspon se može promatrati kao premija rizika koju investitori zahtijevaju uslijed držanja rizičnije imovine, poput primjerice korporativnih obveznica koje u pravilu imaju više prinose u odnosu na državne obveznice. Razina ovog rizika je determinirana i kretanjima odnosno sentimentom na tržištu kapitala, kao i kreditnom kvalitetom izdavatelja financijskog instrumenta (Doff, 2011).

Izvor: Obrada autora

Obzirom da je, s aspekta investicijskog portfelja, kamatni rizik najvažniji i najznačajniji segment tržišnog rizika, u poglavlju 4.3. posebno je analizirana problematika okruženja niskih kamatnih stopa za osiguratelje u analiziranom razdoblju 2006.-2020. godine.

2.2.1.2. Kreditni rizik

U investicijskom kontekstu, kreditni rizik se kod društava za osiguranje javlja kroz značajnu izloženost izdavateljima dužničkih instrumenata, primarno državnih i korporativnih obveznica, ali i depozita u bankama. Svi emitenti financijskih instrumenata potencijalno su izloženi riziku slabljenja vlastitog boniteta (tj. kreditnog rejtinga) koji je odraz njihove sposobnosti ispunjavanja preuzetih obveza. Drugi oblici izloženosti ovoj vrsti rizika pojavljuju se kroz preuzimanje ulagačke pozicije u derivativnim instrumentima obzirom da takvi poslovi spadaju u oblik ugovorne obveze. Od relevantnih kreditnih izloženosti za osiguratelje izdvajaju se i poslovi reosiguranja, no oni nisu dio investicijskog procesa.

Državne obveznice se u pravilu tretiraju kao nerizične izloženosti, što znači da osiguratelj u tom slučaju nije izložen kreditnom riziku jer je gotovo sigurno da će obveznice biti isplaćene po dospijeću. Većina zapadnih razvijenih EU zemalja, uključujući neke dodatne zemlje poput SAD-a, Kanade, Japana, smatra se vrlo solventnim te dakle i nerizičnima. S druge strane, zemlje

u razvoju, i one s nižim kreditnim rejtingom, smatraju se manje solventnim što dovodi u pitanje pretpostavku o nerizičnosti obveznica takvih zemalja.

Primjerice, tijekom krize u Argentini 2002. godine, vlada nije bila u stanju ispuniti svoje obveze, te nije platila niti kamate ni glavnicu na svoj dug. Drugi primjer je kriza državnih obveznica pojedinih EU zemalja, posebice onih na području mediterana (tzv. PIIGS[4] zemlje), koja je uslijedila kao posljedica financije krize 2007-2008 u SAD-u. Investitori su tada imali izrazito negativan sentiment i sumnje da vlade tih zemalja neće biti u mogućnosti otplatiti svoj dug uslijed visokih proračunskih deficita, posebno u slučaju Grčke (Škunca, 2016). Bijlsma i Vermeulen (2016) analizirali su aktivnosti osiguratelja tijekom navedene krize koji su značajan dio sredstava iz svojih investicijskih portfelja realocirali u sigurnije oblike ulaganja (eng. *flight to quality*). U situaciji nemogućnosti države da podmiri svoj dug temeljem izdanih obveznica, investitori bi tada imali određeni gubitak u visini cjelokupne ili djelomične vrijednosti obveznica (Doff, 2011). U ovom kontekstu je potrebno spomenuti i primjer Islanda koji je tijekom 2008-2011. doživio potpuni kolaps bankarskog sustava koji se odrazio i na cjelokupnu ekonomiju zemlje.

Pored državnih obveznica, osiguratelji investiraju svoja sredstva i u korporativne obveznice koje uključuju više kreditnog rizika. U cilju kompenzacije višeg rizika, prinos na korporativne obveznice je u pravilu veći nego na državne obveznice. Društva za osiguranje često koriste izvedene financijske instrumente za hedžiranje rizičnih izloženosti, posebno kod izloženosti kamatnom i valutnom riziku, ali i kod kreditnih izloženosti (eng. *credit default swap*). Derivati su izvedeni financijski instrumenti čija je vrijednost izvedena iz vrijednosti cijena roba, kamatnih stopa, cijena dionica, deviznih tečajeva, ali također i osigurateljnih indeksa (Vaughan i Vaughan 2008). Osiguratelj u slučaju ugovaranja derivata također preuzima kreditni rizik obzirom da može doći do neispunjenja obveze od suprotne strane.

2.2.1.3. Rizik likvidnosti

Rizik likvidnosti također se može smatrati kao jedan od bitnijih investicijskih rizika, a što potvrđuje i zadnja financijska kriza. Rizik likvidnosti može se definirati kao rizik neočekivanih ili neočekivano visokih plaćanja, gdje bi ispunjenje obveza uključivalo gubitak. Ovaj rizik za osiguratelje može se javiti u slučaju događaja katastrofalnih šteta, gdje obveze iz neživotnih osiguranja mogu iznenada biti u potrebi za plaćanjem uz visoke i frekventne iznose

[4] Portugal, Italija, Irska, Grčka i Španjolska

šteta. Društva za osiguranje manje su međusobno poslovno povezana nego što je to slučaj kod banaka, što ih stavlja u situaciju manje vjerojatnosti da će problemi jednog osiguratelja imati utjecaj na druga društva (Doff, 2011).

Osiguratelji koriste likvidnu imovinu odnosno novčana sredstva u svrhu isplate šteta osiguranicima, a koju prikupljaju kroz premiju osiguranja. U kontekstu investicijskog portfelja, likvidna sredstva u pravilu donose manje prinose od primjerice ulaganja u obveznice ili dionice, no s druge strane smatraju se manje rizičnim. Dakle, društva za osiguranje nastoje osigurati adekvatnu razinu raspoloživih likvidnih sredstava koja pritom ne ograničava postizanje ciljanih prinosa ulaganja. Rizik likvidnosti je vrlo specifičan rizik, posebno s aspekta kaskadnog utjecaja na ostale rizike ukoliko dođe do njegove realizacije. Primjerice, ukoliko društvo nije u mogućnosti ispuniti obveze prema osiguranicima, pouzdanost i povjerenje osiguranika može biti značajno narušeno, a time dolazi do manifestacija rizika gubitka ugleda, unatoč tome što osiguratelj možda ima i visoku razinu solventnosti. Gubitak ugleda može dovesti do smanjenja prodaje i prekida postojećih polica osiguranja, što potom dovodi do manje količine premija i novih likvidnih sredstava, a što dodatno produbljuje nemogućnost osiguratelja da ispuni svoje obveze. Iz navedenih razloga, likvidnost poslovanja vrlo je bitan čimbenik za sigurnost i kontinuitet poslovanja osiguratelja (Škunca 2016).

Jedna od glavnih mjera upravljanju rizikom likvidnosti proizlazi iz upravljanja novčanim tokovima imovine i obveza koji bi trebali biti u maksimalnog mjeri ročno usklađeni. Drugim riječima, dospijeće novčanih tokova imovine trebalo bi korespondirati dospijeću novčanih tokova obveza. U praksi često nije moguće u potpunosti uskladiti dinamiku odnosno dospijeće novčanih tokova, te je iz tog razloga visina likvidnih rezervi iznimno bitna kod upravljanja ovim rizikom.

2.2.2. Regulacija investicijskih rizika

U pogledu upravljanja investicijskim rizicima, potrebno je spomenuti i važeću zakonsku regulativu. Prijašnji regulatorni okvir (Solventnost I) imao je definirane striktne limite na udjele pojedinih oblika ulaganja čime je direktno usmjeravao investicijski proces društava za osiguranje. Novi regulatorni režim za osiguratelje, Solventnost II (u nastavku: SII regulativa), stupio je na snagu 1.1.2016. a transponiran je u postojeći Zakon o osiguranju i vezane podzakonske akte te je uveo značajne promjene u regulaciji industrije osiguranja, posebno one vezane uz upravljanje (tržišnim) rizicima.

Novom SII regulativom se ukidaju striktni limiti ulaganja i otvara mogućnost društvima za osiguranje da potpuno autonomno donose investicijske odluke u pogledu odabira oblika ulaganja i njihovog udjela u investicijskom portfelju. Ovakav pristup baziran je na načelima, a ne strogim pravilima (eng. *principle based vs rule based*). U cilju obeshrabrivanja osiguratelja da ulažu značajan udio slobodnih sredstava u rizičnije oblike ulaganja, Solventnost II uvodi mehanizam nametanja visokih kapitalnih zahtjeva na oblike ulaganja koji se smatraju rizičnijim (npr. kapitalni zahtjevi na ulaganja u dionice znatno su viši od onih na državne obveznice).

Nadalje, solventnost društva za osiguranje nije više povezana s volumenom premija i tehničkih rezervi, već s procjenom izloženosti rizicima na temelju financijskog modela. Sukladno tome, uvode se potpuno novi kriteriji za adekvatnu kapitaliziranost u kojoj glavni termin postaje potreban solventni kapital (eng. *Solvency Capital Requirement*) čija visina mora biti pokrivena vlastitim kapitalom. Istovremeno, implementirani su i kriteriji kojima se određuje kvaliteta i struktura kapitala kojom se može pokrivati potreban solventni kapital.

Detaljnije o novoj regulativi Solventnost II , te kapitalnim zahtjevima i njihovom utjecaju na investicijski proces i portfelj osiguratelja, biti će izloženo u poglavlju 4.

2.3. Markowitzev model optimizacije i njegove alternative

U ovom dijelu jezgrovito će se prezentirati najpoznatiji model optimizacije, tzv. Markowitzev model[5], njegove prednosti i nedostaci, kao i neke alternativne kojima je kroz povijest unaprijeđen. Obzirom da je detaljna prezentacija modela dostupna iz cijelog niza prethodnih znanstvenih radova različitih autora, u nastavku će se izložiti samo najvažnija obilježja u cilju boljeg razumijevanja problema istraživanja kao i višekriterijskog modela čija se kreacija naslanja na Markowitzev model.

2.3.1. Markowitzev model optimizacije

Teorija upravljanja investicijskim portfeljem koja se odnosi na analizu kombinacije odabranih oblika ulaganja koje će sačinjavati portfelj, na temelju očekivanog prinosa i varijance, uobičajeno se naziva moderna teorija portfelja (eng. *Modern Portfolio Theory*). Najpoznatiji i najpopularniji koncept moderne teorije portfelja upravo je Markowitzev model (Markowitz, 1952). Osnovu teorije i samog modela čini (Šego et al., 2018):

[5] Nerijetko se koristi i kolokvijalni naziv *Mean-variance* (MV) model

a) analiza u kojoj se za danu razinu rizika maksimizira očekivani prinos portfelja, odnosno za danu razinu očekivanog prinosa minimizira rizik i
b) pojam diverzifikacije koji je ukazao na mogućnost smanjenja rizika portfelja u odnosu na rizike pojedinačnih vrijednosnica odnosno oblika ulaganja od kojih je sastavljen.

Markowitz je prvi uspio demonstrirati diverzifikaciju portfelja kroz svoj model u kojem je ukazao kako je ukupan rizik oblikovanog portfelja manji ili jednak u odnosu na portfelj koji nije uzimao u obzir međuodnose odnosno kovarijancu prinosa sastavnica portfelja. Drugim riječima, odluke o formiranju portfelja ne mogu se donijeti samo temeljem karakteristika individualnih oblika ulaganja, već je potrebno promatrati i njihove kovarijance, odnosno korelacije prinosa (Škrinjarić, 2013).

Dvije glavne varijable u modelu su očekivani prinos i rizik koji je mjeren preko varijance odnosno standardne varijance. U kontekstu korištenja navedenih pojmova, Markowitzev model se često popularno naziva i *mean-variance* model sukladno originalnom engleskim terminima za očekivani prinos i varijancu. Prinosi na uključene sastavnice portfelja (npr. pojedine dionice ili druge oblike ulaganja) često se računaju sljedećom formulom za kontinuirane prinose u vremenskom razdoblju *t*

$$R_i(t) = ln\left(\frac{P_i(t)}{P_i(t-1)}\right). \tag{2.2}$$

pri čemu $R_i(t)$ predstavlja prinos na dionicu *i* za razdoblje *t*, a *ln* prirodni logaritam. Ovakvo računanje prinosa koristi se kod provedenih optimizacija u okviru ovog istraživanja. Pregled deskriptivne statistike korištenih varijabli u istraživanju vidljiv je u poglavlju 5.

Kao dio konciznog pregleda Markowtzevog modela, potrebno je svakako spomenuti i glavne pretpostavke na kojima se model temelji (Fabozzi i Markowitz, 2011):

- *Pretpostavka* 1. Jedina dva parametra koji utječu na odluke investitora jesu očekivani prinos i varijanca portfelja, što znači da investitori donose odluke koristeći se dvoparametarskim modelom.
- *Pretpostavka* 2. Investitori imaju averziju prema riziku, što znači da suočeni s dvije mogućnosti investiranja s jednakim očekivanim prinosom ali različitim razinama rizika, preferiraju onu mogućnost investiranja s manjom razinom rizika.
- *Pretpostavka* 3. Svi investitori teže ostvariti najveći očekivani prinos za danu razinu rizika.

- *Pretpostavka* 4. Svi investitori imaju jednaka očekivanja glede očekivanog prinosa, varijance i kovarijance sve rizične imovine – očekivanja su homogena.
- *Pretpostavka* 5. Svim investitorima je i zajednički horizont investiranja od jednog razdoblja.

Markowitz je formirao matematički model kojim se pronalazi onaj portfelj koji bi za zadanu razinu rizika ostvarivao najveći očekivani prinos. Takav portfelj naziva se ujedno i efikasnim portfeljem obzirom da se nalazi na efikasnoj granici koja se dobiva na grafu gdje je na osi apscisa ucrtana standardna devijacija portfelja dok se na osi ordinata prikazuje očekivani prinos portfelja za zadanu razinu rizika. Drugim riječima, cilj optimizacije je pronaći udjele sastavnica portfelja kojima se minimizira rizik za danu razinu prinosa (Peterson, 2012). Navedeni portfelj ima minimalnu varijancu i također se nalazi na efikasnoj granici (eng. *efficient frontier*). U ovom kontekstu potrebno je spomenuti i tangencijalni portfelj koji ima optimalan omjer prinosa i rizika promatrano najčešće preko neke od mjera efikasnosti portfelja (npr. Sharpeov omjer).

U nastavku je formalan opis modela koji će se koristiti kasnije u poglavlju 5. u provedbi optimizacije i testiranja hipoteze H1.

$$\max_{w_i} \quad \left[E(R_P) = \sum_{i=1}^{I} w_i E(R_i) \right]$$

uz ograničenja

$$\sigma_P^2 = \sum_{i=1}^{I} \sum_{j=1}^{I} w_i w_j \sigma_{ij} \leq c$$

$$\sum_{i=1}^{I} w_i = 1$$

$$w_i \geq 0, \quad i \in \{1,\ 2,\ ..,\ I\}. \qquad (MM^6)$$

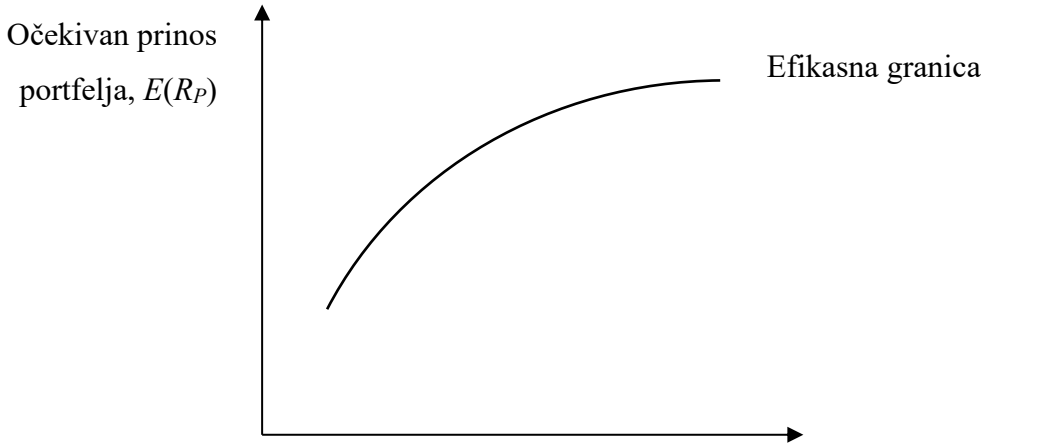
Varijable odlučivanja su udjeli sastavnica portfelja w_i, dok je c proizvoljno zadana razina rizika. Ukoliko se pretpostavi i mogućnost kratke prodaje (eng. *short selling*) posljednjih I ograničenja o nenegativnosti udjela svih dionica u portfelju nestaju. Nadalje, moguće je dodati još jedno ograničenje za svaki pojedinačni udio,

$$a \leq w_i \leq b, \quad i \in \{1, 2, .., I\}. \qquad (2.3)$$

[6] Markowitzev model (MM)

kojim se ograničava udio pojedinog oblika ulaganja u portfelju. Ovakvo ograničenje vrlo je realno u praksi obzirom da investitori teže većoj disperziji ulaganja koja omogućava pozitivne učinke diversifikacije. Konstante odnosno gornje i donje ograničenje udjela a i b, $a < b$, se proizvoljno odrede, pri čemu vrijednost a može biti jednako 0, ili pak neki pozitivan ili negativan broj. Vrijednost b je u pravilu pozitivan broj. Rješavanjem problema optimizacije mijenjajući konstantu c, dobivamo sve portfelje koji se nalaze na efikasnoj granici, koja je prikazana na grafu 2 (Škrinjarić, 2013).

Graf 2 - Efikasna granica kao rezultat Markowitzeva modela



Izvor: (Škrinjarić, 2013)

Efikasni investitori biraju portfelj s efikasne granice, gdje je najpovoljnija kombinacija rizika i portfelja, pri čemu preferencija pojedinog investitora utječu na izbor optimalnog portfelja s efikasne granice. Konzervativni investitori biraju portfelje koji nose manji očekivani prinos, ali ujedno i manji rizik, te se takve kombinacije portfelja nalaze na donjem lijevom dijelu efikasne granice. S druge strane, agresivni investitor odabire portfelj koji nosi veći očekivani prinos, ali isto tako i veći rizik te biraju portfelje na gornjem desnom dijelu efikasne granice (Šego et al., 2018).

Problem maksimizacije funkcije cilja se u optimizaciji naziva još i problemom primala. Spomenuto je također da se Markowitzev model može promatrati i kao problem minimizacije (rizika) koji se naziva problemom duala. Takva postavka modela primjerenija je za institucionalne investitore (npr. društva za osiguranja) koji preferiraju što niži rizik odnosno volatilnost izraženu preko varijance.

2.3.2. Kritike modela

Jedna od mnogih kritika Markowitzevog modela odnosi se primjerice na vremenski horizont ulaganja od jednog razdoblja (eng. *single period*). Prema toj pretpostavci, investitori ulažu svoja sredstva u dionice samo u jednome razdoblju što implicira da je Markowitzev model statičan. Kako bi se premostila ova pretpostavka, razvijeni su više-periodni modeli optimizacije. Homogena očekivanja (o riziku i prinosu) i efikasnost tržišta kapitala (eng. *Efficient Market Hypothesis*) su također dvije nerealne pretpostavke. Bihevioralni ekonomisti su najveći kritičari ovih pretpostavki uz onu o racionalnosti svih investitora. Naime, kada bi svi investitori imali jednaka očekivanja, na tržištu ne bi dolazilo do trgovanja. U stvarnosti postoji asimetrija informacija, povlaštene informacije (eng. *inside information*) koje su dostupne samo određenim pojedincima, itd. Efikasnost tržišta kapitala podrazumijeva da se sve dostupne informacije trenutno ugrađene u cijene dionica, stoga se na tržištu ne mogu ostvariti iznadprosječni prinosi.

Međutim, perzistirajući trendovi cijena koji dovode do cjenovnih balona i posljedično financijske krize koje su se dogodile kroz povijest ukazuju na nerealnost ovih pretpostavki. Odsustvo transakcijskih troškova također je predmet brojnih kritika. Investitori u praksi ne donose svoje odluke isključivo temeljem prinosa i rizika dionica, već one ovise i o drugim faktorima, među kojima transakcijski troškovi zauzimaju značajno mjesto. U modelu se koristi varijanca odnosno standardna devijacija kao osnovna mjera rizika, a koja je kao mjera višestruko kritizirana jer jednako vrednuje pozitivna i negativna odstupanja od očekivanog prinosa. Markowitz je već tada prepoznao taj nedostatak, te je predložio polu-varijancu kao mjeru rizika koja ne uzima u obzir prinose veće od očekivanog. Međutim, uslijed ograničenih računalnih mogućnosti u periodu razvijanja modela, nije uspio navedenu adekvatniju mjeru uključiti u sam model (Šego et al., 2018).

Svakako jedna od najčešćih kritika Markowitzevog modela odnosi se na pretpostavku normalne distribucije prinosa sastavnica portfelja. Ukoliko prinosi analiziranih oblika ulaganja slijede normalnu distribuciju, dovoljno je koristiti prva dva središnja momenta distribucije (tj. očekivani prinos i varijancu/standardnu devijaciju). Sukladno tome, za treći i četvrti središnji moment (asimetrija i zaobljenost) smatra se da imaju vrijednost 0 i 3. Samuelson (1967 i 1970) ukazao je na određene nedostatke u korištenju samo prva dva momenta distribucije. Financijske serije u pravilu karakteriziraju distribucije koje odstupaju od pretpostavke normalnosti na što ukazuju brojni empirijski radovi u slučaju prinosa dionica i obveznica (Mandelbrot, 1963; Fama, 1965; Malevergne i Sornette, 2005; Mandelbrot i Hudson, 2006; Bali et al., 2013; Dong,

2017; Vidović, 2010; Škrinjarić, 2013) te hedge fondova (Brooks i Kat, 2002; Bergh i van Rensburg, 2008; Jaggi et al., 2011).

Kod iznošenja kritika, Markowitzev model potrebno je staviti u kontekst vremena u kojemu je nastao. To je bio prvi model koji je omogućio kvantifikaciju rizika portfelja i objasnio pojam diverzifikacije rizika. Računalne mogućnosti u to doba ograničavale su primjenu kompliciranijih modela koji su bliži stvarnosti, posebice u dijelu mjerenja rizika.

Iako se ne odnosi direktno na još jednu od kritika modela, bitno je istaknuti kako rezultati optimizacije uvelike ovise o kvaliteti ulaznih podataka. Naime, dobiveni optimalni udjeli sastavnica portfelja vrlo su osjetljivi na male promjene inputa i, sukladno tome, na pogrešku u procjeni parametara (eng. *estimation error*). U svom utjecaju na rezultate Markowitzeve optimizacije u alokaciji imovine, procijenjeno je da je greška procjene očekivanih prinosa otprilike 10 puta važnija od pogreške procjene u varijancama i 20 puta važnija od pogreške procjene u kovarijancama. Best i Grauer (1991) pokazuju da mali porast očekivanog prinosa jednog od uključenih oblika ulaganja u portfelj može isključiti polovicu drugih oblika iz portfelja. Sukladno tome, najvažniji ulazni podaci u Markowitzevoj optimizaciji su serije očekivanih prinosa promatranih varijabli odnosno oblika ulaganja. S druge strane, očekivani prinosi su i najteži ulazni podaci za procjenu (Sharpe et al., 2007). Unatoč brojnim kritikama, Markowitzev model je i dalje daleko od umirovljenja (Kritzman, 2011) te će radi svoje jednostavnosti i široke primjene, i dalje biti prisutan u rješavanju mnogih problema optimizacije u ekonomiji (Markowitz, 1991).

2.3.3. Alternativni modeli optimizacije

U ovom dijelu kratko će se opisati nekoliko alternativnih modela kojima se Markowitzev model može nadograditi.

Tablica 5 - Pregled alternativnih modela optimizacije

Model	Opis modela
Model optimizacije portfelja s donjom polu-apsolutnom devijacijom	Kao kritika na distribucije prinosa koje nisu normalnog oblika nastaju modeli koji uključuju druge mjere rizika s kojima se nastoje otkloniti nedostaci varijance, odnosno standardne devijacije. Tako su razvijene donje parcijalne mjere rizika, koje ne vrednuju jednako prinose manje ili veće od određene granice. Jedna od tih mjera je i donja poluapsolutna devijacija (eng. *Lower Semi-Absolute Deviation, LSAD*).

Model	Opis modela
	Prednost ovoga modela u odnosu na Markowitzev jest to što nije potrebno računati matricu varijanci i kovarijanci koja je velikih dimenzija kada se rade empirijske analize.
Model optimizacije portfelja s polu-varijancom	Uočavanjem nedostataka varijance kao mjere rizika, Markowitz (1959) je predložio polu-varijancu (eng. *semi-variance*) kao mjeru rizika koja ne uvažava jednako ispod i nadprosječne prinose. Ovaj model je sličan prethodnom, osim što koristi drugu mjeru rizika.
Model optimizacije portfelja s uvjetnom rizičnošću vrijednosti (*Conditional Value at Risk; CVaR*)	Rizična vrijednost *(eng. Value at risk-VaR*) je u današnjoj praksi upravljanja rizicima vrlo raširen koncept. Nastao je kao pokušaj da se putem jednog broja sumira ukupan rizik portfelja, a pionir njegovog razvoja i primjene bila je velika investicijska banka JPMorgan (Hull, 2017). VaR izražava rizik kao jedan broj, što ga čini vrlo pristupačnim i jednostavnim za razumjeti (Doff, 2011). Ovaj model je također sličan prethodnima, osim što koristi drugu mjeru rizika.
Model maksimizacije Sharpeova i Sortinova omjera	Klasičan pristup Markowitzeva modela temelji se na činjenju ustupaka (eng. *trade offs*) između rizika i prinosa koji se temelje na investitorovim preferencijama i funkciji korisnosti (Rubinstein, 1973). U navedenim modelima se maksimizira omjer viška očekivanog prinosa i rizika. Glavna razlika između modela je što se kod Sortinovog omjera umjesto standardne devijacije koristi donja polu-apsolutna devijacija.
Minimax (MM) model	Young (1998) godine razvija model koji se temelji na pretpostavci da investitori imaju jaku averziju prema riziku (mjerenim donjim mjerama rizika).. Model se naziva Minimax jer u uvjetima neizvjesnosti, racionalni investitor želi minimizirati maksimalni gubitak ili maksimizirati minimalni prinos.

Izvor: (Šego et al., 2018)

Svi navedeni modeli ne uzimaju u obzir više momente distribucije, a samim time manje su robusni na pretpostavku normalnosti. U nastavku su izložene glavne značajke modela koji uključuje više momente, kao i oblike nelinearnog programiranja koji su s istim povezani.

2.4. Uloga i značenje modela optimizacije uz više momente distribucije

Otprije je spomenuto da se Markowitzev model temelji na pretpostavci normalne distribucije prinosa. Iz tog razloga, u provedbi optimizacije njegovim modelom dovoljno je koristiti prva dva središnja momenta distribucije, odnosno prosječan očekivani prinos i varijancu/standardnu devijaciju. Međutim, brojni empirijski radovi su ukazali kako prinosi vrijednosnica nisu normalno distribuirani, radi čega se ta činjenica ne smije zanemariti pri provedbi optimizacije portfelja. Modeli koji uzimaju u obzir više momente predstavljaju vrlo kvalitetne i robusne alternative tzv. *mean-variance* modelu.

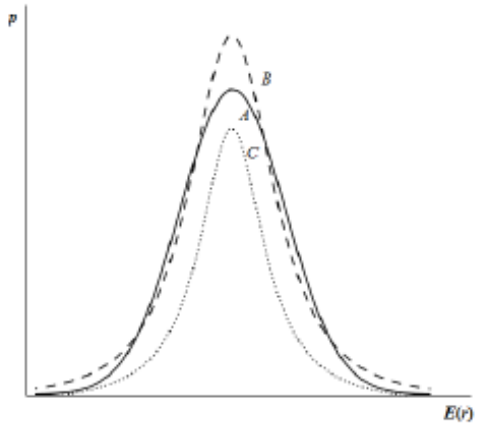
Fabozzi i Markowitz (2011) objašnjavaju kako je Markowitzev model intuitivan, lako ga je implementirati i računski je puno lakše izvesti u odnosu na modele koji uzimaju u obzir više momente distribucije prinosa. Uzimajući u obzir tehnološki razvoj, u suvremenim istraživanjima gdje se provodi neki oblik optimizacije, neopravdano bi bilo ignorirati izračun viših momenata portfelja ako klasični statistički testovi ukažu da distribucija prinosa ne slijedi normalan oblik. Ovakva pojava je prisutna kada je u pitanju uključivanje alternativnih oblika ulaganja u investicijski portfelj, posebice hedge fondova.

Sukladno tome, potrebno je uzeti u obzir treći i četvrti moment distribucije prinosa odnosno koeficijente asimetrije i zaobljenosti. U slučaju normalne distribucije, koeficijent asimetrije iznosi 0 dok koeficijent zaobljenost iznosi 3[7]. Ukoliko je prisutna pozitivna asimetrija distribucije prinosa (koeficijent >0), nadprosječne prinose karakterizira veća apsolutna vrijednost u odnosu na ispodprosječne prinose. S druge strane, negativno asimetrična distribucija (koeficijent <0) ukazuje kako su iznadprosječni prinosi učestaliji ali nisu puno veći od nule, dok se ispodprosječni prinosi ostvaruju rjeđe, ali su po apsolutnoj vrijednosti znatno veći od iznadprosječnih prinosa.

U pogledu koeficijenta zaobljenosti, vrijednost veća od 3 ukazuje na pojavu leptokurtične distribucije koju karakteriziraju šiljatiji vrhovi u odnosu na normalnu distribuciju, te su repovi tih distribucija deblji. Vrijednost niža od 3 ukazuje na javljanje platikurtične distribucije koju karakteriziraju plosnatiji vrhovi i tanji repovi u odnosu na normalnu distribuciju. Debljina repova distribucije veže se uz vjerojatnosti nastupa ekstremnih događaja, odnosno prinosa ili

[7] U mnogim računalnim programima (npr. excel), izračun koeficijenta zaobljenosti iskazuje se na način da se ukupan koeficijent umanjuje za 3 (tzv. excess kurtosis). Ukoliko u takvom izračunu dobijemo vrijednost 0, to ukazuje da se radi o vrijednosti koeficijenta zaobljenosti od 3 koji karakterizira normalnu distribuciju.

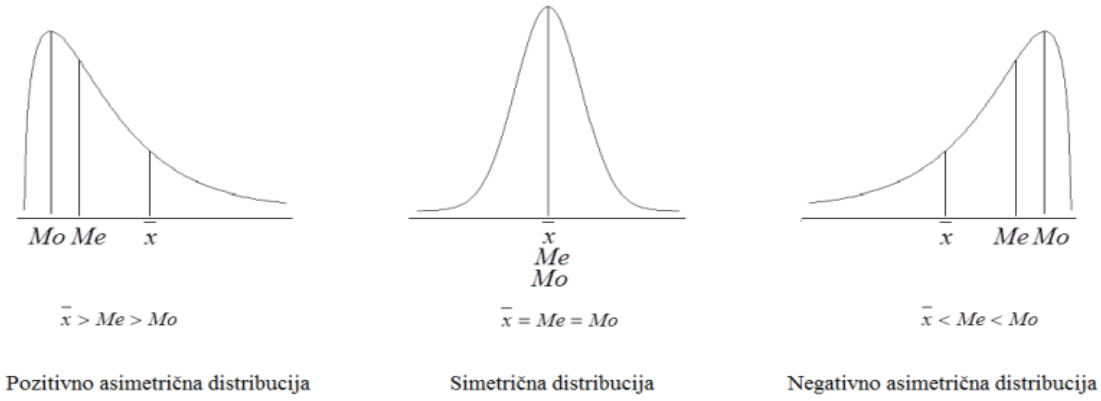
gubitaka ovisno radi li se o lijevoj ili desnoj strani distribucije, a što ukazuje na važnost razmatranja i četvrtog momenta distribucije (Šego et al., 2018).



Slika 1- Usporedba normalne (A), leptokurtične (B) i platikurtične (C) distribucije

Izvor: Šego et al., 2018

Na slici 1 vidi se razlika između promatranih distribucija na osnovi koeficijenta zaobljenosti. Glavna razlika može se uočiti u debljini repova distribucije.



Slika 2 – Asimetrična i simetrična (normalna) distribucija

Izvor: Šimić, 2017

Iz slike 2 razvidna je razlika između (a)simetričnih distribucija uz prikaz odnosa srednje vrijednosti, medijana i moda distribucije. U pogledu preferencija prema središnjim momentima, investitori preferiraju veće vrijednosti neparnih momenata portfelja odnosno očekivani prinos i asimetriju, dok teže manjim vrijednostima parnih momenata portfelja (rizik očitovan u standardnoj devijaciji te zaobljenost) kako bi na taj način smanjili gubitke i povećali vjerojatnosti ostvarivanja dobitaka (Scott i Horvath, 1980; Athayde i Flores, 2004; Odo, 2011; Hoffman i Kaminski, 2016).

Za izračun trećeg i četvrtog momenta portfelja potrebno je izračunati koeficijente asimetrije za svaki oblik ulaganja zasebno, kao i koeficijente koasimetrije za svaki mogući par, te isto tako izračunati koeficijente zaobljenosti i kozaobljenosti. Više o samom načinu izračuna komomenata u poglavlju 5.2.

Primjerice, distribucija prinosa hedge fondova je asimetrična i leptokurtična, te ju dodatno karakterizira značajna koasimetrija i kozaobljenost s prinosima drugih oblika ulaganja (Popova et al., 2007; Davies et al., 2009; Abrams et al., 2014; Savona, 2016).

U financijskoj literaturi razvijeni su različiti pristupi kako bi se uključile individualne preferencije za višim momentima u probleme optimalne alokacije imovine. Ovi se pristupi mogu podijeliti na programe primala i duala za određivanje efikasne granice bazirane na prva 4 središnja momenta distribucije odnosno očekivanog prinosa, varijance, asimetrije i zaobljenosti (Jurczenko et al., 2006). U ovom radu, kao model višekriterijske optimizacije portfelja, korištena je metoda polinomnog ciljnog programiranja.

Najčešći pristup optimizaciji portfelja uz više momente je korištenje modela u kojemu se optimiziraju sva četiri momenta odjednom. Iz tog razloga govorimo da se radi o višekriterijskoj optimizaciji jer investitor razmatra više od jedne funkcije cilja, tj. više kriterija. U slučaju optimizacije portfelja s prva četiri momenta, model se sastoji od minimizacije dvije funkcije cilja (varijanca i zaobljenost) te maksimizacije preostale dvije funkcije cilja (prinos i asimetrija) uz standardna ograničenja nenegativnosti udjela imovinskih oblika u portfelju i sume udjela pojedinog oblika:

$$\max_{w_i}\left[E\left(R_P\right)=\sum_{i=1}^{I}w_iE\left(R_i\right)\right]$$

$$\min_{w_i}\left[\sigma_P^2=\sum_{i=1}^{I}\sum_{j=1}^{I}w_iw_j\sigma_{ij}\right]$$

$$\max_{w_i}\left[S_{Pr}=\frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}w_iw_jw_ks_{ijk}}{\sigma_P^3}\right]$$

$$\min_{w_i}\left[K_{Pr}=\frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}\sum_{l=1}^{I}w_iw_jw_kw_kk_{ijkl}}{\sigma_P^4}\right]$$

uz ograničenja

$$\sum_{i=1}^{I} w_i = 1$$

$$w_i \geq 0, \quad i \in \{1, 2, ..., I\}. \qquad (MVM^8)$$

Može se uočiti kako se radi o problemu u kojemu se javlja konfliktnost funkcija cilja. Ovakav problem značajno se razlikuje u odnosu na jednostavnije probleme optimizacije poput primjerice Markowitz modela (optimizacija jedne funkcije cilja). Prilikom višekriterijske optimizacije, postoji više pristupa rješavanju ovakvih problema, pri čemu svaki pristup ima svoje prednosti i nedostatke.

Višekriterijsko programiranje odnosi se na istovremenu optimizaciju više funkcija cilja – kriterija (Lukač i Neralić, 2012):

$$\max f_1(\boldsymbol{x})$$
$$\max f_2(\boldsymbol{x})$$
$$\ldots$$
$$\max f_k(\boldsymbol{x})$$
$$\boldsymbol{x} \in S,$$

gdje f_i, $i \in \{1, 2, \ldots, k\}$ predstavljaju funkcije cilja (kriterije), $\boldsymbol{x}$ je vektor nepoznatih varijabli $x_1, x_2, \ldots, x_n$, te je $S = \{\boldsymbol{x} \mid {}^{g_j}(\boldsymbol{x}) \geq 0, j \in \{1, 2, \ldots, m\}\}$ kompaktan skup mogućih rješenja. Sve funkcije cilja mogu se smjestiti u jednu vektorsku funkciju $\boldsymbol{z}(\boldsymbol{x})$, kako bi se problem višekriterijskog programiranja zapisao kompaktnije:

$$\max \boldsymbol{z}(\boldsymbol{x})$$
$$\boldsymbol{x} \in S. \qquad (2.4)$$

Ako je potrebno neke funkcije minimizirati, takav problem može se svesti na problem maksimizacije na sljedeći način:

$$\min f_k(\boldsymbol{x}) = -\max\left(-f_k(\boldsymbol{x})\right). \qquad (2.5)$$

Pretpostavimo da su sve funkcije cilja definirane na kompaktnom skupu *S.* Ako postoji dopustivo rješenje $\boldsymbol{x}^* \in S$ za koje vrijedi $\boldsymbol{z}(\boldsymbol{x}^*) \geq \boldsymbol{z}(\boldsymbol{x}), \forall \boldsymbol{x} \in S$, takvo rješenje nazivamo idealnim rješenjem. Često se u praksi događa da idealno rješenje ne postoji, već se promatra efikasno rješenje (ili Pareto optimalno) $\boldsymbol{x}^0 \in S$, koje je rješenje problema višekriterijske optimizacije ako ne postoji $\boldsymbol{x} \in S$ takav da je $\boldsymbol{z}(\boldsymbol{x}) \geq \boldsymbol{z}(\boldsymbol{x}^0)$ i $\boldsymbol{z}(\boldsymbol{x}) \neq \boldsymbol{z}(\boldsymbol{x}^0)$. Dakle, efikasno

[8] Model s višim momentima (MVM).

rješenje je ono kome se ne može poboljšati jedna komponenta a da se pritom druge komponente ne pogoršaju.

Dvije najčešće vrste višekriterijskih modela optimizacije su kompromisno i ciljno programiranje. **Kompromisno programiranje** temelji se na minimiziraju udaljenosti točke $\boldsymbol{x} \in S$ od referentne točke koja je uobičajeno idealna točka $\boldsymbol{x}^*$. Pritom se za mjerenje udaljenosti koriste različite metrike. Dakle, inicijalni problem maksimizacije k funkcija cilja na skupu mogućih rješenja svodi se na problem minimizacije udaljenosti vrijednosti $f_i(\boldsymbol{x})$, $i \in \{1,2,...,I\}$, od (idealne) vrijednosti $f_i(\boldsymbol{x}^*)$:

$$\min\left(\sum_{i=1}^{k}\left|f_i(\boldsymbol{x}^*)-f_i(\boldsymbol{x})\right|^p\right)^{\frac{1}{p}} \qquad (2.6)$$

$$\boldsymbol{x} \in S.$$

Minimizira se apsolutna vrijednost udaljenosti od idealne točke, pri čemu se p odnosi na red metrike koja se koristi. Najčešće se koriste L_1 (p = 1), L_2 (Euklidska, p = 2) ili L_∞ (Čebišljeva) metrika. U analizu se mogu uključiti i težine/ponderi λ_i ako donositelj odluke smatra određene kriterije odnosno moment važnijim od drugih. Tada se formira sljedeći problem:

$$\min\left(\sum_{i=1}^{k}\lambda_i\left|f_i(\boldsymbol{x}^*)-f_i(x)\right|^p\right)^{\frac{1}{p}} \qquad (2.7)$$

$$\boldsymbol{x} \in S.$$

Ciljno programiranje za razliku od kompromisnog, umjesto idealne točke, koristi neku zadanu točku $g=(g_1,g_2,...,g_k)$ kao referentnu, koja može biti podbačena ili premašena. Uvedu li se oznake d_i^+ za premašaj i d_i^- za podbačaj i-tog cilja, formulira se sljedeći problem:

$$\min\sum_{i=1}^{k}\left(d_i^+ + d_i^-\right)$$

$$f_i(\boldsymbol{x}) - d_i^+ + d_i^- = g_i, \quad i \in \{1,2,...,k\}, \qquad (2.8)$$

$$\boldsymbol{x} \in S, \; d_i^+, d_i^- \geq 0, \quad i \in \{1,2,...,k\}.$$

Višekriterijsko programiranje počinje se koristiti u području financija tek krajem 80-ih godina prošloga stoljeća. Obzirom da se u pravilu radi o nelinearnom programiranju, s više konfliktnih kriterija, te imajući u vidu tadašnje tehnološke mogućnosti, nije bilo realno za očekivati raniju

primjenu ovakvih metoda u području financija (Škrinjarić, 2013.). Aouni et al. (2014) daju kvalitetan pregled radova s primjenom ciljnog programiranja u upravljanju financijskim portfeljem. Di Francesco (2021) provodi optimizaciju portfelja u režimu Solventnosti II uz primjenu višekriterijskog pristupa gdje su funkcije cilja maksimizacija očekivanog prinosa te minimizacija volatilnosti vlastitih sredstava i visine kapitalnih zahtjeva za tržišne rizike.

Ciljno programiranje spada u tzv. pristup primala te se sastoji od dva koraka. U prvome koraku optimizira se svaka funkcija cilja pojedinačno, na istome skupu mogućih rješenja. Na taj način se dobiva efikasna točka koja se sastoji od optimuma pojedinačnih potproblema optimizacije ($E^*(R_p)$, σ_p^{2*}, S_p^*, K_p^*). Ovaj korak opisan je modelom *(M)*. Nakon toga se minimizira odstupanje od spomenute točke (Šego et al., 2018):

$$\min M = \left|\frac{d_1}{E^*\left(R_P\right)}\right|^{\lambda_1} + \left|\frac{d_2}{\sigma_P^{2*}}\right|^{\lambda_2} + \left|\frac{d_3}{S_{Pr}^*}\right|^{\lambda_3} + \left|\frac{d_4}{K_{Pr}^*}\right|^{\lambda_4}$$

uz ograničenja

$$\sum_{i=1}^{I} w_i E\left(R_i\right) + d_1 = E^*\left(R_P\right)$$

$$\sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij} - d_2 = \sigma_P^{2*}$$

$$\frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I} w_i w_j w_k s_{ijk}}{\sigma_P^3} + d_3 = S_{Pr}^*$$

$$\frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}\sum_{l=1}^{I} w_i w_j w_k w_k k_{ijkl}}{\sigma_P^4} - d_4 = K_{Pr}^*$$

$$\sum_{i=1}^{I} w_i = 1$$

$$d_m \geq 0, \quad m \in \{1,...,4\}$$

$$w_i \geq 0, \quad i \in \{1,2,...,I\}. \qquad (F)$$

Parametri λ_i, $i \in \{1, 2, 3, 4\}$ predstavljaju investitorove preferencije vezane za prinos, rizik, asimetriju i zaobljenost portfelja, p red metrike za mjerenje udaljenosti, dok varijable d_m predstavljaju udaljenosti momenata portfelja dobivenog iz optimizacije modela (*F*) od optimalnog portfelja, tj. točke ($E^*(R_p)$, σ_p^{2*}, S_p^*, K_p^*).

Uvođenjem investitorovih preferencija u analizu ukazuje se na važnost ustupaka (eng. *trade off-a*). Veća dodijeljena vrijednost pojedinom momentu znači kako investitor preferira upravo taj moment u odnosu na ostale, odnosno daje mu veću pažnju. U ovom radu pretpostaviti će se da investitori imaju jednake preferencije po pitanju momenata te se model (F) može zapisati i bez λ_i parametara.

Kod ciljnog programiranja bitno je istaknuti da je korišten u brojnim radovima gdje se rješavaju višekriterijski problemi optimizacije. Primjerice, Davies et al. (2009) koriste ciljno programiranje za utvrđivanje efikasnih portfelja hedge fondova po sva 4 središnja momenta. Nedostatak ovog primalnog pristupa je što se problem alokacije sredstava riješen u ciljnom programiranju ne može precizno povezati s očekivanom funkcijom korisnosti. Konkretno, izbor parametara koji se koriste za ponderiranje odstupanja momenata nije povezan s parametrima funkcije korisnosti. Još jedan nedostatak procjene efikasne granice na temelju 4 momenta putem višekriterijskog programiranja je da nije potpuno u skladu s Pareto optimalnom definicijom efikasne granice portfelja. Drugim riječima, minimiziranje odstupanja od prva četiri središnja momenta istovremeno jamči samo rješenje blizu efikasne granice temeljene na prva 4 momenta odnosno lokalni minimum/maksimum (Jurczenko et al., 2006).

Modeli (MVM) i (F) biti će aplicirani na varijable iz poglavlja 5.1. i korišteni u provedbi višekriterijske optimizacije za testiranje Hipoteze H2.

2.5. Pregled mjera efikasnosti portfelja

U nastavku su prezentirane neke od najčešće korištenih mjera u okviru mjerenja efikasnosti portfelja. Takve mjere su bitne jer omogućavaju usporedivost optimiziranih portfelja što omogućava donošenje kvalitetnih poslovnih odluka po pitanju alokacije sredstava na moguće oblike ulaganja. Stenki i Mohammad (2015) daju kvalitetan pregled mjera efikasnosti dok ih Caporin et al. (2014) svrstavaju u 4 kategorije: relativne, apsolutne, generalne i mjere koje uzimaju u obzir funkciju korisnosti investitora.

2.5.1. Sharpeov omjer

Sharpeov omjer smatra se jednom od najčešće korištenih mjera efikasnosti portfelja. Efikasnost se u kontekstu investicijskog portfelja primarno fokusira na ostvarivanje što većeg prinosa po jedinici preuzetog (tržišnog) rizika. Na takvoj osnovi kreiran je i Sharpeov omjer koji

predstavlja odnos viška prinosa određenog ulaganja iznad nerizične kamatne stope (npr. državni trezorski zapis) i rizika koji se najčešće mjeri standardnom devijacijom. Sukladno tome, Sharpeov omjer se povećava s rastom viška prinosa ili padom visine rizika.

Prednost ove mjere je jednostavnost izračuna i lakše razumijevanje u odnosu na neke možda kompleksnije mjere. S druge strane, nedostatak Sharpeovog omjera je fokus na rizik izražen preko volatilnosti što u pravilu ne pokazuje uvijek stvarnu rizičnost investicije, posebno kada se evaluiraju performanse hedge fondova čiji prinosi ne slijede oblik normalne distribucije. Eling i Schuhmacher (2007) uspoređuju rezultate mjerenja performansi hedge fondova pomoću Sharpeovog omjera s 12 drugih mjera uz zaključak da ne dolazi do promjene u rangiranju fondova bez obzira na korištenu mjeru.

Dodatan nedostatak ove mjere je korištenje samo prva dva središnja momenta distribucije, očekivanog prinosa i varijance, što implicira pretpostavku normalne distribucije koja često nije prisutna u uzorcima financijskih serija. Sharpeov omjer dobiva se sljedećim izrazom:

$$SR_i = \frac{E(r_i) - E(r_f)}{\sigma_i} \tag{2.9}$$

gdje SR_i predstavlja Sharpeov omjer i oblika ulaganja, $E(r_i)$ očekivani prinos i oblika ulaganja, $E(r_f)$ očekivani prinos na bezrizičnu imovinu (npr. trezorski zapis), te rizik σ_i oblika mjeren standardnom devijacijom.

2.5.2. Sortinov omjer

Sharpeov omjer koristi standardnu devijaciju kao mjeru koja predstavlja rizik što znači da se jednako vrednuju pozitivna i negativna odstupanja. No, investitore zanimaju primarno negativna volatilnost (eng. *downside volatility*) odnosno ona odstupanja koja su ispod prosječnog očekivanog prinosa. Sortinov omjer temelji se na ispodprosječnim prinosima i umjesto standardne devijacije razmatra se donja polu-apsolutna devijacija.

Argument u korist Sortinovog omjera u odnosu na Sharpeov je taj da visoka volatilnost može biti rezultat porasta prinosa ulaganja. Stoga je Sharpeov omjer penaliziran pozitivnom volatilnosti. Nedostatak Sortinovog omjera je što se informacije, koje se mogu pronaći u povijesnoj volatilnosti, dodatno umanjuju uklanjanjem podataka o iznadprosječnim prinosima.

Podjela između dobre i loše volatilnosti pretpostavlja da se nije moglo dogoditi nešto drugo osim onoga što se stvarno dogodilo. Realizacija stvarnosti u kojoj nije došlo do negativnog

scenarija dodatno pojačava takvu pogrešnu perspektivu. Sortinov omjer dobiva se istim izrazom kao i Sharpeov omjer, osim što se u nazivniku uzima standardna devijacija ispodprosječnih prinosa.

2.5.3. Rizična vrijednost

Rizična vrijednost (eng. *Value at risk-VaR*) je procjena gubitka (u novčanom izrazu) odnosno granice za koju menadžer portfelja očekuje da će biti premašena s danom razinom statističke pouzdanosti tijekom određenog vremenskog razdoblja. Primjerice, za interval statističke pouzdanosti od 99%, može se interpretirati da će se jednom u 100 puta dogoditi gubitak koji će biti viši od vrijednosti VaR-a. To je ekvivalent 2.5 dana u godini, uzimajući u obzir da godišnje ima 250 dana za trgovanje. Osim njegove široke primjene u financijskoj industriji, VaR je kao mjera postao i osnovni standard za izgradnju suvremenih regulatornih okvira baziranih na rizicima (Doff, 2011).

Jedan od glavnih nedostataka VaR-a je što ne ukazuje na veličinu najgorih mogućih ishoda preko definirane granice (Fong i Guin, 2007). Pored toga, za empirijski izračun Var-a dovoljna su prva dva momenta distribucije odnosno očekivani prinosi i standardna devijacija što također implicira korištenje pretpostavke normalne distribucije. Prednost ove mjere je u kvantificiranju rizika u obliku jednog broja koji je lako razumljiv širokom spektru investitora.

2.5.4. Uvjetna rizična vrijednost (Cvar)

U cilju rješavanja nedostataka rizične vrijednosti kao mjere rizika, razvijena je uvjetna rizična vrijednost (eng. *Conditional Value at Risk*, *CVaR*). Uvjetna rizična vrijednost definira se kao procjena maksimalnog iznosa koji se može izgubiti u slučaju da se granica *VaR*-a premaši.

CVaR se u praksi još može nazivati i očekivani deficit (eng. *expected shortfall-ES*). Kao i kod VaR-a, CVaR također treba biti popraćen specifikacijom razine pouzdanosti i vremenskog horizonta ulaganja, po mogućnosti istima koji se koriste za izračun VaR-a (Braga, 2016). Obje mjere se nerijetko koriste u problemu optimizacije portfelja na način da se funkcija cilja postavi u smjeru njihove minimizacije.

2.5.5. Omega omjer

Omega omjer razvili su Keating i Shadwick (2002) kako bi se prevladala neadekvatnost mnogih tradicionalnih mjera efikasnosti koje se primjenjuju na oblike ulaganja čije distribucije prinosa odstupaju od pretpostavke normalnosti. U odnosu na ostale mjere efikasnosti, Omega je razvijena s namjerom da se u obzir uzme cjelokupna distribucija prinosa.

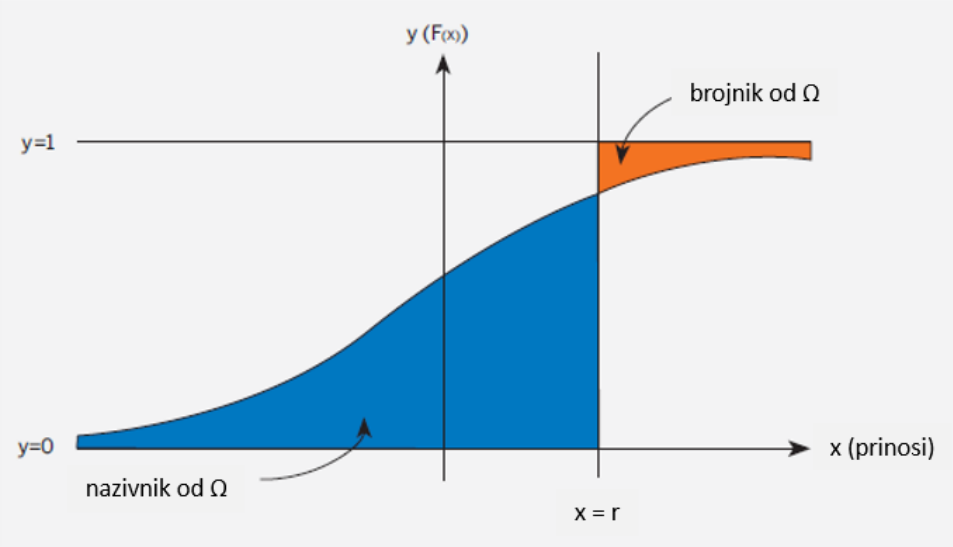
Omega mjera u obzir uzima i određenu granicu (eng. *threshold level*) iznad koje bi investitor bio zadovoljan a apsolutnim prinosom i obrnuto. Korištenje ove mjere omogućava prevladati nedostatke tzv. *mean-variance* okvira. Bitno je naglasiti da Omega u potpunosti uključuje utjecaj svih viših momenata distribucije prinosa u intuitivnu mjeru efikasnosti koja omogućuje procjenu rizika i prinosa u kontekstu vlastitog praga gubitka bez opterećujućih funkcija korisnosti (Keating i Shadwick, 2002). Balder i Schweizer (2017) ukazuju na pojedinosti pri korištenju Omega omjera u rangiranju investicijskih opcija te ističu da se omjer ne bi trebao koristiti kao mjerodavan ukoliko je njegova vrijednost niža od 1. Dyk et al. (2014) i Rambo i Van Vuuren (2017) koriste Omega omjer kao komplementarnu mjeru Sharpeovom omjeru u procjeni performansi prinosa hedge fondova te ukazuju na dodanu vrijednost Omege kao mjere efikasnosti.

Investitori specificiraju svoj vlastiti prag gubitka ili minimalni prihvatljivi prinos koji potom služi kao referentno mjerilo uspješnosti. Omega mjera uspoređuje ponderirane vjerojatnosti "profita" i "gubitaka", u odnosu na prag koji je odredio investitor. Definirana se sljedećim izrazom:

$$\Omega(r) := \frac{\int_r^b [1-F(x)]dx}{\int_a^r F(x)dx} \tag{2.10}$$

gdje *F(x)* predstavlja kumulativnu distribuciju funkcije prinosa, omeđenu krajnjim točkama *a* i *b*, zajedno s definiranim pragom *r* (Keating i Shadwick, 2002). Na grafu 3 ilustrirana je kumulativna distribucije funkcije određenog oblika ulaganja zajedno s prikazom granice te integralima profita i gubitka.

Graf 3 – Kumulativna distribucija i Omega mjera



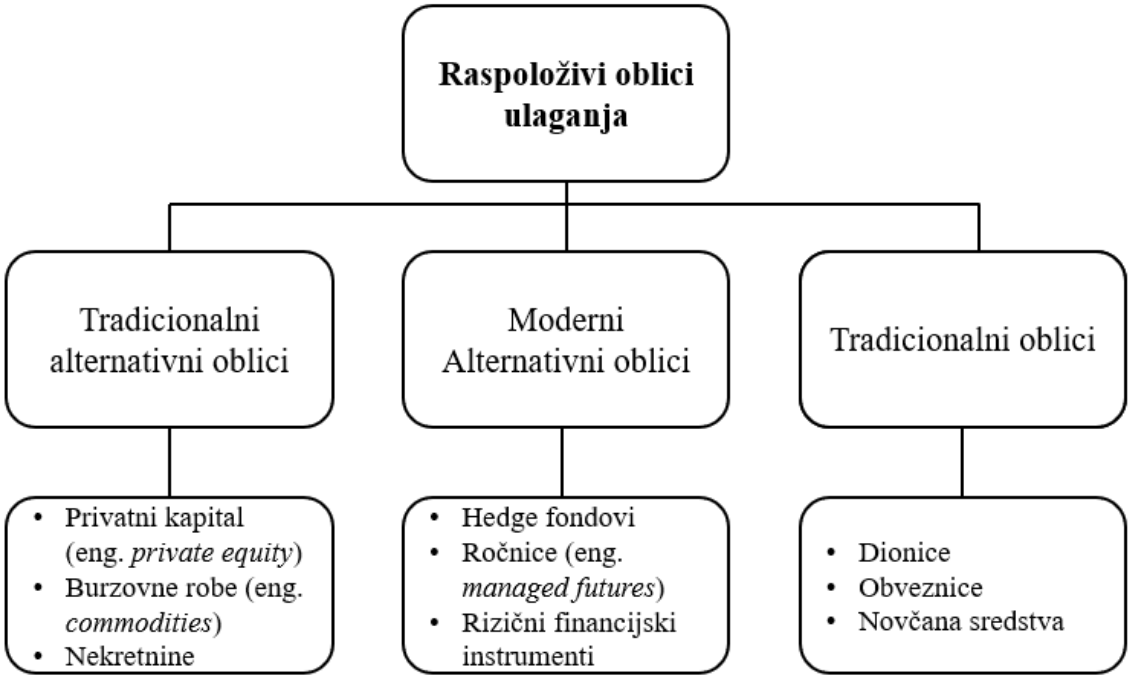
Izvor: Bhaduri i Kaneshige, 2005

Površina funkcije desno od prihvatljivog praga *r* predstavlja prinose iznad definirane granice, te ujedno i brojnik izračuna omega mjere dok je površina funkcije koja se nalazi s lijeve strane praga nazivnik gdje se nalaze prinosi ispod praga *r*. Omega pruža izuzetno koristan alat jer uzima u obzir nenormalne distribucije prinosa koje su uobičajene u financijskim serijama, posebno kod alternativnih oblika ulaganja. Unatoč prividnoj intuitivnosti Sharpeovog omjera, činjenica da isti zanemaruje asimetriju i zaobljenost te penalizira pozitivnu volatilnost, umanjuje njegovu korisnost u analizi efikasnosti pojedinih oblika ulaganja odnosno investicijskih portfelja (Abrams et al., 2014).

3. ALTERNATIVNI OBLICI ULAGANJA I NJIHOV UTJECAJ NA EFIKASNOST INVESTICIJSKOG PORTFELJA

Izraz "alternativni oblik ulaganja" obično se koristi za opisivanje grupe imovine koja se smatra nestandardnom ili netradicionalnom, a koju investitor može uključiti u svoj portfelj. Ovisno o kontekstu, alternativni oblici ulaganja mogu uključivati nekretnine, privatni kapital (eng. *private equity*), hedge fondove, robne i upravljane terminske ugovore (eng. *commodity and managed futures*), umjetnost, kreditne derivate, kriptovalute i dr. Međutim, ne postoji jedinstvena definicija onoga što čini alternativni oblik ulaganja. Primjerice, hedge fondovi se obično karakteriziraju kao alternativna ulaganja, ali mnogi tvrde da hedge fondovi nisu alternativni oblik ulaganja *per se*, iako neki hedge fondovi mogu dati investitorima pristup alternativnim oblicima ulaganja (npr. fondovima koji se bave ročnicama).

Važna karakteristika alternativnih oblika je da proširuju skup mogućnosti ulaganja i potencijalno poboljšavaju odnos rizika i prinosa investicijskog portfelja. Takva tvrdnja je validna zbog činjenice da alternativni oblici ulaganja pokazuju relativno nisku korelaciju s tradicionalnim oblicima. Alternativni oblici su nerijetko manje likvidni od tradicionalnih, što implicira da bi valuacija njihove vrijednosti mogla biti problem te da bi investitori koji razmatraju ovakva ulaganja trebali imati dulje vremenske horizonte ulaganja (Verbeek, 2010).



Shema 1 – Tradicionalni i alternativni oblici ulaganja

Izvor: Obrada autora prema (Yau et. al, 2007)

Povijesno gledano, nekretnine, privatni kapital (eng. *private equity*) i robe (npr. poljoprivredna dobra, plemeniti metali i nafta) percipirani su kao primarne alternative tradicionalnim oblicima ulaganja (dionice i obveznice). U međuvremenu, pojavila su se dodatni oblici alternativnih ulaganja poput hedge fondova i ročnica koja se danas smatraju „modernim alternativnim oblicima". Popis alternativnih ulaganja iz sheme 1 može se smatrati kao reprezentativan, ali nipošto isključiv. Primjerice, određeni investitori odabiru ulaganja u drvnu građu, kriptovalute ili nefinancijske oblike ulaganja (npr. likovna umjetnost, skupocjena vina, kolekcije automobila). Uz razlikovanje tradicionalnih ili modernih oblika, alternativna ulaganja možemo svrstati u tri skupine prema primarnoj ulozi koju imaju u investicijskom portfelju (Yau et. al, 2007):

- Ulaganja koja prvenstveno osiguravaju izloženost faktorima rizika kojima se nije moguće izložiti putem tradicionalnih ulaganja u dionice i obveznice.
- Ulaganja koja osiguravaju izloženost specijaliziranim investicijskim strategijama koje kreiraju i provode portfolio menadžeri. Hedge fondovi i ročnice mogu se staviti u ovu kategoriju. Dodana vrijednost odnosno viši prinos iz takvih ulaganja uvelike ovisi o vještinama menadžera.
- Ulaganja koja kombiniraju značajke prethodne dvije skupine. Fondovi privatnog kapitala i rizični financijski instrumenti (eng. *distressed securities*) mogu se uključiti u ovu skupinu.

Alternativni oblici ulaganja već su duže vrijeme predmet rasprave, kako u znanstvenoj literaturi tako i u praksi, koja uključuje dvije perspektive. Jedna perspektiva se odnosi na definiranje te ima za cilj odrediti što se podrazumijeva kao alternativno ulaganje. Druga perspektiva se odnosi na upravljanje investicijskim portfeljem gdje se javlja problem definiranja udjela koji treba dodijeliti ovim oblicima ulaganja u kontekstu investicijskih odluka (Abbink, 2010; Anson, 2006; Dorsey, 2007).

Problem definiranja može se riješiti razmatranjem sljedećih obilježja alternativnih ulaganja (Basile, 2016):

- Sve što se ne poistovjećuje s tradicionalnim oblicima ulaganja (tržište novca, obveznice i dionice),
- Inovativne strategije upravljanja tradicionalnim oblicima ulaganja,
- Instrumenti o kojima se pregovara izvan uređenih tržišta.

Drugim riječima, alternativnim oblikom ulaganja može se smatrati svaki oblik koji proširuje skup investicijskih prilika za investitora (Anson, 2006).

Iz perspektive institucionalnih investitora, načelo na kojem se temelji zakon koji regulira društva za upravljanje unutar EU zvuči jasnije i učinkovitije. Prema navedenom načelu, alternativnim ulaganjima smatraju se svi subjekti za zajednička ulaganja (tj. investicijski fondovi) koji nisu obuhvaćeni UCITS Direktivom[9], a što se odnosi na sljedeće oblike ulaganja (Basile, 2016):

- Hedge fondovi,
- Fondovi rizičnog (eng. *venture capital*) i privatnog kapitala (eng. *private equity*),
- Fondovi specijalizirani za ulaganja u nekretnine (npr. REIT),
- Ulaganja u robe (eng. *commodities*),
- Infrastrukturni fondovi i ostali oblici.

U ovom radu primaran fokus biti će na hedge fondovima i upravljanim ročnicama (eng. *managed futures*) kao alternativnim oblicima ulaganja, te su u poglavljima u nastavku rada izložena njihova glavna obilježja.

3.1. Pojam, vrste i odrednice hedge fondova

Hedge fond odnosi se na sve subjekte za kolektivno ulaganje (eng. *collective investment vehicles*) koji putem aktivnih strategija investiranja[10] i često uz visoku financijsku polugu, imaju za cilj postizanje što viših apsolutnih prinosa, bez obzira na trendove na financijskim tržištima. Fleksibilna regulacija ove vrste fondova omogućava upraviteljima portfelja široki raspon diskrecije u provedbi aktivnih strategija investiranja koje su svrsishodne investicijskim ciljevima (Basile, 2016).

Hedge fond nije hedžiran[11] u smislu da nije izložen tržišnim rizicima. Postoje hedge fondovi namijenjeni isključivo za hedžiranje odnosno zaštitu od rizika, ali to nije preduvjet da bi se fond smatrao hedge fondom (Favre, 2010). Ne postoji precizna zakonska ili univerzalno prihvaćena definicija hedge fonda. Izvorno su hedge fondovi bili privatna partnerstva čiji je primaran cilj bio upravo hedžiranje rizika kroz zauzimanje „dugih“ i „kratkih“ pozicija u dioničkim

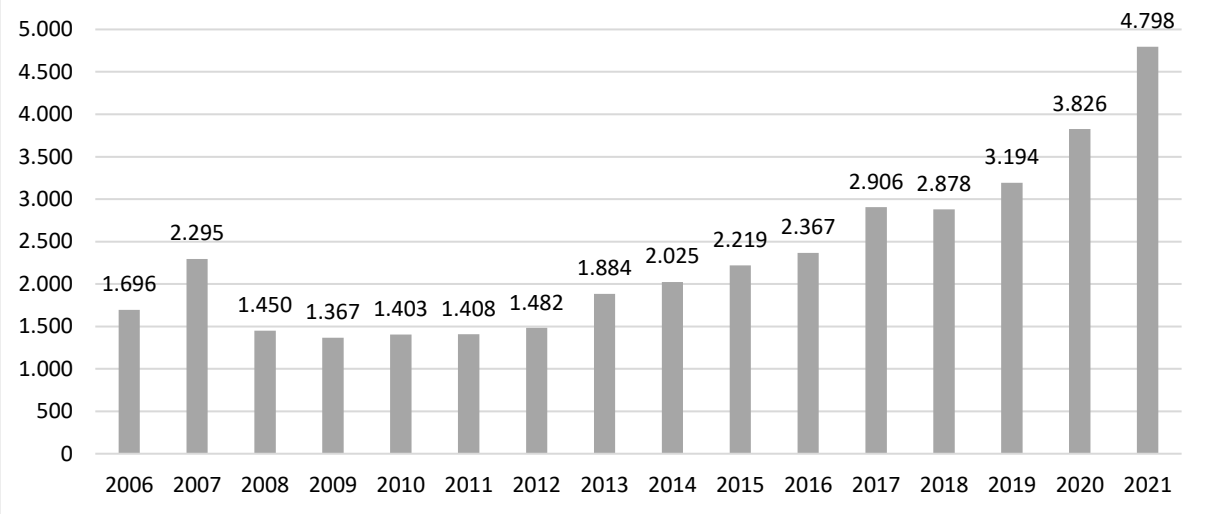
[9] Direktiva koja regulira industriju investicijskih fondova na području EU.
[10] Primarni cilj je ostvarivanje što višeg prinosa kroz kupnju i prodaju financijskih instrumenata. S druge strane, pasivno investiranje svodi se na kupnju i držanje određenog oblika ulaganja.
[11] (Ne)financijska transakcija čija je primarna svrha smanjenje rizika (Hull, 2017).

ulaganjima. Danas pojam hedge fond ima mnogo šire značenje koji eksplicitno ne ukazuje na hedžiranje rizika u portfelju, već ga određuju organizacijske i strukturne karakteristike investicijskog portfelja (Yau et. al, 2007). Pedersen et al. (2014) ukazuju na važnost kvalitetne procjene rizika alternativnih oblika te predlažu rješenja na ovaj problem.

Generalni cilj menadžera hedge fondova je postizanje boljih prinosa od menadžera koji upravljaju tradicionalnim investicijskim fondovima. Postizanje takvog cilja ovisi o razvijenosti i dubini financijskog tržišta, kao i dostupnosti financijskih instrumenata, mogućnosti korištenja financijske poluge (eng. *leverage*), derivativnih instrumenata i kratke prodaje (eng. *short selling*). Zakamouline (2009) naglašava da izbor mjera za analizu uspješnosti utječe na procjenu hedge fondova.

Hedge fondovi su danas široko prihvaćeni, osobito kod institucionalnih investitora, koji žele diversificirati svoju izloženost putem nisko koreliranih oblika ulaganja, a čime se unapređuje odnos prinosa i rizika investicijskog portfelja.

Graf 4 – Vrijednost imovine pod upravljanjem[12] hedge fondova globalno (u mlrd. USD[13])



Izvor: (Barclayhedge, 2022)

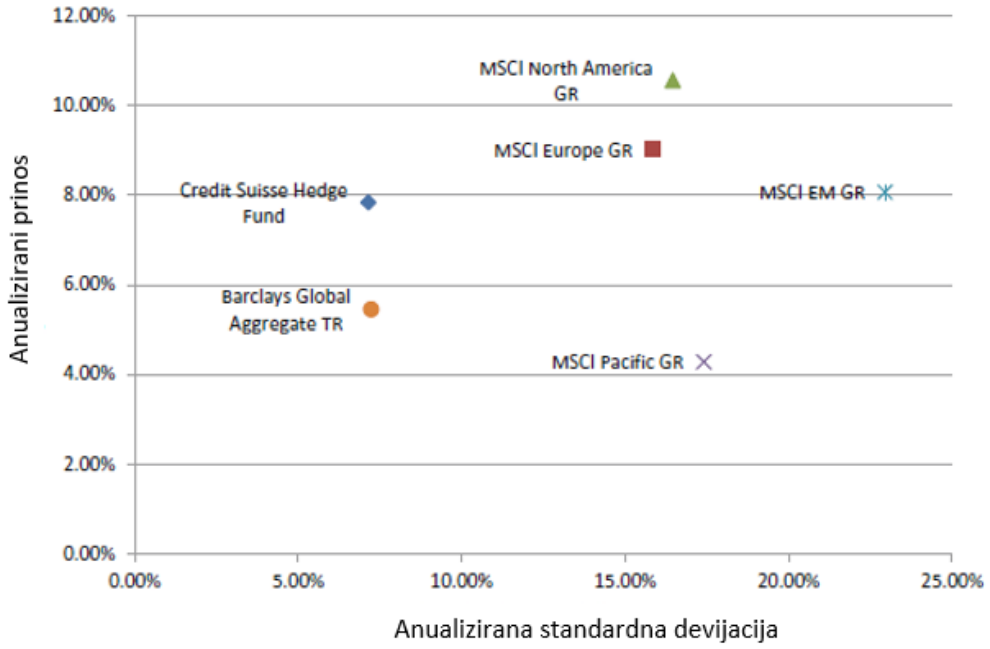
Na grafu 4 vidljiva je vrijednost imovine pod upravljanjem hedge fondova u zadnjih 15 godina. Inicijalni vrhunac vrijednosti imovine zabilježen je 2007. netom prije globalne financijske krize nakon čega je došlo do značajnog pada i stagnacije novih financijskih priljeva sve do početka 2010-ih godina. Evidentan je i značajan rast imovine u 2020. godini kada je svijet zadesila pandemija COVID-19, a takav trend materijalnog porasta nastavio se i tijekom 2021. godine.

[12] eng. Assets Under Management-AUM.
[13] Podatak za 2021. godinu odnosi se na kraj trećeg tromjesečja (3Q 2021).

Na kraju trećeg kvartala 2021. godine vrijednost imovine pod upravljanjem hedge fondova iznosila je 4,8 mlrd. dolara što predstavlja dvostruko više nego krajem pretkrizne 2007. godine.

Ukoliko se promatra povijesne prinose i volatilnosti industrije hedge fondova, graf 5 u nastavku jasno prikazuje primjer efikasnosti hedge fondova kao alternativnog oblika ulaganja. MSCI indeksi odnose se na prinose dioničkih indeksa, dok se Barclays Global odnosi na prinose obvezničkog indeksa u promatranom razdoblju. Indeks hedge fondova (Credit Suisse) ostvario je znatno bolji odnos prinosa i rizika u promatranom razdoblju u odnosu na tradicionalne oblike.

Graf 5 – Prinosi i volatilnost odabranih oblika ulaganja (1994-2015)



Izvor: Credit Suisse Hedge Fund Indexes (2019)

Međutim, potrebno je uzeti u obzir da prinose hedge fondova karakteriziraju nenormalne distribucije prinosa i širok raspon investicijskih strategija koje se mogu podijeliti u dvije glavne kategorije. U navedenu podjelu spadaju strategije usmjerenja (eng. *directional*) kojima se pokušava iskoristiti uzlazne i silazne tržišne trendove te neusmjerene strategije koje se temelje na tehnikama arbitraže (Aragon i Strahan, 2012). U nastavku rada slijedi pregled vrsta hedge fondova prema kriteriju odabrane investicijske strategije.

3.1.1. Vrste hedge fondova

Investicijske strategije usmjerenja temelje se na predviđanju tržišnih trendova. U praksi, ove su strategije povezane s vještinama menadžera portfelja u određivanju optimalnog trenutka (eng. *market timing*) kupnje ili prodaje određenog financijskog instrumenta (Basile, 2016).

Tablica 6 – Vrste hedge fondova prema kriteriju investicijske strategije

Strategija	Politika upravljanja	Odrednice performansi
Strategije usmjerenja (eng. *Directional*)		
Duga/Kratka ulaganja u dionice (eng. *Long/Short Equity*)	Menadžer istovremeno zauzima duge i kratke pozicije odnosno kupuje i prodaje dionice na temelju očekivanog trenda kretanja tržišta. Glavna odluka odnosi se na odabir neto izloženosti rastu ili padu dioničkog tržišta koristeći financijsku polugu.	Smjer kretanja dioničkih tržišta Visina financijske poluge Odabir dionica za kupnju i prodaju (eng. *stock picking*)
Upravljane ročnice (eng. *Managed Futures)*	Fokus na derivativne instrumente u obliku ročnica (eng. *futures*) koje obuhvaćaju cijeli spektar realne imovine poput roba (eng. *commodities*), financijskih instrumenata (dionice, obveznice, kamatne stope, valutni tečaj), plemenitih metala i sl. Cilj strategije je iskoristiti rastući ili opadajući trend cijene odabrane imovine.	Smjer kretanja odabranih tržišta Učinkovitost tehničke analize instrumenata
Globalne makro strategije (eng. *Global Macro*)	Temelj za ulaganje predstavljaju detaljne makroekonomske analize tržišnih trendova i fundamenata s ciljem uočavanja tržišnih anomalija koje se mogu iskoristiti[14]. Fokus je na iznimno likvidnim tržištima gdje se zauzimaju duge/kratke pozicije u različitim financijskim instrumentima.	Smjer kretanja globalnih tržišta Učinkovitost tržišta izvedenica Sposobnost prognoziranja tržišnih kretanja
Kratka prodaja (eng. *Short Selling*)	Fokus je na zauzimanju kratke pozicije na dioničkim tržištima i ostvarivanja prinosa od padajućih tržišnih trendova	Smjer kretanja tržišta Učinkovitost sustava za trgovanje
Tržišta u razvoju (eng. *Emerging Markets*)	Ulaganje u dionice i indekse zemalja u razvoju, bez limita na koncentraciju izloženosti i financijsku polugu.	Smjer kretanja i pristup tržištima u razvoju
Neusmjerene strategije (eng. *Nondirectional*)		
Arbitraža dužničkih instrumenata (eng. *Fixed Income Arbitrage*)	Menadžeri koji se bave arbitražom pokušavaju identificirati precijenjene i podcijenjene vrijednosne papire na temelju očekivanja promjene vremenske strukture kamatnih stopa ili kreditne kvalitete izdavatelja. Izloženost tržišnom riziku neutralizirana je kombinacijom duge i kratke pozicije.	Razina kreditnih raspona (eng. *credit spreads*) Arbitraža s krivuljom budućih kamatnih stopa Financijska poluga Učinkovitost kamatne imunizacije

[14] Primjerice, ukoliko je došlo do promjene određenog makroekonomskog faktora (globalno ili u specifičnoj zemlji), a određeni financijski instrumenti nisu odreagirali sukladno pretpostavljenim tržišnim zakonitostima (npr. rast prinosa na izdane obveznice nakon smanjenja referentnih kamatnih stopa).

Strategija	Politika upravljanja	Odrednice performansi
Neutralnost u dioničkom tržištu (eng. *Equity Market Neutral*)	Istovremena kupnja dionica koje se smatraju pod/precijenjenim u cilju eliminacije sistemskog rizika te profitiranja na osnovi neefikasnosti financijskih tržišta.	Financijska poluga Volatilnost Odabir dionica za kupnju i prodaju (eng. *stock picking*)
Konvertibilna arbitraža (eng. *Convertible Arbitrage*)	Temelj strategije čini arbitraža između dionica i konvertibilnih obveznica[15] istog izdavatelja, gdje se zauzima kratka pozicija u dionici i duga pozicija u obveznicama, u cilju iskorištavanja pogrešnog određivanja cijena.	Visina kuponskih kamata Razlika između dividende i kamatne stope kod kratkih pozicija Volatilnost i kreditni rasponi
Strategije vođene događajima (eng. *Event Driven*)	Iskorištavanje prilika u slučaju financijskih operacija, kao što su spajanja i akvizicije (eng. *mergers/acquistions*) i otkupi pomoću financijske poluge (eng. *leveraged buyouts*), koristeći arbitražu na vrijednosnim papirima uključenih tvrtki. Duge pozicije se obično zauzimaju u instrumentima tvrtke koja se preuzima, a kratke pozicije kod tvrtke koja preuzima.	Tržišni ciklusi Uspješnost financijske transakcije
Rizični instrumenti (eng. *Distressed Securities*)	Kupnja vrijednosnih papira kompanija koje su u privremenom ili trajnom financijskom problemu, no njihovo poslovanje ukazuje na značajnu vjerojatnost prevladavanja krize ili pretjeranu penalizaciju od strane tržišta u smislu nagle prodaje vrijednosnih papira kompanije.	Negativna ekonomska situacija Degradacija vrijednosti nelikvidnih instrumenata Dostupnost pravne, porezne i menadžerske ekspertize

Izvor: Obrada autora prema (Basile, 2016)

Između navedenih investicijskih strategija, prema visini imovine pod upravljanjem, najviše su zastupljene strategije s dužničkim instrumentima (eng. *fixed income*) koje su na kraju trećeg tromjesečja 2021. godine obuhvaćale 979,5 mlrd. dolara od ukupne imovine pod upravljanjem hedge fondova. Slijede ih tzv. *emerging markets* (423,4 mlrd. dolara) i *event driven* strategije (273,7 mlrd. dolara)[16].

Iz tablice 6 vidljivo je da menadžeri hedge fondova koriste niz investicijskih strategija koje mogu varirati u kompleksnosti provedbe. U ovom radu fokus je na prinosima generalne industrije hedge fondova koja uključuje agregirane prinose navedenih strategija te podvrsti hedge fondova koja se može promatrati kao zaseban alternativni oblik ulaganja, a odnosi se na

[15] Obveznica koje se može pretvoriti u vlasnički udio kompanije izdavatelja (tj. dionice).
[16] Izvor: https://www.barclayhedge.com/solutions/assets-under-management/.

ročnice (eng. *managed futures*). Ovaj alternativni oblik pokazao se kao vrlo dobar diverzifikator za institucionalne investitore, posebno u kriznim vremenima na financijskim tržištima.

3.1.2. Glavne odrednice Hedge fondova

Hedge fondovi kao alternativni oblik ulaganja imaju brojne specifičnosti gdje se kao glavne mogu izdvojiti (Schneeweis et al., 2011 i Lhabitant, 2006):

- menadžeri hedge fondova pokušavaju ostvariti što više apsolutne prinose bez usporedbe uspješnosti s definiranim mjerilom (eng. *benchmark*),
- manja opterećenost regulatornim ograničenjima,
- manjak transparentnosti u pogledu strukture investicija u fondu,
- izdvajanje poslova (eng. *outsourcing*) koji nisu povezani s upravljanjem investicijama,
- prosječno manji iznos imovine pod upravljanjem u odnosu na tradicionalne fondove.

U pogledu distribucije prinosa, hedge fondovi pokazuju sljedeća obilježja (Savona, 2016):

- **Debljina „repova“ distribucije prinosa** – analizom prinosa brojnih hedge fondova utvrđena je ponavljajuća značajna koncentracija opažanja prinosa na ekstremima distribucije što rezultira većom vjerojatnosti pojave značajnog odstupanja očekivanih prinosa u odnosu na normalne (tzv. Gaussove) distribucije čiji su repovi povezani s vrlo malim vjerojatnostima;
- **Asimetrija** – prinosi hedge fondova često su negativno asimetrični čime mogu ukazivati na veću vjerojatnost realizacije negativnih prinosa,
- **Serijska korelacija** – označava pojavu moguće pristranosti središnjih momenata odabranog uzorka (posebno u standardnoj devijaciji).

Obzirom na prethodno navedena obilježja, može se zaključiti da prinosi hedge fondova ne slijede oblik normalne distribucije stoga korištenje tradicionalnih mjera performansi može dovesti do pogrešnih interpretacija.

Razumijevanje statističkog obrasca kretanja prinosa pojedinih strategija hedge fondova ključni je čimbenik za odabir hedge fondova kao oblika ulaganja. Proučavanje njihovih povijesnih prinosa pruža mnogo informacija, no važno je razumjeti i određena ograničenja. Prinosi u određenom dijelu ekonomskog ciklusa mogle bi sustavno biti slabiji nakon što se ekonomski ciklus promijeni (Pascual, 2013).

Postoje određene metode kojima se mogu neutralizirati posljedice specifičnih odrednica prinosa hedge fondova (Yau et al, 2007):

- Primjena pristupa odabira hedge fondova koji se bazira na kriteriju vrijednosti prva 4 središnja momenta distribucije (očekivani prinos, varijanca, asimetrija i zaobljenost) kako bi se uvažila nenormalna distribuiranost prinosa. Takav primjer vidljiv je u (Kat, 2005 i 2007; Davies et al., 2009 i Sunrise Capital, 2016) gdje se kombiniraju različite vrste hedge fondova i ročnice s tradicionalnim oblicima ulaganja u cilju postizanja pozitivnijih vrijednosti centralnih središnjih momenata portfelja.
- Investiranje u ročnice (eng. *Managed futures*) pomoću kojih se provode strategije praćenja tržišnih trendova (eng. *Trend following*), a koje blagotvorno utječu na asimetrične karakteristike koje su suprotne od onih koje imaju hedge fondovi.

Investitori mogu postići izloženost prema hedge fondovima kroz direktno ulaganje u pojedini fond ili indirektno kroz udjele u fondovima kojima se trguje na burzi (*eng. Exchange traded funds-ETF*), a koji slijede određeni referentni indeks industrije hedge fondova (npr. *Barclay Hedge Fund index*).

3.1.2.1 Mjerodavni indeks prinosa industrije hedge fondova u analiziranom razdoblju – Barclay Hedge Fund Indeks

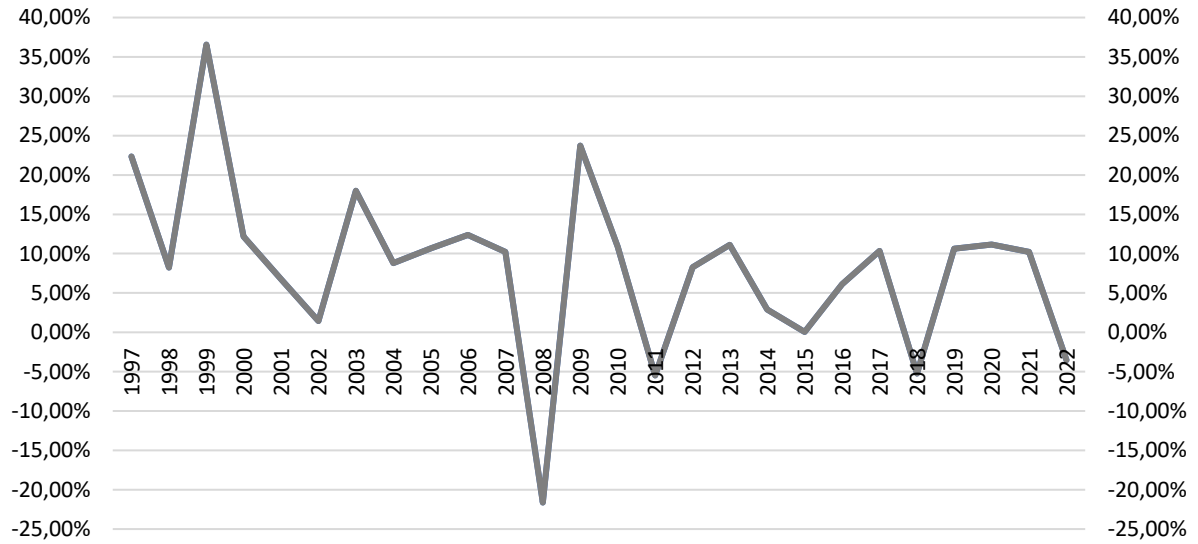
Barclay Hedge Fund Indeks mjera je prosječnog prinosa svih hedge fondova u Barclay bazi podataka. Indeks je jednostavan aritmetički prosjek neto prinosa svih fondova koji su prijavili prinose za pojedini mjesec. Indeks se izračunava i ažurira u stvarnom vremenu na stranici *barclayhedge.com* čim se evidentiraju mjesečni prinosi fondova. Broj fondova koji su trenutno uključeni u izračun indeksa za recentan period iznosi preko 3000.

Barclay Hedge Fund Indeks može se smatrati globalno jednim od najmjerodavnijih indeksa koji reprezentira prinose globalne industrije hedge fondova. Baza podataka za alternativne oblike ulaganja, *Barclay Hedge* baza, pokazala se najkvalitetnijom uzimajući u obzir recentne radove (Molyboga et al., 2017; Joenvaarra et al., 2012) gdje je utvrđeno da predmetna baza ima najveći broj fondova alternativnih oblika ulaganja u odnosu na druge izvore podataka (npr. TASS, HFR). Buraschi et al. (2014) ukazuju na dvije glavne prednosti korištenja navedene baze podataka. Prva se odnosi na činjenicu što je baza najmanje izložena riziku pristranosti podataka (eng. *survivorship bias*) jer uključuje najveći broj aktivnih i ugašenih fondova. Druga glavna

prednost je što baza posjeduje najdužu povijest podataka o imovini pod upravljanjem (eng. *asset under management*).

Graf 6 pokazuje kontinuitet ostvarivanja pozitivnih godišnjih prinosa hedge fondova tijekom duljih vremenskih razdoblja, osim za vrijeme velike financijske krize (2008.), no razina prinosa imala je brz oporavak. Početkom 2010-ih godina ponovno dolazi do značajnog pada prinosa te izražene volatilnosti do danas. U pogledu recentnih performansi industrije hedge fondova, tijekom perioda COVID-19 krize ostvareni su prinosi na razinama od 10% bez izražene korekcije kao što je to primjerice bio slučaj kod dionica. Prvo tromjesečje 2022. godine obilježeno je padom prinosa.

Graf 6 - Godišnji prinosi hedge fondova (*Barclay Hedge Fund Index*) u periodu 1997-2022[17]



Izvor: (Barclayhedge, 2022)

3.1.2.2 Pristranost (eng. *bias*) u podacima

Korištenje povijesnih podataka iz vremenske serije indeksa hedge fondova u evaluaciji performansi i alokacije sredstava u pojedinu strategiju fonda temelji se na pretpostavci da indeksi neutralno odražavaju uspješnost pojedine strategije. Jedan od povijesno glavnih nedostataka, koji je postepeno ublažen, je da se većina baza podataka samoprijavljuje što je otvaralo mogućnost manipulativnog odnosno pristranog izvještavanja o podacima. Unatoč tome, korelacije između indeksa hedge fondova temeljenih na sličnim strategijama općenito su umjereno visoke.

[17] Podatak za 2022. odnosi se na period do kraja 2. mjeseca

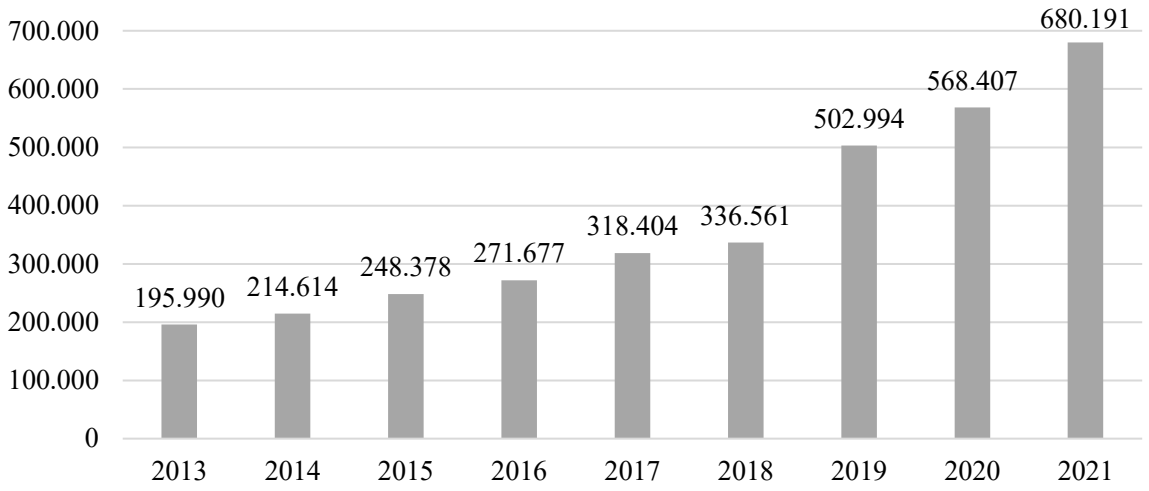
Iz navedenog proizlazi jedna od negativnih karakteristika hedge fondova koju je potrebno spomenuti, a odnosi se na inherentna ograničenja u dostupnim bazama podataka. U praksi postoji nekoliko vrsta pristranosti u povijesnim podacima a dijele se na:

- **Pristranost selekcije** (*eng. Self-selection Bias*) - menadžeri samostalno odabiru kategoriju kojoj pripadaju njihovi hedge fondovi bez ikakve analize neovisnih strana. Osim toga, menadžeri mogu biti potaknuti da dostavljaju informacije samo o fondovima koji su postigli najbolje rezultate. Učinak ovog oblika pristranosti na povijesnu seriju prinosa može precijeniti prinose kada su podaci dostavljeni samo za najbolje fondove, kao i mogući učinak podcjenjivanja prinosa, kada najbolji fondovi, čiji je upis novih udjela zatvoren, ne žele transparentno objaviti svoje podatke (Asness et al., 2001).
- **Pristranost nadopunjavanja** (*eng. Backfill Bias*) - kada fondovi po prvi puta dostavljaju podatke o prinosima, također podnose i svoje povijesne rezultate. Menadžeri mogu odlučiti objaviti samo podatke koji se odnose na vremensko razdoblje u kojem je fond ostvario najbolje prinose, a što dovodi do precijenjenosti prinosa (Yau et al., 2007).
- **Pristranost preživljavanja** (*eng. Survivorship Bias*) **-** ovaj fenomen se javlja kada fondovi u bazi podataka prestanu dostavljati informacije o prinosima, što se događa nakon perioda značajnih gubitaka. Pojava generira precijenjenost prinosa koji proizlazi iz različitih strategija budući da se najgori fondovi isključuju iz uzorka (Baker and Filbeck, 2013).
- **Pristranost likvidacije** (*eng. Liquidation Bias*) - uobičajena praksa menadžera hedge fondova je da prestanu davati informacije o fondovima neposredno prije njihove likvidacije odnosno nakon odluke o prestanku njihove aktivnosti. Ova praksa onemogućuje utvrđivanje neto imovine fondova (eng. *net asset value*) u likvidaciji (Teo, 2011).

Uzimajući u obzir rizike pristranosti u podacima, u ovom radu se koristi *Barclay Hedge* baza podataka za alternativne oblike ulaganja iz razloga koji su navedeni u potpoglavlju 3.1.2.1. Duljina vremenske serije analiziranog razdoblja od 2006.-2020. godine obuhvaća nekoliko kriznih perioda. Razina kvalitete podataka s vremenom se očekivano povećala pa recentnije vremenske serije iz mjerodavnih baza mogu pružiti realan odraz učinkovitost hedge fondova kao alternativnih oblika ulaganja.

3.1.3 Alternativni fondovi u Republici Hrvatskoj

Graf 7 – Imovina alternativnih fondova u RH u periodu 2013 - 2021. (u '000 EUR)



Izvor: Izrada autora prema (HANFA, 2022)

Graf 7 prikazuje imovinu pod upravljanjem (eng. *asset under management*) alternativnih investicijskih fondova koji su bili aktivni u periodu 2013. do kraja 2021. godine, a spadaju u sljedeće kategorije:

- Otvoreni alternativni investicijski fondovi s javnom ponudom (eng. *Opened - end alternative investment funds with public offering*)
- Zatvoreni alternativni investicijski fondovi s javnom ponudom (eng. *Closed - end Alternative Investment Funds with Public Offering*)
- Zatvoreni alternativni investicijski fondovi s privatnom ponudom (eng. *Closed - end alternative investment funds with private offering*)
- Osnovni alternativni investicijski fondovi s privatnom ponudom (eng. *Base alternative Investment funds with private offering*)
- Posebni alternativni investicijski fondovi s privatnom ponudom (eng. *Special alternative investment funds with private offering*).

Ukupna imovina alternativnih fondova navedenih kategorija u Republici Hrvatskoj na kraju 2021. godine iznosila je 680,2 mil. EUR te se kontinuirano povećavala u promatranom razdoblju, tj. više od tri puta u odnosu na kraj 2013. kada je iznosila 196 mil. EUR. Predmetni fondovi u većini slučajeva ne koriste opisane vrste strategija hedge fondova te se prema tom kriteriju ne mogu smatrati hedge fondovima u pravom smislu, no radi svojih karakteristika i važeće EU regulative se svrstavaju u alternativne investicijske fondove. Pregled upravitelja alternativnih fondova dostupan je u poglavlju 3.6.

3.2. Pojam i odrednice ročnica

Upravljane ročnice (eng. *managed futures*) odnose se na aktivno trgovanje *futures* ugovorima na fizičku robu, financijsku imovinu i valute. Svrha ove industrije je omogućiti investitorima da profitiraju od promjena cijena *futures* ugovora bez stvarne fizičke razmjene imovine. Strategije upravljanih ročnica su stil ulaganja koji se temelji na vještinama menadžera portfelja. Kod takvih stilova, investicijski menadžeri pokušavaju iskoristiti svoja posebna znanja i uvid u kupnju i prodaju *futures* ugovora kako bi ostvarili pozitivan prinos (Anson, 2006). Ovaj alternativni oblik ulaganja se, kao i hedge fondovi, može opisati kao strategija ostvarivanja što viših apsolutnih prinosa. Hurst et al. (2013) kvalitetno opisuju glavna obilježja prinosa ovog oblika ulaganja.

Ročnice označavaju sektor investicijske industrije u kojem profesionalni menadžeri aktivno upravljaju imovinom klijenata koristeći *futures* ugovore i druge derivativne vrijednosne papire kao i investicijske instrumente. Menadžeri fondova ročnica se u praksi često nazivaju CTA što označava engleski termin *Commodity Trading Advisors* (u nastavku: CTA) koji se također koristi u svrhu prepoznatljivosti industrije upravljanih ročnica. Kao i većina hedge fondova, CTA-ovi se bave institucionalnim i individualnim investitorima koji su financijski sofisticirani, imaju specifične investicijske zahtjeve i kojima je potrebna diverzifikacija ulaganja. Istovremeno, prinosi ročnica pokazuju mnogo nižu korelaciju s onima na tradicionalne oblike te stoga omogućuju mnogo bolju diverzifikaciju od privatnog kapitala, rizičnog kapitala ili konvencionalnih hedge fondova. Bitno je spomenuti da ročnice kao oblik ulaganja pružaju mnogo višu razinu likvidnosti od ostalih alternativnih oblika (Burghardt i Walls, 2011).

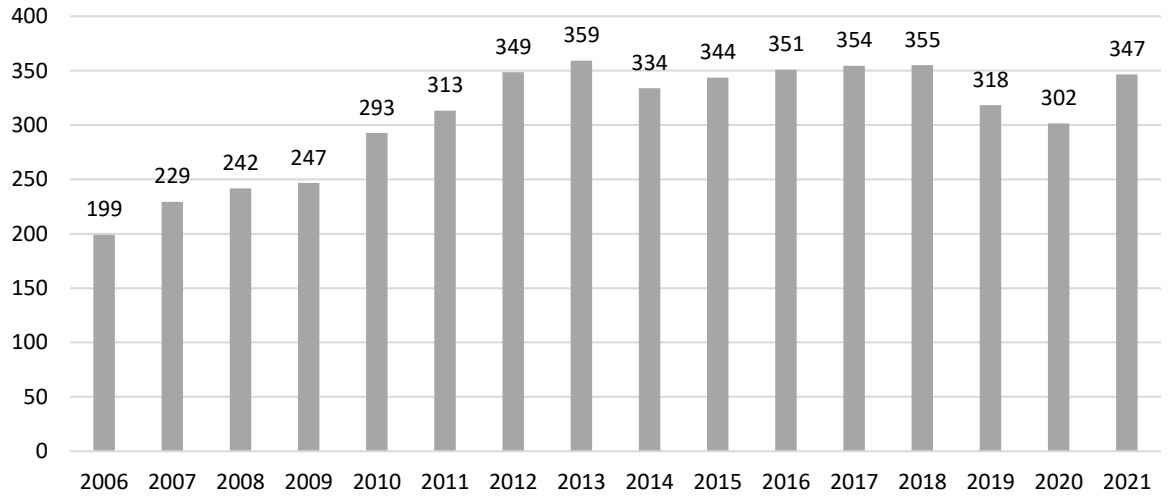
Ovaj alternativni oblik obuhvaća nekoliko aktivnih strategija hedge fondova koji su specijalizirani za likvidna, transparentna, burzovna tržišta ročnica i dubokih deviznih tržišta. Ročnice se ponekad promatra i kao podskup globalnih makro hedge fondova obzirom da se u njihovim strategijama također pokušava iskoristiti prednosti sustavnih pomaka na glavnim (ne)financijskim tržištima. Ročnice često nadmašuju performanse tradicionalnih oblika i većine alternativnih strategija hedge fondova, posebno tijekom nepovoljnih situacija na tržištu i značajnih makroekonomskih događaja (Abrams et al., 2012 i 2014).

Fondovi upravljanih ročnica imaju sličnu kompenzacijsku strukturu kao i hedge fondovi koja se sastoji od naknada za upravljanja i naknade za uspješnost. U pogledu investicijskih strategija, fondovi ročnica se dijele na podgrupe koje se odnose na:

- **Stil investiranja** (sistematičan ili diskrecijski) – Sistematičan stil se odnosi na model investiranje prema unaprijed definiranim pravilima uz minimalnu diskrecijsku intervenciju portfolio menadžera. Pravila mogu biti kodirana u automatizirani algoritam koji samostalno izvršava aktivnosti kupnje i prodaje instrumenata. S druge strane, diskrecijski stil ostavlja puno veći broj odluka o ulaganjima menadžeru portfelju od čega i proizlazi sam naziv stila,
- **Tržišta na kojima se trguje** (npr. financijski instrumenti, valute, robe i dr.),
- **Strategije trgovanja** (praćenje ili kontriranje tržišnih trendova).

Većina sistematičnih stilova investiranja koristi strategiju praćenja trendova (eng. *trend following*) koja se dodatno može razdijeliti po fokusu na kratkoročne, srednjoročne i dugoročne trendove ili njihovu kombinaciju. U dijelu diskrecijskih strategija, trguje se financijskim, valutnim i robnim futures ugovorima. Takvi modeli temelje se na korištenju fundamentalnih ekonomskih podataka i intuiciji menadžera.

Graf 8 - Vrijednost imovine pod upravljanjem (AUM) industrije ročnica (u mlrd. USD)



Izvor: (Barclayhedge, 2022)

Na grafu 8 vidljiva je vrijednost imovine pod upravljanjem industrije ročnice u periodu od 2006. do kraja 2021. godine. Vrijednost imovine rasla je čak i za vrijeme velike financijske krize (2006.-2008.) sve do kraja 2013. nakon čega dolazi do blagog pada i stagnacije. Recentna COVID kriza utjecala je na dodatan pad vrijednosti imovine dok je tijekom 2021. godine ponovno zabilježen značajan rast te je imovina fondova ročnica iznosila ukupno 347 mlrd. dolara. Rast popularnosti tržišta ročnica doveo je do značajnog rasta imovine pod upravljanjem u segmentu upravljanih ročnica. Elektronička tržišta i tehnologija također su pridonijele skalabilnosti i kapacitetu industrije.

3.2.1. Glavne odrednice ročnica

U cilju spoznaje uspješnosti ročnica kao alternativnog oblika ulaganja, posebno tijekom kriznih razdoblja na tržištu, potrebno je jasno odrediti i istaknuti glavna obilježja. Ročnice obuhvaćaju niz aktivnih strategija trgovanja koje su specijalizirane za likvidne, transparentne *futures* ugovore kojima se trguje na burzi, te opcije i devize, i mogu se smatrati likvidnom, transparentnom strategijom hedge fondova. Ročnice mogu zauzimati duge i kratke pozicije na tržištima na kojima trguju, dostupne su samo kvalificiranim investitorima i mogu koristiti financijsku polugu. Bitna razlika ovog oblika u odnosu na primjerice dionice je što kod ročnica nema ograničenja u kratkoj prodaji.

Prethodno spomenuti termin *Commodity Trading Advisor* (CTA) često rezultira pogrešnim korištenjem pasivnih indeksa roba, kao što su *Goldman Sachs Commodity Index* (GSCI) ili *DJ AIG Commodity Index* (DJ AIG) kao reprezentativna mjerila uspješnosti industrije ročnica. Navedeni indeksi nisu prikladni jer uključuju samo mali dio tržišta ročnica i ne uzimaju u obzir aktivno upravljanje ili mogućnost zauzimanja kratkih i dugih pozicija, a što rezultira izostankom korelacije tijekom vremena.

Aktivno upravljanje i sposobnost zauzimanja dugih i kratkih pozicija ključne su značajke koje razlikuju strategije upravljanih ročnica ne samo od pasivnih indeksa roba, već i od tradicionalnih oblika ulaganja. Iako većina fondova upravljanih ročnica trguje indeksima dionica, obveznicama i ročnicama valuta, njihovi prinosi trebali bi biti nisko korelirani i nepovezani s prinosima ovih oblika ulaganja. Većina menadžera fondova upravljanih ročnica ne preuzima sistemsku izloženost oblika na osnovi kojih je ročnica izvedena, već pokušava ostvariti dodatan prinos kroz aktivno trgovanje ročnicama što može rezultirati potpuno drugačijim profilima prinosa od dugotrajnih pasivnih tradicionalnih indeksa (Abrams, 2014).

Ročnice su dobar izbor za institucionalne investitore iz nekoliko razloga koji uključuju (Burghardt i Walls, 2011):

- **Transparentnost** - Cijene ročnica određuju se konkurentno i svakodnevno na tržištu. Činjenica da svatko može vidjeti knjigu trgovanja gdje se jasno vidi cijena namire čini cijene ročnica točnijim i pouzdanijim od cijene određene na bilo kojem drugom tržištu. Cijene na tržištu nisu ustajale i nema pojedinih nedostataka specifičnih za tržišta dionica i obveznica. Također, nisu potrebni posebni modeli za vrednovanje strukturiranih vrijednosnih papira. Rezultat ove prednosti je što su vidljivi prinosi stvarni i nisu izglađeni

(eng. *smoothed*). Teško se može pronaći serijska korelacija u prinosima povezana s diskrecijom koju drugi hedge fondovi imaju u tome kada i koliko revalorizirati portfelj kada se tržišne cijene promijene. Također, i sami upravitelji fondova ročnica nastoje biti izuzetno transparentni kada su u pitanju strategije trgovanja, zauzete pozicije u instrumentima, skrbništvo nad investiranim novčanim sredstvima itd.

- **Likvidnost -** Transakcijski troškovi kod ročnica su niži nego na njihovim temeljnim tržištima. Prednosti vrste aktivnog upravljanja i trgovanja ročnicama ostavljanju znatno manji tržišni utjecaj na cijene nego što bi to bio slučaj kod iste vrste trgovanja, ali na temeljnim tržištima.
- **Nizak valutni rizik -** Ročnice na inozemnu imovinu ili robu dolaze s ugrađenom zaštitom od valutnog rizika. Kupnja ročnica na europski indeks dionica ne stvara izloženost riziku promjeni tečaja eura, dok direktno ulaganje u europske vrijednosnice kreira takvu izloženost.

Dodatno je potrebno naglasiti pitanje likvidnosti čija se važnost može podcijeniti, a izuzetno je bitna za investitore, posebice društva za osiguranje koja moraju imati pristup kratkoročnoj likvidnosti radi obveza prema osiguranicima. Ukoliko određeni hedge fond trguje nelikvidnim instrumentima i ima dug predefiniran period „držanja“ investicije, direktna usporedba prinosa s prinosima ročnica kojima se trguje na burzi nije ispravna (Bhaduri i Art, 2008). Period obveznog držanja investicije od strane fondova privatnog kapitala i hedge fondova koji trguju nelikvidnim instrumentima koštaju investitore u obliku smanjene fleksibilnosti i trebali bi biti kompenzirani višim prinosima odnosno premijom za nelikvidnost ulaganja.

Trgovanje ročnicama često se u javnosti prikazuje kao izrazito rizičan i špekulativan oblik ulaganja. Međutim, inherentne karakteristike *futures* ugovora čini ih znatno manje rizičnim od investiranja u druge oblike imovine. Ročnice su stekle reputaciju rizičnog oblika ponajviše zbog volatilnosti pojedinačnih tržišta roba, koje mnogi blisko povezuju s tržištima ročnica. Visoka volatilnost indeksa roba, kao što je *Goldman Sachs Commodity Index* (GSCI), također dijelom objašnjava percepciju visokog rizika ročnica. Međutim, potrebno je razjasniti niz kritičnih razlika između roba i ročnica.

Postoje značajne razlike između pasivnih dugotrajnih indeksa kao što je GSCI i aktivno upravljanih strategija trgovanja. Robe (eng. *commodities*), kao oblik ulaganja, znatno se razlikuju od *futures* ugovora koji su financijski instrumenti kojima se trguje na burzi, a čija je vrijednost povezana s cijenama raznih oblika imovine. Ročnice mogu biti više volatilne od

nekih strategija hedge fondova, ali to ne znači nužno da su rizičnije (Abrams, 2014). Mjerenje rizika pomoću volatilnosti može navoditi na krive zaključke, posebno kada se radi o alternativnim oblicima ulaganja čije distribucije prinosa odstupaju od pretpostavki normalnosti. Iz tog razloga, u mjerenju performansi potrebno je koristiti mjere efikasnosti koje uzimaju u obzir više momente distribucije (asimetriju i zaobljenost) kao što je Omega omjer koji je opisan u poglavlju 2.5.5. te se primjenjuje u ovom znanstvenom istraživanju.

3.2.2. Strategije trgovanja upravljanim ročnicama

Prethodno je spomenuto da se upravljane ročnice većinom povezuju s investicijskim strategijama praćenja trendova. Međutim, likvidnost *futures* ugovora i obilne količine dostupnih podataka olakšavaju primjenu brojnih drugih varijacija kvantitativnih sistematičnih strategija trgovanja.

Strategija praćenja trenda (eng. *trend following*) pokazala je svoju uspješnost tijekom više od 30 godina, a otprilike 70 posto stilova trgovanja ročnicama potpada pod ovu strategiju. Tehnikom praćenja trenda dominiraju strategije zamaha (eng. *momentum*) i/ili proboja (eng. *breakout*) koje pokušavaju iskoristiti velike pomake u cijeni određenog instrumenta koji perzistiraju određeni vremenski period u smjeru rasta ili pada cijene. Drugim riječima, metode su usmjerene na eksploataciju tržišnih neefikasnosti. Moskowitz et al. (2012) su u svom radu dokumentirali glavna obilježja i povijesne rezultate zamaha vremenskih serija (eng. *time series momentum*) u ročnicama na financijske indekse dionica, valuta, roba i obveznica. Autori su utvrdili perzistenciju kretanja prinosa u istom smjeru unutar raspona od 1 do 12 mjeseci što nije u potpunosti sukladno hipotezi efikasnih tržišta. Šonje et al. (2010) provode testiranje hipoteze efikasnosti tržišta na osnovi tržišta dionica SAD-a i RH. Autori evidentiraju određene periode neefikasnosti tržišta iz kojih nije bilo moguće donijeti zaključak o potpunoj (ne)efikasnosti promatranih tržišta.

Strategija se može dodatno podijeliti na vremenski okvir praćenja trendova od dugoročnog (mjeseci, godine) do kratkoročnijeg (dani, tjedni). Uspješnost rezultata usko je povezan s vremenom držanja investicije u ovom obliku ulaganja obzirom da najveći pozitivni prinosi proizlaze iz koncentriranih perioda (npr. nekoliko mjeseci). D'Souza et al. (2016) ukazuju na pozitivne performanse navedene strategije u iznimno dugom vremenskom periodu od 1927. do 2014. godine. Hurst et al. (2017) i Miffre i Perez (2011) također potvrđuju zaključke o performansama strategije praćenja trendova i zamaha (eng. *momentum*). Harvey et al. (2019)

ističu upravljane ročnice kao učinkovit oblik ulaganja ukoliko se investor želi zaštititi od sistematičnih kriza na financijskim tržištima.

Postoji još niz strategija za trgovanje ročnicama koje ne moraju nužno imati bilo kakvu statističku povezanost s prethodno opisanom strategijom praćenja trendova. Primjerice, kontratrend strategije pokušavaju iskoristiti često brze i dramatične preokrete koji se događaju na kraju prolongiranih cjenovnih trendova. Pojedini menadžeri investicijskih portfelja koriste ekonometrijsku analizu fundamentalnih faktora, koji utječu na cijene instrumenata, za razvoj sustava trgovanja ročnicama. U ovom kontekstu mogu se koristiti i napredne kvantitativne tehnike kao što su filtriranje tržišnih signala za kupnju ili prodaju, neuronske mreže, računalni algoritmi i druge znanstvene metode. Ovakvi pristupi trgovanju omogućeni su na temelju napretka u računalnoj snazi i tehnologiji. Bezbrojne kombinacije aktivnih stilova i tehnika ulaganja ročnica rezultiraju prinosima koji nisu korelirani s prinosima drugih tradicionalnih i alternativnih oblika ulaganja (Abrams et al., 2012).

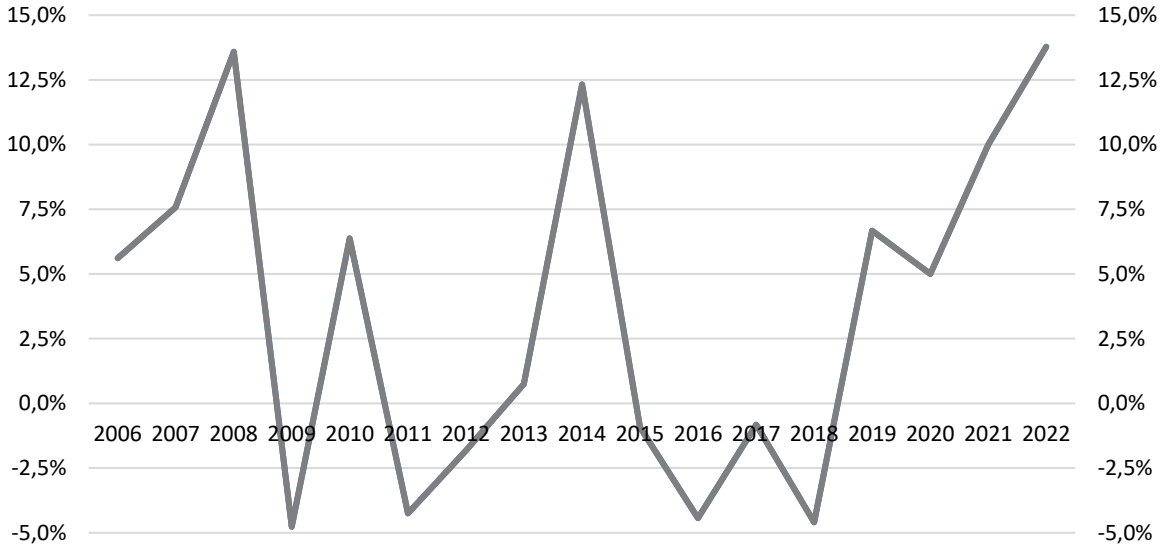
3.2.2.1. Indeks prinosa industrije ročnica u analiziranom razdoblju – BTOP50

Indeksi *Barclay Hedge* baze često se koriste u reprezentaciji prinosa industrije ročnica obzirom da primjerice CTA indeks predstavlja nepristrane prinose ročnica (Molyboga et al., 2017). *Barclay Hedge* baza, pokazala se najkvalitetnijom uzimajući u obzir recentne radove (Molyboga et al., 2017; Joenvaarra et al., 2012) gdje je utvrđeno da predmetna baza ima najveći broj fondova alternativnih oblika ulaganja u odnosu na druge izvore podataka (npr. TASS, HFR). Buraschi et al. (2014) ukazuju na prednosti korištenja navedene baze podataka koje se odnose na nisku izloženosti riziku pristranosti podataka i činjenici da predmetna baza posjeduje najdužu povijest podataka o imovini pod upravljanjem (eng. *asset under management*).

Indeks BTOP50 nastoji replicirati cjelokupni sastav industrije upravljanih ročnica s obzirom na stil trgovanja i ukupnu izloženost tržištu. Najveći CTA menadžeri, mjereni imovinom pod upravljanjem, odabrani su za uključivanje u BTOP50. U svakoj kalendarskoj godini odabrani fondovi predstavljaju, ukupno, ne manje od 50% imovine industrije ročnica u koju se može uložiti. Kriteriji da bi određeni fond ili program trgovanja bio uključen u BTOP50 indeks su sljedeći (*Barclayhedge*):

- Menadžer mora biti spreman osigurati podatke o dnevnim prinosima,
- Program mora imati povijest od najmanje dvije godine trgovanja,
- Savjetnik programa mora imati povijest rada od najmanje tri godine.

Graf 9 – Godišnji prinosi BTOP50 indeksa u periodu 2006.-2022**.** godine



Izvor: (Barclayhedge, 2022)

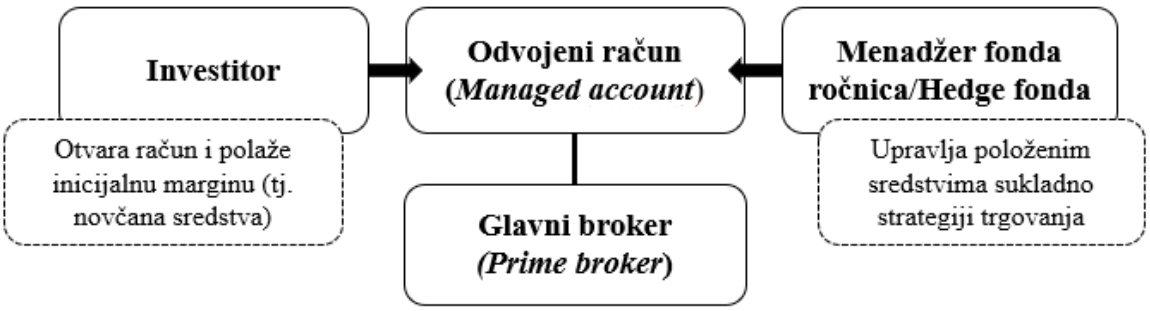
Graf 9 prikazuje godišnje prinose indeksa ročnica. Zaključak iz pregleda prinosa je na tragu spomenutog odnosno vjerojatnost ostvarivanja viših prinosa upravljanih ročnica povećava se ukoliko investitor održava alokaciju u ovaj oblik ulaganja tijekom duljeg vremenskog perioda (npr. minimalno 3 i više godina). Također, zanimljivo je promatrati recentne performanse indeksa, posebno u kontekstu COVID-19 krize i početnog perioda inflacije gdje su ostvareni godišnji prinosi iznosili iznad 5%. Povijesno gledano, indeks u promatranom razdoblju nije ostvario nijednom negativan prinos ispod -5% što dodatno naglašava pogodnosti ovog oblika ulaganja u dugom roku, posebno u kriznim razdobljima.

U razdobljima nižih prinosa i stagnacija, menadžeri ročnica izlaze iz postojećih pozicija i ulaze u nove za koje je očekivana dobit veća što često rezultira konvergencijom prinosa prema dugoročnoj srednjoj vrijednosti te kreira efekt iznenadnog rasta prinosa, a što je vidljivo i na grafu 9. Iskusni investitori često povećavaju svoja ulaganja u ove oblike u periodu nižih ili negativnih prinosa u očekivanju spomenutog efekta.

3.2.3. Prednosti ulaganja u ročnice za institucionalne investitore

Za institucionalne investitore, ročnice predstavljaju likvidan i transparentan oblik ulaganja koji je pritom nisko koreliran s tradicionalnim i drugim alternativnim oblicima. Ulaganjem u ročnice mogu se ostvariti povoljni prinosi u nepovoljnom tržišnom okruženju koje negativno utječe na prinose dionica i obveznica. Važna prednost ročnica je činjenica da im se može pristupiti preko zasebno odvojenih računa (eng. *managed accounts*) čime se značajno umanjuje operativni rizik,

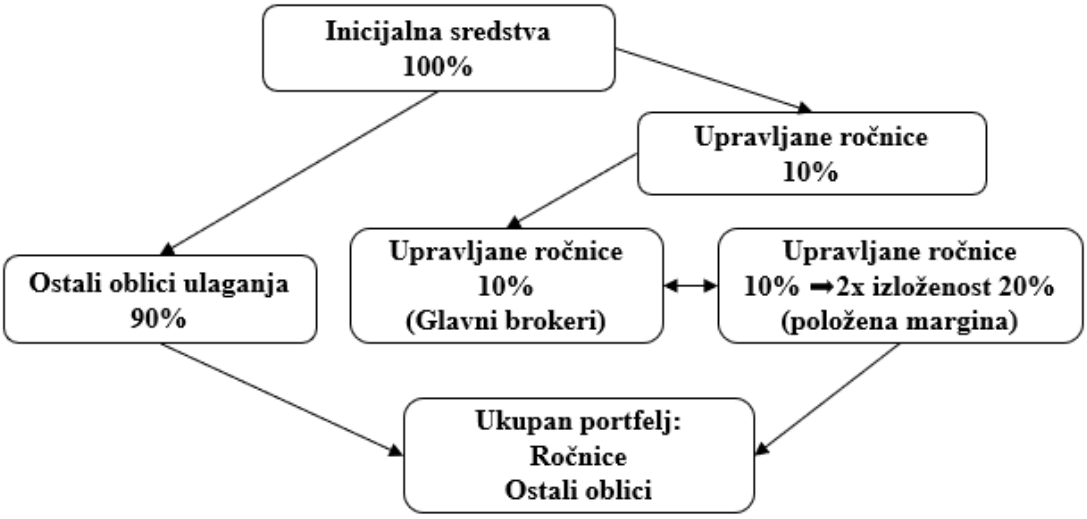
mogućnost prijevare, skrbništvo nad sredstvima, te omogućava potpuna transparentnost otvorenih ulagačkih pozicija.



Shema 2 – Primjer toka novca kod odvojenih računa (eng. *managed account*)

Izvor: Izrada autora

Ovakav način ulaganja u ročnice dostupan je modelom trgovanja koji često koriste upravitelji fondova ročnica, a koji se naziva trgovanje na marginu (eng. *margin trading*). Takav oblik trgovanja podrazumijeva situaciju u kojoj investitor posuđuje sredstva za investiranje od brokera, a prije čega je dužan položiti određeni iznos novčanih sredstava (tzv. marginu) kao kolateral. Visina kolaterala iznosi određeni postotak željenog iznosa ulaganja (npr. 50%). Specifičnost ovog stila trgovanja je u tome što investitor ne treba uložiti 100% svojih sredstava da bi kupio ili prodao ročnicu na određeni financijski instrument, već značajan dio investicije pokriva posuđivanjem sredstava od brokera čime se postiže efikasna alokacija kapitala.



Shema 3 – Pregled ulaganja u upravljane ročnice (eng. *managed futures*)

Izvor: Izrada autora

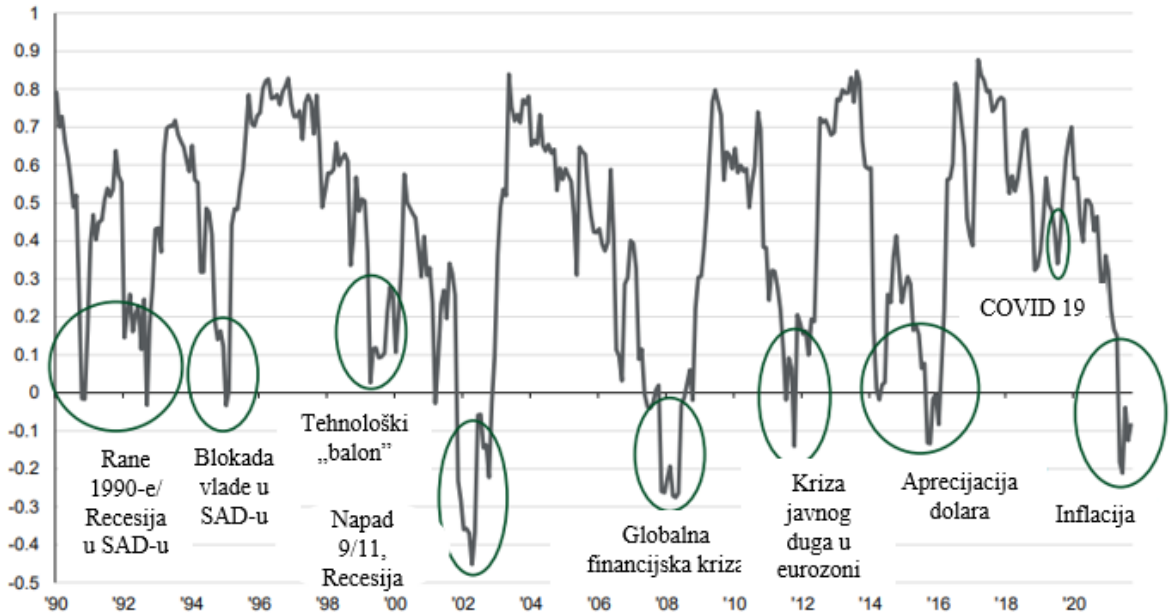
Prednost ulaganja u ročnice odnosno trgovanja na marginu je mogućnost kreiranja veće izloženosti od inicijalnog ulaganja kroz posuđivanje sredstava od brokera. Shema 3 prikazuje

takvu dinamiku investiranja gdje se od 100% slobodnih sredstava, 10% investira u ročnice nakon čega se putem margine može kreirati potrebna visina izloženosti koja će kreirati optimalne diversifikacijske učinke (npr. 20% udjela portfelja), dok se ostatak sredstava može investirati u druge strateške oblike ulaganja. Također, pitanje usklađenosti imovine i obveza također je važno za mnoge institucionalne investitore, posebno za društva za osiguranje. Visoka likvidnost upravljanih ročnica i drugih likvidnih strategija hedge fondova znatno ublažava potencijalnu neusklađenost imovine i obveza (Abrams, 2014).

3.3. Korelacija hedge fondova s tradicionalnim oblicima ulaganja i utjecaj na investicijski portfelj

U pogledu korelacije hedge fondova s dionicama i obveznicama, na grafu 10 prikazana je korelacija hedge fondova (indeks *HFRI Macro*) s teoretskim portfeljem u omjeru 60% dionica (*S&P 500*) i 40% obveznica (*Barclays U.S. Aggregate*) u razdoblju od 1990.-2022. godine. Posebno su istaknute korelacije u kriznim periodima (Heerden et al., 2014) koji su negativno utjecali na financijska tržišta gdje se u većini slučajeva korelacija kretala u rasponu od 0,2 - 0, pa čak ušla i u negativan teritorij. Korelacija hedge fondova i dionica u pravilu nije niska, no kada se u sastav portfelja uključe i obveznice, razine korelacije i dalje upućuju na potencijalne učinke diversifikacije koji se mogu ostvariti uključivanjem hedge fondova u investicijski portfelj.

Graf 10 - Korelacija prinosa hedge fondova s teoretskim 60/40 portfeljem dionica i obveznica



Izvor: J.P. Morgan, Guide to Alternatives (3Q 2022)

Hedge fondovi koriste širok raspon strategija čija se uspješna provedba temelji na vještinama menadžera portfelja dok investitori imaju različite preferencije u pogledu strategije hedge fonda koji odgovaraju njihovom apetitu za rizikom. Učinak diverzifikacije od uključivanja hedge fonda može varirati ovisno o profilu investitora i pojedine strategije fonda.

Tablica 7 – Korelacija prinosa hedge fondova, tradicionalnih i alternativnih oblika ulaganja u periodu 2008 - 1Q 2022

2008 - 1Q 2022		#	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Financijska ulaganja	Global bond	1	1,0														
	Global equity	2	0,3	1,0													
Globalne nekretnine	USA RE	3	-0,2	0,1	1,0												
	Europe RE	4	-0,3	0,2	0,8	1,0											
	APAC RE	5	-0,1	0,1	0,8	0,7	1,0										
Nekretnine	Infrastruktura	6	-0,1	-0,1	0,3	0,1	0,2	1,0									
	Transport	7	-0,2	0,0	0,6	0,5	0,6	0,0	1,0								
	Drvna građa	8	-0,2	-0,1	0,3	0,2	0,2	0,2	0,1	1,0							
Privatni kapital	Direct lending	9	0,0	0,7	0,3	0,4	0,3	0,2	0,2	-0,1	1,0						
	Venture Capital	10	0,0	0,6	0,3	0,5	0,3	0,1	0,2	0,1	0,5	1,0					
	Private Equity	11	0,2	0,9	0,3	0,5	0,4	0,0	0,2	-0,1	0,8	0,8	1,0				
Hedge fondovi (strategije)	Equity Long/Short	12	0,2	0,9	0,0	0,2	0,0	0,0	0,2	-0,1	0,7	0,7	0,9	1,0			
	Relative Value	13	0,2	0,9	-0,1	0,2	0,0	0,0	0,0	-0,2	0,9	0,5	0,8	0,9	1,0		
	Macro	14	0,1	0,4	0,0	0,1	-0,1	0,0	-0,2	0,1	0,2	0,3	0,3	0,4	0,3	1,0	
Crypto	Bitcoin	15	0,1	0,1	0,2	-0,2	0,1	0,5	0,1	0,0	0,1	0,1	0,2	0,1	0,1	0,0	1,0

Izvor: Obrada autora prema (J.P. Morgan, Guide To Alternatives, Q3 2022)

Podaci u tablici 7 sugeriraju potencijalno značajne prednosti diverzifikacije kroz izloženosti alternativnim oblicima, a posebno hedge fondovima koji imaju nisku korelaciju s većinom promatranih oblika ulaganja. Dionice, privatni kapital jedini su oblici ulaganja s kojima hedge fondovi nisu kompatibilni u pogledu korelacije.

Jedna od briga mnogih investitora je dostupnost resursa za izravno ili neizravno istraživanje ulaganja u ove alternativne oblike. Informacije o dionicama i obveznicama kojima se javno trguje dostupnije su nego za privatne dionice, dok indeksirani instrumenti ulaganja za alternativne oblike često nedostaju. Sukladno tome, investitori se mogu suočiti s internim ograničenjem resursa koje im ograničava ulaganje u alternativne oblike, no takva ograničenja se više odnose na privatne investitore. Institucionalni investitori ipak imaju više resursa unutar organizacije koji im omogućavaju razmatranje uključivanja alternativnih oblika u investicijski portfelj. Ulaganja u fondove koji ulažu u nekoliko različitih (strategija) hedge fondova prikazanih u tablici 7 može poslužiti kao početna točka za razmatranje ulaganja u ovaj oblik.

3.4. Korelacija upravljanih ročnica s tradicionalnim oblicima ulaganja i utjecaj na investicijski portfelj

Raznolikost strategija trgovanja ročnicama te izostankom korelacije među njima, kao i s drugim tradicionalnim i alternativnim oblicima ulaganja, omogućuje povećanje prinosa ili smanjenje rizika portfelja uključivanjem ovog alternativnog oblika. Lintnerovo pionirsko istraživanje pokazalo je da postoje značajne koristi koje proizlaze iz "selektivne diverzifikacije" među različitim fondovima ročnica zbog "prilično umjerenih" korelacija među njima (Lintner 1996).

Tablica 8 – Povijesne korelacije ročnica s ostalim oblicima ulaganja

Financijski indeks	#	1	2	3	4	5	6	7	8	9	10	11	12
BTOP 50 (Ročnice)	1	1.00											
S&P 500 TR (Dionice)	2	-0.04	1.00										
MSCI World (Dionice)	3	-0.01	0.88	1.00									
Capital Bond US (Obveznice)	4	0.20	-0.10	-0.09	1.00								
Capital Bond Global (Obveznice)	5	0.22	0.19	0.23	0.89	1.00							
GSCI TR (Robe)	6	0.12	0.17	0.23	-0.03	0.00	1.00						
DJ UBS Commodity (Robe)	7	0.17	0.30	0.40	0.01	0.11	0.90	1.00					
HFRI Fund (Hedge fond)	8	-0.02	0.74	0.75	-0.08	0.06	0.30	0.44	1.00				
HFRI Equity Hedge (Hedge fond)	9	-0.02	0.73	0.72	-0.08	0.06	0.35	0.43	0.95	1.00			
LPX Buyout (Privatni kapital)	10	-0.21	0.75	0.77	-0.10	-0.14	0.30	0.31	0.77	0.78	1.00		
S&P/Citigroup World REIT (Nekretnine)	11	-0.02	0.61	0.64	0.18	0.26	0.22	0.37	0.51	0.49	0.60	1.00	
Newedge Short-Term Traders (Ročnice)	12	0.54	-0.50	-0.44	0.00	0.08	-0.14	-0.09	-0.34	-0.40	-0.48	-0.42	1.00

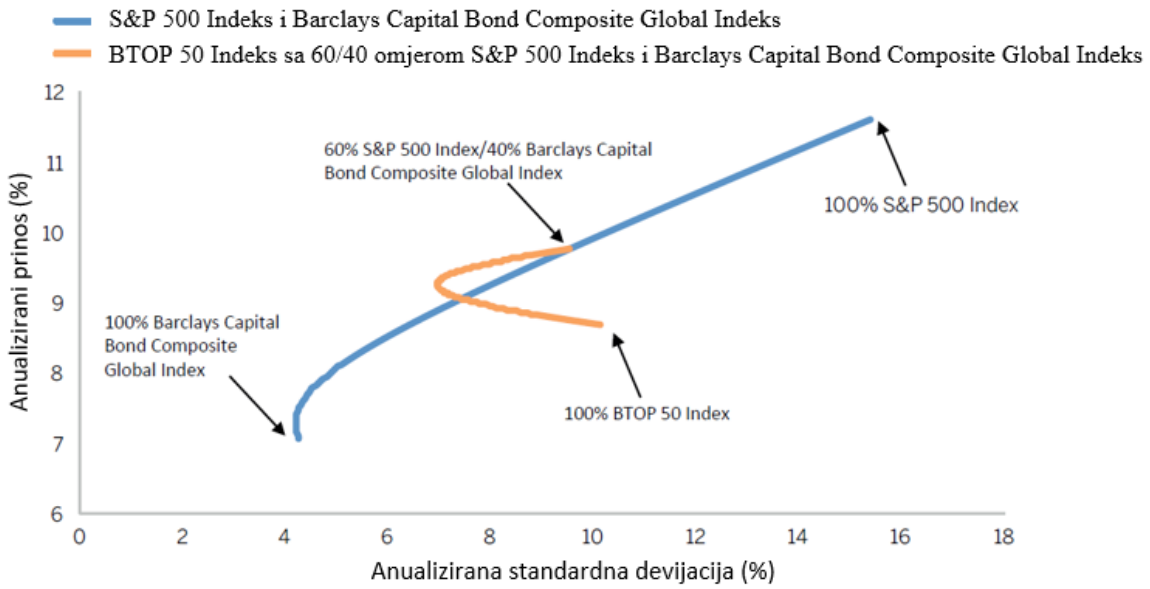
Izvor: Obrada autora prema (Abrams et al., 2014)

U tablici 8 prikazane su korelacije ročnica s drugim tradicionalnim i alternativnim oblicima ulaganja. Period vremenske serije razlikuje se ovisno o obliku obzirom da je cilj analize bio prikupljanje što većeg broja opservacija, no ukupan period promatranja počinje 1980-ih, a završava s krajem 2011. godine. Također, vidljiv je izostanak korelacije indeksa upravljanih ročnica (BTOP 50) sa svim ostalim indeksima tradicionalnih i alternativnih oblika ulaganja, ali i dodatnim strategijama ulaganja s ročnicama (*Newedge Short-Term Traders*). Ova razina korelacije omogućuje ročnicama davanje pozitivnog doprinosa većini investicijskih portfelja, a institucionalnim investitorima pristup cijelom spektru likvidnih strategija hedge fondova.

Iskorištavanje trendova i drugih cjenovnih pomaka koji obično prate velike makro događaje od strane industrije ročnica inducira pozitivne prinose i nisko koreliranu varijancu što ih čini aditivnim za većinu portfelja. Iako ročnice obično imaju visoku volatilnost i niže Sharpeove omjere u odnosu na druga alternativna ulaganja, dodavanje nisko koreliranog oblika svakako povećava prinos i smanjuje varijancu investicijskog portfelja. Ukoliko je oblik ulaganja volatilan sam po sebi ne znači nužno da će povećati volatilnost cijelog portfelja (Abrams, 2012).

Lintner (1996) je u svom radu prvi ukazao na nisku i povremenu negativnu korelaciju između portfelja ročnica i portfelja tradicionalnih oblika ulaganja koji se sastoje od dionica i obveznica, a što omogućava kreiranje znatno efikasnijeg portfelja. Karakteristike strategija trgovanja ročnicama proizvode pozitivno asimetrične distribucije, uz relativno nisku zaobljenost, što je preferencija većine institucionalnih investitora (Athayde i Flores, 2004). Primjerice, većina strategija hedge fondova ima negativno asimetrične distribucije s debljim repovima u lijevom dijelu gdje se nalaze negativni prinosi, a što proizlazi iz činjenice da u normalnim tržišnim uvjetima generiraju dobre prinose, dok u visoko volatilnim uvjetima visoke gubitke.

Graf 11 – Efikasna granica investicijskog portfelja sastavljenog od ročnica, dionica i obveznica u periodu 1987-2014.



Izvor: Obrada autora prema (Abrams et al., 2014)

Graf 11 prikazuje utjecaj uključivanja ročnica u portfelj sastavljen od dionica i obveznica uz vidljivo unapređenje efikasne granice u pogledu odnosa prinosa i standardne devijacije. Prinosi ročnica tijekom vremena demonstrirali su značajna dugoročna diversifikacijska svojstva u kontekstu formiranja investicijskog portfelja s više različitih oblika ulaganja. Također,

predstavljaju jednu od rijetkih investicijskih strategija koje imaju potencijal za ostvarivanje iznadprosječnih pozitivnih prinosa tijekom duljih stresnih perioda na financijskim tržištima (Meisner et al., 2012).

3.5. Ostali alternativni oblici ulaganja

U nastavku će se ukratko navesti osnovna obilježja ostalih alternativnih oblika ulaganja koji su u praksi često zastupljeni u investicijskom portfelju. Od dodatnih alternativnih oblika izdvajaju se nekretnine (*eng. real estate*), privatni kapital (eng. *private equity i venture capital*) i robe (*eng. commodities*). Navedeni popis nije isključiv obzirom da postoje još brojni (pod)oblici ulaganja koji se radi svojih obilježja mogu smatrati alternativnim.

3.5.1. Nekretnine

Financijske nekretnine su klasa imovine s jedinstvenim karakterističnim značajkama u području upravljanja investicijskim portfeljem. U kontekst nekretnina kao alternativnih oblika spadaju fondovi nekretnina, fondovi za ulaganja u nekretnine (*eng. Real estate investment trust-REIT*), kao i nekretninski fondovi kojima se trguje na burzi (*eng. Exchange traded funds-ETF*) i drugi oblici. U kontekstu ulaganja, nekretnine se koriste u cilju eksploatacije prihoda u obliku najma i potencijala aprecijacije vrijednosti. Čimbenici koji utječu na prinose i rizike ovog oblika ulaganja imaju karakteristike koje se često ne nalaze u drugim oblicima imovine i stoga omogućuju veću diverzifikaciju portfelja (Abate, 2016).

Brueggeman i Fisher (2015) ulaganja u nekretnine dijele na direktno odnosno privatno ulaganje i indirektno odnosno financijsko ulaganje koje se može nazvati i vlasničko ulaganje u nekretnine (eng. *equity real estate*). Vrednovanje portfelja nekretnina predviđa ostvarivanje prihoda od nekretnine njezinim iznajmljivanim na komercijalnom tržištu poslovnih prostora kao i povećanje vrijednosti odnosno tržišne cijene nekretnine s ciljem ostvarivanja kapitalne dobiti od buduće prodaje. Tržište nekretnine specifično je u smislu da ne postoji centralno organizacijsko tijelo putem kojeg se provode kupoprodajne transakcije nekretnina kao primjerice kod dionica gdje se većina trgovanja odvija putem burze. Kod nekretnina se transakcije odvijaju ili putem posrednika/agenta ili direktno između dvije strane uz mnoštvo transakcijskih troškova koji uključuju posredničke provizije, poreze i administrativne naknade. Tržište nekretnina se može segmentirati po više kriterija, od geografskog (lokalno, regionalno nacionalno) do kriterija svrhe korištenja (rezidencijalne, komercijalne, industrijske i sl.).

Korištenje financijskih instrumenata kod ulaganja u nekretnine može ponuditi značajne prednosti u usporedbi s izravnom kupnjom. Prije svega, treba istaknuti povećanu diverzifikaciju portfelja koja je ostvariva čak i za manje razine investicija, zahvaljujući nižim početnim pragovima ulaganja. Drugim riječima, vlasnička ulaganja u nekretnine mogu biti reprezentirana financijskim instrumentima s niskom jediničnom cijenom dok kod izravnih ulaganja, trošak cjelokupne nekretnine je takav da svaka investicijska strategija zahtijeva značajne izdatke, posebno za individualnog investitora.

U pogledu likvidnosti, ukoliko je fond uvršten na regulirano tržište, troškovi vezani uz raspon cijene (eng. *bid-ask spread*) znatno su niži od onih na općem tržištu nekretnina. Među negativnim čimbenicima vlasničkih ulaganja u nekretnine treba uzeti u obzir da je razina kontrole nad imovinom investitora znatno niža u usporedbi s izravnim vlasništvom te da uključivanje treće strane rezultira plaćanjem naknade za upravljanje. S druge strane, prisutnost profesionalnog upravljanja može biti samo djelomično negativna, s obzirom na veće iskustvo upravitelja imovine, objekata i nekretnina u usporedbi s običnim investitorom koji bi u svakom slučaju trebao snositi administrativne troškove angažiranja specijaliziranih stručnjaka.

Tablica 9 - Prednosti, troškovi i rizici direktnih i vlasničkih ulaganja u nekretnine

Oblik ulaganja	Prednosti	Troškovi i rizici
Vlasnička ulaganja u nekretnine	– Niža početna granica za investiranje – Diversifikacija – Profesionalno upravljanje imovinom i objektima – Visoka razina likvidnosti (za ulaganja uvrštena na burzama)	– Niska kontrola nad nekretninama – Visoke upravljačke naknade – Rizici koji proizlaze iz prekomjerne financijske poluge – Niska likvidnost (za ulaganja koja nisu uvrštena na burzama)
Posjed nekretnine	– Potpuna kontrola vlasništva nad nekretninom i upravljanje – Fleksibilnost u opcijama financiranja kupnje (odabir visine financijske poluge)	– Visoki inicijalni pragovi za investiranje (kupnja cijele nekretnine) – Visoki transakcijski i administrativni troškovi (posrednici, porezi, održavanje) – Visoka koncentracija rizika – Niska likvidnost

Izvor: Abate, 2016

Nekretnine se mogu smatrati jednim od najranijih tradicionalnih alternativnih oblika ulaganja radi čega i danas imaju značajnu ulogu u investicijskim portfeljima različitih profila investitora. U pogledu prinosa tijekom 2020. godine, globalna ulaganja u nekretnine na tržištima SAD-a, Europe i Azije ostvarila su prinose u rasponu 4-5% dok se ukupan iznos ulaganja u nekretnine kretao na razini 150 mlrd. dolara (J. P. Morgan, 2022*)* što predstavlja značajan pad u odnosu na

godine prije COVID krize. Bitno je istaknuti vrlo nisku i negativnu korelaciju s globalnim dionicama i obveznicama u periodu nakon financijske krize (2008.- 1Q 2022.) što ukazuje na diversifikacijski potencijal ovog oblika ulaganja.

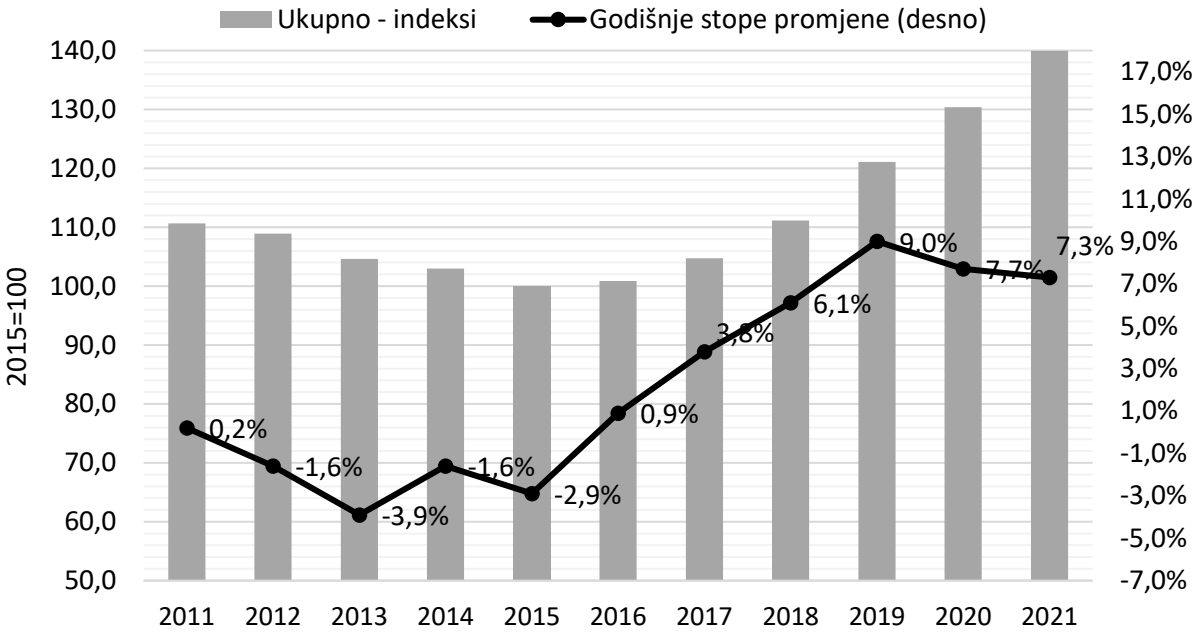
Tablica 10 – Korelacija prinosa nekretnina s dionicama i obveznicama (2008 - 1Q 2022)

2008- 1Q 2022		Global bond	Global equity	USA RE	Europe RE	APAC RE	Global Infra
Financijska ulaganja	Global bond	1					
	Global equity	0,3	1				
Globalne i ostale nekretnine	USA RE	-0,2	0,1	1			
	Europe RE	-0,3	0,2	0,8	1		
	APAC RE	-0,1	0,1	0,8	0,7	1	
	Global Infra	-0,1	-0,1	0,3	0,1	0,2	1

Izvor: Izvor: Obrada autora prema (J.P. Morgan, Guide To Alternatives, Q3 2022)

Stanje na tržištu nekretnina Republike Hrvatske može se u određenoj mjeri promatrati preko indeksa cijena stambenih nekretnina (tzv. ICSN indeks). Indeks kvartalno objavljuje Državni Zavod za Statistiku (DZS), a odnosi se na kretanje tržišnih cijena stambenih objekata koje su kupila kućanstva. Podatke o transakcijama nekretnina dostavlja Porezna uprava.

Graf 12 – Kretanje vrijednosti ICSN indeksa u periodu 2002.-2021. (2015. = 100)



Izvor: DZS

Na grafu 12 vidljivo je kretanje vrijednost ICSN indeksa u periodu 2002.-2021. godine gdje je kao bazna odabrana 2015. godina. Vrijednosti indeksa prikazane su za ukupno tržište nekretnina, a mogu se segregirati na nove i postojeće stambene objekte, te geografski na Grad Zagreb, Jadran i Ostalo. Unatoč pandemiji COVID-19, zanimljivo je primijetiti da je vrijednost indeksa na kraju 2020. godine porasla na najvišu razinu otkada se indeks prati i izračunava.

Prosječni prinos kretanja vrijednosti indeksa u promatranom razdoblju iznosio je 4,5% što je na razini globalnih tržišta. Detaljniji uvid u kretanja vrijednosti ukazuje na značajan pad cijena tržišta nekretnina nakon zadnje globalne financijske krize koji je trajao do 2015. nakon čega počinje kontinuirani rast koji se posebno intenzivirao u posljednjih nekoliko godina.

3.5.2. Privatni kapital

Ulaganje u kapital kompanije kojim se stječe dio vlasništva može se odnositi na tvrtke koja kotiraju na reguliranom tržištu ili na one koje ne kotiraju. U prvom slučaju radi se o transakciji javnog kapitala odnosno dionice dok se drugi odnosi na transakcije privatnog kapitala a definira se kao institucionalna investicijska aktivnost u ciljna poduzeća koja ne kotiraju na burzi. Investicijska aktivnost se provodi kupnjom dionica i, potencijalno, hibridnih dužničko-vlasničkih instrumenata, s ciljem povećanja vrijednosti tvrtke u koje se ulaže, a sve u cilju naknadne prodaje u srednjem ili dugom roku (Abate, 2016). Ulaganja u privatni kapital zahtijevaju kontinuirane aktivnosti praćenja kako bi se odabrale potencijalne tvrtke koje treba unaprijediti. Ovaj cilj uključuje pristup "aktivnog vlasništva", kroz osiguravanje ne samo financijskih sredstava, već i stručnih, tehničkih i upravljačkih kompetencija (Manigart i Wright, 2013).

Ukoliko je financijski i ljudski kapital osiguran u početnim fazama poslovnog životnog ciklusa poduzeća, tada se investicijska aktivnost naziva rizičnim kapitalom (eng. *venture capital*). Prema praksi SAD-a, rizični kapital je skupina šire industrije privatnog kapitala, dok praksa EU-a jasno razdvaja te dvije skupine, favorizirajući posebne značajke ulaganja u nova poduzeća, tzv. *start-up* (Caselli i Negri, 2018).

Investicije privatnog kapitala u tvrtke koje su prešle početnu fazu poslovanja spadaju u kategorije financiranja ekspanzije. Takve tvrtke nalaze se u fazi brzog rasta i stoga im je potreban pristup stabilnim izvorima financiranja kako bi proširili svoje poslovanje. Ulaganja u privatni kapital završavaju dezinvestiranjem odnosno prodajom udjela u ciljnom društvu. Takav postupak se može provesti na više načina od koji su najistaknutiji:

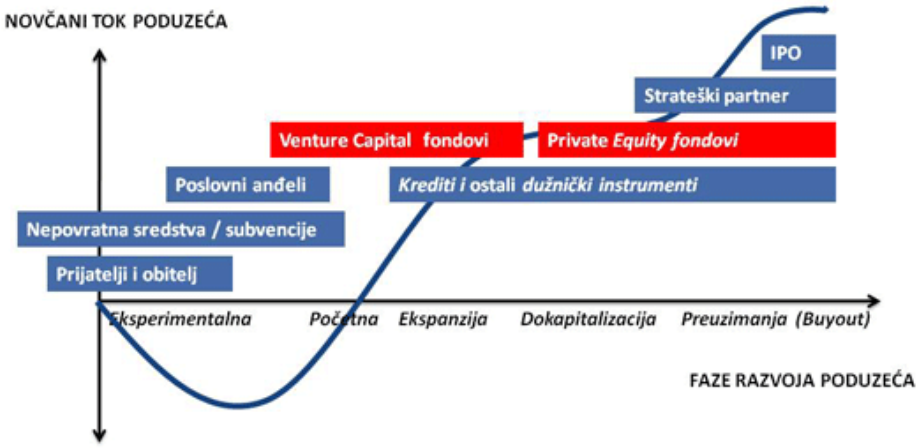
- Izlistavanje tvrtke na burzi kroz inicijalnu javnu ponudu (eng. *initial public offering*, IPO),
- Prodaje značajnog udjela drugom entitetu koji planira nastaviti ulaganja u cilju daljnjeg rasta tvrtke,
- Potpuno brisanje vlasničkog udjela, ukoliko investicija nije uspjela ili planirani ciljevi nisu ostvareni.

Privatnom kapitalu kao alternativnom obliku ulaganja može se pristupiti izravno, kroz sudjelovanje u vlasničkom kapitalu jedne ili više tvrtki ili neizravno, korištenjem različitih investicijskih subjekata, od kojih svaki ima svoje karakteristike. Pojedinim kotiranim instrumentima se trguje na reguliranim tržištima, dok ostali spadaju u skupinu nekotiranih ulaganja privatnog kapitala. Glavni investicijski subjekti privatnog kapitala su (Abate, 2016):

- Fondovi privatnog kapitala
- Kompanije s posebnom svrhom akviziranja
- Investicijska društva privatnog kapitala
- Fondovi kojima se trguje na burzi (*eng. Exchange traded funds-ETF*) a odnose se na oblik ulaganja privatnog kapitala. Ova vrsta subjekta omogućava pristup širokom rasponu investitora.

Posljednje navedeni subjekt omogućava indeksirani pristup investiranja u privatni kapital. Fondovi kojima se trguje na burzi specijalizirani su za repliciranje reprezentativnih indeksa privatnog kapitala gdje se izdvajaju sljedeći: *S&P Listed Private Equity Index, Red Rocks Capital Global Listed Private Equity, LPX Composite, Societe Generale Privex*.

Privatni kapital kao oblik ulaganja karakterizira izrazita segmentacija različitih strategija koje provode eksperti angažirani od strane investitora. Upravljačke strategije se obično klasificiraju prema fazi poslovnog životnog ciklusa tvrtke u koje se ulaže. Doprinos privatnog kapitala maksimizira vrijednost kompanije, posebno onda kada je tvrtka u kritičnoj fazi svog životnog ciklusa u kojem se javlja značajna potreba za kapitalom, a u isto vrijeme kreditiranje ili izdavanje dionica na tržištu kapitala nisu povoljne opcije.



Slika 3 – Strategije privatnog kapitala i financiranje razvoja poduzeća

Izvor: Cvijanović et al., 2008

Na slici 3 prikazane su strategije privatnog i rizičnog kapitala ovisno o fazi životnih ciklusa odnosno razvoja poduzeća. U pravilu se rizični kapital javlja u ranijim fazama razvoja dok se privatni kapital angažira u fazi ekspanzije i dokapitaliziranja tvrtke radi spomenutih razloga.

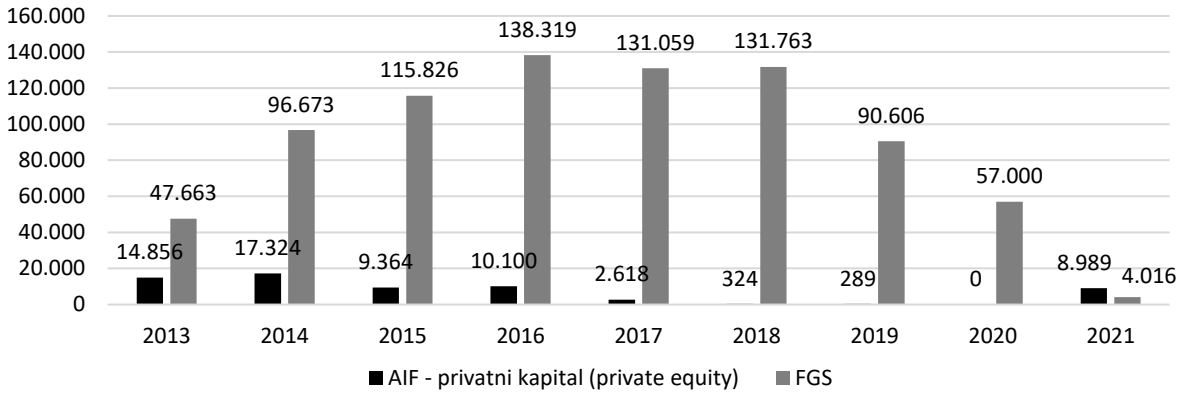
Tablica 11 - Korelacija prinosa privatnih ulaganja s ostalim oblicima (2008. – 1Q 2022.)

2008 - 1Q 2022		Global bond	Global equity	USA RE	Europe RE	APAC RE	Global Infra	Direct lending	Venture Capital	Private Equity
Financijska ulaganja	Global bond	1								
	Global equity	0,3	1							
Globalne i ostale nekretnine	USA RE	-0,2	0,1	1						
	Europe RE	-0,3	0,2	0,8	1					
	APAC RE	-0,1	0,1	0,8	0,7	1				
	Global Infra	-0,1	-0,1	0,3	0,1	0,2	1			
Privatna tržišta	Direct lending	0	0,7	0,3	0,4	0,3	0,2	1		
	Venture Capital	0	0,6	0,3	0,5	0,3	0,1	0,5	1	
	Private Equity	0,2	0,9	0,3	0,5	0,4	0	0,8	0,8	1

Izvor: Obrada autora prema (J.P. Morgan, Guide To Alternatives, Q3 2022)

Korelacija prinosa privatnih ulaganja s tradicionalnim oblicima poput globalnih dionica i obveznica u promatranom razdoblju znatno se razlikuje na način da je kod dionica prisutna očekivano visoka pozitivna korelacija dok je kod obveznica evidentna neutralna korelacija. Recentniji prinosi ulaganja privatnog kapitala u periodu od 2014.-2018. godine, mjereno preko interne stope profitabilnosti, iznosili su 21% dok su investicijski subjekti privatnog kapitala tijekom 2020. godine prikupili 400 mlrd. dolara (J.P. Morgan, Q3 2022).

Graf 13 – Imovina fondova privatnog kapitala u RH (u '000 EUR)[18]



Izvor: (HANFA, 2022.)

Iz grafa 13 vidljivo je kretanje imovine fondova privatnog kapitala u RH od perioda početka izvještavanja do kraja 2021. kada je imovina fondova privatnog kapitala značajno pala na najnižu razinu u promatranom razdoblju te je ukupno iznosila 13 mil. EUR. Na RH tržištu posluje samo nekoliko fondova u vlasništvu društava za upravljanje, a koji se bi se mogli

[18] AIF-Alternativni investicijski fond, FGS- Fondovi za gospodarsku suradnju

svrstati pod kategoriju fondova privatnog kapitala. Formalni naziv ovakvih fondova je Alternativni investicijski fondovi rizičnog kapitala s privatnom ponudom (eng. *Private equity open - ended alternative Investment funds with private offering*) i Fondovi za gospodarsku suradnju (eng. *Private equity funds for economic cooperation*).

Profil rizika i prinosa fondova privatnog kapitala kao oblika ulaganja intrinzično je povezan s procesom stvaranja vrijednosti tipičnim za potencijalne razvojne strategije tvrtke. U svakom slučaju, privatni kapital bitno se razlikuje od tradicionalnih oblika ulaganja i stoga mjerenje performansi zahtijeva kombinaciju inovativnih i klasičnih metrika prilagođenih specifičnostima ove kategorije alternativnih ulaganja (Baker et al., 2015).

3.5.3. Robe

Pojam roba označava sva ona realna dobra koja imaju maksimalnu zamjenjivost, što znači da su potpuno zamjenjivi i mogu se identificirati na temelju ograničenog broja specifičnih karakteristika. Kao rezultat njihove standardizacije, robom se može trgovati na reguliranim tržištima, eliminirajući izravan i jedinstven odnos između dviju strana koji se obično nalazi u trgovanju realnom imovinom. U pogledu klasifikacije roba, ona se može proizvesti izravno od strane primarnog sektora (npr. sirovine) ili biti rezultat određenog proizvodnog procesa te se mogu klasificirati prema proizvodnom sektoru iz kojeg potječu. Prije svega tu spadaju proizvodi iz poljoprivrednog sektora (tzv. mekane robe, *eng. soft commodities*) te rudarskog i energetskog sektora (tzv. tvrde robe, *eng. hard commodities*). Meke robe se potom dijele na poljoprivredne i stočarske dok tvrda roba uključuje tri makro-kategorije: metale, energiju i kemikalije (Abate, 2016).

Navedena podjela temelji se na kvalitativnim aspektima robe, ali kako bi se razumjelo kretanje cijena roba, u obzir treba uzeti i druge značajke. Robe se također mogu razlikovati po tome mogu li se skladištiti ili ne. Samo nekoliko vrsta roba, npr. električna energija, ne može se pohraniti tijekom vremena, dok za one koje mogu, relativni trošak skladištenja i sezonalnost u proizvodnji i/ili potrošnji su iznimno važni (Geman, 2008).

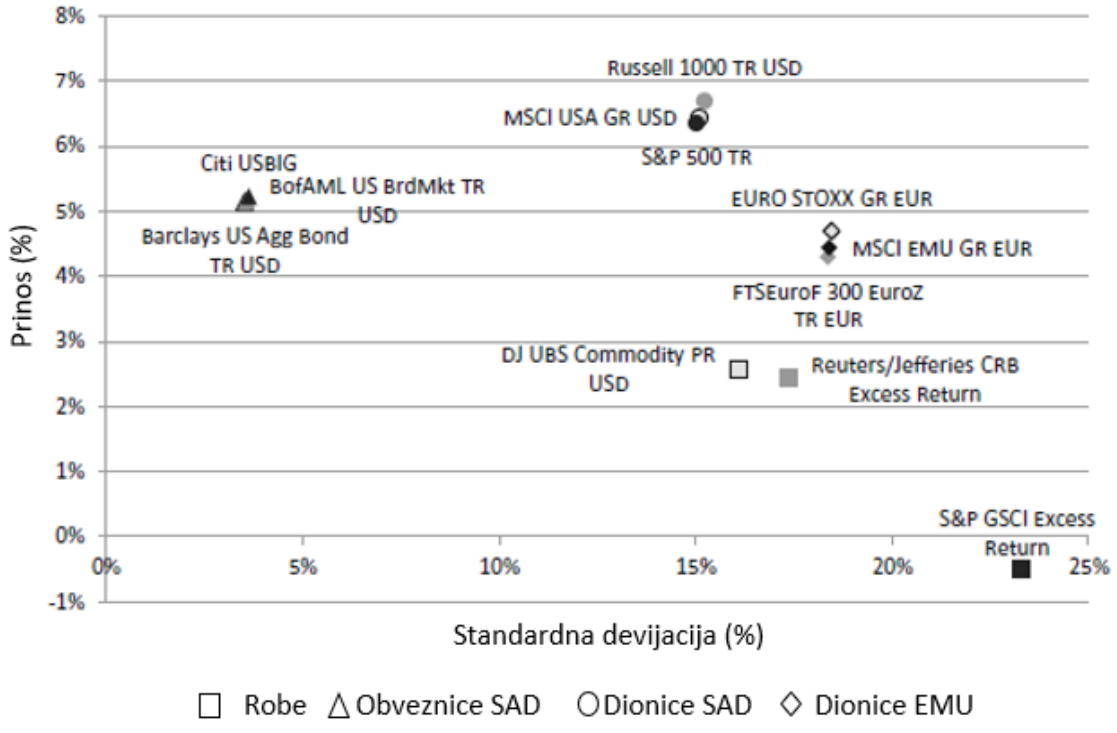
Tržišta roba su jedna od najstarijih tržišta, ali njihova formalna organizacija i regulacija je počela sredinom 1800-ih godina prošlog stoljeća dok se robni ugovori podmiruju fizičkom isporukom roba. U kontekstu ulaganja u ovaj alternativni oblik, danas se većina trgovine odvija putem ugovaranja ročnica (*eng. futures*) i budućnosnica (*eng. forward*) te se u radu nerijetko spominju engleski termini radi njihovog učestalijeg korištenja u praksi i prethodnim radovima.

Forward ili *futures* ugovor u svom najjednostavnijem obliku je obvezujući ugovor za kupnju ili prodaju robe, ali s odgođenom zamjenom robe i novca. Dakle, ako osoba danas kupi zlato, odmah preuzme zlato i odmah preda gotovinu za transakciju, kaže se da se razmjena dogodila na promptnom (eng. *spot*) tržištu. Navedeni ugovori obvezuju prodavatelja da isporuči ugovorenu imovinu po utvrđenoj cijeni i u određeno vrijeme. S druge strane, kupac ugovora pristaje kupiti imovinu po zadanoj cijeni i u određeno vrijeme. Postoje tri opće vrste terminskih ugovora: financijski *futures* ugovori, valutni *futures* ugovori i robni *futures* ugovori. Glavna razlika između *forward* i *futures* ugovora je u tome što se *forward* ugovori sklapaju direktno (eng. *over the counter*) dok se *futures* ugovorima trguje na uređenim burzama čime oni dijele iste prednosti burze dionica odnosno centralno tržište i transparentnost cijena, klirinški entitet, standardiziranost ugovora i uvjeta te dnevnu likvidnost (Anson et al., 2012).

Uzimajući u obzir administrativnu složenost, ulazne barijere i uključenu ekonomiju razmjera, izravna fizička ulaganja u robe nisu prikladna za institucionalne investitore koji svoju izloženost ovom obliku ulaganja postižu putem:

- udjela u kompanijama koje posluju u sektoru roba,
- robnim izvedenicama (npr. *futures* ugovori),
- robnim fondovima kojima se trguje na burzi (eng. *Exchange traded funds-ETF*).

Graf 14 – Prinos i rizik odabranih indeksa uključujući i robne indekse u periodu 2001-2015



Izvor: (Abate, 2016)

Na grafu 14 vidi se odnos prinosa (vertikalna os) i rizika (horizontalna os) odabranih indeksa tradicionalnih oblika ulaganja i 3 najčešće korištena robna indeksa (S&P GSCI, DJ-UBSCI, CRB). U promatranom razdoblju vidljiva je ipak nešto viša efikasnost dionica i obveznica u odnosu na robe.

Primarne motivacije za ulaganje u robe su diverzifikacija i povećanje prinosa. Diversifikacijski potencijal roba kao alternativnog oblika ulaganja temelji se na njihovoj različitosti u faktorima koji utječu na kretanje cijene u odnosu na dionice i obveznice. Drugim riječima, cijene roba su pod utjecajem drugačijih ekonomskih fundamenata u odnosu na tradicionalne oblike čime bi trebale imati nisku ili čak negativnu korelaciju s cijenama financijske imovine. Također, cijene roba su pozitivno korelirane s inflacijom dok je kod dionica i obveznica obrnuta situacija što dodatno upućuje na njihovu međusobno nisku korelaciju. Niska korelacija s inflacijom čini jednu od glavnih prednosti ulaganja u robe odnosno služi kao instrument za hedžiranje rizika inflacije (Anson et. al, 2012). S druge strane, rezultati u (Daskalaki i Skiadopoulos, 2011) preispituju navodne diversifikacijske učinke od ulaganja u robe uzimajući u obzir transakcijske troškove i period financijske krize tijekom 2007.-2009. godine.

3.6. Pregled upravitelja alternativnih fondova na globalnom i EU financijskom tržištu

U ovom dijelu rada dati će se pregled nekih od najvećih i najuspješnijih upravitelja hedge fondova i fondova ročnica na kraju 2021. godine. kao i trenutno aktivna društva za upravljanje alternativnim investicijskim fondovima u RH. Pregled upravitelja provesti će se prema kriteriju imovine pod upravljanjem i ostvarenih prinosa. Prije toga, izložiti će se okviran proces dubinske analize upravitelja fondova koji je potrebno provesti prije donošenja odluke o odabiru i ulaganju u alternativni fond.

3.6.1. Dubinska analiza upravitelja hedge fondova i fondova ročnica

Hedge fondovi su kroz povijest bili slabo regulirani, no zadnja financijska kriza potakla je promjene na tom području te su na svim većim financijskim tržištima doneseni novi zakonski okviri sa svrhom podizanja razine reguliranosti i standardizacije nadzora alternativnih fondova. Alternativne oblike ulaganja, posebice termin hedge fond, i dalje ponekad prate negativne konotacije kao i stereotip visoko rizičnih ulaganja. Takva percepcija može se argumentirati činjenicom da hedge fondovi dug period nisu imali formalne obveze i standardizirane zahtjeve za objavljivanjem kao primjerice tradicionalni investicijski fondovi.

Iako hedge fondovi obično podnose godišnji revidirani financijski izvještaj i pregled performansi u pogledu ostvarenih prinosa, rijetko otkrivaju svoje postojeće ulagačke pozicije u portfelju. Moguća zabrinutost koja proizlazi iz ovog nedostatka transparentnosti (Anson, 2006) uključuje sljedeće:

- Autentičnost podataka o prinosima upravitelja hedge fonda upitna je ako investitori ne mogu samostalno validirati objavljene podatke,
- Praćenje i upravljanje rizicima su otežani za investitore bez objave otvorenih pozicija portfelja od strane upravitelja hedge fonda. Bez navedenih informacija, investitori ne mogu razumjeti profil rizika kojima je portfelj fonda izložen.

Obzirom da poslovanje i strategije hedge fondova mogu biti nejasne, smanjenje investicijskih rizika koji proizlaze iz ulaganja u hedge fondove počinje s dubinskom analizom (eng. *due dilligence*). Dubinska analiza je kvantitativno i kvalitativno ispitivanje i provjera poslovne prakse, poslovanja, financijskih izvještaja i pravnih detalja budućeg poslovnog klijenta ili partnera. Taj se proces općenito obavlja prije uspostavljanja poslovnog odnosa; međutim, rutinska istraživanja postojećih poslovnih odnosa također mogu biti od koristi u otkrivanju relevantnih informacija. Okvir za dubinsku analizu upravitelja hedge fonda obuhvaća tržišne podatke, investicijski proces, organizaciju, ljude, uvjete i strukturu, pružatelje usluga, dokumente i prospekt fonda. Investitor može intervjuirati upravitelja hedge fonda i/ili poslati upitnik. Udruženje za upravljanje alternativnim ulaganjima (eng. *The Alternative Investments Management Association*) definira sljedeću provjeru kao vodič za investitore koji provode dubinsku analizu i (pr)ocjenjuju upravitelje hedge fondova:

Tablica 12 – Vodič za dubinsku analizu (eng. *due diligence*) upravitelja hedge fondova

I. Struktura alternativnog/hedge fonda
a) Pravni entitet: oblik i struktura vlasništva
b) Naziv i adresa upravitelja hedge fonda
c) Domicil: domaći (eng. *onshore*) ili inozemni (eng. *offshore*)
i. Područni uredi ili druge lokacije
d) Regulatorni tretman (npr. investicijski savjetnik ili savjetnik za trgovanje robama tj. CTA)
e) Zaposlenici: odgovorne osobe i zaposlenici (uključujući njihov CV)
f) Revizori, pravno savjetovanje i informacije o glavnom brokeru
II. Struktura alternativnog/hedge fonda
a) Strategija/Stil fonda (vidjeti poglavlje 3.1.1.)
b) Instrumenti koji se koriste za provedbu strategije (npr. popis korištenih izvedenih financijskih instrumenata)
c) Mjerilo uspjeha (eng. *benchmark, hurdle rate, high-water mark)*

d) Komparativna prednost/niša ili druga jedinstvenost fonda
i. Izvor investicijskih ideja i strategije
ii. Kako strategija funkcionira pod različitim tržišnim okolnostima
iii. Tržišne okolnosti u kojima strategija ima najbolje performanse
iv. Ograničenja strategije
e) Trenutne investicije: vrste i pozicije
III. Podaci u uspješnosti/prinosu
a) Popis svih fondova i performansi od početka rada
b) Podaci o poslovanju fondova i obrazloženja
IV. Rizik
a) Koji su rizici investicije i kako se mjere i upravljaju
i. Zaposlenici uključeni u upravljanje rizicima
b) Posebne mjere kontrole rizika, ako postoje (npr. ograničenja pozicije, derivati, kreditni limiti druge ugovorne strane)
c) Prošla, sadašnja i buduća upotreba financijske poluge
V. Istraživanje
a) Promjene strategije u prošlosti proizašle iz rezultata istraživanja
b) Resursi uloženi u istraživanje ideja za ulaganje/trgovanje
c) Budžet i osoblje (interno i eksterno) za istraživanje
VI. Administracija
a) Tužbe, sudski sporovi, regulatorni postupci protiv fonda ili upravitelja
b) Fluktuacija (značajnih) zaposlenika
c) Raspored osoblja za račune klijenata: odgovorni rukovoditelj računa klijenata
d) Plan oporavka u slučaju katastrofe (eng. *disaster recovery plan*)
VII. Pravni segment
a) Struktura naknada: naknade za upravljanje i uspješnost
b) Vremensko zaključavanje investicije i trajanje (eng. *Lock-up*)
c) Moguća visina ulaganja: maksimum i minimum
d) Penali za preuranjeno povlačenje sredstava
VIII. Reference
a) Profesionalni: revizor, glavni broker, pravni savjetnik
b) Postojeći investitori

Izvor: Obrada autora prema www.aima.org

Upravitelj fonda je najvažniji element u hedge fondu kao investicijskoj organizaciji (Pascual i Cuellar, 2010). Investitor bi trebao provjeriti koliko jedinstvenih strategija, fondova i zasebnih računa savjetuje upravitelj fonda i imovinu pod upravljanjem za svaki fond. Ovo je važno ne samo za prikupljanje podataka o uspješnosti, već i da bi investitor dobio osjećaj o investicijskom kapacitetu upravitelja fonda. Bitno je prikupiti saznanja o svim sredstvima ili računima koji su ukinuti kako bi se izbjegla pristranost odabira (eng. *selection bias*) u analizi uspješnosti.

Investitor bi kod dubinske analize trebao postaviti sljedeća važna pitanja (Anson et al., 2012):

1. Koliko dugo upravitelj fonda aktivno upravlja trenutnim i prethodnim fondom?
2. Je li uspješnost menadžera dosljedna tijekom vremena i svih fondova?
3. Kako se uspoređuju i preispituju strategije ulaganja fondova?

Za fondove je aktivan period postojanja od pet godina dovoljan da se prinosi fonda mogu smatrati mjerodavnim. Dosljednost uspješnosti kroz vrijeme pruža uvid u rizičnost fonda. (Burghardt i Walls, 2011) dodatno ukazuju na implikacije svojeg istraživanja u kontekstu provedbe dubinske analize upravitelja fonda. Autori ističu da sreća može dominirati nad vještinom menadžera fonda tijekom određenih vremenskih perioda promatranja, stoga u tom slučaju povijesne performanse treba uzeti s dozom opreza. Bitan element koji je potrebno uzeti u obzir kod analize hedge fonda je i operativni rizik (Lo, 2001). Investitori kod razmatranja fonda trebaju doći do spoznaje na koji način se upravitelj nosi s problemom procjene središnjih momenata prinosa te kako koristi svoje razumijevanje nedostataka korištenih statističkih metoda u organizaciji portfelja. Mjera dodatnog opreza u analizi i selekciji upravitelja fonda svakako je upoznavanje sa slučajevima „slavnih" fondova koji su bankrotirali (npr. slučaj *Long Term Capital Management* fonda) ili situacije gdje je fond bio tzv. Ponzi shema (npr. slučaj Bernarda Madoffa) u kojoj je većina investitora financijski oštećena. Brown et al. (2018) ukazuju na važnost analize upravitelja fondova u pogledu veze između njihove osobnosti i stila investiranja.

3.6.2. Pregled upravitelja alternativnih fondova

U tablici 13 nalazi se pregled nekih od najvećih upravitelja hedge fondova i upravljanih ročnica prema imovini i broju različitih strategija fondova pod upravljanjem.

Tablica 13 – Pregled globalnih upravitelja hedge fondova u 2021. godini (u mil. USD)

Naziv	Imovina	Država
Bridgewater Associates	105.700	SAD
Man Group	76.800	UK
Renaissance Technologies	58.000	SAD
Millennium Mgmt.	52.314	SAD
TCI Fund Mgmt.	40.000	UK
D.E. Shaw Group	39.738	SAD
Two Sigma Investments/Advisers	39.550	SAD
Farallon Capital Mgmt.	38.100	SAD
Citadel	37.630	SAD
Davidson Kempner Capital Mgmt.	37.350	SAD

Izvor: (Pionline, 2022)

U tablici 14 navedeni su samo privatni fondovi koji eksplicitno koriste neke od strategija hedge fondova. Određeni upravitelji također vode otvorene fondove putem tradicionalnih pasivnih strategija investiranja (npr. Blackrock). U pogledu globalnih upravitelja hedge fondova, većina se nalazi na području SAD-a što se može smatrati očekivanim obzirom na visoku razvijenost tržišta kapitala.

Tablica 14 - Pregled upravitelja hedge fondova na području Europe (u mil. EUR)

Naziv	Imovina	Država
Man Group	71.700	UK
Marshall Wace	29.000	UK
H2O Asset Management	22.000	UK
The Children's Investment Fund Management	19.600	UK
Capula Investment Management	17.300	UK
CQS	16.600	Švicarska
Aberdeen Standard Investments	15.400	UK
Winton Capital	15.400	UK
RWC Partners	13.000	UK
Algebris Investments	11.700	UK

Izvor: (PREQIN, 2020)

Upravitelji hedge fondova na području Europe nisu značajno manji od američkih pandana prema vrijednosti imovine pod upravljanjem. Takva činjenica također ukazuje na visoku razvijenost europskih financijskih tržišta. Većina upravitelja locirana je u Ujedinjenom Kraljevstvu dok je samo jedan fond iz prvih 10 lociran u Švicarskoj.

Tablica 15 - Pregled globalnih upravitelja fondova ročnica (eng. *managed futures*) u mil. USD

Naziv upravitelja (fond)	Imovina	Država
AlphaSimplex Group (Managed Futures)	6.300	SAD
Graham Capital Mgmt (Tactical Trend A)	6.000	SAD
Transtrend (DTP/Enhanced Risk - USD)	5.500	Nizozemska
Systematica Investments (BlueTrend)	3.600	Švicarska
PIMCO (Trends)	2.300	SAD
Statar Capital (Natural Gas)	2.290	SAD
AQR Capital Mgmt (MV Strategy)	1.203	SAD
Winton Capital Mgmt (Divers Futures)	1.269	UK
Polar Star Mgmt SEZC (Polar Star Ltd)	401	Kajmansko otočje
Man Investments (AHL Alpha)	327	Australija

Izvor: Barclay Managed Funds Report, 4th Quarter 2021

Lokacija fondova upravljanih ročnica je raznolika s time da veći broj upravitelja fondova ima sjedište u SAD-u, no imaju osnovane područne urede po svim većim financijskim centrima svijeta i Europe. Popis navedenih fondova svakako nije isključiv ali je sastavljen primarno iz fondova koji čine sastav BTOP50 indeksa ročnica. Strategije navedenih fondova uglavnom se odnose na strategije praćenja trendova koje su često automatizirane putem kodiranih računalnih algoritama.

U slučaju razmatranja ulaganja u neki od prethodno navedenih inozemnih hedge fondova ili ročnica, investitori imaju mogućnost krenuti od prethodnog pregleda upravitelja fondova, uz korištenje upitnika iz tablice 12.

Tablica 16 - Pregled upravitelja i alternativnih fondova u Republici Hrvatskoj

Naziv	Fond(ovi)	Imovina (u EUR)	Opis
ERSTE asset management	Erste PB1, PB2, PR-AZ-1	231.971.125	Fondovi u najvećoj mjeri izloženi tradicionalnim oblicima ulaganja[19] i namijenjeni profesionalnim investitorima.
Hrvatsko mirovinsko investicijsko društvo	Kapitalni Fond, HMID plus	247.889.101	Fondovi u najvećoj mjeri izloženi tradicionalnim oblicima ulaganja.
Intercapital asset management	Capital Private 1, Conservative Private, Capital Private, Equinox, Hermes, KWSO Capital Flex, Adria Value Fund, Dynamic Allocation, Outfox Macro Income Fund, Total Return	66.096.605	Osnovni i posebni alternativni fondovi s privatnom ponudom.
CGS capital	Alpha, Beta, Delta, Gamma	50.388.151	
Maverick wealth management	Aprivate, MWM 1, MWM 2, Infinity Alpha	33.062.031	MWM 1 i 2 su fondovi čiji se investicijski cilj ostvaruje ulaganjem pretežito u *private equity*, nekretnine, *mezzanine* i ostale kreditne strukture. Fondovi su izloženi pretežito CE-SEE regiji i Hrvatskoj te su namijenjeni investitorima s dugoročnim investicijskim horizontom. Infinity Alpha je hedge fond koji investicijski cilj ostvaruje ulaganjem

[19] Uslijed niske dostupnosti detaljnih podataka o fondu, moguća su odstupanja od navedenih izloženosti fonda

Naziv	Fond(ovi)	Imovina (u EUR)	Opis
			primarno u tzv. *blue chip* dionice na razvijenim tržištima, gdje će jedna od korištenih strategija biti *long-short equity* (https://maverick.hr/).
SQ capital	Anchor, Mooring, Primus	9.428.832	Slavonski ZAIF koji čini najveći udio imovine (96,3 mil. HRK) izložen pretežito tradicionalnim (tj. vlasničkim) oblicima ulaganja.
Inspire investments	Private, Fusion, Slavonski ZIF	8.808.819	Posebni alternativni investicijski fondovi s privatnom ponudom
Feelsgood Capital Partners	Feelsgood	4.452.065	Fond u najvećoj mjeri izložen domaćim i stranim dionicama srednjih i velikih kompanija.
White Bridge asset management	Passive Digital Asset	3.864.418	Prvi hrvatski fond s pasivnim ulaganjem u kriptovalutu Bitcoin
Alternative invest	Turizam 2042, AP2, AP3	2.484.029	Fondovi u najvećoj mjeri izloženi dionicama uz dugoročan horizont ulaganja.
Generali investments	Value	294.737	
ZB invest	ZB Private World	105	
Ukupno	**39**	**658.740.018**	

Izvor: (HANFA, 2022)

Upravitelji fondova prikazani u tablici 16, kao i ukupna vrijednost imovine fondova pod upravljanjem, spadaju u skupinu alternativnih fondova A, C, D, E i F sukladno relevantnom izvještaju HANFA-e[20]. Većina alternativnih fondova u RH ne koristi klasične strategije hedge fondova prikazane u poglavlju 3.1.1. Stil ulaganja menadžera fondova većinom se odnosi na korištenje kombinacije dionica kao instrumenta ulaganja uz manji udio obveznica, izvedenih instrumenata i financijske poluge. Takvi investicijski fondovi nisu namijenjeni širem broju investitora (npr. fizičke osobe), već profesionalnim ulagateljima koji mogu zadovoljiti viši prag minimalne investicije. Broj upravitelja alternativnih fondova na kraju 2020. godine iznosio je 13 uz 42 alternativna fonda čija je ukupna vrijednost imovine iznosila 570,7 mil. EUR. Prvih 5 upravitelja zauzimaju preko 90% ukupne imovine fondova što ukazuje na visoku koncentraciju alocirane imovine u fondove manjeg broja upravitelja.

[20] https://www.hanfa.hr/publikacije/statistika/ (B-12 Neto imovina alternativnih investicijskih fondova)

3.7. Regulacija alternativnih ulaganja

Regulacija alternativnih ulaganja razlikuje se prema lokacijama financijskih tržišta te će se u ovom radu fokus staviti na regulaciju alternativnih fondova na području EU. Globalna kriza koju su financijska tržišta doživjela od 2007. također se djelomično pripisuje industriji hedge fondova u kontekstu slabe transparentnosti, prekomjerne sklonosti riziku upravitelja fondova i nepostojanja jedinstvenog regulatornog okvira. U cilju vraćanja kredibiliteta i stabilnosti cjelokupnoj industriji alternativnih ulaganja, tijela Europske unije izdala su 2011. godine EU Direktivu pod nazivom „*Alternative Investment Fund Manager Directive*" (AIFMD)[21]. Raspon primjene regulative nije ograničen samo na hedge fondove, već se proteže na upravljanje svim fondovima izvan opsega primjene tzv. UCITS[22] IV Direktive koja regulira industriju tradicionalnih investicijskih fondova.

U 2011. godini formirano je i tijelo na razini EU nadležno za nadzor financijskih tržišta vrijednosnica pod nazivom ESMA, *The European Securities and Markets Authority* sa sjedištem u Parizu. ESMA ima tri glavna cilja:

- **zaštita ulagača** – osiguranje da su potrebe korisnika financijskih proizvoda bolje zadovoljene te jačanje njihovih prava kao ulagača i potvrđivanje njihovih odgovornosti,
- **uređena tržišta** – promicanje integriteta, transparentnosti, učinkovitosti i dobrog funkcioniranja financijskih tržišta i snažne tržišne infrastrukture,
- **financijska stabilnost** – jačanje financijskog sustava kako bi on mogao podnositi šokove i posljedice financijskih neravnoteža te poticanje gospodarskog rasta.

AIFMD definira harmonizirani referentni okvir za regulaciju koja se odnosi na ovlaštenje, rad i transparentnost svih upravitelja alternativnih investicijskih fondova. Također, predmetna Direktiva se fokusira na upravitelje alternativnih fondova, dok se poslovanje samih fondova regulira i nadzire od strane nacionalnih supervizorskih tijela. Svaka zemlja članica EU može izdati dodatan zakonski okvir za regulaciju alternativnih fondova na domaćem financijskom tržištu koji naravno treba biti usklađen s glavnim načelima AIFM Direktive. Republika Hrvatska je implementirala predmetnu Direktivu trenutkom ulaska u EU (srpanj 2013. godine).

[21] Direktiva 2011/61/CE

[22] eng. *Undertakings for Collective Investment in Transferable Securities* (UCITS)

Tablica 17 – Pregled načela AIFM Direktive

Predmet regulacije	Opis
Okvir ovlaštenja	• Upravitelji alternativnih investicijskih fondova (AIF) čija vrijednost imovine prelazi prag od 100 mil. EUR trebaju podnijeti zahtjev za posebno odobrenje od nadležnih tijela svoje matične Države Članice. Prag se povećava na 500 mil. EUR ako AIF ne koristi financijsku polugu i ne daje prava isplate investitorima u razdoblju od 5 godina. • Manje strog i opsežan regulatorni i nadzorni okvir za upravitelje AIF-ova čija je vrijednost imovine pod upravljanjem ispod praga od 100 mil. EUR. Niži zahtjevi u pogledu organizacije i transparentnosti. • Upravitelji AIF-ova moraju imati početni minimalni kapital, ovisno o tome djeluju li kao vanjski menadžeri (125.000 EUR) ili interni menadžeri (300.000 EUR). Dodatan iznos, razmjeran imovini pod upravljanjem, dodaje se za pokriće rizika profesionalne odgovornosti. • Ovlaštenje se razlikuje od ovlaštenja nealternativnih upravitelja fondova (UCITS IV). • Pravni domicil fonda i vrsta fonda (otvoreni ili zatvoreni) nisu od značaja.
Marketing	• Ovlašteni upravitelji AIF-ovi mogu oglašavati svoje alternativne fondove i u svojim zemljama i u drugim državama članicama EU-a. Putovnica fonda vrijedi samo za profesionalne investitore, dok je mogućnost proširenja na maloprodajno tržište (eng. *retail market*) diskrecijska odluka svake zemlje.
Organizacija	• Pravila postupanja slična onima utvrđenima po UCITS IV Direktivi. • Zahtjev za usvajanjem politika i organizacije koje su adekvatne za upravljanje standardnim rizicima upravljanja imovinom. • Zahtjev za imenovanje banke depozitara i glavnog brokera s posebnim zahtjevima i obvezama segregacije. • Zahtjev za donošenjem potrebnih mjera za sprječavanje sukoba interesa. • Usklađenost sa specifičnim zahtjevima u pogledu financijske poluge (maksimalna razina navedena u prospektu) i likvidnosti.
Transparentnost	• Obvezno periodično izvješće koje se dostavlja investitorima i nadzornim tijelima, ovisno prema izloženosti riziku. • Imovina će biti pravilno vrednovana od strane neovisnog subjekta i u skladu s domaćim zakonima.

Izvor: Obrada autora prema (Basile, 2016)

Nadležno tijelo za regulaciju alternativnih fondova u RH je Hrvatska agencija za nadzor financijskih usluga (HANFA) dok je rad alternativnih investicijskih fondova (u nastavku: AIF) reguliran Zakonom o alternativnim investicijskim fondovima (NN 16/2013) čije su glavne odredbe:

- Društva za upravljanje alternativnim investicijskim fondovima posluju kao d.o.o. ili d.d. sa sjedištem u Republici Hrvatskoj.
- Odobrenje za rad izdaje se na neodređeno vrijeme.
- Najniži iznos temeljnog kapitala jednak je kao u AIFM Direktivi (125 tis. EUR za vanjske i 300 tis. EUR za unutarnje upravitelje fondova).

HANFA je podzakonskim aktom u obliku Pravilnika o vrstama alternativnih investicijskih fondova (NN 105/2013) dodatno definirala način osnivanja mogućih vrsta alternativnih fondova gdje se izdvajaju otvoreni i zatvoreni AIF-ovi s javnom ponudom te AIF-ovi s privatnom ponudom. Glavna razlika između navedenih vrsta fondova je u tome što se fondovi s javnom ponudom mogu nuditi širem rasponu ulagatelja, dok je kod onih s privatnom ponudom to moguće uglavnom samo profesionalnim ulagateljima. Sukladno Pravilniku, za kvalificiranog ulagatelja se smatra mali ulagatelj koji se obvezuje uplatiti 400 tis. HRK. Također, vrijednost njegove neto imovine mora minimalno iznositi 3 mil. HRK, te uz to ulagatelj mora imati dovoljno iskustva i znanja razumjeti rizike koji proizlaze iz ulaganja u AIF-ove.

4. SEKTOR OSIGURANJA I REGULATIVA SOLVENTNOST II

U ovom dijelu rada analizirati će se struktura ulaganja osiguratelja na tržištu RH te utvrditi efekti regulative na ovaj poslovni segment kao i pregled glavnih obilježja Solventnosti II kao važećeg regulatornog režima.

Društva za osiguranje dio su financijskog sustava i važne financijske institucije odnosno institucionalni investitori. Ekonomski značaj industrije osiguranja leži u njezinoj jedinstvenoj ulozi preuzimatelja osobnih i poslovnih rizika (Tschampion et al., 2007). Važnost društava za osiguranje u financijskom sustavu može se prikazati udjelom aktive društava za osiguranje u aktivi svih financijskih institucija. Akumulirana imovina osiguratelja jamči ispunjenje tekućih i budućih obveza (HUO, 2021).

Tablica 18 – Udio imovine društava za osiguranje u financijskom sustavu RH (u mil. HRK)

Financijski posrednik	Imovina u 2021; prosinac	Udio
Poslovne banke	504.074	67,37%
Obvezni mirovinski fondovi	132.984	17,77%
Društva za osiguranje	48.398	6,47%
UCITS investicijski fondovi	21.512	2,88%
Leasing društva	19.938	2,66%
Dobrovoljni mirovinski fondovi	7.805	1,04%
Stambene štedionice	4.954	0,66%
Alternativni investicijski fondovi	4.937	0,66%
Mirovinsko osiguravajuće društvo	2.073	0,28%
Investicijski fondovi po posebnim zakonima	1.148	0,15%
Faktoring društva	366	0,05%
SVEUKUPNO	**748.189**	**100,00%**

Izvor: Obrada autora prema HNB, HANFA (podaci za prosinac 2021.)

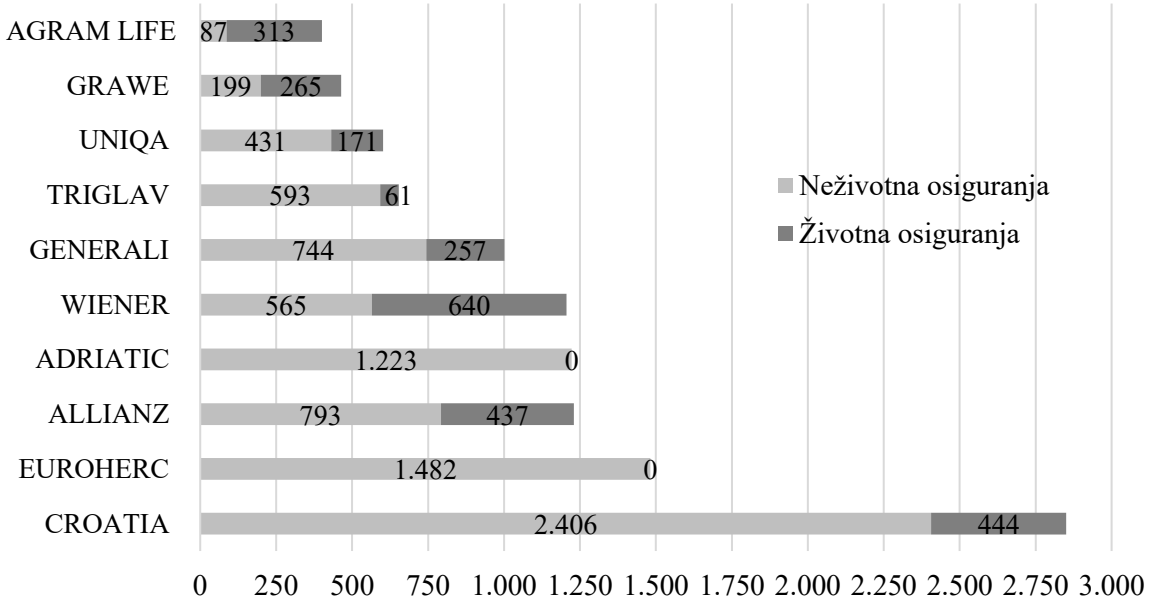
Hrvatski financijski sustav je tradicionalno bankocentričan i karakterizira ga dominantna pozicija banaka sa preko 67% udjela u ukupnoj aktivi svih financijskih institucija. Društva za osiguranje značajni su institucionalni investitori u financijskom sustavu Republike Hrvatske. Udio njihove imovine u ukupnoj imovini financijskog sustava u 2021. iznosio je 6,5% što osiguratelje stavlja na treće mjesto, iza banaka i obveznih mirovinskih fondova. Imovina osiguratelja u financijskom sektoru kontinuirano raste. Aktiva hrvatskih osiguratelja u 2007. godini iznosila je 22,4 mlrd. kn ili 5,1% ukupne imovine financijskih institucija, dok je na kraju 2021. godine iznosila 48,4 mlrd. kn (HUO, 2022).

4.1. Pregled i struktura investicijskog portfelja društava za osiguranje

Na kraju 2021. godine na tržištu osiguranja poslovalo je ukupno 15 društava za osiguranje sa sjedištem u Republici Hrvatskoj. Od ukupnog broja društava, 2 ih je obavljalo isključivo poslove životnih osiguranja, 4 društava isključivo poslove neživotnih osiguranja, dok je preostalih 9 društava za osiguranje obavljalo poslove životnih i neživotnih osiguranja te se smatraju kompozitnim društvima (HUO, 2022).

Ukupna premija osiguratelja na kraju 2021. godine iznosila je 11,7 mlrd. kn od čega se na neživotna osiguranja odnosilo 8,8 mlrd. kn (75,3%), dok su životna osiguranja ostvarila ukupno 2,9 mlrd. kn premije (24,7%). Najzastupljenija vrsta osiguranja u neživotnim osiguranjima i dalje je osiguranje od odgovornosti za upotrebu motornih vozila sa zaračunatom bruto premijom od 3,3 mlrd. kn. Najveći udio na hrvatskom tržištu osiguranja zauzima Croatia osiguranje sa 2,85 mlrd. kn premije, što čini 24,3% tržišta. Prvih 5 osiguravajućih društava sa svojom premijom predstavljaju 68% tržišta.

Graf 15 – Pregled prvih 10 osiguratelja na RH tržištu prema zaračunatoj premiji na kraju 2021. godine (u mil. HRK)

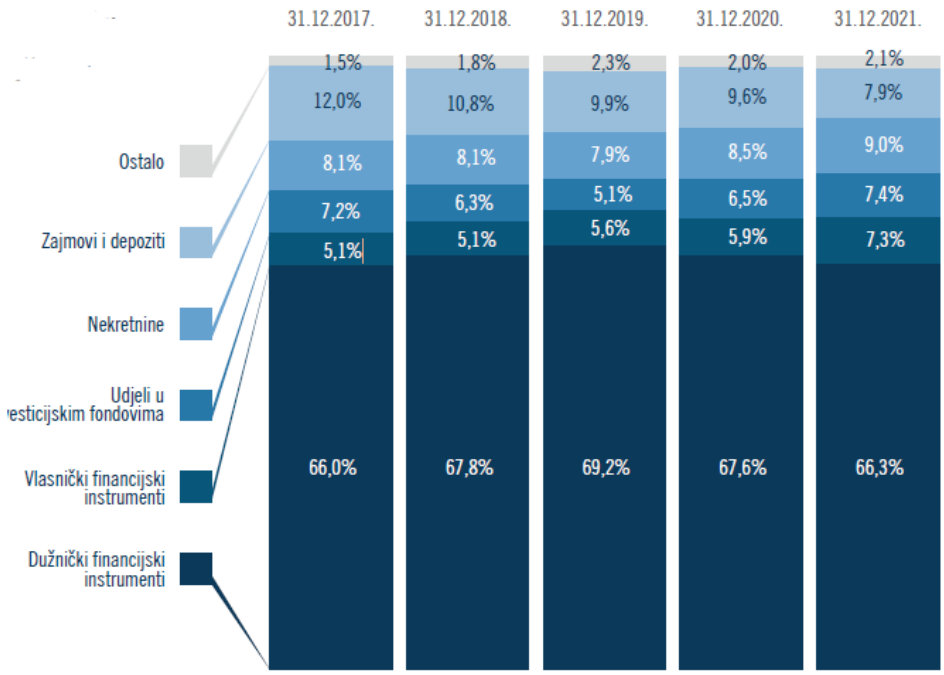


Izvor: izrada autora prema podacima Hrvatskog ureda za osiguranje (HUO, 2022)

4.1.1. Ulaganja društava za osiguranje na tržištu RH

Ulaganja su ključna stavka imovine društava za osiguranje s udjelom od 79,0% u ukupnoj imovini osiguratelja i iznosom od 37.790 mil. kn na kraju 2021. godine.. Ulaganja društava za osiguranje regulatorno su uređena, a prema novom regulatornom okviru Solventnosti II, rizična izloženost ulaganja uključena je u izračun kapitalnih zahtjeva. Drugim riječima, osiguratelji prema novoj regulativi mogu ulagati u bilo koji oblik ulaganja, no ovisno o njegovoj rizičnosti, dužni su rezervirati određenu visinu vlastitog kapitala za pokriće potencijalnih gubitaka odnosno negativnih prinosa (HUO, 2022).

Društva za osiguranje su često konzervativni investitori dugog vremenskog horizonta ulaganja i veliki dio imovine ulažu u državne obveznice (Anđelinović et al., 2018) koje imaju percepciju nisko rizičnog i nevolatilnog oblika ulaganja. Iz tog razloga, u strukturi ulaganja najveći udio čine upravo takva ulaganja.



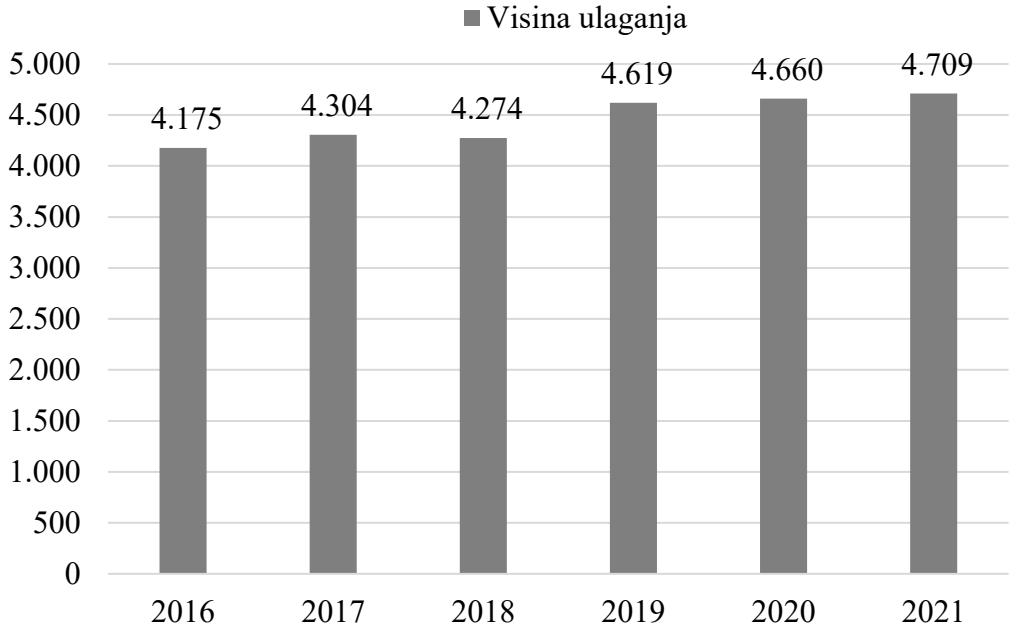
Slika 4 – Struktura ulaganja društava za osiguranje (2017.-2021. godina)

Izvor: HANFA

Na slici 4 vidljiv je pregled relativne strukture ulaganja društava za osiguranje u periodu 2017.-2021. godine. Udio dužničkih financijskih instrumenata, gdje pretežito spadaju državne i korporativne obveznice, izrazito je dominantan u odnosu na ostale oblike ulaganja od kojih se još ističu vlasnički instrumenti (tj. dionice), udjeli u investicijskom fondovima, nekretnine, te zajmovi i depoziti.

Vremenski period koji se promatra u rasponu je od 2016. do 2021. godine koliko je regulativa Solventnost II na snazi. Izvor podataka bila je javno dostupna baza podataka na stranicama[23] Europskog nadzornog tijela za osiguranje i strukovno mirovinsko osiguranje (u nastavku: EIOPA[24]).

Graf 16 - Visina ulaganja[25] društava za osiguranje na tržištu RH (u mil. EUR)



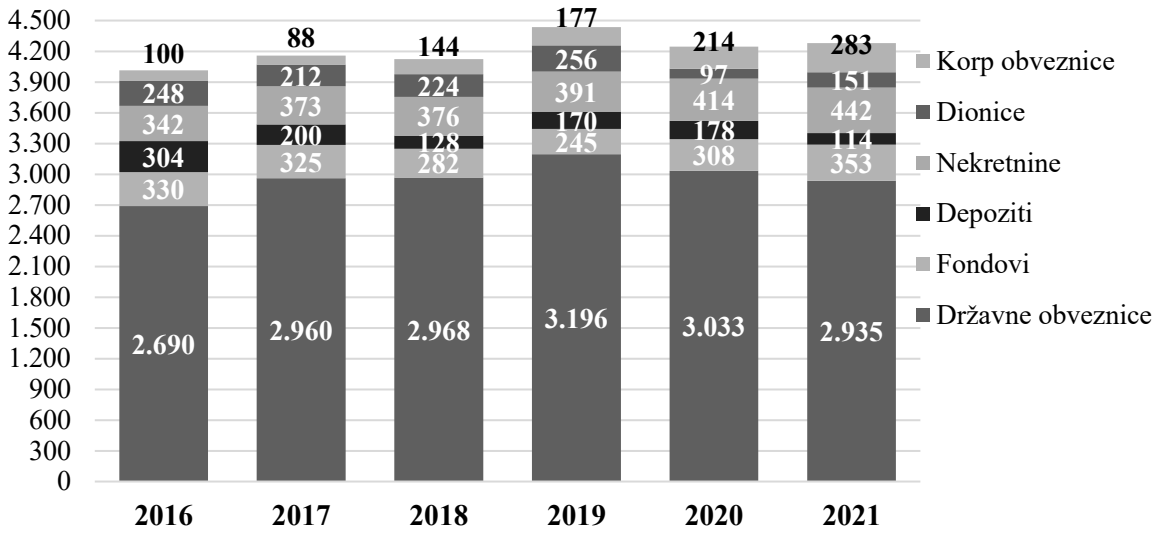
Izvor: izrada autora prema podacima EIOPA-e

Visina ulaganja društava za osiguranje u RH krajem 2021. iznosila je 4,7 mlrd. EUR te se obujam ulaganja kontinuirano povećava od uvođenja regulative Solventnost II. Hrvatski osiguratelji po visini ulaganja nalaze se na 23. mjestu od ukupno 30 zemalja EU.

U pogledu strukture oblika ulaganja u promatranom razdoblju, najveći udio zauzimaju državne obveznice. Njihov udio na kraju 2021. godine iznosio je preko 2,9 mlrd. EUR što predstavlja gotovo 60% ukupne vrijednosti ulaganja. S druge strane, udio dionica postepeno se smanjivao sa 6% na kraju 2016. do svega 3% na kraju 2021. godine. Jedna od posljedica takvog trenda svakako je visoka kapitalna penalizacija vlasničkih ulaganja[26] kao i pojava pandemije COVID-19 koja je negativno utjecala na dionička tržišta. Visok udio državnih obveznica posljedica je i povoljnog kapitalnog tretmana u okviru Solventnosti II obzirom da se državne obveznice regulatorno tretiraju kao niskorizičan oblik ulaganja.

[23] Dostupno na: https://www.eiopa.europa.eu/tools-and-data/statistics-and-risk-dashboards/insurance-statistics_en
[24] eng. *The European Insurance and Occupational Pensions Authority (EIOPA)*
[25] Bez ulaganja gdje investicijski rizik preuzimaju osiguranici (tzv. *unit linked* ulaganja)
[26] Vidjeti poglavlje 4.2.3. za detalje o rizičnom tretmanu pojedinog oblika ulaganja po Solventnosti II

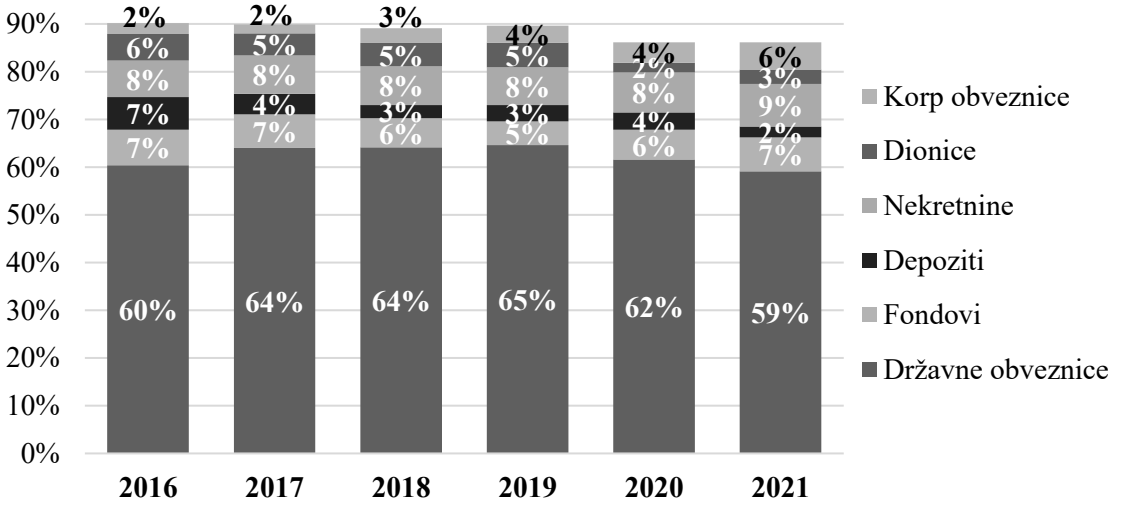
Graf 17 - Apsolutna struktura ulaganja RH osiguratelja u periodu 2016.-2021. (u mil. EUR)



Izvor: izrada autora prema podacima EIOPA-e

Pregled relativne strukture omogućava praćenje promjena udjela oblika ulaganja. Osim državnih obveznica i dionica, ulaganja u nekretnine održala su se na jednakoj visini tijekom dosadašnjeg perioda nove regulative, unatoč tome što nekretnine kao manje likvidna imovina imaju stroži kapitalni tretman. Takva pojava može se objasniti kroz uzak spektar mogućih oblika ulaganja na financijskom tržištu RH i činjenice da su osiguratelji tradicionalno pasivno konzervativni investitori. Postepeno se smanjivao i udio depozita na što je utjecalo okruženje niskih kamatnih stopa gdje su kao novčani oblik ulaganja izgubili svoj investicijski potencijal.

Graf 18 - Relativna struktura oblika ulaganja u periodu 2016.- 2021.[27] godine



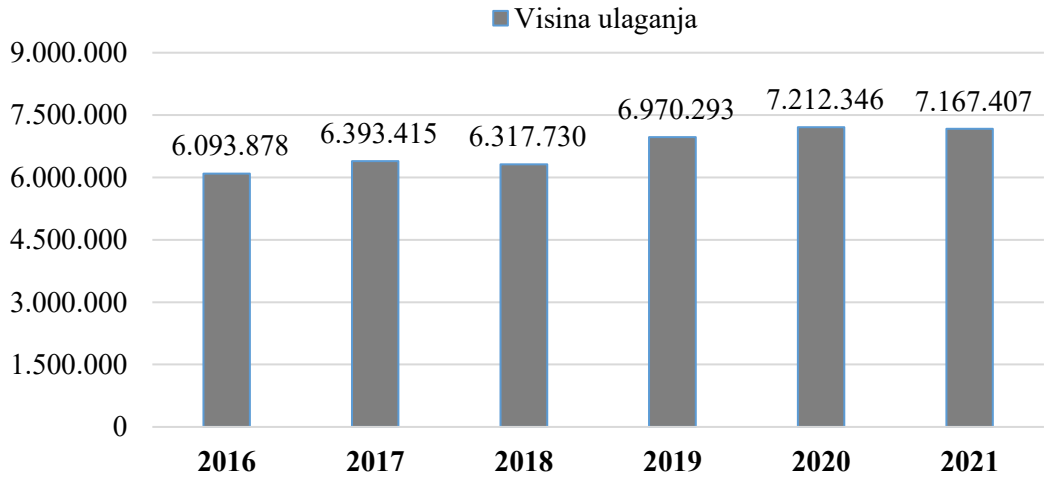
Izvor: izrada autora prema podacima EIOPA-e

[27] Uslijed preglednosti, na grafu nisu prikazani udjeli u povezanim društvima i krediti/hipoteke

4.1.2. Struktura ulaganja stranih osiguratelja u EU

Strani osiguratelji, posebice društva za osiguranje razvijenih zemalja zapadne Europe suočeni su s problemom okruženja niskih kamatnih stopa u analiziranom razdoblju mnogo dulje od osiguratelja na RH tržištu. Njihova veličina i razvijenost financijskih tržišta omogućavaju im širi izbor strategija ulaganja kojim mogu pozitivno utjecati na rezultate investicijskog segmenta.

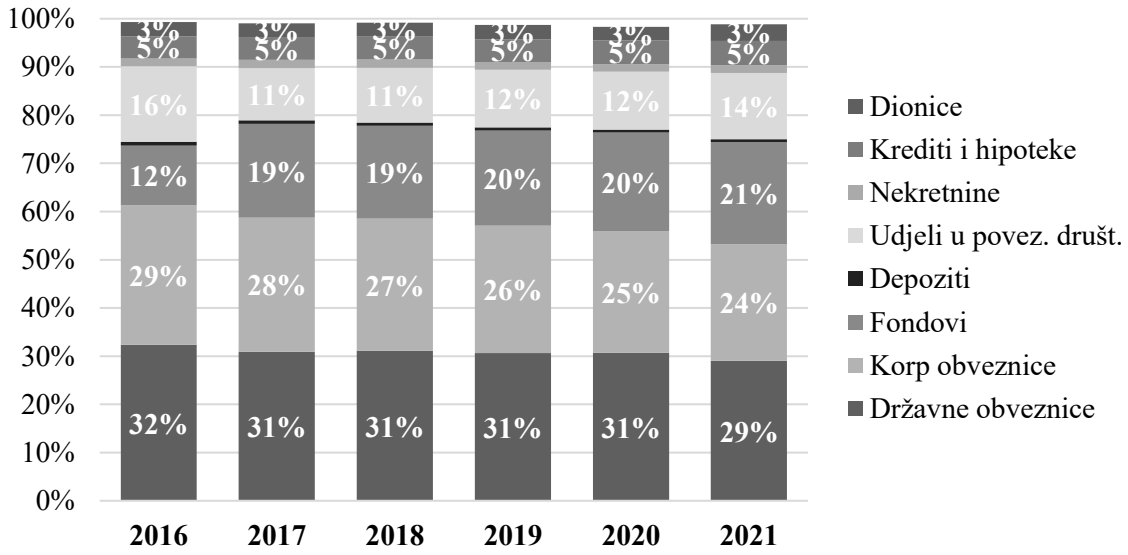
Graf 19 - Visina ulaganja[28] društava za osiguranje zemalja EU (u mil. EUR)



Izvor: izrada autora prema podacima EIOPA-e

Visina ulaganja društava za osiguranje u zemljama EU na kraju 2021. godine iznosila je 7,2 bilijuna EUR gdje je obujam ulaganja također pratio pozitivan trend rasta.

Graf 20 - Relativna struktura oblika ulaganja zemalja EU



Izvor: izrada autora prema podacima EIOPA-e

[28] Bez ulaganja gdje investicijski rizik preuzimaju osiguranici (tzv. *unit linked* ulaganja), RH i UK osiguratelja

Graf 20 ukazuje na značajne razlike u strukturi oblika ulaganja osiguratelja na RH tržištu i onih iz zemalja EU. U slučaju EU osiguratelja, državne obveznice i dalje imaju najveći udio (29%), no isti je znatno manji nego kod osiguratelja na tržištu RH (59%). Isto tako, udio korporativnih obveznica vrlo je sličan udjelu državnih, s time da navedeni oblici ulaganja čine preko 50% udjela u ukupnim ulaganjima. Slijedi ih udio fondova koji je također visok te iznosi 21% nakon čega se još izdvajaju udjeli u povezanim društvima (14%) koji čine značajan dio ulaganja obzirom da su mnogi EU osiguratelji velike osiguratelјne grupe. Zanimljivo je da udio ulaganja u nekretnine u portfeljima EU osiguratelja iznosi svega 2% dok je na RH tržištu na razini 9%. Dionice također imaju nizak udio u portfelju ulaganja koji iznosi u prosjeku oko 3%. Udio depozita je zanemariv obzirom na analizirani period okruženja niskih kamatnih što je učinilo predmetni oblik neatraktivnom investicijom.

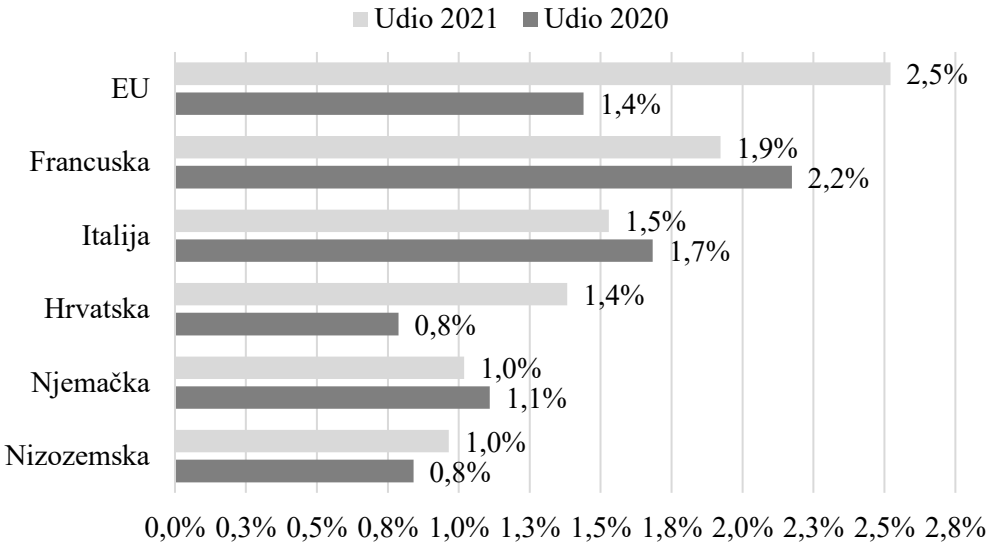
Analizom i usporedbom strukture ulaganja RH i EU osiguratelja vidljiva je značajna razlika kod udjela državnih obveznica koja proizlazi iz činjenice da su prinosi na obveznice EU zemalja niži od prinosa državnih obveznica RH u analiziranom razdoblju. Iz tog razloga, EU osiguratelji značajan dio sredstava ulažu u imovinski oblik korporativnih obveznica koji predstavlja primaran izbor u cilju ostvarivanja viših prinosa.

Značajnu kategoriju čine investicijski fondovi čiji se udio značajno povećao u posljednje dvije godine. Obzirom na svoju mješovitu strukturu i geografsku nepristranost, EU osiguratelji ih koriste kao diversifikatore u smislu oblika i lokacije ulaganja (globalna, domaća tržišta).

Detaljniji uvid u strukturu (pod)oblika ulaganja omogućen je odredbama regulative Solventnost II prema kojima su osiguratelji dužni kvartalno izvještavati o strukturi i vrijednosti svoje investicijske imovine. Podaci o poslovanju osiguratelja na razini EU dostupni su na stranicama EIOPA-a gdje je moguće dobiti uvid u razne vrste podataka (bilanca, kapital, premije, štete, troškovi, ulaganja i dr.). U dijelu podataka o ulaganjima, regulativa nalaže da se svaki pojedini oblik imovine osiguratelja na razini instrumenta klasificira prema CIC[29] kodovima što omogućava detaljan uvid u investicijske pozicije. Prema navedenoj klasifikaciji, moguće je izdvojiti ulaganja u investicijski fondove koji se svrstavaju u fondove alternativnih oblika ulaganja (npr. infrastrukturni fondovi, *private equity* fondovi, alternativni fondovi i dr.). Takvi fondovi najčešće imaju CIC kodove 46-49 te je na grafu 21 prikazan njihov udio u ukupnim ulaganjima odnosno investicijskom portfelju osiguratelja na kraju 2021. godine.

[29] eng. *Complementary Identification Code*

Graf 21 – Udio alternativnih fondova[30] u investicijskom portfelju EU osiguratelja na kraju 2021. godine



Izvor: izrada autora prema podacima EIOPA-e

U pogledu disperzije udjela alternativnih fondova, vidljivo je da raspon udjela ne varira značajno između promatranih zemalja. Najveći udio (1,9%) predmetnih oblika fondova, od nacionalnih tržišta, imali su francuski osiguratelji dok je najniži udio (1,0%) utvrđen na nizozemskom tržištu. Obzirom na nizak udio dionica i alternativnih fondova, evidentan je prostor za rast udjela ovih oblika u cilju dodatne diversifikacije investicijskog portfelja.

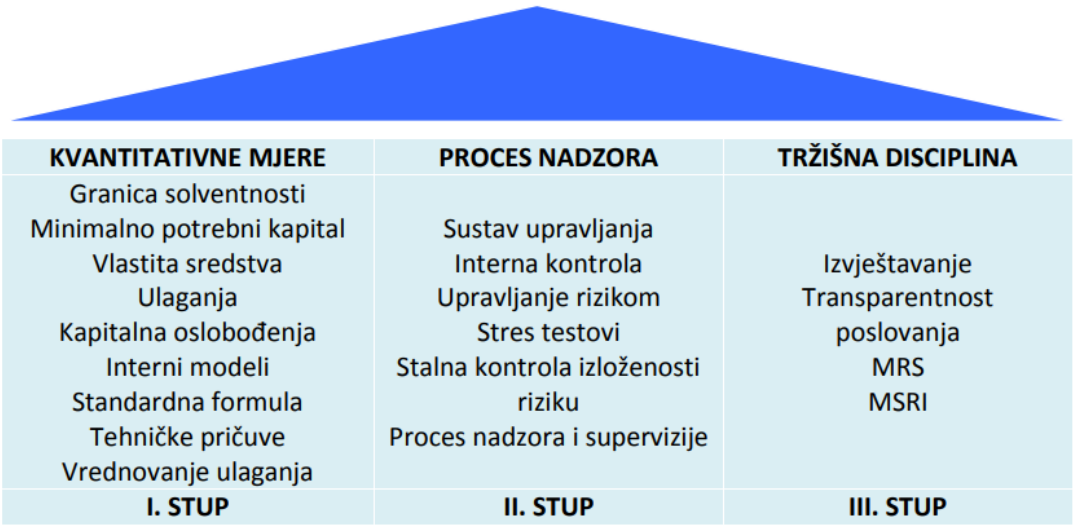
4.2. Glavna obilježja regulative Solventnost II

U ovom dijelu obrazlažu se glavna obilježja regulative Solventnost II koji su utjecali na poslovanje osiguratelja u području ulaganja, izloženosti rizicima i solventnosti. U cilju boljeg razumijevanja međuodnosa odabira oblika ulaganja i utjecaja na solventnost i rizik investicijskog portfelja, u nastavku je definiran pojam ekonomskog kapitala i solventnosti, kao i vrste investicijskih rizika.

Osigurateljna regulativa Solventnost II stupila je na snagu 1.1.2016. i zamijenila dotadašnji regulatorni režim Solventnost I. Novi zakonski okvir donio je radikalne promjene u regulaciji industrije osiguranja, posebno u području upravljanja rizicima radi čega se često spominje da se radi o regulativi baziranoj na rizicima. Metodološki pristup izračuna solventnosti i zahtjevi za kapitalom nisu više linearno povezani s volumenom premija i tehničkih rezervi, već s

[30] Odnosi se na CIC kodove 46 (*Alternative funds*), 47 (*Private equity funds*) i 48 (*Infrastructure funds*)

razinom izloženosti pojedinim vrstama rizika. Osnovni cilj nove regulative Solventnost II bio je potpuna harmonizacija supervizorskih sustava zemalja članica Europske Unije. Jedno od glavnih obilježja smatra se visoka razina kompleksnosti koja nije uvijek opravdana u svrhu postizanja željenih rezultata (Eling, 2015). Radi lakšeg poimanja kompleksnosti i opsega regulative, odredbe i zahtjevi često se prikazuju preko homogena 3 stupa (eng. *pillars*) koji su vidljivi na slici 5.



Slika 5 – Podjela regulative Solventnost II na 3 stupa

Izvor: CEA, Solvency II, Introductory Guide

Slična struktura bila je dizajnirana i tijekom stvaranja bankarskog standarda Basela II koji se može smatrati pandanom Solventnosti II. U okviru navedena tri stupa, isti pokrivaju sljedeća područja *(Doff, 2011)*:

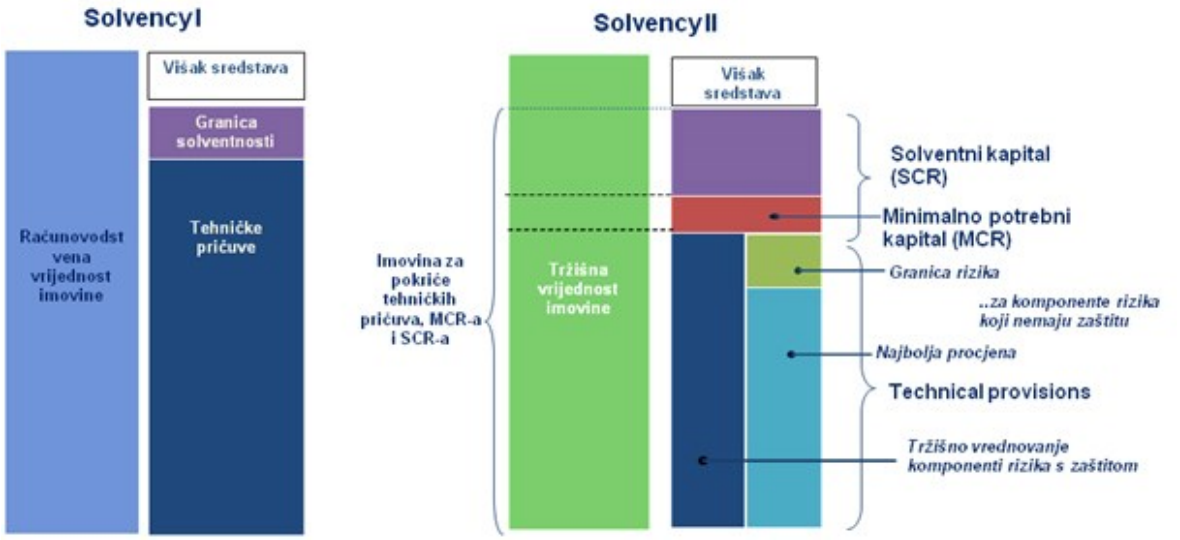
- **Prvi stup – kvantitativne mjere i zahtjevi.** Definira vrednovanje imovine i obveza, izračun tehničkih pričuva (eng. *Best estimate*), klasifikaciju vlastitih sredstava odnosno kapitala, granicu solventnosti (tj. potreban solventni kapital) te minimalni potrebni kapital. U suštini, zahtjevi prvog stupa čine temelj regulative Solventnost II, te su većinom kvantitativne prirode.

- **Drugi stup – kvalitativni zahtjevi i mjere upravljanja rizicima.** Ovaj stup podrazumijeva zahtjeve vezane uz kvalitativne elemente koji se odnose na: sustav upravljanja rizicima, interne kontrole, vlastitu procjenu rizika i solventnosti te proces nadzora i supervizije. Prema ovom stupu, nacionalni regulator osigurateljnog sektora trebao bi imati kompletan i sveobuhvatan pregled svih rizika i tehnika upravljanja

rizicima koje je društvo za osiguranje implementiralo u svoj poslovni model. Inherentni princip ovog stupa je da su društva za osiguranje samostalno odgovorna za upravljanje rizicima i osiguranje adekvatne razine kapitala koja je razmjerna izloženosti riziku.

- **Treći stup - Tržišna disciplina i transparentnost.** Treći stup uključuje zahtjeve za standardizirano tržišno postupanje u pogledu transparentnosti poslovanja, javno objavljivanje i regulatorno izvještavanje kvantitativnih i kvalitativnih informacija. Zahtjevi trećeg stupa omogućavaju svim tržišnim sudionicima uvid u informacije o poslovanju i rizičnom profilu društava za osiguranje, a što je javno dostupno u godišnjem Izvješću o solventnosti i financijskom stanju (tzv. SFCR izvješće).

Na slici 6 nalazi se prikaz glavnih razlika između regulative Solventnost I i II u pogledu računovodstvenih aspekata odnosno vrednovanja imovine i obveza. Vidljivo je kako se po Solventnosti I imovina vrednovala prema računovodstvenoj vrijednosti dok se kod Solventnosti II ista vrednuje po tržišnoj vrijednosti.



Slika 6 – Usporedba regulative Solventnost I i II na primjeru računovodstvenih aspekata

Izvor: Hrvatski ured za osiguranje (HUO)

4.2.1. Pojmovno određenje ekonomskog i solventnog kapitala

Ekonomski kapital u svakom društvu za osiguranje predstavlja primarni mehanizam zaštite od rizika. Osiguratelji rezerviraju kapital s ciljem apsorbiranja neočekivanih gubitaka uzrokovanih realizacijom rizika. Također, regulator zahtijeva od društava da održavaju potrebnu razinu kapitala u svrhu zaštite osiguranika i očuvanja stabilnosti financijskog sustava (Doff, 2011).

4.2.1.1 Potreban solventni kapital

Potreban solventni kapital (dalje u tekstu: SCR[31]) jedan je od glavnih mehanizama regulative Solventnost II koji služi praćenju solventne pozicije društava za osiguranje. Drugim riječima, solventni kapital je ujedno i razina kapitala koja u jednom broju predstavlja ukupnu izloženost svim preuzetim rizicima. Regulator osigurateljnog tržišta zahtijeva da društva za osiguranje osiguravaju i održavaju razinu ekonomskog kapitala[32] jednaku ili iznad razine potrebnog solventnog kapitala kako bi njihov omjer uvijek mogao biti minimalno 1 (tj. 100%). U protivnom, smatra se da osiguratelj nije u potpunosti solventan i regulator mu može nametnuti mjere s ciljem oporavka solventnosti iznad regulatorno dozvoljenog minimuma.

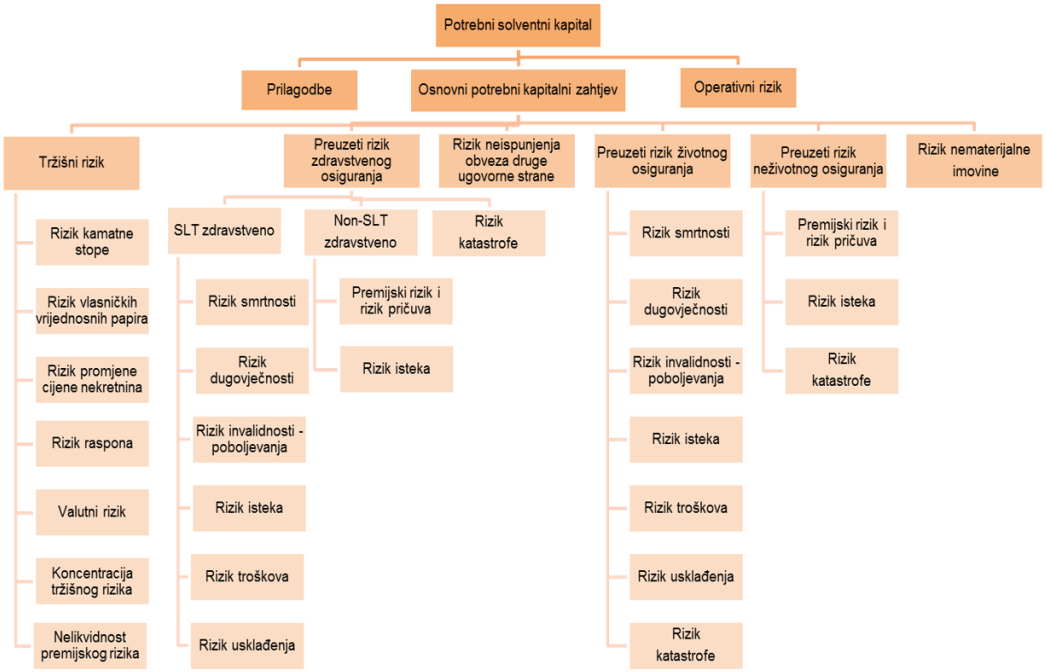
SCR je moguće izračunati pomoću nekoliko metodoloških pristupa. Društva za osiguranje najčešće koriste model standardne formule koji je propisan od strane EIOPA-e i dostupan svim društvima. Pored standardnog modela, osiguratelji mogu koristiti djelomični interni model (kombinacija internog i standardnog), te puni interni model prilagođen specifičnom rizičnom profilu osiguratelja. Izrada i implementacija predmetnih modela zahtijeva znatno više troškove od primjene standardnog modela uslijed čega se veliki broj društava na kraju odlučuje upravo za potonji.

Standardni model uključuje glavne vrste rizika kojima su izložena društva za osiguranje i temelji se na faktorskom i scenarijskom pristupu. Faktorski pristup bazira se na rizičnim faktorima koji se najčešće apliciraju na fer vrijednost imovine ili obveza za koju se računa kapitalni zahtjev. Scenarijski pristup pretpostavlja simulaciju određenog scenarija u kojem dolazi do izravnog gubitka kapitala. Razlika imovine i obveza prije i poslije aplikacije rizičnog faktora odnosno scenarija predstavlja kapitalni zahtjev. Svaka kategorija rizika ima određene podvrste čiji se kapitalni zahtjevi agregiraju uz predefiniranu korelaciju u cilju izračuna ukupnog potrebnog solventnog kapitala. Spomenuti izračuni su tehnički kompleksni dok je kalibracija standardnog modela bazirana na rizičnom profilu prosječnog europskog društva za osiguranje.

Unatoč složenosti izračuna, posebnost i značaj potrebnog solventnog kapitala je u tome što se izloženost svim rizicima kvantificira preko jednog broja koji predstavlja rizičnu vrijednost (eng. *Value at Risk*) uz razinu pouzdanosti od 99,5% i vremenski horizont od 1 godine. Takva

[31] eng. *solvency capital requirement (SCR)*
[32] U računovodstvenom smislu se kapital smatra razlikom imovine i obveza

kalibracija visine rizične vrijednosti, statistički gledano predstavlja najgori mogući gubitak koji se može realizirati jednom u 200 godina.



Slika 7 – Standardni model izračuna potrebnog solventnog kapitala

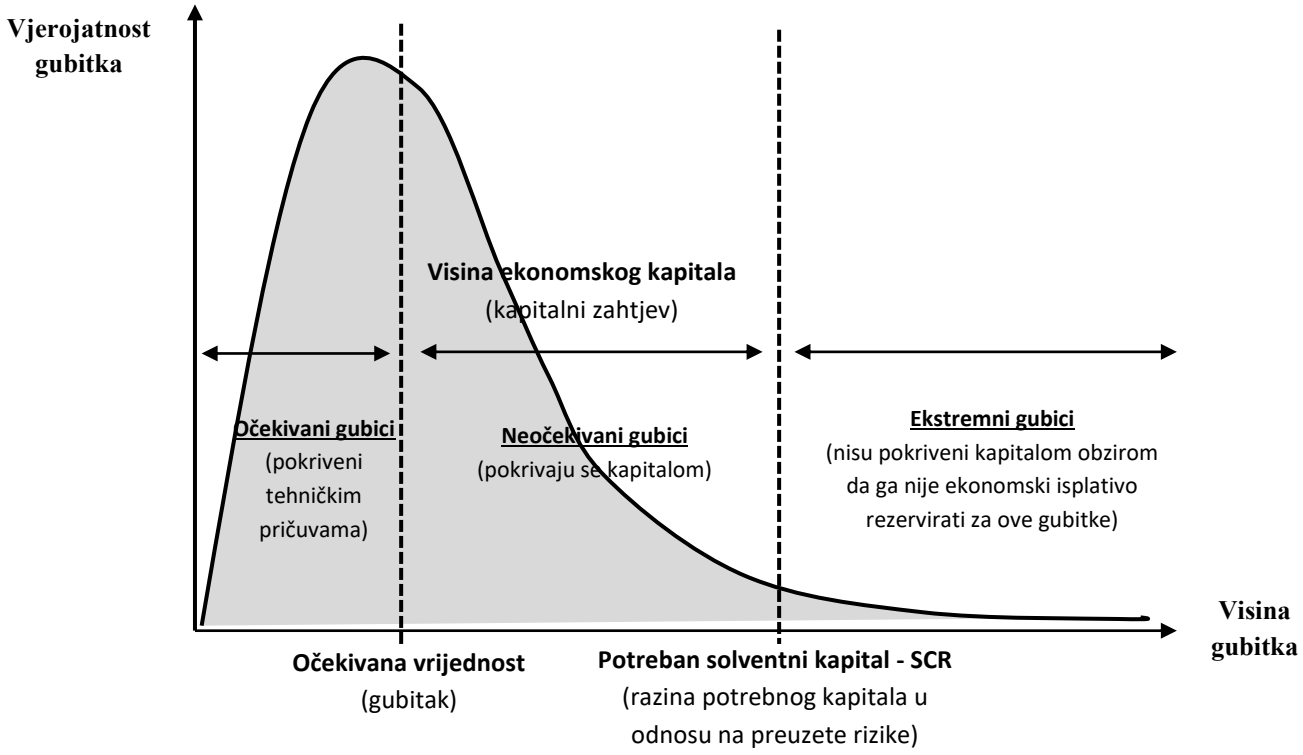
Izvor: EK, QIS5 Technical Specifications

Minimalni potrebni kapital (eng. *minimum capital requirement* – MCR) predstavlja apsolutnu minimalnu razinu kapitala koju bi društva za osiguranje morala održavati barem za pokriće rizika iz osiguratelje djelatnosti. Izračun minimalnog kapitala znatno je manje složen te se kao ulazni podaci primarno koriste tehničke pričuve i premije osiguranja. Ukoliko bi kapital osiguratelja pao ispod razine tzv. MCR-a, tada bi osiguranici bili izloženi neprihvatljivoj razini rizika što bi zahtijevalo snažnu i rigoroznu intervenciju regulatora. Raspon kretanja visine minimalno potrebnog kapitala ograničen je visinom SCR-a.

4.2.1.2 Kapitalni zahtjevi za preuzete rizike

Kapitalni zahtjevi predstavljaju visinu ekonomskog kapitala koju treba rezervirati kako bi se mogla pokriti izloženost pojedinoj vrsti rizika. U tehničkom smislu, njihova visina također predstavlja rizičnu vrijednost istih karakteristika kao potrebni solventni kapital. Drugim riječima, kapitalni zahtjev predstavlja potencijalnu razinu neočekivanih gubitaka koji se mogu realizirati na osnovi preuzetih rizika, a pokrivaju se vlastitim kapitalom. Na grafu 22 je prikazana grafička reprezentacija ekonomskog i potrebnog solventnog kapitala.

Graf 22 – Grafički prikaz koncepta ekonomskog kapitala, solventnosti i kapitalnih zahtjeva



Izvor: izrada autora

Graf 22 predstavlja distribuciju gubitaka koji mogu proizaći iz preuzetih rizika društava za osiguranje. Najčešći gubici zapravo se odnose na štete iz osiguranja koje se može okarakterizirati kao očekivane gubitke obzirom da su već uključeni u premije osiguranja. Takvi gubici su po svojoj prosječnoj apsolutnoj vrijednosti prihvatljivi za osiguratelja i pokrivaju se tehničkim pričuvama. Rizik za osiguratelja predstavljaju neočekivani gubici koji se trebaju pokriti iz vlastitog kapitala, a čija je visina veća od očekivanih gubitaka. Najveću apsolutnu vrijednost imaju ekstremni gubici čija je vrijednost viša i od potrebnog solventnog kapitala. Rezervacija kapitala za ovakve gubitke nije ekonomski isplativa radi visokog oportunitetnog troška.

4.2.2. Vrste i regulacija tržišnih rizika

Osiguratelji kao institucionalni investitori ulažu značajan dio svoje imovine na financijskim tržištima. Iz tog razloga, tržišni rizik se smatra, uz rizik osiguranja, najznačajnijom vrstom rizika za osiguratelje. Definira se kao rizik pada vrijednosti imovine uslijed promjene tržišnih varijabli, poput kamatnih stopa, cijene dionica, nekretnina, deviznog tečaja i dr. (Doff, 2011).

U okviru investicijske aktivnosti osiguratelja, glavne vrste tržišnog rizika čine kamatni rizik, rizik vlasničkih vrijednosnih papira (eng. *equity risk*), rizik promjene cijene nekretnina, valutni

rizik te rizik kreditnih raspona (eng. *credit spread risk*). Ovakvu podjelu slijedi i regulatorni okvir uz dodatak rizika tržišne koncentracije koji se odnosi na prekomjernu izloženost financijskim instrumentima iste poslovne grupacije.

Tablica 19 - Definicije vrsta tržišnog rizika

Vrsta tržišnog rizika	Definicija (opis)
Kamatni rizik	Rizik pada vrijednosti uslijed promjene kamatnih stopa. Usklađivanje imovine i obveza je od posebne važnosti kod ovog rizika obzirom da kamatne stope imaju utjecaj na obje strane bilance osiguratelja.
Rizik vlasničkih vrijednosnih papira	Rizik pada vrijednosti uslijed promjene u cijenama vlasničkih instrumenata.
Rizik nekretnina	Rizik pada vrijednosti uslijed promjena cijena nekretnina.
Valutni rizik	Rizik pada vrijednosti uslijed promjena u valutnim tečajevima.
Rizik kreditnih raspona	Rizik pada vrijednosti uslijed promjene kreditnih raspona. Kreditni raspon je dodatno zahtijevani prinos iznad (nerizičnog) prinosa državnih obveznica radi veće rizičnosti korporativnih obveznica.
Rizik tržišne koncentracije	Rizik značajnog gubitka uslijed visoke koncentracije investiranih sredstava u suprotne strane koje pripadaju istoj poslovnoj grupaciji

Izvor: Obrada autora prema (Delegirana Uredba EK 2015/35)

Stupanjem na snagu nove regulative, tržišni rizici dobili su na prominentnosti u kontekstu praćenja izloženosti i većeg fokusa u kvalitetnoj provedbi upravljanja usklađenosti imovinom i obvezama. To se ponajviše odnosi na ročnu, valutnu i kamatnu (ne)usklađenost gdje u slučaju većih diskrepancija može doći do značajne penalizacije dodatnim kapitalnim zahtjevima.

4.2.3. Utjecaj kapitalnih zahtjeva na odabir oblika ulaganja

Jedna od značajnijih promjena koje su uvedene regulativom Solventnost II, a koje se odnose na segment ulaganja društava za osiguranje, bila je ukidanje rigidnih limita na dozvoljene oblike ulaganja koje su osiguratelji morali poštivati u procesu investiranja. Drugim riječima, nova regulacija omogućava društvima investiranje u sve raspoložive oblike ulaganja, no s druge strane, za svaku investiciju potrebno je rezervirati određenu visinu vlastitog kapitala koja ovisi o rizičnosti oblika ulaganja. Primjerice, državne obveznice smatraju se znatno manje rizičnima nego dionice radi čega ulaganje u iste ne zahtijeva izdvajanje visoke razine vlastitog kapitala za pokriće eventualnih gubitaka.

Bitno je istaknuti da osiguratelji danas imaju mogućnost neograničeno ulagati u bilo koji oblik imovine (obveznice, dionice, nekretnine, alternativne oblike ulaganja i dr.) dokle god imaju dovoljno vlastitog kapitala za pokriće potencijalnih gubitaka takvog ulaganja.

Ukidanje striktnih limita na dozvoljene oblike ulaganja proširilo je spektar odabira oblika ulaganja koja osiguratelji mogu uključiti u svoj investicijski portfelj. Takav pristup pozitivno doprinosi razvoju financijskih tržišta, no s druge strane zahtijeva veću razinu fokusa i ekspertize u pogledu rizika koji mogu proizaći iz manje zastupljenih oblika ulaganja. Kouwenberg (2018) izvodi optimalnu alokaciju imovine osiguratelja u kojoj se minimiziraju kapitalni zahtjevi za tržišne rizike uz uvjet ciljanog prinosa na vlastita sredstva prema Solventnosti II.

U cilju kvalitetnog razumijevanja međuzavisnosti kapitalnih zahtjeva i oblika ulaganja, tablica 20 detaljnije pojašnjava međuzavisnost oblika ulaganja i pojavu tržišnog rizika.

Tablica 20 - Međuzavisnost oblika ulaganja i tretmana tržišnog rizika

Oblik ulaganja	Vrsta rizika	Faktor(i) rizika	Tretman po Solventnost II
Državne obveznice	Kamatni rizik; Rizik kreditnih raspona	Promjena kamatnih stopa; Rejting izdavatelja; Dospijeće obveznice (Duracija)	Državne obveznice smatraju se najniže rizičnim oblikom ulaganja što osigurateljima daje dodatan motiv ulaganja u ovaj oblik. Iako se državne obveznice u suštini smatraju nerizičnim ulaganjem, u praksi se ipak smatra da postoji određena razina rizika[33], posebice u pogledu kreditnog rizika prema središnjoj državi. Društvima za osiguranje bitno je pratiti izloženost kamatnom riziku obzirom da cijena obveznica znatno ovisi o kretanju općih kamatnih stopa.
Korporativne obveznice	Kamatni rizik; Rizik kreditnih raspona	Promjena kamatnih stopa; Rejting izdavatelja; Dospijeće obveznice (Duracija)	Predstavljaju izloženost riziku promjene kreditnih raspona. U odnosu na državne obveznice, ulaganjem u ovaj oblik može se ostvariti veći prinos koji je uglavnom praćen i višim rizikom.
Dionice	Rizik promjene cijene vlasničkih	Cijena dionice, Sentiment financijskih tržišta, Ekonomski ciklus, Stopa inflacije	Uslijed visoke volatilnosti, ovaj oblik se regulatorno tretira kao najrizičniji te se ulaganja u dionice penaliziraju visokim kapitalnim zahtjevima čija se inicijalna visina kreće u rasponu 39%-49% vrijednosti ulaganja.

[33] Državne obveznice RH (rejting BBB) i Njemačke (rejting AAA) ne mogu se svrstati u isti razred rizičnosti

Oblik ulaganja	Vrsta rizika	Faktor(i) rizika	Tretman po Solventnost II
	vrijednosnih papira		
Depoziti	Rizik kreditnih raspona	Visina i trajanje depozita, Rejting suprotne strane	Izloženost riziku primarno ovisi o visini i trajanju depozita, te rejtingu suprotne strane. Prinosi na depozite u posljednjem su desetljeću značajno pali radi čega je se smanjila i njihova atraktivnost kao oblika ulaganja
Nekretnine	Rizik promjene cijena nekretnina	Volatilnost cijena nekretnina Makro/Mikro lokacija	Pošto se radi o nelikvidnoj imovini, kapitalni tretman je vrlo nepovoljan i ne favorizira ovakvu vrstu ulaganja. Unatoč tome, RH osiguratelji ulažu značajan udio svog portfelja imovine u ovaj oblik ulaganja.
Novčani oblici	Rizik inflacije Kreditni rizik suprotne strane	Stopa inflacije, Vrijednost udjela novčanih oblika, Kreditni bonitet suprotne strane	Novac se po regulativi Solventnost II ne tretira kao tržišni, već kao kreditni rizik. Rizik držanja novčanih sredstava primarno ovisi o njihovoj količini, rejtingu banke te stopi inflacije.
Investicijski fondovi	Sve prethodno navedeno		Investicijski fondovi mogu generirati višu ili nižu izloženost riziku koja ovisi primarno o vrsti fonda (novčani, dionički, obvenički, alternativni i dr.).
Hedge fondovi	Vrsta izloženosti rizicima ovisi o strategiji fonda		Hedge fondovi i ročnice kao oblik ulaganja nisu eksplicitno tretirani kao zaseban oblik, već kao dio vrste rizika vlasničkih vrijednosnih papira. Smatraju se visokorizičnim ulaganjem radi čega je potrebno izdvojiti visok kapitalni zahtjev u odnosu na vrijednost investicije. Ovakav tretman razumljiv je iz perspektive da se radi o slabo zastupljenim oblicima ulaganja u investicijskom portfelju osiguratelja.
Ročnice (eng. *managed futures*)			

Izvor: Izrada autora

Nijedna regulativa nije idealna pa tako ni Solventnost II. Početna iskustva primjene nove regulative dovela su do zabrinutosti osiguratelja da bi, unatoč ukidanju strogih limita, odredbe o ulaganjima mogle rezultirati brojnim negativnim posljedicama u području investiranja. Primjerice, Braun et al. (2015) analizirali su kapitalne zahtjeve za tržišne rizike unutar modela standardne formule nove regulative i ukazali na mogućnost pogrešne procjene rizika insolventnosti kod osiguratelja male i srednje veličine. Braun et al. (2017) proširuju analizu na investicijske portfelje te zaključuju da parametri standardne formule za procjenu tržišnih rizika imaju značajne nedostatke koji negativno utječu na investicijske odluke osiguratelja. U tom

kontekstu, Fischer i Schlütter (2015) analiziraju ograničenja parametara modela standardne formule za procjenu rizika vlasničkih vrijednosnih papira dok (Swinkels et al., 2018) predlažu način unapređenja kalibracije navedenih parametara. Dülla et al. (2017) ukazuju na rizik u portfeljima obveznica kao značajan faktor izloženosti rizika za osiguratelja, a što nije adekvatno reflektirano u aktualnoj regulativi. Braun et al. (2018) ukazuju na negativan učinak Solventnosti II prilikom korištenja mjera baziranim na rizicima[34] za procjenu uspješnosti društava za životno osiguranje.

Upravo iz navedenih razloga, kreatori regulative ugradili su zahtjeve za revizijom odredbi kako bi osigurali što adekvatniju primjenu i napravili izmjene tamo gdje je potrebno.

Prva revizija regulative provedena je u 2018., no smatra se da nije dovoljno adresirala neke kritične točke regulacije i donijela veći opseg unapređenja pojedinih odredbi, posebno u području investiranja. Prema EIOPA-i, izmjene koje su trebale biti donesene, a koje su imale empirijsko uporište, mogle su osloboditi dodatnih 160 mlrd. € kapitala koje su osiguratelji mogli iskoristiti za rast i investicije (*Insurance Europe*, 2019).

Insurance Europe, krovno europsko udruženje (re)osiguratelja, proveo je anketu tijekom prve polovice 2018. na 87 društava za osiguranje iz 17 europskih tržišta koji zajedno čine trećinu ukupnih ulaganja cijele europske industrije. Anketom je, između ostaloga, utvrđeno da se 70% društava odmaknulo od poslova životnih osiguranja s dugoročnim garancijama. Iako se niske kamatne stope u analiziranom razdoblju navode kao jedan od glavnih razloga takvih promjena, više od dvije trećine društava identificiralo je regulativu Solventnost II kao jedan od uzroka. Također, navode i njezin negativan utjecaj na investicijske odluke što je dovelo do suboptimalne alokacije imovine. Gotovo 50% ispitanih društava navelo je regulativu kao ograničenje pri ulaganju (*Insurance Europe*, 2019).

Tablica 21 - Društva koja ulažu suboptimalne iznose u oblike ulaganja radi primjene Solventnosti II (rezultati ankete)

(Pod)oblik ulaganja	% Društava
Dionice	27%
Dugoročne korporativne obveznice	28%
Privatni plasmani/Dužnički instrumenti bez rejtinga (npr. subordinirani dug)	28%
Infrastruktura	19%
Nekretnine	19%

Izvor: Insurance Europe

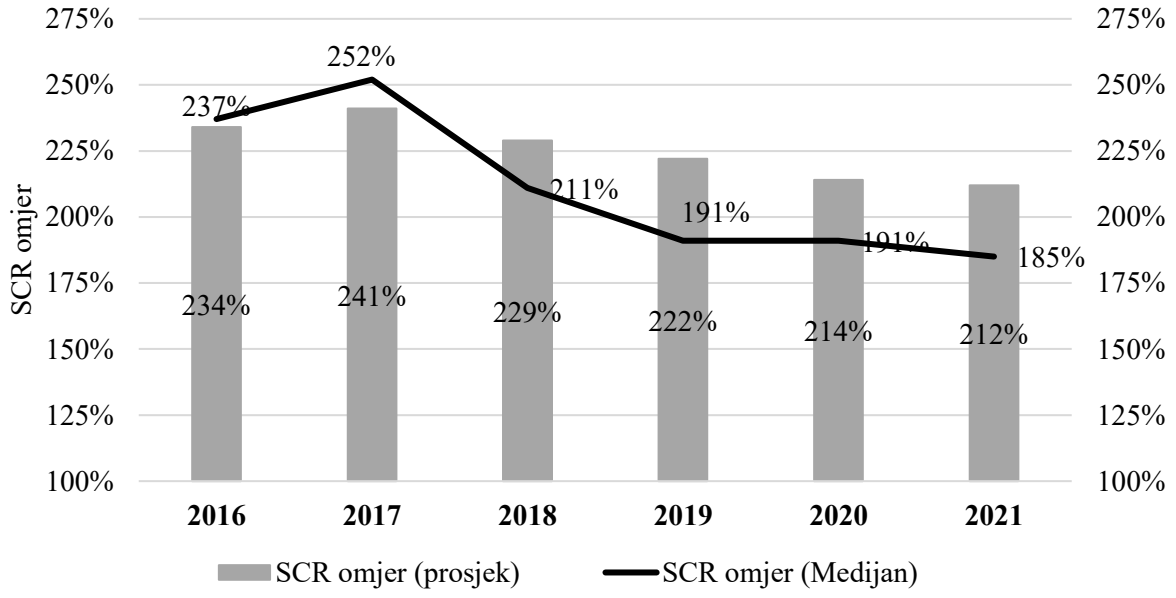
[34] eng. *Risk adjusted performance measures*

Sukladno ovim rezultatima, u reviziji regulative tijekom 2020. godine promijenjene su odredbe u dijelu rizičnosti vlasničkih ulaganja te je omogućena primjena nižeg rizičnog faktora za dugoročna vlasnička ulaganja kao i infrastrukturne projekte. Trenutno je u tijeku revizija regulative za 2022. godinu. *Insurance Europe*, kao tijelo koje zastupa interese EU osiguratelja, navodi da bi se EIOPA u tekućoj reviziji trebala dodatno fokusirati na područje dugoročnog investiranja. Nadalje, europsko udruženje smatra da kapitalni zahtjevi Solventnosti II za osiguratelje koji investiraju u realnu imovinu kao što su dionice, dug poduzeća i nekretnine ne odražavaju stvarnu izloženost ekonomskim rizicima s kojima se susreću osiguratelji. Glavni razlog tome je što regulatorni okvir općenito i pogrešno pretpostavlja da su društva za osiguranje u potpunosti izložena kratkoročnoj volatilnosti tržišnih cijena (tj. riziku trgovanja financijskim instrumentima) kada su, u stvarnosti, izloženi nižem riziku dugoročno slabe izvedbe svojih ulaganja. Revizija Solventnosti II u 2022. trebala bi svakako adresirati ovu problematiku (Insurance Europe, 2022).

4.2.4. Utjecaj uključivanja alternativnih oblika ulaganja na solventnost osiguratelja

U ovom dijelu rada procijenjen je hipotetski učinak uključivanja alternativnih oblika ulaganja na solventnost društava za osiguranje. Prije svega, izložen je prosjek omjera solventnosti (tzv. SCR omjer) najvećih osiguratelja na tržištu Republike Hrvatske u periodu primjene Solventnosti II.

Graf 23 – Prosječni i medijalni SCR omjer društava za osiguranje na RH tržištu (2016.-2021.)



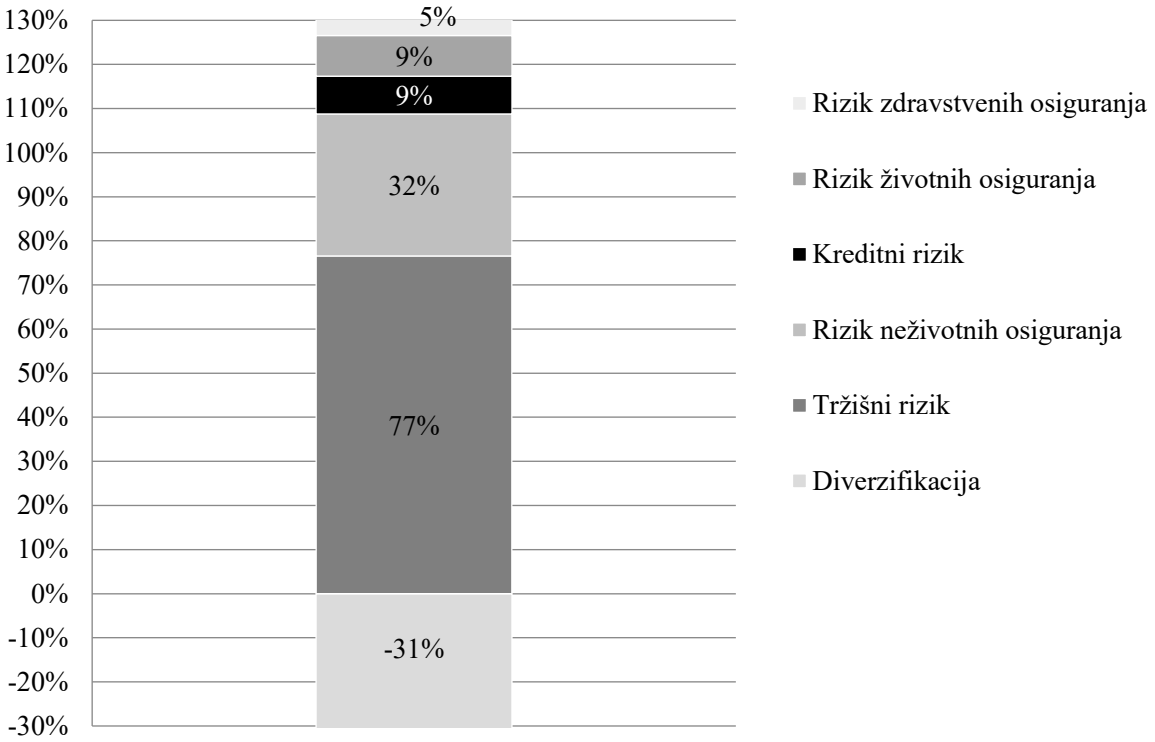
Izvor: izrada autora prema podacima EIOPA-e

Prosječan omjer solventnosti osiguratelja na RH tržištu u promatranom periodu iznosio je preko 200%, dok je medijalni omjer u posljednjih nekoliko godina na nešto nižoj razini (za 2021. godinu iznosio je 185%). Takve razine SCR omjera ukazuju na visoku kapitaliziranost društava za osiguranje koje posluju na osiguranjeljnom tržištu RH, posebice uzimajući u obzir regulatorni minimum (100%). Medijalni SCR omjer na kraju 2021. godine bio je niži od EU prosjeka koji je iznosio 219%. Uzimajući podatak samo o prosječnom i medijalnom SCR omjeru, vidljivo je da postoji značajan višak kapitala osiguratelja koji se može iskoristiti za preuzimanje dodatnih rizika.

Ukoliko bi SCR omjeri bili niži, primjerice na razinama oko ili ispod 150%, društva s takvim omjerom teško mogu razmatrati preuzimanje većeg rizika obzirom da za to nemaju kapitalni kapacitet. Takva bi odluka dodatno smanjila solventnost na razinu koja interno i/ili regulatorno nije prihvatljiva.

Odluka o investiranju u alternativne oblike ulaganja, konkretno hedge fondove i ročnice, utjecala bi na porast kapitalnih zahtjeva u segmentu tržišnih rizika koji čine značajan dio strukture kapitalnih zahtjeva osiguratelja obzirom da imovina čini najveći dio aktive, te samim time znači i veću pojavnost rizika.

Graf 24 – Struktura potrebnog solventnog kapitala osiguratelja na RH tržištu na 31.12.2020.



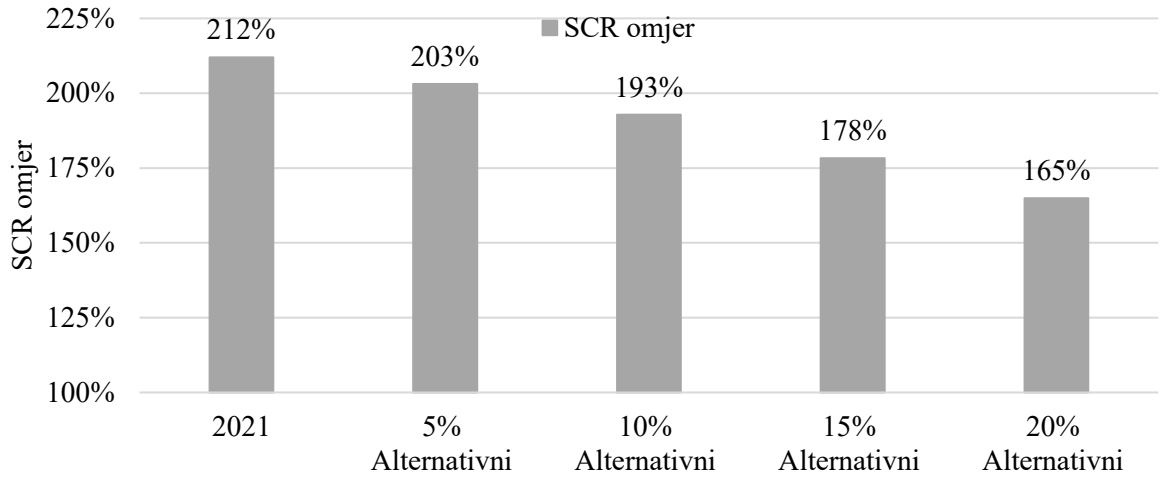
Izvor: izrada autora prema podacima EIOPA-e

Struktura potrebnog solventnog kapitala ukazuje na dominantan udio tržišnog rizika koji je u osnovnom potrebnom solventnom kapitalu[35] na kraju 2020. godine iznosio 77%, a slijede ga rizik neživotnih osiguranja s 32% udjela i ukupna diverzifikacija koja čini 31% strukture. Efekt diversifikacije se pojavljuje uslijed predefiniranih korelacija koje su uključene u agregaciju pojedinačnih kapitalnih zahtjeva. Nakon pregleda omjera solventnosti i strukture potrebnog solventnog kapitala osiguratelja na tržištu RH, potrebno je ispitati kako bi uključivanje alternativnih oblika ulaganja utjecalo na konačan potreban solventni kapital (SCR). U tu svrhu, mogu se primijeniti sljedeće pretpostavke:

- Ulaganja u hedge fondove i ročnice tretiraju se u modulu rizika vlasničkih vrijednosnih ulaganja kao vlasnička ulaganja Tipa 2 (*eng. Type 2 equities*), te se tretiraju s najrigoroznijim rizičnim faktorom umanjenja vrijednosti od 49% sukladno čl. 169., st. 2 (b) Delegirane Uredbe EK 2015/35.
- Pretpostavlja se utjecaj na kapitalni zahtjev za tržišnim rizikom i ukupan potreban solventni kapital (SCR).
- Ulaganje u alternativne oblike financiralo bi se realokacijom sredstava iz nekretnina, fondova i depozita. Time bi došlo do smanjenja kapitalnih zahtjeva za rizikom nekretnina i raspona ovisno o visini ulaganja u alternative oblike.
- Agregiranje kapitalnih zahtjeva vrsta tržišnog rizika provodi se uz korelacijsku matricu koja pretpostavlja scenarij pada kamatnih stopa.
- Testira se utjecaj uključivanja navedenih alternativnih oblika ulaganja u visini 5, 10, 15 i 20% vrijednosti investicijskog portfelja[36].
- Osnovni scenarij u odnosu na koji se provodi testiranje je realizirano stanje solventnosti na kraju 2020. godine sukladno dostupnim podacima EIOPA-e.

[35] eng. *Basic solvency capital requirement (BSCR)*
[36] Osnova za izračun apsolutne vrijednosti je visina ulaganja na kraju 2020. godine (4,7 mlrd. EUR, Izvor: EIOPA)

Graf 25 – Utjecaj uključivanja alternativnih oblika ulaganja u investicijski portfelj na omjer solventnosti društava za osiguranje



Izvor: izrada autora

Graf 25 pokazuje rezultate scenarija ulaganja određene visine investicijskog portfelja društava za osiguranje u alternativne oblike. Ukoliko bi se 5% sredstava portfelja investiralo u alternativne oblike, došlo bi do smanjenja SCR omjera od 9 postotnih poena što ne bi značajno utjecalo na adekvatnost kapitala. Utjecaj uključivanja alternativnih oblika na solventnost očekivano je viši kod većih vrijednosti alokacije udjela alternativnim oblicima, a što proizlazi iz visoke kapitalne penalizacije ovakvih oblika ulaganja. Temeljem rezultata scenarija može se zaključiti da čak ni alokacija od 20% portfelja u alternative oblike ne bi značajno ugrozila solventnost obzirom na visok prosječan omjer solventnosti društava za osiguranje. Drugim riječima, robustan kapitalni kapacitet osiguratelja na RH tržištu omogućava hipotetsko investiranje u alternative oblike u rasponu 5-20% investicijskog portfelja. Treba napomenuti da se u prethodnom grafu radi o aproksimaciji utjecaja na solventnost, dok stvaran učinak ulaganja u alternativne oblike ovisi o profilu tržišnih rizika pojedinog osiguratelja, njegovom (početnom) omjeru solventnosti i kapacitetu nosivosti rizika koji imaju visoke kapitalne zahtjeve prema Solventnosti II.

4.3. Analiza okruženja niskih kamatnih stopa u analiziranom razdoblju

Problematika okruženja niskih kamatnih stopa u analiziranom razdoblju utječe na poslovanje osiguratelja primarno u području investiranja gdje se prinosi investicijskog portfelja kontinuirano smanjuju. Pojava ovog fenomena proizlazi iz inherentne strukture portfelja koji u većinskom dijelu sadrži državne i korporativne obveznice. Prinosi ovih instrumenata smanjuju

se zajedno s padom opće razine kamatnih stopa obzirom da se svako novo izdanje obveznica plasira s manjim kuponskim kamatnim stopama.

Problem okruženja niskih kamatnih stopa u analiziranom razdoblju od posebnog je (negativnog) značaja za osiguratelje koji se bave životnim osiguranjima. Möhlmann (2021) daje kvalitetan uvid u navedeni fenomen kada su u pitanju društva za životno osiguranje. Naime, životni osiguratelji tradicionalno su nudili police mješovitog životnog osiguranja s ugrađenim garancijama godišnjeg prinosa. Prodaja takvog proizvoda bila je omogućena i više nego dostatnim prinosima na ulaganja kojim bi se u potpunosti pokrila garantirana stopa prinosa prema osiguranicima. Pad prinosa, izazvan prolongiranim okruženjem niskih kamatnih stopa, doveo je do izrazite (strukturne) nemogućnosti da se prihodom iz ulaganja podmire garancije po dugoročnim policama životnih osiguranja. Ovaj problem počeo se značajnije materijalizirati s intenziviranjem dinamike pada općih kamatnih stopa i prinosa na obveznice, a što je dovelo do reinvestiranja dospjelih tranši obveznica po sve po nižim stopama, dok su garancije osiguranicima ostale fiksne (CRO forum, 2016). Takva situacija proizlazi iz ročne neusklađenosti imovine i obveza gdje potonje imaju dulje dospijeće od instrumenata koje služe za njihovo pokriće, a što je bio problem i za hrvatske osiguratelje.

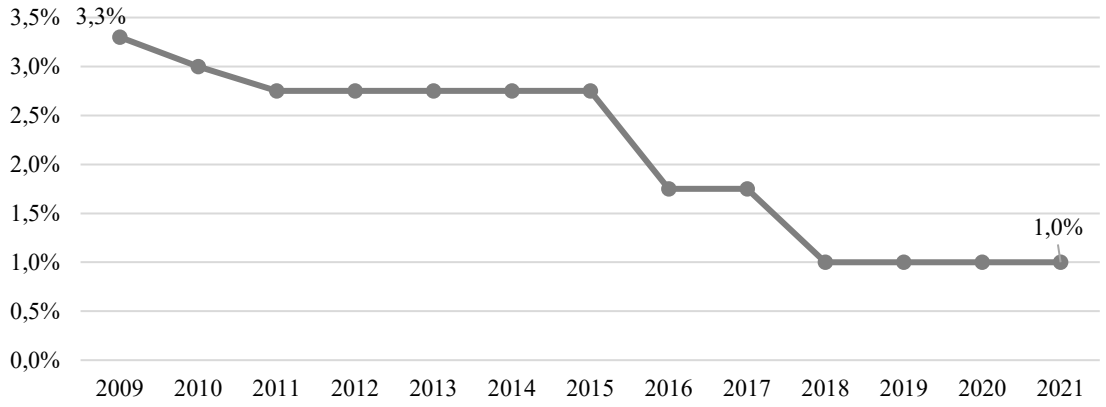
Kamatni rizik jedan je od najznačajnijih rizika za osiguratelje upravo radi tradicionalne strukture investicijskog portfelja koja dominantno uključuje udjele instrumenata s fiksnim prinosom (npr. državne i korporativne obveznice). Vrijednost odnosno cijene takvih instrumenata usko su povezane s kretanjem razine općih kamatnih stopa na način da se nalaze u obrnuto proporcionalnom odnosu. Drugim riječima, kada su kamatne stope u porastu, cijene obveznica padaju i obrnuto. Posebnost kamatnog rizika u poslovanju osiguratelja je što se on pojavljuje na strani imovine i obveza obzirom da je vrijednost tehničkih pričuva prema Solventnosti II u istom međuodnosu s promjenom kamatnih stopa kao i vrijednost imovine. Vrijednost obveza osiguratelja koje uključuju proizvode s ugrađenim garantiranim (fiksnim) prinosima još su znatnije osjetljive na kretanje kamatnih stopa. Sukladno tome, osiguratelji teže neutralizaciji kamatnog rizika na način da usklade ročnost imovine i obveza kako bi sinkronizirali njihove pomake vrijednosti izazvane promjenom kamatnih stopa.

Ukoliko se vrijednost imovine ne mijenja u skladu s obvezama, društvo za osiguranje može biti suočeno s gubitkom (ili dobiti) koji predstavlja manifestaciju kamatnog rizika. Kamatni rizik raste sukladno s visinom ročne neusklađenosti imovine i obveza i njihovim dospijećima odnosno trajanju.

Kod većine životnih osiguratelja, trajanje imovine je kraće od trajanja obveza, pa time svako smanjenje kamatnih stopa rezultira negativnim utjecajem na kapital osiguratelja. U situaciji kada je trajanje imovine dulje od trajanja obveza, osiguratelji su izloženi riziku naglog porasta kamatnih stopa obzirom gdje bi vrijednost imovine značajnije pala u odnosu na vrijednost obveza.

Društva za osiguranje već su unazad nekoliko godina počela smanjivati garancije na police životnih osiguranja kao djelomičan odgovor na okruženje niskih kamatnih stopa u analiziranom razdoblju. Takav zaštitni mehanizam primijenio je i regulator (HANFA) te se razina minimalnih garancija na police životnih osiguranja postepeno smanjivala.

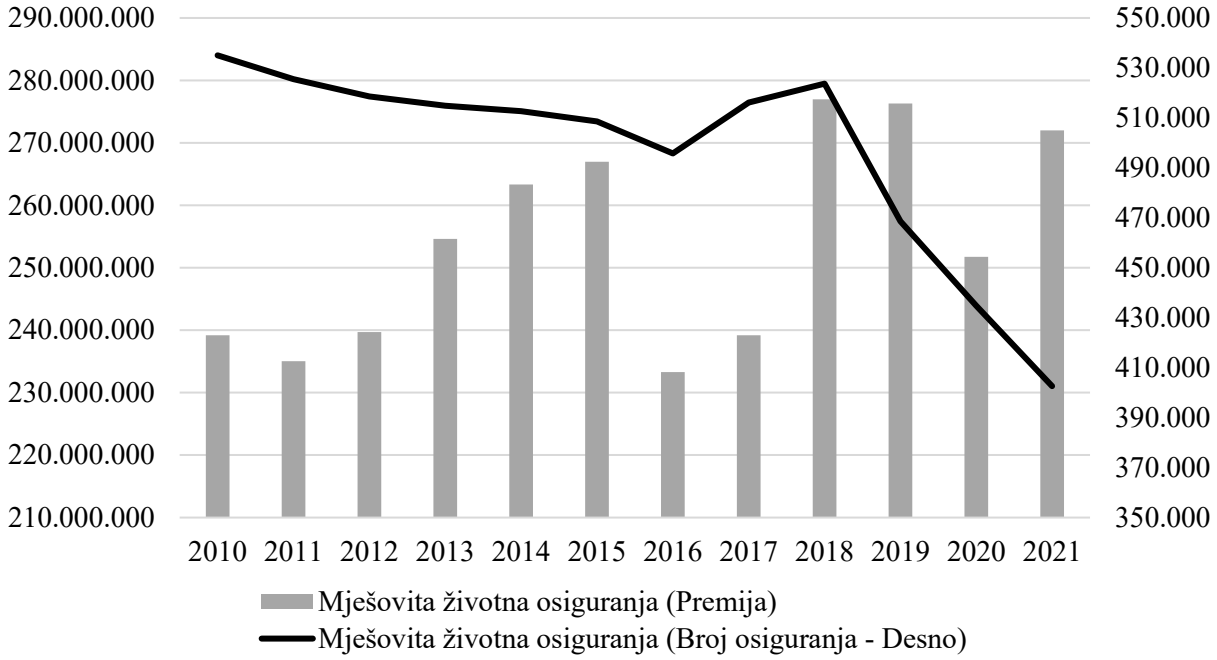
Graf 26 - Kretanje minimalnih garancija po policama životnih osiguranja na RH tržištu



Izvor: HANFA

Trenutna stopa minimalne garancije iznosi 1% i primjenjuje se od 1.1.2018. za nove police mješovitih životnih osiguranja. Smanjenje garantiranih prinosa značajno je smanjilo atraktivnost proizvoda mješovitog životnih osiguranja s ugrađenim garancijama. Dodatne mjere osiguratelja za ublažavanje efekta niskih kamatnih stopa na poslovanje, i sprečavanja pada tržišta životnih osiguranja, bile su usmjerene na rast prodaje drugih vrsta životnih osiguranja, poput investicijskih životnih osiguranja gdje tržišne rizike preuzimaju osiguranici.

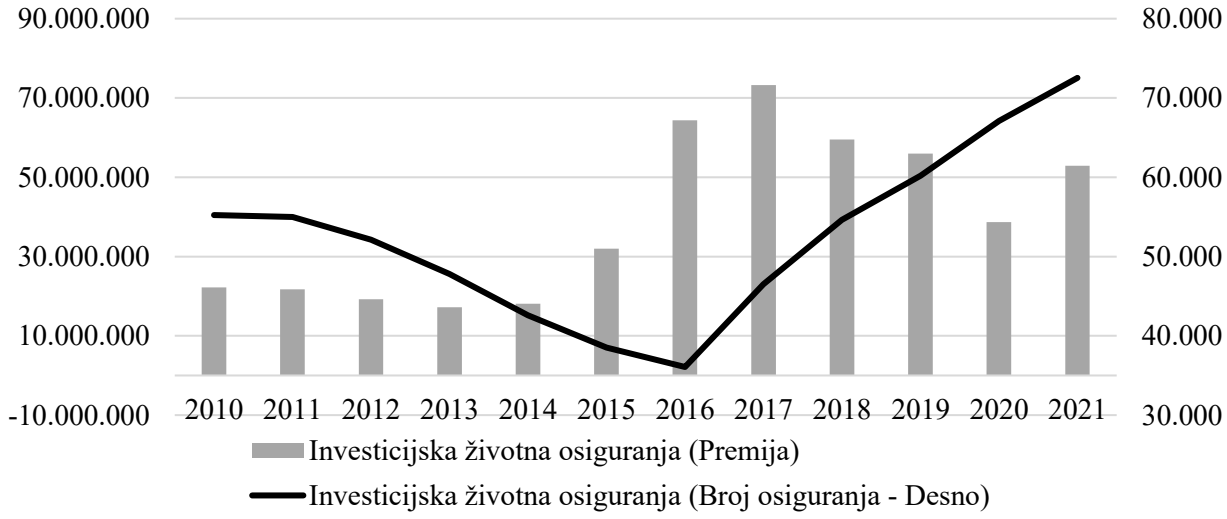
Graf 27 – Premija i broj polica mješovitih životnih osiguranja (u EUR)



Izvor: Izrada autora prema podacima Hrvatskog ureda za osiguranje (HUO)

Na grafu 27 vidljivo je da ukupna premija mješovitih životnih osiguranja i dalje nema evidentan trend pada. Takva pojava moguća je na osnovi polica sklopljenih u periodu 2000-ih i 2010-ih godina čija premija ulazi u statistiku i koje su dalje na snazi. S druge strane, pokazatelj koji ukazuje da je smanjenje garancija ipak dovelo do neatraktivnosti ove vrste osiguranja je broj osiguranja čija se visina vidljivo smanjuje u promatranom razdoblju. Umjereni pad broja osiguranja može se primijetiti već od 2010. godine dok je posebno izražen od 2018. do kraja 2021. godine. U tom periodu broj mješovitih životnih osiguranja pao je preko 120.000 (-23%).

Graf 28 - Premija i broj polica investicijskih životnih osiguranja (u EUR)



Izvor: Izrada autora prema podacima Hrvatskog ureda za osiguranje (HUO)

Ukupna premija investicijskih životnih osiguranja u početnim godinama 2010-ih kretala se na razini 20 mil. EUR uz opadajući broj osiguranja. Na kraju 2016. dolazi do promjene trenda uz značajan porast ukupne premije koja se udvostručila u odnosu na 2015. Broj osiguranja doživljava snažan porast od kraja 2016. do 2021. koji se u tom periodu također udvostručio.

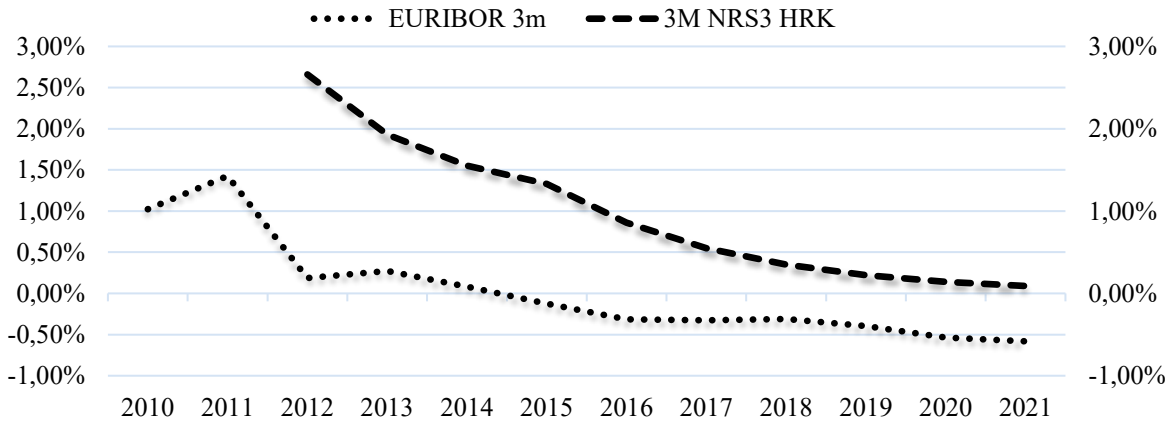
Graf 29 - Kretanje referentne kamatne stope Europske Središnje Banke (ESB) u analiziranom razdoblju



Izvor: ECB

Europska središnja banka od 2016. zadržava referentnu kamatnu stopu na razini 0% u analiziranom razdoblju. Graf 30 pokazuje važeće referentne kamatne stope u RH u analiziranom razdoblju, a to su NRS i EUROBIOR. NRS predstavlja prosječan trošak financiranja hrvatskog bankovnog sektora, za pojedine valute, na temelju podataka o poslovanju bankovnog sektora. EURIBOR-om predstavlja prosječnu kamatnu stopu po kojoj banke jedna drugoj posuđuju sredstva na međubankarskom tržištu EU. NRS i Euribor su značajno zastupljene stope u formiranju kamatnih stopa na bankarske kredite. U promatranom razdoblju vidljiva je konvergencija kamatnih stopa.

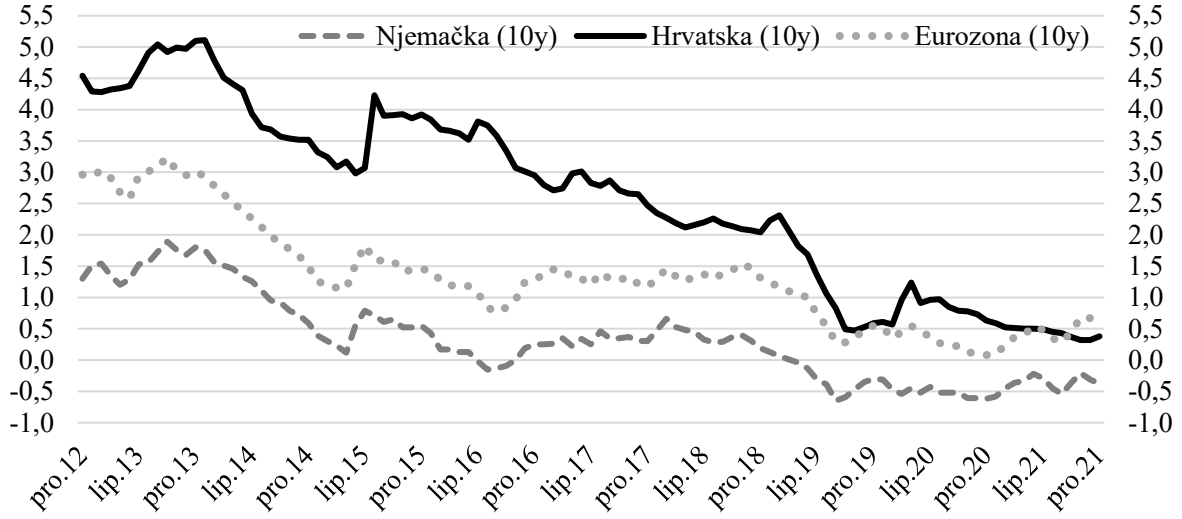
Graf 30 - Kretanje referentnih kamatnih stopa u RH u analiziranom razdoblju



Izvor: HNB, HUB

Promatrano razdoblje ukazuje na trend pada prinosa na osnovi okruženja niskih kamatnih stopa što je značajno utjecalo na prinose investicijskih portfelja društava za osiguranje. Preostaje vidjeti kako će inflatorni pritisci utjecati na gospodarska kretanja u EU i prinose obveznica.

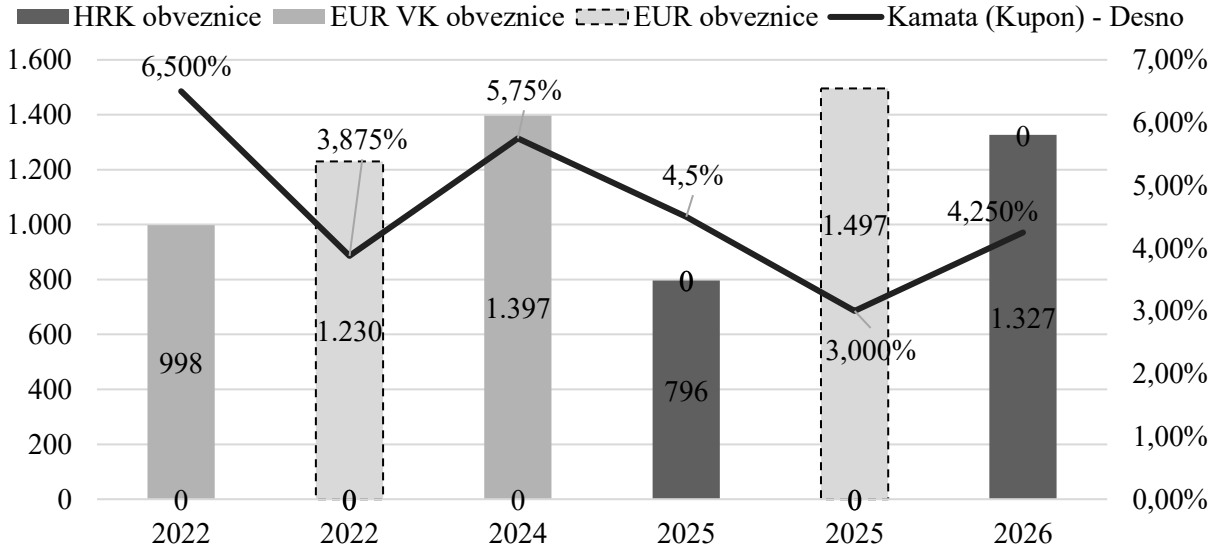
Graf 31 – Prinos (u %) na 10-godišnje državne obveznice u periodu 12/2012-02/2022



Izvor: ECB

U cilju dobivanja uvida u približan (financijski) značaj smanjenih prinosa u analiziranom razdoblju, graf 32 pokazuje dospijeća i vrijednosti tranši državnih obveznica RH kako bi se iz dostupnih podataka moglo procijeniti potencijalne smanjenje budućeg kamatnog prihoda za institucionalne investitore. U pregled obveznica uključene su obveznice denominirane u HRK i EUR (tzv. euroobveznice) te obveznice s valutnom klauzulom u EUR. Razlog odabira ovih izdanja je njihova visoka zastupljenost u investicijskom portfelju osiguratelja.

Graf 32 - Pregled državnih obveznice i dospijeće po godinama (u mil. EUR)



Izvor: (Ministarstvo financija, 2022)

Na grafu 32 prikazana su izdanja obveznica koja dospijevaju u sljedeće 4 godine (tj. do 2026.). Ukupna vrijednost promatranih obveznica iznosi 7,24 mlrd. EUR dok se raspon njihovih kuponskih kamata kreće od 4-7%. Postoji još izdanja obveznica koje dospijevaju u periodu od 2022.-2026. godine, no njihovi kuponi već su znatno niži (tj. ispod 2%) stoga nisu uzete u obzir. Prosječna ponderirana kuponska kamatna stopa prikazanih obveznica iznosi 4,6% što je ekvivalent 330 mil. EUR kamatnog prihoda za investitore odnosno troška za izdavatelja. Ukoliko se pretpostavi da Republika Hrvatska predmetna izdanja ponovno plasira uz dvostruko nižu kuponsku kamatu (cca 2,3%), u tom slučaju bi godišnji prihod od kamata odnosno kamatni trošak za državu bio niži za 165 mil. EUR. Potencijalni gubitak prihoda od kamata za pojedinog institucionalnog investitora ovisi o udjelu odnosno vrijednosti državnih obveznica u investicijskom portfelju.

Buduće kretanje kamatnih stopa teško je predvidjeti. Uzimajući u obzir trenutnu situaciju s rastućom inflacijom, može se očekivati određeni rast kamatnih stopa, no prognozirati unaprijed intenzitet porasta vrlo je izazovno. Ukoliko dođe do rasta kamatnih stopa u EU, takav slučaj može se očekivati i u Hrvatskoj, no ono što je realno za očekivati je da će ulaskom u eurozonu, razine kamatnih stopa u RH dodatno konvergirati prema stopama u EU. Sukladno tome, analizirano razdoblje ukazuje da se može očekivati dodatno smanjenje prinosa na državne obveznice i novi pritisak na snižavanje investicijskih prinosa društava za osiguranje.

5. OPTIMIZACIJA I EMPIRIJSKA ANALIZA UTJECAJA ALTERNATIVNIH OBLIKA ULAGANJA NA INVESTICIJSKI PORTFELJ

5.1. Pregled varijabli

Varijable od primarnog značaja za testiranje hipoteza su alternativni i tradicionalni oblici ulaganja odnosno vremenske serije njihovih mjesečnih prinosa. U pogledu duljine vremenske serije, koristiti će se mjesečne opservacije u periodu 2006.-2020. godine što daje ukupno 180 opažanja te omogućava visoku reprezentativnost rezultata istraživanja**.** Prilikom usporedbe prinosa oblika ulaganja često se koriste i anualizirani prinosi gdje se dani ili mjeseci konvertiraju u godine. Navedeno se može napraviti ukamaćivanjem dnevnog ili mjesečnog prinosa s brojem dana trgovanja (252) ili brojem mjeseci (12) (Romero i Balch, 2015).

Varijabla „**Alternativni oblici ulaganja**" definira se kao udio alternativnih oblika ulaganja, koji se odnose na hedge fondove i ročnice, u investicijskom portfelju sačinjenom od tradicionalnih oblika ulaganja (dionice, obveznice i dr.). Hedge fondovi i ročnice se odnose na njihove mjesečne prinose koji su reprezentirani odgovarajućim financijskim indeksom. Udio alternativnih oblika ulaganja će se mjeriti u obliku postotka (udjela) u ukupnom investicijskom portfelju temeljem odabrane metode optimizacije.

Podatke o kretanju ukupnih prinosa **Hedge fondova** predstavljaju mjesečne promjene vrijednosti indeksa *Barclay Hedge Fund Index* u razdoblju od 2006.-2020. godine. Izvor podataka je *Barclay Hedge* baza. Podatke o kretanju ukupnih prinosa **ročnica (eng. *Managed futures*)** predstavljaju mjesečne promjene vrijednosti indeksa *Barclay BTOP50 index* u razdoblju od 2006.-2020. godine. Radi se o indeksu koji replicira ukupnu kompoziciju industrije ročnica obzirom na stil ulaganja i ukupnu izloženost vrstama tržišta ročnica (robne, financijske i dr.). Unutar indeksa uključeni su najveći upravitelji fondova ročnica mjereni po imovini pod upravljanjem. Izvor podataka je *Barclay Hedge* baza. Oba indeksa alternativnih oblika nisu uloživa odnosno nemaju burzovni fond čijim se udjelima trguje na burzi (eng. *exhange traded fund*) i koji prati njihovo kretanje.

Baza podataka za alternativne oblike ulaganja, *Barclay Hedge* baza*,* pokazala se najkvalitetnijom uzimajući u obzir recentne radove (Molyboga et al., 2017; Joenvaarra et al., 2012) gdje je utvrđeno da predmetna baza ima najveći broj fondova alternativnih oblika

ulaganja u odnosu na druge izvore podataka (npr. TASS, HFR). Buraschi et al. (2014) ukazuju na dvije glavne prednosti korištenja navedene baze podataka. Prva se odnosi na činjenicu što je baza najmanje izložena riziku pristranosti podataka (eng. *survivorship bias*) jer uključuje najveći broj aktivnih i ugašenih fondova. Druga glavna prednost je što baza posjeduje najdužu povijest podataka o imovini pod upravljanjem (eng. *asset under management*).

Varijabla „**Tradicionalni oblici ulaganja**" definira se kao udio tradicionalnih oblika ulaganja u investicijskom portfelju (domaće i strane državne obveznice, domaće i strane dionice, korporativne obveznice, novčana sredstva). Domaće dionice i obveznice se odnose na prinose vrijednosnih papira koji kotiraju na tržištu Republike Hrvatske koji su reprezentirani odgovarajućim indeksom. Strane dionice se odnose na prinose dionica koje kotiraju na tržištu kapitala SAD-a, EU i globalnom financijskom tržištu. Strane obveznice se odnose na prinose državnih i korporativnih obveznica koje kotiraju na razini tržišta EU i SAD. Navedeni oblici ulaganja su reprezentirani odgovarajućim indeksom. Udio tradicionalnih oblika ulaganja će se mjeriti u obliku postotka (udjela) u ukupnom portfelju temeljem odabrane metode optimizacije.

Podatke o kretanju prinosa **domaćih dionica** Republike Hrvatske predstavljaju mjesečne promjene vrijednosti indeksa CROBEXtr u razdoblju od 2006.-2020. godine. Izvor podataka je stranica Zagrebačke burze. Podatke o kretanju prinosa **domaćih obveznica** Republike Hrvatske predstavljaju mjesečne promjene vrijednosti indeksa CROBIStr u razdoblju od 2006.-2020. godine. Izvor podataka je stranica Zagrebačke burze. Indeks obveznica nema burzovni fond čijim se udjelima trguje na burzi, dok u slučaju CROBEX-a investitori mogu kupiti udjele u fondu InterCapital CROBEX10tr UCITS ETF-u koji je osnovan krajem 2020. godine i replicira strukturu specijaliziranog indeksa Zagrebačke burze CROBEX10tr. Podfondom upravlja društvo za upravljanje Intercapital asset management.

U pogledu vremenske serije domaćih financijskih indeksa, podaci za seriju ukupnih prinosa dostupni su tek od kraja veljače 2014. godine za CROBEXtr i prosinca 2011. godine za CROBIStr. Sukladno tome, ukupna vremenska serija za domaće dionice i obveznice modificirana je na način da su prethodna razdoblja (do siječnja 2006. godine) dopunjena s mjesečnim prinosima baznih indeksa CROBEX i CROBIS.

Podatke o kretanju prinosa **stranih dionica na tržištu kapitala SAD-a** predstavljaju mjesečne promjene vrijednosti indeksa S&P 500 Index u razdoblju od 2006.-2020. godine. Podatke o kretanju prinosa **stranih dionica na tržištu kapitala EU** predstavljaju mjesečne promjene

vrijednosti indeksa MSCI Europe Index u razdoblju od 2006.-2020. godine. Podatke o kretanju prinosa **stranih dionica na globalnom tržištu** kapitala predstavljaju mjesečne promjene vrijednosti indeksa S&P Global 1200 Index u razdoblju od 2006.-2020. Podatke o kretanju prinosa **stranih dionica na tržištima u razvoju** predstavljaju mjesečne promjene vrijednosti indeksa MSCI Emerging Markets Index u razdoblju od 2006.-2020. godine. Izvor podataka za sve strane oblika dionica je Bloomberg. Indeksi stranih dionica imaju oblike burzovnih fondova čijim se udjelima trguje na burzi i odnose se na indekse ukupnih prinosa.

Podatke o kretanju prinosa **stranih državnih obveznica na tržištu kapitala EU** predstavljaju mjesečne promjene vrijednosti indeksa FTSE EMU Government Bond Index (EGBI), u razdoblju 2006.-2020. godine, koji mjeri prinos državnih obveznica investicijskog rejtinga zemalja uključenih u Europsku monetarnu uniju, a koje zadovoljavaju specifične kriterije (FTSE Russel, 2019). Podatke o kretanju prinosa **korporativnih obveznica na tržištu kapitala EU** predstavljaju mjesečne promjene vrijednosti indeksa Barclays Euro Corporate Bond Index, u razdoblju 2006.-2020. godine, koji mjeri prinos korporativnih obveznica investicijskog rejtinga najvećih kompanija u EU. Podatke o kretanju prinosa **stranih obveznica na tržištu kapitala SAD-a** predstavljaju mjesečne promjene vrijednosti indeksa Barclays U.S Aggregate Bond Index, u razdoblju 2006.-2020. godine, koji mjeri prinos obveznica investicijskog rejtinga na financijskom tržištu SAD-a. Podatke o kretanju prinosa **stranih obveznica na globalnom tržištu** kapitala predstavljaju mjesečne promjene vrijednosti indeksa Barclays Global Aggregate Bond Index, u razdoblju 2006.-2020. godine, koji mjeri prinos obveznica investicijskog rejtinga na globalnom financijskom tržištu. Podatke o kretanju prinosa **stranih obveznica na tržištima u razvoju** predstavljaju mjesečne promjene vrijednosti indeksa J.P. Morgan Euro EMBI Global Diversified Index u razdoblju 2006.-2020. godine, koji mjeri prinos obveznica investicijskog rejtinga na tržištima kapitala zemalja u razvoju. Izvor podataka za sve strane obveznice je Bloomberg. Indeksi stranih obveznica imaju oblike burzovnih fondova čijim se udjelima trguje na burzi[37] i odnose se na indekse ukupnih prinosa.

Podatke o kretanju prinosa na **novčana sredstva** predstavljaju mjesečne promjene vrijednosti fonda ZB Plus, u razdoblju 2006.-2020. godine, kao kratkoročnog obvezničkog fonda s najvećom vrijednosti imovine pod upravljanjem. Izvor podataka je *hrportfolio.hr*. Naime, klasičnih novčanih fondova u RH više nema obzirom da je Hrvatska agencija za nadzor

[37] Za ulaganje u strane obveznice na globalnom tržištu kapitala može se koristiti *iShares World Government Bond Index Fund* koji replicira FTSE World Government Bond Index-a (WGBI).

financijskih usluga (HANFA) promijenila pravilnik o strukturi ulaganja novčanih fondova. Iz tog razloga su sva investicijska društva promijenila Prospekte svojih investicijskih fondova te novčane fondove pod upravljanjem promijenila u kratkoročne obvezničke fondove koji pretežito investiraju sredstva u visoko likvidne i kratkoročne oblike ulaganja (npr. kratkoročne obveznice, novac i novčane ekvivalente, depozite, trezorske zapise i sl.).

Očekivan prinosi $E(R_i)$ promatranih varijabli i, $i \in \{1, 2, .., I\}$ odnose se na prosjek mjesečnih prinosa koji se računaju kao logaritam zadnje cijene zadnjeg dana u mjesecu u odnosu na zadnju cijenu zadnjeg dana prethodnog mjeseca. Izračun mjesečnih prinosa dan je formulom:

$$r_{i,t} = \ln\left(\frac{P_{i,t}}{P_{i,t-1}}\right), \tag{5.1}$$

gdje ri,t predstavlja prinos na varijablu odnosno oblik ulaganja i, a ln prirodni logaritam.

Varijanca prinosa σ_i^2 varijable i dana formulom

$$\sigma_i^2 = E\left[R_i(t) - E(R_i)\right]^2 = \frac{1}{T}\sum_{t=1}^{T}\left[R_i(t) - E\left(R_i\right)\right]^2. \tag{5.2}$$

Investicijski portfelj kao varijabla sastoji se od udjela odabranih oblika ulaganja koji se izračunavaju na osnovi relevantne metode optimizacije odnosno predstavljaju rješenje korištenog modela. Tradicionalni investicijski portfelj sadrži isključivo tradicionalne oblike ulaganja dok se prinos investicijskog portfelja definira kao prvi središnji moment distribucije prinosa. **Prinos investicijskog portfelja** mjeri se kao ponderirana suma dobivenih udjela alternativnih i tradicionalnih oblika ulaganja temeljem provedene optimizacije. S druge strane, **rizik investicijskog portfelja** definira se kao varijanca/standardna devijacija investicijskog portfelja odnosno drugi središnji moment distribucije prinosa. Varijabla se mjeri kao varijanca portfelja koja je dana sljedećim izrazom:

$$\sigma_P^2 = \sum_{i=1}^{I} w_i^2\sigma_i^2 + 2\sum_{\substack{i,j=1 \\ i\neq j}}^{I} w_i\, w_j cov\left(R_i, R_j\right), \tag{5.3}$$

koju je moguće još zapisati kao:

$$\sigma_P^2 = \sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij}. \tag{5.4}$$

Standardna devijacija je pozitivni drugi korijen varijance.

Efikasnost investicijskog portfelja definira se kao relevantna mjera učinkovitosti portfelja ovisno o testiranoj hipotezi. U hipotezi H1 se koriste Sharpeov i Sortinov omjer jer se hipoteza H1 testira primjenom Markowitzevog modela optimizacije koji koristi pretpostavku normalnosti radi čega u model i mjere nije potrebno uključivati više momente. Sukladno tome, za evaluaciju efikasnosti dovoljno je koristiti navedene omjere pošto njihova vrijednost ovisi samo o prva dva momenta distribucije prinosa. U hipotezi H2 se koristi Omega mjera obzirom da se radi o relevantnoj mjeri učinkovitosti portfelja kada distribucija ne slijedi normalni oblik. Višekriterijski model optimizacije, kojim će se testirati hipoteza H2, uključuje više momente gdje se istovremeno maksimizira 1. i 3. moment i minimizira 2. i 4. moment. Iz tog razloga se takav model smatra višekriterijskim što implicira da mjera kojom se uspoređuju portfelji treba također uključivati više momente kao što je to slučaj kod Omega mjere.

U **hipotezi H1**, varijabla efikasnosti investicijskog portfelja se mjeri preko **Sharpeovog** i **Sortinovog omjera** koji spadaju među najpoznatije pokazatelje za mjerenje uspješnosti investicijskog portfelja. Veća vrijednost indikatora ukazuje na veću efikasnost odnosno uspješnost portfelja. **Sharpeov omjer** mjeri se preko sljedećeg izraza:

$$\left.\begin{array}{l} \max\limits_{w_i}\left[\dfrac{\mu_P - R_f}{\sigma_P}\right] \\ \textit{uz ograničenja} \\ \sum\limits_{i=1}^{N} w_i = 1 \\ w_i \geq 0,\ i \in \{1,2,...,N\} \end{array}\right\} \tag{5.5}$$

Sharpeov omjer temelji se na omjeru viška očekivanog prinosa (μ_p - R_f) i rizika portfelja (σ_p). Za kritičnu granicu R_f uzima se u pravilu bezrizična kamatna stopa koja se u empirijskim istraživanjima uobičajeno aproksimira kamatnom stopom na trezorske zapise. Sharpeov omjer ima sljedeće ekonomsko tumačenje: želimo maksimizirati omjer viška prinosa i rizika, odnosno na jednu jedinicu rizika želimo ostvariti što veći višak prinosa portfelja (Šego et. al., 2018).

Sortinov omjer mjeri se preko sljedećeg izraza:

$$\left.\begin{array}{l} \max\limits_{w_i}\left(\dfrac{\mu_P - R_T}{\dfrac{1}{T}\sum\limits_{t=1}^{T}\left|\sum\limits_{i=1}^{N}\left(\bar{r}_{i,t} - E(r_i)\right)w_i\right|}\right) \\ \textit{uz ograničenja} \\ \sum\limits_{i=1}^{N} w_i = 1 \\ w_i \geq 0,\ i \in \{1,2,...,N\} \end{array}\right\} \tag{5.6}$$

Sortinov omjer temelji se na ispodprosječnim prinosima i umjesto standardne devijacije razmatra se donja polu-apsolutna devijacija. Također, umjesto bezrizične kamatne stope, razmatra se zahtijevana stopa prinosa portfelja *RT*. Izraz $r_{i,t}^{-}$ predstavlja prinos pojedinog oblika ulaganja koji je manji od očekivanog prinosa istog (Šego et. al., 2018).

U **hipotezi H2**, varijabla efikasnosti investicijskog portfelja se mjeri preko **Omega omjera** koji je primjeren za korištenje u slučajevima kada distribucija prinosa portfelja ne slijedi normalni oblik. Mjera je obrazložena i korištena u Keating i Shadwick, 2002; Bhaduri et al. 2005; Abrams et al. 2012). Veća vrijednost Omega mjere ukazuje na veću efikasnost portfelja. **Omega omjer** mjeri se preko sljedećeg izraza:

$$\Omega(r) := \frac{\int_{r}^{b} [1-F(x)]dx}{\int_{a}^{r} F(x)dx} \qquad (5.7)$$

gdje je *F(x)* kumulativna funkcija distribucije prinosa, ograničena krajnjim točkama *a* i *b*, s granicom prihvatljivog prinosa *r* (Keating i Shadwick, 2002). Omega mjera predstavlja koristan alat za mjerenje učinkovitosti investicijskog portfelja jer uzima u obzir nenormalnost distribucije prinosa koja su česta pojava u vremenskim serijama financijskih instrumenata, posebno kod alternativnih oblika ulaganja (Abrams et. al., 2012).

Kamatne stope kao varijabla predstavljaju referentne kamatne stope na financijskom tržištu EU koje se koriste pri određivanju tržišnih kamatnih stopa i cijena financijskih instrumente poput obveznica, depozita i kredita. **Utjecaj promjene kamatnih stopa** na prinose tradicionalnih i alternativnih oblika ulaganja definira se na način da ukoliko dođe do promjene kamatnih stopa, vrlo je izgledno da će doći do promjene prinosa odnosno cijene promatranog oblika ulaganja. Drugim riječima, promjena prinosa promatranog oblika ulaganja uzrokovana je promjenom kamatnih stopa. Podatke o kretanju referentne kamatne stope predstavljaju mjesečne promjene vrijednosti 3M EURIBOR-a u razdoblju 2006.-2020. godine. Izvor podataka je statistička baza Europske središnje banke.

5.2. Oblikovanje modela optimizacije

Hipoteze H1 i H2 će se testirati provedbom optimizacije portfelja pomoću Markowitzevog i višekriterijskog modela uključivanjem prethodno navedenih varijabli. Provedbom optimizacije odnosno dobivenim rezultatima dobiti će se rezultat testiranja pojedinih hipoteza (H1 i H2). Svi izračuni i optimizacije provedeni su u programu R. Na temelju korištenih podataka, izračunati su mjesečni prinosi, kao i podaci o varijanci, koeficijentu asimetrije i koeficijentu zaobljenosti za svaki indeks odnosno imovinski oblik.

Obzirom da su u optimizaciju uključena *N* oblika ulaganja, potrebno je izračunati *N* očekivanih prinosa, $\binom{N+1}{2}$ varijanci i kovarijanci, $\binom{N+2}{3}$ koeficijenata asimetrije i koasimetrije (5.8) i $\binom{N+3}{4}$ koeficijenata zaobljenosti i kozaobljenosti. Analize i izračuni u koje su uključeni viši momenti postaju složeniji s povećanjem broja varijabli (npr. broja dionica), u ovom slučaju broja oblika ulaganja. Drugim riječima, s rastom broja varijabli, broj koeficijenata koje je potrebno izračunati povećava se po ubrzanoj stopi (Šego et al. 2018). Međutim, zbog simetrije koeficijenata, ako imamo N varijabli, trebamo izračunati „samo“ $\binom{N+2}{3}$ koeficijenta asimetrije i koasimetrije te $\binom{N+3}{4}$ koeficijenta zaobljenosti i kozaobljenosti (Škrinjarić, 2013). Problem eksponencijalnog rasta broja parametara koje je potrebno procijeniti uključivanjem više varijabli može se ublažiti korištenjem više faktorskog modela (Boudt et al., 2015). Sukladno tome, općeniti koeficijenti koasimetrije se računaju po formuli

$$s_{ijk} = E\left[\left(R_i - E(R_i)\right)\left(R_j - E\left(R_j\right)\right)\left(R_k - E(R_k)\right)\right]$$

dok se koeficijenti kozaobljenosti računaju prema zapisu,

$$k_{ijkl} = E\left[\left(R_i - E(R_i)\right)\left(R_j - E\left(R_j\right)\right)\left(R_k - E(R_k)\right)\left(R_l - E(R_l)\right)\right] \quad (5.9)$$

Procjena komomenata promatranog uzorka može značajno odstupati kada su u pitanju mali uzorci. Ova pojava može se ublažiti korištenjem procjena skupljanja (eng. *shrinkage estimators*). Boudt et al. (2017) predlažu primjenu takve za metode za procjenu koasimetrije varijabli u optimizaciji portfelja hedge fondova koja uzim u obzir očekivani prinos, varijancu i asimetriju. Ledoit i Wolf (2003) koriste navedenu metodu u procjeni matrice kovarijance prinosa dionica. Martellini i Ziemann (2010) ukazuju na važnost uvođenja unaprijeđenih procjenitelja za parametre koasimetrije i kozaobljenosti u pogledu utjecaja na analizu portfelja koja uključuje više momente.

Uobičajeno se u literaturi formule za **asimetriju i zaobljenost portfelja** zapisuju kako slijedi:

$$S_P = E\left[R_P - E\left(R_P\right)\right]^3 = \sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I} w_i w_j w_k s_{ijk} \tag{5.10}$$

i

$$K_P = E\left[R_P - E\left(R_P\right)\right]^4 = \sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}\sum_{l=1}^{I} w_i w_j w_k w_k k_{ijkl}, \tag{5.11}$$

odnosno relativna asimetrija i zaobljenost

$$S_{Pr} = \frac{E\left[R_P - E\left(R_P\right)\right]^3}{\sigma_P^3} = \frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I} w_i w_j w_k s_{ijk}}{\left(\sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij}\right)^{\frac{3}{2}}} \tag{5.12}$$

i

$$K_{Pr} = \frac{E\left[R_P - E\left(R_P\right)\right]^4}{\sigma_P^4} = \frac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}\sum_{l=1}^{I} w_i w_j w_k w_k k_{ijkl}}{\left(\sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij}\right)^{2}}, \tag{5.13}$$

gdje se potencirana standardna devijacija koristila kao faktor skaliranja. Preporučljivo je koristiti relativne mjere kako bi na taj način normalizirali više momente što omogućava usporedivost s drugim modelima. Nadalje, kovarijanca prinosa između dviju varijabli *i j* dana je izrazom;

$$cov\left(R_i, R_j\right) = E\left[\left(R_i(t) - E(R_i)\right)\left(R_j(t) - E\left(R_j\right)\right)\right]. \tag{5.14}$$

Uz izračun asimetrije i zaobljenosti portfelja, te (ko)varijance između promatranih oblika ulaganja, **očekivani prinos portfelja** $E(R_P)$ računa se kao ponderirana aritmetička sredina prinosa na pojedinačne imovinske oblike koji ga sačinjavaju, pri čemu su ponderi udjeli w_i:

$$E\left(R_P\right) = \sum_{i=1}^{I} w_i E\left(R_i\right). \tag{5.15}$$

Varijanca portfelja dana je izrazom:

$$\sigma_P^2 = \sum_{i=1}^{I} w_i^2 \sigma_i^2 + 2\sum_{\substack{i,j=1 \\ i \neq j}}^{I} w_i w_j cov\left(R_i, R_j\right), \tag{5.16}$$

koju je moguće još zapisati kao:

$$\sigma_P^2 = \sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij}. \tag{5.17}$$

Standardna devijacija je pozitivni drugi korijen varijance.

5.3. Optimizacija pomoću Markowitzevog modela (Hipoteza 1)

Optimizacija pomoću Markowitzevog modela koristi se u kontekstu testiranja hipoteze H1 gdje se postupno uključuju navedene varijable tradicionalnih i alternativnih oblika ulaganja. Na početku se nalazi pregled deskriptivne statistike odabranih varijabli, kao i matrice korelacije promatranih oblika ulaganja. Model je prvo optimiziran na portfelju od isključivo tradicionalnih oblika, a potom su varirani udjeli tradicionalnih oblika u cilju testiranja i pokušaja unapređenja efikasne granice uključivanjem dodatnih tradicionalnih i alternativnih oblika. Nakon što se iscrpe raspoložive mogućnosti s tradicionalnim, u optimizaciju se postepeno dodaju alternativni oblici ulaganja. Uključivanje dodatnih tradicionalnih i alternativnih oblika ulaganja fiksirat će se na inkremente od 10% udjela u cilju jednostavnijeg praćenja rezultata optimizacije.

Tablica 22 - Deskriptivna statistika odabranih tradicionalnih i alternativnih oblika ulaganja

Oblik ulaganja	Indeks	Očekivani prinos	Std. dev.	Koef. asimetrije	Koef. zabljenosti	Jarque-Bera	*p-vrijednost*
Obveznice RH	**CROBIStr**	0,0025	0,012	-0,137	3,299	82,18	0,00
Dionice RH	**CROBEXtr**	0,0003	0,067	-0,925	7,157	409,79	0,00
Novčana sredstva	**ZB Plus**	0,0018	0,002	1,739	3,906	205,14	0,00
Obveznice EU	**FTSE EMU**	0,0034	0,012	-0,030	0,333	0,86	0,65
Dionice EU	**MSCI Europe**	0,0013	0,056	-0,781	2,036	49,39	0,00
Hedge fondovi	**Barclay Hedge Fund**	0,0044	0,020	-1,221	4,728	212,36	0,00
Ročnice	**BTOP50**	0,0020	0,019	0,137	-0,174	0,79	0,67
Obveznice SAD	**Barclays U.S Aggregate**	0,0037	0,009	0,109	1,072	8,97	0,01
Dionice SAD	**S&P 500**	0,0061	0,044	-0,889	2,247	61,59	0,00
Obveznice Global	**Barclays Global Aggregate**	0,0033	0,015	-0,239	1,010	9,37	0,01
Dionice Global	**S&P Global 1200**	0,0042	0,047	-0,961	2,662	80,82	0,00
Obveznice EM	**J.P. Morgan Euro EMBI**	0,0042	0,114	-0,291	86,175	55698,77	0,00
Dionice EM	**MSCI EM**	0,0033	0,064	-0,934	3,541	120,23	0,00
Korp obveznice EU	**Barclays Euro Corporate**	0,0030	0,012	-1,564	9,587	762,70	0,00

Izvor: izračun autora u programskom paketu R

U tablici 22 prikazana je deskriptivna statistika mjesečnih promjena prinosa odabranih domaćih i stranih tradicionalnih, te alternativnih oblika ulaganja u periodu siječanj 2006. - prosinac 2020. godine što daje ukupno 180 opažanja. Rezultati deskriptivne statistike pokazuju da je prinos najveći kod Hedge fondova, dok je rizik, izražen preko standardne devijacije, najviši kod obveznica tržišta u razvoju (Obveznice EM). Vidljivo je također kako su koeficijent asimetrije

i eksces zaobljenosti za većinu promatranih prinosa varijabli različiti od nule, što upućuje da njihovi prinosi ne slijede normalnu distribuciju. To je dodatno potvrđeno Jarque-Bera testom koji je ukazao da na razini statističke signifikantnosti od 1% odbacujemo hipotezu (H0) o normalnoj distribuciji prinosa za sve promatrane oblike ulaganja, osim kod prinosa ročnica i obveznica EU gdje ne možemo odbaciti nultu hipotezu te se njihove vremenske serije smatraju normalno distribuiranim. Činjenica da većina varijabli nije normalno distribuirana dodatno opravdava korištenje modela koji će uzeti u obzir više momente distribucije (tj. asimetriju i zaobljenost). U tablici 22 su također označene najveće i najmanje vrijednosti središnjih momenata distribucije prinosa. Nakon izračuna deskriptivne statistike, u tablici 23 nalazi se matrica koeficijenata korelacije između promatranih oblila ulaganja[38].

Tablica 23 – Koeficijenti korelacija promatranih oblika ulaganja

	#	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Obveznice RH	**1**	1													
Dionice RH	**2**	0,37	1												
Novac	**3**	-0,14	-0,03	1											
Obveznice EU	**4**	0,20	-0,16	0,10	1										
Dionice EU	**5**	0,30	0,60	0,02	-0,07	1									
Hedge fondovi	**6**	0,32	0,66	0,06	-0,10	0,88	1								
Ročnice	**7**	-0,01	-0,03	0,03	0,28	0,07	0,12	1							
Obveznice SAD	**8**	0,16	0,00	0,17	0,60	0,09	0,05	0,20	1						
Dionice SAD	**9**	0,30	0,59	-0,04	-0,07	0,88	0,87	0,04	0,03	1					
Obveznice Global	**10**	0,22	0,20	0,17	0,38	0,45	0,32	0,20	0,72	0,30	1				
Dionice Global	**11**	0,31	0,63	-0,01	-0,08	0,96	0,92	0,06	0,07	0,97	0,39	1			
Obveznice EM	**12**	-0,01	0,07	0,03	0,14	0,11	0,10	0,10	0,11	0,12	0,08	0,11	1		
Dionice EM	**13**	0,29	0,59	0,11	-0,07	0,86	0,88	0,06	0,16	0,78	0,48	0,87	0,13	1	
Korp obveznice EU	**14**	0,36	0,31	0,16	0,56	0,46	0,55	0,13	0,49	0,46	0,46	0,49	0,11	0,47	1

Izvor: izračun autora

Zanimljivo je pogledati i empirijske koeficijente korelacije promatranih oblika ulaganja radi uvida u intenzitet povezanosti predmetnih varijabli. Od promatranih oblika ulaganja, najviši koeficijent korelacije imaju hedge fondovi i dionice što se može obrazložiti da u promatranom indeksu hedge fondova dominiraju oni koji pretežito koriste dionička tržišta za provedbu ulagačkih strategija. Najniža odnosno negativna korelacija prisutna je između domaćih obveznica i tržišta novca, te domaćih dionica i obveznica EU. Nisku i pretežito negativnu korelaciju imaju ročnice sa svim ostalim promatranim oblicima čime se nameće zaključak da

[38] Radi većeg broja varijabli, margine stranice ne omogućavaju primjeren prikaz matrice varijanci/kovarijanci.

kao alternativni oblik imaju značajan diversifikacijski potencijal. Hedge fondovi s ostalim oblicima osim dionica imaju pretežito nisku korelaciju što znači da im se prinosi ne kreću u istom smjeru. Negativna korelacija između promatranih oblika ulaganja upućuje da se njihovi prinosi kreću u suprotnom smjeru.

Optimizacija Markowitzevim modelom započinje s optimizacijom udjela tradicionalnih oblika ulaganja. Početni portfelj se sastoji od hrvatskih obveznica, dionica i tržišta novca te se postepeno uključuju dodatni tradicionalni inozemni oblici i varijable alternativnih oblika. U optimizaciji su postavljena minimalna i maksimalna ograničenja na udjele oblika ulaganja kako bi rezultati bili što konzistentniji s realnim svijetom i omogućili praktičnu primjenu. Obzirom na strukturu obveza i investicijske ciljeve društava za osiguranje, ali i rizični tretman pojedinih oblika, u optimizaciji je postavljeno da obveznice RH čine minimalno 40-50% udjela u portfelju. Također, radi omogućavanja aplikativne primjene modela, ograničenja na udjele oblika ulaganja postavljena su na inkremente po 10% (npr. 10, 20, 30). Optimizacija je provedena na način da je za svaku kombinaciju udjela oblika ulaganja cilj minimizacija rizika sukladno preferenciji društava za osiguranje.

Tablica 24 – Rezultati optimizacije (portfelji 1-10)

Oblik ulaganja/ # portfelja	**Udjeli u portfelju**									
	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
Obveznice RH	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,4
Dionice RH	0,2	0,2	0,0	0,0	0,1	0,2	0,0	0,0	0,1	0,1
Novac	0,3	0,1	0,2	0,2	0,2	0,1	0,2	0,2	0,2	0,1
Hedge fondovi	0,0	0,0	0,0	0,0	0,0	0,1	0,2	0,1	0,1	0,1
Ročnice	0,0	0,0	0,0	0,0	0,0	0,1	0,1	0,2	0,1	0,1
Obveznice EU	0,0	0,1	0,2	0,1	0,1	0,0	0,0	0,0	0,0	0,1
Dionice EU	0,0	0,1	0,1	0,2	0,1	0,0	0,0	0,0	0,0	0,1
Momenti i mjere efikasnosti										
Prinos	0,0017	0,0018	0,0023	0,0020	0,0020	0,0021	0,0027	0,0025	0,0022	0,0022
StdDev	0,0165	0,0205	0,0088	0,0125	0,0140	0,0186	0,0084	0,0077	0,0121	0,0149
Asimetrija	-1,818	-2,034	-1,142	-1,508	-2,057	-1,684	-0,998	-0,335	-1,570	-1,755
Zaobljenost (Eksces)	8,976	9,156	4,400	5,272	8,818	7,584	4,238	1,492	6,309	6,425
Sharpe omjer	0,101	0,088	0,265	0,164	0,141	0,112	0,322	0,321	0,185	0,148
Sortino omjer	0,131	0,110	0,396	0,223	0,180	0,145	0,508	0,563	0,251	0,193

Izvor: izračun autora u programskom paketu R studio

U tablici 24 vidi se pregled rezultata optimizacije za simuliranih 10 portfelja variranjem udjela odabranih oblika ulaganja. Oblici uključeni u pojedini portfelj označeni su radi lakšeg praćenja

tablice. Portfelj 1 sastoji se isključivo od tradicionalnih oblika ulaganja na RH tržištu odnosno domaćih obveznica, dionica i novčanih sredstava. Portfelji 2-10 sastoje se od određenog udjela dodatnih stranih tradicionalnih i alternativnih oblika ulaganja u cilju utvrđivanja utjecaja na prinos i rizik portfelja i provedbe testiranja Hipoteze 1. Sukladno tome, portfelji 2-5 dodatno uključuju tradicionalne oblike obveznica i dionica na financijskom tržištu EU. U scenariju portfelja 2, kada se u investicijski portfelj s domaćim oblicima dodatno uključi udio po 10% svakog od stranih tradicionalnih oblika (ukupno 20%), dobiveni portfelj manje je efikasan od početnog portfelja 1. Usporedba efikasnosti portfelja provodi se korištenjem Sharpeovog i Sortinovog omjera.

Portfelji 3 i 4 uključuju ukupno 30% udjela EU obveznice i dionica, dok je s druge strane isključen udio domaćih dionica obzirom da je kompenziran s EU dionicama. Efikasnost navedenih portfelja viša je od osnovnog Portfelja 1 čime je potvrđeno da bi takva kombinacija udjela pozitivno utjecala na prinos i rizik. Najpozitivniji utjecaj vidljiv je kod portfelja 3 obzirom da ima najviši Sharpeov i Sortinov omjer.

Isti postupak proveden je kod portfelja 6-9 koji se sastoje od domaćih tradicionalnih i alternativnih oblika ulaganja. U scenariju portfelja 6, kada se u investicijski portfelj s domaćim oblicima uključi po 10% alternativnih oblika (ukupno 20%), **dobiveni portfelj efikasniji je od portfelja 1.** Isto vrijedi i za portfelj 7, 8 i 9 gdje je izmijenjena struktura udjela alternativnih oblika. Evidentno je da u usporedbi s dodatnim tradicionalnim EU oblicima ulaganja, **uključivanje alternativnih oblika ima jači pozitivni utjecaj na prinos i rizik investicijskog portfelja**. Ovakav zaključak proizlazi iz direktne međusobne usporedbe portfelja 2-5 i 6-9 gdje se variraju udjeli tradicionalnih domaćih oblika i dodatno uključuju jednaki udjeli stranih tradicionalnih i alternativnih oblika. U pogledu simuliranih portfelja, najefikasniji portfelj bio bi portfelj 7 i 8 koji sadrže 20% udjela hedge fondova i 10% ročnica i obrnuto.

Portfelj 10 proizvoljno je odabran radi provedbe nasumičnog testiranja kombinacije udjela svih promatranih oblika ulaganja. Takav portfelj bi također bio efikasniji od početnog portfelja. U tablici 25 slijedi pregled rezultata optimizacije kada se u portfelj uključuju dodatni tradicionalni oblici stranih obveznica i dionica SAD-a i globalnog tržišta kapitala.

Tablica 25 - Rezultati optimizacije (portfelji 11-19)

Oblik ulaganja/ # portfelja	Udjeli u portfelju								
	11	**12**	**13**	**14**	**15**	**16**	**17**	**18**	**19**
Obveznice RH	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,4
Dionice RH	0,2	0,0	0,0	0,1	0,2	0,0	0,0	0,1	0,1
Novac	0,1	0,2	0,2	0,2	0,1	0,2	0,2	0,2	0,1
Obveznice SAD	0,0	0,0	0,0	0,0	0,1	0,2	0,1	0,1	0,1
Dionice SAD	0,0	0,0	0,0	0,0	0,1	0,1	0,2	0,1	0,1
Obveznice Global	0,1	0,2	0,1	0,1	0,0	0,0	0,0	0,0	0,1
Dionice Global	0,1	0,1	0,2	0,1	0,0	0,0	0,0	0,0	0,1
Momenti i mjere efikasnosti									
Prinos	0,0021	0,0026	0,0026	0,0023	0,0025	0,0029	0,0032	0,0026	0,0028
StdDev	0,0207	0,0097	0,0125	0,0142	0,0202	0,0085	0,0121	0,0136	0,0171
Asimetrija	-1,951	-1,040	-1,366	-1,937	-2,045	-1,230	-1,283	-2,040	-1,906
Zaobljenost (Eksces)	9,077	4,953	5,265	8,736	9,257	6,075	4,939	8,856	7,894
Sharpe omjer	0,103	0,269	0,210	0,160	0,122	0,349	0,262	0,189	0,167
Sortino omjer	0,130	0,414	0,299	0,210	0,155	0,547	0,382	0,249	0,219

Izvor: izračun autora u programskom paketu R studio

U portfeljima 11-19 testiran je utjecaj uključivanja dodatnih tradicionalnih stranih oblika ulaganja koji se odnose na obveznice i dionice SAD-a i globalnog financijskog tržišta. Simulacije portfelja s uključenim udjelima dodatnih tradicionalnih oblika provedene su na istoj osnovi kao i kod tablice s portfeljima alternativnih oblika te obveznica i dionica EU. Sukladno tome, potrebno je zasebno promatrati portfelje 11-14 i 15-18. U pogledu obveznica i dionica globalnog financijskog tržišta, njihovo uključivanje u manjoj mjeri unapređuje efikasnost početnog portfelja 1 koji se sastoji isključivo od tradicionalnih oblika ulaganja na RH tržištu, ali usporedbom s rezultatima uključivanja alternativnih oblika ne dobiva se efikasniji portfelj.

S druge strane, zanimljivu sliku daju rezultati testiranja uključivanja obveznica i dionica SAD-a. Naime, njihovo uključivanje unapređuje osnovni portfelj 1, dok su određeni portfelji efikasniji od onih dobivenih uključivanjem alternativnih oblika. Primjerice, portfelji 15 i 16 efikasniji su od portfelja 6 i 7 gdje je udio 20% hedge fondova, ali portfelj 17 manje je efikasan od portfelja 8 gdje je udio 20% ročnica. Portfelji 18 i 9 daju podijeljene rezultate u smislu da prvi ima bolji Sharpeov omjer (0,189) dok potonji ima viši Sortinov omjer (0,251). Iz rezultata optimizacije u ovom dijelu može se vidjeti da su obveznice i dionice SAD-a jedini „konkurent“ promatranim alternativnim oblicima, s time da dobiveni portfelji ne pokazuju velike razlike u

efikasnosti. Bitno je svakako naglasiti da portfelj 8 s udjelom od 20% ročnica i 10% hedge fondova ima najbolji Sortinov omjer od svih testiranih portfelja.

Portfelj 19 proizvoljno je odabran radi provedbe nasumičnog testiranja kombinacije udjela svih promatranih oblika ulaganja i efikasniji je od početnog portfelja 1. U tablici 26 nalazi se pregled rezultata optimizacije kada se u portfelj uključuju dodatni tradicionalni oblici stranih obveznica i dionica tržišta u razvoju (eng. *emerging markets-EM*) i korporativnih obveznica EU .

Tablica 26 - Rezultati optimizacije (portfelji 21-28)

Oblik ulaganja/# portfelja	**Udjeli u portfelju**							
	21	**22**	**23**	**24**	**25**	**26**	**27**	**28**
Obveznice RH	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5
Dionice RH	0,2	0,0	0,0	0,1	0,2	0,1	0,1	0,1
Novac	0,1	0,2	0,2	0,2	0,1	0,1	0,2	0,1
Obveznice EM	0,1	0,2	0,1	0,1	0,0	0,0	0,0	0,1
Dionice EM	0,1	0,1	0,2	0,1	0,0	0,0	0,0	0,1
Korp obveznice EU	0,0	0,0	0,0	0,0	0,2	0,3	0,2	0,1
Momenti i mjere efikasnosti								
Prinos	0,0011	0,0010	0,0016	0,0013	0,0020	0,0023	0,0022	0,0015
StdDev	0,0261	0,0245	0,0207	0,0202	0,0184	0,0127	0,0118	0,0208
Asimetrija	-2,916	-8,951	-3,486	-3,832	-1,921	-1,904	-1,872	-3,640
Zaobljenost (Eksces)	1,483	9,967	2,218	2,431	8,836	7,882	8,005	2,189
Sharpe omjer	0,043	0,039	0,075	0,064	0,110	0,184	0,185	0,070
Sortino omjer	0,051	0,042	0,090	0,075	0,140	0,242	0,245	0,082

Izvor: izračun autora u programskom paketu R studio

U portfeljima 21-28 testiran je utjecaj uključivanja dodatnih tradicionalnih stranih oblika ulaganja koji se odnose na obveznice i dionice tržišta u razvoju i korporativnih obveznica EU financijskog tržišta. Simulacije portfelja s uključenim udjelima dodatnih oblika provedene su na istoj osnovi kao i kod prethodnih tablica gdje su prikazani portfelji 1-20. Sukladno tome, potrebno je zasebno promatrati portfelje 21-24 i 25-27. U pogledu obveznica i dionica tržišta u razvoju (eng. *emerging markets*), njihovo uključivanje ne unapređuje efikasnost početnog portfelja 1 koji se sastoji isključivo od tradicionalnih oblika ulaganja na RH tržištu, a što je vidljivo iz dobivenih rezultata testiranja za portfelj 21-24. Uključivanje korporativnih obveznica EU u visini udjela do 20% umjesto 20% udjela novca donekle unapređuje osnovni Sharpe i Sortino omjer u odnosu na portfelj 1. Podizanje efikasnosti je zamjetnije kod portfelja 26 gdje je udio EU korporativnih obveznica podignut na 30%, a sličan rezultat dobiven je kod portfelja 27 gdje je udio stranih obveznica 20%, ali su promijenjeni udjeli domaćih dionica i

novca. Portfelj 28 koji sadrži sve promatrane oblike ulaganja ne unapređuje efikasnost u odnosu na početni portfelj 1. Drugim riječima, niti jedan od testiranih portfelja iz tablice 26 ne ukazuje na bolju efikasnost portfelja, mjerenu Sharpe i Sortino omjerom, u usporedbi s portfeljima 6-9 gdje su uključeni alternativni oblici.

Rezultati optimizacije kombinacije domaćih i stranih tradicionalnih te alternativnih oblika ulaganja ukazuju da gotovo kod svih kombinacija uključivanje alternativnih oblika ima jači pozitivan utjecaj na prinos i rizik investicijskog portfelja odnosno njegovu efikasnost mjerenu preko Sharpe i Sortino omjera. Iznimka su dionice i obveznice SAD-a gdje 2 promatrana portfelja imaju višu efikasnost od onih koji uključuju alternativna ulaganja, ali uzimajući u obzir cjelokupne rezultate, takva pojava više se može smatrati iznimkom nego pravilom.

Sukladno navedenom, **Hipoteza 1 može se smatrati potvrđenom**.

5.4. Optimizacija pomoću Višekriterijskog modela (Hipoteza 2)

Optimizacija portfelja opisanim višekriterijskim modelom provodi se u dvije faze. U prvoj fazi zasebno su optimizirani problemi optimizacije svakog od prva četiri središnja momenta distribucije odnosno maksimizacije očekivanog prinosa, minimizacije varijance tj. standardne devijacije, maksimizacije koeficijenta asimetrije te minimizacije koeficijenta zaobljenosti portfelja:

$$P_1 \begin{cases} & max\, E^*\left(R_P\right) = \sum_{i=1}^{I} w_i E\left(R_i\right) \\ uz\ ograničenje & \\ & \sum_{i=1}^{I} w_i = 1 \\ & w_i \geq 0, \quad i = 1,2,...,I. \end{cases}$$

$$P_2 \begin{cases} & min\, \sigma_P^{2*} = \sum_{i=1}^{I}\sum_{j=1}^{I} w_i w_j \sigma_{ij} \\ uz\ ograničenje & \\ & \sum_{i=1}^{I} w_i = 1 \\ & w_i \geq 0, \quad i = 1,2,...,I. \end{cases}$$

$$P_3\begin{cases} & max\, S_P^* = \dfrac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I} w_i w_j w_k s_{ijk}}{\sigma_P^3} \\ uz\ ograničenje & \\ & \sum_{i=1}^{I} w_i = 1 \\ & w_i \geq 0, \quad i = 1,2,...,I. \end{cases}$$

i

$$P_4\begin{cases} & min\, K_P^* = \dfrac{\sum_{i=1}^{I}\sum_{j=1}^{I}\sum_{k=1}^{I}\sum_{l=1}^{I} w_i w_j w_k w_k k_{ijkl}}{\sigma_P^4} \\ uz\ ograničenje & \\ & \sum_{i=1}^{I} w_i = 1 \\ & w_i \geq 0, \quad i = 1,2,...,I. \end{cases} \qquad (5.18)$$

Temeljem četiri zasebna problema optimizacije dobivena je efikasna točka, koja je polazište za drugu fazu optimizacije:

$$(E^*(R_P), \sigma_P^{2*}, S_{Pr}^*, K_{Pr}^*) = (0.0031, 0.006, -0.352, 0.481).$$

Dakle, efikasna točka sastoji se od maksimalnog mogućeg prinosa, minimalne moguće varijance (tj. standardne devijacije), maksimalnog koeficijenta asimetrije te minimalnog koeficijenta zaobljenosti portfelja. Potrebno je napomenuti da se u slučaju koeficijenta asimetrije i zaobljenosti ne radi o globalnom ekstremu. Naime, postizanje ekstremne vrijednosti odnosno maksimalne asimetrije i minimalne zaobljenosti nije bilo moguće obzirom na definirana ograničenja a koja su postavljena u cilju omogućavanja direktne usporedivosti rezultata provedbe Markowitzeve i višekriterijske optimizacije odnosno testiranja Hipoteze H2. Također, za provedbu prve faze višekriterijske optimizacije primijenjen je klasičan model optimizacije, dok se u drugoj fazi koristio višekriterijski model.

Rezultati prve faze višekriterijske optimizacije dani su u tablici 27 u nastavku gdje su prikazani ekstremi vrijednosti pojedinih problema optimizacije i vrijednosti ostalih momenata. Vidljivo je da su pojedini moment ili najveći ili najmanji u odnosu na ostale probleme optimizacije, a radi čega dolazi do materijalnog pogoršanja vrijednosti ostalih momenata distribucije. U postupku prve faze višekriterijske optimizacije uključena su ograničenja na minimalne i maksimalne udjele oblika ulaganja u cilju postizanja disperzije investicijskog miksa koji ne odstupa značajno od realističnih portfelja u investicijskog praksi. Sukladno tome, postavljeno je ograničenje gdje udio pojedinog oblika može činiti maksimalno 20% portfelja.

Potrebno je naglasiti da je u (višekriterijsku) optimizaciju uključeno 14 varijabli, stoga je bilo potrebno izračunati ukupno 210 koeficijenata (ko)varijance, 560 koeficijenata (ko)asimetrije i 2380 koeficijenata (ko)zaobljenosti. Broj potrebnih izračuna povećava složenost provedbe optimizacije radi čega je korištenje programskog paketa R primjereno u rješavanju ovakvih kompleksnih analiza.

Tablica 27 – Vrijednosti momenata 4 portfelja dobivenih optimizacijom iz prve faze (P_1-P_4)

Momenti	**Portfelj**			
	1 (MAX prinos)	**2 (MIN rizik)**	**3 (MAX asimetrija)**	**4 (MIN zaobljenost)**
Prinos	0,0031	0,0029	0,0027	0,0026
Std.Dev.	0,032	0,006	0,007	0,008
Asimetrija	-4,092	-0,646	-0,352	-0,365
Zaobljenost (Eksces)	3,130	1,979	0,705	0,481

Izvor: izračun autora u programskom paketu R studio

U tablici 28 vidljiva je struktura udjela optimiziranih portfelja iz prve faze optimizacije. Može se uočiti kako se struktura sva četiri portfelja značajno razlikuje, s obzirom na zahtjeve koje investitor nameće na same momente portfelja.

Tablica 28 - Struktura udjela oblika ulaganja u portfeljima dobivenih optimizacijom problema P_1 – P_4 (prva faza)

Oblik ulaganja	**Udjeli**			
	P_1	P_2	P_3	P_4
	MAX prinos	**MIN rizik**	**MAX asim.**	**MIN zaob.**
Obveznice RH	0,00	**0,20**	**0,18**	**0,18**
Dionice RH	0,00	0,00	**0,01**	0,00
Novac	0,00	**0,20**	**0,19**	**0,17**
Hedge fondovi	**0,20**	**0,08**	**0,06**	0,00
Ročnice	0,00	**0,09**	**0,20**	**0,18**
Obveznice EU	0,00	**0,20**	**0,12**	**0,16**
Dionice EU	0,00	0,00	0,00	**0,03**
Obveznice SAD	**0,20**	**0,20**	**0,18**	**0,13**
Dionice SAD	**0,20**	0,00	**0,01**	0,00
Obveznice Global	0,00	0,00	**0,04**	**0,12**
Dionice Global	**0,20**	0,00	0,00	**0,02**
Obveznice EM	**0,20**	0,00	**0,00**	**0,01**
Dionice EM	0,00	0,00	**0,00**	**0,00**
Korp. obveznice EU	0,00	**0,03**	**0,01**	**0,00**
Total	**1,00**	**1,00**	**1,00**	**1,00**

Izvor: izračun autora u programskom paketu R studio

Kada bi investitor preferirao maksimizaciju očekivanog prinosa (tj. portfelj P_1), tada bi svoja investicijska sredstva alocirao u jednakim omjerima na hedge fondove, obveznice i dionice SAD-a, te globalne dionice i obveznice tržišta u razvoju. S druge strane, tražeći kombinaciju oblika ulaganja koja će minimizirati rizik dolazi do promjene u strukturi portfelja i dodatne disperzije udjela. Primjerice, u portfelj P_2 s najnižom standardnom devijacijom uključene su domaće obveznice (20%) i novčana sredstva (20%), alternativni oblici (s ukupno 17% udjela) te korporativne (3%) i državne obveznice EU (20%) i SAD-a (20%).

Kod portfelja P_3, s maksimalnom asimetrijom, dolazi do dodatne disperzije udjela na više oblika ulaganja osim dionica EU i globalnog tržišta. Zanimljivo je da najveći maksimalni udio zauzimaju upravljane ročnice (20%) i novčana sredstva (19%), te obveznice RH (18%) i SAD-a (18%). Zamjetan dio portfelja s maksimalnom asimetrijom uložio bi se i u hedge fondove (6%). U portfelj su uključeni i zanemarivi udjeli pojedinih oblika (npr. obveznice i dionice tržišta u razvoju).

Portfelj P_4, kojeg karakterizira najniži koeficijent zaobljenosti, ima određenih sličnosti u pogledu strukture oblika ulaganja s portfeljem P_3. Primjerice, oblici s najvećim udjelom kod portfelja s maksimalnom asimetrijom slični su kao i kod portfelja s minimalnom zaobljenosti. Najveće razlike u odnosu na portfelj P_3 vidljive su u zamjetno većem udjelu obveznica i dionica globalnih i EU financijskih tržišta, a na račun smanjenog udjela obveznica i dionica SAD-a.

Generalan komentar na rezultate prve faze višekriterijske optimizacije bio bi da dionice svih promatranih tržišta, osim u portfelju P_1 gdje se maksimizirao prinos, nemaju materijalan udio u portfelju. S druge strane, alternativni oblici ulaganja čine značajan udio svakog portfelja te njihov raspon udjela varira od 17-26%.

Nakon prve, provedena je druga faza višekriterijske optimizacije. U njoj se minimizirala udaljenost od efikasne točke $(E^*(R_P), \sigma_P^{2*}, S_{Pr}^*, K_{Pr}^*) = (0.0031, 0.006, -0.352, 0.481)$ pri čemu su u ovom modelu jednake težine dodijeljene svakome momentu ($\lambda_1 = \lambda_2 = \lambda_3 = \lambda_4 = 1$). Višekriterijski model omogućava promjenu preferencija kako bi se veću težinu stavilo na određeni moment sukladno investitorovim preferencijama.

Rezultati druge faze optimizacije su dani u tablici 29. Dobivena je točka $(E(R_P), \sigma_P^2, S_{Pr}, K_{Pr}) = (0.0031, 0.007, -1.229, 4.688)$, te su prikazane pojedine udaljenosti dobivenih momenata u odnosu na efikasnu točku. Najveća udaljenost od referentne točke

očituje se u koeficijentu zaobljenosti, dok se najmanja udaljenost očituje u prinosu i standardnoj devijaciji te iznosi gotovo 0.

Tablica 29 – Vrijednosti momenata optimalnog portfelja dobivenog višekriterijskom optimizacijom (druga faza) – MVSK portfelj[39]

Momenti		**Udaljenost**	
Prinos	0,0031	d_1	0,00002
StdDev	0,007	d_2	0,00049
Asimetrija	-1,229	d_3	0,87784
Zaobljenost (Eksces)	4,688	d_4	4,20720

Izvor: izračun autora u programskom paketu R studio

Za provedbu višekriterijske optimizacije koristi se R programski paket *MVSK portfolios* koji omogućava direktnu optimizaciju prva četiri središnja momenta bez provedbe 1. koraka optimizacije u kojem se traže ekstremne vrijednosti maksimalnog prinosa i asimetrije te minimalne varijance tj. standardne devijacije i zaobljenosti.

U tablici 30 prikazana je struktura dobivenog, tzv. MVSK optimalnog portfelja. Najveći udio čine domaće obveznice RH (18%) i novčana sredstva (20%), potom alternativni oblici odnosno hedge fondovi (18%) i ročnice (2%). Značajan udio u portfelju zauzimaju i obveznice EU i SAD (po 20%). Određeni manji udio u portfelju imaju još globalne obveznice (2%). U portfelju optimiziranom pomoću višekriterijskog modela nema udjela dionica čije su mjesto zauzeli alternativni oblici radi povoljnijih vrijednosti viših momenata.

Tablica 30 - Struktura optimalnog portfelja[40] dobivenog višekriterijskom optimizacijom (2. faza)

Oblik ulaganja	**MVSK**
	Udio
Obveznice RH	**0,18**
Dionice RH	0,00
Novac	**0,20**
Hedge fondovi	**0,18**
Ročnice	**0,02**
Obveznice EU	**0,20**
Dionice EU	0,00
Obveznice SAD	**0,20**
Dionice SAD	0,00
Obveznice Global	**0,02**

[39] eng. *Mean-Variance-Skewness-Kurtosis* (MVSK).
[40] Odnosi se na portfelj s najvišom Omega omjerom efikasnosti.

Oblik ulaganja	MVSK
	Udio
Dionice Global	0,00
Obveznice EM	0,00
Dionice EM	0,00
Korp. obveznice EU	0,00
Ukupno	**1,00**

Izvor: izračun autora u programskom paketu R studio

Kako bi se ocijenila efikasnost MVSK portfelja korištena je tzv. Omega mjera efikasnosti koju su prvu predstavili Keating i Shadwick (2002). Omega mjera je primjerena za procjenu efikasnosti portfelja u slučajevima kada distribucija prinosa portfelja ne slijedi normalni oblik. Mjera je dodatno korištena u radovima Bhaduri et al. (2005) i Abrams et al. (2012, 2014). Veća vrijednost Omega mjere ukazuje na veću efikasnost portfelja.

Direktna usporedba portfelja korištenjem Markowitzeve i višekriterijske optimizacije moguća je jedino putem korištenja jednakih ograničenja na udjele uključenih oblika ulaganja u modelu. Sukladno tome, u provedbi optimizacije postavljeno je ograničenje na maksimalan udio pojedinog oblika ulaganja od 20% (tj. 0,2). Visina ograničenja odabrana je proizvoljno na način da optimizirani portfelji uključuju minimalno 5 različitih oblika ulaganja što je bliže realnoj investicijskog praksi u kojoj se teži disperziji kapitala na više raspoloživih oblika ulaganja.

Vrijednost Omega mjere MVSK portfelja i onih iz prve faze višekriterijske optimizacije gdje se koristi Markowitz optimizacija, pokazuju da je MVSK portfelj najefikasniji.

Također, test normalnosti (Jarque-Bera) pokazao je da se prinosi MVSK, MAX prinos, MIN rizik i MAX asimetrija portfelja, uz uobičajenu razinu signifikantnosti (5%), ne mogu smatrati normalno distribuiranim što potvrđuje primjerenost korištenja Omega mjere koja ne pretpostavlja normalnost distribucije. Jedino se kod portfelja MIN zaobljenost ne može odbaciti hipoteza normalnosti obzirom na p-vrijednost iz provedenog *Jarque-Bera* testa.

Usporedba i rezultati optimizacije vidljivi su u tablicama 31 i 32 u nastavku.

Tablica 31 – Rezultati Markowitzeve (MV[41]) i višekriterijske (MVSK[42]) optimizacije[43]

Opis	Višekriterijska optimizacija			Markowitz optimizacija			
	MVSK (w_o=EW)	**MVSK (w_o=DR)**	**MVSK (w_o=ERC)**	**MAX prinos**	**MIN rizik**	**MAX asim.**	**MIN zaob.**
Očekivan prinos	0,0031	0,0029	0,0029	0,0031	0,0029	0,0027	0,0026
Stand. devijacija	0,007	0,006	0,006	0,032	0,006	0,007	0,008
Asimetrija	-1,229	-0,646	-0,646	-4,092	-0,646	-0,352	-0,365
Zaobljenost (eksces)	4,688	1,979	1,979	3,130	1,979	0,705	0,481
Omega mjera[44]	**3,536**	3,394	3,394	1,390	3,394	2,738	2,373
Jarque-Bera	210,18	41,88	41,89	575,80	41,89	7,44	5,73
p-vrijednost	0,000	0,000	0,000	0,000	0,000	0,024	0,057

Izvor: izračun autora u programskom paketu R studio

U provedbi višekriterijske optimizacije, R programski paket (eng. *library*) *MVSK portfolios* omogućava podešavanja odnosno kalibraciju početnih postavki za provedbu optimizacije. Kalibracija tzv. MVSK optimizacije u R programu zahtijeva da investitor definira kriterij optimalnosti $h_{\text{ref}}(\cdot)$ za koji je $\mathbf{w}_0$ optimalno rješenje. Predmetni kriterij je funkcija udjela portfelja $\mathbf{w}$, te momenata prinosa oblika ulaganja $\boldsymbol{\mu}$, $\boldsymbol{\Sigma}$, $\boldsymbol{\Phi}$ i $\boldsymbol{\Psi}$ koji se odnose na očekivani prinos, varijancu (tj. standardnu devijaciju), asimetriju i zaobljenost. Najjednostavniji kriterij optimalnosti je volatilnost pogreške praćenja (eng. *tracking error volatility, tzv. TEvol*) koja predstavlja volatilnost razlike udjela u sastavu optimiziranog portfelja ($\mathbf{w}$) u odnosu na optimalni portfelj ($\mathbf{w}_0$). Volatilnost pogreške praćenja minimizirana je kada su udjeli optimiziranog portfelja jednaki optimalnom odnosno $\mathbf{w} = \mathbf{w}_0$ (Boudt et al., 2020).

Ostali kriteriji optimalnosti koji se mogu koristiti u višekriterijskom modelu odnose se na Herfindahlov indeks koji se minimizira s jednakim udjelima portfelja (eng. *equally-weighted portfolio*). DeMiguel et al. (2009) ovaj portfelj nazivaju alokacijom $1/N$. Portfelj koristi naivan pristup diversifikaciji jer zanemaruje heterogenost komponenti u distribuciji prinosa prilikom optimizacije udjela. Ovaj kriterij se u R programu *MVSK portfolios* definira kao h_{ref}(EW). Jedan od mogućih kriterija za optimalnost je i kriterij kontribucije volatilnosti pojedinog oblika ulaganja i. Rješenje optimizacije je portfelj gdje udio svakog oblika predstavlja jednaku rizičnu kontribuciju (eng. *equal-risk contribution*) ukupnom riziku portfelja (Maillard et al., 2010) te se označava s h_{ref} (ERC). Lee (2011) analizira više pristupa alokacije imovine baziranoj na rizicima te ističe pristup kontribucije rizika kao potencijalno više primjenjiv u odnosu na ostale.

[41] eng. *Mean-Variance* (MV).
[42] Ibid. str. 135, fusnota 39
[43] Ograničenje maksimalnog udjela pojedinog oblika u provedbi optimizacije iznosi 20% (0,2).
[44] Prag gubitka postavljen na 0 sukladno početnim postavkama Omega funkcije u R studio.

Kriterij optimalnosti može biti i diversifikacijski omjer (eng. *diversification ratio*) kojeg su definirali (Choueifaty i Coignard, 2008), a u kojemu razmatraju odnos prosječne standardne devijacije vrijednosnica u portfelju i standardne devijacije portfelja. Ovaj kriterij u R programu *MVSK portfolios* označava se s h_{ref} (DR) te je korišten i u radu (Boudt et al., 2020).

Kod rezultata višekriterijske optimizacije, u cilju ekstenzivnog testiranja Hipoteze H2, korišteni su svi navedeni argumenti optimalnog portfelja $\mathbf{w}_0$ (EW, DR i ERC). Takav pristup omogućio je i usporedbu rezultata po mogućim parametrima višekriterijske optimizacije u korištenom R paketu. Za kriterij optimalnosti koristio se argument h_{ref} (TE_{vol}) odnosno volatilnost pogreške praćenja.

U cilju postizanja dodatne mjerodavnosti rezultata testiranja hipoteze H2, opisani postupak višekriterijske i Markowitzeve optimizacije ponovljen je s različitim visinama ograničenja udjela na oblike ulaganja, a dobiveni rezultati vidljivi su u tablici 32. Označene su najviše vrijednosti Omega mjere u pojedinom razredu ograničenja.

Tablica 32 – Rezultati optimizacije primjenom ograničenja udjela na oblike ulaganja

Opis	Ograničenje udjela na oblik ulaganja	**Višekriterijska optimizacija**			**Markowitz optimizacija**			
		MVSK (w_0=EW)	**MVSK (w_0=DR)**	**MVSK (w_0=ERC)**	**MAX prinos**	**MIN rizik**	**MAX asim.**	**MIN zaob.**
Omega mjera	Max 10%	1,929	1,929	**1,930**	1,483	1,929	1,799	1,749
	Max 15%	**3,056**	2,957	3,018	1,527	2,957	2,178	2,296
	Max 20%	**3,536**	3,394	3,394	1,390	3,394	2,738	2,373
	Max 25%	3,771	3,786	**3,789**	1,297	3,786	2,609	2,535
	Max 30%	3,976	4,087	**4,088**	1,386	4,087	2,214	2,715
	Max 40%	4,097	**4,674**	4,659	1,494	4,672	2,141	3,544
	Max 50%	4,091	**5,494**	5,477	1,573	5,487	1,803	4,127

Izvor: izračun autora u programskom paketu R studio

U svim testiranim razinama ograničenja na udjele oblika ulaganja, MVSK portfelji pokazali su se efikasnijim obzirom na vrijednost Omega mjere. Također, bitno je istaknuti da su gotovo kod svih optimiziranih portfelja, i prema višekriterijskom i prema Markowitz modelu, značajan udio zauzeli i alternativni oblici ulaganja što ukazuje na njihov blagotvoran učinak na efikasnost portfelja.

Zanimljivo je istaknuti da su udjeli portfelja dobivenih višekriterijskom optimizacijom, u slučaju korištenja parametra „DR“ (diversifikacijski omjer) i „ERC“ (jednaku rizičnu kontribuciju) kao optimalnog referentnog portfelja, slični udjelima portfelja gdje je funkcija

cilja minimizirati rizik (tj. MIN rizik portfelj). Obzirom da višekriterijski model istovremeno optimizira prva 4 središnja momenta distribucije, njihova efikasnost ipak je u određenoj razini viša od „MIN rizik“ portfelja dobivenih Markowitz optimizacijom.

Sukladno rezultatima testiranja hipoteze, **Hipoteza 2 može se smatrati potvrđenom**.

5.5. Utjecaj promjene kamatnih stopa na tradicionalne i alternativne oblike ulaganja (Hipoteza 3)

Hipoteza 3 testirati će se korištenjem opće VAR metodologije, odnosno vektorskog auto regresijskog (VAR) modela. Rezultati testiranja trebali bi proširiti spoznaju o intenzitetu utjecaja promjene kamatnih stopa na prinose odabranih tradicionalnih i alternativnih oblika ulaganja. Također, utvrditi će se je li pretpostavljeni utjecaj varijabli u modelu sukladan ekonomskoj teoriji o međuodnosu kamatnih stopa i tradicionalnih oblika ulaganja, posebno obveznica.

Ekonomska teorija i logika pretpostavlja određen smjer i intenzitet povezanosti makroekonomskih varijabli i financijskih tržišta odnosno u ovom slučaju promjene kamatnih stopa na prinose dionica i obveznica. Naime, pretpostavlja se da bi rast kamatnih stopa trebao negativno utjecati na cijene dionica, ali i vrijednost obveznica u kratkom roku obzirom na inverzan odnos cijene obveznica i kretanja kamatne stope. U duljem roku ekonomska teorija pretpostavlja da bi rast kamatnih stopa trebao dovesti do rasta prinosa na obveznice obzirom da prinosi takvih instrumenata ovise o referentnim kamatnim stopama na financijskim tržištima. Ista pretpostavka vrijedi i za slučaj pada kamatnih stopa, s time da bi se prinosi na dionice trebali povećati jer bi investitori svoja sredstva realocirali iz obvezničkih u dionička ulaganja.

Obzirom na intenzivniji međuodnos kamatnih stopa i tradicionalnih oblika ulaganja, očekuje se da promjene kamatnih stopa imaju slabiji utjecaj na promjenu prinosa alternativnih oblika poput hedge fondova i ročnica. Testiranjem hipoteze H3 nastoji se ukazati na manju osjetljivost prinosa alternativnih oblika na efekte promjene kamatnih stopa u odnosu na tradicionalne, a što za posljedicu ima smanjenje izloženosti riziku nagle promjene kamatnih stopa.

Varijable oblika ulaganja koje će se koristiti u modelu su dionice i obveznice RH kao tradicionalni oblici te hedge fondovi i ročnice kao alternativni oblici[45]. Varijabla kamatnih stopa

[45] Detaljnije informacije o varijablama oblika ulaganja navedene su u poglavlju 5.1.

reprezentirana je preko mjesečnih promjena 3-mjesečnog EURIBOR-a. Kvantitativni podaci o varijablama odnose se na mjesečne frekvencije u periodu siječanj 2006. – prosinac 2020. godine s ukupno 180 opažanja. Svi izračuni vezani uz VAR analizu provedeni su u programu R studio koristeći relevantne pakete (eng. *library*).

Korištenjem službenog alata Eurostata za desezoniranje (JDemetra+), kod svih varijabli testirana je eventualna prisutnost sezonske komponente vremenskih serija. Rezultati testa sezonalnosti ukazuju da nema prisutne sezonske komponente niti u jednoj promatranoj varijabli.

Potrebno je istaknuti da je u pretraživanju literature, u kontekstu utjecaja makroekonomskih varijabli na prinose oblike ulaganja, evidentiran oskudan broj domaćih znanstvenih radova koji se bave ovom problematikom, posebice kada su u pitanju i alternativni oblici ulaganja. Od relevantnih domaćih istraživanja izdvaja se rad (Jakšić, 2008) u kojem je provedena analiza utjecaja monetarnog agregata M4 i kamatnih stopa na CROBEX primjenom kointegracijskog pristupa Johansena. U radu je utvrđeno da postoji povezanost varijabli u dugom roku. Varijable za reprezentaciju kamatnih stopa bile su kamatne stope na dugoročne kredite trgovačkim društvima u kunama s valutnom klauzulom. Period analize je 02/2000-05/2007 uz mjesečnu frekvenciju podataka.

Anđelinović (2011) analizira utjecaj makroekonomskih varijabli (industrijska proizvodnja, monetarni agregat M1, inflacija) na prinose i rizičnost imovinskih razreda (dionice i obveznice RH, obveznice EU, novac RH) koristeći VAR metodologiju. Rezultati VAR analize u većini slučajeva ne pokazuju Grangerovu uzročnost tj. nije dokazano da kretanje odabranih makroekonomskih varijabli i ekonomskih ciklusa prethodi kretanju prinosa i rizičnosti odabranih imovinskih razreda. Period analize je 2000-2010 uz mjesečnu frekvenciju podataka.

Ehrmann et al. (2011) analiziraju i procjenjuju međunarodne financijske transmisije između oblika ulaganja koji se odnose na novac, obveznice, dionice i valutni tečaj u SAD-u i europodručju. Autori zaključuju da prinosi oblika ulaganja najsnažnije reagiraju na šokove u prinosima drugih domaćih oblika.

Benigno i Lapeña (2016) istražuju povezanost između promjena prinosa 10-godišnjih državnih obveznica i prinosa dionica u 14 razvijenih zemalja u razdoblju 1999.-2015. Empirijski rezultati ukazali su na značajnu heterogenost promatranih zemalja u pogledu veze između kamatnih stopa i dioničkog tržišta.

Lütkepohl i Netšunajev (2018) koriste kointegrirani strukturni vektorski autoregresivni model za istraživanje odnosa između monetarne politike u eurozoni i dioničkih tržišta. Rezultati modela ukazuju da šokovi kontrakcijske monetarne politike dovode do dugotrajnog pada cijena dionica. Period analize je 01/1999-12/2014 uz mjesečnu frekvenciju podataka. Jareño et al. (2019) istražuju utjecaj promjene u razini, nagibu i zaobljenosti krivulje kamatnih stopa na dioničke sektorske indekse SAD-a uz primjenu asimetričnog nelinearnog kointegracijskog pristupa.

Vektorski autoregresijski model (u nastavku: VAR) može se definirati kao (Guidolin i Pedio, 2018): VAR(*p*) je proces koji se može zapisati na sljedeći način:

$$y_t = a_0 + A_1 y_{t-1} + A_2 y_{t-2} + \ldots + A_p y_{t-p} + \varepsilon_t = a_0 + \sum_{i=1}^{p} A_i y_{t-i} + \varepsilon_t, \qquad (5.19.)$$

gdje je $\boldsymbol{y}t = [y1t\ y2t\ \ldots\ yNt]'$ *N*-dimenzionalni vektor koji sadrži *N* endogenih stacionarnih varijabli, $\boldsymbol{a}0 = [a10\ a20\ \ldots\ aN0]'$ je *N*-dimenzionalni vektor konstanti, $\boldsymbol{A}1$, $\boldsymbol{A}2$, … , $\boldsymbol{A}p$ su $N \cdot N$ matrice autoregresijskih koeficijenata te je $\boldsymbol{\varepsilon}t = [\varepsilon 1t\ \varepsilon 2t\ \ldots\ \varepsilon Nt]'$ vektor slučajnih procesa.

Početak svake VAR analize je testiranje stacionarnosti varijabli za što je potrebno provesti testove jediničnoga korijena (eng. *unit root test*). U provedbi testiranja stacionarnosti, koristiti će se *Phillips Perron* test u kojem nije potrebno specificirati broj pomaka i prošireni *Dickey-Fullerov* test (eng. *Augmented Dickey Fuller* test, ADF). Oba testa su robusna na način da ADF rješava autokorelaciju kroz pomake, a *Phillips-Perronov* test provodi neparametarsku korekciju testne veličine.

Nulta hipoteza oba testa je nestacionarnost varijable, tj. pretpostavlja da varijabla ima jedinični korijen dok alternativna hipoteza pretpostavlja stacionarnost, odnosno da varijabla nema jedinični korijen.

Tablica 33 – Rezultati testiranja stacionarnosti varijabli

Varijabla	Test veličina (PP test)	Test veličina (ADF test)	p-vrijednost (PP test)	p-vrijednost (ADF test)
EURIBOR	-113,630	-3,359	0,01	0,063
CROBIStr	-145,210	-4,705	0,01	0,01
CROBEXtr	-147,720	-5,500	0,01	0,01
Hedge fund	-139,030	-4,939	0,01	0,01
Managed futures	-168,670	-5,677	0,01	0,01

Izvor: izračun autora u programskom paketu R studio

Rezultati testiranja stacionarnosti ukazuju da su, na razini signifikantnosti od 5%, sve promatrane varijable stacionarne obzirom na test veličine i p-vrijednost provedenih testova koji ukazuju na odbacivanje nulte hipoteze o nestacionarnosti. Iznimka je varijabla EURIBOR, za koju se nulta hipoteza o nestacionarnosti može odbaciti na razini signifikantnosti 10%.

Ukoliko se kod ADF testa varijable EURIBOR odredi duljina pomaka (k=1), p-vrijednost u tom slučaju iznosi 0,01 i nulta hipoteza se može odbaciti[46]. Također, ukoliko se uzme u obzir rezultat *Phillips Perron* testa, vidljivo je da se nulta hipoteza za varijablu EURIBOR može odbaciti te se vremenski niz ipak može smatrati stacionarnim. Nakon utvrđivanja reda integracije analiziranih vremenskih nizova, može se provesti daljnja VAR analiza.

Procjena VAR modela provedena je u programu R studio. Korištenjem relevantnih funkcija potrebno je povezati vremenske nizove promatranih varijabli nakon čega je potrebno odrediti adekvatan broj pomaka *p* (eng. *lagova*) u modelu. U cilju odabira duljine pomaka koristi se R funkcija „VARselect" koja automatski generira preferirani redoslijed pomaka na temelju multivarijatne iteracije standardnih informacijskih kriterija: Akaike informacijski kriterij (AIC), Schwartzov informacijski kriterij (SC), Hannan-Quinnov informacijski kriterij (HQIC) i FPE kriterij (eng. *final prediction error*).

Provedbom navedene R funkcije prijedlog duljine pomaka iznosi 1 na temelju rezultata informacijskih kriterija. Idući korak je procjena VAR (1) modela za što se koristi R funkcija „VAR" u kojoj se određuje predložena duljina pomaka (1). Model se odnosi na klasični opći oblik VAR modela (eng. *general unrestricted Vector AutoRegression model*) s konstantom bez specifikacije egzogene varijable u sustavu.

Obzirom na opsežnost procijenjenog VAR modela, nisu prikazani svi rezultati procjene modela već samo oni za varijablu kamatnih stopa. Bitno je naglasiti da su sve svojstvene vrijednosti modela po apsolutnoj vrijednosti manje od 1 što ukazuje da je model stabilan. Obično se ne interpretiraju koeficijenti VAR-a, već se interpretiraju rezultati aplikacije modela. No, ukoliko se pogledaju samo koeficijenti VAR modela za svaku varijablu, vidljivo je da varijabla EURIBOR, koja predstavlja promjene kamatnih stopa, jače utječe na ostale varijable modela u kratkom roku u odnosu na utjecaj ostalih varijabli na varijabli EURIBOR. U tablici 34 prikazani su rezultati procjene VAR modela, ali samo za varijablu kamatnih stopa (tj. EURIBOR).

[46] Rezultati ispitivanja informacijskih kriterija za VAR model sugeriraju korištenje pomaka od 1.

Tablica 34 - Rezultati procjene VAR(1) modela – varijabla EURIBOR

Varijabla	Estimate	Standardna pogreška	t vrijednost	Pr (>| t |)
EURIBOR	0,4137	0,0688	6,01	0,000
CROBIStr	-1,7367	1,7301	-1,00	0,32
CROBEXtr	0,1533	0,39	0,39	0,69
HedgeF	-0,7934	1,2708	-0,62	0,53
MFutures	0,6054	1,0315	0,59	0,56
const	-0,0339	0,0205	-1,65	0,10

Izvor: izračun autora u programskom paketu R studio

Varijabla EURIBOR statistički je značajna u modelu na što nam ukazuje pripadna t-vrijednost.

Nakon procjene modela potrebno je provesti inovacijsku analizu koja započinje s provedbom Grangerovog testa uzročnosti svake individualne varijable u modelu u odnosu na ostale varijable. Cilj Grangerovog testa je definiranje poretka varijabli u funkciji impulsnoga odziva i dekompoziciji varijance. Uzročnost u Grangerovom smislu ne znači nužno da jedna varijabla uzrokuje drugu, već da uključivanje prethodnih vrijednosti varijable A u opisivanje dinamike varijable B doprinosi boljem opisivanju te dinamike.

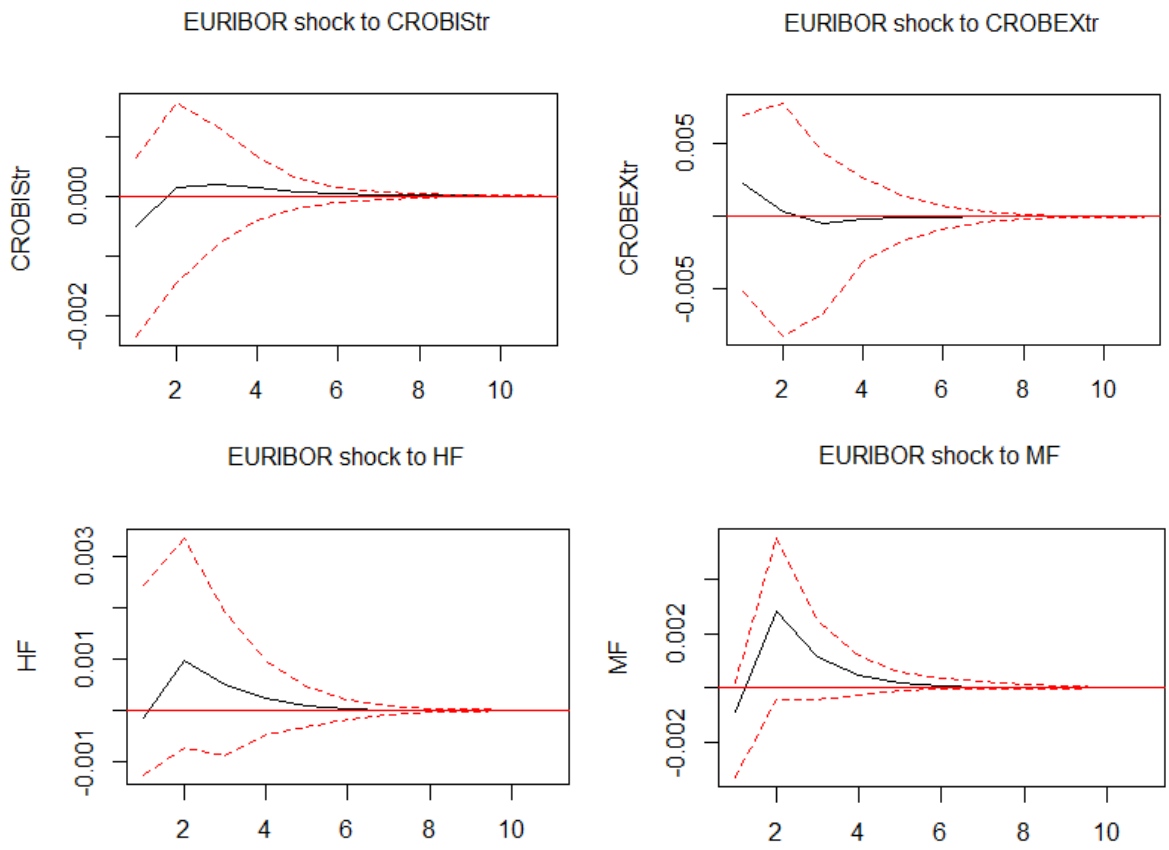
Tablica 35 – Rezultati Grangerovog testa uzročnosti za VAR(1) model

Varijabla	Test veličina (F-test)	p-vrijednost	Interpretacija
EURIBOR	1,24	0,29	ne možemo odbaciti H_0
CROBIStr	1,36	0,26	ne možemo odbaciti H_0
CROBEXtr	0,31	0,87	ne možemo odbaciti H_0
Hedge Fund	3,98	0,00	odbacujemo H_0
MFutures	1,48	0,21	ne možemo odbaciti H_0

Izvor: izračun autora u programskom paketu R studio

Nulta hipoteza Grangerovog testa pretpostavlja da nema uzročnosti u Grangerovom smislu. Sukladno tome, rezultati testa ukazuju da varijabla EURIBOR ne uzrokuje druge varijable u Grangerovom smislu osim varijable Hedge fondova gdje se odbacuje nulta hipoteza.

Inovacijska analiza se nastavlja s funkcijom impulsnoga odziva s kojom će se odrediti kako šokovi na pojedinim varijablama utječu na ostale varijable u modelu. Obzirom da u hipotezi H3 testiramo jačinu utjecaja kamatnih stopa na tradicionalne i alternativne oblike ulaganja, te uzimajući u obzir ekonomsku teoriju, varijabla *EURIBOR* biti će postavljena kao impulsna varijabla za sve testirane varijable. Redoslijed varijabli ostaje jednak kao i kod Grangerovog testa uzročnosti. Analiza funkcije impulsnoga odziva provedena je za sljedećih 10 mjeseci.



Slika 8 – Funkcija impulsnog odziva za model VAR (1) i šok u varijabli EURIBOR

Izvor: izračun autora u programskom paketu R studio

Šok od jedne standardne devijacije u stopi promjene kamatnih stopa ne rezultira sa značajnom reakcijom ostalih varijabli obzirom da je vrijednost 0 uključena u 95%-tni interval pouzdanosti. U tablici 36 prikazani su koeficijenti funkcije impulsnog odziva.

Tablica 36 – Koeficijenti funkcije impulsnog odziva (EURIBOR impulsna varijabla)

N	CROBISTr	CROBEXtr	Hedge Fund	MFutures
1	-0,00050632	0,00231476	-0,00014509	-0,00089154
2	0,00014389	0,00029372	0,00097661	0,00281624
3	0,00018526	-0,00052517	0,00051283	0,00112809
4	0,00013433	-0,00012119	0,00023965	0,00046064
5	0,00007289	-0,00004496	0,00009637	0,00017668
6	0,00003496	-0,00002364	0,00003613	0,00006772
7	0,00001562	-0,00001387	0,00001296	0,00002594
8	0,00000668	-0,00000758	0,00000453	0,00000996
9	0,00000278	-0,00000382	0,00000156	0,00000383
10	0,00000113	-0,00000180	0,00000053	0,00000147
11	0,00000045	-0,00000081	0,00000018	0,00000057

Izvor: izračun autora u programskom paketu R studio

Koeficijenti funkcija impulsnog odziva ukazuju da šok od jedne standardne devijacije u stopi promjene kamatnih stopa rezultira smanjenjem prinosa na domaće obveznice, hedge fondove i ročnice u prvom mjesecu, s time da od drugog mjeseca nadalje dolazi do stabilizacije učinka. S druge strane, šok u stopi promjene kamatnih stopa rezultira s kratkoročnim rastom prinosa dionica dok od trećeg mjeseca nadalje dolazi do pada prinosa.

Tablica 37 - Koeficijenti kumulativne funkcije impulsnog odziva (EURIBOR impulsna varijabla)

N	CROBIStr	CROBEXtr	Hedge Fund	MFutures
1	-0,00050632	0,00231480	-0,00014509	-0,00089154
2	-0,00036243	0,00260850	0,00083152	0,00192470
3	-0,00017717	0,00208330	0,00134435	0,00305279
4	-0,00004284	0,00196210	0,00158400	0,00351343
5	0,00003005	0,00191720	0,00168037	0,00369011
6	0,00006501	0,00189350	0,00171650	0,00375783
7	0,00008063	0,00187960	0,00172946	0,00378377
8	0,00008731	0,00187210	0,00173399	0,00379373
9	0,00009009	0,00186820	0,00173555	0,00379756
10	0,00009122	0,00186640	0,00173608	0,00379904
11	0,00009167	0,00186560	0,00173626	0,00379961

Izvor: izračun autora u programskom paketu R studio

Razmatranje kumulativnog učinka pomoću kumulativne funkcije impulsnog odziva ukazuje na stabiliziranje učinka u dugome roku što implicira da se radi o stabilnom modelu.

Pored funkcije impulsnog odziva, inovacijska analiza uključuje i dekompoziciju varijance u okviru koje se razmatra koliki udio prognostičkih pogrešaka je objašnjen šokovima u svim varijablama. Varijanca svake varijable u modelu može se raščlaniti na onaj dio koji je uzrokovan šokom u samoj toj varijabli, te dijelovima koji su posljedica šokova u drugim varijablama. Dekompozicija varijance provedena je za idućih 5 mjeseci obzirom da je utvrđeno da nakon tog perioda ne dolazi do značajne promjene u eksplanatornoj strukturi šokova pojedinih varijabli. Poredak varijabli ostaje jednak kao i kod procjene samog modela odnosno testiranja Grangerove uzročnosti i funkcije impulsnog odziva.

Tablica 38 – Dekompozicija varijance modela VAR (1) – varijabla EURIBOR

N	EURIBOR	CROBIStr	CROBEXtr	Hedge fund	MFutures
1	1,000000	0,000000	0,000000	0,000000	0,000000
2	0,991050	0,005936	0,000000	0,001370	0,001640
3	0,987170	0,008987	0,000001	0,001979	0,001859
4	0,986070	0,009852	0,000002	0,002171	0,001902
5	0,985830	0,010045	0,000002	0,002216	0,001909

Izvor: izračun autora u programskom paketu R studio

Rezultati dekompozicije varijance za varijablu EURIBOR pokazuju da je varijanca pogreške predviđanja stope promjene kamatnih stopa u prvome mjesecu objašnjena u potpunosti šokovima u toj istoj varijabli (varijabla stopa promjene kamatnih stopa u prvome mjesecu objašnjava 100% svoje varijacije). Tek u petom mjesecu šokovi u stopi promjene kamatnih stopa djelomično su pojašnjeni šokovima u varijabli domaćih obveznica (CROBIStr) i to u visini od 1%.

Tablica 39 – Dekompozicija varijance modela VAR (1) – varijabla CROBIStr

N	EURIBOR	CROBIStr	CROBEXtr	Hedge fund	MFutures
1	0,001957	0,998040	0,000000	0,000000	0,000000
2	0,001918	0,987120	0,000020	0,009686	0,001260
3	0,002138	0,985780	0,000020	0,010810	0,001253
4	0,002260	0,985560	0,000020	0,010905	0,001253
5	0,002296	0,985520	0,000020	0,010910	0,001253

Izvor: izračun autora u programskom paketu R studio

Rezultati dekompozicije varijance za varijablu CROBIStr pokazuju da varijanca pogreške predviđanja promjene prinosa obveznica RH u prvome mjesecu je objašnjena gotovo u potpunosti šokovima u toj istoj varijabli. Tek su u trećem mjesecu šokovi u promjeni prinosa domaćih obveznica djelomično objašnjeni šokovima u varijabli domaćih dionica (CROBEXtr) i to u visini od 1,1%.

Tablica 40 - Dekompozicija varijance modela VAR (1) – varijabla CROBEXtr

N	EURIBOR	CROBIStr	CROBEXtr	Hedge fund	MFutures
1	0,001337	0,144370	0,854290	0,000000	0,000000
2	0,001190	0,126940	0,784870	0,064541	0,022459
3	0,001240	0,126110	0,781380	0,068823	0,022446
4	0,001243	0,126160	0,781080	0,069066	0,022443
5	0,001243	0,126180	0,781060	0,069073	0,022442

Izvor: izračun autora u programskom paketu R studio

Rezultati dekompozicije varijance za varijablu CROBEXtr pokazuju da varijabla dionica RH u prvome mjesecu objašnjava 85,4% varijance svoje prognostičke pogreške dok šokovi u promjeni prinosa domaćih obveznica objašnjavaju 14,4% ukupne varijance promjene prinosa dionica RH. Od drugog mjeseca pa nadalje smanjen je udio šokova u promjeni prinosa dionica (78,5%) i obveznica (12,7%), dok se povećao udio šokova promjene prinosa hedge fondova (6,5%) i ročnica (2,2%).

Tablica 41 - Dekompozicija varijance modela VAR (1) – varijabla Hedge fund

N	EURIBOR	CROBIStr	CROBEXtr	Hedge fund	MFutures
1	0,000053	0,115160	0,297110	0,587670	0,000000
2	0,002304	0,107290	0,291390	0,596760	0,002261
3	0,002912	0,107720	0,291020	0,596090	0,002254
4	0,003046	0,107960	0,290920	0,595820	0,002253
5	0,003068	0,108010	0,290900	0,595770	0,002253

Izvor: izračun autora u programskom paketu R studio

Rezultati dekompozicije varijance za varijablu Hedge fondova pokazuju da predmetna varijabla u prvome mjesecu objašnjava 58,8% varijance svoje prognostičke pogreške. Ostatak udjela u ukupnoj promjeni zauzimaju šokovi u promjeni prinosa domaćih dionica (CROBEXtr) koji objašnjavaju 29,7% ukupne varijance promjene prinosa hedge fondova i šokovi u promjeni prinosa obveznica RH odnosno varijabli CROBIStr (11,5%). Slična struktura udjela šokova koji objašnjavaju varijancu pogreške predviđanja promjene prinosa hedge fondova vidljiva je i u budućim mjesecima. Ovakav rezultat dekompozicije varijance za varijablu prinosa hedge fondova nije u potpunosti koherentan s ekonomskom teorijom.

Tablica 42 - Dekompozicija varijance modela VAR (1) – varijabla Mfutures

N	EURIBOR	CROBIStr	CROBEXtr	Hedge fund	MFutures
1	0,0022654	0,00063686	0,0015741	0,027233	0,96829
2	0,0238595	0,01817574	0,0026967	0,026322	0,92895
3	0,0271478	0,02050294	0,0027267	0,026866	0,92276
4	0,0276939	0,02085179	0,0027279	0,026960	0,92177
5	0,0277742	0,02089932	0,0027278	0,026974	0,92162

Izvor: izračun autora u programskom paketu R studio

Rezultati dekompozicije varijance za varijablu Mfutures (ročnice) pokazuju da predmetna varijabla u prvome mjesecu objašnjava 96,8% varijance svoje prognostičke pogreške dok se ostatak promjene odnosi na šokove u promjeni prinosa hedge fondova (2,7%). Od drugog mjeseca pa nadalje smanjen je udio šokova u promjeni prinosa ročnica (92,3%), dok se povećao udio šokova promjene varijable EURIBOR odnosno kamatnih stopa (2,4%) i CROBIStr odnosno obveznica RH (1,8%). Do kraja 5. mjeseca nema značajnih promjena u strukturi udjela šokova koji objašnjavaju varijancu pogreške predviđanja promjene prinosa ročnica.

Ukupno gledajući, rezultati dekompozicije varijance ukazuju da makroekonomska varijabla EURIBOR, koja reprezentira promjene kamatnih stopa, objašnjava manji dio varijacija u promjeni prinosa tradicionalnih i alternativnih oblika ulaganja. Drugim riječima, eksplanatorna snaga kamatnih stopa smatra se slabom u objašnjavanju kretanja prinosa odabranih oblika

ulaganja što nije u potpunosti sukladno s ekonomskom teorijom, posebice kod pretpostavljenog međuodnosa kretanja kamatnih stopa i prinosa obveznica i dionica.

Razlog takvog ishoda rezultata može biti u odabiru varijable koja reprezentira kamatnu stopu. U ovom slučaju je odabran 3M EURIBOR kao jedna od referentnih kamatnih stopa na financijskom tržištu Europske Unije. Također, ovakav ishod za dekompoziciju varijanci i koeficijenata funkcije impulsnih odziva može biti i posljedica neznačajnosti pojedinih varijabli u VAR modelu.

VAR analiza dodatno je provedena na način da se postojeći VAR (1) model podijeli na 2 modela u koje su uključene po 3 varijable a koje se odnose na kamatne stope i tradicionalne oblike s jedne strane (tj. dionice i obveznice RH) i kamatne stope i alternativne oblike s druge strane (tj. hedge fondove i ročnice). Rezultati takve VAR analize istovjetni su rezultatima VAR (1) modela koji inicijalno uključuje 5 varijabli. Opseg testiranja proširen je i s procjenom modela linearne regresije s dvije varijable gdje su kamatne stope određene kao nezavisna varijabla dok je kao zavisna definiran pojedini oblik ulaganja. Dobiveni teorijski predznaci mogu se u određenoj mjeri poistovjetiti s ekonomskom teorijom. Unatoč tome, varijabla kamatnih stopa nije značajna niti u jednom regresijskom modelu dok je koeficijent determinacije (R2) izuzetno nizak što ukazuje na slab prediktivan kapacitet regresijskog modela.

Na temelju rezultata VAR analize i opsežne provedbe svih relevantnih testova uzročnosti i inovacijske analize**, Hipotezu 3 nije bilo moguće u potpunosti potvrditi, ali niti odbaciti**. Naime, dosadašnja istraživanja nisu dovodila u vezu sve korištene varijable te se nije moglo sa sigurnosti unaprijed tvrditi kakva će biti povezanost varijabli u pogledu smjera i intenziteta odnosno hoće li pretpostavljeni utjecaj biti sukladan ekonomskoj teoriji.

Dodatno se provode i multivarijatni testovi vezani uz inovacijske procese odnosno autokorelacije reziduala i heteroskedastičnosti u VAR (1) modelu za različite vrijednosti pomaka. Lütkepohl (2006) navodi da ispitivanje ovih karakteristika slučajnog procesa εt nije od primarne važnosti ako se VAR koristi u svrhu prognoziranja (predviđanja). No, korisno je provesti testove nad procjenom slučajnom procesa εt, pogotovo kada se model konstruira temeljem ekonomske teorije, a ne vjerojatnosnih svojstava varijabli koje se razmatraju.

Tablica 43 – Multivarijatni test autokorelacije reziduala

Broj pomaka	Test veličina	p-vrijednost	Interpretacija
1	3,46	0,000	odbacujemo H_0
2	28,9	0,270	ne možemo odbaciti H_0
3	60,6	0,150	ne možemo odbaciti H_0
4	94,8	0,061	ne možemo odbaciti H_0
5	124,0	0,053	ne možemo odbaciti H_0
6	156,0	0,030	odbacujemo H_0
7	178,0	0,057	ne možemo odbaciti H_0
8	210,0	0,037	odbacujemo H_0
9	235,0	0,046	odbacujemo H_0
10	263,00	0,040	odbacujemo H_0
15	364,00	0,29	ne možemo odbaciti H_0

Izvor: izračun autora u programskom paketu R studio

Za multivarijatni test autokorelacije odabran je *Portmanteu Test* koji se u programu Rstudio provodi odabirom funkcije „*serial.test*“. Nulta hipoteza testa pretpostavlja da nema autokorelacije reziduala. Test je proveden za nekoliko razina pomaka u cilju veće mjerodavnosti rezultata. Rezultati testiranja razlikuju se ovisno o odabiru broja pomaka. Primjerice, za odabir duljine pomaka 1, 6 i 8-10, p-vrijednost znatno je manja od teorijske razine signifikantnosti (5%) te se nulta hipoteza, koja pretpostavlja da nema autokorelacije reziduala, može odbaciti. Nadalje, kod odabira pomaka 2-5, 7 i 15 rezultati testa ukazuju na suprotan zaključak odnosno uslijed više razine p-vrijednosti od teorijske razine signifikantnosti (5%), ne može se odbaciti nulta hipoteza.

Tablica 44 - Multivarijatni test heteroskedastičnosti reziduala u VAR(1) modelu

Broj pomaka (lag)	Test veličina	p-vrijednost	Interpretacija
1	565	0,000	odbacujemo H_0
2	829	0,000	odbacujemo H_0
3	1047	0,000	odbacujemo H_0
4	1258	0,000	odbacujemo H_0
5	1433	0,000	odbacujemo H_0
6	1601	0,000	odbacujemo H_0
7	1809	0,000	odbacujemo H_0
8	1994	0,001	odbacujemo H_0
9	2170	0,013	odbacujemo H_0
10	2340	0,092	ne možemo odbaciti H_0
15	2460	1,00	ne možemo odbaciti H_0

Izvor: izračun autora u programskom paketu R studio

Provedbom multivarijatnog testa heteroskedastičnosti uočava se da je p-vrijednost kod pomaka 1-9 ispod teorijske razine (0,05) temeljem čega se može odbaciti nulta hipoteza koja pretpostavlja da nema prisutne heteroskedastičnosti reziduala. Ukoliko je broj pomaka 10 i više,

nulta hipoteza se ne može odbaciti odnosno test ukazuje da heteroskedastičnost reziduala nije prisutna.

Tablica 45 - Univarijatni test heteroskedastičnosti reziduala u VAR(1) modelu

Varijabla	Test veličina	p-vrijednost	Interpretacija
EURIBOR	4,79	1	ne možemo odbaciti H_0
CROBIStr	13,6	0,63	ne možemo odbaciti H_0
CROBEXtr	56	0,00	odbacujemo H_0
HedgeF	40,7	0,00	odbacujemo H_0
MFutures	16,7	0,41	ne možemo odbaciti H_0

Izvor: izračun autora u programskom paketu R studio

Provedbom univarijatnog testa heteroskedastičnosti reziduala u modelu vidljivo je da varijable EURIBOR, CROBIStr i Mfutures (ročnice) nemaju prisutnu heteroskedastičnost dok se kod varijabli CROBEXtr i Hedge fondova može odbaciti nulta hipoteza koja pretpostavlja da nema heteroskedastičnosti reziduala.

Rezultati provedenog multivarijatnog **testa normalnosti** reziduala (Jarque-Bera test) ukazuju da se nulta hipoteza o multivarijatnoj normalnosti reziduala u VAR modelu može odbaciti.

5.6. Rezultati istraživanja i testiranja hipoteza

U ovom dijelu detaljnije su obrazloženi rezultati i zaključci testiranja hipoteza istraživanja.

5.6.1. Hipoteza 1

H1: Uključivanje alternativnih oblika ulaganja u investicijski portfelj ima jači pozitivni utjecaj na prinos i rizik investicijskog portfelja u odnosu na uključivanje dodatnih tradicionalnih oblika ulaganja.

Navedena hipoteza se može smatrati potvrđenom na temelju provedbe testiranja kombinacija udjela domaćih i stranih tradicionalnih te alternativnih oblika ulaganja. Detaljnim testiranjem hipoteze H1 u poglavlju 5.3. dobivena je spoznaja o empirijskom utjecaju uključivanja alternativnih oblika ulaganja u investicijski portfelj. Zadržavanjem udjela domaćih tradicionalnih oblika simulirani portfelji odražavaju realne investicijske portfelje te omogućavaju aplikativnu primjenu za institucionalne investitore u smislu uzimanja u obzir rezultata testiranja ove hipoteze kod kreacije investicijskog portfelja.

5.6.2. Hipoteza 2

H2: Korištenjem višekriterijskog modela optimizacije koji uključuje više momente distribucije dobiva se efikasniji investicijski portfelj od onog koji je optimiziran Markowitzevim modelom optimizacije.

Analizom rezultata testiranja hipoteze iz poglavlja 5.4., Hipoteza H2 može se smatrati potvrđenom. Takva tvrdnja temelji se na činjenici da se korištenjem višekriterijskog modela dobio efikasniji portfelj od portfelja koji su rezultat optimizacije Markowitzevim modelom.

Usporedivost portfelja dobivenih korištenim modelima optimizacije omogućena je postavljanjem istih razina ograničenja u oba modela optimizacije. Kod svih razina ograničenja udjela pokazalo se da se višekriterijskim modelom dobiva efikasniji investicijski portfelj. Naime, u provedbi testiranja korišteno je više razina ograničenja u cilju utvrđivanja dobiva li se višekriterijskim modelom efikasniji portfelj kada se ograničenja udjela promijene a što doprinosi mjerodavnosti dobivenih rezultata.

Višekriterijski model omogućava kvalitetniju kalibraciju a što je samo po sebi dodana vrijednost kod kreiranja investicijske strategije institucionalnih investitora.

U rezultatima višekriterijske optimizacije jednaka je važnost pridodana svim središnjim momentima portfelja ($\lambda_1 = \lambda_2 = \lambda_3 = \lambda_4 = 1$). Naime, višekriterijski model omogućava izmjenu težina pojedinih preferencija kako bi investitor kalibrirao preferencije sukladno svojim investicijskim ciljevima. Primjerice, nastavak analize moguće je provesti kroz daljnje optimizacije modela u kojima investitori daju različitu važnost pojedinim središnjom momentima distribucije.

5.6.3. Hipoteza 3

H3: Promjena kamatnih stopa jače utječe na promjenu prinosa tradicionalnih oblika ulaganja nego na promjenu prinosa alternativnih oblika ulaganja

Testiranjem Hipoteze H3 pokušalo se dobiti detaljniji uvid u smjer i intenzitet utjecaja promjene kamatnih stopa na promjenu prinosa odabranih tradicionalnih i alternativnih oblika ulaganja. Rezultati VAR analize nisu ukazali da postoji mjerodavna povezanost odnosno utjecaj promjene kamatnih stopa na prinose dionice i obveznice što nije u potpunosti sukladno ekonomskoj teoriji. S druge strane, utjecaj kamatnih stopa na alternative oblike nije bio

pretpostavljen *a priori* obzirom na ekonomsku teoriju i oskudnost znanstvenih radova koji se bave istraživanjem smjera i intenziteta utjecaja kamatnih stopa na hedge fondove i ročnice.

Uzimajući u obzir rezultate testiranja, Hipoteza H3 nije u potpunosti potvrđena, no temeljem prethodnih znanstvenih radova nije ju moguće niti odbaciti.

Unatoč tome, testiranje hipoteze dovelo je do novih spoznaja o međusobnom smjeru utjecaja i intenziteta odabranih varijabli. U cilju proširivanja opsega testiranja hipoteze, moguće je odrediti neku drugu varijablu kao reprezentant kretanja kamatnih stopa (npr. prinos tržišta novčanih oblika ulaganja, dugoročne stope na kredite, stopu refinanciranja ECB-a). Obzirom na stacionarnost varijabli u modelu, upitno je može li se koristiti metodu kointegracije kao u (Jakšić, 2008) za dodatno testiranje utjecaja kamatnih stopa na odabrane oblike ulaganja.

6. ZAKLJUČAK

Upravljanje investicijskim portfeljem vrlo je odgovoran zadatak za svakog institucionalnog investitora, posebno jer financijska sredstva predstavljaju najveći dio njihove imovine, a time i značajan generator prihoda i rizika. Odabir kombinacije oblika ulaganja, u širokom dijapazonu dostupnih oblika, predstavlja rigorozan proces koji zahtijeva ekstenzivnu analizu financijskih tržišta, definiranje investicijske strategije, kao i detekciju prisutnog ekonomskog ciklusa u pogledu projekcije kretanja značajnih makroekonomskih varijabli.

Investicijski portfelj izrazito je značajan segment poslovnog modela društava za osiguranje. Prije svega, radi se o primarnom izvoru financiranja i servisiranja obveza odnosno plaćanja šteta osiguranicima. Investicijski portfelj služi i kao važan generator dodatnog prihoda koji može predstavljati i svojevrsnu komparativnu prednost. Iz tog razloga, kod definiranja investicijskih ciljeva u obzir je potrebno uzeti i profil obveza, prije svega njihovu visinu, valutu i ročnost. Analiza strukture ulaganja osiguratelja, na primjeru RH i EU tržišta, ukazuje na i dalje izrazitu dominantnost udjela državnih obveznica koja je nešto manje izražena kod EU društava. Pored državnih obveznica, kao alternativa za povećanje prinosa veći udio postepeno zauzimaju i korporativne obveznice, posebno kod EU osiguratelja. Ulaganja u vlasničke instrumente odnosno dionice tradicionalno su slabije zastupljena u investicijskom portfelju društava za osiguranje, a dodatan čimbenik tome predstavlja i rigorozan kapitalni tretman prema novoj osiguratelјnoj regulativi Solventnost II.

Predmetna regulativa stupila je na snagu početkom 2016. godine i sa sobom donijela niz promjena koje su iz temelja promijenile regulaciju industrije osiguranja. Generalno gledajući, odredbe Solventnosti II primarno se baziraju na principima i inherentnoj izloženosti rizicima osiguratelja. S druge strane, osnovu prethodne regulative Solventnost I činila su stroga pravila koja nisu bila u dovoljnoj mjeri osjetljiva na rizične komponente poslovanja društava za osiguranja. U pogledu upravljanja investicijskim portfeljem, potrebno je naglasiti da su osiguratelji dobili znatno veću diskreciju u odabiru kombinacije oblika ulaganja.

Solventnost II ukida rigidna ograničenja na dozvoljene oblike ulaganja koje su osiguratelji morali poštivati u procesu investiranja. Nova regulacija omogućava društvima investiranje u sve raspoložive oblike ulaganja, no s druge strane, za svaku investiciju potrebno je rezervirati određenu visinu vlastitog kapitala koja ovisi o stupnju rizičnosti oblika ulaganja. Drugim riječima, osiguratelji danas mogu ulagati u bilo koji oblik imovine, bez obzira radi li se o

tradicionalnom ili alternativnom obliku, dokle god imaju dovoljno vlastitog kapitala za pokriće potencijalnih gubitaka odnosno rizika koji proizlaze iz takve investicije. Takav regulatorni pristup stavlja veći fokus na upravljanje investicijskim rizicima obzirom da tržišni rizici zauzimaju najveći udio izloženosti u investicijskom portfelju osiguratelja. Tržišne rizike induciraju nepovoljne promjene eksternih faktora rizika (npr. cijene financijskih instrumenata, kamatne stope, inflacija, tečaj i dr.).

Alternativni oblici ulaganja zauzimaju značajnu ulogu u financijskoj industriji, a time sve važnije postaje razumijevanje njihovih karakteristika, posebice prednosti koje investitori mogu ostvariti njihovim uključivanjem u investicijski portfelj. U ovom radu ekstenzivno je testirana i empirijski dokazana prethodna tvrdnja na primjeru investicijskog portfelja koji se sastoji od tradicionalnih domaćih i stranih oblika ulaganja, a u koji se potom uključuju alternativnih oblici hedge fondova i ročnica. U radu se koriste metode optimizacije portfelja na osnovi Markowitzevog modela i višekriterijskog modela optimizacije koji uključuje više momente distribucije. Takav oblik optimizacije je specifičan obzirom da se u njemu javlja konfliktnost funkcije cilja. Drugim riječima, istovremeno se maksimiziraju prvi i treći moment te minimiziraju drugi i četvrti moment distribucije prinosa. Primjena višekriterijskog modela donosi nekoliko prednosti. Prije svega, investitori mogu proizvoljno odabrati preferencije u pogledu naglaska na pojedine momente u samoj optimizaciji, a što onda utječe na višu ili nižu vrijednost momenata (tzv. *trade-off*) ovisno o samoj preferenciji. Također, višekriterijska optimizacija pogodna je za korištenje u situaciji kada vremenske serije promatranih varijabli ne slijede oblik normalne distribucije čime je moguće premostiti pretpostavku normalnosti iz klasičnog Markowitzevog modela optimizacije. Brojni empirijski radovi ukazali su već na nenormalnu distribuiranost vremenskih serija većine poznatih tradicionalnih, ali i alternativnih oblika ulaganja.

Uključivanjem alternativnih ulaganja u investicijski portfelj institucionalnih investitora omogućava se postizanje optimalnog odnosa prinosa i rizika portfelja. Takva tvrdnja osnovana je na brojnim empirijskim radovima gdje se pokazalo da alternativna ulaganja nisu (visoko) korelirana s dionicama i obveznicama. Koristi od alternativnih oblika mogu se dobiti već na razini strateške alokacije imovine, kroz smanjenje izloženosti tržišnom riziku, a i na razini taktičke alokacije imovine, gdje se generira dodatan prinos temeljem dinamičkih tehnika aktivnog upravljanja portfeljem.

Isto tako, postoji niz empirijskih radova, prezentiranih u poglavlju 1.3., koji su istraživali i ukazali na pozitivan utjecaj ulaganja u hedge fondove na prinos i rizik portfelja. Takav učinak proizlazi iz spomenute niske koreliranosti alternativnih oblika s prinosima tradicionalnih oblika ulaganja (obveznice, dionice).

Prije razmatranja kako uključiti hedge fondove u investicijski portfelj, potrebno je uzeti u obzir potencijal prinosa hedge fondova i njihovu ulogu u diversifikaciji odnosno utjecaj na ukupan rizik portfelja. Hedge fondovi mogu proširiti investicijske mogućnosti za investitore, budući da većina strategija hedge fondova nudi prinose koji su konkurentni ili viši od prinosa dionica i obveznica, ali i s nižim rizikom od primjerice dionica. Sukladno tome, osnova odluke o uključivanju hedge fondova u portfelj može biti jednostavno potraga za dodatnim prinosom ili dodatna diversifikacija tržišnih rizika.

Pored hedge fondova, upravljane ročnice (eng. *managed futures*) smatraju se kvalitetnim alternativnim oblikom koji može pružiti dodatan izvor nisko koreliranih apsolutnih prinosa. Distribucija prinosa ovog oblika ulaganja ima karakteristike normalne distribuiranosti te u kombinaciji s tradicionalnim oblicima vrlo povoljno utječe na više momente i efikasnost portfelja. Bitno je istaknuti i da ročnice pokazuju sklonost nadmašivanja prinosa referentnih financijskih indeksa tradicionalnih oblika u periodima tržišnih neizvjesnosti i financijskim krizama.

Likvidnost i transparentnost temeljnih instrumenata ročnica značajno ublažavaju skrivene rizike koji često prate ulaganje u nelikvidne hedge fondove i ostale oblike alternativnih ulaganja. Vrijednost likvidnosti često je podcijenjena, a hedge fondovi koji trguju nelikvidnim instrumentima često ostvaruju lošije rezultate od hedge fondova koji u provođenju investicijskih strategija koriste likvidnije oblike ulaganja.

Upravljane ročnice (eng. *managed futures*) nude institucionalnim investitorima aktivno upravljanu izloženost uistinu globalnom i raznolikom nizu likvidnih, transparentnih instrumenata. Prinosi mnogih od njih ne pokazuju korelaciju s tradicionalnim ili alternativnim ulaganjima. Iz navedenih razloga, uključivanje ročnica u investicijski portfelj dovodi do boljih riziku prilagođenih performansi bez obzira mjere li se rezultati na temelju tzv. *mean-variance* okvira ili putem Omega mjere koja uzima u obzir cjelokupnu distribuciju prinosa.

Prethodno navedene tvrdnje o uključivanju alternativnih oblika ulaganja dodatno su testirane u ovom istraživanju putem postavljenih hipoteza. Na temelju rezultata provedenih optimizacija u

poglavlju 5 potvrđene su Hipoteze H1 i H2. Naime, u Hipotezi 1 cilj je bio testirati ima li uključivanje alternativnih oblika ulaganja u investicijski portfelj, koji sadrži samo tradicionalne oblike ulaganja na tržištu Republike Hrvatske (obveznice, dionice, novac), jači pozitivan utjecaj od uključivanja dodatnih stranih tradicionalnih oblika (obveznice i dionice na tržištu EU, SAD-a i dr.). Rezultati testiranja hipoteze H1 ukazali su da alternativni oblici imaju jači pozitivan utjecaj na efikasnost portfelja mjerenu preko Sharpeovog i Sortinovog omjera kod gotovo svih testiranih kombinacija udjela promatranih oblika ulaganja.

U Hipotezi H2 testirano je hoće li korištenje višekriterijskog modela optimizacije dati efikasniji portfelj u odnosu na korištenje Markowitzevog modela. S ciljem mjerodavne usporedbe simuliranih i optimiziranih portfelja korištena su jednaka ograničenja udjela na uključene oblike ulaganja. Omega omjer korišten je kao mjera za ocjenu efikasnosti dobivenih portfelja jer, pored prinosa i varijance, uzima u obzir više momente portfelja koji se odnose na koeficijent asimetrije i zaobljenosti, a koji se također optimiziraju višekriterijskim modelom. Portfelj koji ima višu Omega mjeru smatra se efikasnijim. Rezultati testiranja H2 također potvrđuju postavljenu hipotezu što omogućava kvalitetniju kreaciju i odabir raspoloživih oblika ulaganja u investicijski portfelj. Također, praktično pokazuje korist od višekriterijskog modela koji je kodiran u programskom jeziku R, a što olakšava daljnju aplikativnu primjenu zainteresiranim investitorima i ostalim dionicama.

Hipoteza H3 postavljena je u svrhu testiranja utjecaja promjene kamatnih stopa na prinose promatranih tradicionalnih i alternativnih oblika ulaganja koji se odnose na dionice i obveznice Republike Hrvatske, te hedge fondove i ročnice. Teorijska pretpostavka koja čini osnovu hipoteze H3 je da promjena kamatnih stopa, bez obzira radi li se o njihovom rastu ili padu, očekivano jače utječe na promjenu prinosa obveznica i dionica nego što utječe na prinose hedge fondova i ročnica. Sukladno tome, investitori čiji investicijski portfelji dominantno uključuju obveznice i dionice mogu smanjiti izloženost riziku promjene kamatnih stopa kroz uključivanje hedge fondova i ročnica odnosno smanjenje udjela obveznica i dionica. Predmetna hipoteza testirana je korištenjem općeg vektorskog autoregresijskog modela, također putem programskog paketa R. Rezultati testiranja hipoteze H3 ukazali su da hipotezu nije bilo moguće u potpunosti potvrditi, ali niti odbaciti.

Rezultati testiranja hipoteza u ovom doktorskom istraživanju potvrđuju da se uključivanjem alternativnih oblika ulaganja, u kombinaciji s tradicionalnim oblicima, može kreirati efikasniji investicijski portfelj od onog koji sadrži isključivo tradicionalne oblike.

6.1. Ograničenja istraživanja

Kao i u svakom znanstvenom istraživanju, i ova disertacija ima određena ograničenja. Jedno od često prisutnih empirijskih ograničenja u znanstvenim radovima, a koje se pojavljuje i u ovoj disertaciji, odnosi se na korištenje povijesnih podataka za dedukciju zaključaka. U cilju što veće mitigacije ovog ograničenja i primjerene reprezentativnosti rezultata testiranja, odabrana je vremenska serija koja obuhvaća period unutar kojeg su se realizirali scenariji sa značajnim utjecajem na distribucije prinosa promatranih varijabli, a koje se sastoji od ukupno 180 mjesečnih opažanja (tj. period od početka 2006. do kraja 2020. godine).

Unatoč tome, pri korištenju povijesnih podataka moguća je prisutnost pogreške u procjeni središnjih momenata distribucije odnosno očekivanog prinosa, varijance (tj. standardne devijacije), te koeficijenata asimetrije i zaobljenosti. Naime, vrijednosti središnjih momenata imaju tendenciju da se mijenjaju tijekom vremena ovisno o karakteristikama vremenske serije koja se koristi. Iz toga razloga, rezultati temeljeni na duljim vremenskim serija mogu se smatrati mjerodavnijim nego oni dobiveni korištenjem kraćih serija. Središnji momenti distribucije prinosa poput asimetrije, zaobljenosti i varijance mijenjaju se tijekom vremena te je bitno koliko dug i kakav period će se točno uzeti za provedbu analize.

Bitno je istaknuti da određeni financijski indeksi koji su korišteni u istraživanju nemaju u potpunosti jednake karakteristike u pogledu podataka na kojima su izvedeni. Primjerice, dionički indeksi tržišta SAD-a su u potpunosti tzv. *total return* indeksi, dok je indeks domaćih dionica parcijalno modificiran obzirom da se CROBEXtr indeks ukupnih prinosa počeo izračunavati tek krajem veljače 2014. godine, dok je izračun domaćeg obvezničkog indeksa ukupnih prinosa (CROBIStr) počeo s izračunom od prosinca 2011. Navedeno ograničenje ublaženo je kroz korištenje raspona udjela domaćih i stranih tradicionalnih oblika ulaganja gdje je maksimalan udio stranih oblika limitiran kako njihova vremenska serija ne bi značajno utjecala na središnje momente optimiziranog portfelja. Utjecaj spomenutog ograničenja ne smatra se materijalnim jer u provedenom istraživanju nije fokus isključivo na prinose kao prvi središnji moment, već i na preostale više momente odnosno varijancu, asimetriju i zaobljenost koji su predmet cilja višekriterijske optimizacije.

U dijelu empirijskih ograničenja, potrebno je napomenuti i apstrahiranje utjecaja strukture obveza društava za osiguranje čiji profil utječe na formiranje investicijskog portfelja. Utjecaj ovakvog pristupa također je ublažen kroz uvođenje ograničenja na udjele domaćih oblika

ulaganja gdje značajan udio zauzimaju državne obveznice, a što je približno stvarnoj strukturi investicijskog portfelja društava za osiguranje. U ovom kontekstu može se promatrati i različitost strukture imovine i obveza između društava koja se bave životnim i onih koji se bave neživotnim osiguranjima. Uzimajući u obzir problem istraživanja, analiza je u određenoj mjeri malo više naklonjena društvima za životno osiguranje. S druge strane, korištenje likvidnih oblika tradicionalnih i alternativnih ulaganja, rezultati testiranja i provedenih optimizacija primjenjivi su i na poslovne modele neživotnih osiguratelja kod kojih je likvidnost imovine izraženiji faktor nego kod životnih osiguranja.

Neisticanje jasne distinkcije između životnih i neživotnih društava za osiguranje proizlazi iz cilja da rezultati istraživanja omogućuju donošenje općenitijih zaključaka koji će biti potencijalno primjenjivi na širi spektar institucionalnih i profesionalnih investitora.

U pogledu teorijskih ograničenja disertacije, prisutna su ograničenja korištenih modela optimizacije od kojih su izraženija ona koje sadrži Markowitzev model. Nedostaci ovog modela opisani su u drugom poglavlju disertacije, no svakako je potrebno dodatno naglasiti činjenicu da se radi o jedno periodnom modelu u kojem se koriste povijesni podaci za promjenu komomenata distribucije. Isto teorijsko ograničenje odnosi se i na višekriterijski model optimizacije, unatoč njegovoj naprednosti u odnosu na Markowitzev model.

VAR metodologija korištena za testiranje Hipoteze H3 također ima svoja inherentna ograničenja od kojih se nameće problem autokorelacije i heteroskedastičnosti reziduala.

6.2. Prijedlozi za buduće znanstvene radove

Ova disertacija predstavlja jedan od rijetkih radova u području upravljanja investicijskim portfeljem, posebice u kontekstu industrije osiguranja nakon ulaska Republike Hrvatske u Europsku uniju i liberalizacije financijskih tržišta. Uvođenje regulative Solventnosti II dodatno je proširilo investicijski spektar potencijalnih oblika ulaganja za osiguratelje. Sukladno tome, rezultati provedenog istraživanja predstavljaju kvalitetan temelj za buduće znanstvene radove u domeni investicijskih aktivnosti društava za osiguranje, ali i drugih institucionalnih i profesionalnih investitora na domaćem i inozemnom financijskom tržištu.

Buduća istraživanja mogu fokusirati svoje znanstvene ciljeve u smjeru kojim se nastoji premostiti neka od prethodno navedenih ograničenja što bi unaprijedilo ovo istraživanje i

kreiralo novi znanstveni doprinos. Jedan od načina unapređenja može biti korištenje dodatnih metoda za procjenu viših (ko)momenata distribucije prinosa promatranih varijabli.

Također, buduća istraživanja mogu uključiti nove ili dodatne značajne alternativne oblike ulaganja, poput primjerice referentnog (pod)indeksa određene strategije hedge fondova, indeksa nekretnina, indeksa privatnog vlasničkog kapitala, pa čak i indeksa kriptovaluta kao sve prominentnijeg oblika ulaganja kod širokog broja investitora. Distribucije indeksa spomenutih alternativnih oblika, odnosno vrijednosti njihovih središnjih momenata mogu se kvalitetno komplementirati s odabranim indeksima tradicionalnih oblika ulaganja.

Dodatno se može provesti istraživanje u kojem bi se rezultati ovog ili sadržajno bliskog rada dodatno testirali na vremenskom periodu koje je izvan korištenog perioda za provedbu višekriterijske optimizacije (tzv. *out-of-sample* period).

Provedeno istraživanje u ovoj disertaciji može se dodatno proširiti uključivanjem preferencija investitora prema pojedinom središnjem momentu ovisno o profilu i investicijskim ciljevima pojedinog investitora, a što omogućava primjena višekriterijskog modela. U slučaju društava za osiguranje, nastavak istraživanja mogao bi ići u smjeru višekriterijske optimizacije gdje bi se veća težina preferencije stavila na minimizaciju zaobljenosti obzirom da visoka volatilnost vrijednosti imovine i obveza nije poželjna u bilancama i investicijskom portfelju osiguratelja.

No, i bez uvođenja spomenutih inovacija u analizu, nakon određenog vremenskog odmaka moguće je provesti istovjetno istraživanje s još duljim vremenskim nizom gdje se zaključci takvog istraživanja mogu usporediti s rezultatima ove doktorske disertacije. Jedno od mogućih unapređenja postojećeg istraživanja može biti i generiranje vremenske serije nasumičnih prinosa u cilju smanjenja pristranosti u korištenim podacima ili provođenje istovjetnog istraživanja korištenjem različite vremenske serije.

Ulaskom Republike Hrvatske u eurozonu doći će do promjene u razini kamatnih stopa i prinosa na dužničke instrumente, posebno obveznice, radi nižeg rizika države. U takvom okruženju biti će zanimljivo promatrati reakciju institucionalnih investitora u pogledu rebalansa njihovih investicijskih portfelja. Budući znanstveni rad mogao bi se bazirati na podjeli vremenske serije na prije i poslije ulaska RH u eurozonu ili na nekoliko vremenskih podserija koje karakteriziraju specifične tržišne okolnosti (npr. period niskih kamatnih stopa ili inflacije i rastućih kamatnih stopa, financijske krize i sl.).

POPIS LITERATURE

1. Abate, G. (2016.), Real Estate, u: Basile, I., Ferrari, P. (ur.), *Asset Management and Institutional Investors* (str. 355-371.), Springer
2. Abbink, J. B. (2010.), *Alternative assets and strategic allocation. Rethinking the institutional approach*, Cham: Wiley Hoboken i Bloomberg Press
3. Abrams, R., Bhaduri, R. i Flores, E. (2012.), *A Quantitative Analysis of Managed Futures for Plan Sponsors, Endowments and Foundations* [e-publikacija], preuzeto s https://www.cmegroup.com/education/files/PM282_White_Paper_Lintner_Revisited.pdf
4. Abrams, R., Bhaduri, R. i Flores, E. (2014.), *A Quantitative Analysis of Managed Futures Strategies* [e-publikacija], preuzeto s https://www.cmegroup.com/education/files/Lintner_Revisited_Quantitative_Analysis.pdf
5. Amin, G.S. i Kat, H.M. (2003.), Hedge Fund Performance 1990–2000. Do the Money Machines Really Add Value?, *Journal of Financial and Quantitative Analysis*, *38*(8), 1–24. https://doi.org/10.2307/4126750
6. Anđelinović, M. (2011.), *Utjecaj ekonomskih ciklusa na oblikovanje investicijskog portfelja društava za osiguranje*, doktorski rad, Ekonomski fakultet u Splitu, Split
7. Anđelinović, M., Samodol, A. i Pavković, A. (2018.), Asset allocation and profitability of croatian insurers in the pre-solvency II period, *Ekonomické rozhľady, 47*(4)*,* 387-411.
8. Anson, M. (2006.), *Handbook of alternative assets*, 2. izd., Wiley, Hoboken
9. Anson, M., Chambers R. D., Keith H. B. i Kazemi, H. (2012.), *CAIA level I : an introduction to core topics in alternative investments*, 2. izd., Wiley finance series
10. Anson, M., Ho, H. i Silberstein, K. (2007.), Building a hedge fund portfolio with kurtosis and skewness, *The Journal of Alternative Investments, 10*(1), 25-34. https://doi.org/10.3905/jai.2007.688991
11. Aouni, B., Colapinto, C. i La Torre, D. (2014.), Financial portfolio management through the goal programming model: Current state-of-the-art, *European Journal of Operational Research*, *234*(2), 536-545. https://doi.org/10.1016/j.ejor.2013.09.040
12. Aracioglu, B., Demircan, F., i Soyuer, H. (2011.), Mean-variance-skewness-kurtosis approach to portfolio optimization: An application in istanbul stock Exchange/Portföy optimizasyonunda ortalama-varyans-çarpiklik-BasiklikYaklasimi: IMKB uygulamasim, *Ege Akademik Bakıs, 11*(Special I), 9-17. https://ideas.repec.org/a/ege/journl/v11y2011ispecialissuep9-17.html

13. Aragon G. O. i Strahan P. E. (2012.), Hedge funds as liquidity providers: evidence from the Lehman bankruptcy, *Journal of Financial Economics 103*(3), 570–587. https://doi.org/10.1016/j.jfineco.2011.10.004
14. Asness C. S., Krail R. J. i Liew J. M. (2001.), Do Hedge Funds Hedge?, *The Journal of Portfolio Management*, *21*(1), 6-19. DOI: https://doi.org/10.3905/jpm.2001.319819
15. Athayde, G. i Flôres, R. (2004.), Finding a maximum skewness portfolio - A general solution to three-moments portfolio choice, *Journal of Economic Dynamics and Control 28*(7), 1335-1352. https://doi.org/10.1016/S0165-1889(02)00084-2
16. Bacmann, J.F., Jeanneret, P. i Scholz, S. (2008.), What correlation does not tell you about hedge funds: A factor approach to hedge fund correlations, *Journal of Derivatives & Hedge Funds*, *14*(2), 90–101. https://doi.org/10.1057/jdhf.2008.10
17. Baesel J. B., Gonzalez-Heres J. F., Chen P. i Shin S. S. (2013.), Hedge fund benchmarking: equity correlation regimes and alpha, *The Journal of Alternative Investments, 15*(4) 24-47. https://doi.org/10.3905/jai.2013.15.4.024
18. Bahna, M. (2016.), Portfolio Optimization using Higher Order Moments of the Stocks Returns Distribution: The Case of Bucharest Stock Exchange, *International Journal of Academic Research in Economics and Management Sciences 5*(4), 20-31. http://dx.doi.org/10.6007/IJAREMS/v5-i4/2272
19. Bahovec, V. i Erjavec, N. (2009.), *Uvod u ekonometrijsku analizu*, Element, Zagreb
20. Baker H. K. i Filbeck G. (2013.), *Alternative investments. Instruments, performance, benchmarks, and strategies*, Wiley, Hoboken
21. Baker H. K., Filbeck G. i Kiymaz H. (2015.), *Private equity: opportunities and risks*, Oxford University Press, New York
22. Balder, S. i Schweizer, N. (2017.), Risk aversion vs. the Omega ratio: Consistency results, *Finance Research Letters, 21*, 78-84. https://doi.org/10.1016/j.frl.2016.12.012
23. Bali, T., Brown, S. i Demirtas, O. (2013.), Do Hedge Funds Outperform Stocks and Bonds?, *Management Science, 59*(8), 1887-1903. https://doi.org/10.1287/mnsc.1120.1689
24. Baltas N. i Kosowski R. (2011.), *Momentum Strategies in Futures Markets and Trend-following Funds* (Research Collection BNP Paribas Hedge Fund Centre) [e-publikacija], preuzeto s https://ink.library.smu.edu.sg/bnp_research/17/
25. Barclayhedge (2022.), *Barclay Hedge Fund Indices* [podatkovni dokument], preuzeto s https://portal.barclayhedge.com/cgi-bin/indices/displayHfIndex.cgi?indexCat=Barclay-Hedge-Fund-Indices&indexName=Barclay-Hedge-Fund-Index

26. Barclayhedge (2022.), *BTOP50 Index* [podatkovni dokument], preuzeto s https://portal.barclayhedge.com/cgi-bin/indices/displayHfIndex.cgi?indexCat=Barclay-Investable-Benchmarks&indexName=BTOP50-Index
27. Basile, I. (2016.), Portfolio Diversification Policies: Alternative Asset Classes, u: Basile, I., Ferrari, P. (ur.), *Asset Management and Institutional Investors*, (str. 327-338.), Springer
28. Basile, I. i Ferrari, P. (2016.), *Asset Management and Institutional Investors*, Springer
29. Baur, D.G. i Lucey, B.M. (2010.), Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold, *The Financial Review*, *45*(2), 217-229. https://doi.org/10.1111/j.1540-6288.2010.00244.x
30. Benigno, A. M. i Lapeña, R. F. (2016.), Relationships between interest rate changes and stock returns: international evidence using a quantile-on-quantile approach, preuzeto 5. rujna 2022. s https://www.uv.es/bfc/TFM2016/TFM_AdrianMaizonadaBenigno.pdf
31. Berdin, E., Gründl, H. (2015.), The Effects of a Low Interest Rate Environment on Life Insurers, *Geneva Papers on Risk and Insurance. Issues and Practice*, *40*(3), 385-415. https://doi.org/10.1057/gpp.2014.38
32. Bergh, G. i van Rensburg, P. J. (2008.), Hedge funds and higher moment portfolio selection, *Journal of Derivatives and Hedge Funds*, *14*(2), 102–126. https://doi.org/10.1057/jdhf.2008.14
33. Bessler, W., Holler, J. i Kurmann, P. (2012.), Hedge funds and optimal asset allocation: Bayesian expectations and spanning tests, *Financial Markets and Portfolio Management*, *26*(1), 109–141. https://doi.org/10.1007/s11408-011-0179-5
34. Best, M. J. i Grauer, R. R. (1991.), On the Sensitivity of Mean-Variance-Efficient Portfolios to Changes in Asset Means: Some Analytical and Computational Results, *The Review of Financial Studies, 4*(2), 315-342. https://doi.org/10.1093/rfs/4.2.315
35. Bhaduri, R. i Art, C. (2008.), *Liquidity Buckets, Liquidity Indices, Liquidity Duration, and their Applications to Hedge Funds*, *Alternative Investment Quarterly*, *Second Quarter*, [e-publikacija], preuzeto s https://www.cmegroup.com/education/files/liquidity-buckets.pdf
36. Bhaduri, R. i Kaneshige, B. (2005.), *Risk Management – Taming the Tail, Benefits and Pensions Monitor,* [e-publikacija], preuzeto s https://www.cmegroup.com/education/files/risk-management-taming-the-tail.pdf
37. Bhandari, R. i Sanjiv R. D. (2009.), Options on portfolios with higher-order moments, *Finance Research Letters, 6*(3), 122-129. https://doi.org/10.1016/j.frl.2009.04.002

38. Bijlsma, M. i Vermeulen, R. (2016.), Insurance companies trading behaviour during the European sovereign debt crisis: Flight home or flight to quality?, *Journal of Financial Stability*, *27*, 137-154. https://doi.org/10.1016/j.jfs.2016.11.001
39. Boudt, K., Cornilly, D. i Verdonck, T. (2017.), A coskewness shrinkage approach for estimating the skewness of linear combinations of random variables, *Journal of Financial Econometrics*, *Forthcoming*, preuzeto s http://dx.doi.org/10.2139/ssrn.2839781
40. Boudt, K., Cornilly, D., Holle, F. i Willems, J. (2020.), Algorithmic portfolio tilting to harvest higher moment gains, *Heliyon*, *6*(3), https://doi.org/10.1016/j.heliyon.2020.e03516
41. Boudt, K., Lu, W. i Peeters, B. (2015.), Higher order comoments of multifactor models and asset allocation, *Finance Research Letters*, *13*, 225-233. https://dx.doi.org/10.2139/ssrn.2409603
42. Braga, M. D. (2016.), Methods and Tools for Portfolio Selection, u: Basile, I. i Ferrari, P. (ur.), *Asset Management and Institutional Investors* (str. 173-201.), Springer
43. Braun, A., Schmeiser, H. i Schreiber F. (2018.), Return on Risk-Adjusted Capital Under Solvency II: Implications for the Asset Management of Insurance Companies, *Geneva Papers on Risk and Insurance. Issues and Practice, 43*(3), 456-472. https://doi.org/10.1057/s41288-017-0076-x
44. Braun, A., Schmeiser, H. i Schreiber, F. (2015.), Solvency IIs market risk standard formula: How credible is the proclaimed ruin probability?, *Journal of Insurance Issues 38*(1), 1–30. https://www.jstor.org/stable/43295110
45. Braun, A., Schmeiser, H. i Schreiber, F. (2017), Portfolio optimization under solvency II: Implicit constraints imposed by the market risk standard formula, *The Journal of Risk and Insurance, 84*(1), 177-207. https://doi.org/10.1111/jori.12077
46. Brooks, C. i Kat, H. M. (2002.), The Statistical Properties of Hedge Fund Index Returns and their Implications for Investors, *Journal of Alternative Investments, 5*(2), 26-44. https://doi.org/10.3905/jai.2002.319053
47. Brown, S., Lu, Y., Ray, S., i Teo, M. (2018.), Sensation seeking and hedge funds*, The Journal of Finance (New York), 73*(6), 2871-2914. https://doi.org/10.1111/jofi.12723
48. Brueggeman W. B. i Fisher J. D. (2015.), *Real estate finance and investments*, Cham: McGraw-Hill/Irwin
49. Buckley, I., Saunders, D. i Seco, L. (2008.), Portfolio Optimization when Asset Returns have the Gaussian Mixture Distribution, *European Journal of Operational Research, 185*(3), 1434-1461. https://doi.org/10.1016/j.ejor.2005.03.080

50. Buraschi, A., Kosowski, R. i Trojani, F. (2014.), When there is no place to hide: Correlation risk and the cross-section of hedge fund returns, *Review of Financial Studies 27*(2), 581–616. https://doi.org/10.1016/j.ejor.2005.03.080
51. Burghardt, W. i Walls, B. (2011.), *Managed Futures for Institutional Investors: Analysis and Portfolio Construction*, Cham: Bloomberg
52. Caporin, M., Jannin, G. M., Lisi, F. i Maillet, B. B. (2014.), A survey on the four families of performance measures, *Journal of Economic Surveys, 28(5)*, 917-942. https://doi.org/10.1111/joes.12041
53. Carayannopoulos P. i Perez F. M. (2015.), Diversification through Catastrophe Bonds: Lessons from the Subprime Financial Crisis, *Geneva Papers on Risk and Insurance. Issues and Practice, 40*(1), 1–28. https://doi.org/10.1057/gpp.2014.14
54. Caselli S. i Negri, G. (2018.), *Private equity and venture capital in Europe: markets, techniques, and deals*, 2. izd, Cham: Academic Press
55. Choueifaty, Y. i Coignard, Y. (2008.), Toward maximum diversification, *Journal of Portfolio Management, 35*(1), 40-51. http://dx.doi.org/10.3905/JPM.2008.35.1.40
56. Credit Suisse (2019.), *Summary Edition Credit Suisse Global Investment Returns Yearbook 2019* [e-publikacija], preuzeto s https://www.credit-suisse.com/about-us/en/reports-research/studies-publications.html
57. CRO Forum (2016.), *Low Interest Rate Environment – Industry paper* [e-publikacija], preuzeto s https://www.thecroforum.org/wp-content/uploads/2016/12/LIRE-CRO-Forum-Working-Group-December-2016-FINAL.pdf
58. Cvijanović, V., Marović, M. i Sruk, B. (2008.), *Financiranje malih i srednjih poduzeća*, Zagreb, Hrvatska private equity i venture capital asocijacija i Binoza press
59. D'Souza, I., Srichanachaichok, V., Wang, G. J. i Yao, C. Y. (2016.), *The Enduring Effect of Time-Series Momentum on Stock Returns Over Nearly 100-Years*, Asian Finance Association, preuzeto s: https://dx.doi.org/10.2139/ssrn.2720600
60. Daskalaki C. i Skiadopoulos G. (2011.), Should investors include commodities in their portfolios after all? New evidence, *Journal of Banking & Finance*, *35*(10), 2606-2626. https://doi.org/10.1016/j.jbankfin.2011.02.022
61. Davies, R., Kat, H. i Lu, S. (2009.), Fund of Hedge Funds Portfolio Selection: A Multiple Objective Approach, *Journal of Derivatives & Hedge Funds, 15*, 91–115. https://doi.org/10.1057/jdhf.2009.1

62. Davó, N. B., Resco, C. i Barroso, M. (2013.), Portfolio Diversification with Life Settlements: An Empirical Analysis Applied to Mutual Funds, *Geneva Papers on Risk and Insurance. Issues and Practice, 38*, 22–42. https://doi.org/10.1057/gpp.2012.44
63. Delegirana uredba Komisije (EU) 2015/35 od 10. listopada 2014. o dopuni Direktive 2009/138/EZ Europskog parlamenta i Vijeća o osnivanju i obavljanju djelatnosti osiguranja i reosiguranja (Solventnost II) Tekst značajan za EGP
64. DeMiguel, V., Garlappi, L. i Uppal, R., (2009.), Optimal versus naive diversification: how inefficient is the 1/n portfolio strategy?, *The Review of Financial Studies, 22*(5), 1915–1953. https://doi.org/10.1093/rfs/hhm075
65. Di Francesco, M. (2021.), Portfolio optimization under solvency II: A multi-objective approach incorporating market views and real-world constraints, *Decisions in Economics and Finance, 44*(1), 269-294. https://doi.org/10.1007/s10203-021-00320-3
66. DIREKTIVA 2009/138/EZ EUROPSKOG PARLAMENTA I VIJEĆA od 25. studenoga 2009. o osnivanju i obavljanju djelatnosti osiguranja i reosiguranja (Solventnost II)
67. Doff, R. (2011.), *Risk management for insurers,* 2. izd., Risk Books
68. Dong, Y. (2017.), *Measuring treasury bond portfolio risk and portfolio optimization with a non-Gaussian multivariate model*, doktorski rad, Stony Brook University, New York
69. Dorsey, A. H. (2007.), *Active alpha: a portfolio approach to selecting and managing alternative investments*, Wiley, Hoboken
70. Državni Zavod za Statistiku (DZS), *Indeks cijena stambenih nekretnina* [podatkovni dokument], preuzeto s https://podaci.dzs.hr/hr/podaci/cijene/indeks-cijena-stambenih-nekretnina/
71. Dülla, R., König, F. i Ohls, J. (2017.), On the exposure of insurance companies to sovereign risk - Portfolio investments and market forces, *Journal of Financial Stability, 31*, 93-106. https://doi.org/10.1016/j.jfs.2017.06.008
72. Dyk, van F., Vuuren, van G. i Heymans, A. (2014.), Hedge Fund Performance Evaluation Using The Sharpe And Omega Ratios, *The International Business & Economics Research Journal (Online), 13*(3), 485-512. https://doi.org/10.19030/iber.v13i3.8588
73. Ehrmann, M., Fratzscher, M. i Rigobon, R. (2011.), Stocks, bonds, money markets and exchange rates: Measuring international financial transmission, *Journal of Applied Econometrics (Chichester, England), 26*(6), 948-974. https://doi.org/10.1002/jae.1173
74. Eling, M. (2015.), The Complexity Risk of Regulation: an Article on the Complexity of Solvency II, *Newsletter Risk management*, *55*, [e-publikacija], preuzeto s

https://www.genevaassociation.org/sites/default/files/research-topics-document-type/pdf_public//ga2015-rm55-eling.pdf

75. Eling, M. i Schuhmacher F. (2007.), Does the choice of performance measure influence the evaluation of hedge funds?, *Journal of Banking & Finance*, *31*(9), 2632-2647. https://doi.org/10.1016/j.jbankfin.2006.09.015
76. Euribor rates (2021.), *12 months Euribor rate* [podatkovni dokument], preuzeto s https://www.euribor-rates.eu/euribor-rate-12-months.asp
77. Europska središnja banka, ECB (2021.), *Statistička baza podataka* [podatkovni dokument], preuzeto s http://sdw.ecb.europa.eu/home.do.
78. Europsko nadzorno tijelo za osiguranje i strukovno mirovinsko osiguranje, EIOPA (2022.), *Insurance statistics* [podatkovni dokument], preuzeto s https://www.eiopa.europa.eu/tools-and-data/statistics-and-risk-dashboards/insurance-statistics_en
79. Fabozzi F. i Markowitz, H. M. (2011.), *The Theory and Practice of Investment Management: Asset Allocation, Valuation, Portfolio Construction, and Strategies*, Wiley
80. Fama, E. (1965.), The Behaviour of Stock Market Prices, *The Journal of Business*, *38*(1), 34–105. https://doi.org/10.1086/294743
81. Favre, L. (2010.), Hedge Fund, u: Reid, C. D. (ur.), *Encyclopedia of alternative investments*, (str. 16.), Reference Reviews
82. Fischer E. O. i Lind-Braucher S. (2010.), Optimal Portfolios with Traditional and Alternative Investments: An Empirical Investigation, *The Journal of Alternative Investments, 13*(2), 58-77. https://doi.org/10.3905/jai.2010.13.2.058
83. Fischer, K. i Schlütter, S. (2015.), Optimal Investment Strategies for Insurance Companies when Capital Requirements are Imposed by a Standard Formula, *Geneva Papers on Risk and Insurance. Issues and Practice*, *40*(1), 15–40. https://doi.org/10.1057/grir.2014.6
84. Flifel, K. (2014.), Impact of hedge funds on traditional investment products, *The Journal of Applied Business and Economics, 16*(3), 35. http://www.na-businesspress.com/JABE/FlifelK_Web16_3_.pdf
85. Fong, H. G. i Guin., L. D. (2007.), Fixed-Income Portfolio Management, u: Maginn L., Tuttle D.L., McLeavey D.W., Pinto J.E. (ur.), *Managing investment portfolios. A dynamic process*, (str. 328-406.), Wiley, Hoboken
86. Gautefall C. J. i Chen, V. (2017.), *Higher-moment portfolios with practical constraints based on Polynomial goal programming*, magistarski rad, preuzeto s http://hdl.handle.net/11250/2453527

87. Geman, H. (2008.), *Risk management in commodities markets: from shipping to agriculturals and energy*, Cham: Wiley
88. Glawischnig, M. i Seidl, I. (2013.), Portfolio optimization with serially correlated, skewed and fat tailed index returns: CEJOR, *Central European Journal of Operations Research, 21*(1), 153-176. https://doi.org/10.1007/s10100-011-0219-2
89. Guidolin, M. i Pedio, M. (2018.), *Essentials of Time Series for Financial Applications*, Cham: Academic Press
90. Harvey, C. R., Hoyle E., Rattray S., Sargaison i Van Hemert, T. (2019.), The Best of Strategies for the Worst of Times: Can Portfolios Be Crisis Proofed, *Journal of Portfolio Management, 45*(5), 7-28. https://doi.org/10.3905/jpm.2019.45.5.007
91. Harvey, C. R., Liechty, J. C., Liechty, M. W. i Müller, P. (2010.), Portfolio Selection with Higher Moments, *Quantitative Finance, 10*(5), 469-485. https://doi.org/10.1080/14697681003756877
92. Heerden, C. v., Heymans, A., Vuuren, G. v. i Brand, W. (2014.), A Risk-Adjusted Performance Evaluation Of US And EU Hedge Funds And Associated Equity Markets Over The 2007-2009 Financial Crisis, *The International Business & Economics Research Journal, 13*(1), 169-190. https://doi.org/10.19030/iber.v13i1.8367
93. Hitaj A. i Mercuri L. (2013.), Hedge Fund Portfolio Allocation with Higher Moments and MVG Models, u: Batten J.A., MacKay P., Wagner N. (ur.), *Advances in Financial Risk Management* (str. 331-346), London: Palgrave Macmillan
94. Hoffman, B. i Kaminski, K. (2016.), *The Taming of the Skew*, Campbell White Paper Series, [e-publikacija], preuzeto s https://www.hvst.com/posts/timely-new-campbell-company-white-paper-the-taming-of-the-skew-XWaTZYaj/attachment/the-taming-of-the-skew-campbell-company-pdf-095209?download=True
95. Hrvatska agencija za nadzor financijskih usluga (HANFA), Pravilnik o minimalnim standardima, načinu obračuna i mjerilima za izračun tehničkih pričuva prema računovodstvenim propisima, Narodne novine br. 10/16., 42/17. i 59/2017. (2016.)
96. Hrvatska agencija za nadzor financijskih usluga, HANFA (2022.), *B-12 Neto imovina alternativnih investicijskih fondova* [podatkovni dokument], preuzeto s https://www.hanfa.hr/publikacije/statistika/
97. Hrvatska narodna banka (2021.), *Nacionalna referentna stopa (NRS)* [podatkovni dokument], preuzeto s https://www.hnb.hr/nrs
98. Hrvatska udruga banaka (2021.), *NRS* [podatkovni dokument], preuzeto s https://www.hub.hr/sites/default/files/inline-files/NRS-2019-1q-objava_1.pdf

99. Hrvatska udruga banaka (2021.), *ZIBOR* [podatkovni dokument], preuzeto s https://www.hub.hr/index.php/hr/zibor
100. Hrvatski ured za osiguranje, HUO (2021.), Ključne informacije o tržištu osiguranja u Republici Hrvatskoj u 2020. godini [e-publikacija], preuzeto s https://huo.hr/upload_data/site_files/kljucne-informacije-4.pdf
101. Hrvatski ured za osiguranje, HUO (2022.), Ključne informacije o tržištu osiguranja u Republici Hrvatskoj u 2021. godini [e-publikacija], preuzeto s https://huo.hr/upload_data/site_files/kljucne-informacije-web-8.7.pdf
102. Hrvatski ured za osiguranje, HUO (2022.), *Statistika (Mjesečna izdanja)* [podatkovni dokument], preuzeto s https://huo.hr/hr/statistika
103. Hull J.C. (2017.), *Options, futures, and other derivatives*, Cham: Prentice Hall
104. Hurst, B., Hua Ooi, Y. i Pedersen, L. H. (2013.), Demystifying Managed Futures, *Journal of Investment Management 11*(3), 42–58. https://images.aqr.com/-/media/AQR/Documents/Insights/Journal-Article/Demystifying-Managed-Futures.pdf
105. Hurst, B., Hua Ooi, Y. i Pedersen, L. H. (2017.), A Century of Evidence on Trend-Following Investing, *Journal of Portfolio Management 44*(1), 15–29. https://doi.org/10.3905/jpm.2017.44.1.015
106. Insurance Europe (2019.), *Insurance Europe Annual Report 2018–2019* [e-publikacija], preuzeto s https://www.insuranceeurope.eu/publications/706/annual-report-2018-2019/
107. Insurance Europe (2022.), *Solvency II Review and Insurance Recovery & Resolution Directive* [e-publikacija], preuzeto s https://www.insuranceeurope.eu/priorities/5/solvency-ii
108. J.P. Morgan (2022.), *Guide to Alternatives* [e-publikacija], preuzeto s https://am.jpmorgan.com/us/en/asset-management/adv/insights/market-insights/guide-to-alternatives/
109. J.P. Morgan (2022.), *Guide to Alternatives 4Q 2022* [e-publikacija], preuzeto s https://am.jpmorgan.com/us/en/asset-management/adv/insights/market-insights/guide-to-alternatives/
110. Jaggi, A., Jeanneret, P. i Scholz, S. (2011.), Boost your traditional portfolio: Activate traditional asset classes with alternative investments, *Journal of Derivatives & Hedge Funds*, *17*(2), 133–150. https://doi.org/10.1057/jdhf.2011.7
111. Jakšić, S. (2008.), Utjecaj monetarnog agregata M4 i kamatnih stopa na CROBEX, *Zbornik Ekonomskog fakulteta u Zagrebu, 6* (1), 131-139. https://hrcak.srce.hr/30950

112. Jareño, F., Tolentino, M., González, María de la O i Oliver, A. (2019.), Impact of changes in the level, slope and curvature of interest rates on U.S. sector returns: An asymmetric nonlinear cointegration approach, *Economic Research - Ekonomska Istraživanja, 32*(1), 1275-1297. https://doi.org/10.1080/1331677X.2019.1632726

113. Jean, W. H. (1971.), The Extension of Portfolio Analysis to Three or More Parameters, *The Journal of Financial and Quantitative Analysis*, *6*(1), 505–515. https://doi.org/10.2307/2330125

114. Jean, W. H. (1973.), More on Multidimensional Portfolio Analysis, *The Journal of Financial and Quantitative Analysis*, *8*(3), 475–490. https://doi.org/10.2307/2329646

115. Joenvaarra, J., Kauppila, M., Kosowski, R. i Tolone., P. (2012.), *Hedge Fund Performance: Are Stylized Facts Sensitive to Which Database One Uses?, Critical Finance Review, Forthcoming, SSRN Electronic Journal*, preuzeto s http://dx.doi.org/10.2139/ssrn.1989410

116. Jondeau, E. i Rockinger, M. (2006.), Optimal Portfolio Allocation under Higher Moments, *European Financial Management, 12*(1), 29–55. https://doi.org/10.1111/j.1354-7798.2006.00309.x

117. Jurczenko, E. i Maillet, B. (2006.), *Multi-moment Asset Allocation and Pricing Models*, Cham: John Wiley & Sons

118. Jurczenko, E., Maillet, B. i Merlin, P. (2006.), Hedge Fund Portfolio Selection with Higher-order Moments: A Nonparametric Mean-Variance-Skewness-Kurtosis Efficient Frontier, u: Jurczenko, E. i Maillet, B. (ur.), *Multi-moment Asset Allocation and Pricing Models*, (str. 51-66.), Wiley & Sons

119. Kat, H. M. (2004.), Managed futures and hedge funds: a match made in heaven, *Journal of investment management, 2*(1), 1–9. https://doi.org/10.1142/9789812569448_0006

120. Kat, H. M. (2005.), Integrating Hedge Funds into the Traditional Portfolio, *The Journal of Wealth Management, 7*(4), 51-57. https://doi.org/10.3905/jwm.2005.470615

121. Keating, C. i Shadwick, W. F. (2002.), A Universal Performance Measure, *Journal of Performance Measurement, 6*, 59-84.

122. Kemalbay, G., Özkut, C. M. i Franko, C. (2011.), Porfolio Selection with Higher Moments: a Polynomial Goal Programming Approach to ISE-30 Indeks, *Ekonometri Ve Istatistik Dergisi, 13*(1), 41-61.

123. Khan, K. I., Naqvi, Syed M. Waqar Azeem, Ghafoor, M. M. i Akash, R. S. I. (2020.), Sustainable portfolio optimization with higher-order moments of risk, *Sustainability (Basel, Switzerland), 12*(5), 2006. https://doi.org/10.3390/su12052006

124. Kouwenberg, R. (2018.), Strategic asset allocation for insurers under solvency II, *Journal of Asset Management, 19*(7), 447-459. https://doi.org/10.1057/s41260-018-0097-4

125. Kritzman, M. (2011.), The graceful aging of mean-variance optimization, *Journal of Portfolio Management, 37*(2), 3. https://doi.org/10.3905/jpm.2011.37.2.003

126. Lai K. K., Yu L. i Wang S. (2006.), Mean-variance-skewness-kurtosis-based portfolio optimization, *Proceedings of the First International Multi-Symposiums on Computer and Computational Sciences, 2*, 292-297. https://doi.org/10.1109/IMSCCS.2006.239

127. Lai, T. (1991.), Portfolio selection with skewness: A multiple-objective approach, *Review of Quantitative Finance and Accounting, 1*(3), 293-305. https://doi.org/10.1007/BF02408382

128. Ledoit, O. i Wolf., M. (2003.), Improved estimation of the covariance matrix of stock returns with an application to portfolio selection, *Journal of Empirical Finance, 10*(5), 603-621. https://doi.org/10.1016/S0927-5398(03)00007-0

129. Lee, W. (2011.), Risk-based asset allocation: A new answer to an old question?, *Journal of Portfolio Management, 37*(4), 11-28. https://doi.org/10.3905/jpm.2011.37.4.011

130. Lhabitant F. S. (2006.), *Handbook of hedge funds*, Cham: Wiley, Hoboken

131. Lintner, J. (1996.), The Potential Role of Managed Commodity Financial Futures Accounts (and/or Funds.) in Portfolios of Stocks and Bonds, u: Peters, C.C. i Warwick, B. (ur.), *The Handbook of Managed Futures: Performance, Evaluation & Analysis. McGraw-Hill Professional* (str. 99-137.), McGraw Hill Professional

132. Lo, A. W. (2001.), Risk Management for Hedge Funds: Introduction and Overview, *Financial Analysts Journal, 57*(6), 16–33. https://doi.org/10.2469/faj.v57.n6.2490

133. Lukač, Z. i Neralić, L. (2012.), *Operacijska istraživanja*, Zagreb, Element d.o.o.

134. Lütkepohl, H. (2006.), Forecasting with VARMA Models, u: Elliott, G., Granger, C. and Timmermann, A. (ur.), *Handbook of Economic Forecastingch* (str. 287-325.), Elsevier

135. Lütkepohl, H. i Netsunajev, A. (2018.), The Relation between Monetary Policy and the Stock Market in Europe, *Econometrics, 6*(3) doi:https://doi.org/10.3390/econometrics6030036

136. Maillard, S., Roncalli, T. i Teïletche, J. (2010.), The properties of equally weighted risk contribution portfolios, *Journal of Portfolio Management, 36*(4), 60–70. https://doi.org/10.3905/jpm.2010.36.4.060

137. Malevergne, Y. i Sornette, D. (2005.), Higher-Moment Portfolio Theory: Capitalizing on Behavioral Anomalies of Stock Markets, *Journal of Portfolio Management, 31*(4), 49-55. https://doi.org/10.3905/jpm.2005.570150

138. Mandelbrot, B. (1963.), The Variation of Certain Speculative Prices, *Journal of Business, 36*(4), 394-419. http://dx.doi.org/10.1086/294632

139. Mandelbrot, B. i Hudson, R. (2006.), *Misbehaviour of markets: A Fractal View of Financial Turbulence*, Cham: Basic Books

140. Manigart S. i Wright M. (2013.), Reassessing the relationships between private equity investors and their portfolio companies, *Small Business Economics, 40*(3), 479–492. https://doi.org/10.1007/s11187-011-9387-7

141. Markowitz, H. M. (1952.), Portfolio Selection, *Journal of Finance, 7*(1), 77–91. https://doi.org/10.2307/2975974

142. Markowitz, H. M. (1991.), Foundations of Portfolio Theory, *Journal of Finance 46*(2), 469-477. https://doi.org/10.2307/2328831

143. Martellini, L. i Ziemann, V. (2010.), Improved Estimates of Higher-Order Comoments and Implications for Portfolio Selecion, *The Review of Financial Studies, 23*(4), 1467-1502. https://doi.org/10.1093/rfs/hhp099

144. Meisner, J., Kristofer K. i Delano, J. (2012.), *Understanding the Managed Futures Stratey and its Role in the Institutional Portfolio*, [e-publikacija], preuzeto s https://www.cmegroup.com/education/files/understanding-managed-futures-role.pdf

145. Mhiri, M. i Prigent, J. L. (2010.), International Portfolio Optimization with Higher Moments, *International Journal of Economics and Finance, 2*(5), 157-169. 10.5539/ijef.v2n5p157

146. Miffre, J. i Fernandez-Perez, A. (2011.), The Case for Long-Short Commodity Investing, *Journal of Alternative Investments, 18*(1), 92-104. https://doi.org/10.3905/jai.2015.18.1.092

147. Ministarstvo financija (2022.), *Obveznice - domaće* [podatkovni dokument], preuzeto s https://mfin.gov.hr/istaknute-teme/javni-dug/obveznice-domace/2277

148. Möhlmann, A. (2021.), Interest rate risk of life insurers: Evidence from accounting dana, *Financial Management, 50*(2), 587. https://doi.org/10.1111/fima.l2305

149. Molyboga, M., Baek, S. i Bilson, J. F. O. (2017.), Assessing hedge fund performance with institutional constraints: evidence from CTA funds, *Journal of Asset Management, 18*(7), 547–565. https://doi.org/10.1057/s41260-017-0053-8

150. Moskowitz T. J., Ooi, Y. H. i Pedersen, L. H. (2012.), Time series momentum, *Journal of Financial Economics, 104*(2), 228-250. https://doi.org/10.1016/j.jfineco.2011.11.003

151. Myint S. i Famery F. (2012.), *The Handbook of Corporate Financial Risk Management,* 2. izd., Cham: Risk Books

152. Naqvi, B., Mirza, N., Azeem Naqvi, W.i Rizvi, S. K. A. (2017.), Portfolio optimisation with higher moments of risk at the pakistan stock exchange, *Economic Research-Ekonomska Istraživanja, 30*(1), 1594-1610. https://doi.org/10.1080/1331677X.2017.1340182

153. Odo, M. (2011.), *Skewness and Kurtosis* (A Zephyr working paper), preuzeto s https://www.styleadvisor.com/sites/default/files/article/zephyr_concepts_skewness_and_kurtosis_pdf_36978.pdf

154. Otruba, S., Quesada, C. i Scholz, S. (2006.), The added value of hedge funds in an asset-liability framework, *Journal of Asset Management, 6*(6), 433-444. https://doi.org/10.1057/palgrave.jam.2240193

155. Pascual, J. L i Cuellar, R. D. (2010.), *Assessment and Selection of Hedge Funds and Funds of Hedge Funds* [e-publikacija], preuzeto s https://biblioteca.cunef.edu/files/documentos/05_Assessment_and_selection_of_hedge_funds_JoaquinLopezPascual.pdf

156. Pascual, J. L. (2013.), The Investment in Hedge Funds as an Alternative Investment, u: Márquez, F. P. G. i Lev, B. (ur.), *Engineering Management* (str. 167-180.), IntechOpen

157. Pedersen, N., Page, S. i He, F. (2014.), Asset allocation: Risk models for alternative investments, *Financial Analysts Journal, 70*(3), 34-45. https://doi.org/10.2469/faj.v70.n3.4

158. Peterson, S. (2012.), *Investment theory and risk management*, Cham: Wiley

159. Pionline (2022.), The largest hedge fund managers 2021, preuzeto 15. listopada 2022. s https://www.pionline.com/interactive/largest-hedge-fund-managers-2021

160. Popova, I., Morton, D., Popova, E. i Yau, J. (2007.), Optimizing benchmark-based portfolios with hedge funds, *Journal of Alternative Investments 10*(1), 35–55. https://doi.org/10.3905/jai.2007.688992

161. Prakash, A., Chang, C.H. i Pactwa, E. (2003.), Selecting a Portfolio with Skewness: recent Evidence from US, European, and Latin America Equity Markets, *Journal of Banking and Finance 27*(7), 1375–1390. https://doi.org/10.1016/S0378-4266(02)00261-3

162. PREQIN, (2020.)*, PREQIN Markets in focus: Alternative assets in Europe, September 2020* [e-publikacija], preuzeto s https://www.preqin.com/insights/research/reports/2020-preqin-markets-in-focus-alternative-assets-in-europe

163. Rambo, J. i Van Vuuren, G. (2017.), An omega ratio analysis of global hedge fund returns, *Journal of Applied Business Research, 33(3)*, 565-586. https://doi.org/10.19030/jabr.v33i3.9947

164. Romero, P. J. i Balch, T. (2015.), *What Hedge Funds Really Do: An Introduction to Portfolio Management*, New York, Business Expert Press

165. Rubinstein, M. (1973.), The Fundamental Theorem of Parameter-preference Security Valuation, *The Journal of Financial and Quantitative Analysis*, *8*(1), 61–69. https://doi.org/10.2307/2329748

166. Samuelson, A. P. (1967.), General Proof that Diversification Pays, *The Journal of Financial and Quantitative Analysis, 2*(1), 1-13. https://doi.org/10.2307/2329779

167. Samuelson, A. P. (1970.), The Fundamental Approximation Theorem of Portfolio Analysis in terms of Means, Variances and Higher Moments, *The Review of Economic Studies, 37*(4), 537–542. https://doi.org/10.2307/2296483

168. Saranya, K. i Prasanna, P. K. (2014.), Portfolio selection and optimization with higher moments: Evidence from the indian stock market, *Asia-Pacific Financial Markets, 21*(2), 133-149. https://doi.org/10.1007/s10690-014-9180-0

169. Savona, R. (2016.), Hedge Fund Performance, u: Basile, I., Ferrari, P. (ur.), *Asset Management and Institutional Investors* (str. 403-431.), Springer

170. Schneeweis T., Kazemi H. i Szado E. (2011.), Hedge fund database "deconstruction": are hedge fund databases half full or half empty?, *Journal of Alternative Investments 14*(2), 65–88. https://doi.org/10.3905/jai.2011.14.2.065

171. Scott, R. i P. Horvath (1980.), On the Direction of Preference for Moments of Higher Order Than the Variance, *The Journal of Finance*, *35*(4), 915–919. https://doi.org/10.2307/2327209

172. Sharpe F. W., Peng C., Pinto E. J. i McLeavy W. D. (2007.), Asset Allocation, u: Maginn L., Tuttle D.L., McLeavey D.W., Pinto J.E. (ur.), *Managing investment portfolios. A dynamic process* (str. 230-327.), Wiley, Hoboken

173. Siew, L. W., Jaaman, S. H. i Hoe, L. W. (2021.), Higher moment of portfolio optimization with polynomial goal programming approach*, Journal of Physics. Conference* Series, 1988(1), 12001. https://doi.org/10.1088/1742-6596/1988/1/012001

174. Steenkamp, T. B. M., Hoevenaars, R., Schotman, P. C. i Molenaar, R. D. J. (2008.), Strategic asset allocation with liabilities: Beyond stocks and bonds, *Journal of Economic Dynamics & Control, 32*(9), 2939-2970. https://doi.org/10.1016/j.jedc.2007.11.003

175. Stenki, O. i Mohammad, Z. (2015.), Common Metrics for Performance Evaluation: Overview of Popular Performance Measurement Ratios, *SSRN Electronic Journal*, preuzeto s: https://dx.doi.org/10.2139/ssrn.2662054

176. Sunrise Capital (2016.), *Why Tactical Macro Investing Still Makes Sense, Sunrise Capital* [e-publikacija], preuzeto s https://www.trendfollowing.com/pdfs/Revisiting_Kats_Managed_Futures_Hedge_Funds_Match_Made_Heaven.pdf

177. Swinkels, L., Blitz, D., Hallerbach, W. i van Vliet, P. (2018.), Equity solvency capital requirements - what institutional regulation can learn from private investor regulation, *Geneva Papers on Risk and Insurance. Issues and Practice, 43*(4), 633-652. https://doi.org/10.1057/s41288-018-0086-3

178. Šego, B., Gardijan Kedžo, M. i Škrinjarić, T. (2018.), *Odabrana poglavlja matematičkih metoda za upravljanje financijskom imovinom*, Zagreb: Ekonomski fakultet

179. Šimić, M. (2017.), *Mjere asimetrije podataka*, Diplomski rad, Prirodoslovno-matematički fakultet u Zagrebu, Zagreb

180. Škrinjarić, T. (2013.), *Modeli optimizacije portfelja uz više momente u burzovnom poslovanju*, postdiplomski specijalistički rad, Ekonomski fakultet u Zagrebu, Zagreb

181. Škrinjarić, T. (2013.), Portfolio Selection with Higher Moments and Application on Zagreb Stock Exchange, *Zagreb international review of economics & business, 16*(1), 65-78. https://hrcak.srce.hr/102022

182. Škunca, F. (2016.), *Upravljanje rizicima investicijskog portfelja društava za osiguranje*, Diplomski rad, Ekonomski fakultet u Zagrebu, Zagreb

183. Šonje, V., Alajbeg, D. i Bubaš, Z. (2011.), Efficient market hypothesis: is the croatian stock market as (in)efficient as the U.S. market, *Financial theory and practice, 35*(3), 301-326. https://hrcak.srce.hr/71567

184. Štimac, D. (2012.), *Analiza portfelja i opravdanosti limita ulaganja mirovinskih fondova*, doktorski rad, Ekonomski fakultet u Zagrebu, Zagreb

185. Teo, M., (2011.), The liquidity risk of liquid hedge funds, *Journal of Financial Economics, 100*(1), 24-44. https://doi.org/10.1016/j.jfineco.2010.11.003

186. Tschampion R. C., Siegel L. B., Takahashi D. J. i Maginn J. L. (2007.), Managing institutional investor portfolios, u: Maginn L., Tuttle D. L., McLeavey D. W., Pinto J. E. (ur.), *Managing investment portfolios. A dynamic process* (str. 63-127.), Wiley, Hoboken

187. Vaughan, E.J. i Vaughan, T. (2008.), *Fundamentals of Risk and Insurance*, 10. izd., John Wiley, Hobo-ken

188. Verbeek, M. (2010.), Alternative Asset Class, u: Reid, C. D. (ur.), *Encyclopedia of alternative investments* (str. 16.), Reference Reviews

189. Vidović, J. (2010.), *Model optimizacije portfelja dionica na tržištima kapitala zemalja novih članica i kandidata za ulazak u EU*, doktorski rad, Ekonomski fakultet u Splitu, Split
190. Vlada Republike Hrvatske (2020.), *Nacionalni plan zamjene hrvatske kune eurom* [e-publikacija], preuzeto s https://euro.hnb.hr/documents/2070751/2104255/Nacionalni-plan-zamjene-hrvatsk-kune-eurom_prosinac-2020.pdf/6bcd2d43-5ef8-1a8d-00d186b9a71c696f
191. Woerheide, W. i Persson, D. (1993.), An index of portfolio diversification, *Financial Services Review, 2*(2), 73–85. https://doi.org/10.1016/1057-0810(92)90003-U
192. Xu, Q., Jiang, C. i Kang, P. (2007.), Dynamic Portfolio Selection with Higher Moments Risk Based on Polynomial Goal Programming*, International Conference on Management Science and Engineering*, 2152– 2157. https://doi.org/10.1109/ICMSE.2007.4422158
193. Yang, C. W. i Hung, K. (2010.), A Generalized Markowitz Portfolio Selection Model with Higher Moments, *International Review of Accounting, Banking and Finance, 2*(1), 1-7. http://www.irabf.org/upload/journal/prog/2010v2n1_1.pdf
194. Yau J. K., Schneeweis T., Robinson T. R. i Weiss L. R. (2007.), Alternative investments portfolio management, u: Maginn L., Tuttle D. L., McLeavey D. W. i Pinto J. E. (ur.), *Managing investment portfolios. A dynamic process* (str. 477-578.), Wiley, Hoboken
195. Young, M. R. (1998.), A Minimax Portfolio Selection Rule with Linear Programming Solution, *Management Science, 44*(5), 673–683. https://doi.org/10.1287/mnsc.44.5.673
196. Zagrebačka burza, ZSE (2021.), *CROBEX* [podatkovni dokument], preuzeto s https://zse.hr/hr/indeks/365?isin=HRZB00ICBEX6&tab=index_history
197. Zagrebačka burza, ZSE (2021.), *CROBEXtr* [podatkovni dokument], preuzeto s https://zse.hr/hr/indeks/365?isin=HRZB00ICBTR6&tab=index_history
198. Zagrebačka burza, ZSE (2021.), *CROBIS* [podatkovni dokument], preuzeto s https://zse.hr/hr/indeks/365?isin=HRZB00ICRBS8&tab=index_history
199. Zagrebačka burza, ZSE (2021.), *CROBIStr* [podatkovni dokument], preuzeto s https://zse.hr/hr/indeks/365?isin=HRZB00ICRBT6&tab=index_history
200. Zakamouline, V. (2009.), The Choice of Performance Measure Does Influence the Evaluation of Hedge Funds, *SSRN Electronic Journal*, preuzeto s: https://dx.doi.org/10.2139/ssrn.1403246
201. Zakon o osiguranju - neslužbeni pročišćeni tekst Narodne Novine br. 30/15., 112/18., 63/20., 133/20. (2015.)

POPIS TABLICA

Tablica 1 – Korelacija prinosa *hedge* fondova s tradicionalnim oblicima ulaganja (1994-2015) 2
Tablica 2 – Investicijska strategija društava za osiguranje 19
Tablica 3 – Primjer strateške alokacije investicijskog portfelja 20
Tablica 4 – Glavne vrste tržišnih rizika 26
Tablica 5 - Pregled alternativnih modela optimizacije 35
Tablica 6 – Vrste hedge fondova prema kriteriju investicijske strategije 53
Tablica 7 – Korelacija prinosa hedge fondova, tradicionalnih i alternativnih oblika ulaganja u periodu 2008 - 1Q 2022 69
Tablica 8 – Povijesne korelacije ročnica s ostalim oblicima ulaganja 70
Tablica 9 - Prednosti, troškovi i rizici direktnih i vlasničkih ulaganja u nekretnine 73
Tablica 10 – Korelacija prinosa nekretnina s dionicama i obveznicama (2008 - 1Q 2022) 74
Tablica 11 - Korelacija prinosa privatnih ulaganja s ostalim oblicima (2008. – 1Q 2022.) 77
Tablica 12 – Vodič za dubinsku analizu (eng. *due diligence*) upravitelja hedge fondova 81
Tablica 13 – Pregled globalnih upravitelja hedge fondova u 2021. godini (u mil. USD) 83
Tablica 14 - Pregled upravitelja hedge fondova na području Europe (u mil. EUR) 84
Tablica 15 - Pregled globalnih upravitelja fondova ročnica (eng. *managed futures*) u mil. USD 84
Tablica 16 - Pregled upravitelja i alternativnih fondova u Republici Hrvatskoj 85
Tablica 17 – Pregled načela AIFM Direktive 88
Tablica 18 – Udio imovine društava za osiguranje u financijskom sustavu RH (u mil. HRK) 90
Tablica 19 - Definicije vrsta tržišnog rizika 103
Tablica 20 - Međuzavisnost oblika ulaganja i tretmana tržišnog rizika 104
Tablica 21 - Društva koja ulažu suboptimalne iznose u oblike ulaganja radi primjene Solventnosti II (rezultati ankete) 106
Tablica 22 - Deskriptivna statistika odabranih tradicionalnih i alternativnih oblika ulaganja 125
Tablica 23 – Koeficijenti korelacija promatranih oblika ulaganja 126
Tablica 24 – Rezultati optimizacije (portfelji 1-10) 127
Tablica 25 - Rezultati optimizacije (portfelji 11-19) 129
Tablica 26 - Rezultati optimizacije (portfelji 21-28) 130

Tablica 27 – Vrijednosti momenata 4 portfelja dobivenih optimizacijom iz prve faze (P_1-P_4) 133
Tablica 28 - Struktura udjela oblika ulaganja u portfeljima dobivenih optimizacijom problema P_1 – P_4 (prva faza)..... 133
Tablica 29 – Vrijednosti momenata optimalnog portfelja dobivenog višekriterijskom optimizacijom (druga faza) – MVSK portfelj 135
Tablica 30 - Struktura optimalnog portfelja dobivenog višekriterijskom optimizacijom (2. faza) 135
Tablica 31 – Rezultati Markowitzeve (MV) i višekriterijske (MVSK) optimizacije 137
Tablica 32 – Rezultati optimizacije primjenom ograničenja udjela na oblike ulaganja 138
Tablica 33 – Rezultati testiranja stacionarnosti varijabli 141
Tablica 34 - Rezultati procjene VAR(1) modela – varijabla EURIBOR 143
Tablica 35 – Rezultati Grangerovog testa uzročnosti za VAR(1) model 143
Tablica 36 – Koeficijenti funkcije impulsnog odziva (EURIBOR impulsna varijabla) 144
Tablica 37 - Koeficijenti kumulativne funkcije impulsnog odziva (EURIBOR impulsna varijabla)..... 145
Tablica 38 – Dekompozicija varijance modela VAR (1) – varijabla EURIBOR 145
Tablica 39 – Dekompozicija varijance modela VAR (1) – varijabla CROBIStr 146
Tablica 40 - Dekompozicija varijance modela VAR (1) – varijabla CROBEXtr 146
Tablica 41 - Dekompozicija varijance modela VAR (1) – varijabla Hedge fund 147
Tablica 42 - Dekompozicija varijance modela VAR (1) – varijabla Mfutures 147
Tablica 43 – Multivarijatni test autokorelacije reziduala 149
Tablica 44 - Multivarijatni test heteroskedastičnosti reziduala u VAR(1) modelu..... 149
Tablica 45 - Univarijatni test heteroskedastičnosti reziduala u VAR(1) modelu..... 150

POPIS SLIKA

Slika 1- Usporedba normalne (A), leptokurtične (B) i platikurtične (C) distribucije 38
Slika 2 – Asimetrična i simetrična (normalna) distribucija..... 38
Slika 3 – Strategije privatnog kapitala i financiranje razvoja poduzeća 76
Slika 4 – Struktura ulaganja društava za osiguranje (2017.-2021. godina)..... 92
Slika 5 – Podjela regulative Solventnost II na 3 stupa 98
Slika 6 – Usporedba regulative Solventnost I i II na primjeru računovodstvenih aspekata..... 99
Slika 7 – Standardni model izračuna potrebnog solventnog kapitala 101

Slika 8 – Funkcija impulsnog odziva za model VAR (1) i šok u varijabli EURIBOR 144

POPIS SHEMA

Shema 1 – Tradicionalni i alternativni oblici ulaganja 48
Shema 2 – Primjer toka novca kod odvojenih računa (eng. *managed account*) 67
Shema 3 – Pregled ulaganja u upravljane ročnice (eng. *managed futures*) 67

POPIS GRAFOVA

Graf 1 – Efikasna granica sa i bez uključivanja alternativnih oblika ulaganja 9
Graf 2 - Efikasna granica kao rezultat Markowitzeva modela 33
Graf 3 – Kumulativna distribucija i Omega mjera 47
Graf 4 – Vrijednost imovine pod upravljanjem hedge fondova globalno (u mlrd. USD) 51
Graf 5 – Prinosi i volatilnost odabranih oblika ulaganja (1994-2015) 52
Graf 6 - Godišnji prinosi hedge fondova (*Barclay Hedge Fund Index*) u periodu 1997-2022 57
Graf 7 – Imovina alternativnih fondova u RH u periodu 2013 - 2021. (u '000 EUR) 59
Graf 8 - Vrijednost imovine pod upravljanjem (AUM) industrije ročnica (u mlrd. USD) 61
Graf 9 – Godišnji prinosi BTOP50 indeksa u periodu 2006.-2022. godine 66
Graf 10 - Korelacija prinosa hedge fondova s teoretskim 60/40 portfeljem dionica i obveznica 68
Graf 11 – Efikasna granica investicijskog portfelja sastavljenog od ročnica, dionica i obveznica u periodu 1987-2014. 71
Graf 12 – Kretanje vrijednosti ICSN indeksa u periodu 2002.-2021. (2015. = 100) 74
Graf 13 – Imovina fondova privatnog kapitala u RH (u '000 EUR) 77
Graf 14 – Prinos i rizik odabranih indeksa uključujući i robne indekse u periodu 2001-2015 79
Graf 15 – Pregled prvih 10 osiguratelja na RH tržištu prema zaračunatoj premiji na kraju 2021. godine (u mil. HRK) 91
Graf 16 - Visina ulaganja društava za osiguranje na tržištu RH (u mil. EUR) 93
Graf 17 - Apsolutna struktura ulaganja RH osiguratelja u periodu 2016.-2021. (u mil. EUR) 94
Graf 18 - Relativna struktura oblika ulaganja u periodu 2016.- 2021. godine 94
Graf 19 - Visina ulaganja društava za osiguranje zemalja EU (u mil. EUR) 95
Graf 20 - Relativna struktura oblika ulaganja zemalja EU 95
Graf 21 – Udio alternativnih fondova u investicijskom portfelju EU osiguratelja na kraju 2021. godine 97

Graf 22 – Grafički prikaz koncepta ekonomskog kapitala, solventnosti i kapitalnih zahtjeva 102
Graf 23 – Prosječni i medijalni SCR omjer društava za osiguranje na RH tržištu (2016.-2021.) 107
Graf 24 – Struktura potrebnog solventnog kapitala osiguratelja na RH tržištu na 31.12.2020. 108
Graf 25 – Utjecaj uključivanja alternativnih oblika ulaganja u investicijski portfelj na omjer solventnosti društava za osiguranje 110
Graf 26 - Kretanje minimalnih garancija po policama životnih osiguranja na RH tržištu 112
Graf 27 – Premija i broj polica mješovitih životnih osiguranja (u EUR) 113
Graf 28 - Premija i broj polica investicijskih životnih osiguranja (u EUR) 113
Graf 29 - Kretanje referentne kamatne stope Europske Središnje Banke (ESB) u analiziranom razdoblju 114
Graf 30 - Kretanje referentnih kamatnih stopa u RH u analiziranom razdoblju 114
Graf 31 – Prinos (u %) na 10-godišnje državne obveznice u periodu 12/2012-02/2022 115
Graf 32 - Pregled državnih obveznice i dospijeće po godinama (u mil. EUR) 115

ŽIVOTOPIS

OSOBNI PODACI

Ime i prezime: Filip Škunca
Adresa: Fijanova 8, 10000 Zagreb
Kontakt: +385 91 3172 194
E-mail: skuncaf@gmail.com
Datum i mjesto rođenja: 15.01.1989., Zadar



RADNO ISKUSTVO

Listopad 2016. –	**Voditelj Samostalne službe za upravljanje rizicima,** Triglav osiguranje d.d.
Travanj 2013. – Rujan 2016.	**Risk manager,** Triglav osiguranje d.d.
Rujan – Prosinac 2012.	**Stručna praksa**, Triglav osiguranje d.d.

EDUKACIJA

Listopad 2016. –	**Poslijediplomski (doktorski) studij ekonomije i poslovne ekonomije** Sveučilište u Zagrebu - Ekonomski fakultet
Listopad 2018.- Svibanj 2019.	**Triglav Insurance Business Academy** Center of Business Excellence, Faculty of Economics in Ljubljana
Lipanj 2016.	**Magistar ekonomije, Smjer: Financije** Sveučilište u Zagrebu - Ekonomski fakultet
Siječanj 2013.	**Master in insurance and risk management** MIB School of management, Trst, Italija
Listopad 2011.	**Sveučilišni prvostupnik ekonomije** Sveučilište u Zagrebu - Ekonomski fakultet

PROFESIONALNA I DODATNA EDUKACIJA (SEMINARI)

- Temeljni seminar o osiguranju, diploma Hrvatskog ureda za osiguranje, Zagreb,
- Centar za edukaciju djelatnika u osiguranju (CEDOH) pri Hrvatskom uredu za osiguranje,
    - Own Risk and Solvency Assessment (ORSA), Zagreb,
    - Integrirano upravljanje rizicima u društvima za osiguranje,
- Insurance risk management academy, 2015. (OP2M d.o.o.)
- Stručna praksa u matičnom Društvu iz područja upravljanja sustavom poslovnih procesa (Zavarovalnica Triglav d.d.),

- Hrvatski ured za osiguranje, Hrvatski dani osiguranja 2015.-2019.; Opatija

NAGRADE I ČLANSTVA U UDRUGAMA

- **Nagrada** za najbolji diplomski rad iz područja osiguranja, Hrvatski dani osiguranja 2016.
- Član Komisije za upravljanja rizicima pri Hrvatskom aktuarskom društvu (HAD)
- EFZG, MIB School of Management i Triglav alumni