

Dr. sc. Bojan Morić Milovanović

Viši asistent
Katedra za ekonomiku poduzeća
Ekonomski fakultet, Sveučilište u Zagrebu
E-mail: bmoric@efzg.hr

Marko Ćurković

Student prediplomskog sveučilišnog studija Ekonomija
Ekonomski fakultet, Sveučilište u Zagrebu
E-mail: marko.curkovic@finance.hr

UTJECAJ SVJETSKJE FINACIJSKE KRIZE NA FORMIRANJE MULTISEKTORSKI- DIVERZIFICIRANIH OPTIMALNIH PORTFELJA UZ POMOĆ MARKOWITZEVE TEORIJE NA ZAGREBAČKOJ BURZI

UDK / UDC: 336.761

JEL klasifikacija / JEL classification: G11

Stručni rad / Professional paper

Primljeno / Received: 5. studenog 2013. / November 2, 2013

Prihvaćeno za tisak / Accepted for publishing: 10. lipnja 2014. / June 10, 2014

Sažetak

Na Zagrebačku burzu su 22. veljače 2013. godine uvedeni sektorski indeksi iz čega se može zaključiti da u kontekstu razvoja hrvatskog tržišta kapitala na značenju dobiva promatranje prinosa i rizika po sektorima. Cilj ovoga rada je prikazati rezultate statističke analize povrata i rizik na odabrane dionice uvrštene u sektorske indekse kroz duže razdoblje kako bi se dobila slika o rezultatima pojedinih sektora prije i za vrijeme krize pri čemu je uz pomoć korelacijske matrice provedena analiza povezanosti kretanja cijene dionica. U dosadašnjim radovima vezanima uz kreiranje optimalnog portfelja uz pomoć Markowitzove teorije na hrvatskom tržištu kapitala, optimalni se portfelj kreirao na bazi tjednih podataka ili na bazi mjesečnih podataka prije 2005. godine. Doprinos ovog rada predstavlja analiza utjecaja svjetske financijske krize na uspješnost različitih sektorskih indeksa Zagrebačke burze.

Ključne riječi: Markowitzeva teorija, moderna teorija portfelja, Zagrebačka burza, sektorska diverzifikacija, svjetska financijska kriza.

1. UVOD

Portfelj predstavlja skup imovine koju posjeduje pojedinac ili organizacija da bi na bazi diverzifikacije smanjio rizik ulaganja te tako najbolje zaštitio svoje interese (Bodie, Kane i Marcus, 2006). U kontekstu financija, portfelj se promatra u investicijskom smislu, tj. on se sastoji od vrijednosnih papira (Andrijašević i Petranović, 1999), a u ovom radu će se promatrati kao portfelj dionica. Kod odabira portfelja dionica ili drugih vrijednosnih papira, investitor promatra dva osnovna parametra: rizik i prinos, pri čemu je rizik izražen uz pomoć standardne devijacije, tj. odstupanja prinosa dionica od očekivane vrijednosti, dok se prinos mjeri rastom cijene dionice između dva razdoblja (Jakšić, 2007). U ovom je radu provedena sektorska analiza dionica prema spomenutim parametrima te je na temelju Markowitzve teorije kreiran optimalan portfelj kako bi se postigla redukcija rizika (Markowitz, 1952).

Cilj ovoga rada je analiza utjecaja krize na rizičnost i prinose sektora te analiza utjecaja krize na kretanje udjela sektora u optimalnim portfeljima, prije i nakon početka krize, ovisno visini zahtijevanog prinosa, a na temelju moderne teorije portfelja koju je razvio Harry Markowitz. U analizi su uključene dionice iz pet sektorskih indeksa sa Zagrebačke burze te su pritom uvedena ograničenja koje dionice moraju ispunjavati kako bi bile uključene u analizu. Nakon toga slijedi popis svih dionica uvrštenih u sektorske indekse te popis onih dionica koje su zadovoljile ograničenja i razlog otpisa ostalih dionica.

Interpretirani su rezultati i primijenjene su metode empirijske analize u skladu s ograničenjima i pretpostavkama Markowitzve teorije, a na temelju mjesečnih podataka u razdoblju od 1. siječnja 2005. do 31. siječnja 2013. godine. Uspoređeni su prinosi i rizici pojedinih sektora, prije i nakon početka krize, a kao početak krize, uzet je listopad 2008. godine kada je propala jedna od najvećih investicijskih banaka na svijetu – Lehman Brothers, a dionički indeks Zagrebačke burze – CROBEX ostvario treći najveći dnevni pad u povijesti (-11,36%). Na kraju je dan osvrt na mogućnosti i nedostatke korištenja Markowitzve teorije na hrvatskom tržištu kapitala te osvrt na rezultate analize utjecaja krize na prinos i rizičnost pojedinih sektora.

2. ULOGA MARKOWITZEVE TEORIJE U KREIRANJU OPTIMALNOG PORTFELJA

Jedna od najpoznatijih teorija pronalaza optimalnog portfelja vrijednosnih papira je Markowitzeva teorija, tj. moderna teorija portfelja (eng. *Modern Portfolio Theory* – MPT). Osnovne pretpostavke moderne teorije portfelja su: a) investitori su racionalni – tj. maksimizirati će prinos za danu razinu varijancu, b) prinosi vrijednosnih papira su normalno

distribuirane slučajne varijable, c) korelacije između vrijednosnih papira su fiksne i zauvijek konstantne, d) investitori imaju cilj maksimizirati svoju ekonomsku korist, e) svi investitori su racionalni i imaju averziju prema riziku, f) investitori su savršeno informirani, f) investitori imaju točna predviđanja mogućih prinosa, g) ne postoje porezi niti transakcijski troškovi, h) svi investitori su *price takeri*, tj. svojim djelovanjem nemaju utjecaja na kretanje cijena, i) svi vrijednosni papiri su savršeno djeljivi, j) rizik/volatilnost vrijednosnog papira je poznata i konstantna (Markowitz, 1959; Jerončić i Aljinović, 2011).

Temeljni model moderne teorije portfelja jest MV model¹, čiji cilj nije pronaći portfelj kojim se maksimizira očekivani prihod, već pronaći ravnotežu između dva osnovna parametra modela, prinosa i rizika (Markowitz, 1952). To se postiže minimizacijom rizika za zadanu razinu prinosa ili maksimizacijom prinosa za zadanu razinu rizika, a portfelj koji je rezultat tog procesa naziva se efikasan portfelj (Jerončić i Aljinović, 2011). Model pretpostavlja da investitori imaju averziju prema riziku, tj. da će između dva portfelja s jednakim očekivanim prinosom, izabrati onaj koji sadrži manje rizika. Visina rizika koju je pojedini investitor spreman prihvatiti ovisi o njegovim preferencijama, a investitori koji imaju veliku averziju prema riziku spremni su prihvatiti niži prinos za veću razinu sigurnosti, tj. manju razinu rizika, a obrnuto vrijedi za investitore koji imaju manju averziju prema riziku (Orsag, 2011). Sam rizik je izražen uz pomoć standardne devijacije, tj. odstupanje cijene dionica od njihovih očekivanih vrijednosti, dok se prinos mjeri rastom cijene dionice između dva razdoblja. (Aljinović, Marasović i Šego, 2011).

Kombiniranjem različitih vrsta vrijednosnih papira koji nisu savršeno korelirani, modelom se pokušava reducirati ukupnu varijancu, tj. rizik portfelja. Na rizik portfelja utjecaj ima broj dionica uvrštenih u portfelj, s tim da se povećanjem broja dionica rizik može reducirati, tj. smanjiti (Jakšić, 2007), stoga investitorov interes nije primarno orijentiran na rizičnost i prinos pojedinih dionica, već na rizičnost i prinos skupa dionica, tj. portfelja (Rubinstein, 2002). Istraživanja govore da se povećanjem broja dionica rizik smanjuje, ali po opadajućoj stopi, tj. dodavanjem svake nove dionice rizik, tj. korist od diverzifikacije se povećava za manji iznos u usporedbi s prethodno dodanom dionicom (Statman, 1987). Rizik portfelja može se reducirati ulaganjem u dionice poduzeća iz različitih sektora gospodarstva, što se još naziva i diverzifikacija (Van Horne, 1997). Diverzifikacijom se može smanjiti specifični rizik tvrtke, koji se može nazivati i diverzificirajućim ili nesistematskim rizikom (Brealey i Myers, 1991). Takav rizik ovisi o prilikama koje se odnose na jedno jedino konkretno poduzeće zbog čega se

¹ eng. Mean-variance model – model kojim se vrši trade-off između rizika i prinosa dionica na način da se za zadanu razinu rizika maksimizira prinos ili za zadanu razinu prinosa minimizira rizik, a konačan rezultat je optimalna kombinacija skupa dionica, tj. optimalni portfelj.

takav rizik može ukloniti diverzifikacijom portfelja. Rizik na koji investitor ne može utjecati je tržišni rizik, koji pokazuje stupanj sistemskog kretanja prinosa dionice, povezanog s kretanjem prinosa cjelokupnog tržišta vrijednosnih papira (Orsag, 2011).

Iako su osporavane mnoge pretpostavke moderne teorije portfelja poput onih koje se mogu sažeti u domenu teorije efikasnosti tržišta (Chopra, Lakonishok i Ritter, 1992) te pretpostavki poput savršene djeljivosti dionica i nepostojanja transakcijskih troškova, moderna teorija portfelja predstavlja najznačajniju inovaciju u 20. stoljeću na području upravljanja portfeljima. Ona je omogućila da se dotadašnja financijska i fundamentalna analiza, nadopune s vrlo moćnim statističkim alatom koji omogućuje kvantificiranje rizika (Jerončić i Aljinović, 2011). Na temelju moderne teorije portfelja razvijene su nove teorije i modeli poput postmoderne teorije portfelja² (Rom i Ferguson, 1993) i Black-Litterman modela³ (Black i Litterman, 1992) koji imaju široku primjenu u modernom upravljanju portfeljima.

3. METODE ISTRAŽIVANJA

3.1. Odabir dionica

Pri promatranju dionica, krenulo se od promatranja dionica iz sektorskih indeksa koji su od veljače 2013. godine uvršteni na Zagrebačku burzu. Radi se o indeksima CROBEXindustrija (industrijska proizvodnja), CROBEXkonstrukt (građevinarstvo), CROBEXnutris (proizvodnja i prerada hrane), CROBEXtransport (transport) i CROBEXturist (turizam).⁴ Uvođenje sektorskih indeksa olakšalo je sektorsku analizu dionica na Zagrebačkoj burzi, a dionice uvrštene u sektorske indekse imaju jednaku težinu, tj. jednak ponder. Sektorski indeksi uobičajena su pojava na velikim svjetskim burzama te je uvođenje istih na Zagrebačku burzu logičan nastavak praćenja svjetskih trendova na tržištima kapitala. Osim što su od dionica unutar indeksa, koje zadovoljavaju ograničenja formirani skupovi optimalnih portfelja, ovisnih o rizičnosti i prinosu, provedena je i analiza prinosa i rizika sektora, prije i poslije početka svjetske financijske krize na temelju mjesečnih podataka od 1. siječnja 2005. do 31. siječnja 2013. godine. Spomenuti indeksi sastoje se od ukupno 35 dionica, no samo 21 dionica

² Proširenje tradicionalne moderne teorije portfelja (MPT) od koje se razlikuje iz razloga što se kod post-moderne teorije portfelja kao poveznica između rizika i prinosa koristi interna stopa povrata (IRR). Kao mjera prinosa koristi se negativni rizik (eng. downside risk), a kao mjera rizika koristi se standardna devijacija negativnih prinosa, dok MPT koristi standardnu devijaciju svih prinosa.

³ Model kojeg su razvila dvojica zaposlenika Goldman Sachs – Fischer Black i Robert Litterman. Model je razvijen kako bi se prevladali problemi s kojima se institucionalni investitori susreću korištenjem moderne teorije portfelja u praksi. Za razliku od MPT-a model ne zahtjeva procjenu očekivanih prinosa, već zahtjeva samo procjenu razlike između očekivanih prinosa u odnosu na kretanje tržišta te stupanj pouzdanosti alternativnih procjena.

⁴ U radu se riječ „sektor“ koristi kao sinonim za sektorski indeks.

zadovoljava iduća ograničenja: a) trgovanje na Zagrebačkoj burzi počelo je u siječnju 2005. godine ili prije, b) dovoljno velika vremenska serija – minimalno 95 mjesečnih podataka. U tablici 1. navedeni su simboli i izdavatelji dionica koje su zadovoljile ograničenja te su razvrstane prema sektorskom indeksu u kojem se nalaze.

Tablica 1.

Dionice iz sektorskih dionica koje zadovoljavaju ograničenja

SEKTORSKI INDEKS	SIMBOL	IZDAVATELJ
CROBEX turist	ACI-R-A	ACI d.d.
	ARNT-R-A	Arenaturist d.d.
	HUPZ-R-A	HUP-Zagreb d.d.
	KORF-R-A	Valamar Adria holding d.d.
	RIVP-R-A	Riviera Adria d.d.
CROBEX transport	ATPL-R-A	Atlantska plovidba d.d.
	JDPL-R-A	Jadranska plovidba d.d.
	JNAF-R-A	Jadranski naftovod d.d.
	LKRI-R-A	Luka Rijeka d.d.
	ULPL-R-A	Uljanik Plovidba d.d.
CROBEX nutris	BD62-R-A	Badel 1862 d.d.
	KRAS-R-A	Kraš d.d.
	LEDO-R-A	Ledo d.d.
	PODR-R-A	Podravka d.d.
CROBEX konstrukt	DLKV-R-A	Dalekovod d.d.
	IGH-R-A	Institut IGH d.d.
	THNK-R-A	Tehnika d.d.
	VDKT-R-A	Viadukt d.d.
CROBEX industrija	ERNT-R-A	Ericsson Nikola Tesla d.d.
	KOEI-R-A	Končar d.d.
	PTKM-R-A	Petrokemija d.d.

Izvor: službena web stranica Zagrebačke burze [online]. Dostupno na: www.zse.hr

3.2. Opis istraživanja

Investitori se u izgradnji portfelja koriste dvama osnovnim izvorima informacija o učinku dionica (Markowitz, 1959.). Jedan pristup se temelji na povijesnim podacima o učinku dionica (*ex-post*), a drugi se temelji na očekivanjima u budućnosti (*ex-ante*) (Bendeković, 2000.). Uz pretpostavku da su povijesni podaci dobre procjene budućih kretanja, u ovom radu će naglasak biti upravo na povijesnim podacima. Kao što je već spomenuto, dva osnovna parametra kod odabira portfelja su prinos i rizik. Prinos se mjeri kretanjem tržišne cijene dionica, a iz tog razloga su promatrane prosječne dnevne cijene zadnjeg dana trgovanja u mjesecu u razdoblju od 1. siječnja 2005. do 31. siječnja 2013. godine, a za potrebe analize ovog rada promatrani su samo kapitalni dobitci. Radi mogućnosti usporedbe prinosa između dionica, korištene su relativne mjesečne promjene u logaritamskom obliku za 97 mjesečnih podataka, tj. 45 mjesečnih podataka za razdoblje prije početka krize i 52 mjesečna podatka za razdoblje nakon početka krize. Logaritamski prinos je prirodni logaritam omjera cijena iz razdoblja t i razdoblja $t-1$, što je prikazano u izrazu (1). Za cijenu određenog razdoblja uzet je zadnji dan u kojem se trgovalo promatranom dionicom u razdoblju t , tj. u promatranom mjesecu.

$$R_{it} = \ln\left(\frac{P_{it}}{P_{i,t-1}}\right) \quad (1)$$

R_t = povrat ulaganja u i -tu dionicu u razdoblju t

t = razdoblje t

P_{it} = cijena i -te dionice u razdoblju t

$P_{i,t-1}$ = cijena i -te dionice u razdoblju $t-1$

Kako bi se dobio prosječni prinos i -te dionice u promatranom razdoblju potrebno je podijeliti sumu svih mjesečnih logaritamskih prinosa s brojem podataka, tj. s brojem mjeseci uključenih u analizu, što je prikazano u izrazu (2).

$$E(R_{it}) = \bar{R}_i = \frac{1}{N} \sum_{t=1}^N R_{it} = \frac{1}{N} (R_{i1} + R_{i2} + R_{i3} + \dots + R_{iN}) \quad (2)$$

$E(R_i)$ = očekivani prinos i -te dionice u promatranom razdoblju

\bar{R}_i = prosječan prinos i -te dionice u promatranom razdoblju

R_{it} = povrat ulaganja u i -tu dionicu u razdoblju t

t = razdoblje t

N = broj mjesečnih podataka = 97

Prinos portfelja ovisi o prosječnim prinosima pojedinih dionica te o njihovom udjelu u portfelju, što je prikazano u izrazu (3).

$$E(R_p) = \sum_{i=1}^n w_i \bar{R}_i \quad (3)$$

\bar{R}_i = prosječan prinos i-te dionice u promatranom razdoblju

$E(R_p)$ = očekivani prinos portfelja

w_i = udjel i-te dionice u portfelju

n = broj dionica

Drugi osnovni parametar kod odabira portfelja je rizik. Rizik se mjeri varijancom, odnosno standardnom devijacijom (drugi korijen iz varijance), tj. odstupanjem vrijednosti cijene dionica od njihove prosječne (očekivane) vrijednosti (Statman, 1987) Varijanca se može izračunati ako se suma kvadrata odstupanja vrijednosti od očekivane vrijednosti podijeli s brojem mjesečnih podataka. Formula je prikazana u izrazu (4). Što su odstupanja od očekivane vrijednosti veća, to je veća i standardna devijacija, što znači da je i rizik promatrane dionice veći.

$$\hat{\sigma}_i^2 = \frac{1}{N} \sum_{t=1}^N (R_{it} - E(R_i))^2 \quad (4)$$

$E(R_i)$ = očekivani prinos i-te dionice u promatranom razdoblju

R_{it} = povrat ulaganja u i-tu dionicu u razdoblju t

$\hat{\sigma}_i^2$ = varijanca

t = razdoblje t

N = broj mjesečnih podataka = 97

No mnogo važniji rizik za investitora koji drži portfelj je tržišni rizik portfelja. (Rubinstein, 2002). Tržišni rizik ovisi o očekivanom riziku pojedinih dionica unutar portfelja, očekivanim kovarijancama prinosa između dionica i udjelu dionica u portfelju. No kod promatranja sektorskih indeksa tako da se svaki indeks može promatrati kao portfelj dionica, svaka dionica ima jednak udjel, tj. težinu u portfelju. Pet različitih sektorskih portfelja korišteni su kod analize utjecaja svjetske financijske krize na pojedini sektor, a kod formiranja optimalnih portfelja MV modelom, sve dionice iz tablice 1. formiraju portfelje prije i nakon početka krize te je zato potrebno odrediti optimalan udio svake pojedine dionice u portfelju, ovisno o rizičnosti i visini prinosa, što je napravljeno u tablicama 5. i 6.

$$\hat{\sigma}_p^2 = \sum_{i=1}^n w_i^2 \hat{\sigma}_i^2 + 2 \sum_{\substack{i,j=1 \\ i \neq j}}^n w_i w_j \sigma_{ij} \quad (5)$$

$\hat{\sigma}_p^2$ = varijanca portfelja

σ_{ij} = kovarijanca između i-te i j-te dionice

w_i = udjel i-te dionice u portfelju

w_j = udjel j-te dionice u portfelju

n = broj dionica u portfelju

Povezanost prinosa između dvije dionice mjeri se uz pomoć koeficijenta korelacije i kovarijance. A povezanost između dionica unutar određenog indeksa ili portfelja iskazuje se uz pomoć korelacijske matrice. Izrazom (6) je prikazana kovarijanca (prosječnih mjesečnih) prinosa između dvije promatrane dionice, čime se koristi pri izračunu varijance portfelja (izraz 4). Kovarijanca se dobije tako da se suma svih umnožaka odstupanja dionica od svojih prosječnih vrijednosti pomnoži s recipročnom vrijednošću broja podataka, tj. broja mjeseci (N).

$$\sigma_{ij} = \frac{1}{N} \sum_{t=1}^N [R_{it} - E(R_i)][(R_{jt} - E(R_j))] \quad (6)$$

σ_{ij} = kovarijanca između i-te i j-te dionice

$E(R_i)$ = očekivani prinos i-te dionice u promatranom razdoblju

R_{it} = povrat ulaganja u i-tu dionicu u razdoblju t

N = broj mjesečnih podataka = 97

Postoji više različitih vrsta koeficijenta korelacije, no prilikom rada s linearnim modelima koristi se Pearsonov koeficijent korelacije prikazan u izrazu (7), te je zato korišten i u ovom radu (Rodgers, Nicewander, 1988). Za izračun koeficijenta korelacije potrebno je izračunati kovarijancu između dionica te standardne devijacije svake od dionica. Ukoliko je koeficijent korelacije jednak -1, to znači da su dionice savršeno negativno korelirane, koeficijent 0 znači da dionice nisu korelirane, a gornja granica 1 predstavlja savršenu pozitivnu korelaciju između dionica.

$$r_{ij} = \frac{\sigma_{ij}}{\sigma_i \sigma_j}, -1 \leq r_{ij} \leq 1 \quad (7)$$

r_{ij} = koeficijent korelacije između i-te i j-te dionice

σ_{ij} = kovarijanca između i-te i j-te dionice

σ_i = standardna devijacija i-te dionice

σ_j = standardna devijacija j-te dionice

Koristeći izraz (6) može se izračunati kovarijančna matrica (drugi naziv je matrica varijanci i kovarijanci) koja je označena slovom S (izraz 8). Na glavnoj dijagonali kovarijančne matrice ($i=j$) nalaze se procjene varijanci za određenu dionicu, dok se izvan glavne dijagonale nalaze elementi koji predstavljaju kovarijance između dionica, s tim da vrijedi jednakost $\sigma_{ij} = \sigma_{ji}$, zbog čega se kod izračuna parametara mogu izostaviti vrijednosti iznad glavne dijagonale. Oznaka $\sigma_{ij}, i \in \{1, \dots, N\}, j \in \{1, \dots, M\}$ označava kovarijancu između i-te i j-te dionice. Vrijedi jednakost $N=M$, jer se radi o kvadratnoj matrici.

$$S = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1j} & \dots & \sigma_{1M} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2j} & \dots & \sigma_{2M} \\ \vdots & \vdots & & \vdots & & \vdots \\ \sigma_{i1} & \sigma_{i2} & \dots & \sigma_{ij} & \dots & \sigma_{iM} \\ \vdots & \vdots & & \vdots & & \vdots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{Nj} & \dots & \sigma_{NM} \end{bmatrix} \quad (8)$$

Koristeći se izrazom (7) može se izračunati korelacijska matrica (izraz 9), u kojoj r_{ij} označava korelaciju između i-te i j-te dionice. Na glavnoj dijagonali matrice nalaze se jedinice iz razloga jer vrijedi $r_{ii}=1$, tj. prinos bilo koje dionice u korelaciji sa samim sobom je uvijek jednak vrijednosti jedan. Također, vrijedi i jednakost $r_{ij} = r_{ji}$ što znači da se kod izračuna parametara mogu izostaviti vrijednosti iznad glavne dijagonale, kao što je slučaj i s kovarijančnom matricom.

$$R = \begin{bmatrix} 1 & r_{12} & \dots & r_{1j} & \dots & r_{1M} \\ r_{21} & 1 & \dots & r_{2j} & \dots & r_{2M} \\ \vdots & \vdots & & \vdots & & \vdots \\ r_{i1} & r_{i2} & \dots & 1 & \dots & r_{iM} \\ \vdots & \vdots & & \vdots & & \vdots \\ r_{N1} & r_{N2} & \dots & r_{Nj} & \dots & 1 \end{bmatrix} \quad (9)$$

4. IZRAČUN PARAMETARA ANALIZE

4.1. Izračun očekivanih prinosa i rizika po sektorima

Usporedba prinosa i standardnih devijacija sektorskih indeksa, prije početka i nakon početka krize, prikazana je u tablici 2. Svi mjesečni podaci nakon listopada 2008. godine predstavljaju krizno razdoblje, a podaci od siječnja 2005. do rujna 2008. godine pretkrizno razdoblje. Iz ovih podataka može se iščitati na koji je sektor kriza najviše utjecala, a na koji najmanje te rizičnost pojedinih sektora. Dionice iz promatranih sektora uvrštene su u skupove optimalnih portfelja za zadane rizike, a zanimljivo je vidjeti dionice kojeg sektora imaju najveće udjele za određenu zahtijevanu razinu prinosa.

Tablica 2.

Prosječan prinos i standardna devijacija sektorskih indeksa prije i nakon početka krize

	\bar{R}_i	σ_i
CROBEXturist	0,34%	8,72%
-prije krize	1,21%	6,30%
-kriza	-0,41%	8,58%
CROBEXtransport	-0,71%	12,40%
-prije krize	1,40%	11,02%
-kriza	-2,53%	13,21%
CROBEXnutris	0,25%	7,38%
-prije krize	1,64%	7,42%
-kriza	-0,95%	7,22%
CROBEXkonstrukt	-0,58%	12,19%
-prije krize	2,74%	10,40%
-kriza	-3,45%	13,12%
CROBEXindustrija	0,85%	6,42%
-prije krize	1,70%	5,67%
-kriza	0,11%	6,98%

Izvor: izračun autora na temelju podataka sa Zagrebačke burze. [online] Dostupno na <http://zse.hr>

Iz podataka se vidi da su najveći ukupni prosječni prinos ostvarile dionice u industrijskoj proizvodnji, tj. dionice koje se uvrštene u indeks CROBEXindustrija – 0,85% mjesečno. To je jedini sektor koji je ostvario pozitivan prosječni mjesečni prinos nakon početka krize. Najmanji prinos u prosjeku su ostvarile dionice iz transportne industrije, tj. dionice uvrštene u indeks CROBEXtransport – prosječni mjesečni pad od 0,71%.

CROBEXturist ostvario je prinos od 0,34% kroz čitavo razdoblje - pretkrizni prinos je bio pozitivan (1,21%), dok je prosječni prinos nakon početka krize bio negativan (-0,41%). Također, kao i kod ostalih indeksa (osim CROBEXnutris), standardna devijacija je bila manja prije krize (6,30%) u odnosu prema standardnoj devijaciji u kriznom razdoblju (8,58%). Najrizičniji sektor bio je CROBEXtransport pošto je njegova standardna devijacija iznosila 12,40%. Ukoliko se gleda pretkrizna rizičnost i rizičnost nakon početka krize, može se iščitati da je ovaj sektor bio najrizičniji od promatranih sektora u oba razdoblja. Specifičnost sektora prehrambene industrije jest ta da je veća volatilnost zabilježena prije krize. CROBEXkonstrukt je ostvario najveći prosječni prinos u pretkriznom razdoblju – čak 2,74% mjesečno, ali i najveći pad u kriznom razdoblju (3,45% mjesečno), što znači da je kriza imala najveći utjecaj upravo na ovu industriju. Standardna devijacija prije krize iznosila je 10,40%, a nakon krize 13,12% što ukazuje da se volatilnost prinosa povećala nakon početka krize. CROBEXindustrija je indeks koji je imao najveći prinos kroz promatrano razdoblje, a osim toga to je bio i najmanje rizičan indeks, jer su standardne devijacije najmanje u usporedbi s ostalim sektorima promatranim u oba razdoblja.

4.2. Izračun očekivanih prinosa i rizika po dionicama

U tablici 3. su prikazani prosječni mjesečni prinosi i standardne devijacije svih dionica, na temelju čega će biti kreirani skupovi optimalnih portfelja, ovisno o rizičnosti i očekivanom prinosu portfelja.

Tablica 3.

Prosječan prinosi i standardna devijacija za odabrane dionice

Indeks	Dionica	prije početka krize		nakon početka krize	
		\bar{R}_i	σ_i	\bar{R}_i	σ_i
CROBEX turist	ACI-R-A	3,35	11,36	-2,04	12,08
	ARNT-R-A	-0,43	18,39	0,68	19,45
	HUPZ-R-A	3,27	11,90	-1,22	8,19
	KORF-R-A	-1,19	10,65	1,17	16,49
	RIVP-R-A	1,03	10,38	-0,62	13,79
CROBEX transport	ATPL-R-A	2,91	15,17	-3,90	15,12
	JDPL-R-A	-0,10	11,28	-3,14	16,18
	JNAF-R-A	1,18	14,24	-0,04	13,43
	LKRI-R-A	3,04	18,38	-1,77	16,66
	ULPL-R-A	0,02	16,11	-3,81	14,23
CROBEX nutris	BD62-R-A	1,33	13,64	-3,13	17,06
	KRAS-R-A	0,40	8,28	-0,27	9,04
	LEDO-R-A	3,99	19,81	0,04	13,90
	PODR-R-A	0,83	7,98	-0,46	9,92
CROBEX konstrukt	DLKV-R-A	2,19	13,20	-4,56	15,09
	IGH-R-A	3,46	14,81	-5,08	18,38
	THNK-R-A	1,88	13,66	-2,56	17,21
	VDKT-R-A	3,43	18,46	-1,61	22,35
CROBEX industrija	ARNT-R-A	0,38	10,32	-0,42	10,94
	KOEI-R-A	2,51	12,73	0,54	12,94
	PTKM-R-A	2,20	10,03	0,22	16,34

Izvor: izračun autora na temelju podataka sa Zagrebačke burze. [online] Dostupno na <http://zse.hr>

Pojedinačno gledano, od svih dionica, LEDO-R-A ostvarila je najveći prosječni prinosi (3,99% mjesečno) u razdoblju prije krize, ali uz najveću standardnu devijaciju (19,81%), tj. uz najveću rizičnost, dok je dionica KORF-R-A ostvarila najmanji prinosi prije krize, tj. pad od 2,05% mjesečno. Dionica s najmanjom standardnom devijacijom je PODR-R-A sa standardnom devijacijom od 7,98%. Nakon početka krize najveći prinosi zabilježila je dionica ARNT-R-A (0,68%), a najmanji prinosi je iznosio -5,08%, a ostvarila ga je dionica IGH-R-A. Osim što je ostvarila najveći prihodi, dionica ARNT-R-A je i najrizičnija dionica u kriznom razdoblju uz standardnu devijaciju od 19,45%. Najmanje rizična dionica nakon početka krize je HUPZ-R-A uz standardnu devijaciju od 8,19%.

Iz korelacijske matrice prinosa za razdoblje prije krize (dodatak 1.) vidi se da u većini slučajeva postoji slaba ili umjerena pozitivna korelacija, a najveća korelacija (0,89) postignuta je između dionica KOEI-R-A i KORF-R-A, što je kontraintuitivno jer se radi o dionicama iz različitih sektora. S druge strane, u korelacijskoj matrici nakon početka krize (dodatak 2.) najveći intenzitet (0,89) je postignut između dionica JDPL-R-A i ULPL-R-A, što je i logično jer se radi o dionicama iz istog sektora (CROBEXtransport). Jak intenzitet korelacije znači da investitor može u slučaju ekspanzije gospodarstva očekivati prinose sličnog intenziteta, a u vrijeme recesije može očekivati gubitke sličnog intenziteta između dionica. S gledišta investitora, najpoželjnija situacija je kada dionice (ili indeksi u ovom slučaju) imaju nisku ili po mogućnosti negativnu korelaciju, što znači da u slučaju kada jedna dionica (indeks) ostvaruje gubitak, druga dionica (indeks) ostvaruje prinos što rezultira redukcijom rizika. Primjer toga je negativna korelacija (-0,21) između dionica PODR-R-A i HUPZ-R-A u portfelju pretkriznog razdoblja ili npr. negativna korelacija (-0,25) između dionica KRAS-R-A i ACI-R-A u portfelju kriznog razdoblja.

4.3. Udio dionica u portfelju

Ukupan zbroj svih dionica u konačnom portfelju iznos 1, s tim da svaka dionica ima udio ovisno o zadanom riziku čitavog portfelja te ovisno o zadanim ograničenjima. U izrazu 10 prikazan je uvjet kojeg smo opisali.

$$\sum_{i=1}^{21} w_i = 1 \quad (10)$$

w_i = udjel i-te dionice u portfelju

Udjeli u portfelju moraju biti pozitivne veličine uz dani uvjet da nema posuđivanja dionica (eng. *short-selling*) (Markowitz, 1959.). U ovom radu će se primijeniti taj uvjet zato što na Zagrebačkoj burzi još uvijek ne postoji mogućnost posuđivanja dionica.

$$w_i \geq 0 \quad (11)$$

w_i = udjel i-te dionice u portfelju

Kada bi svaka dionica imala jednak ponder u portfelju, on bi iznosio 0,047619 pošto je u portfelju 21 dionica. Kod formiranja portfelja, udjeli dionica u portfelju ograničeni su izrazom:

$$0,02 \leq w_i \leq 0,15 \quad (12)$$

w_i = udjel i-te dionice u portfelju

Sama optimizacija portfelja napravljena je uz pomoć Microsoft Excela, tj. potprograma Solvera koji se može ugraditi u sam program. Solver omogućava vrlo brz i precizan izračun udjela dionica u portfelju uz zadana ograničenja (izrazi 10 i 11), a prema zadanoj razini rizika. Standardne devijacije portfelja koje predstavljaju rizičnost mogu se izračunati ako je poznata kovarijančna matrica te ukoliko su poznati udjeli dionica u portfelju. Kako je kovarijančna matrica nepromjenjiva, mijenjajući stupnjeve rizičnosti, mijenjaju se i udjeli dionica unutar portfelja. Optimizacija je napravljena tako što se maksimizirao prinos s obzirom na zadanu razinu rizika (standardne devijacije) portfelja i zadana ograničenja opisana u izrazima 10 i 11.

U tablici 4. prikazano je sedam različitih skupova portfelja ovisnih o riziku i prinosima portfelja za razdoblje prije krize. Vidljivo je kako porastom traženog prinosa raste i rizik mjereno standardnom devijacijom. Uz ograničenja, najveći mogući prinos portfelja iznosi 2,76% mjesečno, a ostvaruje se uz standardnu devijaciju od 9,93% (portfelj 9). U tom portfelju, četiri dionice s najvišim pojedinačnim prinosima imaju i najveće udjele (15%), dionica koja je ostvarivala peti najviši prinos (HUPZ-R-A) ima udio od 8%, dok sve ostale dionice imaju minimalni udio od 2%. Krećući se s lijeva u desno prema manje rizičnim portfeljima raste udio onih dionica koje su imale najmanje standardne devijacije. Krajnje lijevo nalazi se portfelj 1 pri kojem je rizik maksimalno reduciran s obzirom na ograničenja. Maksimalne udjele od 15% imaju dionice PODR-R-A, PTKM-R-A i HUPZ-R-A koje pojedinačno gledano imaju najmanji stupanj rizičnosti (standardne devijacije) u promatranom razdoblju. U portfeljima od 1 do 3 postignuta je redukcija rizika, pošto je rizik portfelja manji od rizika najmanje rizične dionice KRAS-R-A koja ima standardnu devijaciju od 8,28%. Ako se udjeli sektora u portfelju gledaju kao zbroj udjela pripadajućim dionicama, uočavaju se neke pravilnosti. Iz tablice 4. se može iščitati kako udjeli sektora CROBEXtransport, CROBEXindustrija i CROBEXnutris padaju kako se krećemo udesno k rizičnijim portfeljima. CROBEXturist najprije bilježi rast udjela do 36%, a nakon toga se taj udio smanjuje na 29% u portfelju 7. Trend rasta kako se krećemo prema portfeljima s većim zahtijevanim prinosom ima CROBEXkonstrukt, što se može objasniti činjenicom da u se u tom sektoru nalaze dionice koje nose visoki prinos.⁵

⁵ izračun autora

Tablica 4.

Prinosi i standardne devijacije portfelja prije početka krize (izraženo u %)

Portfelj	1	2	3	4	5	6	7
	udjeli dionica u portfelju (w_i)						
ACI-R-A	3,10	15,00	15,00	15,00	15,00	15,00	15,00
ARNT-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ATPL-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
BD62-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
DLV-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ERNT-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
HUPZ-R-A	15,00	15,00	15,00	15,00	15,00	11,41	8,00
IGH-R-A	2,00	2,00	7,48	14,12	15,00	15,00	15,00
JDPL-R-A	5,93	2,00	2,00	2,00	2,00	2,00	2,00
JNAF-R-A	5,72	2,82	2,00	2,00	2,00	2,00	2,00
KOEI-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
KORF-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
KRAS-R-A	12,24	2,00	2,00	2,00	2,00	2,00	2,00
LEDO-R-A	2,00	9,94	13,15	15,00	15,00	15,00	15,00
LKRI-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
PODR-R-A	15,00	12,24	4,37	2,00	2,00	2,00	2,00
PTKM-R-A	15,00	15,00	15,00	8,88	2,78	2,00	2,00
RIVP-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
THNK-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ULPL-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00
VDKT-R-A	2,00	2,00	2,00	2,00	7,22	11,59	15,00
$E(R_P)$	1,65	2,27	2,51	2,66	2,74	2,75	2,76
$\hat{\sigma}_P$	7,11	7,50	8,00	8,50	9,00	9,50	9,93
CROBEX	zbroj udjela dionica u portfelju iz sektorskih indeksa						
turist	24,10	36,00	36,00	36,00	36,00	32,41	29,00
transport	17,66	10,82	10,00	10,00	10,00	10,00	10,00
nutris	31,24	26,18	21,52	21,00	21,00	21,00	21,00
konstrukt	8,00	8,00	13,48	20,12	26,22	30,59	34,00
industrija	19,00	19,00	19,00	12,88	6,78	6,00	6,00

Izvor: izračuna autora na temelju podataka s web stranice Zagrebačke burze [online]. Dostupno na: <http://www.zse.hr>

Tablica 5.

Prinosi i standardne devijacije portfelja nakon početka krize (izraženo u %)

Portfelj	1	2	3	4	5	6	7	8	9
	udjeli dionica u portfelju (w_i)								
ACI-R-A	15,00	7,36	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ARNT-R-A	11,77	15,00	15,00	15,00	15,00	15,00	15,00	15,00	15,00
ATPL-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
BD62-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
DLV-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ERNT-R-A	11,23	7,11	8,92	7,39	5,96	2,00	2,00	2,00	2,00
HUPZ-R-A	15,00	15,00	13,22	9,24	5,57	2,00	2,00	2,00	2,00
IGH-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
JDPL-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
JNAF-R-A	2,00	2,00	2,00	2,00	2,00	4,64	2,00	2,00	2,00
KOEI-R-A	2,00	10,53	15,00	15,00	15,00	15,00	15,00	15,00	15,00
KORF-R-A	2,00	2,00	2,87	8,37	13,47	15,00	15,00	15,00	15,00
KRAS-R-A	15,00	15,00	15,00	15,00	15,00	15,00	10,66	3,84	2,00
LEDO-R-A	2,00	2,00	2,00	2,00	2,00	2,58	2,00	6,16	8,00
LKRI-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
PODR-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
PTKM-R-A	2,00	2,00	2,00	2,00	2,00	4,78	12,34	15,00	15,00
RIVP-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
THNK-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
ULPL-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
VDKT-R-A	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00	2,00
$E(R_P)$	-1,07	-0,83	-0,67	-0,55	-0,44	-0,36	-0,33	-0,30	-0,30
$\hat{\sigma}_P$	6,97	7,50	8,00	8,50	9,00	9,50	10,00	10,50	10,62
CROBEX	zbroj udjela dionica u portfelju iz sektorskih indeksa								
turist	45,77	41,36	35,08	36,61	38,04	36,00	36,00	36,00	36,00
transport	10,00	10,00	10,00	10,00	10,00	12,64	10,00	10,00	10,00
nutris	21,00	21,00	21,00	21,00	21,00	21,58	16,66	14,00	14,00
konstrukt	8,00	8,00	8,00	8,00	8,00	8,00	8,00	8,00	8,00
industrija	15,23	19,64	25,92	24,39	22,96	21,78	29,34	32,00	32,00

Izvor: izračuna autora na temelju podataka s web stranice Zagrebačke burze [online]. Dostupno na: <http://www.zse.hr>

U kriznom portfelju prikazano je sedam različitih portfelja poredanih s lijeva na desno uz rastuću razinu rizičnosti, tj. uz rastuću standardnu devijaciju portfelja. Uz zadana ograničenja u izrazima 10., 11. i 12. maksimalan očekivani prinos portfelja iznosi -0,30%, što znači da nijedna kombinacija dionica ne daje profitabilan portfelj. Taj prinos je ostvaren uz standardnu devijaciju od 10.62%, što je za 0,69 postotnih poena više od standardne devijacije kombinacije dionice koja daje najviši prinos za razdoblje prije početka krize. Iako se u usporedbi s pretkriznim portfeljem može postići niži rizik, tj. niža standardna devijacija za 0,14 postotnih poena, očekivani prinos za tu razinu rizika iznosi -1,07%, dok za razdoblje prije krize prinos uz najnižu razinu rizika iznosi 1,65%. U svim portfeljima, izuzev portfelja 6, sve dionice iz sektora CROBEXkonstrukt i CROBEXtransport imaju minimalan udio, što je pokazatelj kako je kriza imala velik utjecaj na prinose i rizik dionica u tim sektorima. Udio CROBEXkonstrukta iznosi 8% za sve portfelje u tablici 5., dok udio CROBEXtransporta, uz izuzetak portfelja 6, iznosi 12% za sve portfelje. Iako nema pravilnosti kretanja udjela sektorskih indeksa CROBEXindustrija, CROBEXnutris i CROBEXindustrija, vide se razlike između udjela za niže i više razine očekivanog prinosa. Tako pada udio CROBEXturista s 45,77% (portfelj 1) na 36% (portfelj 9), dok udio CROBEXnutrisa pada s 21% na 14%, kako se povećava očekivani prinos. Udio sektora CROBEXindustrije je porastao kada uspoređujemo portfelje 1 i 9.

5. ZAKLJUČAK

Uvidom u podatke Zagrebačke burze jasno se može iščitati da je svjetska financijska kriza uzrokovala pad prinosa svih indeksa i većine dionica, no nameće se pitanje koji sektor je bio pogođeniji svjetskom financijskom krizom. Analizom smo došli do zaključka da su građevinski sektor (CROBEXkonstrukt) i sektor transporta (CROBEXtransport) doživjeli najveći pad prosječnih prinosa nakon početka krize. Uz prosječni rast od 2,74% mjesečno prije početka krize CROBEXkonstrukt je imao najveće prinose, dok je nakon početka krize uz pad od 3,45% mjesečno ostvarivao najveće gubitke, što znači da je kriza uzrokovala smanjenje prosječnih prinosa od čak 6,19 postotnih poena, a za CROBEXtransport taj pad iznosi 3,93 postotna poena. Sektor industrijske proizvodnje jedini je sektor koji je ostvario pozitivan prosječni mjesečni prinos u oba promatrana razdoblja, a upravo je na taj sektor kriza imala najmanji utjecaj uz smanjenje prosječnih mjesečnih prinosa od 1,59 postotnih poena.

Također, rezultati analize ukazuju na razlike u portfeljima prije i nakon početka svjetske financijske krize koja je znatno utjecala na prinose i rizičnost dionica, a samim time i na rizičnost određenih sektora. Tako se prije početka krize udio dionica iz sektorskog indeksa CROBEXturist povećava kako raste zahtijevani prinos, a nakon početka krize taj udio u prosjeku pada, dok za

CROBEXindustriju vrijedi obratna situacija, jer prije početka krize udio pada s porastom zahtijevanog prinosa, a nakon početka krize udio raste s porastom zahtijevanog prinosa. Isti smjer kretanja udjela, tj. pad udjela s porastom zahtijevanog prinosa, neovisno o razdoblju, nalazimo kod sektora proizvodnje i prerade hrane (CROBEXnutris), dok građevinski sektor i sektor transporta imaju konstantan udio nakon početka krize bez obzira na razinu zahtijevanog prinosa te zato analiza kretanja njihovih udjela s obzirom na razdoblje nije prikladna.

No treba biti svjestan da je Markowitz svoju teoriju razvio na temelju visoko likvidnog američkog tržišta dionica, što nije slučaj s hrvatskim tržištem dionica gdje je prosječni dnevni promet dionica u sastavu referentnog indeksa CROBEX na Zagrebačkoj burzi pao za 83,27% od 2008. do 2012. godine. To ukazuje na znatan pad likvidnosti trgovanja. Također pad realnih dohodaka i rast nezaposlenosti izazvao je smanjenje zainteresiranosti domaćih ulagača, tako da se daljnji rast prometa na Zagrebačkoj burzi može očekivati kada se hrvatsko gospodarstvo nađe na uzlaznoj putanji rasta. Tada bi na popularnosti trebali dobiti i sektorski indeksi, koji su uobičajena pojava na velikim svjetskim burzama te je zato uvođenje istih na Zagrebačku burzu logičan nastavak praćenja svjetskih trendova na tržištima kapitala. No ulazak u EU bi trebao izazvati veću zainteresiranost stranih ulagača u hrvatsko tržište kapitala, što bi moglo rezultirati rastom obujma trgovanja dionica na Zagrebačkoj burzi i rastom popularnosti analize dioničkog tržišta uz pomoć raznih alata, a među kojima je i Markowitzeva teorija koja je često korištena na razvijenim tržištima kapitala.

Zaključno, izračunom standardnih devijacija, kao mjere rizičnosti i prinosa i mjere profitabilnosti, utvrđeno je da je kriza imala znatan utjecaj na poslovne rezultate promatranih sektora što se reflektiralo kroz pad cijene dionica u razdoblju nakon početka krize i kroz činjenicu da u kriznom razdoblju nijedna kombinacija dionica nije dala portfelj s pozitivnim prinosom. Sam utjecaj krize na poslovne rezultate izazvao je i promjene u rizičnosti i profitabilnosti sektora te u skladu s time i na njihove udjele u portfeljima prije i nakon početka krize. Analizom je utvrđeno da nakon krize nije bilo moguće formirati optimalni portfelj koji bi ostvarivao pozitivan prinos, s obzirom na dana ograničenja.

DODATCI

Dodatak 1. Korelacijska matrica za razdoblje prije početka krize

	ACI	ARNT	ATPL	BD62	DLKV	ERNT	HUPZ	IGH	JDPL	JNAF	KOEI	KORF	KRAS	LEDO	LKRI	PODR	PTKM	RVP	THNK	UPL	VDKT			
ACI	1																							
ARNT	0,46	1																						
ATPL	0,61	0,53	1																					
BD62	0,55	0,58	0,64	1																				
DLKV	0,55	0,52	0,76	0,67	1																			
ERNT	0,54	0,64	0,65	0,65	0,65	1																		
HUPZ	0,15	0,12	0,17	0,25	0,03	-0,10	1																	
IGH	0,35	0,39	0,62	0,51	0,79	0,52	-0,04	1																
JDPL	0,29	0,27	0,64	0,39	0,52	0,53	0,04	0,49	1															
JNAF	0,05	0,26	0,12	0,39	0,36	0,34	0,04	0,53	0,09	1														
KOEI	0,57	0,59	0,71	0,71	0,83	0,82	0,10	0,69	0,53	0,55	1													
KORF	0,54	0,61	0,67	0,62	0,73	0,82	0,04	0,56	0,47	0,43	0,89	1												
KRAS	0,51	0,58	0,69	0,64	0,69	0,66	0,15	0,63	0,48	0,28	0,71	0,65	1											
LEDO	0,18	0,23	0,32	0,20	0,40	0,27	-0,12	0,42	0,27	0,29	0,44	0,29	0,28	1										
LKRI	0,52	0,47	0,68	0,58	0,67	0,59	-0,01	0,61	0,52	0,19	0,62	0,50	0,54	0,31	1									
PODR	0,62	0,54	0,51	0,54	0,61	0,80	-0,21	0,53	0,33	0,33	0,74	0,74	0,69	0,35	0,41	1								
PTKM	0,24	0,30	0,29	0,39	0,41	0,42	0,08	0,46	0,42	0,27	0,52	0,39	0,39	0,26	0,42	0,28	1							
RVP	0,51	0,51	0,62	0,64	0,56	0,65	0,02	0,51	0,37	0,21	0,62	0,60	0,64	0,25	0,52	0,57	0,45	1						
THNK	0,34	0,45	0,58	0,68	0,67	0,54	0,26	0,66	0,58	0,49	0,73	0,62	0,62	0,40	0,53	0,48	0,57	0,63	1					
UPL	0,39	0,44	0,69	0,60	0,65	0,45	0,18	0,55	0,35	0,20	0,56	0,49	0,54	0,18	0,55	0,32	0,26	0,63	0,47	1				
VDKT	0,23	0,52	0,60	0,58	0,68	0,53	0,27	0,60	0,55	0,34	0,66	0,55	0,63	0,43	0,54	0,41	0,49	0,34	0,61	0,48	1			

Izvor: izračuna autora na temelju podataka s web stranice Zagrebačke burze [online]. Dostupno na: <http://www.zse.hr>

Dodatak 2. Korelacijska matrica za razdoblje poslije početka krize

	ACI	ARNT	ATPL	BD62	DLKV	ERNT	HUPZ	IGH	JDPL	JNAF	KOEI	KORF	KRAS	LEDO	LKRI	PODR	PTKM	RIVP	THNK	ULPL	VDKT	
ACI	1																					
ARNT	-0,05	1																				
ATPL	0,03	0,08	1																			
BD62	0,12	0,03	0,41	1																		
DLKV	-0,08	0,14	0,61	0,40	1																	
ERNT	0,10	-0,08	0,58	0,49	0,53	1																
HUPZ	0,06	0,17	0,36	0,11	0,32	0,13	1															
IGH	0,09	-0,01	0,44	0,32	0,73	0,61	0,13	1														
JDPL	0,16	0,01	0,84	0,38	0,70	0,51	0,23	0,59	1													
JNAF	0,15	0,15	0,55	0,35	0,58	0,50	0,43	0,48	0,57	1												
KOEI	0,25	-0,21	0,59	0,36	0,72	0,64	0,24	0,68	0,68	0,55	1											
KORF	0,22	0,12	0,70	0,41	0,64	0,59	0,30	0,63	0,77	0,60	0,75	1										
KRAS	-0,25	-0,09	0,34	0,09	0,63	0,27	0,21	0,48	0,38	0,20	0,44	0,33	1									
LEDO	0,11	-0,07	0,60	0,27	0,65	0,68	0,31	0,65	0,61	0,72	0,79	0,66	0,48	1								
LKRI	0,14	0,02	0,58	0,36	0,72	0,51	0,25	0,67	0,78	0,60	0,74	0,73	0,48	0,65	1							
PODR	0,30	-0,04	0,61	0,36	0,59	0,54	0,31	0,57	0,74	0,51	0,75	0,73	0,36	0,63	0,69	1						
PTKM	0,00	0,03	0,54	0,43	0,70	0,50	0,24	0,58	0,66	0,59	0,72	0,64	0,60	0,71	0,77	0,61	1					
RIVP	0,30	0,20	0,41	0,22	0,24	0,36	0,26	0,26	0,32	0,60	0,30	0,48	0,03	0,36	0,35	0,21	0,26	1				
THNK	0,01	0,18	0,63	0,46	0,80	0,58	0,25	0,70	0,74	0,57	0,76	0,76	0,52	0,69	0,79	0,66	0,83	0,28	1			
ULPL	0,11	0,00	0,87	0,38	0,58	0,56	0,25	0,51	0,89	0,55	0,61	0,69	0,35	0,62	0,73	0,65	0,61	0,34	0,62	1		
VDKT	0,03	0,27	0,71	0,52	0,79	0,59	0,31	0,65	0,76	0,51	0,65	0,66	0,45	0,62	0,74	0,62	0,70	0,26	0,80	0,70	1	

Izvor: izračun autora na temelju podataka s web stranice Zagrebačke burze [online]. Dostupno na: <http://www.zse.hr>

LITERATURA

- Aljinović, Z., Marasović, B., Šego, B., 2011. Financijsko modeliranje, 2. izmijenjeno i dopunjeno izdanje. Split: Ekonomski fakultet u Splitu
- Andrijašević, S., Petranović, V., 1999. Ekonomika osiguranja, Alfa, Zagreb
- Bendeković, D., 2000. Pristup procjeni rizika i povrata kod ulaganja u obične dionice, Ekonomski pregled, 51 (11-12) 1282-1312
- Black F. i Litterman R. (1992), Global Portfolio Optimization, Financial Analysts Journal, Vol. 48 No. 5, str. 28-43
- Bodie Z. & Kane A. & Marcus A. J., 2006. Počela ulaganja. Mate, Zagreb
- Brealey, R. A., Myers, S. C., 1991. Principles of Corporate Finance, McGraw-Hill, Sixth Edition, New York, str. 160-168.
- Chopra, N., Lakonishok, J., Ritter, J. (1992). Measuring Abnormal Performance: Do Stocks Overreact, Journal of Financial Economics, Vol. 31, Issue 2, str. 235-268
- Jakšić, S., 2007. Primjena Markowitzove teorije na tržište dionica Zagrebačke burze, Zbornik ekonomskog fakulteta, Vol. 5 No. 1, Zagreb
- Jerončić, M. i Aljinović, Z., 2011. Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu, Ekonomski pregled, 62 (9-10), str. 583-606
- Markowitz, H. M., 1952. Portfolio Selection, The Journal of Finance, Vol. 7, Issue 1
- Markowitz, H. M., 1959. Portfolio Selection (Efficient Diversification of Investment), John Wiley & Sons, New York
- Orsag, S., 2011. Vrijednosni papiri, Revicon, Sarajevo
- Rodgers, J.L., Nicewander W. A., 1988. Thirteen ways to look at the correlation coefficient. The American Statistician, Vol. 42, No. 1
- Rom B., Ferguson K. (1993), Post-Modern Portfolio Theory Comes of Age, Journal of Investing, Winter 1993 Issue, str. 27-33
- Rubinstein, M., 2002. Markowitz's "Portfolio Selection": A Fifty-Year Retrospective, The Journal of Finance, Vol. 57, No. 3, str. 2.
- Statman, M., 1987. How Many Stocks Make a Diversified Portfolio?, The Journal of Financial and Quantitative Analysis, Vol. 22, No. 3
- Van Home, J. C., 1997. Financijsko upravljanje i politika (Financijski menadžment), deveto izdanje, MATE, Zagreb

Bojan Morić Milovanović, Ph. D.

Senior Assistant
Department for Managerial Economics
Faculty of Economics and Business, University of Zagreb
E-mail: bmoric@efzg.hr

Marko Čurković

Undergraduate student
Faculty of Economics and Business, University of Zagreb
E-mail: marko.curkovic@finance.hr

**THE IMPACT OF GLOBAL FINANCIAL CRISIS ON
CREATION OF MULTISECTORAL DIVERSIFICATED
OPTIMAL PORTFOLIOS BY USING MARKOWITZ
THEORY ON THE ZAGREB STOCK EXCHANGE*****Abstract***

On the 22nd of February 2013, the sectoral indices were introduced on the Zagreb Stock Exchange, so it can be concluded that in the context of the Croatian capital market development, the observation of sectoral yields and risks gained more importance. The purpose of this paper is to present the risk and return statistical analysis results of selected stocks listed in the sectoral indices over a long period of time. In this way, it is possible to obtain performance results of individual sector indices before and after the beginning of the financial crisis. The analysis of relationship between observed stock price changes is conducted by using correlation matrix. Previous researches have primarily focused on creation of an optimal portfolio by using weekly or monthly data without analyzing the impact of financial crisis. Therefore, the contribution of this paper can be seen in analyzing the impact of financial crisis on performance of different sector indices.

Keywords: Markowitz theory, Modern Portfolio Theory, Zagreb Stock Exchange, Sectoral Diversification, Global Financial Crisis

JEL classification: G11

