BROJ 16

Kvartalni bilten I/2012

HANFA
HRVATSKA AGENCIJA ZA NADZOR FINANCIJSKIH USLUGA

1. Tržište kapitala 3
1.1. Kretanje tržišta kapitala 3
1.2. Primjena internih modela za izračun kapitalnih zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik investicijskih društava 19

2. Otvoreni investicijski fondovi 36
2.1. Kvartalno kretanje otvorenih investicijskih fondova 36
2.2. Analiza distribucije promjene neto imovine i vrijednosti udjela otvorenih investicijskih fondova 45
2.2.1. Novčani fondovi 45
2.2.2. Obveznički fondovi 46
2.2.3. Mješoviti fondovi 47
2.2.4. Dionički fondovi 48
2.3. Struktura udjelničara otvorenih investicijskih fondova s javnom ponudom 49

3. Mirovinski fondovi 51
3.1. Obvezni mirovinski fondovi (OMF) 51
3.2. Otvoreni dobrovoljni mirovinski fondovi (ODMF) 54
3.3. Zatvoreni dobrovoljni mirovinski fondovi (ZDMF) 57

4. Tržište osiguranja 60
4.1. Zaračunata premija društava za osiguranje i društava za reosiguranje 61
4.2. Struktura izvještaja o financijskom položaju društava za osiguranje i društava za reosiguranje 64

5. Leasing 66
5.1. Imovina, kapital i obveze 67
5.2. Financijski rezultat poslovanja 69
5.3. Struktura portfelja leasing društava 70
5.3.1. Struktura portfelja leasing društava prema objektima leasinga/zajma 72
5.4. Indeksi koncentracije u djelatnosti leasinga u RH 74

Impresum 75

1. Tržište kapitala

1.1. Kretanje tržišta kapitala

U prvom kvartalu 2012. gotovo svi promatrani indeksi zabilježili su porast vrijednosti, dok su pad vrijednosti zabilježila dva indeksa, banjalučki BIRS i sarajevski SASX10 indeks. Od promatranih svjetskih indeksa najveći rast u prvom kvartalu 2012. ostvario je japanski indeks NIKKEI 225 u iznosu od 19,26%, zatim njemački indeks DAX od 17,78%. Od 20 razmatranih indeksa njih 17 je u prvom kvartalu ostvarilo najveći kvartalni prinos unutar razdoblja od godinu dana. Svi svjetski indeksi osim japanskog svoju su minimalnu vrijednost u razmatranom kvartalu dostigli u prvoj polovici siječnja, dok su maksimalnu vrijednost svi indeksi, osim kanadskog i kineskog indeksa, dostigli u drugoj polovini ožujka 2012. godine.

Grafikon 1.1.1. Prikaz kretanja indeksa SAD-a, Kanade, Japana, Australije i Kine

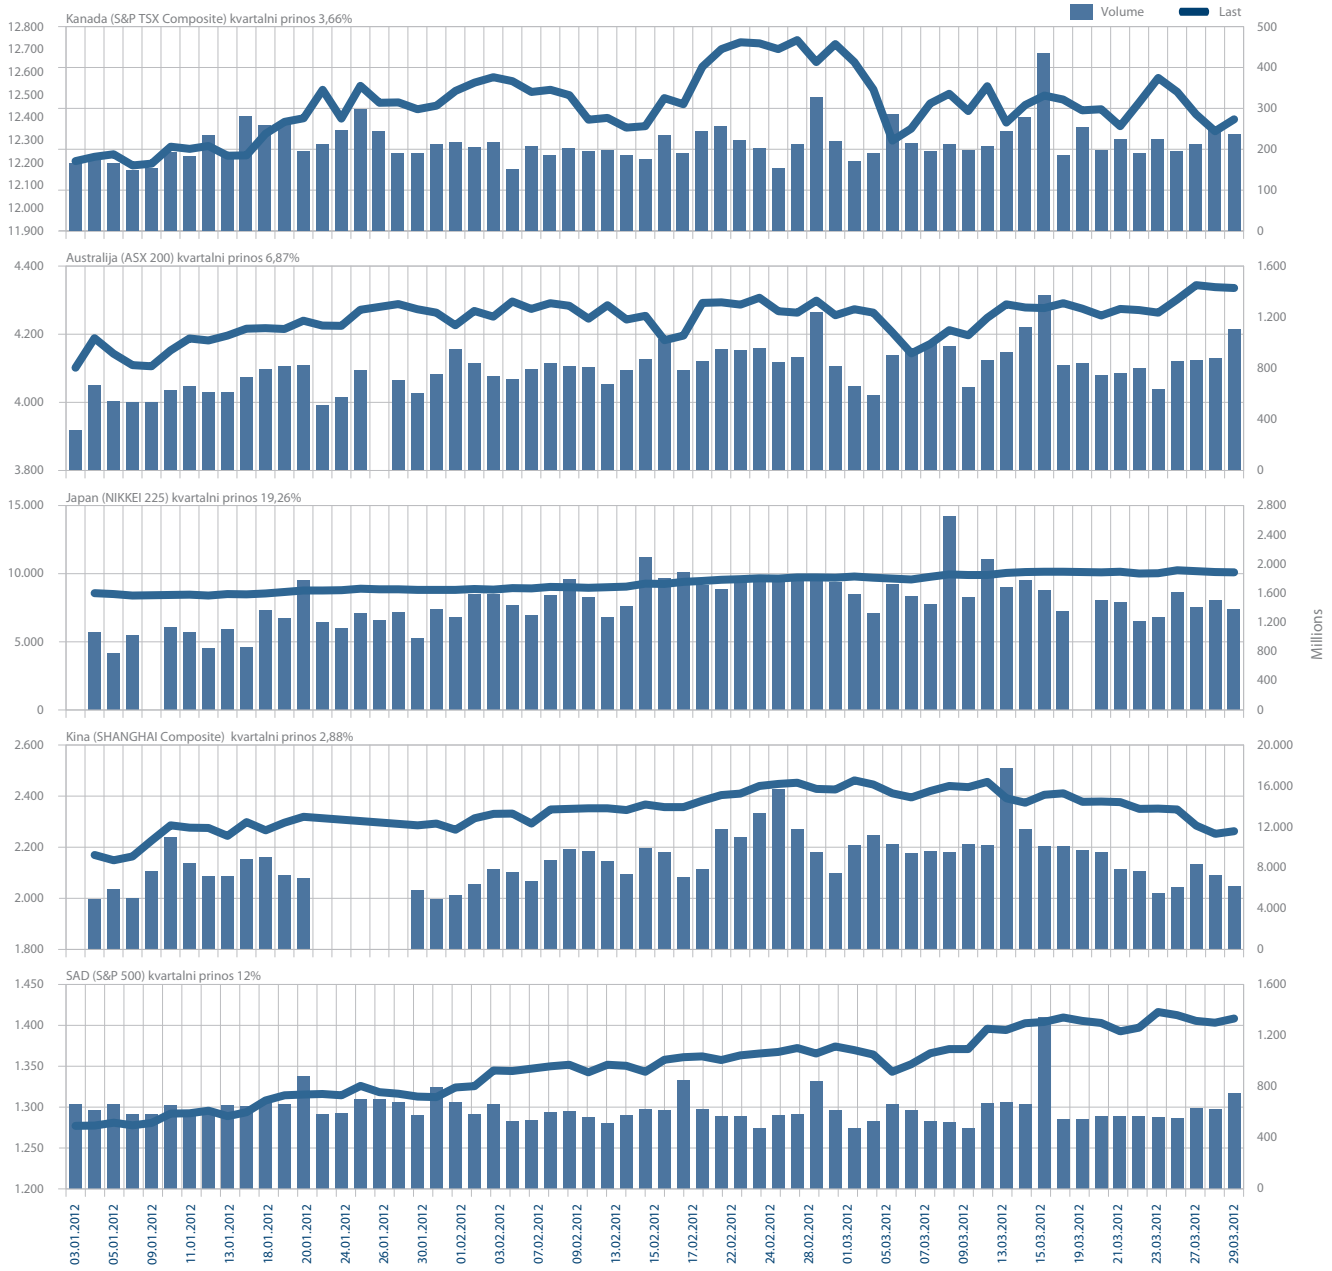

Izvor: Bloomberg

Na području Eurozone svi su indeksi zabilježili rast u prvom kvartalu 2012. Pet indeksa područja Eurozone najveći kvartalni rast zadnjih godinu dana ostvarili su upravo u prvom kvartalu 2012. Najveći rast ostvario je njemački indeks DAX u iznosu od 17,78%, zatim austrijski indeks ATX od 14,13%, francuski CAC40 od 8,35%, poljski WIG20 od 6,62%, talijanski FTSE MIB od 5,90%, švicarski SMI od 5,04%, nizozemski AEX od 3,53% i britanski FTSE100 od 3,52%. Svi indeksi Eurozone osim švicarskog svoju su minimalnu vrijednost u prvom kvartalu dostigli u prvoj polovici siječnja 2012, dok su najvišu vrijednost svi indeksi osim poljskog indeksa dostigli u drugoj polovini ožujka.

Grafikon 1.1.2. Prikaz kretanja indeksa Eurozone

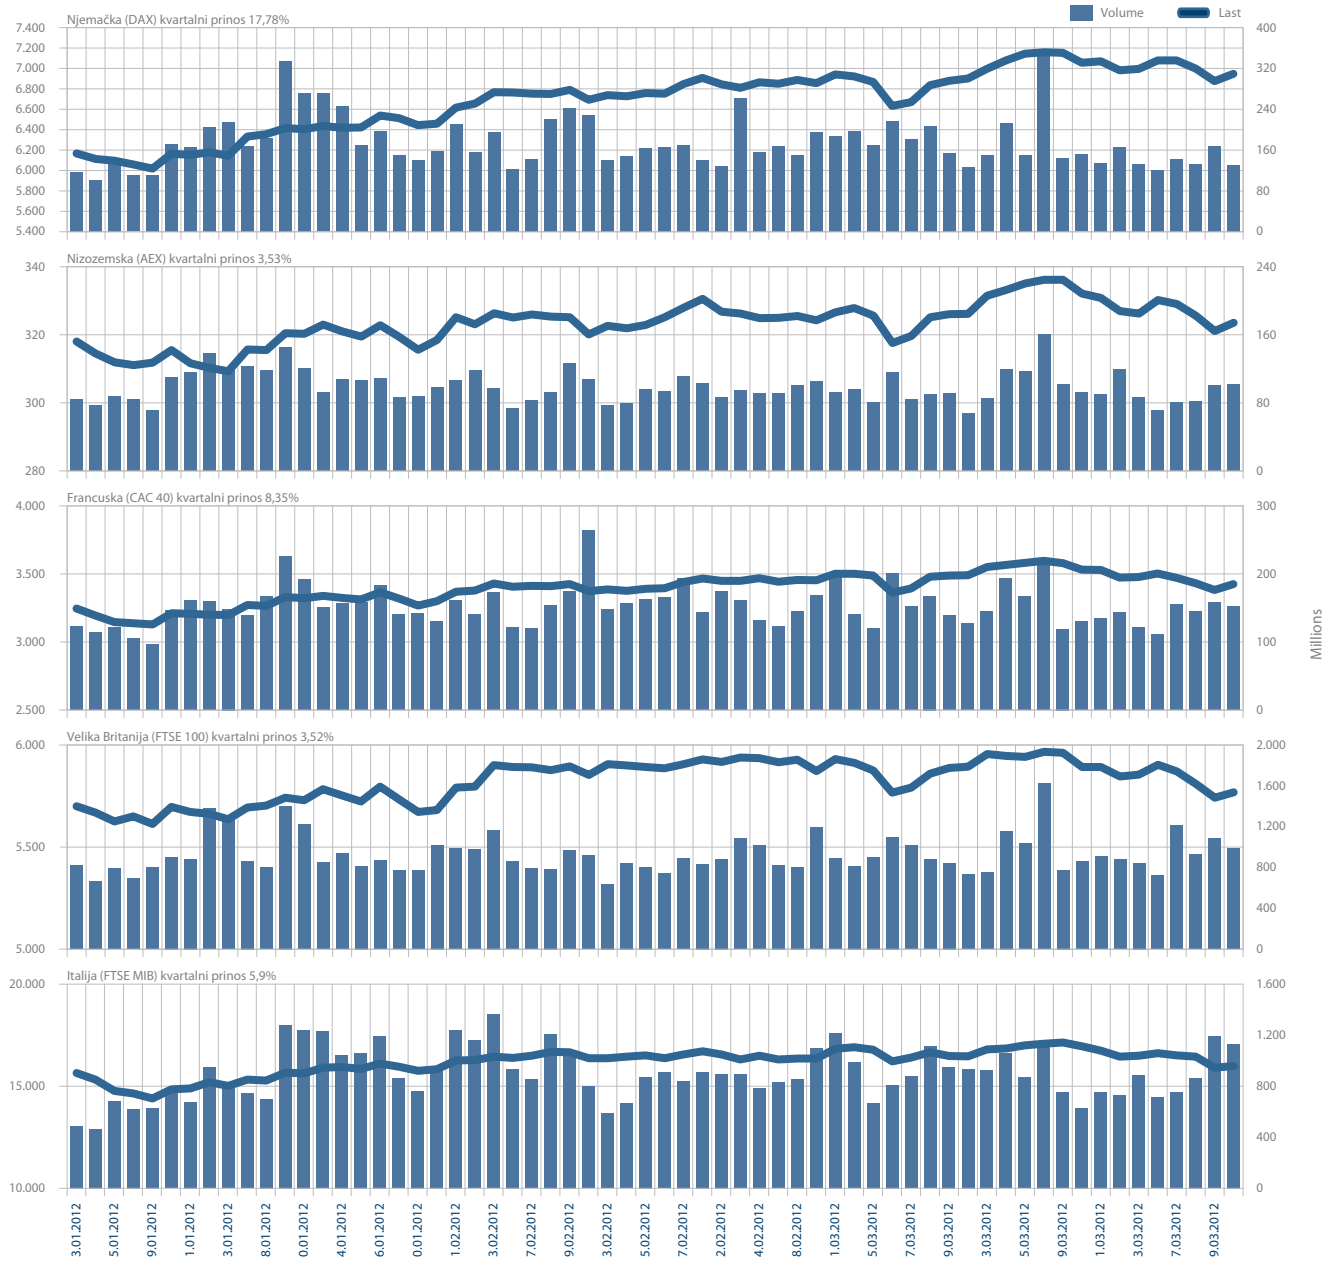

Izvor: Bloomberg

Grafikon 1.1.2. Prikaz kretanja indeksa Eurozone - nastavak

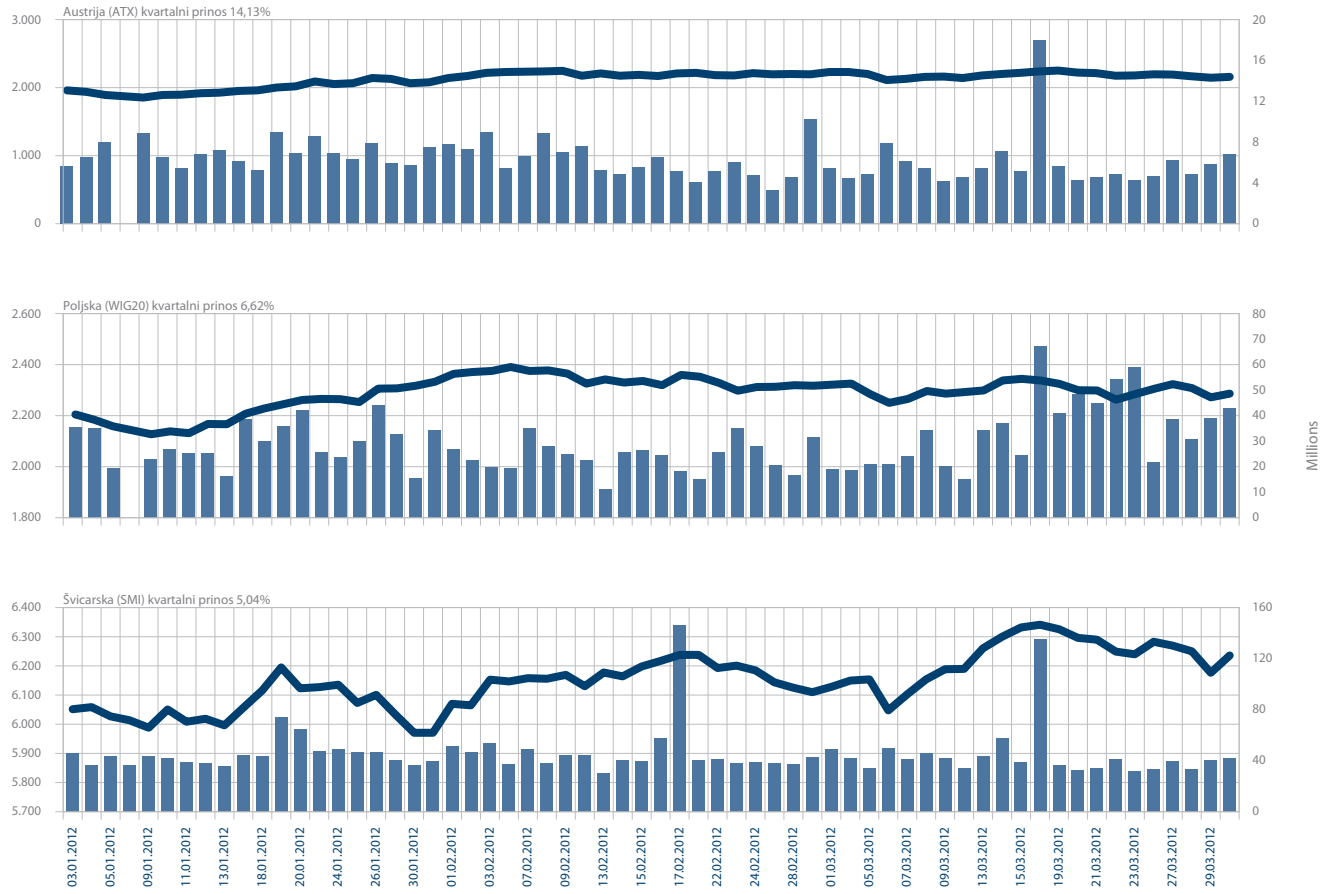

Izvor: Bloomberg

Tržišta regije zabilježila su najveći kvartalni prinos tijekom zadnja četiri kvartala. Najveći rast indeksa ostvario je srpski indeks BELEX15 u iznosu od 6,59%, zatim hrvatski CROBEX od 5,36%, makedonski MBI 10 s rastom od 2,56%, crnogorski MONEX s rastom od 2,17% te slovenski SBI TOP s prinosom od 1,64%. Pad vrijednosti ostvarili su banjalučki indeks BIRS i sarajevski indeks SASX10 u iznosima od 4,69% i 3,57%.

Grafikon 1.1.3. Prikaz kretanja indeksa regije

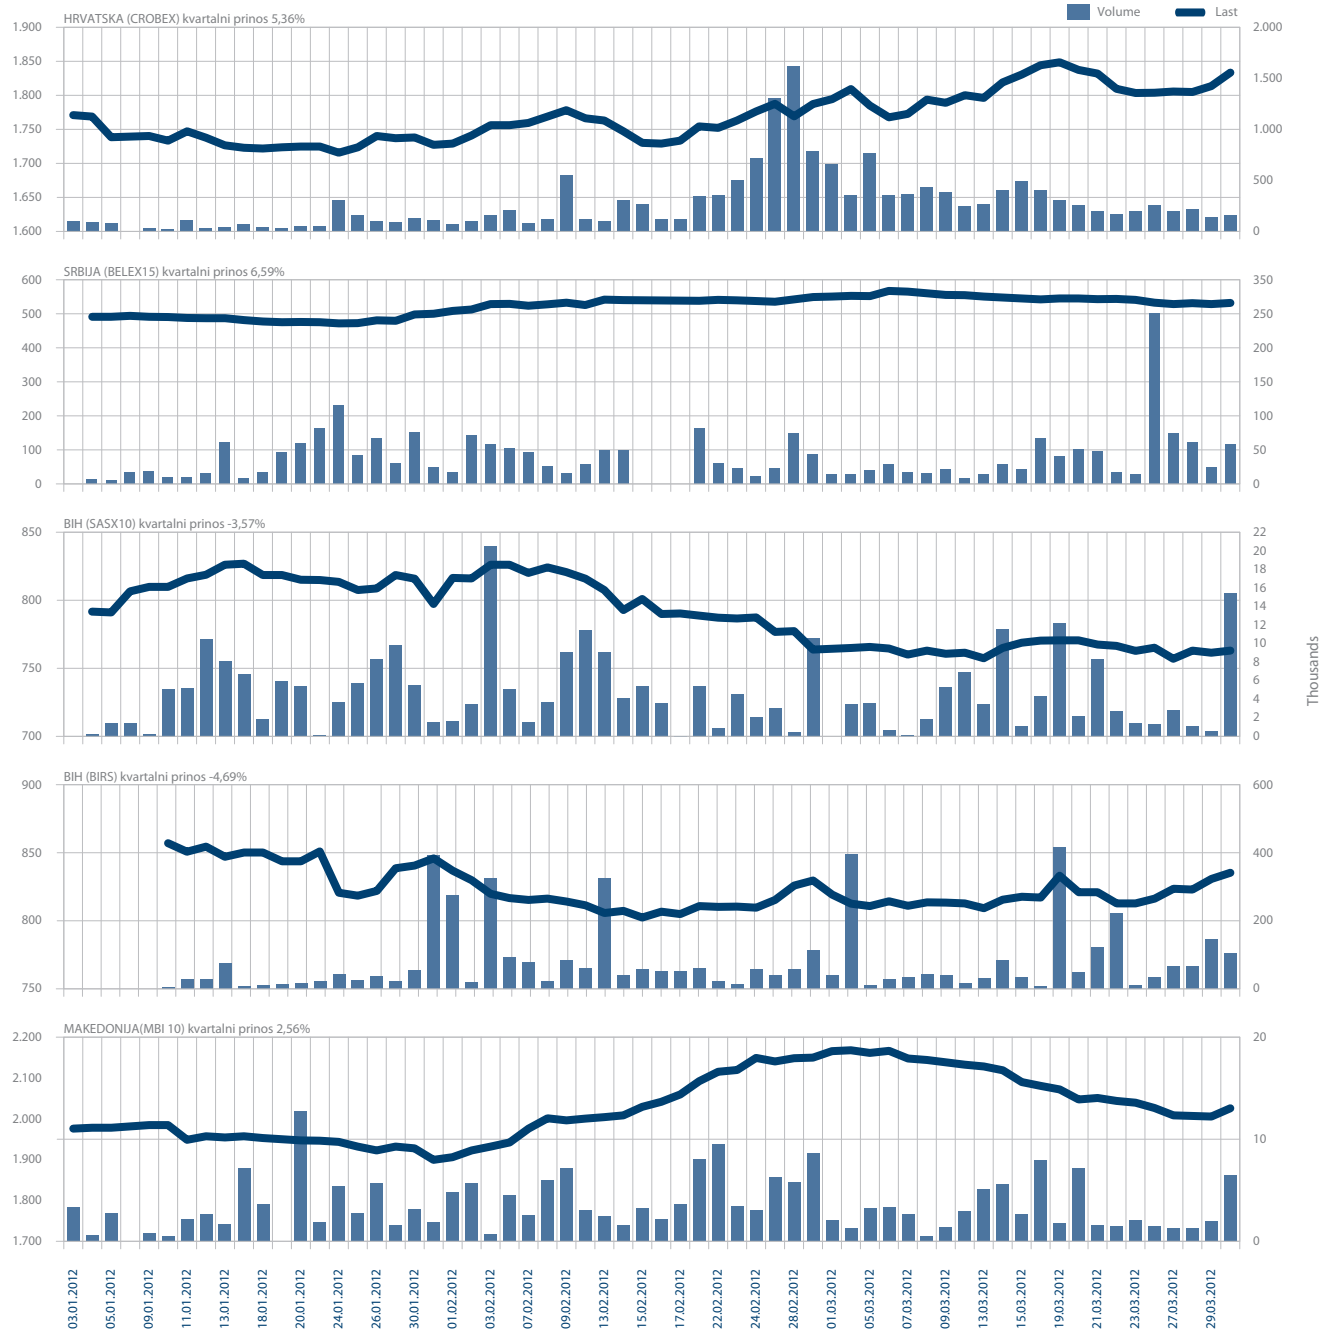

Izvor: Bloomberg

Grafikon 1.1.3. Prikaz kretanja indeksa regije - nastavak

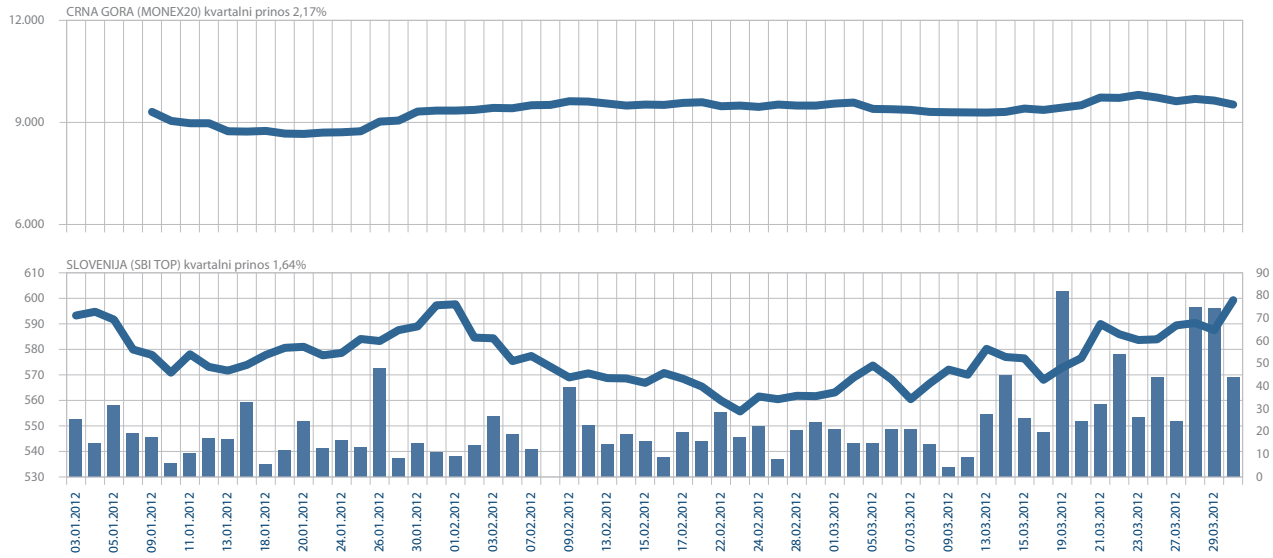

Izvor: Bloomberg

Hrvatski indeks tržišta kapitala CROBEX ostvario je u prvom kvartalu 2012. rast od 5,36% s vrijednosti od 1.740,21 na 1.833,54. Tržišna kapitalizacija vrijednosnih papira se u I. kvartalu 2012. povećala za 1,6% u odnosu na IV. kvartal 2011. i iznosila je 187,7 milijuna kuna. Pritom se tržišna kapitalizacija dionica povećala za 1,2%, a tržišna kapitalizacija obveznica za 2,6% u odnosu na prethodni kvartal. U kvartalu se ukupno trgovalo 64 dana. Sveukupni promet je veći za 68,5% i u I. kvartalu je iznosio 1,29 milijardi kuna. Redovni promet dionicama se povećao za 54,1%, na 1,04 milijardi kuna, a redovni promet obveznicama se povećao za 310,4% i iznosio je 138,7 milijuna kuna, dok se pravima i komercijalnim zapisima u I. kvartalu na redovnom tržištu nije trgovalo.

Grafikon 1.1.4. Kretanje Crobex-a po kvartalima

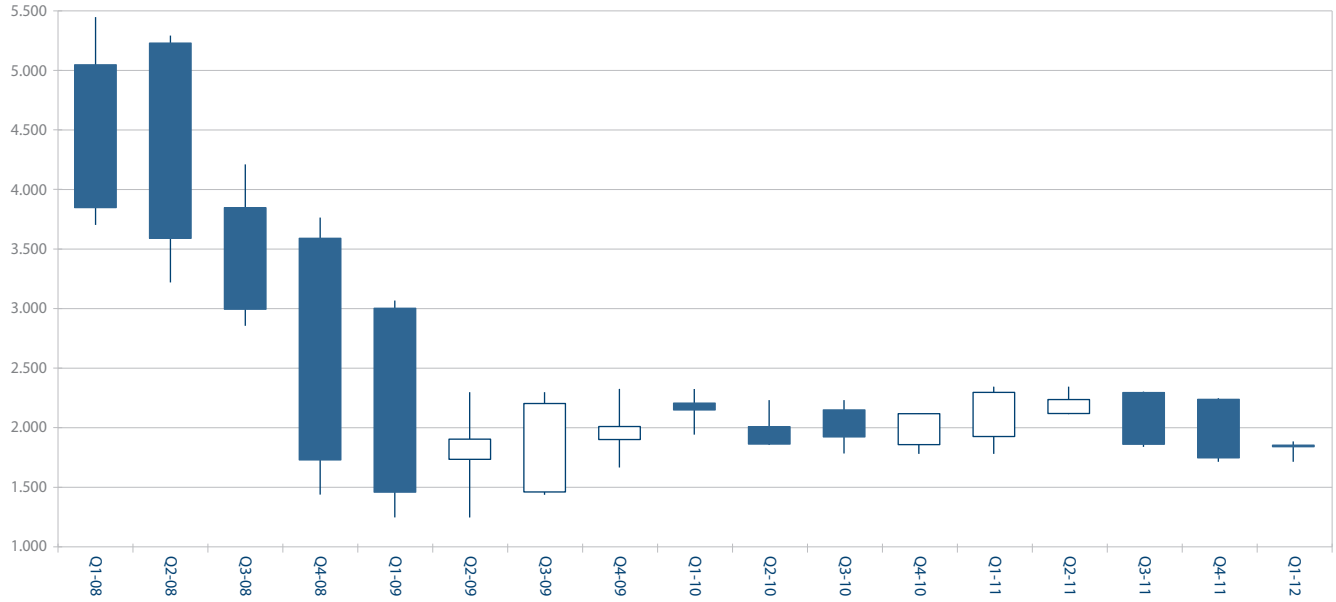

Izvor: HANFA, ZSE

Tablica 1.1.1. Karakteristike Zagrebačke burze

		4. kvartal 2011.	1. kvartal 2012.
TRŽIŠNA KAPITALIZACIJA	• DIONICE	130.630,70	132.224,40
	• OBVEZNICE	54.102,90	55.481,50
PROMET	• REDOVNI PROMET	707.594.630	1.176.976.028
	• BLOK PROMET	9.184.600	2.796.300
	• PRIJAVLJENI PROMET	46.167.813	106.029.803
SVEUKUPNO	• TRŽIŠNA KAPITALIZACIJA	184.734	187.706
	• PROMET	762.947.043	1.285.802.130
	• VOLUMEN	32.309.061	198.823.029
	• BROJ TRANSAKCIJA	65.054	103.232
PROSJEČNI DNEVNI	• PROMET	12.110.271	20.090.658
	• VOLUMEN	512.842	3.106.610
	• BROJ TRANSAKCIJA	1.032	1.613
OTC TRANSAKCIJE	• PROMET	2.016.432.089	3.818.364.358
	• VOLUMEN	964.137.664	1.763.816.862
	• BROJ TRANSAKCIJA	362	526

*tržišna kapitalizacija u milijunima kuna
Izvor: ZSE

Redovni promet

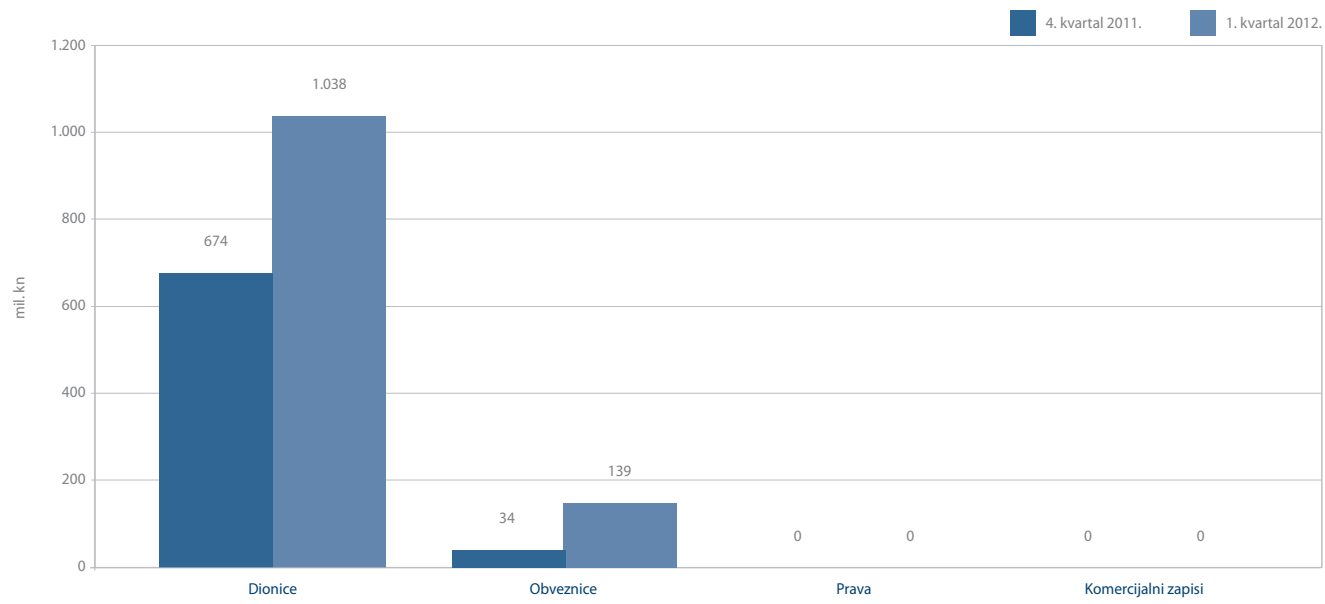

U tablici 1.1.2. prikazan je detaljan pregled trgovanja po mjesecima u I. kvartalu 2012. godine. Najveći broj transakcija ostvaren je u ožujku u iznosu od 48.363, dok je najmanji broj transakcija ostvaren u siječnju u iznosu od 17.445. Ukupan broj transakcija u I. kvartalu 2012. iznosio je 103.232, što predstavlja povećanje od 58,7% u odnosu na prethodni kvartal. U istom kvartalu ostvaren je promet dionicama u iznosu od 1,04 milijardi kuna što predstavlja rast od 52,44% u odnosu na prethodni kvartal. Promet obveznicama u I. kvartalu 2012. godine iznosio je 244,7 milijuna kuna što je povećanje od 206,3% u odnosu na prethodni kvartal.

Tablica 1.1.2. Pregled trgovine po mjesecima za I. kvartal 2012. godine

	Broj transakcija		**Volumen**			**"Broj aktivnih vrijednosnih papira"**	**"Tržišna kapitalizacija"**
	UKUPNI	"PROSJECNI DNEVNI"	UKUPNI	"PROSJECNI DNEVNI"	PROMJENA S OBZIROM NA PRETHODNI PERIOD		
siječanj	17.445	831	81.191.970	3.866.284	652,67%	155	183.181,90
veljača	37.424	1.782	74.198.133	3.533.244	-8,61%	168	185.068,70
ožujak	48.363	2.198	43.432.927	1.974.224	-41,46%	177	187.706,00
UKUPNO I. KV	103.232	1.613	198.823.029	3.106.610		209	

*tržišna kapitalizacija u milijunima kuna
Izvor: ZSE

Tablica 1.1.3. Promet po vrstama vrijednosnih papira

	Dionice		**Obveznice**		**Prava**		**Ukupni promet**
	Promet	Udjel %	Promet	Udjel %	Promet	**Udjel %**	
siječanj	213,3	65,4%	113,0	34,6%	0	0%	326,3
veljača	351,1	84,3%	65,2	15,7%	0	0%	416,2
ožujak	476,7	87,8%	66,6	12,2%	0	0%	543,3
UKUPNO I.KV	1.041,1	81,0%	244,7	19,0%	0	0%	1.285,8

*promet u milijunima kuna
Izvor: ZSE

Tržišna vrijednost vrijednosnih papira pohranjenih u depozitoriju SKDD-a na kraju I. kvartala 2012. godine iznosila je 305,6 milijardi kuna što je za 3% više nego u prethodnom kvartalu.

Grafikon 1.1.5. Kretanje tržišne vrijednosti vrijednosnih papira pohranjenih u SKDD-u

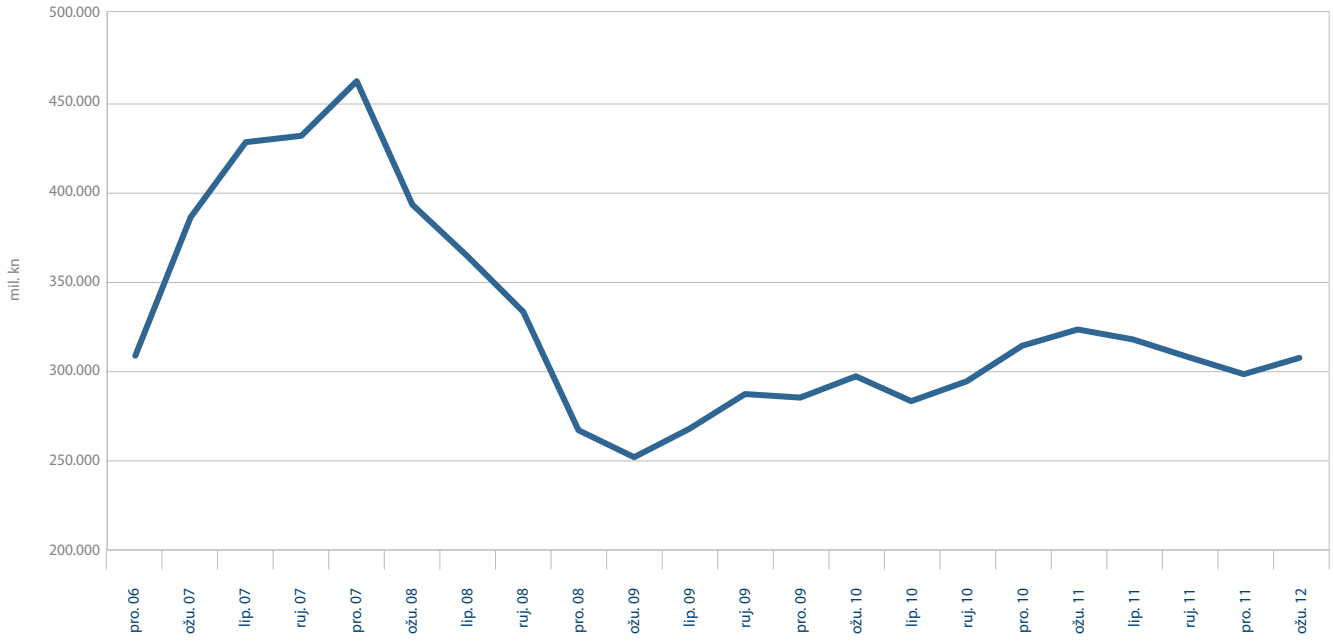

Izvor: SKDD

Struktura vlasništva vrijednosnih papira prikazana je na grafikonu 1.1.6. na kojem je vidljivo da su najveći ulagatelji i dalje domaće pravne osobe s imovinom u iznosu od 160,8 milijardi kuna (u prethodnom kvartalu 154,4 mlrd. kn), dok su drugi po redu najveći ulagatelji strane osobe s iznosom ulaganja od 82,0 milijardi kuna (u prošlom kvartalu 80,1 mlrd. kn). Također, vidljivo je povećanje tržišne vrijednosti vrijednosnih papira svih vrsta investitora u odnosu na prethodni kvartal. Tržišna vrijednost vrijednosnih papira domaćih pravnih osoba povećana je u odnosu na prethodni kvartal za 4% (sa 154,4 milijardi na 160,8 milijardi kuna) što je najveći rast od svih ulagatelja.

Prema strukturi imovine podijeljenoj po vrijednosnim papirima vidljivo je da su domaće fizičke osobe i dalje najviše izložene dionicama (95,8%), isto kao i strane osobe (99,0%), dok su domaće pravne osobe na 31.03.2012. izložene dionicama u iznosu od 67,7%, obveznicama u iznosu od 17,4%, a komercijalnim zapisima u iznosu od 14,9%.

Grafikon 1.1.6. Usporedni prikaz vlasničke strukture imovine

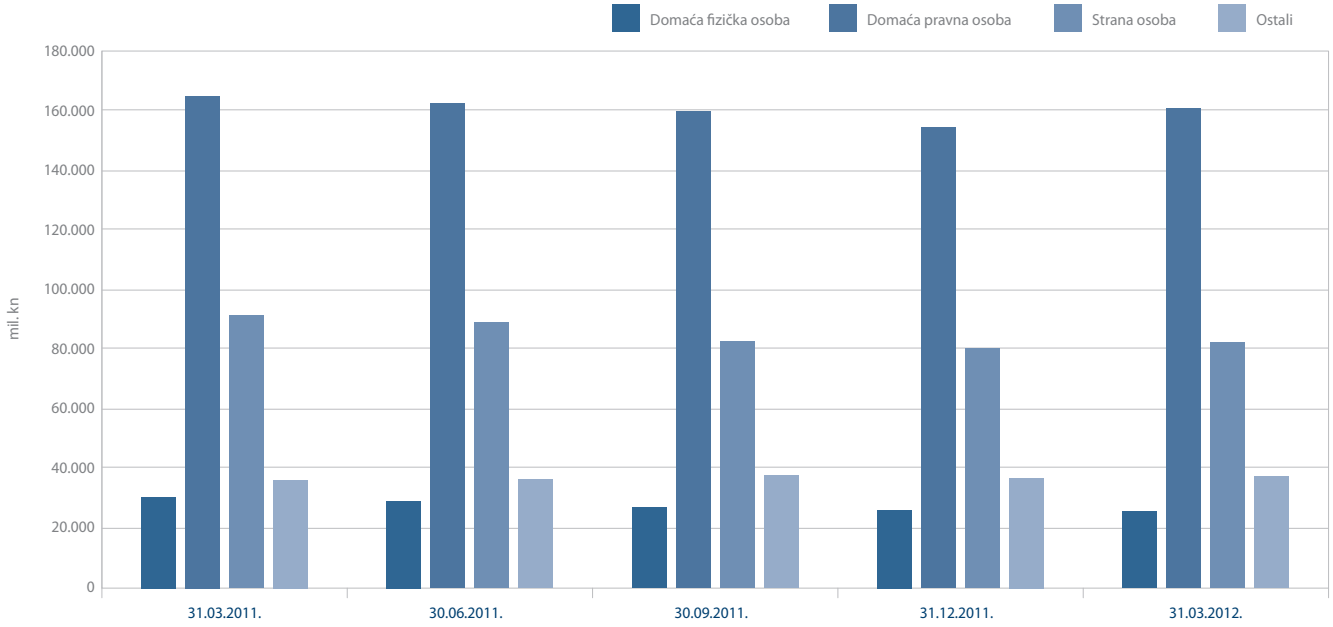

Izvor: SKDD

U sljedećim tablicama prikazane su karakteristike deset najtrgovanijih dionica u prvom kvartalu 2012. godine. Na vrhu ljestvice najlikvidnijih dionica i dalje se nalaze dionice HT-a s prometom od 229 milijuna kuna i ostvarenih 22,1% udjela u ukupnom prometu dionica. Slijede dionice Ingre s prometom od 95,8 milijuna kuna i udjelom od 9,2% u ukupnom prometu dionica. Prema standardnoj devijaciji kao mjeri volatilnosti, od 10 najtrgovanijih dionica najrizičnije su bile dionice Ingre s volatilnošću dnevnih prinosa od 8,65%. Slijede dionice Croatia osiguranja s volatilnošću od 4,84% i dionice Petrokemije s volatilnošću od 3,12% (u prethodnom kvartalu najvolatilnija s 2,17%). Najmanju volatilnost imale su dionice Ine sa standardnom devijacijom od 0,43%, dok su u IV. kvartalu 2011. imale volatilnost 1,34%.

Dok su u prethodnom kvartalu pet dionica ostvarile negativne prinose, u posljednjem kvartalu tri od 10 najtrgovanijih dionica ostvarile su pad prinosa. Najveći pad cijene u I. kvartalu ostvarila je dionica HT-a u iznosu od 11,4%, s 242 na 214,4 kunu. Slijedi dionica Ine s padom cijene od 5,9%, s 3.800 na 3.575. Najveći rast cijene ostvarila je dionica Đuro Đaković u iznosu od 63% s 50,7 na 82,65 kuna, zatim dionice Croatia osiguranja u iznosu od 50,2% s 4.000,00 na 6.000,02 kune. Dnevni prinosi dionice Ingre, Petrokemije i Croatia osiguranja dostigli su maksimalne ekstremne vrijednosti, jer se maksimalna vrijednost dnevnih prinosa nalazi iznad apsolutnog ranga prosjeka i četiri standardne devijacije. Prinosi HT-a su jedini dostigli minimalne ekstremne vrijednosti, jer se minimalna vrijednost dnevnih prinosa dionice nalazi ispod apsolutnog ranga prosjeka i četiri standardne devijacije. Ostale najtrgovanije dionice nisu postigle ekstremne vrijednosti.

Tablica 1.1.4. Struktura prometa, volatilnost i promjena cijena 10 najtrgovanijih dionica u I. kvartalu 2012.

- Struktura prometa dionica i volatilnost prinosa te promjena cijena u odnosu na prethodni kvartal:

Simbol	PROMET	VOLATILNOST	CIJENA (31.12.2011)	CIJENA (31.03.2012)	Promjena cijene
HT-R-A	229.204.265	0,94%	242	214,4	-11,4%
INGR-R-A	95.801.036	8,65%	6,71	8,13	21,2%
PTKM-R-A	62.542.211	3,12%	194,99	275	41,0%
INA-R-A	60.063.982	0,43%	3.800	3.575	-5,9%
ADPL-R-A	43.229.965	1,19%	101,49	128,95	27,1%
ADRS-P-A	39.590.171	1,00%	218,99	211	-3,6%
ERNT-R-A	38.697.812	1,86%	1.080	1.172,94	8,6%
KORF-R-A	35.444.184	1,51%	71	95	33,8%
CROS-R-A	30.359.953	4,84%	4.000	6.006,02	50,2%
DDJH-R-A	29.979.465	2,47%	50,7	82,65	63,0%
ostali	373.400.660				
UKUPNO	1.038.313.704				

Izvor: Bloomberg, ZSE

- Struktura prometa dionica

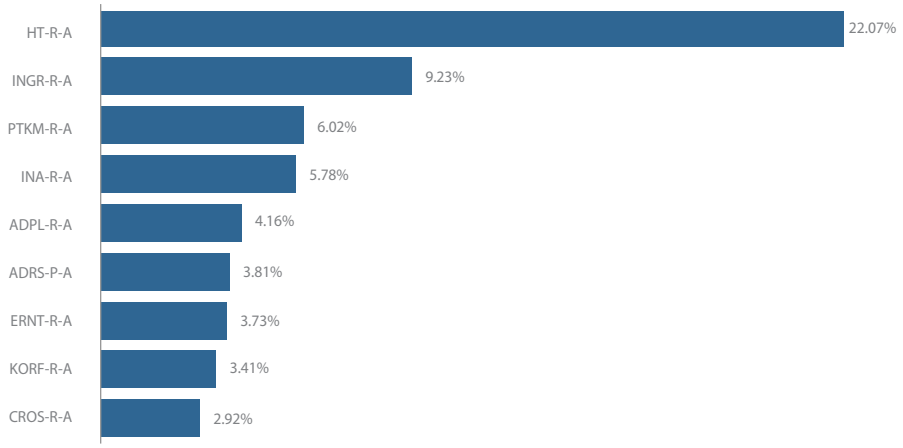

Izvor: Bloomberg, ZSE

- Dnevni prinos (prosjek, minimum, maksimum) u I. kvartalu

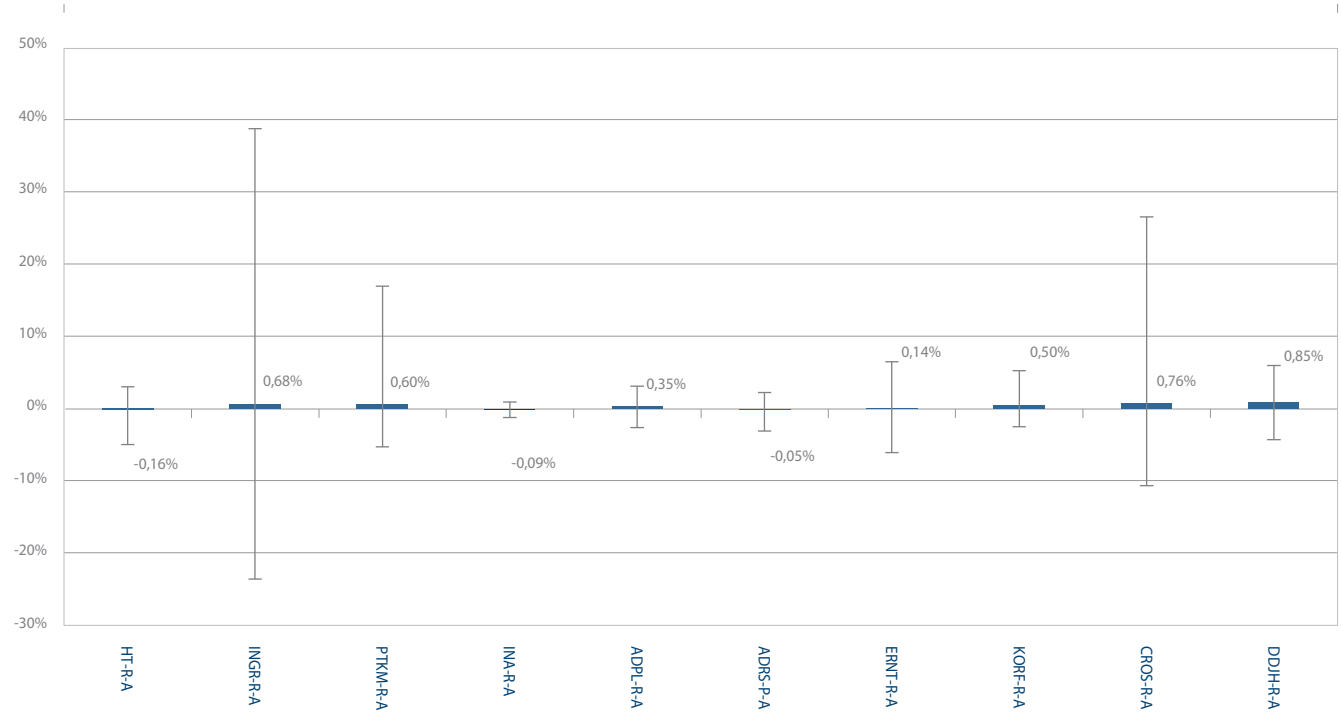

Izvor: Bloomberg, ZSE

U tablici 1.1.5. prikazana je korelacija CROBEX-a s ostalim tržišnim indeksima. Koeficijent korelacije je izračunat na 31.03.2012. godine u vremenskim serijama od 10, 30, 90, 250 i 750 dana. Možemo primijetiti srednje jaku pozitivnu korelaciju u vremenskoj seriji od 10 dana s banjalučkim indeksom BIRS, makedonskim indeksom te austrijskim i francuskim indeksima, a u vremenskoj seriji od 250 dana sa svim europskim indeksima osim s talijanskim i švicarskim (isto kao i u prethodnom kvartalu). U prethodnom kvartalu bila je zastupljenija srednje jaka korelacija s razmatranim indeksima nego u prvom kvartalu 2012. godine. U vremenskoj seriji od 750 dana Crobex bilježi slabu uglavnom pozitivnu korelaciju.

Tablica 1.1.5. Korelacija prinosa CROBEX-a s ostalim tržišnim indeksima

		Broj dana				
Država	Indeks	10	30	90	250	750
BiH	SASX10	0,14	0,08	0,12	0,15	-0,03
BiH	BIRS	0,69	0,23	0,20	0,16	0,05
CRNA GORA	MONEX20	-0,45	0,06			
MAKEDONIJA	MBI	0,55	0,17	0,12	0,32	0,08
SLOVENIJA	SBI TOP	0,42	-0,07	0,06	0,27	0,04
SRBIJA	BELEX 15	0,16	-0,28	0,08	0,39	0,14
AUSTRIJA	ATX	0,62	0,49	0,40	0,60	0,22
FRANCUSKA	CAC40	0,55	0,47	0,40	0,53	0,25
ITALIJA	FTSEMIB	0,23	0,37	0,41	0,46	0,21
NIZOZEMSKA	AEX	0,47	0,43	0,34	0,54	0,23
NJEMAČKA	DAX	0,42	0,44	0,39	0,53	0,24
ŠVICARSKA	SMI	0,43	0,39	0,31	0,47	0,21
VB	UKX	0,34	0,31	0,38	0,53	0,25
AUSTRALIJA	ASX 200	-0,03	0,21	0,36	0,49	0,14
JAPAN	NIKKEI 225	-0,06	0,22	0,17	0,35	-0,03
KANADA	SPTSX	0,23	0,22	0,32	0,39	0,22
KINA	SHCOMP	0,17	0,18	0,14	0,31	0,05
SAD	S&P 500	0,43	0,28	0,34	0,36	0,25

Izvor: Bloomberg

Iz prikazanih korelacija 10 najtrgovanijih dionica na uređenom tržištu vidljivo je da je srednje jaka pozitivna korelacija zastupljena između dionica AD Plastika i Đuro Đaković od 0,5240. Ostale korelacije su slabo pozitivne odnosno slabo negativne. Uočava se da je srednje jaka korelacija u prethodnom kvartalu bila puno više naglašena nego u tekućem kvartalu. U četvrtom kvartalu sedam parova dionica imale su međusobno srednje jaku korelaciju.

Tablica 1.1.6. Korelacija 10 najtrgovanijih dionica u I. kvartalu 2012.

	HT-R-A	INGR-R-A	PTKM-R-A	INA-R-A	ADPL-R-A	ADRS-P-A	ERNT-R-A	KORF-R-A	CROS-R-A	DDJH-R-A
HT-R-A	1									
INGR-R-A	-0,1032	1								
PTKM-R-A	-0,1349	0,0866	1							
INA-R-A	-0,0316	-0,1788	-0,1800	1						
ADPL-R-A	0,1422	0,1376	0,2633	-0,0850	1					
ADRS-P-A	0,2508	-0,0591	-0,0713	0,0489	0,0854	1				
ERNT-R-A	0,0361	-0,0780	0,0391	-0,0839	0,2476	0,0755	1			
KORF-R-A	-0,0656	0,0107	0,4129	-0,0550	0,4242	0,1283	0,0494	1		
CROS-R-A	0,0178	0,0611	-0,1323	-0,2028	0,1592	-0,2028	0,4564	-0,0904	1	
DDJH-R-A	0,0290	0,1683	0,2139	-0,0209	0,5240	0,1855	0,2521	0,3393	-0,0161	1

Izvor: Bloomberg

Za izračun volatilnosti tržišta uzet je reprezentativan uzorak od 10 najtrgovanijih dionica i sljedeća formula:

$$VT = VOLATILNOST\ TRŽIŠTA$$

$$VT = \sum_{i=1}^{10} \left(volatilnost\ dionice\ (i) * \begin{array}{c} udio\ dionice\ (i)\ u\ ukupnom \\ prometu\ 10\ najtrgovanijih \end{array} \right)$$

Volatilnost ukupnog tržišta u prvom kvartalu 2012. iznosila je 2,56%, dok je u prethodnom kvartalu iznosila 1,11% te je prema ovom pokazatelju tržište u ovom kvartalu naglašeno volatilnije nego u prethodnom kvartalu.

Tablica 1.1.7. Volatilnost tržišta

I. kvartal 2012	2,56%
IV. kvartal 2011	1,11%

Izvor: Bloomberg

Najveću volatilnost tečaja u prvom kvartalu imao je tečaj japanskog jena u odnosu na hrvatsku kunu koji je prvi kvartal 2012. završio s volatilnošću od 11,19%. Najveći pad volatilnosti zabilježio je tečaj švicarskog franka u odnosu na hrvatsku kunu s 6,83% u četvrtom kvartalu prethodne godine na 2,63% u prvom kvartalu ove godine.

Tablica 1.1.8. Volatilnost tečaja

ANUALIZIRANA VOLATILNOST TEČAJA					
ZEMLJA	VALUTA	2Q 2011	3Q 2011	4Q 2011	1Q 2012
Australija	AUDHRK	9,65%	12,20%	9,53%	8,40%
Kanada	CADHRK	9,25%	9,84%	8,99%	7,84%
Češka	CZKHRK	4,70%	7,03%	9,82%	7,34%
Danska	HRKDKK	1,91%	2,41%	1,64%	2,23%
Mađarska	HUFHRK	7,06%	12,60%	16,31%	11,07%
Japan	JPYHRK	13,84%	12,54%	12,21%	11,19%
Norveška	NOKHRK	7,36%	9,64%	5,93%	7,45%
Švedska	SEKHRK	6,76%	11,53%	6,33%	6,33%
Švicarska	CHFHRK	11,01%	26,92%	6,83%	2,63%
V. Britanija	GBPHRK	9,24%	8,58%	8,65%	6,87%
SAD	USDHRK	11,93%	12,55%	12,86%	8,91%
EU	EURHRK	1,94%	2,32%	1,47%	1,61%
Poljska	PLNHRK	6,63%	15,28%	11,35%	8,64%
Srbija	RSDHRK	10,44%	10,14%	8,21%	6,82%

Izvor: Bloomberg

Iz prikazanih korelacija razmatranih parova tečajeva u tablici 1.1.9. vidljivo je da su najviše vrijednosti, i to srednje jake pozitivne korelacije, zabilježene između tečajeva USD/HRK i CAD/HRK u iznosu od 0,7279, CAD/HRK i AUD/HRK u iznosu od 0,7131, između tečajeva USD/HRK i JPY/HRK od 0,6893, PLN/HRK i HUF/HRK od 0,6612 te USD/HRK i GBP/HRK u iznosu od 0,6123. Ostale srednje jake pozitivne korelacije su ispod vrijednosti 0,6. Srednje jaka negativna korelacija je zabilježena između DKK/HRK i EUR/HRK (-0,5964) te između USD/HRK i PLN/HRK (-0,5475).

Tablica 1.1.9. Korelacija valuta u I. kvartalu 2012.

	AUDHRK	CADHRK	CHFHRK	CZKHRK	EURHRK	GBPHRK	HRKDKK	HUFHRK	JPYHRK	NOKHRK	PLNHRK	RSDHRK	SEKHRK	USDHRK
AUDHRK	1													
CADHRK	0,7131	1												
CHFHRK	0,0991	-0,0776	1											
CZKHRK	-0,0167	-0,1402	0,0795	1										
EURHRK	0,0087	0,0525	0,2441	0,2582	1									
GBPHRK	0,5523	0,6344	0,0185	-0,2271	0,0103	1								
HRKDKK	-0,0264	0,0322	-0,2539	-0,0938	-0,5964	-0,2000	1							
HUFHRK	0,1179	-0,0862	0,0078	0,5477	0,1989	-0,2483	0,0047	1						
JPYHRK	0,3810	0,4466	0,2440	-0,3101	0,0313	0,4010	-0,1504	-0,4042	1					
NOKHRK	0,2626	0,1704	0,3662	0,0762	0,3215	0,1267	-0,1237	0,1997	-0,1166	1				
PLNHRK	0,0947	-0,1499	0,1452	0,5835	0,0454	-0,2552	0,0770	0,6612	-0,4493	0,2679	1			
RSDHRK	0,2246	0,2950	0,1500	-0,1126	0,1197	0,2242	-0,0960	-0,0749	0,2233	0,1569	-0,0734	1		
SEKHRK	0,1756	0,1913	0,1158	0,0082	0,3340	0,1600	-0,0832	0,1765	-0,1371	0,5852	0,0433	0,1907	1	
USDHRK	0,4094	0,7279	0,0289	-0,3992	-0,0947	0,6123	0,0237	-0,4886	0,6893	-0,1467	-0,5475	0,2018	-0,0620	1

Izvor: Bloomberg

U tablici 1.1.10. prikazana je anualizirana volatilnost referentnih kamatnih stopa od drugog kvartala 2011. godine na hrvatskom, londonskom i europskom međubankarskom tržištu. Hrvatsko tržište obilježeno je volatilnijim kamatnim stopama, a najvolatilnija kamatna stopa kroz sve razmatrane kvartale bio je jednomjesečni ZIBOR te je ujedno i najveći rast volatilnosti bio upravo kod spomenute kamatne stope, sa 66,39% na 442,1%. Jednomjesečni, tromjesečni i šestomjesečni EURIBOR i LIBOR zabilježili su kvartalni pad volatilnosti, a najveći pad volatilnosti zabilježio je šestomjesečni EURIBOR s 9,52% u IV. kvartalu 2011. na 2,92% u I. kvartalu 2012. godine.

Tablica 1.1.10. Volatilnost kamatnih stopa

ANUALIZIRANA VOLATILNOST KAMATNIH STOPA				
KAMATNA STOPA	2Q 2011	3Q 2011	4Q 2011	1Q 2012
ZIBOR 1M	68,05%	175,71%	66,39%	442,10%
ZIBOR 3M	66,30%	106,79%	27,97%	55,74%
ZIBOR 6M	31,86%	173,02%	9,97%	23,33%
EURIBOR 1M	13,17%	10,11%	19,36%	8,22%
EURIBOR 3M	5,46%	6,27%	13,02%	4,80%
EURIBOR 6M	4,62%	6,99%	9,52%	2,92%
Euro LIBOR 1M	14,63%	9,80%	19,29%	10,35%
Euro LIBOR 3M	6,22%	5,83%	11,91%	5,73%
Euro LIBOR 6M	5,14%	5,93%	9,13%	4,34%

Izvor: Bloomberg

Trajanje je pokazatelj volatilnosti cijena obveznica. Što je trajanje obveznice dulje, njezina osjetljivost je veća jer će promjene tržišnih kamatnih stopa izazvati veće promjene njezine cijene. Obveznice s višim kuponskim stopama, odnosno, višim stopama prinosa imaju kraće trajanje, jer će investitor ranije moći reinvestirati cijelu glavnicu. U tablici 1.1.11. prikazano je modificirano trajanje kuponskih obveznica kojima se trgovalo u prvom kvartalu 2012. na Zagrebačkoj burzi. Najveći koeficijent trajanja imaju državne obveznice Ministarstva financija s rokom dospijeća u 2022, 2020. i 2019. s trajanjem od 7,3598, 6,1177 i 6,0076. Najveći koeficijent trajanja među korporativnim obveznicama imaju obveznice Hrvatske Elektroprivrede te zatim obveznice Erste&Steiermärkische banke, u iznosima od 4,5698 te 4,1254, obje s rokom dospijeća u 2017. godini.

Tablica 1.1.11. Modificirano trajanje obveznica

Vrsta obveznice	Vrijednosni papir	Izdavatelj	Valuta	Količina	Cijena	Dospijeće	Kupon	Modificirano trajanje
korporativne	HP-O-127A	HP-Hrvatska pošta d.d.	EUR	3.000.000	101,9	1.7.2012	9,00%	0,2510
korporativne	JDRA-O-129A	Jadranka dioničko društvo hoteli i trgovina	HRK	80.000	93	13.9.2012	6,48%	0,3697
korporativne	OPTE-O-142A	OT-Optima telekom d.d. za telekomunikacije	HRK	1.327.510	49	1.2.2014	9,13%	1,0542
korporativne	MTEL-O-137A	Metronet telekomunikacije d.d. za telekomunikacijske usluge	EUR	500	100	17.7.2013	12,00%	1,0619
korporativne	NEXE-O-13CA	NEXE grupa d.d.	EUR	7.500.000	98	10.12.2013	7,83%	1,5134
korporativne	HEP-O-13BA	Hrvatska elektroprivreda - dioničko društvo	HRK	7.200.000	96,5	29.11.2013	5,00%	1,5326
korporativne	OIV-O-14BA	Odašiljači i veze društvo s ograničenom odgovornošću, za prijenos i odašiljanje radijskih i televizijskih programa za račun drugih	HRK	246.000	100	20.11.2014	7,25%	2,3035
korporativne	ATGR-O-169A	Atlantic Grupa dioničko društvo za unutarnju i vanjsku trgovinu	HRK	50.000	99,42	20.9.2016	6,75%	3,7923
korporativne	RIBA-O-177A	Erste&Steiermärkische banka dioničko duštvo	EUR	618.334	96	18.7.2017	6,50%	4,1254
korporativne	HEP-O-17CA	Hrvatska elektroprivreda - dioničko društvo	HRK	21.100.000	97,2	7.12.2017	6,50%	4,5698
državne	RHMF-O-125A	Ministarstvo financija Republike Hrvatske	EUR	115.896.500	100,5	23.5.2012	6,88%	0,1432
državne	RHMF-O-137A	Ministarstvo financija Republike Hrvatske	HRK	99.481.000	98,7	11.7.2013	4,50%	1,2134
državne	RHMF-O-142A	Ministarstvo financija Republike Hrvatske	EUR	14.080.000	101,87	10.2.2014	5,50%	1,7350
državne	RHMF-O-15CA	Ministarstvo financija Republike Hrvatske	HRK	70.000	97,75	15.12.2015	5,25%	3,2654
državne	RHMF-O-167A	Ministarstvo financija Republike Hrvatske	HRK	188.896.000	98,66	22.7.2016	5,75%	3,7213
državne	RHMF-O-172A	Ministarstvo financija Republike Hrvatske	HRK	69.430.000	94,2	8.2.2017	4,75%	4,2179
državne	RHMF-O-17BA	Ministarstvo financija Republike Hrvatske	HRK	245.612.000	99,45	25.11.2017	6,25%	4,5962
državne	RHMF-O-203A	Ministarstvo financija Republike Hrvatske	HRK	55.000.000	97,3	5.3.2020	6,75%	5,9963
državne	RHMF-O-19BA	Ministarstvo financija Republike Hrvatske	EUR	10.300	93	29.11.2019	5,38%	6,0076
državne	RHMF-O-203E	Ministarstvo financija Republike Hrvatske	EUR	380.900	99	5.3.2020	6,50%	6,1177
državne	RHMF-O-227E	Ministarstvo financija Republike Hrvatske	EUR	1.729.000	100,9	22.7.2022	6,50%	7,3598

Izvor: HANFA, ZSE

1.2. Primjena internih modela za izračun kapitalnih zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik investicijskih društava

Tijekom posljednjih dvadeset godina rast aktivnosti trgovanja na financijskim tržištima, brojni slučajevi financijske nestabilnosti i česti gubici rezultirali su detaljnom revizijom i mjerenjem rizika s kojima se suočava financijski sektor. Financijska aktivnost je po samoj svojoj prirodi nestabilna i rizična. Također i na razvijenim tržištima uvijek se može pojaviti neki događaj kojega tržište nije „doživjelo" nikada ranije. Zato je važnost mjerenja i kontrole financijskih rizika izuzetno velika. Financijske institucije posjeduju *interne* mjere kako bi ostvarile optimalan prinos na kapital (kada je kapital rizičan) i kako bi osigurale opstanak institucije u cjelini. Postoje i *vanjske* mjere koje su vođene konkurencijom i ogromnim porastom industrije upravljanja rizicima te povećanom volatilnošću financijskog tržišta.

Značajnu ulogu u razvoju tehnika upravljanja rizicima ima sama regulativa. *Bazelski odbor* (engl. *Basel Committee on Banking Supervision*) donosi Bazelsku regulativu, koja propisuje pokrivanje rizika kojima su izložene financijske institucije kapitalom te brine za osiguranje kvalitete supervizije banaka i investicijskih društava na globalnoj razini temeljem uređivanja i promoviranja međunarodnih standarda. Temeljni interes Bazelskog odbora je razina adekvatnosti kapitala. Sporazum *Basel I* koji je sadržavao preporuku metodologije izračuna razine adekvatnosti kapitala imao je vrlo povoljan utjecaj na visinu kapitala banaka, pomogao je jačanju stabilnosti međunarodnog bankarskog sustava kao posljedici zahtijevane više stope adekvatnosti kapitala, no ipak nije uspio adekvatno odgovoriti na sve probleme. Izmijenjen je 1996. godine kada su radi sve veće izloženosti tržišnim rizicima upravo ti rizici izdvojeni kao posebna kategorija te su uključeni i kapitalni zahtjevi za tržišne rizike. Od 1996. godine kod upravljanja tržišnim rizicima dozvoljeno je korištenje internih modela za izračun kapitalnih zahtjeva za tržišni rizik.

Basel II je objavljen u lipnju 2004., a početak njegove primjene u razvijenim zemljama je 31.12.2006. godine. Također se uvodi zajednički okvir mjerenja tržišnih rizika s kojima se suočavaju obje vrste institucija. Basel II predstavlja novi način izračuna adekvatnosti kapitala banaka i investicijskih društava uz nova pravila mjerenja i upravljanja rizicima kojima su oni izloženi, a cilj mu je stvoriti osjetljivu i reprezentativnu praksu upravljanja rizicima. On definira koliki je iznos vlastitog kapitala banke i investicijskih društava dovoljan za pokriće neočekivanih gubitaka. Basel II ima cilj poboljšati kvalitetu sustava upravljanja rizicima te doprinijeti financijskoj stabilnosti. On također uvodi kategoriju operativnog rizika i mjerenje kapitalnog zahtjeva za taj rizik. Usvajanjem *Direktiva 2006/48/EC* i *2006/49/EC* izvršena je transpozicija novog Bazelskog sporazuma (Basel II) za superviziju kreditnih institucija i investicijskih društava u zakonodavstvo Europske unije. Spomenute Direktive su poznate pod nazivom *Direktive o kapitalnim zahtjevima* (*engl. Capital Adequacy Direct*ive). Kako bi osigurale efikasnije upravljanje financijskim rizicima, Direktive o adekvatnosti kapitala omogućuju jednaki tretman kreditnih institucija i investicijskih društava ujednačujući kapitalne zahtjeve.

Za mjerenje i kontrolu rizika regulatorima su raspoloživa tri glavna alata: minimalni kapitalni zahtjevi za rizike, nadzor i zahtjevi za izvještavanje te javno objavljivanje. U siječnju 2009. godine u Republici Hrvatskoj je stupio na snagu novi *Zakon o tržištu kapitala* (mijenja stari Zakon o tržištu vrijednosnih papira), koji regulira adekvatnost kapitala investicijskih društava. U isto je vrijeme donesen i *Pravilnik o adekvatnosti kapitala investicijskih društava* u kojem se detaljno razrađuje izračun kapitalnih zahtjeva za sve rizike kojima je društvo izloženo, pa i za tržišni rizik i to primjenom standardizirane metode.

Prema Zakonu o tržištu kapitala i Pravilniku o adekvatnosti kapitala investicijskih društava investicijska društva mogu tražiti odobrenje regulatora (HANFA) za primjenu vlastitog internog VaR modela na temelju kojeg bi se izračunao minimalni potrebni kapital koji bi pokrio tržišni rizik. Investicijsko društvo koje želi primijeniti interni model za izračun maksimalnog mogućeg gubitka vrijednosti portfelja izloženog pozicij-

skom riziku, valutnom i/ili robnom riziku mora razraditi takav model te analizirati učinkovitost takvog modela.

VaR (*engl. Value at risk*) metoda je razvijena u financijskoj industriji u cilju definiranja izloženosti portfelja rizicima i upravo taj alat je dio upravljanja rizicima u mnogim financijskim institucijama. VaR odnosno mjera rizičnosti vrijednosti daje procjenu potencijalne negativne promjene vrijednosti portfelja koja uz određenu vjerojatnost za vrijeme određenog razdoblja neće biti premašena (na primjer procjena moguće promjene vrijednosti portfelja slijedećeg dana). Drugim riječima, VaR je procjena najvećeg gubitka s kojim bi se moglo suočiti investicijsko društvo u svom portfelju. VaR mjera može iskazati izloženost različitim rizicima, na primjer riziku promjene cijene, riziku promjene kamatne stope, valutnom riziku, riziku druge ugovorne strane, riziku likvidnosti i operativnom riziku. Uz pomoć tog alata moguće je kvantificirati glavninu rizika kojima je investicijsko društvo izloženo a sve u svrhu poboljšanja donošenja odluka u samom društvu.

Investicijska društva mogu bazirati procjene takvih gubitaka ili na temelju pravila samih regulatora ili mogu tražiti odobrenje za uvođenje vlastitih internih VaR modela za izračun minimalnog potrebnog kapitala u svrhu pokrivanja njihovih tržišnih rizika. Kapitalni zahtjevi za rizike kod društava koji ne primjenjuju interne modele su najčešće konzervativni, tako da je motivacija za korištenje VaR modela prilično naglašena.

Raspon dostupnih tehnika za upravljanje rizicima se uvelike povećao tako da odluka koju metodologiju usvojiti više nije jednostavna. Prilikom analize odabranih metoda glavni naglasak treba staviti na uspoređivanje učinkovitosti svake od metoda te time i na odabir najefikasnijeg modela za izračun kapitalnog zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik.

Česta tema brojnih financijskih radova je upravo korištenje različitih tehnika internih VaR modela. Dvije osnovne VaR metodologije za računanje VaR mjere su neparametarska (metoda varijance-kovarijance) i parametarska metoda (povijesna metoda). Kod metode varijance-kovarijance volatilnost se može procjenjivati na više načina. Primjerice, procjena volatilnosti se može provesti pomoću jednostavnog pomičnog prosjeka (*engl. Simple Moving Average* - ***SMA***) ili pomoću eksponencijalno ponderiranog pomičnog prosjeka (*engl. Exponentially Weighted Moving Average* - ***EWMA***) no također se mogu koristiti i neke sofisticiranije metode procjene volatilnosti. Jedna od takvih metoda je *generalizirani autoregresivni uvjetni heteroskedastični model* (*engl. Generalized Autoregressive Conditional Heteroscedasticity Model* - ***GARCH***).

Testiranje VaR modela društvo treba provesti korištenjem retroaktivnog testiranja (*engl. back-testing*) VaR mjere u skladu s Pravilnikom o adekvatnosti kapitala investicijskih društava. Pomoću retroaktivnog testiranja provjerava se koji VaR model može učinkovitije procijeniti pozicijski rizik, valutni rizik i/ili robni rizik odnosno koliko maksimalne vrijednosti gubitaka izračunate primjenom različitih modela odstupaju od stvarnih vrijednosti gubitaka portfelja. Na osnovu dobivenih rezultata određuje se koja VaR metoda je najpreciznija.

Primjena modela za izračun kapitalnog zahtjeva za spomenute rizike investicijskog društva trebala bi davati manji kapitalni zahtjev u usporedbi s kapitalnim zahtjevom dobivenim primjenom standardizirane metode definirane zakonskom regulativom. Investicijsko društvo treba uočiti prednosti i nedostatke korištenja internih modela za računanje kapitalnih zahtjeva te na osnovu toga donijeti odluku da li uvesti ili ne interne modele u vlastiti sustav upravljanja rizicima.

VaR procjene najviše ovise o kvaliteti i valjanosti modela na kojima se one temelje. Ako su ovi modeli neprikladni te krivo prikazuju pravu izloženost društva rizicima, onda će kvaliteta informacija dobivena njihovom primjenom biti loša. Netočni VaR modeli ili modeli koji ne daju konzistentne procjene tijekom vremena poništit će glavnu „korist" kapitalnih zahtjeva temeljenih na modelima: usku povezanost između kapitalnih zahtjeva i prave izloženosti investicijskog društva riziku.

Nadzorna tijela nisu samo zainteresirana za valjanost potencijalnih modela nego također i razinu konzervativizma u pogledu procijenjene mjere rizika. Konzervativan model se može definirati kao onaj koji konzistentno daje visoke procjene rizika u odnosu na druge modele. Naravno da investicijsko društvo ima motiva-

ciju usvojiti VaR model koji će zadovoljiti zahtjeve za adekvatnost kapitala i tako biti dovoljno konzervativan kako bi ugodio nadzornom tijelu, no društvo također želi i minimizirati razinu pričuve kapitala koju zakonski moraju održavati. Zbog toga je u interesu društva da procijeni učinkovitost svih promatranih modela prije usvajanja i primjene točno određenog modela.

Investicijsko društvo je u svom poslovanju izloženo tržišnim rizicima, operativnom riziku, kreditnom riziku i riziku likvidnosti. U tržišne rizike se ubrajaju: pozicijski rizik, rizik namire i rizik druge ugovorne strane, rizik prekoračenja dopuštenih izloženosti, valutni rizik i robni rizik. Kod tržišnih rizika kapitalni zahtjev se računa za svaki od rizika koji su sastavni dijelovi tržišnih rizika. Načini izračuna kapitalnih zahtjeva za sve rizike detaljno su propisani Pravilnikom o adekvatnosti kapitala investicijskih društava. Važno je napomenuti da investicijsko društvo mora u svakom trenutku zadovoljavati razinu adekvatnosti kapitala. U tekstu koji slijedi *Agencija* predstavlja Hrvatsku agenciju za nadzor financijskih usluga (HANFA).

Prema Zakonu o tržištu kapitala Agencija investicijskom društvu daje odobrenje za korištenje internih modela za izračun kapitalnih zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik. Društvo može upotrebljavati kombinaciju internih modela i metoda za izračun kapitalnih zahtjeva za pozicijske rizike, valutni rizik i robni rizik, koje su navedene u Pravilniku o adekvatnosti kapitala investicijskih društava, ako je za isto dobilo prethodno odobrenje Agencije. Društvo mora zadovoljavati određene uvjete za dobivanje odobrenja za korištenje internih modela, stroge kvalitativne i kvantitativne standarde te mora ispunjavati kriterije za validaciju modela i provođenje retroaktivnog testiranja, što je propisano u Pravilniku o adekvatnosti kapitala investicijskih društava. Investicijsko društvo je dužno osigurati da validaciju internog modela adekvatno provodi kvalificirana osoba neovisna o razvojnom procesu istog kako bi osigurala da je interni model konceptualno valjan i da na odgovarajući način obuhvaća sve značajne rizike. Navedena validacija provodi se pri početnom razvoju internog modela, te pri svakoj značajnoj promjeni internog modela.

Interni model za mjerenje pozicijskog, valutnog i/ili robnog rizika mora odrediti maksimalni gubitak tijekom 10 trgovinskih dana s pouzdanošću od 99%. Prema tome, investicijsko društvo ima mogućnost procjenjivanja razine gubitka portfelja pomoću VaR mjere s malom vjerojatnosti njenog prekoračenja tijekom fiksnog vremenskog horizonta, no uz pretpostavku da se portfelj ne mijenja tijekom takvog vremenskog horizonta.

Validacija internog modela se provodi periodično te ako je došlo do značajnih promjena na tržištu ili do promjena u strukturi portfelja zbog kojih interni model ne bi više bio adekvatan za upravljanje tržišnim rizicima. Validacija internog modela mora, pored obaveznog stres testiranja, minimalno uključivati i testiranje pretpostavki internog modela kako bi investicijsko društvo utvrdilo da su adekvatne i da ne rezultiraju krivom procjenom rizika, zatim, kao dodatak programu retroaktivnog testiranja, investicijsko društvo je dužno provoditi i vlastite testove vrednovanja internog modela ovisno o rizicima i strukturi portfelja te uporabu hipotetičnih portfelja kako bi se osiguralo da interni model obuhvaća pojedine strukturne karakteristike portfelja.

Investicijsko društvo je dužno kontinuirano pratiti točnost izračuna i funkcioniranje internog modela provođenjem programa retroaktivnog testiranja. Retroaktivno testiranje mora, za svaki radni dan, omogućiti usporedbu mjere jednodnevne rizičnosti vrijednosti dobivene primjenom internog modela za pozicije iz portfelja investicijskog društva na kraju dana s vrijednostima portfelja investicijskog društva na kraju sljedećeg radnog dana. Investicijsko društvo je dužno provoditi retroaktivno testiranje na temelju stvarnih promjena vrijednosti portfelja (izuzimajući naknade, provizije i neto kamatni prihod) i hipotetičnih promjena vrijednosti portfelja (usporedba vrijednosti portfelja na kraju dana i, pod pretpostavkom nepromijenjenih pozicija, njegove vrijednosti na kraju sljedećeg dana).

Investicijsko društvo koje kapitalni zahtjev izračunava primjenom internog modela, kapitalni zahtjev izračunava na način da množi rezultate dobivene primjenom internog modela multiplikacijskim faktorom koji iznosi najmanje 3. Multiplikacijski faktor

se uvećava faktorom uvećanja u iznosu između 0 i 1 (u skladu s Tablicom 6. iz članka 79. Pravilnika o adekvatnosti kapitala investicijskih društava), ovisno o broju prekoračenja za posljednjih 250 radnih dana prema rezultatima retroaktivnog testiranja investicijskog društva. Investicijsko društvo za potrebe utvrđivanja broja prekoračenja može provoditi program retroaktivnog testiranja ili na stvarnim promjenama vrijednosti portfelja ili na hipotetičnim promjenama vrijednosti portfelja, pri čemu je odabrani izbor dužno dosljedno primjenjivati.

Pojam „prekoračenje" ovdje se odnosi na jednodnevnu promjenu vrijednosti portfelja koja premašuje relevantnu mjeru jednodnevne rizičnosti vrijednosti, dobivenu primjenom internog modela investicijskog društva. U svrhu određivanja faktora uvećanja, broj prekoračenja procjenjuje se najmanje jednom tromjesečno. Agencija može, u iznimnim situacijama, dopustiti investicijskom društvu da ne uvećava multiplikacijski faktor faktorom uvećanja, ako investicijsko društvo dokaže da je takvo povećanje neopravdano te da je model u osnovi točan.

Ako investicijsko društvo izračunava kapitalni zahtjev primjenom internog modela, kapitalni zahtjev je veći od:

1. iznosa rizičnosti vrijednosti za prethodni dan, izračunatog prema parametrima navedenim prethodno i, ako je potrebno, dodatnog zahtjeva za rizik neispunjavanja obveza; ili
2. prosjeka dnevnih mjera rizičnosti vrijednosti za proteklih 60 radnih dana, pomnoženog multiplikacijskim faktorom prethodno navedenim, prilagođenog faktorom izračunatim u skladu sa Tablicom 6. iz članka 79. Pravilnika o adekvatnosti kapitala investicijskih društava i, ako je potrebno, uvećanog za dodatni zahtjev za rizik neispunjavanja obveza.

Uporaba VaR metode

Ulagatelj koji je zabrinut radi vjerojatnosti jako velikog gubitka želi dobiti odgovor na slijedeće pitanje: „S kojom vjerojatnošću gubitak u slijedećih *h* dana neće biti veći od iznosa *C*?". Vrijednost *C* je upravo VaR vrijednost portfelja. VaR mjera računa maksimalni mogući gubitak ulaganja tijekom danog vremenskog razdoblja uz određenu razinu pouzdanosti, s pretpostavkom da se za to vrijeme portfelj ne mijenja. VaR je funkcija dva parametra: vremenskog razdoblja *h* (odnosno vremenskog horizonta ili razdoblja držanja – dan, mjesec, godina,...) i razine pouzdanosti α% (obično 95% ili 99%).

VaR metoda je u svijetu postala jedan od najrasprostranjenijih alata za mjerenje rizika. VaR se može koristiti za usporedbu tržišnih rizika svih aktivnosti investicijskog društva i za određivanje jedinstvene mjere koja je lako razumljiva višem menadžmentu. Ona se može izračunati pomoću više različitih metodologija koje odabire samo investicijsko društvo. Odlučujući faktor učinkovitosti odabranog VaR modela je upravo matrica varijanci-kovarijanci prinosa faktora rizika. Matrica varijanci-kovarijanci opisuje varijabilnost prinosa pojedinog financijskog instrumenta (varijanca) te smjer povezanosti prinosa između svakog para financijskih instrumenata (kovarijanca) i uvijek je kvadratna i simetrična. Kod modeliranja podataka pravi je izazov, no i prilično zahtjevan problem izrada velikih matrica varijanci-kovarijanci za globalne sustave upravljanja rizicima.

U slučaju razine pouzdanosti od 99% VaR je jednak prvom percentilu distribucije promjene vrijednosti portfelja odnosno distribucije mogućih dobitaka i gubitaka portfelja (*engl. Profit & Loss* - ***P&L***) dok je uz razinu pouzdanosti od 95% VaR jednak petom percentilu distribucije mogućih dobitaka (ili gubitaka) portfelja. Navedena distribucija proizlazi iz mogućih kretanja tržišnih faktora rizika (na primjer promjene vrijednosti portfelja valuta) za vrijeme fiksnog razdoblja od *h* dana, uz pretpostavku da se portfelj ne mijenja tijekom zadanog razdoblja.

U nastavku će se VaR mjera izraziti formulom. Za statičan portfelj tijekom vremenskog razdoblja *h* definira se gubitak (ili dobitak) portfelja na slijedeći način:

$$\Delta P_{t,h} = P_{t+h} - P_t \qquad (1)$$

gdje je P_{t+h} vrijednost portfelja u trenutku $t+h$, P_t je vrijednost portfelja u trenutku t, a $\Delta P_{t,h}$ je *mogući* (ili „nerealizirani") *h*-dnevni gubitak odnosno dobitak

portfelja. Bez obzira što se ne zna točno kretanje faktora rizika na tržištu u budućnosti odnosno tijekom slijedećih *h* dana, ipak postoje nekakve pretpostavke, pa se može očekivati da će **povijesna volatilnost** i korelacije ostati uglavnom iste. Vjerojatnost kretanja faktora rizika može se sažeti kroz distribuciju $\Delta P_{t,h}$ odnosno distribuciju mogućih dobitaka ili gubitaka portfelja tijekom slijedećih *h* dana. Uz pretpostavku da je tijekom danog vremenskog razdoblja sastav portfelja ostao nepromijenjen, VaR mjera je jednostrani interval pouzdanosti gubitka portfelja, odnosno, α%-tni VaR za razdoblje držanja od *h* dana, $VaR_{\alpha,h}$, jednak je iznosu *C* tako da vrijedi:

$$P(\Delta P_{t,h}<-C)=(100-\alpha)\%, \qquad (2)$$

gdje $\Delta P_{t,h}$ označava promjenu vrijednosti portfelja za vrijeme određenog razdoblja držanja *h*, a α% je zadana razina pouzdanosti. Dakle, promjena vrijednosti portfelja $\Delta P_{t,h}$ neće premašiti vrijednost

$-C=-VaR_{\alpha,h}$ uz razinu pouzdanosti od α%. 95%-tni 1-dnevni VaR odgovara razini gubitka koja bi se mogla premašiti jedan dan u 20 dana, dok je 99%-tni 1-dnevni VaR razina gubitka koja bi se mogla premašiti jedan dan u 100 dana.

Definicija VaR mjere pokazuje da ona u velikoj mjeri ovisi o volatilnosti promjene vrijednosti portfelja za vrijeme razdoblja držanja. Upravo radi izračuna volatilnosti potrebno je imati točnu prognozu matrice varijanci-kovarijanci faktora prinosa. Za primjenu internih modela kod izračuna kapitalnih zahtjeva za pozicijski rizik, valutni rizik i/ili robni rizik, Pravilnik o adekvatnosti kapitala investicijskih društava zadaje slijedeće standarde: dnevni izračun VaR mjere, jednostrani interval pouzdanosti od 99% (α=99), razdoblje držanja od 10 radnih dana, efektivno razdoblje povijesnog promatranja od najmanje godinu dana i tromjesečno ažuriranje serije podataka.

Na grafikonu 1.2.1. prikazana je distribucija dobitaka odnosno gubitaka portfelja i označen je VaR s razinom pouzdanosti od α% za razdoblje držanja od h dana (–VaRα,h). Također, VaR će se povećavati kako se povećava razdoblje držanja, jer se nesigurnost promjene vrijednosti portfelja općenito povećava u skladu s veličinom razdoblja držanja.

Grafikon 1.2.1. Distribucija promjene vrijednosti portfelja i VaRα,h

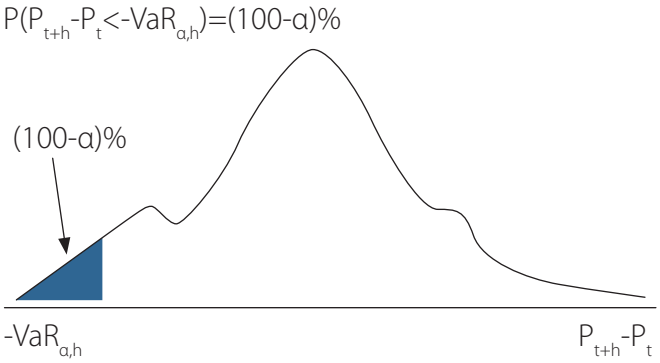

Tri osnovne metode za izračun VaR-a su metoda varijance-kovarijance, povijesna metoda i Monte Carlo simulacija. Metoda varijance-kovarijance pretpostavlja normalnu distribuciju promjene vrijednosti portfelja. Pri korištenju metode varijance-kovarijance mogu se koristiti različiti načini modeliranja volatilnosti. Metoda varijance-kovarijance se primjenjuje kod linearnih portfelja, dok se povijesna metoda i Monte Carlo simulacija primjenjuju i na linearne i na nelinearne portfelje te nemaju nikakve pretpostavke o distribuciji prinosa.

Drugim riječima, metoda varijance-kovarijance zahtijeva procjenu samo dva faktora – očekivane promjene vrijednosti portfelja i standardne devijacije, koji omogućuju da se grafički prikaže normalno distribuirana krivulja. Prednost normalne krivulje je što se na njoj odmah vidi gdje leži „najgorih" 5% ili „najgorih" 1% krivulje. Kod ove metode VaR mjera je funkcija željene razine pouzdanosti α i standardne devijacije σ.

U dijelu empirijskog istraživanja analizirat će se portfelj sastavljen od šest valuta (EUR, USD, CHF, CAD, JPY i GBP) te primijeniti četiri VaR metodologije tijekom razdoblja od 04.01.2006-31.12.2009. Analizirano razdoblje sadrži i prilično volatilno razdoblje tijekom 2008. godine.

Prednosti i nedostaci VaR metoda

Jedna od glavnih prednosti VaR metoda je da uzimaju u obzir i volatilnost i korelacije faktora rizika zbog čega su one usporedive između različitih klasa imovine. VaR model ima značajan potencijal za interno i eksterno upravljanje rizicima te kontrolu

rizika, no isto tako postoje i neki nedostaci njegove uporabe. Trošak implementacije potpuno integriranog VaR sustava može biti prilično velik, a postoji i opasnost da se računanje VaR mjere počne shvaćati kao zamjena za zdravo upravljanje rizicima. Osim spomenutog, VaR mjere mogu biti i prilično neprecizne jer ovise o mnogim pretpostavkama vezanim za parametre modela, a za koje može biti izuzetno teško odlučiti da li ih uključiti ili izostaviti iz razmatranja.

Povijesna metoda

Najčešće korišten neparametarski pristup je povijesna metoda ili povijesna simulacija (*engl.historical simulation* - ***HS***). Povijesna metoda kao metoda neparametarske procjene varijance omogućava modeliranje volatilnosti bez ikakve pretpostavke o statističkoj distribuciji promjene vrijednosti portfelja. Osnovna ideja povijesne metode je korištenje stvarnih povijesnih podataka kako bi se dobila empirijska distribucija dobitaka odnosno gubitaka portfelja.

Empirijska distribucija najčešće nema obilježje normalne distribucije. Na primjer, pojavljivanje debelih repova je karakteristično kod valuta odnosno pojavljivanje koeficijenta zaobljenosti (kurtosis) većeg od koeficijenta zaobljenosti normalne distribucije. U slučaju pojavljivanja debelih repova, VaR mjera procijenjena uz pretpostavku normalne distribucije promjene vrijednosti portfelja rezultirat će podcjenjivanjem „pravog" VaR pokazatelja upravo radi postojanja takvih repova. Povijesna simulacija ne koristi procjenu matrice varijanci-kovarijanci prinosa.

Ova metoda za izračun hipotetske distribucije promjene vrijednosti aktualnog portfelja koristi upravo dinamiku kretanja cijena u prošlosti. U tom slučaju je VaR mjera jednaka percentilu distribucije promjene vrijednosti portfelja za određenu razinu pouzdanosti. Na primjer, ako se koristi 300 povijesnih podataka, tada se jednodnevni 99%-tni VaR dobiva uzimanjem tri najveća gubitka i odabirom najmanjeg od ta tri gubitka, a to je upravo prvi percentil distribucije. Uz pretpostavku da je posljednjih 300 dana dovoljno da se može znati što će se dogoditi slijedeći dan, tada postoji 99%-tna „sigurnost" da gubitak slijedećeg dana neće biti veći od dobivene VaR procjene.

Dakle, primjena ove metode omogućuje da se VaR očita iz povijesne distribucije promjene vrijednosti portfelja, bez pretpostavke bilo kakve distribucije drugačije od one koja je prisutna u povijesnim podacima. Povijesni podaci za portfelj se prikupljaju na dnevnoj bazi i obično pokrivaju razdoblje od nekoliko godina. U Pravilniku o adekvatnosti kapitala investicijskih društava definirano je efektivno razdoblje povijesnog promatranja od najmanje godinu dana, osim kada je kraće razdoblje promatranja opravdano značajnim povećanjem volatilnosti cijena. Ako je moguće najbolje je koristiti od 3 do 5 godina dnevnih podataka.

Na grafikonu 1.2.2. prikazan je primjer histograma jednodnevnih dobitaka odnosno gubitaka portfelja ($\Delta P_t = P_{t+1} - P_t$). Jednodnevni VaR dobiven povijesnom metodom uz 99%-tnu razinu pouzdanosti je prvi percentil empirijske distribucije promjene vrijednosti portfelja prikazane na grafikonu.

Grafikon 1.2.2. Histogram jednodnevne promjene vrijednosti portfelja i VaRα

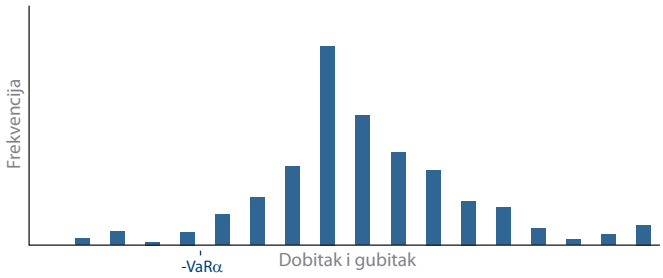

Kod povijesne metode stvarni prinosi se uređuju na način da se raspoređuju od najmanjih do najvećih vrijednosti. Iz perspektive rizika, pretpostavlja se da će se povijest ponoviti. Važno je napomenuti da veoma dugi povijesni podaci mogu sadržavati ekstremne tržišne događaje iz dalje prošlosti koji nisu relevantni za trenutne „normalne" okolnosti. U tom slučaju, kako bi se dobila VaR mjera iz povijesnih podataka primjerena trenutnoj situaciji na tržištu, potrebno je izbaciti ekstremne događaje. Pri tome treba biti pažljiv kako se ne bi odbacili i relevantni podaci, a za VaR modele takvi podaci mogu biti i podaci s izuzetno velikim gubicima. Ako su se ta-

kvi ekstremni događaji dogodili daleko u prošlosti i ako se pretpostavi da nije vjerojatno da se slične okolnosti ponove tijekom slijedećih 10 dana, tada se oni slobodno mogu izbaciti iz analiziranih podataka. Međutim, ako su se ekstremni događaji dogodili nedavno tada ih ne bi trebalo odbaciti, budući su tada takvi podaci relevantni za izračun kapitalnih zahtjeva za tržišni rizik.

Ako je promjena vrijednosti portfelja normalno distribuirana tada bi VaR dobiven povijesnom metodom te metodom varijance-kovarijance trebao biti približno isti. Često je VaR dobiven metodom varijance-kovarijance nešto manji od VaR-a dobivenog povijesnom metodom, što implicira da je distribucija promjene vrijednosti portfelja ili nagnuta ulijevo (pozitivno asimetrična) ili spljoštena sa debelim repovima (zaobljenija u odnosu na normalnu distribuciju), dakle koeficijent asimetrije (skewness) ili koeficijent zaobljenosti (kurtosis) razlikuju se od istih kod normalne razdiobe.

Monte Carlo simulacija

Primjenom ove metode VaR se računa na način da se simuliraju promjene vrijednosti imovine (ili promjene vrijednosti prinosa) pojedinih financijskih instrumenata u potfelju. Zatim se na temelju njih računaju promjene vrijednosti portfelja kao linearne kombinacije simuliranih prinosa financijskih instrumenata i udjela financijskih instrumenata u portfelju. Proces se ponavlja velik broj puta kako bi se generirala reprezentativna distribucija. Nakon što se dobije veliki broj simuliranih vrijednosti promjene vrijednosti portfelja, VaR se dobiva na isti način kao i kod povijesne metode, odnosno VaR mjera je jednaka određenom postotku distribucije (odnosno određenom percentilu distribucije) promjene vrijednosti portfelja. Monte-Carlo simulacija stoga je pogodna ako je portfelj nelinearna funkcija faktora rizika, odnosno ako portfelj sadrži opcije. Dakle, Monte Carlo simulacija umjesto korištenja stvarnih povijesnih podataka, za dobivanje empirijske distribucije dobitaka odnosno gubitaka portfelja, simulira kretanje temeljne imovine od sadašnjeg trenutka pa sve do neke određene točke vremena u budućnosti. Kao početna točka uzimaju se trenutne vrijednosti, a primjenom ove metode generiraju se tisuće mogućih vrijednosti imovine u slijedećih *h* dana.

Ako je generirano 1000 scenarija, a razina pouzdanosti je α%=99%, tada je VaR jednak desetom najvećem gubitku u dobivenim scenarijima, odnosno kao rezultat se uzima (100-*α*)%-tni najveći gubitak. Prednost Monte Carlo simulacije je da ima široku primjenu i da dobro bilježi ponašanje kompleksnih portfelja. Nedostatak ove metode je što može biti vremenski vrlo zahtjevna, pa se koriste neke druge tehnike kako bi se postupak pojednostavio. Na primjer, kako bi se poboljšala efikasnost izračuna jedan od načina je korištenje analize glavnih komponenata, no postoje i druge metode.

Metoda varijance-kovarijance

Kod metode varijance-kovarijance postoji više različitih metoda modeliranja volatilnosti; osim korištenja pomičnih prosjeka postoje i sofisticiraniji modeli prognoziranja volatilnosti. Jedan od takvih modela je GARCH model koji daje prognozu volatilnosti za bilo koju točku u budućnosti. Kao posebna vrsta GARCH modela je i ortogonalni GARCH model (O-GARCH) koji će se uz povijesnu metodu i pomične prosjeke analizirati u empirijskom dijelu u nastavku.

Jednostavni pomični prosjek

U empirijskom dijelu su primijenjena dva pristupa pomičnih prosjeka za procjenu matrice varijanci-kovarijanci: jednostavni pomični prosjek i eksponencijalno ponderirani pomični prosjek. Model jednostavnog pomičnog prosjeka daje jednaki značaj svakom promatranju u razmatranom razdoblju dok metoda eksponencijalno ponderiranog pomičnog prosjeka daje veći značaj novijim opažanjima. Pomični prosjeci se primjenjuju jedino kod procjene bezuvjetne volatilnosti. Budući da je bezuvjetna volatilnost **jedan** broj, odnosno konstanta za čitavu seriju podataka, jedini razlog odstupanja procjena od stvarnih vrijednosti je slučajna pogreška (*engl. sampling error, noise*). Procjena povijesne volatilnosti (*engl. historical volatility*) često se bazira na jednostavnim pomičnim prosjecima (*engl. simple moving average* – ***SMA***) izračunatim na temelju kvadrata *n*

prethodnih vrijednosti prinosa. U nastavku će se definirati **nepristrana procjena varijance distribucije prinosa** u vremenu *T*, na temelju *n* prethodnih dnevnih prinosa r_t (u vremenu *t*), s pretpostavkom da je prosječna vrijednost prinosa jednaka nuli:

$$\hat{\sigma}_T^2 = \sum_{t=T-n}^{T-1} \frac{r_t^2}{n} \qquad (3)$$

Nadalje, potrebno je definirati povijesnu korelaciju na temelju *n* prethodnih vrijednosti prinosa, koja se računa dijeljenjem procjene kovarijance dobivene pomoću jednostavnih pomičnih prosjeka tijekom posljednjih *n* dana s pripadnim standardnim devijacijama:

$$\hat{\rho}_T = \frac{\sum_{t=T-n}^{T-1} r_{1,t} \cdot r_{2,t}}{\sqrt{\sum_{t=T-n}^{T-1} r_{1,t}^{\ 2} \cdot \sum_{t=T-n}^{T-1} r_{2,t}^{\ 2}}} \qquad (4)$$

Treba napomenuti da navedene prognoze mogu imati neke prilično nepoželjne karakteristike. **Prvi se problem** javlja ako se prognoze za cijelo razdoblje držanja računaju primjenom pravila „kvadratnog korijena vremena". Prema tom pravilu standardna devijacija za *h* dana jednostavno se računa kao $\sqrt{h}$ puta dnevna standardna devijacija. Volatilnost je anualizirana forma standardne devijacije i budući da je faktor anualizacije za dnevne prinose jednak $\sqrt{250}$, ako se pretpostavi da u godini ima 250 trgovinskih dana odnosno $\frac{250}{h}$ *h*-dnevnih prinosa, ovo pravilo je ekvivalentno pretpostavci da trenutačna razina volatilnosti ostaje ista odnosno da je konstantna, što u praksi obično nije slučaj.

Drugi problem kod jednostavnog pomičnog prosjeka je da netipičan (ekstreman) prinos tijekom razmatranog razdoblja utječe na procjenu volatilnosti te će ona (i dalje) biti velika točno godinu dana od tog događaja, bez obzira na to što se možda stvarna volatilnost odavno vratila na prosječnu razinu. U ovom slučaju utjecaj ekstremnog događaja podjednako je važan za trenutne prognoze bez obzira da li se dogodio jučer ili daleko u prošlosti. Točno godinu dana nakon tog događaja, veliki prinos „ispada" iz pomičnog prosjeka i tako se prognoza volatilnosti vraća na svoju prosječnu razinu. Kod kraćeg razdoblja primjene jednostavnog pomičnog prosjeka ovo obilježje je puno izraženije, jer se prosječna vrijednost (formula (3)) izračunava na temelju manjeg broja vrijednosti, međutim, tada je utjecaj ekstremnog događaja u procjeni volatilnosti prisutan kraće vremensko razdoblje.

Eksponencijalno ponderirani pomični prosjek (EWMA)

Problem pojavljivanja problema s ekstremnim prinosima kod jednostavnog pomičnog prosjeka ima za posljedicu češće korištenje modela eksponencijalno ponderiranog pomičnog prosjeka (*engl. Exponentially Weighted Moving Average* - ***EWMA***) u matrici varijanci-kovarijanci financijskih prinosa. Kod pristupa eksponencijalno ponderiranog pomičnog prosjeka definira se ponder λ odnosno parametar izglađivanja koji veću „važnost" daje upravo novijim podacima. Starijim opažanjima daje se sve manji i manji ponder.

EWMA za razdoblje od *n* dana primijenjen na kvadratima prinosa r_t^2 definiran je slijedećom formulom:

$$\hat{\sigma}_t^2 = (1 - \lambda) \cdot r_{t-1}^2 + \lambda \cdot \hat{\sigma}_{t-1}^2, \text{ gdje je } 0<\lambda<1. \qquad (5)$$

Procjena kovarijance korištenjem eksponencijalno ponderiranog pomičnog prosjeka definira se na slijedeći način:

$$\hat{\sigma}_{12,t} = (1 - \lambda) \cdot r_{1,t-1} \cdot r_{2,t-1} + \lambda \cdot \hat{\sigma}_{12,t-1} \qquad (6)$$

Uobičajeno je da se manje vrijednosti parametra izglađivanja λ upotrebljavaju za kratkoročne prognoze, a veće vrijednosti za dugoročne prognoze. Važno je naglasiti da eksponencijalno ponderirani pomični prosjek može dati puno bolje procjene kratkoročne volatilnosti od jednostavnog pomičnog prosjeka. U empirijskom istraživanju će se koristiti EWMA s λ=0,94. Važno je napomenuti da EWMA prognoze volatilnosti odmah „reagiraju" na atipičan prinos. Nakon toga, utjecaj atipičnog prinosa tijekom vremena postepeno iščezava.

GARCH model

Na mnogim financijskim tržištima prinosi se ne mogu adekvatno modelirati uz pretpostavku nezavisnosti i jednake distribuiranosti procesa, jer u praksi takva pretpostavka nije realna. Prinosi mogu biti

autokorelirani ili, na primjer, može postojati velika korelacija kvadrata prinosa. U oba slučaja pretpostavka o nezavisnosti procesa nije ispunjena. Pozitivna autokorelacija kvadrata prinosa rezultira **grupiranjem volatilnosti** (*engl. volatility clustering*), kada se mirnija razdoblja s malim prinosima izmjenjuju s volatilnim razdobljima s velikim prinosima (bilo kojeg predznaka). Takvo svojstvo se zove **autoregresivna uvjetna heteroskedastičnost** (*engl. AutoRegressive Conditional Heteroskedasticity* - ***ARCH***).

Na grafikonu 1.2.3. su prikazane dnevne postotne promjene valute američkog dolara USD u odnosu na kunu tijekom razdoblja od 04.01.2006 do 31.12.2009. Vidljiva su razdoblja manjih fluktuacija (2006-2007) i razdoblja velikih fluktuacija (2008-2009). Navedena pojava karakterizira grupiranje volatilnosti.

Grafikon 1.2.3. Dnevna relativna promjena vrijednosti američkog dolara u odnosu na kunu

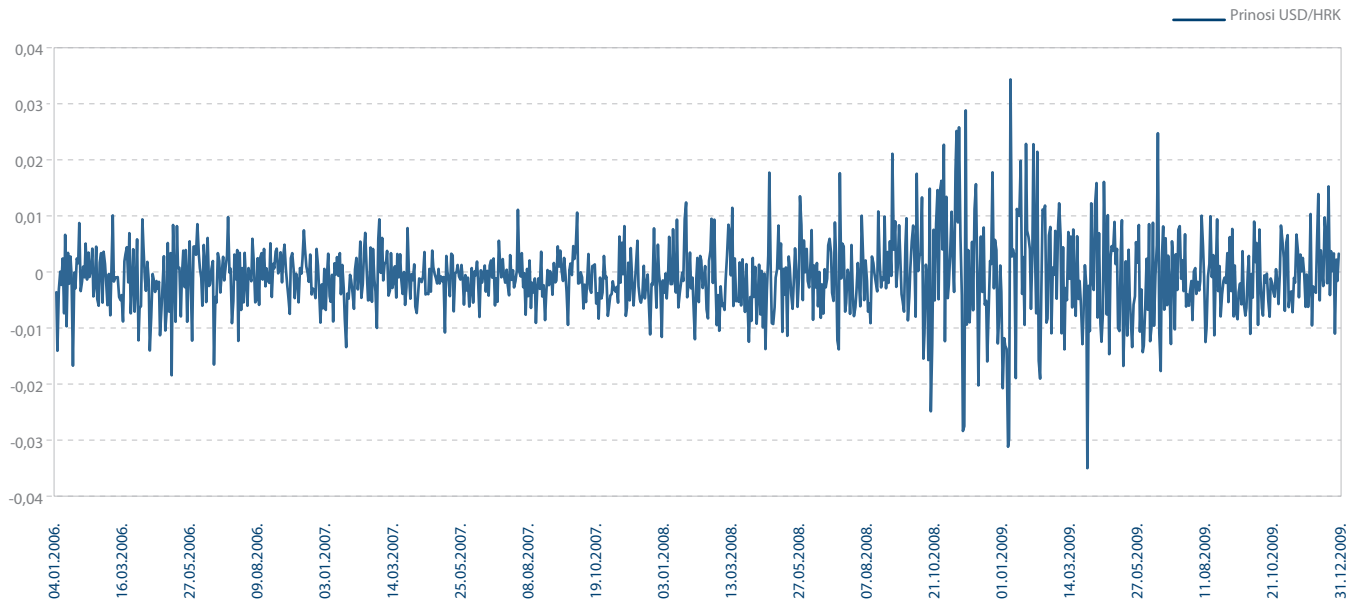

Izvor: HNB, izračun autora

Bollerslev je 1986. uveo simetrični GARCH, a njegova primjena je primjerenija za financijska tržišta. *Generalizirani autoregresivni uvjetni heteroskedastični modeli* (*engl. Generalized AutoRegressive Conditional Heteroscedasticity* - ***GARCH***) omogućuju bolji opis dinamičkog ponašanja serije i od modela eksponencijalno ponderiranih pomičnih prosjeka. U GARCH modelu se pretpostavlja da su prinosi generirani stohastičkim procesom uz vremenski promjenjivu volatilnost. Nadalje, u GARCH modelu se također pretpostavlja da se uvjetna distribucija prinosa mijenja tijekom vremena na autokorelirani način. Točnije, uvjetna varijanca opisuje se autoregresivnim procesom.

Mnoge financijske vremenske serije imaju navedeno svojstvo grupiranja volatilnosti. Ono je vidljivo kod dionica, valuta i roba na dnevnoj, pa čak i na tjednoj razini, a pogotovo je naglašeno u podacima unutar jednog dana.

Uvjetno očekivanje procesa prinosa opisuje se standardnim modelom linearne regresije. Klasični model linearne regresije pretpostavlja da je proces inovacija ε_t (*engl. unexpected return process*, proces grešaka relacije) homoskedastičan, odnosno da ima konstantnu varijancu bez obzira na vrijednost zavisne varijable. Međutim, temeljna ideja GARCH modela je definiranje dodatne jednadžbe kojom se definira i opisuje ponašanje uvjetne varijance procesa inovacija, $V_t(\varepsilon_t) = \sigma_t^2$. Dakle, GARCH model se sastoji od dvije jednadžbe. S obzirom na to da se GARCH model fokusira na uvjetnu varijancu, za prvu jednadžbu uvjetnog očekivanja obično se definira što

jednostavnija jednadžba (na primjer $r_t = c + \varepsilon_t$, gdje je ε_t proces inovacija, a konstanta je prosjek prinosa tijekom danog razdoblja). Općenito, jednadžba uvjetnog očekivanja može biti proizvoljno definirana. U većini empirijskih istraživanja autoregeresijski model prvog reda AR(1) je zadovoljavajući.

Jednadžba uvjetne varijance GARCH(p,q) modela definirana je slijedećom jednadžbom:

$$\sigma_t^2 = a_0 + a_1 \cdot \varepsilon_{t-1}^2 + \ldots + a_p \cdot \varepsilon_{t-p}^2 + \beta_1 \cdot \sigma_{t-1}^2 + \ldots + \beta_q \cdot \sigma_{t-q}^2 \quad (7)$$

gdje su $a_0>0, a_1,\ldots, a_p, \beta_1,\ldots, \beta_q \geq 0$.

Ako se pretpostavi da je konstantni član jednak ω, koeficijent uz član pomičnog prosjeka prvog reda α i koeficijent uz autoregresijski član prvog reda β, tada univarijatni simetrični GARCH(1,1) model sa sredinom nula ima oblik:

$$\sigma_t^2 = \omega + \alpha \cdot \varepsilon_{t-1}^2 + \beta \cdot \sigma_{t-1}^2 \quad (8)$$

gdje ε_t označava proces grešaka relacije, σ_t uvjetnu varijancu od ε_t, a parametri ω, α i β zadovoljavaju uvjet $\omega > 0$, $\alpha, \beta \geq 0$. Ako se u (8) pretpostai da je $\sigma_t^2 = \sigma^2$ za sve vrijednosti t, stabilna varijanca u dugom roku (*engl. long-term steady-state variance*) u GARCH(1,1) modelu jednaka je:

$$\sigma^2 = \frac{\omega}{1 - \alpha - \beta} \quad (9)$$

Da bi proces prinosa bio stacionaran, suma α + β mora biti manja od 1. Jedino će u tom slučaju GARCH volatilnost koja je promjenjiva u vremenu konvergirati prosječnoj razini volatilnosti u dugom roku (*engl. long-term average level of volatility*) definiranoj s (9).

Dakle, osnovni GARCH(1,1) model je:

$$r_t = c + \varepsilon_t,$$
$$\sigma_t^2 = \omega + \alpha \cdot \varepsilon_{t-1}^2 + \beta \cdot \sigma_{t-1}^2 \quad (10)$$

Nenegativna ograničenja na parametre su nužna kako bi se osiguralo da procjena uvjetne varijance uvijek bude pozitivna a parametri se procjenjuju korištenjem funkcije najveće vjerodostojnosti (*engl. maximum likelihood*) s ograničenjima, kao što je objašnjeno u Bollerslev-u (1986). Mnoge financijske institucije u svijetu koriste upravo ovakav osnovni oblik GARCH modela. Alexander (2003) je pokazala da su prognoze u dugom roku generirane pomoću GARCH modela realnije u odnosu na one generirane pomoću modela pomičnih prosjeka. Rijetko je potrebno koristiti GARCH model različit od GARCH(1,1) modela.

Veličine parametara α i β određuju kratkoročnu dinamiku volatilnosti vremenske serije. Velika vrijednost parametra β ukazuje da šokovima koji utječu na uvjetnu varijancu treba dugo vremena da nestanu, odnosno volatilnost je perzistentna. Velika vrijednost parametra α znači da volatilnost reagira prilično „intenzivno" na promjene na tržištu, a ako je α relativno velik, a β relativno mali tada volatilnost ima puno „šiljaka". Na financijskim tržištima je uobičajeno da je procjena parametra perzistencije β temeljena na dnevnim prinosima veća od 0,8, a procjena parametra reakcije α nije veća od 0,2.

Postojanje ekstremnih događaja u povijesnim podacima utječe na prognozu volatilnosti u dugom roku. Kod GARCH modela dovoljno je koristiti nekoliko godina dnevnih podataka kako bi se osigurala konvergencija modela i stabilnost procjena parametara prilikom mijenjanja vremenskog razdoblja podataka, ali ipak ne toliko podataka da te procjene ne odražavaju trenutne uvjete na tržištu. Najčešći uzrok problema s konvergencijom je pokušaj primjene pogrešnog modela ili korištenje loše odabranih podataka. Što se tiče odabira frekvencije podataka, budući da GARCH efekti nisu toliko očiti na nižim frekvencijama obično se koriste dnevni prinosi ili prinosi unutar dana. Radi odabira što primjerenije duljine razdoblja s podacima potrebno je pomno analizirati da li na trenutne prognoze utječu događaji koji su se dogodili više godina ranije.

Jedna od prednosti korištenja GARCH u usporedbi s EWMA modelom je da su kod GARCH modela parametri odabrani optimalno, maksimiziranjem funkcije vjerodostojnosti podataka, dok kod EWMA metode uvijek postoji problem odabira parametra izglađivanja.

Prognoze volatilnosti za bilo koji rok mogu se dobiti iz jednog procijenjenog modela. Kod mnogih GARCH modela je prilično jednostavno konstruirati prognoze jer imaju jednostavnu analitički formu. Prognoze kroz vrijeme konstruirane pomoću takvih modela vraćaju se na prosječnu razinu (*engl. mean-reverting volatility term structures*) prema volatilnosti

u dugom roku i to brzinom koja je određena upravo procijenjenim GARCH parametrima. Ovo je jedna od velikih prednosti GARCH modela u usporedbi sa modelima pomičnih prosjeka koji su bazirani na manje realističnoj pretpostavci – pretpostavci konstantne volatilnosti kroz vrijeme.

Ortogonalni GARCH model

Ako se portfelj sastoji od više oblika imovine, a kako bi se prevladale poteškoće kod izračuna GARCH matrice varijanci-kovarijanci u više dimenzija, potrebno je metodu izračuna takve matrice promjenjive u vremenu bazirati na univarijatnim GARCH modelima.

Ako računamo matricu varijanci-kovarijanci na cijelom skupu imovine (ili na cijelom skupu faktora rizika) dimenzije obično mogu biti tako velike da dolazi do velikih problema kod izračuna, te su često radi toga potrebne određene ograničavajuće pretpostavke. Kao što je navela Alexander (2002),„primjena ovih modela u više od nekoliko dimenzija je izuzetno teška: zato što model ima jako puno parametara, funkcija vjerodostojnosti postaje prilično ravna a samim time i optimizacija funkcije vjerodostojnosti praktički postaje nemoguća." Faktori rizika kao što su krivulje prinosa, kamatne stope, dionički indeksi, valutni tečajevi i cijene roba trebali bi biti uključeni u veliku višedimenzionalnu matricu varijanci-kovarijanci. Takva matrica mora uvijek biti pozitivno semidefinitna[1] (jer bi u protivnom portfelj imao negativnu varijancu, što ne smije biti budući da varijanca uvijek mora biti nenegativna), no prilično je teško generirati veliku pozitivno semidefinitnu matricu koja bi trebala obuhvatiti sve rizike proizašle iz pozicija portfelja. Međutim, postoji primjena izračuna na samo nekoliko ključnih faktora tržišnog rizika koji bilježe najvažnije nekorelirane izvore informacija u podacima te na taj način olakšavaju izračun. U takvim slučajevima od velikog značaja je primjena *ortogonalnih GARCH modela* (*engl. Orthogonal GARCH* - ***O-GARCH***). Ortogonalna GARCH metoda omogućuje jednostavan postupak izračuna primjenom GARCH modela, koja generira pozitivno semidefinitne matrice varijanci-kovarijanci. Ova metoda koristi analizu glavnih komponenata za ortogonalizaciju faktora rizika te onda uz pomoć volatilnosti ortogonalnih faktora generira cijelu matricu varijanci-kovarijanci originalnih faktora rizika. Nije nužno koristiti GARCH modele volatilnosti na glavnim komponentama – umjesto GARCH modela može se koristiti jednostavni pomični prosjek ili eksponencijalno ponderirani pomični prosjek.

Metoda izračuna je prilično jednostavna. Kako bi se dobila cijela matrica varijanci-kovarijanci originalnog sustava prvo se računaju univarijatne volatilnosti prvih nekoliko glavnih komponenata sustava faktora rizika (ili prinosa imovine), zajedno sa matricom pondera faktora reprezentacije glavnih komponenata. Ova metoda je veoma učinkovita kod izračuna budući da se matrica varijanci-kovarijanci prinosa imovine, koja može imati stotine elemenata, može dobiti kao jednostavna transformacija varijanci prvih nekoliko glavnih komponenata. Inače, neki se podaci teško mogu dobiti na direktan način, pogotovo vezano za financijsku imovinu s kojom se aktivno ne trguje. Kada su podaci za neke varijable u sustavu rijetki ili nepouzdani, onda direktna procjena volatilnosti i korelacija može biti prilično komplicirana. U tom slučaju se javlja još jedna prednost ove metode, ako su poznate glavne komponente i ponderi faktora tada se sve volatilnosti i korelacije mogu dobiti korištenjem ortogonalne metode, bez obzira na nepotpune podatke.

Bez obzira da li se za prognoze volatilnosti glavnih komponenata koristi GARCH model ili model pomičnih prosjeka najbolje je metodu primijeniti na skup faktora rizika koji su razumno visoko korelirani.

Neka se X sastoji od x_i vektora normalizirane i-te varijable y_i prinosa imovine:

$$x_i = \frac{y_i - \mu_i}{\sigma_i} \tag{11}$$

gdje je x_i reda Tx1, μ_i je prosječna vrijednost vektora y_i, a T je broj raspoloživih podataka što znači da svaki od vektora x_i ima sredinu 0 i varijancu 1. $X'X$ je kxk matrica s jedinicama na dijagonali, dok su ostali elementi matrice korelacije između varijabli u X,

1 Simetrična matrica V je pozitivno semidefinitna ako i samo ako je $x' \cdot V \cdot x \geq 0$ za sve vektore $x \neq 0$

a k je broj faktora rizika. Svaka od glavnih komponenti je linearna kombinacija vektora x_i s ponderima odabranima iz skupa svojstvenih vektora matrice varijanci-kovarijanci $X'X$ tako da prva glavna komponenta objašnjava maksimalni iznos ukupne varijacije matrice X, dok druga komponenta objašnjava maksimalni iznos preostale varijacije, i tako dalje. Takve glavne komponente su međusobno nekorelirane. Treba naglasiti da je V uvijek pozitivno semidefinitna, a strogo pozitivno definitna jedino u slučaju ako je broj glavnih komponenti $m=k$. Ako je matrica varijanci-kovarijanci u (12) takva da je $m<k$, trebalo bi provjeriti svojstvene vrijednosti kako bi se osigurala stroga pozitivna definitnost. U nekim strukturama promjenjivim u vremenu već prve dvije komponente objašnjavaju više od 99% varijacija, tako da dodavanje treće komponente ne radi nikakvu primjetnu razliku u rezultatu matrice varijanci i kovarijanci.

Reprezentacija glavnih komponenata je multi-faktorski model a ideja korištenja faktorskih modela s GARCH-om nije nova. Engle *et al.* (1990) koriste **model za vrednovanje kapitalne imovine** (*engl. capital asset pricing model* - ***CAPM***) da bi pokazali kako se volatilnosti i korelacije između pojedinih vrsta dionica mogu generirati iz univarijantnih GARCH varijanci tržišnih faktora rizika. Primjenom faktorske analize od većeg se broja izvornih varijabli dobiva manji broj faktora. Ovaj koncept su proširili Alexander i Chibumba (1998) koji predlažu ortogonalni GARCH model. U njihovom pristupu prvo se ortogonaliziraju faktori rizika. Ovi ortogonalni faktori rizika poznati su kao „glavne komponente". Budući da su oni po definiciji međusobno ortogonalni, više se ne trebaju računati kovarijance, time znatno smanjujući broj parametara koje treba procijeniti. Ideja korištenja analize glavnih komponetata za multivarijatno GARCH modeliranje polazi od Dinga (1994). Ding je u reprezentaciji koristio cijeli skup glavnih komponenata, a snaga ortogonalnog GARCH modela počiva na korištenju reduciranog skupa glavnih komponenata, kao što je objašnjeno u Alexander i Chibumba (1996) i Alexander (2000a, 2001b) i Klaassen (2000).

Ortogonalni GARCH model omogućuje da se kxk matrica GARCH varijanci-kovarijanci generira iz samo m univarijatnih GARCH modela. S obzirom da je obično broj glavnih komponenata m puno manji od broja varijabli u sustavu k na taj način se uklanja nepoželjni utjecaj slučajne komponente iz podataka, a dobivene volatilnosti i korelacije postaju puno stabilnije. Neka je u ortogonalnom GARCH modelu sa D_t označena mxm dijagonalna matrica varijanci glavnih komponenata promjenjiva u vremenu. Struktura matrice varijanci-kovarijanci V_t originalnog sustava kroz vrijeme približno je određena sa:

$$V_t = A \cdot D_t \cdot A' \qquad (12)$$

gdje je $A=(\omega_{ij}^*)$ matrica reda kxm (podmatrica matrice kxk svojstvenih vektora od $X'X$) denormaliziranih pondera faktora ($\omega_{ij}^* = \omega_{ij} \cdot \sigma_j$), D=diag ($V(p_1),\ldots V(p_m)$) je dijagonalna matrica varijanci glavnih komponenata, a V_t je matrica varijanci-kovarijanci grešaka relacije. Model (12) se zove **ortogonalni GARCH** ako je dijagonalna matrica varijanci glavnih komponenata D_t procijenjena korištenjem GARCH modela. Ovdje se koristi jednostavni GARCH(1,1) model ('vanilla' GARCH(1,1) model):

$$\sigma_t^2 = \omega + \alpha \cdot \varepsilon_{t-1}^2 + \beta \cdot \sigma_{t-1}^2$$
$$\omega > 0, \alpha, \beta \geq 0 \qquad (13)$$

Reprezentacija (12) će dati pozitivno semidefinitnu matricu u bilo kojoj točki vremena, čak i ako je broj glavnih komponenata m puno manji od broja k varijabli sustava. Pozitivna definitnost matrice varijanci-kovarijanci nužna je kod VaR modela, kako bi oni uvijek generirali pozitivnu VaR mjeru. Treba primijetiti, kako bi se dobila matrica V_t treba jedino procijeniti svojstvene vektore od $X'X$ i elemente na dijagonali u D_t. Još važnije, svaka od varijanci glavnih komponenti se može nezavisno modelirati na univarijatan način korištenjem GARCH modela. U empirijskom dijelu prvo se procjenjuju GARCH(1,1) parametri glavnih komponenti.

Svi elementi matrice varijanci-kovarijanci su dobiveni iz varijanci samo nekoliko glavnih komponenata koje reprezentiraju najvažnije izvore informacija – druge varijacije su pripisane šumu i nisu uključene u model. Inicijalni odabir modela ovisit će o dva važna faktora, **imovini uključenoj u sustav** i **vremenskom razdoblju koje se koristi za procjenu.**

Retroaktivno testiranje

Budući da VaR modeli pokušavaju prognozirati najgori mogući scenarij, trebalo bi ispitati prvi percentil prognozirane distribucije promjene vrijednosti portfelja. To se može napraviti pomoću procedure retroaktivnog testiranja jednodnevnih VaR mjera. Kod retroaktivnog testiranja svaki radni dan se uspoređuje jednodnevna VaR prognoza uz razinu pouzdanosti 99%, dobivena primjenom internog modela za pozicije portfelja na kraju dana s promatranom promjenom vrijednosti portfelja investicijskog društva na kraju sljedećeg radnog dana. Valjanost modela u našem primjeru provjerava se retroaktivnim testiranjem dobivenih VaR mjera za svaki od 251 trgovinskih dana tijekom razdoblja od 01.01.2009.-31.12.2009. godine kako bi se ustanovilo u kojoj mjeri je udio stvarnih gubitaka koji prelazi VaR prognozu u skladu s utvrđenom razinom pouzdanosti modela. Može se primijetiti da je u analiziranom primjeru broj radnih dana 251, a ne 250 tijekom ovog razdoblja, no razlika je vrlo mala.

Tijekom razdoblja od 1 godine dnevna 99%-tna VaR mjera bi trebala pokriti 247 od 250 ishoda uz 3 odstupanja (1% odstupanja). Budući da su statističke pogreške tipa 1 (alfa pogreška, vjerojatnost da će točan model biti odbačen) testa "odbaci model ako se dogode više od 3 greške" prevelike, definiraju se 3 zone a interni VaR model može biti unutar jedne od te 3 zone. Kada se vrijednosti dobivene pomoću VaR modela s jednostranim intervalom pouzdanosti od 99% uspoređuju s dnevnim promjenama vrijednosti portfelja tijekom jedne godine, definirano je da model spada u zelenu zonu ako je prosječan broj odstupanja manji od 5, žuta zona predstavlja od 5 do 9 odstupanja, a ako model ima 10 ili više odstupanja on spada u crvenu zonu. Modeli koji spadaju u žutu zonu podložni su uvećanju vrijednosti multiplikacijskog faktora koji se ,primjenjuje pri uporabi VaR modela u rasponu od 3,40 do 3,85, dok se modeli u crvenoj zoni mogu potpuno odbaciti budući da se smatra kako bitno podcjenjuju 99%-tni VaR. Gore navedene granice su izabrane kako bi maksimizirale vjerojatnost da točni modeli budu unutar zelene zone i da izrazito netočni modeli budu unutar crvene zone. Uz granicu postavljenu na 10 odstupanja za crvenu zonu postoji vrlo mala vjerojatnost pogreške tipa 1, drugim riječima malo je vjerojatno da će točni modeli „pasti" u crvenu zonu. No i točni i netočni modeli mogu biti kategorizirani u žutu zonu ako se dogodi statistička pogreška tipa 1 ili statistička pogreška tipa 2 (beta pogreška). Statistička pogreška tipa 2 znači pogrešno prihvatiti netočan model. Kako bi reducirali vjerojatnost pogreške tipa 2, granica zelene zone je postavljena na x=5. Granica žute zone od 5-9 je postavljena tako da je vjerojatnije da ishodi koji padnu u to područje dolaze od netočnih nego od točnih modela.

Investicijsko društvo također može analizirati i broj odstupanja kod VaR modela s nekom drugom razinom pouzdanosti (na primjer 95%) makar takvo testiranje nije nužno načiniti kod retroaktivnog testiranja prema danoj regulativi, no može se provesti kao „dodatna" provjera. Prema rezultatima u našem primjeru, povijesni model, EWMA (λ=0,94) i O-GARCH model bi prema BIS-u trebalo klasificirati u zelenu zonu, jer imaju svega 2 odstupanja (<1%), a multiplikacijski faktor koji se koristi za računanje kapitalnog zahtjeva za valutni rizik bi trebao biti 3,0. SMA model bi trebalo klasificirati u žutu zonu i njegove mjere množiti s multiplikacijskim faktorom 3,75 budući da ima 8 odstupanja. Tijekom provođenja testiranja valjanosti VaR modela može se primijeniti i dodatno testiranje koje će nam olakšati odluku o tome koji je model učinkovitiji. Jedna od funkcija, koju je uveo Lopez, a može pomoći u odabiru što točnijeg modela je **kvadratna funkcija gubitka** (*engl. Quadratic Loss Function* - ***QLF***) koja uzima u obzir veličinu gubitka koji premašuje VaR procjenu, odnosno uzima u obzir veličinu samog odstupanja. Lopez (1999) je utvrdio da korištenje dodatne informacije povezane s veličinom odstupanja daje moćniju mjeru točnosti modela nego klasično retroaktivno testiranje. Ako se uzme u obzir veličina odstupanja, primjena kvadratne funkcijske forme puno strože reagira na velika odstupanja nego linearna mjera. U Sarma et al. (2000) se navodi da kvadratna funkcija gubitka upravo odgovara ciljevima financijskih regulatora te ju radi toga naziva **regulatorna funkcija gubitka**.

Empirijsko istraživanje i rezultati

U empirijskom dijelu uspoređeno je više metodologija procjene VaR mjere, razmatran je pristup varijance-kovarijance uz korištenje modeliranja volatilnosti primjenom jednostavnog pomičnog prosjeka, eksponencijalno ponderiranog pomičnog prosjeka (EWMA) i ortogonalne GARCH metode te metodologija povijesne simulacije. Upotrebom svakog od navedenih pristupa na portfelju sastavljenom od pozicija 6 valuta u odnosu na kunu (EUR, USD, CHF, CAD, JPY, GBP) izračunate su jednodnevne VaR mjere portfelja korištenjem trogodišnjeg razdoblja podataka prinosa valuta u razdoblju od 03.01.2006. do 31.12.2008. a prognoze VaR mjere su izračunate za razdoblje od 01.01.2009. do 31.12.2009. Od navedene četiri metode mjerenja VaR-a, sve metode osim povijesne uvelike ovise o točnim matricama varijanci-kovarijanci.

Kod modeliranja volatilnosti korištenjem modela jednostavnog pomičnog prosjeka procjena varijance prinosa tečaja valute *i* dobivena je na temelju pomičnog prosjeka kvadrata prinosa tijekom razdoblja od 750 dana (tri godine):

$$\hat{\sigma}_{i,t}^2 = \sum_{j=t-750}^{t-1} \frac{r_j^2}{750}, \; i = 1,\ldots,6 \qquad (14)$$

gdje su r_t dnevni prinosi, *i* redni broj valute, a pomični prosjek se računa na podacima 750 prethodnih dnevnih prinosa. Tako se na primjer jednodnevna procjena varijance za 01.01.2009. računa kao prosjek kvadrata prinosa u 750 dana od 04.01.2006. do 31.12.2008. Korelacija prinosa tečajeva valuta dobivena je korištenjem slijedeće formule:

$$\hat{\rho}_{ij,t} = \frac{\sum_{k=T-750}^{T-1} r_{i,k} \cdot r_{j,k}}{\sqrt{\sum_{k=T-750}^{T-1} r_{i,k}^2 \sum_{k=T-750}^{T-1} r_{j,k}^2}} \quad i,j = 1,\ldots,6 \;\; i \neq j \qquad (15)$$

99%-tna VaR mjera je dobivena primjenom jednakosti:

$$VaR_{99\%} = Z(a) \cdot \hat{\sigma}_T', \qquad (16)$$

gdje je *Z(a)* odgovarajuća kritična vrijednost, odnosno odgovarajući percentil jedinične normalne distribucije, a

$$\hat{\sigma}_T' = \sqrt{p' \cdot C \cdot p}, \qquad (17)$$

gdje je *C* korelacijska matrica prinosa a *p* je vektor vrijednosti svih vrsta imovine pomnožen s korijenom pripadne varijance imovine. VaR mjera se također može dobiti primjenom slijedeće formule, što je ekvivalentno prethodnom rezultatu, a primjenjuje matricu *V* varijanci-kovarijanci prinosa imovine:

$$\hat{\sigma}_T' = \sqrt{p_1' \cdot V \cdot p_1}, \qquad (18)$$

gdje je p_1 vektor vrijednosti uložene u svaku vrstu imovine. Budući da je vrijednost VaR mjere pozitivna treba naglasiti da je na svim grafikonima u nastavku prikazana negativna vrijednost VaR mjere kao mogući gubitak promjene vrijednosti portfelja.

U nastavku će se procijeniti točnost svih analiziranih VaR metoda prognoziranja gubitaka u portfelju. Na grafikonu 1.2.4. je prikaz izračunatih VaR mjera za svaki model uz razinu pouzdanosti od 99%. VaR mjere su dobivene korištenjem sve četiri metode SMA, EWMA, O-GARCH i povijesne metode.

Grafikon 1.2.4. VaR mjera s 99%-tnom razinom pouzdanosti i promjena vrijednosti portfelja

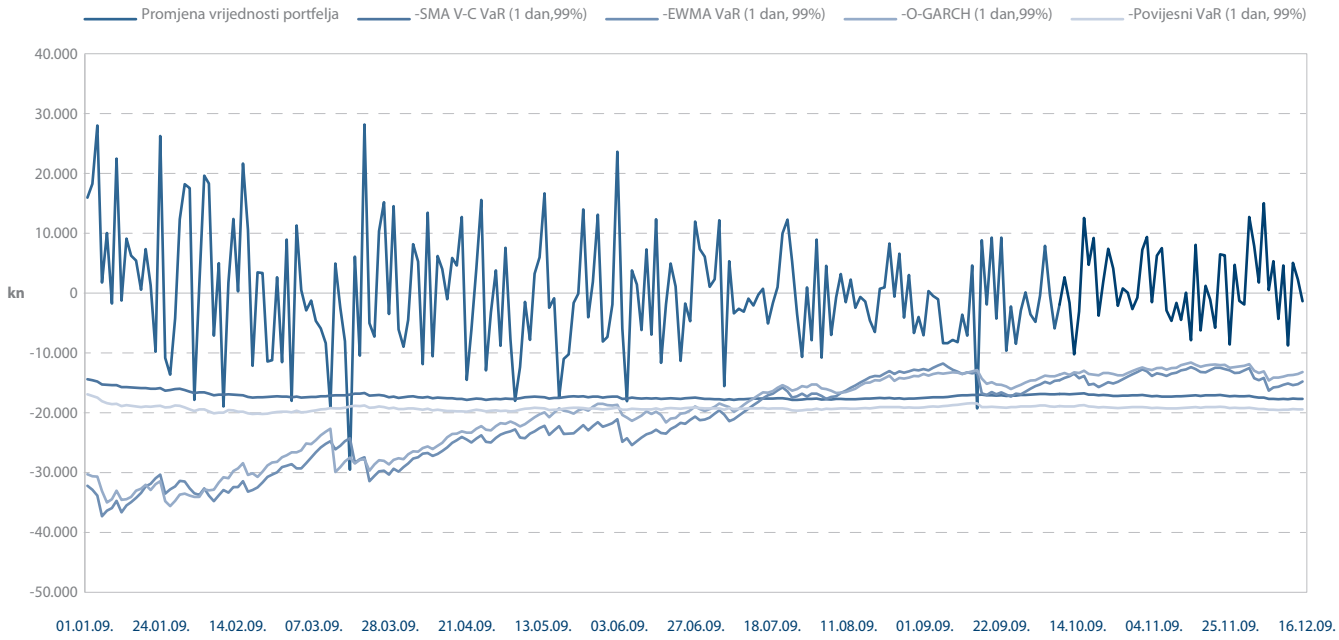

Izvor: izračun autora

Analiza grafikona iznad ukazuje na to da su rezultati dobiveni EWMA i O-GARCH pristupom mnogo osjetljiviji na promjene u podacima. VaR procjene dobivene O-GARCH i EWMA pristupom su preciznije od VaR procjena dobivenih korištenjem ostalih pristupa. Uz zadanu razinu pouzdanosti od 99% SMA model „podcjenjuje" rizik, dok EWMA model u najvećoj mjeri „precjenjuje" rizik, dok ostali VaR modeli imaju rezultat vrlo blizu prosjeku svih modela. U tablicama 1.2.1. i 1.2.2. prikazani su rezultati dobiveni retroaktivnim testiranjem (BT) i korištenjem kvadratne funkcije gubitka (QLF) kod razmatranih VaR modela. Kod retroaktivnog testiranja prikazan je postotak ukupnih odstupanja VaR prognoza na razmatranom uzorku od 251 dana tijekom 2009. godine.

Tablica.1.2.1. Tablica rezultata retroaktivnog testiranja za VaR modele s razinom pouzdanosti od 99%

	SMA VaR	EWMA VaR	O-GARCH VaR	Povijesni VaR
BT za 99% VaR	3,19%	0,79%	0,79%	0,79%

Izvor: Izračun autora

Tablica 1.2.2. Tablica kvadratne funkcije gubitka za VaR modele s razinom pouzdanosti od 99%

	SMA VaR	EWMA VaR	O-GARCH VaR	Povijesni VaR
QLF za 99% VaR	0,6897	0,2535	0,1802	0,4515

Izvor: Izračun autora

Rezultati bazirani na retroaktivnom testiranju i kvadratnoj funkciji gubitka ukazuju na to da je

O-GARCH najtočniji model od sva četiri analizirana modela a i EWMA i O-GARCH pristupi rezultiraju puno konzervativnijim procjenama kapitala za valutni rizik od ostalih modela. Retroaktivno testiranje pokazuje da EWMA, O-GARCH i povijesni model imaju jednako dobre rezultate odnosno najmanji broj odstupanja (0,79% odnosno 2 odstupanja), a kvadratna funkcija gubitka ukazuje na to da su kvadrati odstupanja O-GARCH VaR mjere u odnosu na stvarnu promjenu vrijednosti portfelja po veličini najmanji. Iza O-GARCH modela slijedi EWMA model za koji kvadratna funkcija gubitka prikazuje nešto veće gubitke od O-GARCH modela, ali značajno manje nego ostali modeli. Kada se vrijednosti svih pokazatelja uzmu u obzir, rezultati upućuju na to da je O-GARCH najprikladniji model dok SMA model daje najmanje dobre rezultate.

Zaključuje se da je GARCH metodologija superiornija prema ostalim metodologijama analiziranim u radu, no EWMA i povijesna metoda također daju dobre rezultate uz nešto lošije vrijednosti kvadratne funkcije odstupanja nego što su one kod O-GARCH metode.

Ako se želi zadržati i konzervativnost i točnost, O-GARCH VaR i EWMA VaR metodologija bi trebale biti najbolji izbor. Na kraju, iz ovog razmatranja i analize primjera može se zaključiti da se O-GARCH VaR pristup pokazao kao najučinkovitiji i najtočniji model za izračun kapitalnih zahtjeva za valutni rizik u usporedbi s drugim razmatranim modelima budući da generira najtočnije prognoze, dok je SMA VaR model najmanje učinkovit model. Rezultati testiranja također mogu ovisiti o tome iz kojeg razdoblja su upotrijebljeni podaci. Treba imati na umu da svako investicijsko društvo mora samo provesti testiranje kako bi utvrdilo rezultate za vlastiti portfelj pa na temelju toga donijeti odluku o odabiru najprikladnijeg VaR modela.

Autor
Jasminka Plenković Pastuović, HANFA

LITERATURA

- Alexander, C. (2003) *Market Models: A Guide to Financial Data Sets*. 3. izd. Chichester: John Wiley and Sons Ltd.
- Alexander, C. (2002) Principal component Models for Generating Large GARCH Covariance Matrices. *Economic Notes*, 31(2), str. 337-359.
- Alexander, C. (2001) Orthogonal GARCH. U: Alexander, C., ur., *Mastering Risk Volume 2* . FT Prentice Hall. str. 21-38.
- Alexander, C. (2001). *A primer on the orthogonal GARCH model*. ISMA Centre, University of Reading. Dostupno na: http://www.carolalexander.org/publish/download/DiscussionPapers/OrthogonalGARCH_Primer.PDF
- Alexander, C. O. (2000a) Orthogonal methods for generating large positive semidefinite covariance matrices. *ISMA Centre Discussion Papers in Finance 2000-06, University of Reading, UK*
- Alexander, C., A. Chibumba (1998) Orthogonal GARCH: An Empirical Validation on Equities, Foreign-Exchange and Interest Rates. *University of Sussex, working paper*.
- Alexander, C. i Leigh, C. (1997). On the Covariance Matrices used in Value-at-Risk Models. *Journal of Derivatives* , 4(3), str. 50-62.
- Alexander, C. i Chibumba, A. (1996) Multivariate Orthogonal factor GARCH. *University of Sussex Discussion Papers in Mathematics*
- Bollerslev, T. T. (1986). Generalised Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), str. 307-327.
- Bredin, D. i Hyde S. (2002) FOREX Risk: Measurement and Evaluation using Value-at-Risk, *Financial Services Authority of Ireland, Research Technical Paper*, 6/RT/02
- Cassidy, C. i Gizycki, M. (1997). Measuring Traded Market Risk: Value-at-Risk and Backtesting Techniques. *Reserve Bank of Australia Discussion Paper,* 9708.
- Ding, Z. (1994) *Time series analysis of speculative return*. PhD thesis. San Diego: University of California.

- Engel, J. i Gizycki, M. (1999). Conservatism, Accuracy and Efficiency: Comparing Value at Risk Models. *Australian Prudential Regulatory Authority Discussion Paper(2)*.
- Hull, J. (2002) *Option, Futures and Other Derivatives*. 5. izd. New Jersey: Prentice Hall
- Gizycki, M. i Hereford, N. (1998) Assessing the Dispersion in Banks' Estimates of Market Risk: The Results of a Value-at-Risk Survey. *Australian Prudential Regulatory Authority Discussion Paper*, (1).
- Hendricks, D. i Hirtle, B. (1997). Bank Capital Requirements for Market Risk: The Internal Models Approach, *Economic Policy Review*, Federal Reserve Bank of New York, 3 (4), str. 1 - 12.
- Hendricks, D. (1996). Evaluation of Value-at-Risk Models using Historical Data. *Economic Policy Review,* Federal Reserve Bank of New York, April, str. 39 – 69
- Jackson, P., Perraudin, W. i Maude, D. (1998) Testing Value-at-Risk Approaches to Capital Adequacy, *Bank of England Quarterly Bulletin* , 38(3), str. 256-266.
- Lopez, J. (1999) Methods for Evaluating Value-at-Risk Estimates. *Federal Reserve Bank of San Francisco Economic Review*, (2), str. 3-17.
- Morgan, J. P., Reuters (1996). *RiskMetrics, Techical Document*. 4. izdanje. Morgan Guaranty i Reuters. Dostupno na: www.riskmetrics.com
- Sarma, M., Thomas, S. i Shah, A. (2000) "Performance Evaluation of Alternative VaR Models", mimeo, *Indira Gandhi Institute of Development Research* .
- Narodne novine (2008) *Zakon o tržištu kapitala*. Zagreb: Narodne novine d.d, 88/08 i 146/08
- Narodne novine (2009) *Pravilnik o adekvatnosti kapitala investicijskih društava*. Zagreb: Narodne novine d.d, 48/09
- Narodne novine (2009) *Pravilnik o izvještavanju o adekvatnosti kapitala investicijskih društava*. Zagreb: Narodne novine d.d, 48/09

2. Otvoreni investicijski fondovi

2.1. Kvartalno kretanje otvorenih investicijskih fondova

Na kraju I. kvartala 2012. registrirana su 124 otvorena investicijska fonda (OIF) što je za 4 fonda manje u usporedbi s prethodnim kvartalom, odnosno zabilježeno je smanjenje od 3,13%. U odnosu na isto razdoblje prethodne godine, broj fondova je smanjen za 8 fondova odnosno za 6,06%. U ovom tromjesečju iz registra su brisana 3 dionička fonda, dok je 1 dionički fond pripojen mješovitom fondu istog društva. Također 1 društvo i 1 fond promijenili su naziv, a jednom društvu je oduzeta dozvola za obavljanje djelatnosti osnivanja i upravljanja investicijskim fondovima.

Tablica 2.1.1. Broj fondova prema vrsti fonda

Vrsta fonda	Broj fondova na dan 31.03.2011.	Broj fondova na dan 30.06.2011.	Broj fondova na dan 30.09.2011.	Broj fondova na dan 31.12.2011.	Broj fondova na dan 31.03.2012.	% promjena 31.03.2012./ 31.12.2011.	Godišnja promjena
Novčani	23	23	23	23	23	0,00%	0,00%
Obveznički	10	9	9	9	9	0,00%	-10,00%
Mješoviti	29	28	27	26	26	0,00%	-10,34%
Dionički	63	64	65	63	59	-6,35%	-6,35%
Fond rizičnog kapitala	7	7	7	7	7	0,00%	0,00%
UKUPNO	132	131	131	128	124	-3,13%	-6,06%

Izvor: HANFA

Otvoreni investicijski fondovi na dan 31.03.2012. ukupno broje 99 fondova s javnom ponudom, 18 fondova s privatnom ponudom te 7 fondova rizičnog kapitala.

Tablica 2.1.2. Fondovi prema vrsti ponude

OIF	JAVNA PONUDA	PRIVATNA PONUDA	PRIVATNA PONUDA RIZIČNOG KAPITALA	UKUPNO
Novčani fondovi	23			23
Obveznički fondovi	8	1		9
Mješoviti fondovi	18	8		26
Dionički fondovi	50	9		59
Fond rizičnog kapitala			7	7
SVEUKUPNO	99	18	7	124

Izvor: HANFA

Strukturu ukupnog broja OIF-a u I. kvartalu 2012. sačinjavaju:

- dionički fondovi sa 47,58%
- mješoviti fondovi sa 20,97%
- novčani fondovi sa 18,55%
- obveznički fondovi sa 7,26% i
- fondovi rizičnog kapitala sa 5, 65%.

Grafikon 2.1.1. Struktura broja fondova prema vrsti fonda u I. kvartalu 2012. godine

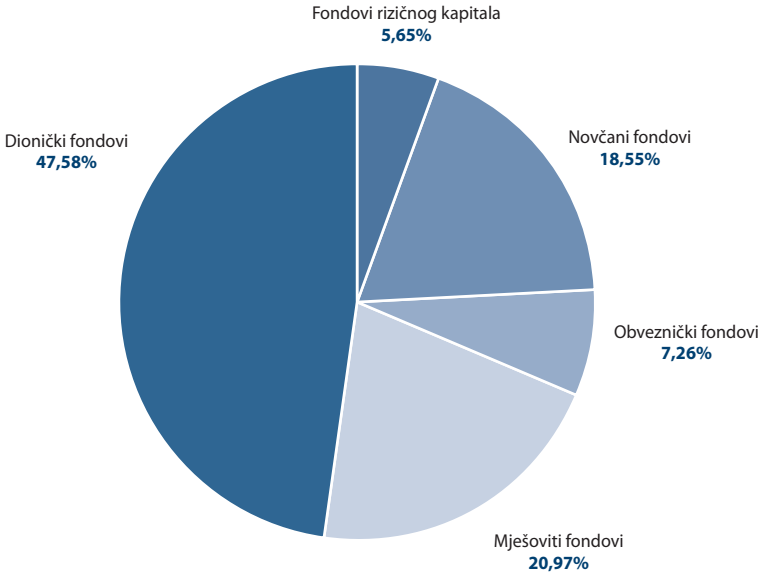

Izvor: HANFA

Ukupna neto imovina OIF-a u I. kvartalu 2012. iznosi 11,99 milijardi kuna što je za 65,53 milijuna kuna više ili 0,55% više u odnosu na IV. kvartal 2011. godine. Kvartalno kretanje neto imovine i vrijednosti udjela, te tromjesečna promjena NAV-a otvorenih investicijskih fondova po društvima i fondovima u IV. kvartalu 2011. i I. kvartalu 2012. prikazani su u sljedećoj tablici.

Tablica 2.1.3. Društva za upravljanje otvorenim investicijskim fondovima u IV. kvartalu 2011. i I. kvartalu 2012. godine

Red. br.	DRUŠTVO	FOND	VRSTA	ULAGANJE	31.12.2011. NAV	31.12.2011. UDJEL	31.03.2012. NAV	31.03.2012. UDJEL	Promjena NAV-a u %
1.	ADRIATICA CAPITAL d.o.o.	AC EXCEL	PP	D	4.094.536	303,7877	4.124.514	306,0118	0,7%
		AC Global Balanced Emerging Markets	JP	M	11.682.397	69,8170	11.176.023	72,4897	-4,3%
		AC Global Dynamic Emerging Markets	JP	D	12.600.221	70,7070	12.552.591	73,6528	-0,4%
		AC Global Utility	PP	D	10.157.858	438,6212	9.070.342	435,1249	-10,7%
		AC RUSIJA	JP	D	8.077.637	234,4792	8.992.894	254,0708	11,3%
		PROSPECTUS Jugoistočna Europa	JP	D	14.972.139	43,2600	14.044.610	44,4975	-6,2%
		Ukupno			**61.584.788**		**59.960.974**		**-2,6%**
2.	AGRAM INVEST d.d.	AGRAM Cash	JP	N	25.244.565	11,7075	23.071.275	10,6996	-8,6%
		AGRAM EURO CASH	JP	N	71.729.119	82,9609	66.852.025	83,5165	-6,8%
		AGRAM PRIVATE	PP	D	60.261.641	7175,8319	62.190.063	7405,4644	3,2%
		AGRAM SKAUT	JP	D					
		AGRAM TRUST	JP	M	15.517.472	62,2994	15.562.693	63,1912	0,3%
		Ukupno			**172.752.797**		**167.676.057**		**-2,9%**
3.	ALLIANZ INVEST d.o.o.	Allianz Cash	JP	N	190.182.632	111,4799	173.678.015	112,4817	-8,7%
		Allianz Equity	JP	D			7.172.790	787,5627	
		Allianz Portfolio	JP	M	7.542.377	110,1281	7.511.411	114,5159	-0,4%
		Ukupno			**197.725.009**		**188.362.216**		**-4,7%**
4.	ALTERNATIVE INVEST d.o.o.	A1	JP	D	6.051.271	70,9732	6.552.144	79,6503	8,3%
		AP1	PP	M	5.018.835	93,3649			
		AP2	PP	D	4.193.032	86,5901	3.640.669	99,0353	-13,2%
		Ukupno			**15.263.139**		**10.192.813**		**-33,2%**
5.	AUCTOR INVEST d.o.o.	Certus Cash	JP	N	5.113.052	101,6609	11.206.669	102,4870	119,2%
		Ukupno			**5.113.052**		**11.206.669**		**119,2%**
6.	CEBA INVEST d.o.o.	C PREMIUM	JP	M	9.923.949	5,1264	9.147.338	4,7960	-7,8%
		C Zenit	JP	D	5.211.475	44,7529	5.186.845	44,5413	-0,5%
		Ukupno			**15.135.424**		**14.334.184**		**-5,3%**
7.	ERSTE - INVEST d.o.o.	Erste Adriatic Equity	JP	D	169.690.717	555,5571	166.928.080	569,2260	-1,6%
		Erste Aggressive	JP	D					
		Erste Balanced	JP	M	81.890.516	817,5892	75.704.334	828,4671	-7,6%
		Erste Bond	JP	O	272.256.359	994,0614	107.195.298	992,4440	-60,6%
		Erste Elite	PP	M	14.324.416	829,9383	5.658.147	818,3808	-60,5%
		Erste Euro - Money	JP	N	482.403.673	817,8347	394.145.633	821,5473	-18,3%
		Erste Exclusive	PP	M	17.527.055	846,5029	18.208.139	879,3971	3,9%
		Erste Moderate	JP	M					
		Erste Money	JP	N	691.582.118	142,0098	656.604.093	143,1762	-5,1%
		Erste TOTAL EAST	JP	D	77.489.001	204,5887	49.573.982	206,6086	-36,0%
		Ukupno			**1.807.163.856**		**1.474.017.703**		**-18,4%**
8.	FIMA GLOBAL INVEST d.o.o.	FIMA Equity	JP	D	14.728.435	67,0199	14.374.536	65,0035	-2,4%
		Ukupno			**14.728.435**		**14.374.536**		**-2,4%**
9.	HPB-INVEST d.o.o.	HPB Dionički	JP	D	18.661.235	79,2128	19.273.135	83,3633	3,3%
		HPB Dynamic	JP	D	13.367.064	42,9130	11.318.273	41,2580	-15,3%
		HPB Euronovčani	JP	N	6.263.043	754,6685	6.160.428	759,6461	-1,6%
		HPB Global	JP	M	76.223.756	90,0595	58.006.238	89,0223	-23,9%
		HPB Novčani	JP	N	156.520.807	135,5136	295.621.196	136,5659	88,9%
		HPB Obveznički	JP	O	19.776.544	941,8535	19.732.973	966,5268	-0,2%
		HPB Titan	JP	D	5.698.496	476,6915	5.257.171	512,5100	-7,7%
		HPB World Absolute Value - DJE	JP	D	11.645.816	655,4442	13.035.143	718,2334	11,9%
		Ukupno			**308.156.761**		**428.404.556**		**39,0%**

Red. br.	DRUŠTVO	FOND	VRSTA	ULAGANJE	31.12.2011. NAV	31.12.2011. UDJEL	31.03.2012. NAV	31.03.2012. UDJEL	Promjena NAV-a u %
10.	HYPO-ALPE-ADRIA INVEST d.d.	Hi-balanced	JP	M	53.895.875	72,9012	56.864.193	76,1931	5,5%
		Hi-cash	JP	N	159.159.885	142,4724	150.854.128	143,4190	-5,2%
		Hi-conservative	JP	O	7.716.294	85,1007	7.892.912	87,4526	2,3%
		Hi-growth	JP	D	43.565.607	59,6121	45.626.236	63,1913	4,7%
		Ukupno			**264.337.661**		**261.237.469**		**-1,2%**
11.	ICAM d.o.o.	Capital One	JP	O	17.709.969	16571,9746	15.609.842	16974,4448	-11,9%
		Capital Two	JP	D	6.380.694	6224,5091	6.485.647	6493,1651	1,6%
		EQUINOX 1	PP	M	10.559.333	1,0019	10.155.588	1,0416	-3,8%
		EQUINOX 2	PP	M	5.074.371	0,6528	4.533.756	0,5833	-10,7%
		EQUINOX 3	PP	M	4.202.304	0,9483	4.233.569	0,9553	0,7%
		Hermes	PP	O	90.969.228	8,6476	92.168.020	8,7616	1,3%
		KWSO Capital Flex	PP	M	11.381.893	0,9807	11.641.618	1,0031	2,3%
		Ukupno			**146.277.792**		**144.828.041**		**-1,0%**
12.	ILIRIKA INVESTMENTS d.o.o.	Ilirika Azijski Tigar	JP	D	4.303.867	338,8155	4.379.627	347,3524	1,8%
		ILIRIKA BRIC	JP	D	14.172.636	625,4788	13.301.009	646,8354	-6,2%
		Ilirika Euro Cash	JP	N					
		Ilirika Gold	JP	D	4.813.551	660,1493	4.657.925	650,4669	-3,2%
		Ilirika Indija	JP	D					
		Ilirika Jugoistočna Europa	JP	D	58.075.947	901,7188	57.575.023	973,4525	-0,9%
		Ukupno			**81.366.001**		**79.913.583**		**-1,8%**
13.	KD INVESTMENTS d.o.o.	KD Balanced	JP	M	5.426.805	7,4494	5.701.723	8,0397	5,1%
		KD Energija	JP	D	8.506.208	9,3746	9.271.387	9,6236	9,0%
		KD Nova Europa	JP	D	15.725.767	5,6878	17.344.757	6,3964	10,3%
		KD Prvi izbor	JP	D	5.357.990	10,7559	5.808.508	11,4452	8,4%
		KD Victoria	JP	D	49.034.232	11,4757	54.842.628	13,0044	11,8%
		Ukupno			**84.051.002**		**92.969.003**		**10,6%**
14.	LOCUSTA INVEST d.o.o.	ICF Balanced	JP	M	12.525.921	108,7982	14.397.298	113,9270	14,9%
		Locusta West	JP	D					
		Locusta Cash	JP	N	116.775.618	1217,3890	109.082.169	1229,1797	-6,6%
		Locusta Value I	PP	D	24.715.607	874,7703	24.945.305	878,6501	0,9%
		Locusta Value II	PP	D	39.701.897	914,3216	39.511.203	909,9300	-0,5%
		Locusta Value III	PP	D	5.167.663	587,3265	6.017.536	683,9181	16,4%
		Ukupno			**198.886.706**		**193.953.510**		**-2,5%**
15.	NFD AUREUS INVEST d.d.	MP-BALKAN.HR	JP	D					
		NFD Aureus BRIC	JP	D	10.040.576	165,1253	9.566.301	175,5911	-4,7%
		NFD Aureus Emerging Markets Balanced	JP	M	12.052.158	76,0470	10.686.344	75,6556	-11,3%
		NFD Aureus Global Developed	JP	D	47.708.781	86,5689	47.557.857	90,0084	-0,3%
		NFD Aureus Mena	JP	D	6.289.542	449,0082	5.071.934	477,2921	-19,4%
		NFD Aureus MultiCash	JP	N	249.888	99,9554	6.461.172	100,1214	2485,6%
		NFD Aureus New Europe	JP	D	11.073.060	81,3705	9.305.899	91,9402	-16,0%
		NFD Aureus Private Fond	PP	D	31.114.415	55,8198	25.284.955	53,3964	-18,7%
		NFD Aureus US Algorithm	JP	D	20.100.661	119,9551	17.233.339	132,8105	-14,3%
		Ukupno			**138.629.080**		**131.167.800**		**-5,4%**
16.	OTP INVEST d.o.o.	OTP Ekspand	JP	D					
		OTP euro obveznički	JP	O	12.655.590	816,3829	12.152.589	843,5864	-4,0%
		OTP Europa Plus	JP	D	8.736.608	734,0087	8.257.625	740,8389	-5,5%
		OTP INDEKSNI FOND	JP	D	101.449.749	35,2126	109.351.245	37,0278	7,8%
		OTP MERIDIAN 20	JP	D	9.388.888	528,4792	9.660.244	571,9441	2,9%
		OTP novčani	JP	N	216.083.535	125,5126	223.826.631	126,5423	3,6%
		OTP uravnoteženi	JP	M	27.677.784	89,9018	27.602.503	93,3490	-0,3%
		Ukupno			**375.992.155**		**390.850.837**		**4,0%**

Red. br.	DRUŠTVO	FOND	VRSTA	ULAGANJE	31.12.2011. NAV	31.12.2011. UDJEL	31.03.2012. NAV	31.03.2012. UDJEL	Promjena NAV-a u %
17.	PBZ INVEST d.o.o.	PBZ Bond	JP	O	87.502.774	982,4894	79.449.455	1006,2873	-9,2%
		PBZ Dollar	JP	N	42.592.384	733,7232	35.576.844	712,6089	-16,5%
		PBZ Equity	JP	D	216.102.899	66,2471	226.333.724	69,3753	4,7%
		PBZ Euro novčani	JP	N	296.293.927	972,0778	288.400.886	977,1127	-2,7%
		PBZ Global	JP	M	229.759.921	94,2312	224.726.003	97,7472	-2,2%
		PBZ I-Stock fond	JP	D	156.564.845	57,3121	162.336.895	62,6586	3,7%
		PBZ Novčani	JP	N	951.326.788	135,3624	1.063.673.339	136,4564	11,8%
		Ukupno			**1.980.143.538**		**2.080.497.146**		**5,1%**
18.	PLATINUM INVEST d.o.o.	Platinum Blue Chip	JP	D	7.959.540	616,2402	8.770.165	643,6035	10,2%
		PLATINUM CASH	JP	N	5.209.558	82,6024	5.146.558	81,6034	-1,2%
		Platinum Global Opportunity	JP	D	6.936.810	64,1562	8.606.795	70,5466	24,1%
		Ukupno			**20.105.909**		**22.523.518**		**12,0%**
19.	POBA ICO INVEST d.o.o.	POBA ICO Equity	JP	D	4.371.596	4852,0212			
		Ukupno			**4.371.596**				
20.	RAIFFEISEN INVEST d.o.o.	Raiffeisen Balanced	JP	M	223.330.336	944,3704	224.741.649	1010,5098	0,6%
		Raiffeisen Bonds	JP	O	175.943.407	1323,7353	160.649.717	1336,1576	-8,7%
		Raiffeisen Cash	JP	N	857.212.935	148,8443	909.249.198	150,0965	6,1%
		Raiffeisen Central Europe	JP	D	112.769.596	332,7201	112.256.299	367,8158	-0,5%
		Raiffeisen euroCash	JP	N	110.368.879	758,6436	104.152.870	762,3889	-5,6%
		Raiffeisen Prestige	JP	M	40.849.753	750,8995	37.571.650	801,3985	-8,0%
		Raiffeisen Prestige Equity	JP	D	24.985.866	751,6192	26.363.913	766,5614	5,5%
		Raiffeisen World	JP	D	35.709.062	778,2799	35.135.138	822,7132	-1,6%
		RF Advantage	PP	M	11.129.347	359,9174	11.665.556	377,2582	4,8%
		Ukupno			**1.592.299.181**		**1.621.785.990**		**1,9%**
21.	ST INVEST d.o.o.	ST Balanced	JP	M	11.726.776	127,5811	12.213.315	132,6943	4,1%
		ST Cash	JP	N	29.385.887	139,4359	18.612.952	141,0971	-36,7%
		ST Global Equity	JP	D	5.608.729	27,1491	6.280.857	30,3401	12,0%
		Ukupno			**46.721.393**		**37.107.124**		**-20,6%**
22.	VB INVEST d.o.o.	VB CASH	JP	N	211.751.005	119,0057	185.629.592	120,1088	-12,3%
		VB Crobex10	JP	D	6.060.034	89,0036	6.084.504	91,4158	0,4%
		VB HIGH EQUITY	JP	D	10.332.502	44,4616			
		VB Smart	JP	M	14.242.557	699,8120	25.267.126	712,5772	77,4%
		Ukupno			**242.386.099**		**216.981.222**		**-10,5%**
23.	ZB INVEST d.o.o.	ZB aktiv	JP	D	359.441.408	88,4144	352.153.945	90,9952	-2,0%
		ZB bond	JP	O	129.859.971	1224,8812	132.333.705	1243,0765	1,9%
		ZB BRIC+	JP	D	110.424.479	673,0734	118.232.758	701,0839	7,1%
		ZB euroaktiv	JP	D	212.320.640	745,0061	226.101.501	804,6550	6,5%
		ZB europlus	JP	N	136.408.784	1074,9392	122.838.993	1079,3906	-9,9%
		ZB global	JP	M	527.287.642	954,4995	504.802.076	987,5331	-4,3%
		ZB plus	JP	N	2.478.163.990	166,8107	2.691.371.770	168,3003	8,6%
		ZB Private East	PP	D	88.596.629	55,6899	90.489.790	56,8799	2,1%
		ZB trend	JP	D	113.200.085	949,1695	113.760.200	979,4756	0,5%
		Ukupno			**4.155.703.627**		**4.352.084.738**		**4,7%**
SVEUKUPNO					11.928.895.000		11.994.429.688		0,5%

Izvor: HANFA

Neto imovina OIF-a s javnom ponudom na dan 31.03.2012. iznosi 11.57 milijardi kuna što je za 0,70% više nego prethodni kvartal odnosno 80,19 milijuna kuna više. Neto imovina s privatnom ponudom ostvarena je u visini od 423,54 milijuna kuna što je za 14,65 milijuna kuna manje nego u prethodnom kvartalu odnosno 3,34% manje.

Tablica 2.1.4. Neto imovina fondova prema vrsti fonda

Vrsta fonda	Imovina fondova na dan 31.03.2011.	Imovina fondova na dan 30.06.2011.	Imovina fondova na dan 30.09.2011.	Imovina fondova na dan 31.12.2011.	Imovina fondova na dan 31.03.2012.	% promjena 31.03.2012./ 31.12.2011.
Novčani	7.655.901.952	8.750.351.829	7.839.918.363	7.240.022.076	7.542.216.434	4,17%
Obveznički	1.545.115.743	1.754.747.253	1.289.081.604	814.390.136	627.184.511	-22,99%
Mješoviti	2.171.698.285	2.062.726.288	1.606.816.636	1.440.773.549	1.387.778.290	-3,68%
Dionički	3.433.000.774	3.300.381.466	2.661.855.307	2.433.709.239	2.437.250.453	0,15%
UKUPNO	14.805.716.753	15.868.206.835	13.397.671.910	11.928.895.000	11.994.429.688	0,55%

Izvor: HANFA

U I. kvartalu 2012. promatrano po vrsti fonda; neto imovina zabilježila je rast kod novčanih i dioničkih fondova, dok su negativne stope rasta kod obveznickih i mješovitih fondova. Pad neto imovine od 22,99% zabilježili su obveznički fondovi, dok su mješoviti fondovi ostvarili pad od 3,68%. Neto imovina novčanih fondova iznosila je 7,54 milijarde kuna ili 4,17% više, dioničkih fondova 2,44 milijarde kuna ili 0,15% više, mješovitih fondova 1,39 milijardi kuna i obveznickih fondova 0,63 milijarde kuna.

Grafikon koji slijedi prikazuje kvartalno kretanje neto imovine OIF-a prema vrsti fonda u posljednjih godinu dana. Na godišnjoj razini neto imovina obveznickih fondova zabilježila je pad od 59,41%, mješovitih fondova 36,10%, dioničkih fondova 29,01%, novčanih fondova 1,48% i ukupna neto imovina OIF-a pad od 18,99%.

Grafikon 2.1.2. Neto imovina OIF-a po kvartalima prema vrsti fonda

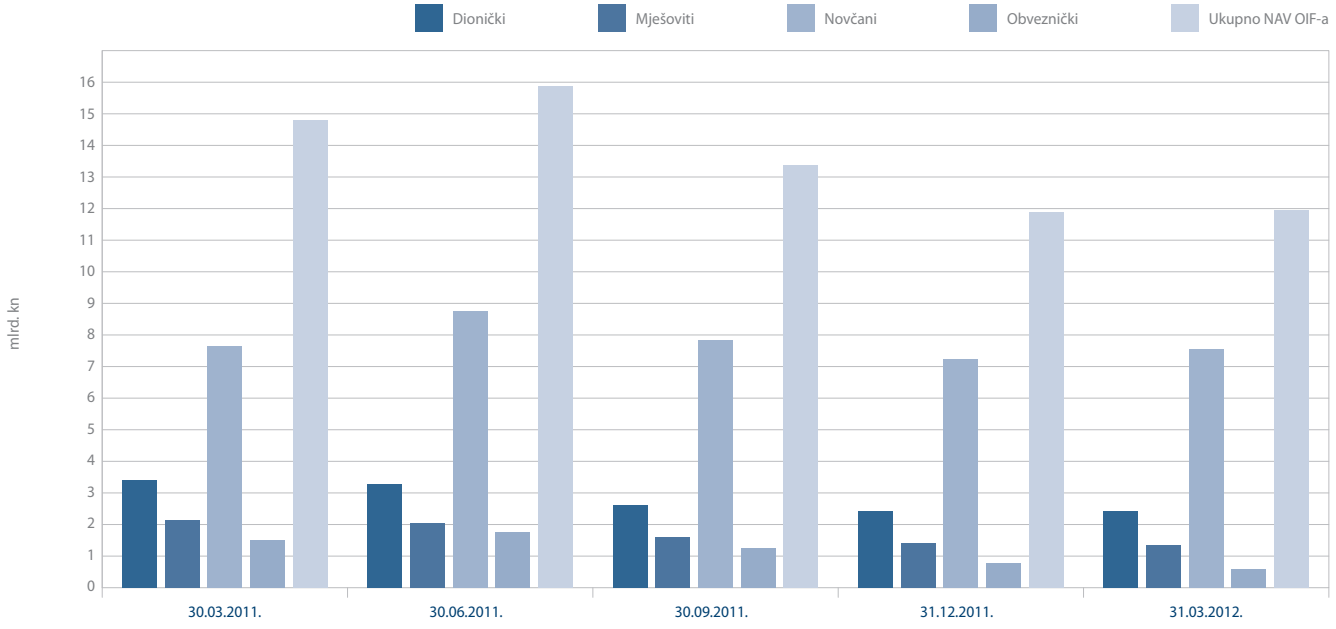

Izvor: HANFA

U I. kvartalu 2012. strukturu ukupne neto imovine otvorenih investicijskih fondova (javna i privatna ponuda) najvećim dijelom čine novčani fondovi (62,88%), zatim dionički (20,32%), mješoviti (11,57%), a najmanji udio imaju obveznički fondovi (5,23%). Kvartalno povećanje učešća u strukturi ukupne neto imovine zabilježili su samo novčani fondovi za 2,19 postotnih poena, dok su obveznički fondovi ostvarili smanjenje za 1,60 postotnih poena, mješoviti fondovi smanjenje za 0,51 postotni poen i dionički fondovi za 0,08 postotnih poena.

Tablica 2.1.5. Struktura neto imovine OIF-a po kvartalima i vrsti fonda u posljednjih godinu dana

Vrsta fonda	NAV - učešće fondova u % na dan 31.03.2011.	NAV - učešće fondova u % na dan 30.06.2011.	NAV - učešće fondova u % na dan 30.09.2011.	NAV - učešće fondova u % na dan 31.12.2011.	NAV - učešće fondova u % na dan 31.03.2012.
Novčani fondovi	51,71%	55,14%	58,52%	60,69%	62,88%
Obveznički fondovi	10,44%	11,06%	9,62%	6,83%	5,23%
Mješoviti fondovi	14,67%	13,00%	11,99%	12,08%	11,57%
Dionički fondovi	23,19%	20,80%	19,87%	20,40%	20,32%
UKUPNO	100,00%	100,00%	100,00%	100,00%	100,00%

Izvor: HANFA

Grafikon 2.1.3. Udio OIF-a u strukturi neto imovine u I. kvartalu 2012. godine

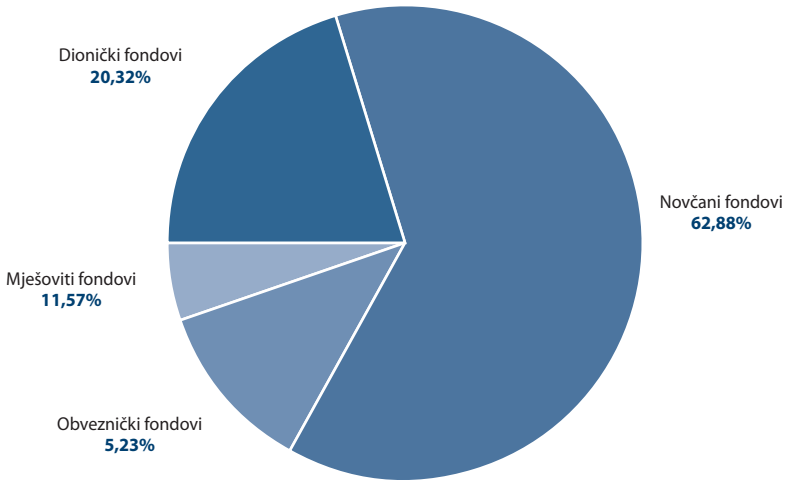

Izvor: HANFA

Tablica 2.1.6. Promjena NAV-a otvorenih investicijskih fondova po društvima u I. kvartalu 2012. i udio u ukupnoj neto imovini po kvartalima

Red. br.	DRUŠTVO	31.12.2011.		31.03.2012.		Promjena NAV-a u %
		NAV	Učešće u %	NAV	Učešće u %	
1	ADRIATICA CAPITAL d.o.o.	61.584.788	0,52%	59.960.974	0,50%	-2,64%
2	AGRAM INVEST d.d.	172.752.797	1,45%	167.676.057	1,40%	-2,94%
3	ALLIANZ INVEST d.o.o.	197.725.009	1,66%	188.362.216	1,57%	-4,74%
4	ALTERNATIVE INVEST d.o.o.	15.263.139	0,13%	10.192.813	0,08%	-33,22%
5	AUCTOR INVEST d.o.o.	5.113.052	0,04%	11.206.669	0,09%	119,18%
6	CEBA INVEST d.o.o.	15.135.424	0,13%	14.334.184	0,12%	-5,29%
7	ERSTE - INVEST d.o.o.	1.807.163.856	15,15%	1.474.017.703	12,29%	-18,43%
8	FIMA GLOBAL INVEST d.o.o.	14.728.435	0,12%	14.374.536	0,12%	-2,40%
9	HPB-INVEST d.o.o.	308.156.761	2,58%	428.404.556	3,57%	39,02%
10	HYPO-ALPE-ADRIA INVEST d.d.	264.337.661	2,22%	261.237.469	2,18%	-1,17%
11	ICAM d.o.o.	146.277.792	1,23%	144.828.041	1,21%	-0,99%
12	ILIRIKA INVESTMENTS d.o.o.	81.366.001	0,68%	79.913.583	0,67%	-1,79%
13	KD INVESTMENTS d.o.o.	84.051.002	0,70%	92.969.003	0,78%	10,61%
14	LOCUSTA INVEST d.o.o.	198.886.706	1,67%	193.953.510	1,62%	-2,48%
15	NFD AUREUS INVEST d.d.	138.629.080	1,16%	131.167.800	1,09%	-5,38%
16	OTP INVEST d.o.o.	375.992.155	3,15%	390.850.837	3,26%	3,95%
17	PBZ INVEST d.o.o.	1.980.143.538	16,60%	2.080.497.146	17,35%	5,07%
18	PLATINUM INVEST d.o.o.	20.105.909	0,17%	22.523.518	0,19%	12,02%
19	POBA ICO INVEST d.o.o.	4.371.596	0,04%	0	0,00%	-100,00%
20	RAIFFEISEN INVEST d.o.o.	1.592.299.181	13,35%	1.621.785.990	13,52%	1,85%
21	ST INVEST d.o.o.	46.721.393	0,39%	37.107.124	0,31%	-20,58%
22	VB INVEST d.o.o.	242.386.099	2,03%	216.981.222	1,81%	-10,48%
23	ZB INVEST d.o.o.	4.155.703.627	34,84%	4.352.084.738	36,28%	4,73%
UKUPNO		11.928.895.000	100,00%	11.994.429.688	100,00%	0,55%

Izvor: HANFA

U I. kvartalu 2012. kod 8 društava za upravljanje otvorenim investicijskim fondovima zabilježeno je povećanje neto imovine fondova. Kvartalne promjene ukupne neto imovine fondova kretale su se u rasponu od -33,22% do 119,18,%. Promatramo li udio pojedinih društava za upravljanje otvorenim investicijskim fondovima u ukupnoj neto imovini OIF-a u I. kvartalu 2012. uočavamo da neto imovina fondova 6 društava sačinjava 86,27% ukupne neto imovine svih fondova. Najveću zastupljenost među njima od 36,28% ukupne neto imovine i dalje ima ZB INVEST d.o.o.. Ukupna neto imovina fondova ovih 6 društava iznosi 10,35 milijardi kuna, dok NAV ostalih 16 društva iznosi 1,65 milijardi kuna ili 13,73% ukupne neto imovine. Kod ostalih društava pojedinačno učešće u ukupnoj neto imovini kreće se u rasponu od 0,08% do 2,18%.

Grafikon 2.1.4. Udio u neto imovini OIF-a po društvima u I. kvartalu 2012. godine

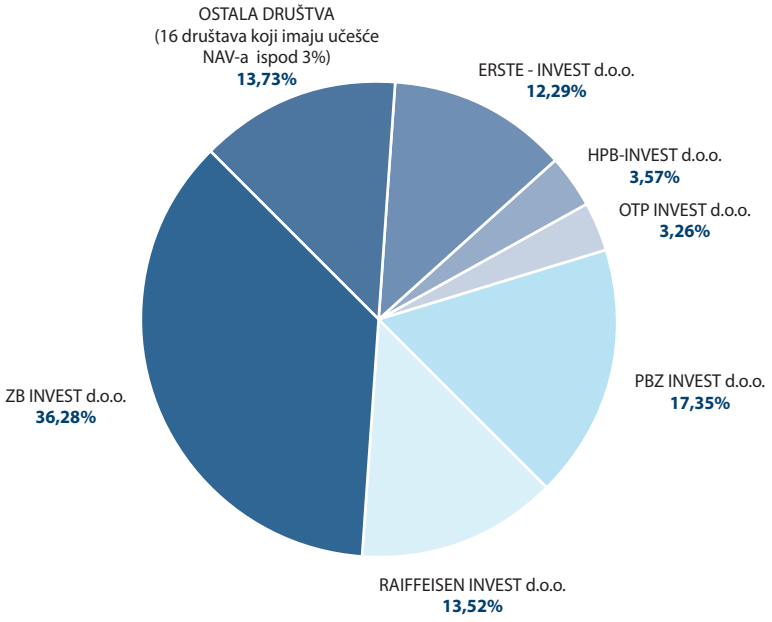

Izvor: HANFA

2.2. Analiza distribucije promjene neto imovine i vrijednosti udjela otvorenih investicijskih fondova

Na osnovi usporedbe vrijednosti neto imovine i vrijednosti udjela otvorenih investicijskih fondova u I. kvartalu 2012. u odnosu na IV. kvartal 2011., sukladno vrsti fonda, konstruirana su četiri grafikona i to za: novčane, obvezničke, mješovite i dioničke fondove.

2.2.1. Novčani fondovi

Od 23 novčana fonda 2 fonda nisu obuhvaćena analizom jer jedan fond ima izrazito visok rast neto imovine (2485,62%) dok drugi fond je počeo s radom u 2012. godini.

Šest novčanih OIF-a zabilježilo je prosječno povećanje neto imovine od 39,69% i povećanje vrijednosti udjela od 0,83%, dvanaest fondova je ostvarilo pad neto imovine od 9,96% i rast vrijednosti udjela od 0,72%, dok su tri fonda poslovala s prosječnim padom neto imovine od 8,76%, i s prosječnim padom vrijednosti udjela od 4,23%.

U prosjeku 21 novčani fond zabilježio je prosječan rast neto imovine od 4,40% i prosječan rast vrijednosti udjela od 0,04%.

Grafikon 2.2.1. Distribucija promjene neto imovine i vrijednosti udjela novčanih OIF-a u I. kvartalu 2012. godine

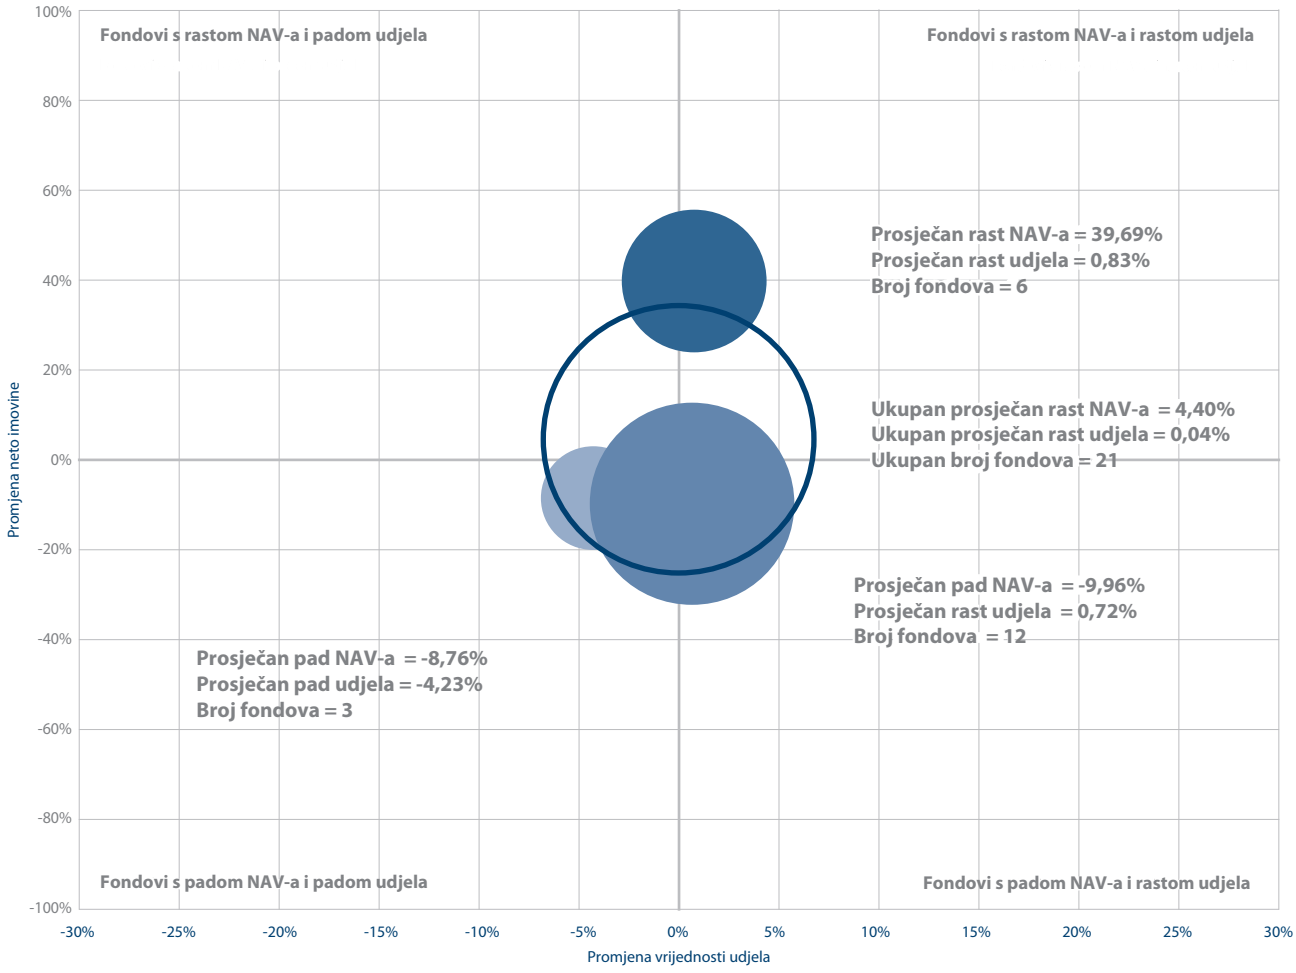

Izvor: HANFA

2.2.2. Obveznički fondovi

Devet obveznickih fondova zajedno je poslovalo s prosječnim padom neto imovine od 9,90%, ali s prosječnim rastom vrijednosti udjela od 1,91%. Tri fonda ostvarila su prosječan rast neto imovine od 1,84% i prosječan rast vrijednosti udjela od 1,86%. Pet fondova ostvarili su prosječan pad neto imovine od 6,79% i prosječan rast vrijednosti udjela od 2,35 %, dok je jedan fonda zabilježio prosječan pad neto imovine od 60,63% i prosječan pad vrijednosti udjela od 0,16%.

Grafikon 2.2.2. Distribucija promjene neto imovine i vrijednosti udjela obveznickih OIF-a u I. kvartalu 2012. godine

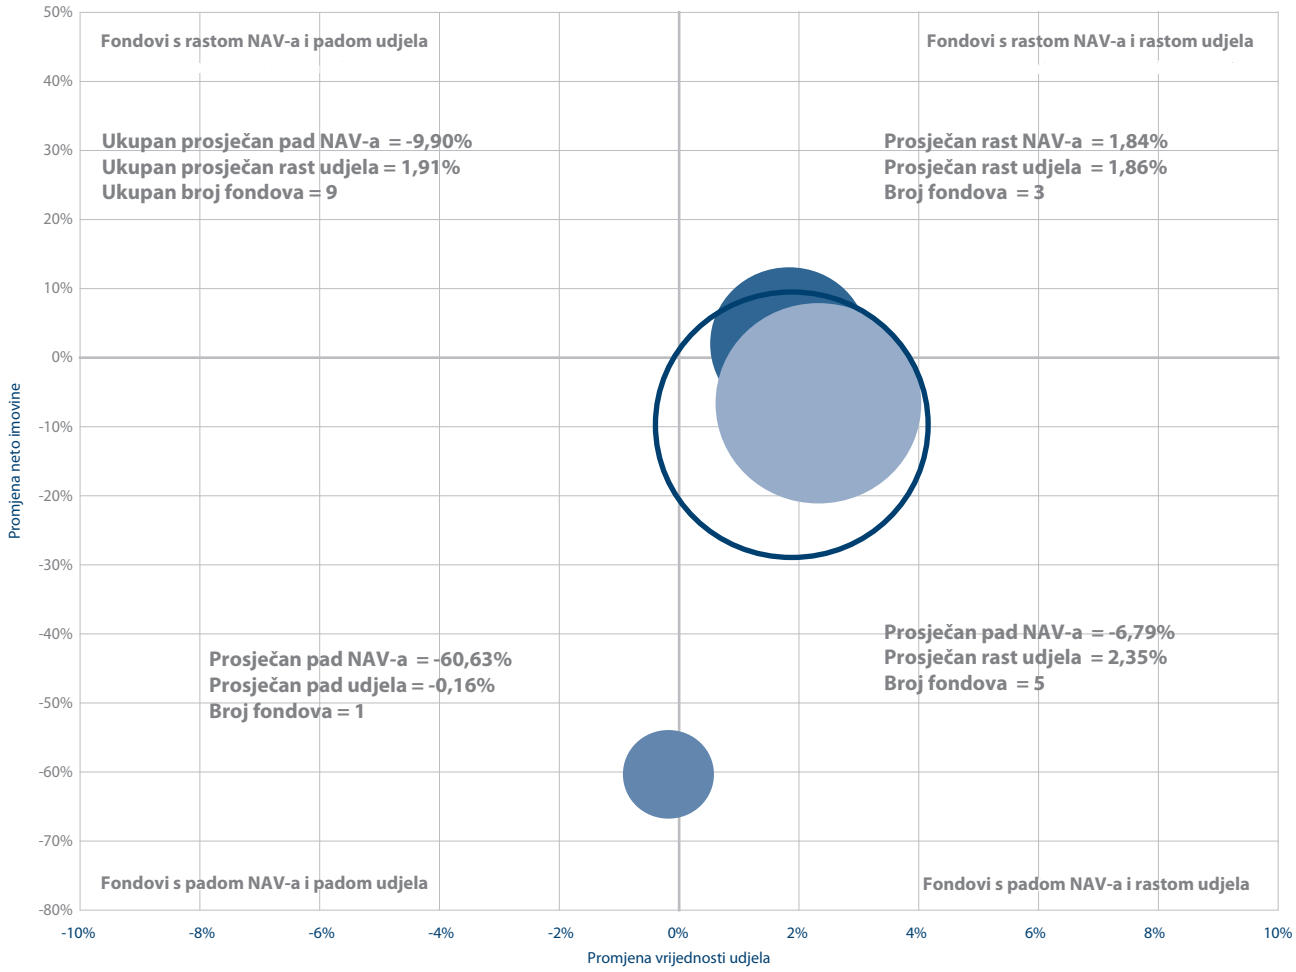

Izvor: HANFA

2.2.3. Mješoviti fondovi

Od ukupno 26 mješovitih fondova analizirano ih je 24, jer jedan fond još nije počeo s radom, dok kod jednog fonda su povučeni svi udjeli. Mješoviti fondovi ukupno su zabilježili prosječan pad neto imovine od 1,06%, ali prosječno povećanje vrijednosti udjela od 2,24% u odnosu na protekli kvartal.

Jedanaest fondova ostvarilo je prosječan rast neto imovine od 10,88% i prosječan rast vrijednosti udjela od 3,92%. Pet fondova ostvarilo je prosječan pad neto imovine od 22,84% i pad vrijednosti udjela od 4,03%. Prosječan pad neto imovine od 3,86% i prosječan rast vrijednosti udjela od 3,86% ostvarilo je osam mješovitih fondova.

Grafikon 2.2.3. Distribucija promjene neto imovine i vrijednosti udjela mješovitih OIF-a u I. kvartalu 2012. godine

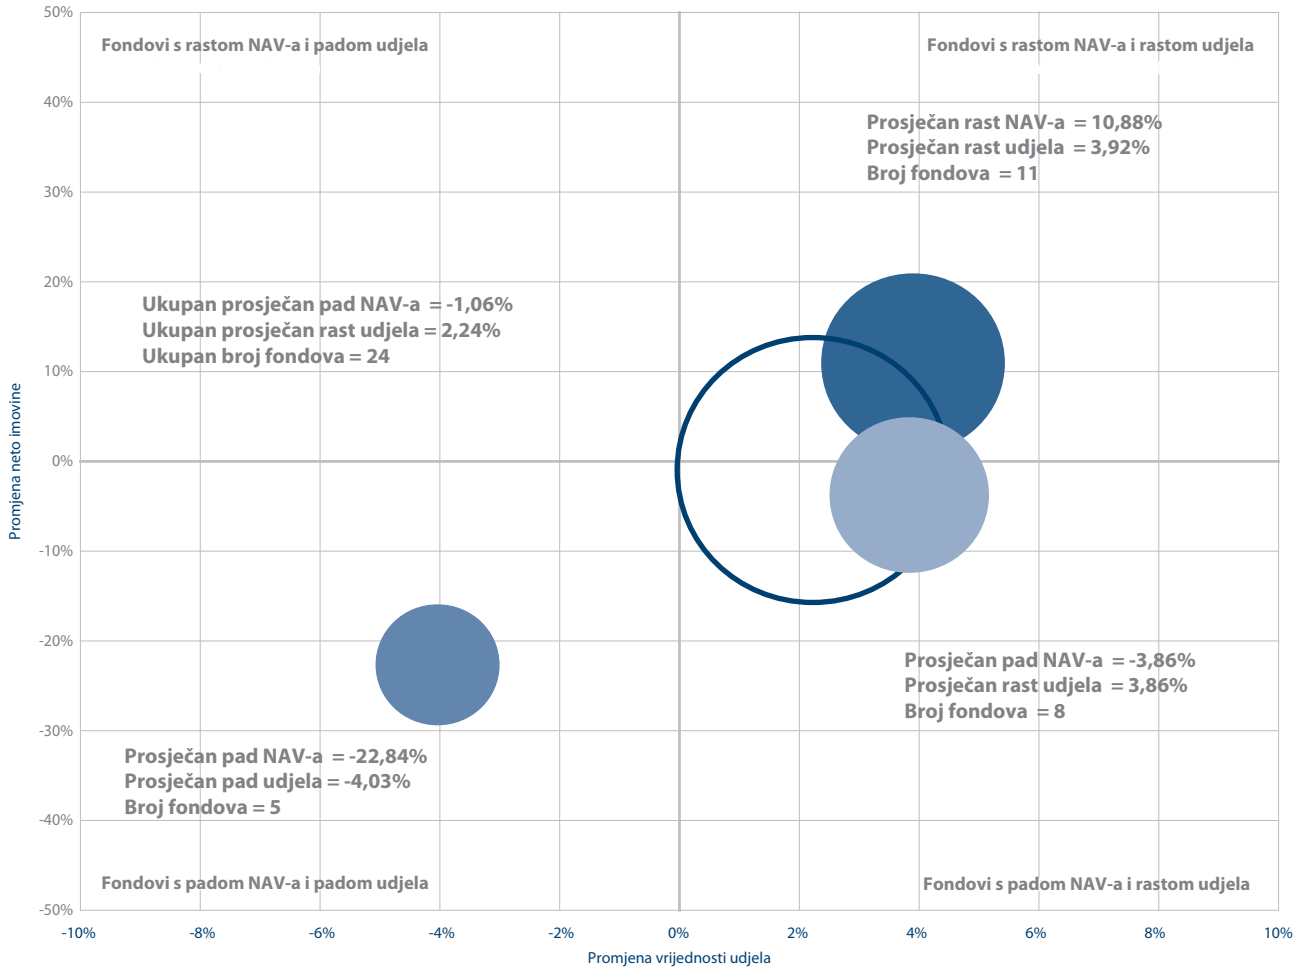

Izvor: HANFA

2.2.4. Dionički fondovi

Od ukupno 59 dioničkih fondova analizirano je 52, jer sedam fondova još nije počelo s radom. Ukupno 52 dionička fonda zabilježili su prosječan rast neto imovine od 0,07% i prosječan rast vrijednosti udjela od 5,18%. Prosječan rast neto imovine od 6,83% i prosječan rast vrijednosti udjela od 6,42% ostvarilo je 28 fondova. Prosječan pad neto imovine od 8,02% i prosječan rast vrijednosti udjela od 6,13% ostvarilo je 17 fondova. Sedam fondova poslovalo je s prosječnim padom neto imovine od 7,34% i prosječnim padom vrijednosti udjela od 2,06%.

Grafikon 2.2.4. Distribucija promjene neto imovine i vrijednosti udjela dioničkih OIF-a u I. kvartalu 2012. godine

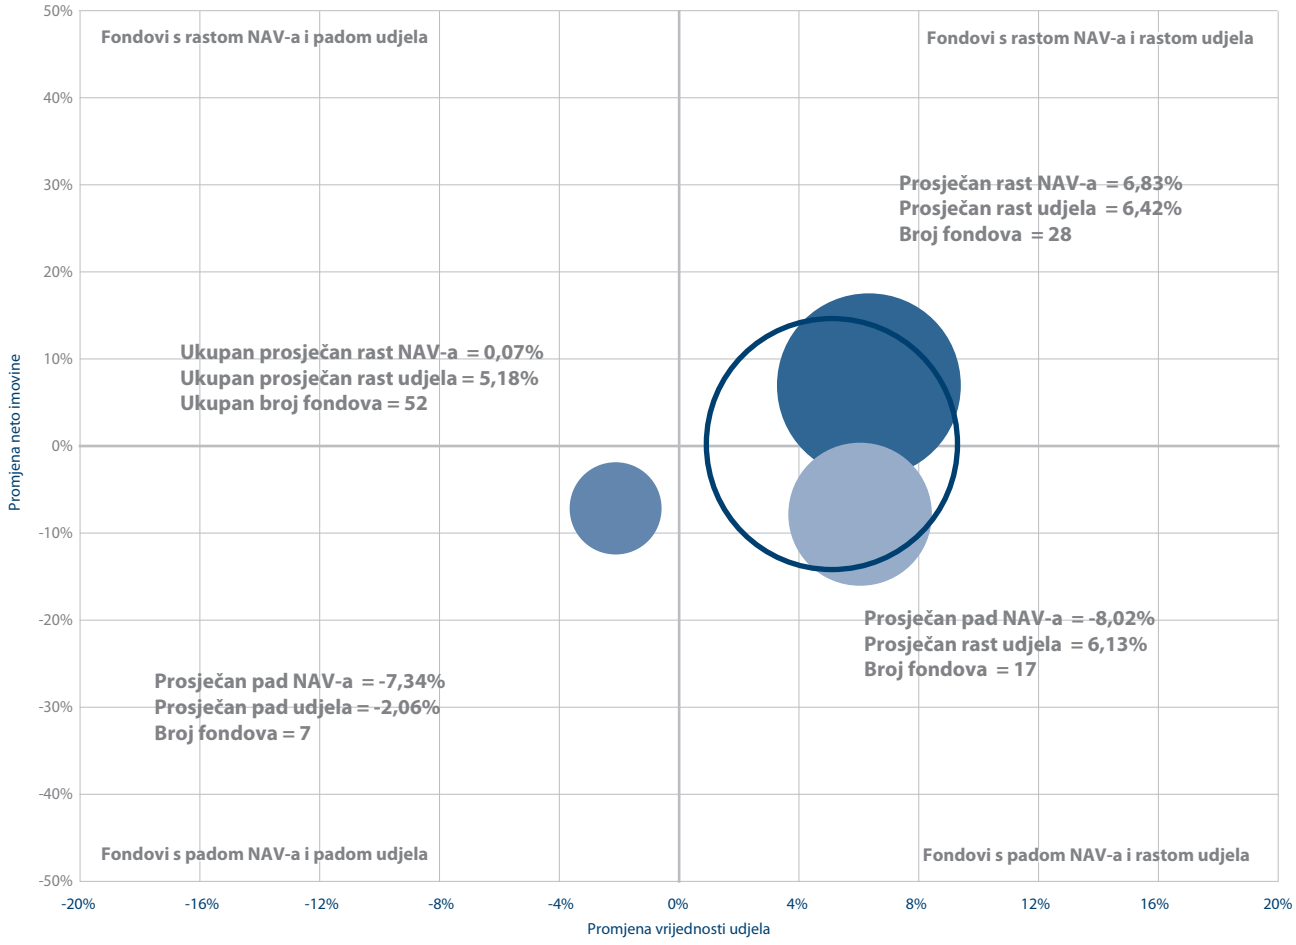

Izvor: HANFA

2.3. Struktura udjelničara otvorenih investicijskih fondova s javnom ponudom

Od 11,57 milijardi kuna imovine investicijskih fondova s javnom ponudom 31. ožujka 2012. 6,24 milijarde kuna ili 53,9% odnosilo se na imovinu fizičkih osoba, a 5,33 milijarde kuna ili 46,1% na imovinu pravnih osoba. Među pravnim osobama najveća je imovina ostalih pravnih osoba s udjelom u imovini investicijskih fondova s javnom ponudom od 14,1%, a za njima slijede osiguravajuća društva s udjelom od 11,6%.

Grafikon 2.3.1. Udjeli imovine pojedine kategorije udjelničara

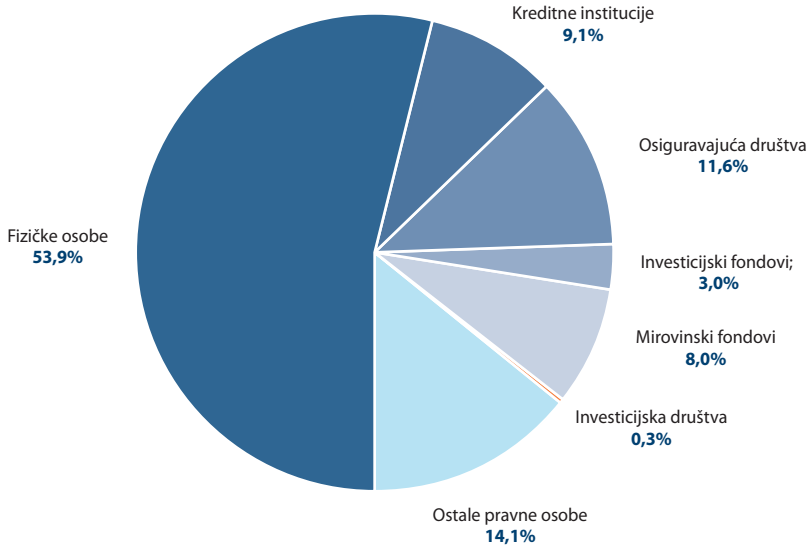

Izvor: HANFA

Raspodjela imovine pojedine kategorije udjelničara prema vrstama fondova prikazana je u tablici 2.3.1.

Tablica 2.3.1. Neto imovina prema kategorijama udjelničara i vrsti fonda (u mil.kn)

Vrsta fonda	Neto imovina 31.03.2012	Raspodjela imovine prema kategoriji udjelničara						
		Kreditne institucije	Osiguravajuća društva	Investicijski fondovi	Mirovinski fondovi	Investicijska društva	Ostali	Fizičke osobe
DIONIČKI OIF s JP	2.172	128	294	58	205	4	135	1.348
MJEŠOVITI OIF s JP	1.322	86	125	21	0	0	118	972
OBVEZNIČKI OIF s JP	535	19	140	2	0	0	41	333
NOVČANI OIF s JP	7.542	821	788	266	722	27	1.332	3.586
UKUPNO OIF s JP	11.571	1.054	1.346	347	928	31	1.626	6.239

Izvor: HANFA

Od 182,3 tisuće udjelničara 179,9 tisuća su fizičke, a 2,4 tisuće pravne osobe[2]. Njihova distribucija prema vrstama fondova u koje su uložili prikazana je na grafikonu 2.3.2.

Grafikon 2.3.2. Broj udjelničara u pojedinoj vrsti fonda prema kategorijama udjelničara

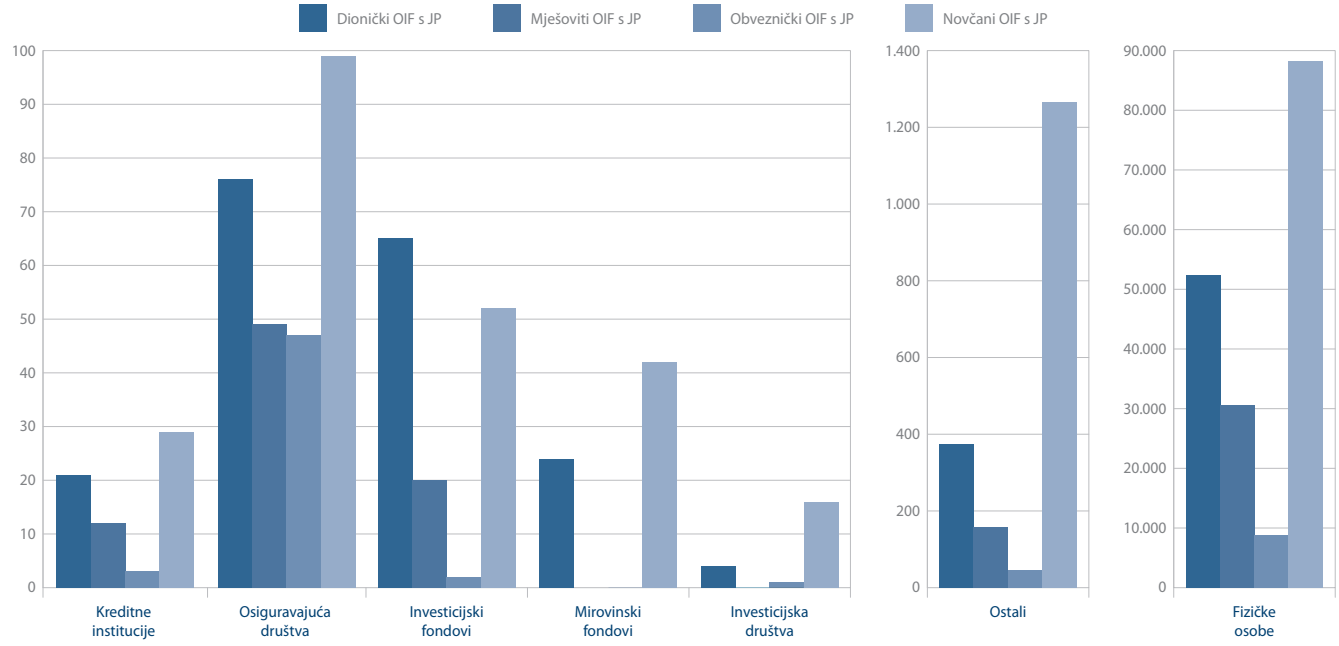

Izvor: HANFA

Domaći udjelničari prevladavaju te njihov udio u imovini iznosi 97,3%. Ako uspoređujemo domaće i strane udjelničare po broju, 98,8% ukupnog broja udjelničara su domaće, a samo 1,2% strane pravne i fizičke osobe.

Grafikon 2.3.3.Odnos imovine domaćih i stranih udjelničara

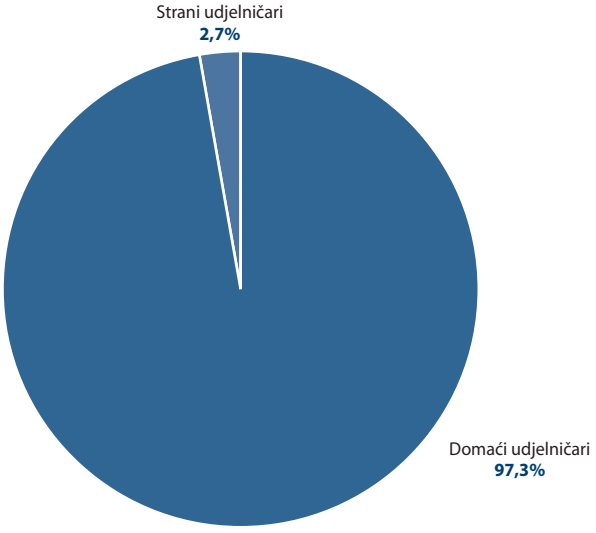

Izvor: HANFA

2 Udjelničari koji imaju sredstva uložena u više fondova brojani su više puta, jer ih je među fondovima nemoguće identificirati.

3. Mirovinski fondovi

3.1. Obvezni mirovinski fondovi (OMF)

Obvezni mirovinski fondovi (OMF) su u I. kvartalu 2012. imali ukupno 1.616.424 **člana**. U odnosu na prethodni kvartal to je porast od 0,75% ili 12.088 članova. Povećanje broja članova u odnosu na I. kvartal 2011. Iznosi 2,82% (44.262 člana).

Ukupna neto imovina obveznih mirovinskih fondova u I. kvartalu 2012. iznosila je 43,3 mlrd. kn, što je porast od 5,55% (2,3 mlrd. kn) u odnosu na prethodni kvartal, dok povećanje u odnosu na I. kvartal prethodne godine iznosi 12,68% (4,9 mlrd. kn).

Tablica 3.1.1. Neto imovina OMF-ova (u mil. kn)

Fond	31.3.2012.	31.12.2011.	31.03.2011.	Promjena 31.03.2012. - 31.12.2011.		Promjena 31.03.2012. - 31.03.2011.	
				Apsolutna	Postotna	Apsolutna	Postotna
AZ OMF	17.490	16.573	15.297	916	5,53%	2.192	14,33%
Erste Plavi OMF	5.728	5.356	5.118	372	6,95%	610	11,93%
PBZ/CO OMF	7.239	6.852	6.490	387	5,65%	748	11,53%
Raiffeisen OMF	12.891	12.286	11.564	605	4,93%	1.327	11,48%
Ukupno	43.348	41.067	38.469	2.281	5,55%	4.878	12,68%

Izvor: HANFA

Kod **strukture ulaganja** na području **domaće** imovine najveći dio čini ulaganje u državne obveznice, koje iznosi 29 mlrd. kn ili 66,68 % ukupne imovine, dok ulaganje u dionice iznosi 5,7 mlrd. kn, što čini 13,06% imovine. Najveći nominalni kvartalni rast, od 90,93%, bilježe ulaganja u kratkoročne vrijednosne papire, dok najveći nominalni kvartalni pad imaju ulaganja u OIF-ove (-10,95%) i municipalne obveznice (-6,70%). U odnosu na I. kvartal 2011. najveći nominalni rast bilježe također ulaganja u kratkoročne vrijednosne papire (186,44%) i depozite (134,19%), dok je najveći nominalni godišnji pad zabilježen kod ulaganja u municipalne obveznice (-45,46%).

Na području **inozemne** imovine najviše se ulagalo u dionice (2,8 mlrd. kn ili 6,46% imovine) i u OIF-ove (1,7 mlrd. kn ili 3,87 % imovine). Najveći nominalni kvartalni rast bilježe ulaganja u OIF-ove (4,05%) , a najveći nominalni kvartalni pad imaju ulaganja u dionice (-3,51%). U odnosu na I. kvartal 2011. najveći nominalni rast imaju ulaganja u dionice (5,55%), a najveći nominalni pad bilježe ulaganja u korporativne obveznice (-64,77%).

Kvartalni prinosi svih OMF-ova na kraju I. kvartala 2012. bili su u rasponu od 2,15% do 4,07%.

Kvartalni prinos Mirex-a iznosio je 2,78 %.

Raspon **prinosa svakog dana u odnosu na početak kvartala** svih OMF-ova tijekom kvartala iznosio je od minimalnih -0,12% do maksimalnih 4,51%.

Prosječni prinosi svakog dana u odnosu na početak kvartala svih OMF-ova kretali su se u rasponu od 1,29% do 2,52%.

Prinosi Mirex-a svakog dana u odnosu na početak kvartala kretali su se u rasponu od -0,03% do 2,91%, a **prosječni prinos Mirex-a svakog dana u odnosu na početak kvartala** u I. kvartalu 2012. iznosio je 1,53 %.

Grafikon 3.1.1. Vrijednosti obračunskih jedinica OMF-ova i Mirex-a u I. kvartalu 2012.

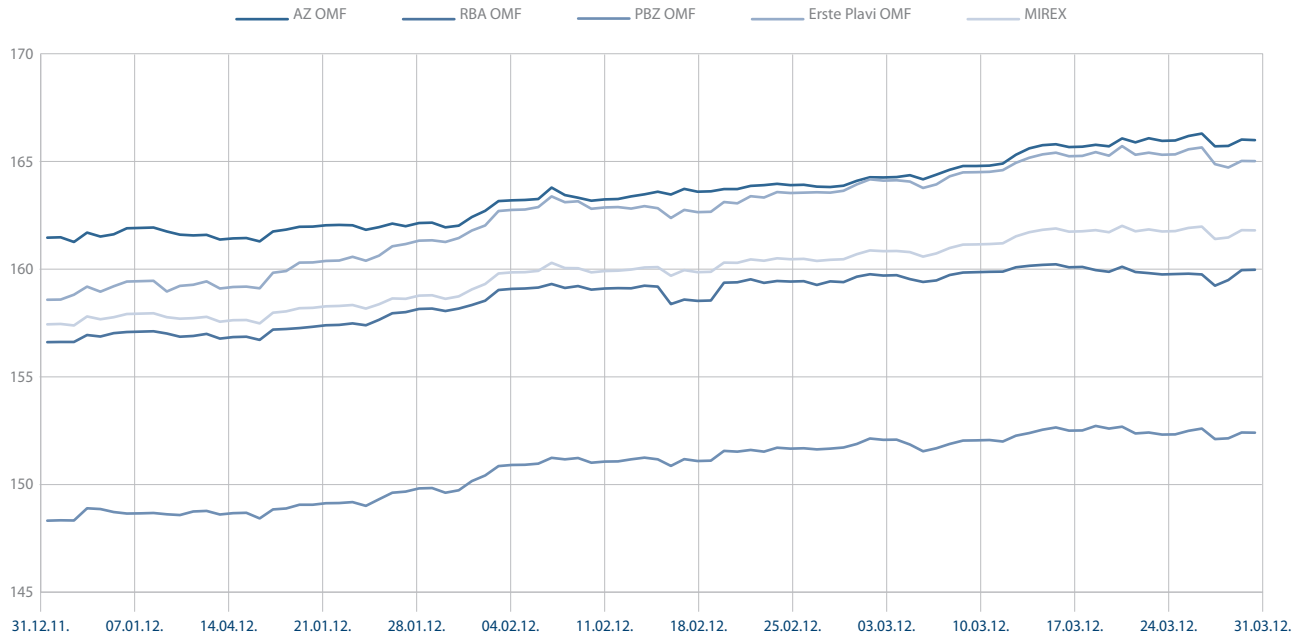

Izvor: HANFA

Grafikon 3.1.2. Prinosi OMF-ova i Mirex-a u I. kvartalu 2012.

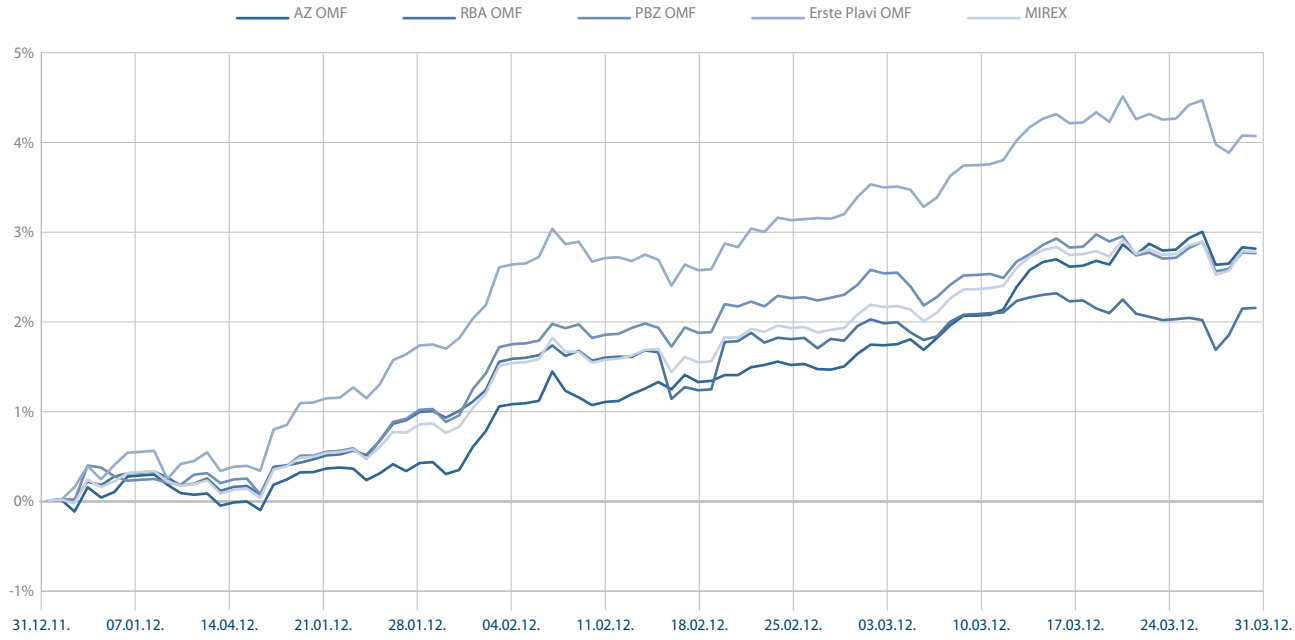

Izvor: HANFA

Grafikon 3.1.3. Promjene udjela domaće imovine u ukupnoj imovini OMF – ova u I. kvartalu 2012.

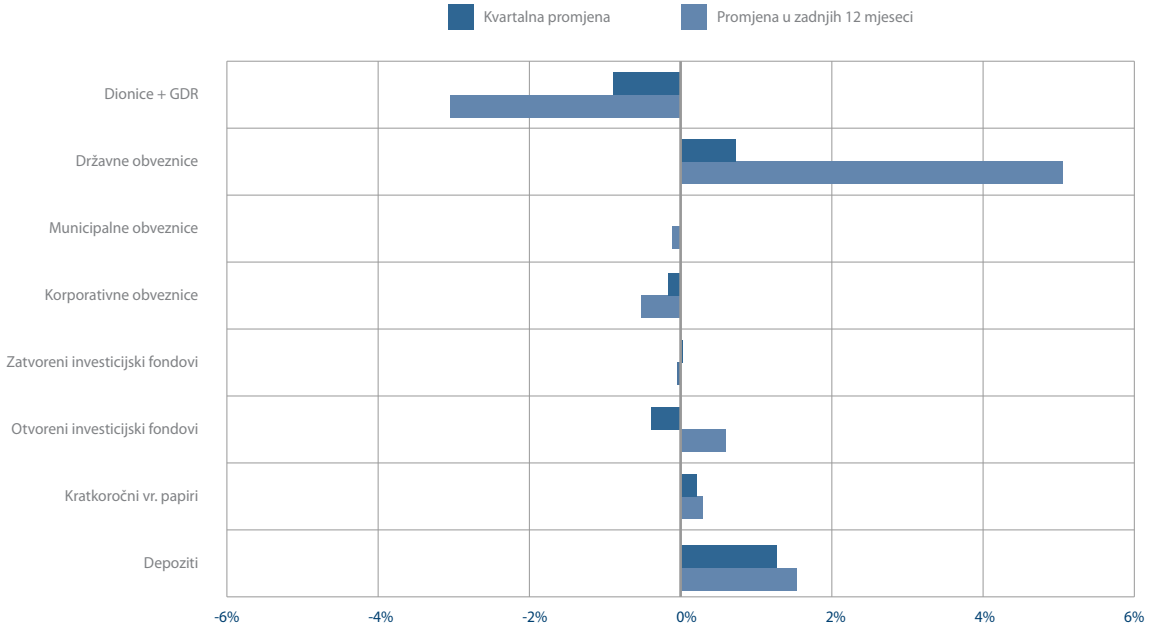

Izvor: HANFA

Grafikon 3.1.4. Promjene udjela inozemne imovine u ukupnoj imovini OMF – ova u I. kvartalu 2012.

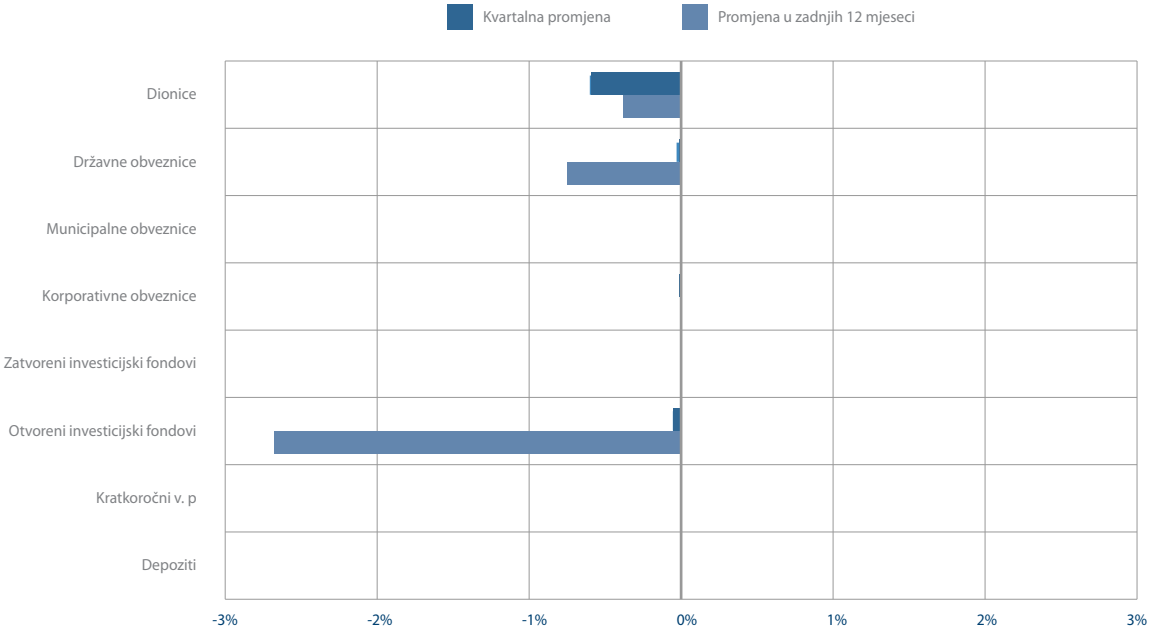

Izvor: HANFA

3.2. Otvoreni dobrovoljni mirovinski fondovi (ODMF)

Na kraju I. kvartala 2012. otvoreni dobrovoljni mirovinski fondovi (ODMF) imali su ukupno 187.324 člana, što je u odnosu na prethodni kvartal porast od 1,74%, odnosno 3.199 novih članova. U odnosu na I. kvartal 2011. to je povećanje od 7,38% (12.874 nova člana).

Ukupna neto imovina ODMF-ova u I. kvartalu 2012. iznosila je 1,8 mlrd. kn, što predstavlja kvartalni rast od 110 mil. kn, odnosno 6,70%. U odnosu na I. kvartal 2011. porast ukupne neto imovine iznosi 171 mil. kn ili 10,80%.

Tablica 3.2.1. Neto imovina ODMF-ova (u mil. kn)

Ukupna neto imovina ODMF-ova	31.3.2012.	31.12.2011.	31.03.2011.	Promjena 31.03.2012. - 31.12.2011.		Promjena 31.03.2012. - 31.03.2011.	
				Apsolutna	Postotna	Apsolutna	Postotna
	1.752	1.642	1.581	110	6,70%	171	10,80%

Izvor: HANFA

U **strukturi ulaganja** ODMF-ova na području **domaće** imovine najveću stavku i dalje čine ulaganja u državne obveznice, 1,0 mlrd. kn (58,43% imovine). Slijede ulaganja u dionice sa 239,9 mil. kn (13,64% imovine), korporativne obveznice sa 123,2 mil. kn (7,0% imovine) i otvorene investicijske fondove sa 17,9 mil. kn (1,02% imovine).

Najveći nominalni kvartalni rast bilježe ulaganja u kratkoročne vrijednosne papire (223,97 %) te ulaganja u depozite (198,69%), dok najveći nominalni kvartalni pad bilježe ulaganja u otvorene investicijske fondove (-56,05%) i korporativne obveznice (-9,45%).

U odnosu na I. kvartal 2011. najviše su se nominalno povećala ulaganja u depozite (149,88%) i kratkoročne vrijednosne papire (100,50%), dok je najveći nominalni pad zabilježen kod ulaganja u OIF-ove (-66,71%) i municipalne obveznice (-29,75%).

Na području **inozemne** imovine najznačajnija su ulaganja u dionice, 122,7 mil. kn (6,98% imovine) i u otvorene investicijske fondove, 48,4 mil. kn (2,75% imovine). Najveći nominalni kvartalni rast bilježe ulaganja u OIF-ove (16,37%). U zadnjih 12 mjeseci najveći nominalni pad od 49,33 % bilježe ulaganja u OIF-ove .

Raspon **kvartalnih prinosa** svih ODMF-ova u I. kvartalu 2012. bio je od 1,63% do 5,56%.

Prosječni kvartalni prinos svih ODMF-ova iznosio je 3,81%.

Raspon **prinosa svakog dana u odnosu na početak kvartala** svih ODMF-ova u . kvartalu 2012. bio je od minimalnih -0,15% do maksimalnih 6,68%.

Prosječni prinosi svakog dana u odnosu na početak kvartala ODMF-ova kretali su se u rasponu od 1,03% do 3,85%.

Grafikon 3.2.1. Vrijednosti obračunskih jedinica ODMF-ova u I. kvartalu 2012.

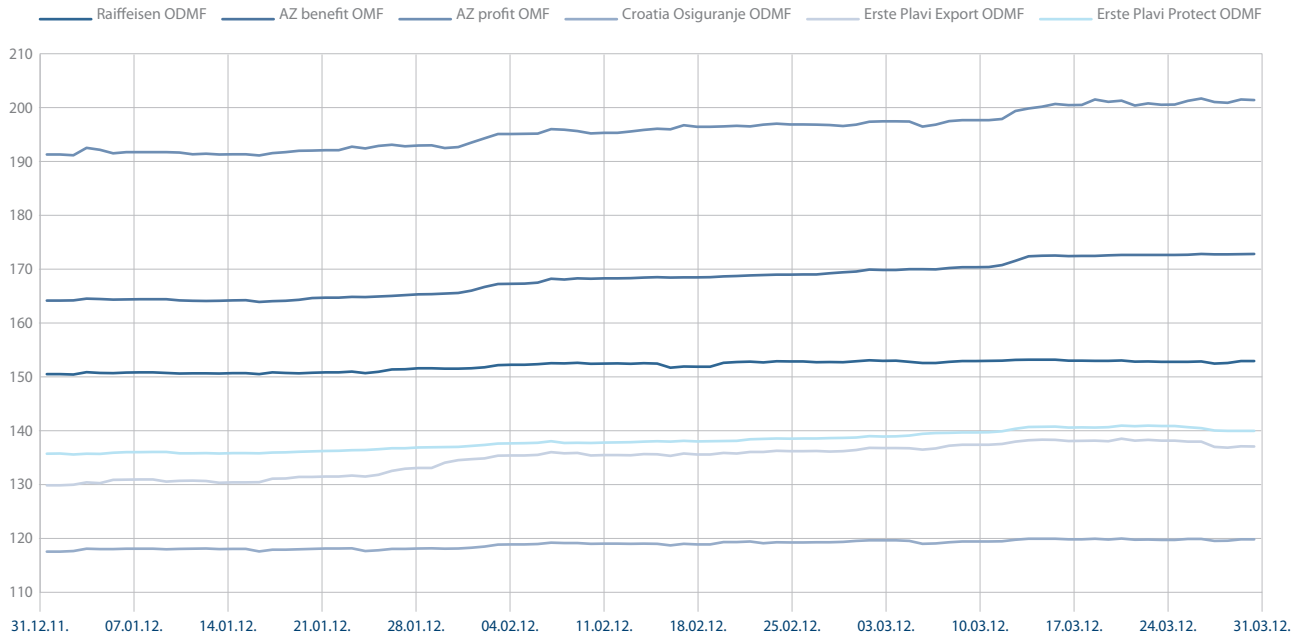

Izvor : HANFA

Grafikon 3.2.2. Prinosi ODMF-ova u I. kvartalu 2012.

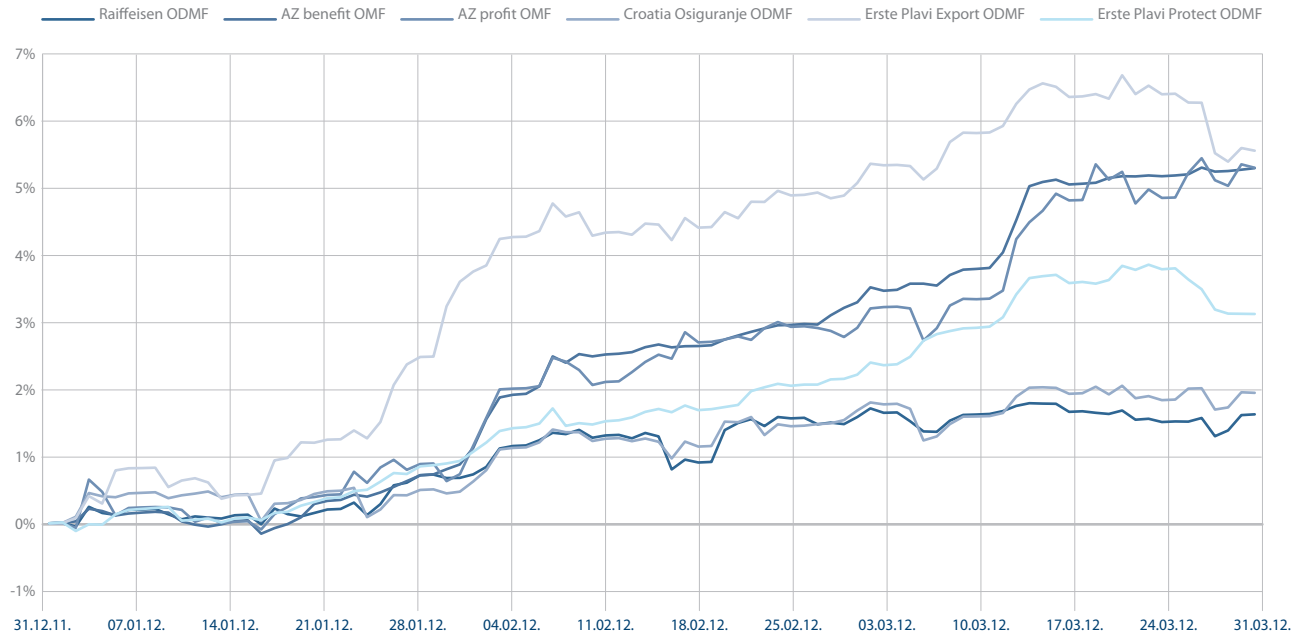

Izvor : HANFA

Grafikon 3.2.3. Promjene udjela domaće imovine u ukupnoj imovini ODMF – ova u I. kvartalu 2012.

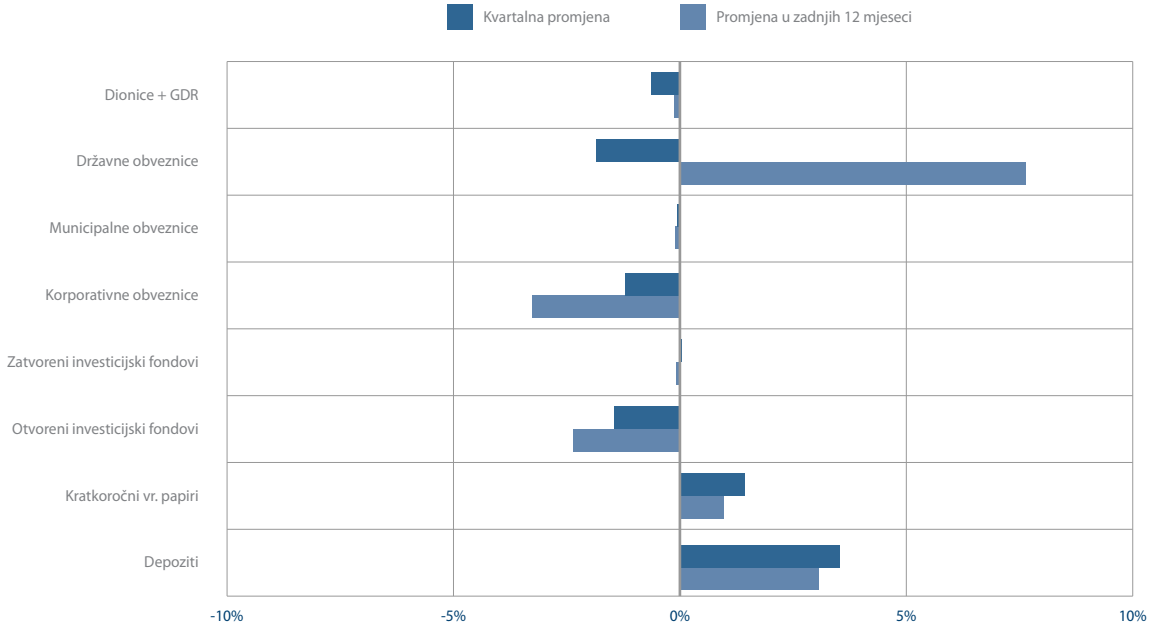

Izvor : HANFA

Grafikon 3.2.4. Promjene udjela inozemne imovine u ukupnoj imovini ODMF – ova u I. kvartalu 2012.

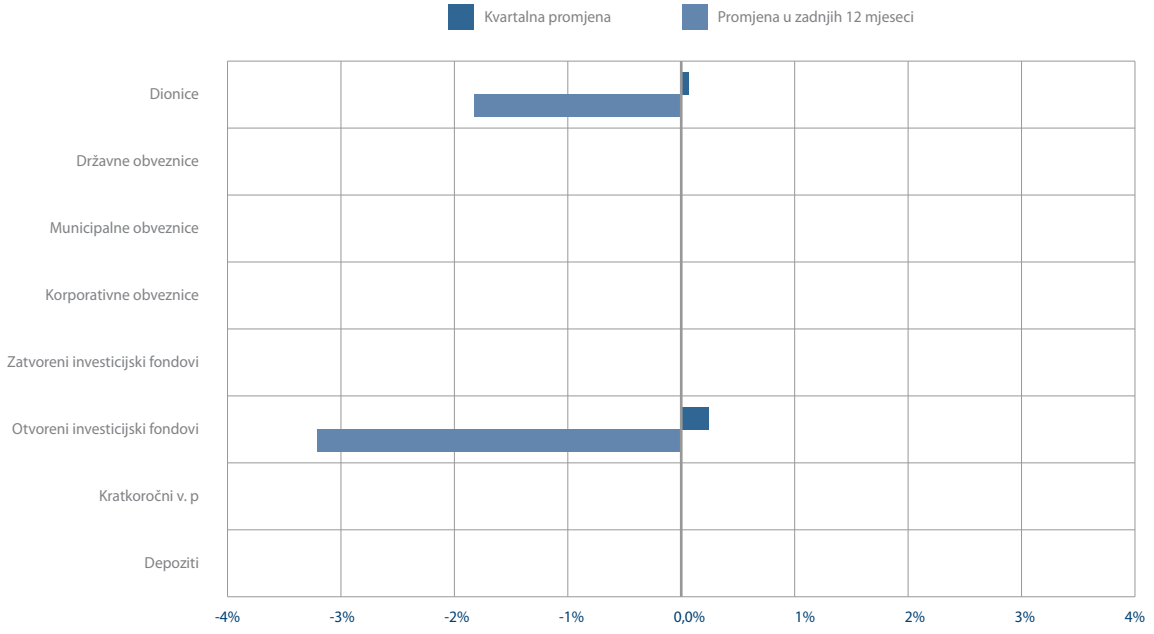

Izvor : HANFA

3.3. Zatvoreni dobrovoljni mirovinski fondovi (ZDMF)

Na kraju I. kvartala 2012. zatvoreni dobrovoljni mirovinski fondovi (ZDMF) imali su ukupno 17.996 članova, što je kvartalni pad od 0,88% (159 članova manje). U odnosu na I. kvartal 2011. to je povećanje od 1,87% (330 članova).

Ukupna neto imovina zatvorenih dobrovoljnih mirovinskih fondova na kraju I. kvartala 2012. iznosila je 346 mil. kn. To je povećanje od 19 mil. kn ili 5,95 % u odnosu na prethodni kvartal, dok u odnosu na I. kvartal 2011. to predstavlja porast od 11,79 % (36 mil. kn).

Tablica 3.3.1. Neto imovina ZDMF-ova (u mil. kn)

Ukupna neto imovina ODMF-ova	31.3.2012.	31.12.2011.	31.03.2011.	Promjena 31.03.2012. - 31.12.2011.		Promjena 31.03.2012. - 31.03.2011.	
				Apsolutna	Postotna	Apsolutna	Postotna
	346	327	310	19	5,95%	36	11,79%

Izvor : HANFA

Kod **strukture ulaganja** ZDMF-ova u I. kvartalu 2012. na području **domaće** imovine i dalje se najviše ulagalo u državne obveznice (189,0 mil. kn ili 54,38% imovine), zatim u dionice (44,0 mil. kn ili 12,67% imovine) i u korporativne obveznice (20,.0 mil. kn ili 5,74% imovine).

Najveći nominalni kvartalni rast bilježe ulaganja u kratkoročne vrijednosne papire (250%) i depozite (45,44%), dok najveći nominalni kvartalni pad bilježe ulaganja u otvorene investicijske fondove (-24,20%).

U odnosu na I. kvartal 2011. najveći nominalni rast bilježe ulaganja u kratkoročne vrijednosne papire (98,38%) i depozite (39,89%), dok najveći nominalni pad bilježe ulaganja u municipalne obveznice (-100,00 %) i OIF-ove (-53,65%).

Na području **inozemne** imovine najviše se ulagalo u dionice (22,8 mil. kn ili 6,56 % imovine). Najveći nominalni kvartalni rast bilježe ulaganja u dionce (12,01%), dok najveći nominalni kvartalni pad imaju ulaganja u OIF-ove (-18,04%). U odnosu na I. kvartal 2011. najveći nominalni rast bilježe ulaganja u OIF-ove (249,74 %).

Raspon **kvartalnih prinosa** svih ZDMF-ova na kraju . kvartala 2012. bio je od 0,97% do 5,80%, a **prosječni kvartalni prinos** svih ZDMF-ova iznosio je 3,04%.

Prinosi svakog dana u odnosu na početak kvartala svih ZDMF-ova kretali su se tijekom I. kvartala 2012. u rasponu od -0,59% do 5,95%.

Raspon **prosječnih prinosa svakog dana u odnosu na početak kvartala** svih ZDMF-ova iznosio je od 0,74% do 2,59%.

Grafikon 3.3.1. Vrijednosti obračunskih jedinica ZDMF-ova u I. kvartalu 2012.

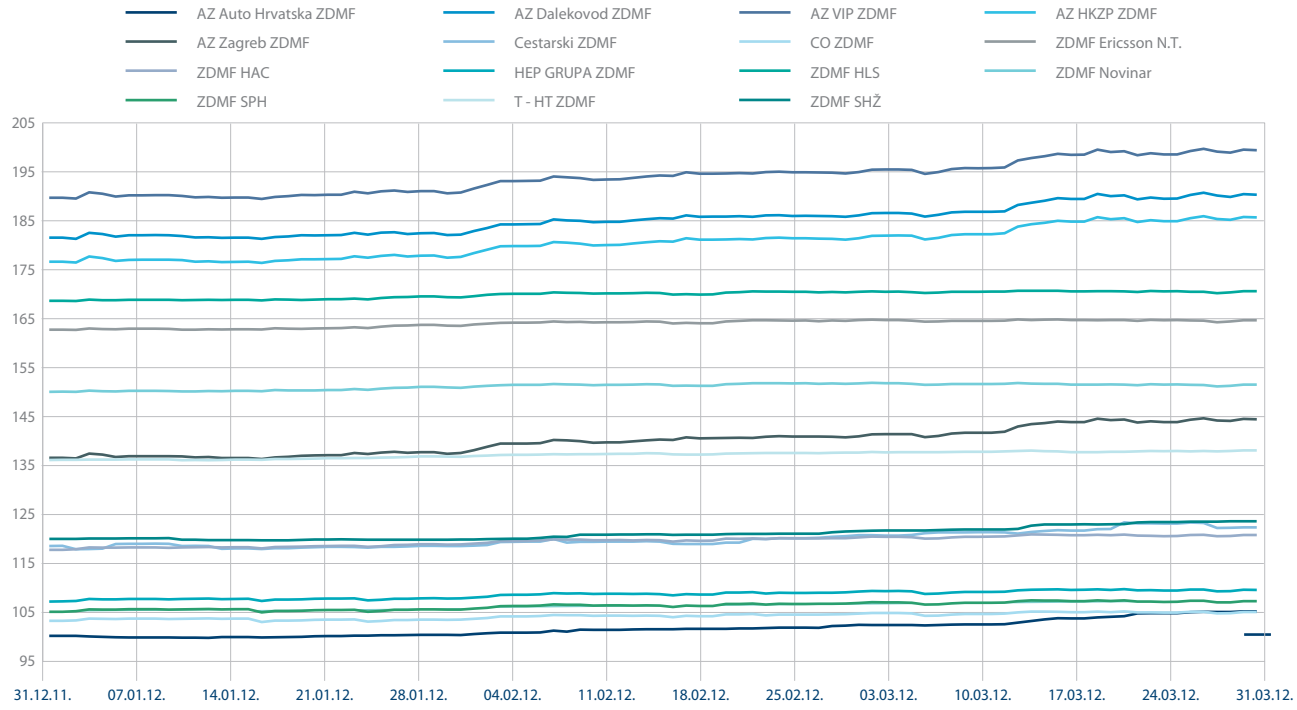

Izvor : HANFA

Grafikon 3.3.2. Prinosi ZDMF-ova u I. kvartalu 2012.

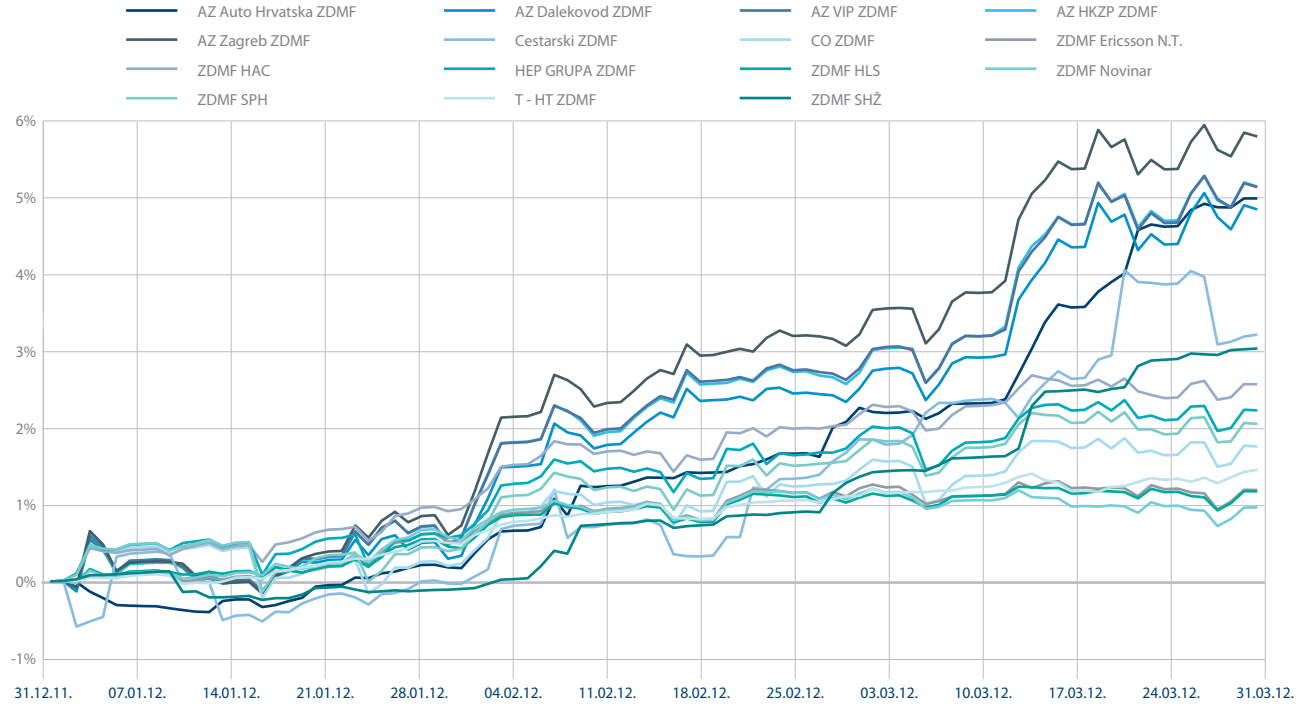

Izvor : HANFA

Grafikon 3.3.3. Promjene udjela domaće imovine u ukupnoj imovini ZDMF – ova u I. kvartalu 2012.

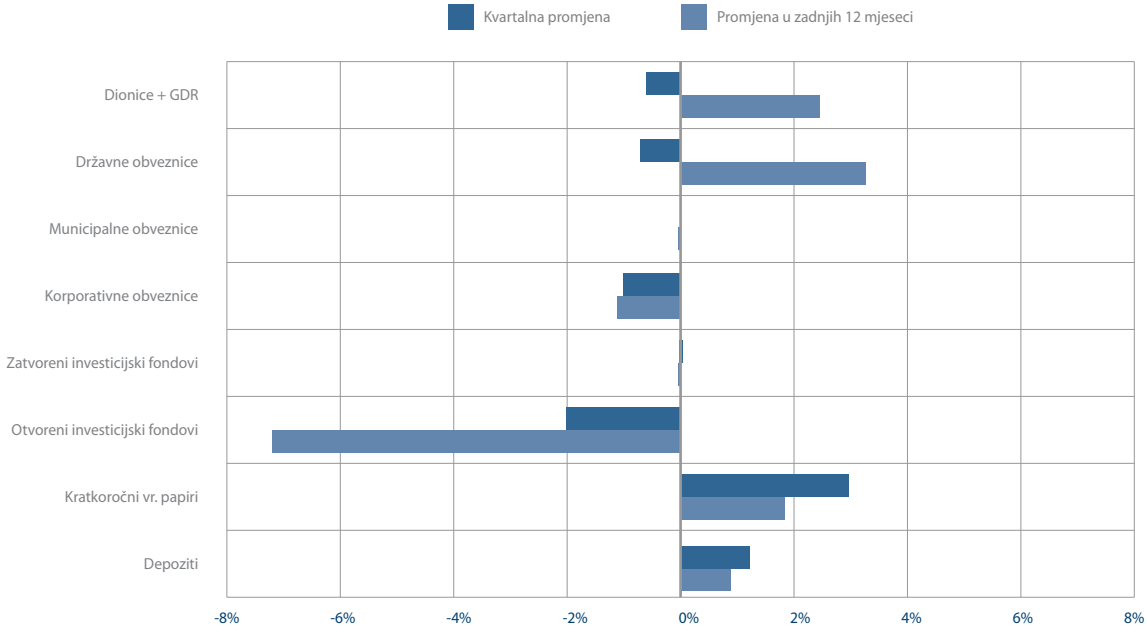

Izvor : HANFA

Grafikon 3.3.4. Promjene udjela inozemne imovine u ukupnoj imovini ZDMF – ova u I. kvartalu 2012.

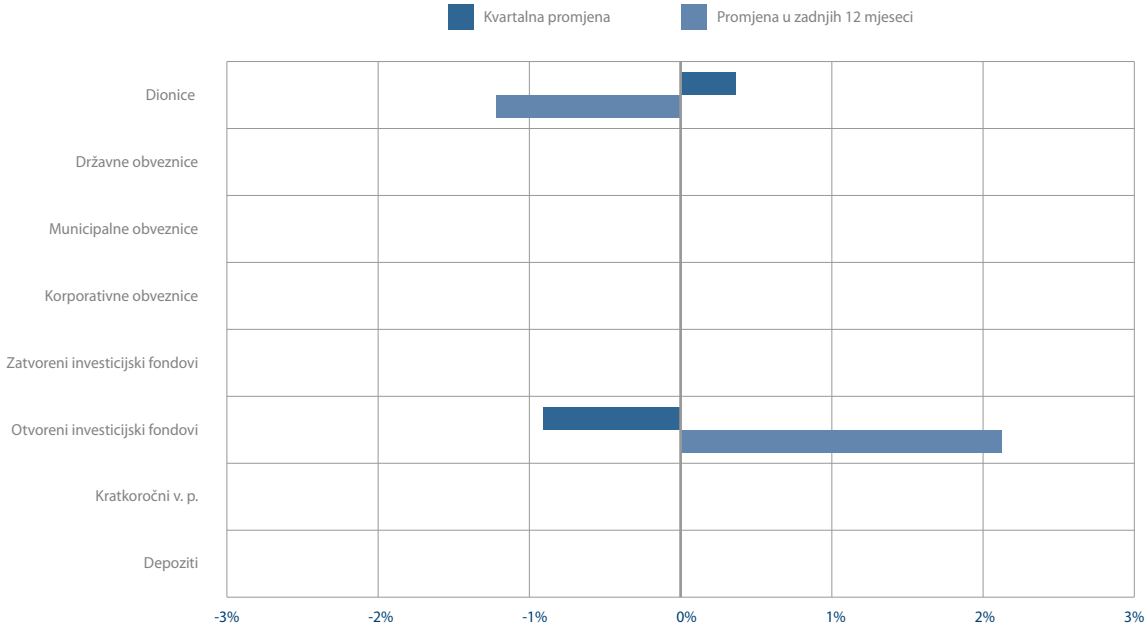

Izvor : HANFA

4. Tržište osiguranja

U razdoblju 01.01.-31.03.2012. kao ukupni rezultat poslovanja[3] 27 društava za osiguranje i 1 društva za reosiguranje ostvarena je dobit nakon oporezivanja u iznosu od 172,0 mil. kn što u odnosu na razdoblje 01.01.-31.03.2011. predstavlja povećanje dobiti od 17,5%. Od ukupnog broja društava koja obavljaju djelatnost osiguranja, 20 društava za osiguranje i 1 društvo za reosiguranje ostvarilo je neto dobit u iznosu od 182,3 mil. kn, dok je 7 društava za osiguranje kao rezultat poslovanja iskazalo neto gubitak u visini od 10,3 mil. kn.

Promatrano po skupinama osiguranja, u okviru životnih osiguranja ostvarena je dobit od 68,0 mil. kn, što je za 27,8% više u odnosu na isto razdoblje prethodne godine, dok je u okviru neživotnih osiguranja ostvarena dobit od 104,0 mil. kn što je za 11,6% više u odnosu na isto razdoblje prethodne godine.

Društvo Wüstenrot životno osiguranje d.d. u listopadu 2011. ishodilo je dozvolu Agencije za obavljanje poslova osiguranja, a s obavljanjem djelatnosti započelo je u I. kvartalu 2012. godine.

Grafikon 4.1. Usporedni prikaz broja društava za osiguranje i društava za reosiguranje na dan 31.03.2011. i 31.03.2012. godine

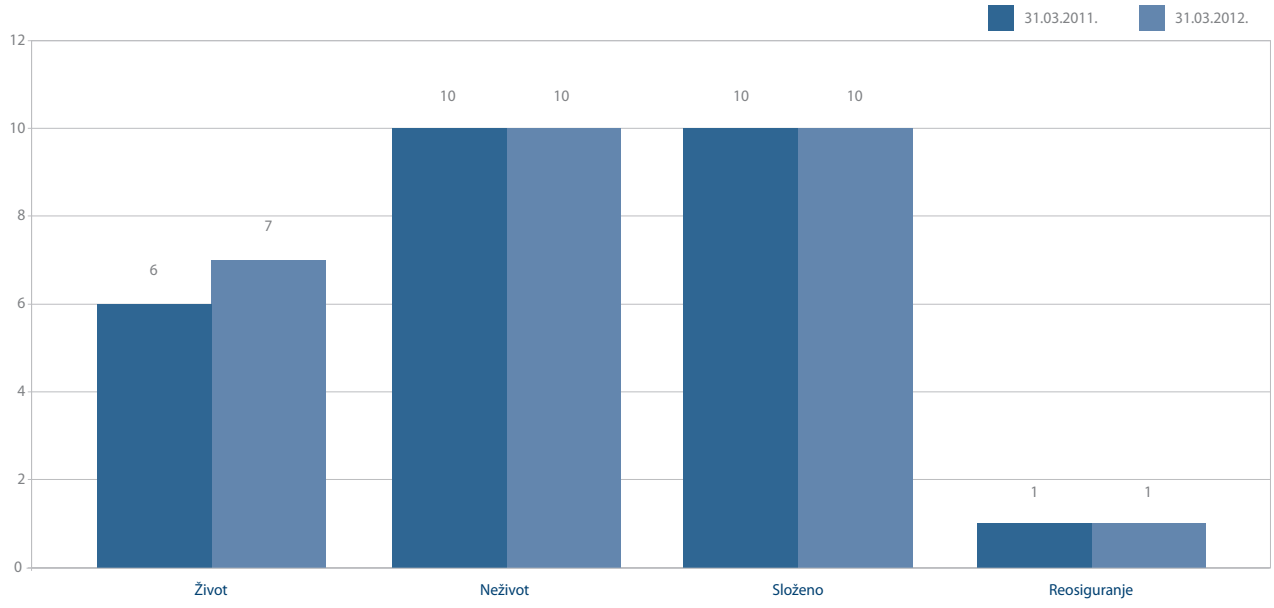

Izvor: HANFA

3 Podaci se temelje na preliminarnim, nerevidiranim podacima za razdoblje 01.01.-31.03.2012., i to za 27 društava za osiguranje i 1 društvo za reosiguranje koja su u tom razdoblju obavljala poslove osiguranja, odnosno reosiguranja.

4.1. Zaračunata bruto premija društava za osiguranje i društava za reosiguranje

Ukupna zaračunata bruto premija društava za osiguranje i društva za reosiguranje za razdoblje 01.01.-31.03.2012. iznosi 2,7 mlrd. kn, što je za 1,8% manje u odnosu na ostvarenu premiju u istom razdoblju 2011. kada je premija iznosila 2,8 mlrd. kn.

Zaračunata bruto premija životnih osiguranja iznosi 572,7 mil. kn i veća je za 2,0% u odnosu na isto razdoblje prethodne godine. Od ukupno 17 društava za osiguranje koja su u I. kvartalu 2012. obavljala poslove životnih osiguranja, 8 društava zabilježilo je pad premije u odnosu na I. kvartal prethodne godine.

Na **zaračunatu bruto premiju neživotnih osiguranja**, uključujući iznos premije koji je ostvarilo i društvo za reosiguranje, odnosi se 2,1 mlrd. kn, što je za 2,7% manje u odnosu na isto razdoblje prethodne godine. Od ukupno 20 društava za osiguranje i 1 društva za reosiguranje koja su obavljala poslove neživotnih osiguranja, u usporedbi s I. kvartalom 2011. pad premije zabilježilo je 10 društava za osiguranje i 1 društvo za reosiguranje.

Tablica 4.1.1. Zaračunata bruto premija društava za osiguranje i društava za reosiguranje (u kn), uključuje premiju suosiguranja

DRUŠTVA ZA OSIGURANJE I DRUŠTVA ZA REOSIGURANJE	ŽIVOTNA OSIGURANJA			udjel u premiji svih društava u %		NEŽIVOTNA OSIGURANJA			udjel u premiji svih društava u %		U K U P N O			udjel u premiji svih društava u %	
	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.	Indeks 2012./2011.	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.	Indeks 2012./2011.	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.	Indeks 2012./2011.	01.01.2011.-31.03.2011.	01.01.2012.-31.03.2012.
AGRAM životno osiguranje d.d.	38.798.020	41.804.340	107,7	6,9%	7,3%				0,0%	0,0%	38.798.020	41.804.340	107,7	1,5%	1,7%
ALLIANZ ZAGREB d.d.	84.169.595	99.227.995	117,9	15,0%	17,3%	198.587.131	216.589.639	109,1	9,9%	11,0%	282.756.727	315.817.634	111,7	11,1%	12,5%
BASLER OSIGURANJE ZAGREB d.d.	46.338.260	43.445.413	93,8	8,3%	7,6%	64.527.627	59.372.209	92,0	3,2%	3,0%	110.865.887	102.817.622	92,7	4,3%	4,1%
BNP PARIBAS CARDIF OSIGURANJE d.d.				0,0%	0,0%	19.083.355	18.198.223	95,4	1,0%	0,9%	19.083.355	18.198.223	95,4	0,8%	0,7%
CROATIA osiguranje d.d.	84.894.737	81.190.280	95,6	15,1%	14,2%	896.701.410	869.967.784	97,0	44,9%	44,3%	981.596.147	951.158.064	96,9	38,4%	37,5%
CROATIA zdravstveno osiguranje d.d.				0,0%	0,0%	31.855.965	32.156.977	100,9	1,6%	1,6%	31.855.965	32.156.977	100,9	1,3%	1,3%
Erste osiguranje Vienna Insurance Group d.d.	24.384.901	24.350.599	99,9	4,3%	4,3%				0,0%	0,0%	24.384.901	24.350.599	99,9	1,0%	1,0%
EUROHERC osiguranje d.d.				0,0%	0,0%	225.036.082	214.878.230	95,5	11,3%	11,0%	225.036.082	214.878.230	95,5	8,8%	8,5%
GENERALI OSIGURANJE d.d.	30.588.701	30.270.703	99,0	5,5%	5,3%	54.572.806	58.263.291	106,8	2,7%	3,0%	85.161.507	88.533.994	104,0	3,3%	3,5%
GRAWE HRVATSKA d.d.	57.529.736	58.673.383	102,0	10,3%	10,3%	35.549.843	34.337.695	96,6	1,8%	1,8%	93.079.579	93.011.078	99,9	3,6%	3,7%
HELIOS Vienna Insurance Group d.d.	30.360.639	29.595.968	97,5	5,4%	5,2%	11.055.342	14.232.388	128,7	0,6%	0,7%	41.415.981	43.828.356	105,8	1,6%	1,7%
HOK - OSIGURANJE d.d.				0,0%	0,0%	45.301.806	47.469.561	104,8	2,3%	2,4%	45.301.806	47.469.561	104,8	1,8%	1,9%
HRVATSKO KREDITNO OSIGURANJE d.d.				0,0%	0,0%	1.453.223	1.580.391	108,8	0,1%	0,1%	1.453.223	1.580.391	108,8	0,1%	0,1%
IZVOR OSIGURANJE d.d.				0,0%	0,0%	3.059.169	8.428.890	275,5	0,2%	0,4%	3.059.169	8.428.890	275,5	0,1%	0,3%
JADRANSKO OSIGURANJE d.d.				0,0%	0,0%	147.500.097	144.067.801	97,7	7,4%	7,3%	147.500.097	144.067.801	97,7	5,8%	5,7%
KD ŽIVOTNO OSIGURANJE d.d.	2.364.554	2.985.711	126,3	0,4%	0,5%				0,0%	0,0%	2.364.554	2.985.711	126,3	0,1%	0,1%
KVARNER VIENNA INSURANCE GROUP d.d.	47.302.909	42.271.326	89,4	8,4%	7,4%	65.987.915	63.367.420	96,0	3,3%	3,2%	113.290.824	105.638.745	93,2	4,4%	4,2%
MERKUR OSIGURANJE d.d.	59.378.846	59.697.426	100,5	10,6%	10,4%	7.453.193	8.438.632	113,2	0,4%	0,4%	66.832.039	68.136.058	102,0	2,6%	2,7%
SOCIETE GENERALE OSIGURANJE d.d.	6.589.697	12.076.338	183,3	1,2%	2,1%				0,0%	0,0%	6.589.697	12.076.338	183,3	0,3%	0,5%
SUNCE OSIGURANJE d.d.				0,0%	0,0%	37.511.790	35.513.515	94,7	1,9%	1,8%	37.511.790	35.513.515	94,7	1,5%	1,4%
TRIGLAV OSIGURANJE d. d.	17.965.749	17.961.538	100,0	3,2%	3,1%	102.159.420	86.093.306	84,3	5,1%	4,4%	120.125.168	104.054.844	86,6	4,7%	4,1%
UNIQA osiguranje d.d.	27.456.277	23.365.362	85,1	4,9%	4,1%	33.228.650	32.621.576	98,2	1,7%	1,7%	60.684.927	55.986.938	92,3	2,4%	2,2%
VELEBIT OSIGURANJE d.d.				0,0%	0,0%	16.062.783	16.969.498	105,6	0,8%	0,9%	16.062.783	16.969.498	105,6	0,6%	0,7%
VELEBIT ŽIVOTNO OSIGURANJE d.d.	1.540.500	2.495.225	162,0	0,3%	0,4%				0,0%	0,0%	1.540.500	2.495.225	162,0	0,1%	0,1%
VICTORIA OSIGURANJE d.d.				0,0%	0,0%	360.797	567.432	157,3	0,0%	0,0%	360.797	567.432	157,3	0,0%	0,0%
VICTORIA ŽIVOTNO OSIGURANJE d.d.	1.849.215	3.041.034	164,5	0,3%	0,5%				0,0%	0,0%	1.849.215	3.041.034	164,5	0,1%	0,1%
WÜSTENROT ŽIVOTNO OSIGURANJE d.d.		208.361		0,0%	0,0%				0,0%	0,0%		208.361		0,0%	0,0%
Croatia Lloyd d.d.						192.159.917	166.915.694	86,9	100,0%	100,0%	192.159.917	166.915.694	86,9	100,0%	100,0%
UKUPNO društva za osiguranje	561.512.337	572.661.003	102,0	100,0%	100,0%	1.997.048.404	1.963.114.457	98,3	100,0%	100,0%	2.558.560.742	2.535.775.460	99,1	100,0%	100,0%
UKUPNO društva za reosiguranje						192.159.917	166.915.694	86,9	100,0%	100,0%	192.159.917	166.915.694	86,9	100,0%	100,0%
UKUPNO	561.512.337	572.661.003	102,0			2.189.208.321	2.130.030.151	97,3			2.750.720.659	2.702.691.154	98,3		

Izvor: HANFA

Grafikon 4.1.1. Udjel skupina osiguranja u ukupnoj zaračunatoj bruto premiji društava za osiguranje za razdoblje siječanj – ožujak 2012. godine (u %)

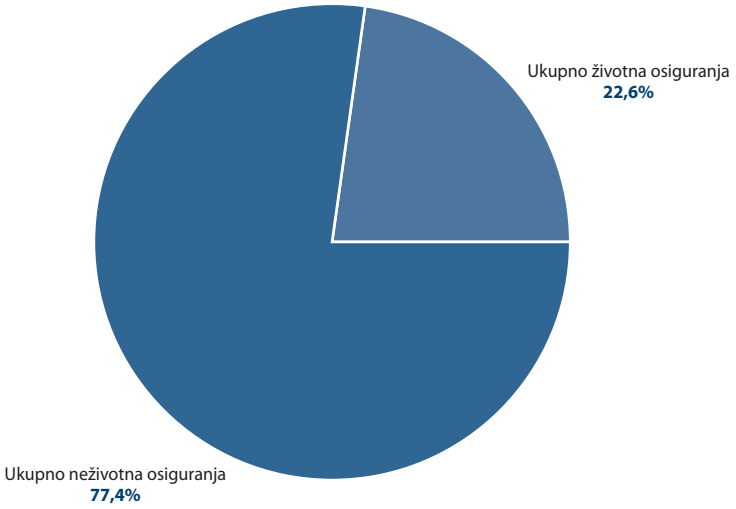

Izvor: HANFA

Grafikon 4.1.2. Struktura zaračunate bruto premije društava za osiguranje po vrstama osiguranja za razdoblje siječanj – ožujak 2012. godine (u %)

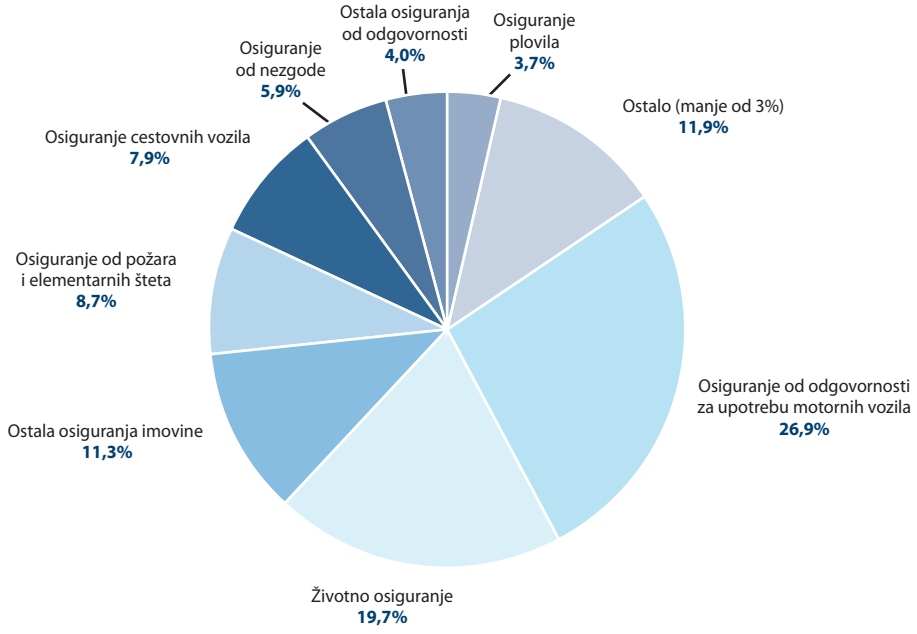

Izvor: HANFA

4.2. Struktura izvještaja o financijskom položaju društava za osiguranje i društava za reosiguranje

Ukupna imovina društava za osiguranje i društava za reosiguranje na dan 31.03.2012. iznosi 34,0 mlrd. kn i u odnosu na 31.03.2011. veća je za 2 mlrd. kn ili 6,3%. Od ukupnog iznosa imovine na imovinu životnih osiguranja se odnosi 47,5%, a na imovinu neživotnih osiguranja 49,4%, dok preostalih 3,1% čini imovinu reosiguranja.

Tablica 4.2.1. Struktura aktive društava za osiguranje i društava za reosiguranje na dan 31.03.2011. i 31.03.2012. godine (u kn)

	život	neživot	ukupno	ukupno udjel (%)	život	neživot	ukupno	ukupno udjel (%)	Indeks 2012./2011.
	31.03.2011.				31.03.2012.				
Potraživanja za upisani a neuplaćeni kapital									
Nematerijalna imovina	10.673.245	116.061.609	126.734.855	0,4%	10.311.636	86.721.894	97.033.530	0,3%	76,6
Materijalna imovina	139.846.184	2.364.822.107	2.504.668.291	7,8%	124.808.414	2.261.256.922	2.386.065.336	7,0%	95,3
Ulaganja	13.433.913.901	10.283.192.821	23.717.106.722	74,2%	14.445.887.354	10.907.875.798	25.353.763.152	74,6%	106,9
Ulaganja za račun i rizik vlasnika polica životnog osiguranja	638.527.727		638.527.727	2,0%	734.363.133		734.363.133	2,2%	115,0
Udio reosiguranja u tehničkim pričuvama	327.401.594	1.039.240.415	1.366.642.009	4,3%	357.370.541	1.349.177.025	1.706.547.567	5,0%	124,9
Odgođena i tekuća porezna imovina	21.474.028	32.870.889	54.344.917	0,2%	26.392.301	22.962.148	49.354.449	0,2%	90,8
Potraživanja	231.608.428	2.562.124.137	2.793.732.565	8,7%	191.474.145	2.579.395.323	2.770.869.468	8,2%	99,2
Ostala imovina	99.987.226	285.229.795	385.217.021	1,2%	77.087.239	375.212.090	452.299.329	1,3%	117,4
Plaćeni troškovi budućeg razdoblja i nedospjela naplata prihoda	141.551.811	243.659.864	385.211.675	1,2%	173.466.529	250.111.267	423.577.796	1,3%	110,0
UKUPNO AKTIVA	15.044.984.143	16.927.201.638	31.972.185.781	100%	16.141.161.292	17.832.712.467	33.973.873.760	100%	106,3

Izvor: HANFA

Grafikon 4.2.1. Usporedni prikaz strukture aktive društava za osiguranje i društava za reosiguranje na dan 31.03.2011. i 31.03.2012. godine (u %)

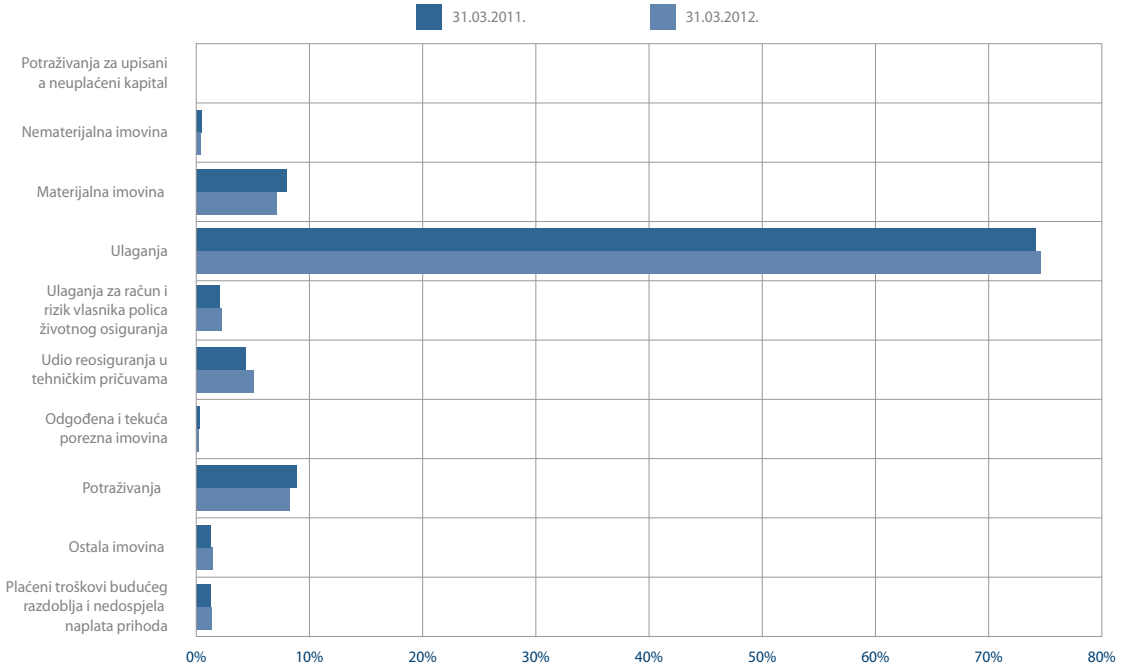

Izvor: HANFA

Tablica 4.2.2. Struktura pasive društava za osiguranje i društava za reosiguranje na dan 31.03.2011. i 31.12.2012. godine (u kn)

	život	neživot	ukupno	ukupno udjel (%)	život	neživot	ukupno	ukupno udjel (%)	Indeks 2012./2011.
	31.03.2011.				31.03.2012.				
Kapital i rezerve	1.537.471.561	4.413.666.132	5.951.137.693	18,6%	1.782.345.110	4.821.564.344	6.603.909.454	19,4%	111,0
Obveze drugog reda (podređene obveze)	76.526.984	65.267.682	141.794.666	0,4%		41.928.567	41.928.567	0,1%	29,6
Tehničke pričuve	12.075.594.220	10.459.255.666	22.534.849.885	70,5%	12.963.289.296	10.708.340.579	23.671.629.875	69,7%	105,0
Posebna pričuva za osiguranje iz skupine živ. osig. kod kojih ugovaratelj osiguranja preuzima invest. rizik, bruto iznos	637.057.188		637.057.188	2,0%	719.182.898		719.182.898	2,1%	112,9
Ostale pričuve	10.117.424	94.610.951	104.728.375	0,3%	17.656.100	85.471.096	103.127.196	0,3%	98,5
Odgođena i tekuća porezna obveza	20.935.712	327.557.880	348.493.592	1,1%	25.005.745	337.166.118	362.171.863	1,1%	103,9
Depoziti zadržani iz posla predanog u reosiguranje	308.730.000	66.492.460	375.222.460	1,2%	340.308.571	77.767.790	418.076.361	1,2%	111,4
Financijske obveze	36.304.391	168.172.797	204.477.188	0,6%	42.639.330	176.450.315	219.089.644	0,6%	107,1
Ostale obveze	271.309.046	1.133.919.039	1.405.228.085	4,4%	217.282.578	1.327.543.232	1.544.825.810	4,6%	109,9
Odgođeno plaćanje troškova i prihod budućeg razdoblja	70.937.617	198.259.031	269.196.647	0,8%	33.451.664	256.480.427	289.932.091	0,9%	107,7
UKUPNA PASIVA	15.044.984.143	16.927.201.638	31.972.185.781	100%	16.141.161.292	17.832.712.467	33.973.873.760	100%	106,3

Izvor: HANFA

Grafikon 4.2.2. Usporedni prikaz strukture pasive društava za osiguranje i društava za reosiguranje na dan 31.03.2011. i 31.03.2012. godine (u %)

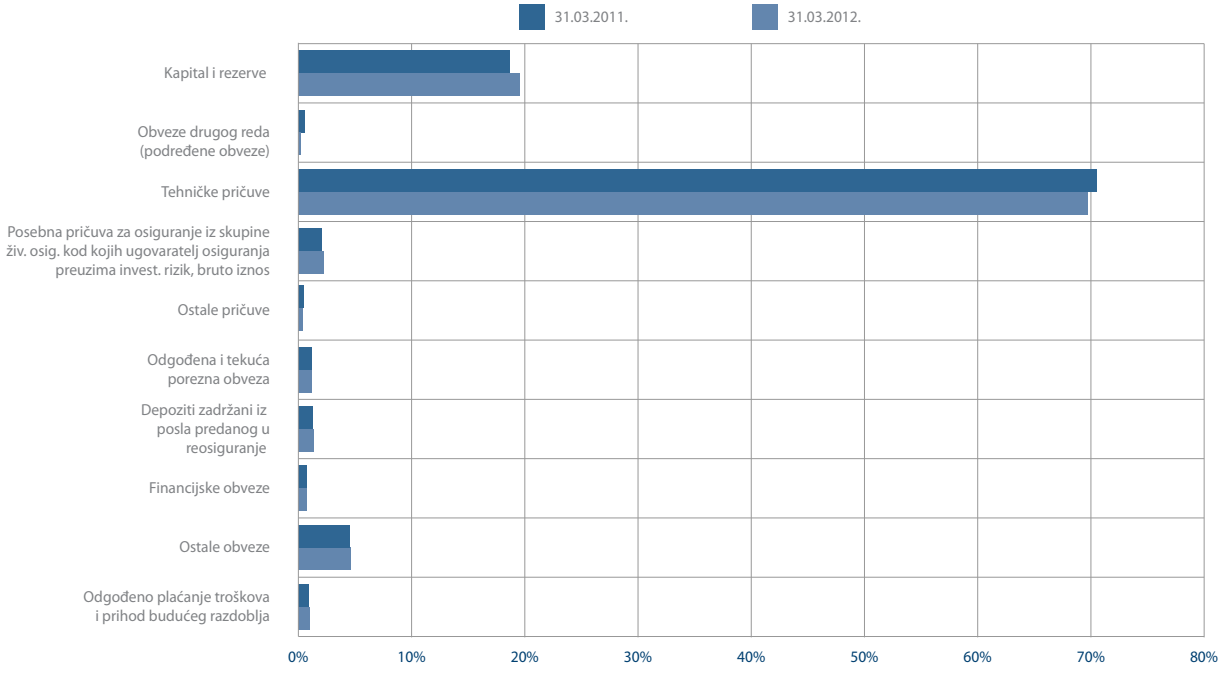

Izvor: HANFA

5. Leasing

U razdoblju 01.01.-31.03.2012. na razini djelatnosti leasinga u Republici Hrvatskoj kao rezultat poslovanja[4] ostvarena je dobit nakon oporezivanja u iznosu od 126,8 mil. kn. Nepovoljna kretanja u gospodarstvu negativno su se odrazila i na djelatnost leasinga, koja je tijekom prvog tromjesečja 2012. obilježena daljnjim usporavanjem opsega poslovanja uvjetovanog smanjenjem investicijske potrošnje. U prvom tromjesečju 2012. primjetan je pad vrijednosti aktive, broja aktivnih ugovora te vrijednosti aktivnih ugovora[5] u odnosu na isto razdoblje 2011., uz istovremeno povećanje broja i vrijednosti novozaključenih ugovora[6].

Osnovni podaci o stanju u djelatnosti leasinga prikazani su u sljedećoj tablici.

Tablica 5.1. Pregled stanja u djelatnosti leasinga na dan 31.03.2011. i 31.03.2012. godine

Datum/ razdoblje od 01.01. do	Ukupna aktiva (mlrd. kn)	Dobit/ gubitak nakon oporezivanja (kn)	Broj novo-zaključenih ugovora	Vrijednost novo-zaključenih ugovora (kn)	Broj aktivnih ugovora	Vrijednost aktivnih ugovora (kn)	Broj zaposlenih
31.03.2011.	26.800.184.854	96.137.186	6.792	1.179.347.285	146.330	20.668.710.543	950
31.03.2012.	24.586.839.661	126.781.622	7.143	1.179.804.855	136.176	18.376.754.446	940

Izvor: HANFA

4 Podaci za kvartalni bilten temelje se na preliminarnim, nerevidiranim podacima za razdoblje 01.01.-31.03.2012. za 25 leasing društava koja su u tom razdoblju obavljala poslove leasinga.

5 Kod aktivnih ugovora nedospjela ugovorena vrijednost u strukturi portfelja operativnog leasinga odnosi se na iznos nedospjelih najamnina (bez PDV-a) po ugovorima o operativnom leasingu. Nedospjela potraživanja odnose se na nedospjeli iznos financiranja (nedospjela glavnica) po ugovorima o financijskom leasingu te zajmovima umanjen za ispravak vrijednosti potraživanja.

6 Kod novozaključenih ugovora ugovorena vrijednost u strukturi portfelja operativnog leasinga odnosi se na ukupno ugovoreni iznos koji je jednak ukupnom zbroju najamnina (bez PDV-a) po ugovorima o operativnom leasingu. Financirana vrijednost ugovora kod strukture portfelja financijskog leasinga odnosi se na iznos financiranja kojim se financira primatelj leasinga (glavnica) po ugovorima o financijskom leasingu sklopljenim u izvještajnom razdoblju.

5.1. Imovina, kapital i obveze

Ukupna aktiva leasing društava na dan 31.03.2012. iznosi 24,6 mlrd. kn i manja je za 2,2 mlrd. kn ili 8,3% u odnosu na ukupnu aktivu iskazanu na dan 31.03.2011. godine. U strukturi aktive najznačajniji dio čine potraživanja po osnovi financijskog leasinga u iznosu od 13,3 mlrd. kn ili 54,2% aktive, što je smanjenje za 0,6 mlrd. kn ili 4,6% u odnosu na isti datum prethodne godine. Osim navedenog, smanjenje aktive uvjetovano je značajnim smanjenjem vrijednosti materijalne imovine dane u operativni leasing te potraživanja po operativnom leasingu u iznosu od 1,5 mlrd. kn ili 17,5% te smanjivanjem danih zajmova za 202,4 mil. kn ili 11,3%. Dani depoziti su porasli za 52,3 mil. kn ili 12,6% u odnosu na isto razdoblje prethodne godine.

Tablica 5.1.1. Usporedni prikaz aktive leasing društava na dan 31.03.2011. i 31.03.2012. godine (u kn)

Opis	31.03.2011.	31.03.2012.	Indeks 31.03.2012./ 31.03.2011.
DUGOTRAJNA IMOVINA	19.143.034.313	17.320.671.955	90,48
Nematerijalna imovina	34.777.193	28.274.352	81,30
Materijalna imovina	8.545.232.515	6.937.366.623	81,18
Dugotrajna financijska imovina	987.997.026	815.364.072	82,53
Dugotrajna potraživanja	9.483.255.064	9.418.294.949	99,32
Odgođena porezna imovina	91.772.515	121.371.959	132,25
KRATKOTRAJNA IMOVINA	7.455.053.773	7.107.546.879	95,34
Zalihe	480.736.241	712.205.777	148,15
Kratkotrajna potraživanja	5.027.741.266	4.431.966.677	88,15
Kratkotrajna financijska imovina	1.641.363.586	1.604.714.171	97,77
Novac na računu i blagajni	305.212.681	358.660.253	117,51
Plaćeni troškovi budućeg razdoblja i nedospjela naplata prihoda	202.096.767	158.620.828	78,49
UKUPNA AKTIVA	26.800.184.854	24.586.839.661	91,74

Izvor: HANFA

U strukturi pasive leasing društava na dan 31.03.2012. najveći dio čine obveze za kredite inozemnih banaka i financijskih institucija koje iznose 20,4 mlrd. kn ili 83,0% pasive te bilježe smanjenje od 2,5 mlrd. kn ili 11,1% u odnosu na isti datum prethodne godine. Istodobno obveze za depozite i jamstva po osnovi leasinga iznose 1,2 mlrd. kn ili 4,8% pasive te bilježe pad za 336,3 mil. kn ili 22,1%.

Ukupno iskazani temeljni (upisani) kapital leasing društava na dan 31.12.2011. iznosi 725,7 mil. kn, od čega je udjel kapitala nerezidenata 80,3% ili 582,6 mil. kn.

Tablica 5.1.2. Usporedni prikaz pasive leasing društava na dan 31.03.2011. i 31.03.2012. godine (u kn)

Opis	31.03.2011.	31.03.2012.	Indeks 31.03.2012./ 31.03.2011.
KAPITAL I REZERVE	220.346.766	1.001.399.850	454,47
Upisani (temeljni) kapital	678.768.500	725.748.500	106,92
REZERVIRANJA	75.950.595	102.372.380	134,79
DUGOROČNE OBVEZE	16.755.196.195	14.590.244.578	87,08
KRATKOROČNE OBVEZE	9.266.155.300	8.476.495.400	91,48
Odgođeno plaćanje troškova i prihod budućeg razdoblja	482.535.997	416.327.454	86,28
UKUPNA PASIVA	26.800.184.854	24.586.839.661	91,74

Izvor: HANFA

5.2. Financijski rezultat poslovanja

Na razini djelatnosti leasinga u 2012. iskazana je dobit nakon oporezivanja u iznosu od 126,8 mil. kn, od čega je dobit nakon oporezivanja u iznosu od 139,6 mil. kn ostvarilo 17 društava, dok je gubitak nakon oporezivanja u iznosu od 12,8 mil. kn ostvarilo 8 društava. Na iskazani rezultat poslovanja u značajnoj je mjeri utjecala iskazana dobit od kamata u iznosu 80,1 mil. kn, dok je s osnove provizija i naknada iskazana dobit u iznosu 6,4 mil. kn. Unatoč iskazanom gubitku od neto tečajnih razlika u iznosu od 28,1 mil. kn, s osnova ostalih prihoda i rashoda iskazana je dobit u iznosu od 46,3 mil. kn. U razdoblju od 01.01.2012.-31.03.2012. leasing društva su iskazala povećanje ispravka vrijednosti u iznosu od 150,0 mil. kn te smanjenje/ukidanje ispravka vrijednosti u iznosu 164,0 mil. kn i naplaćena otpisana potraživanja u iznosu od 571,7 tis. kn. Slijedom navedenog, u promatranom razdoblju na razini djelatnosti iskazan je prihod od ukidanja ispravka vrijednosti za gubitke od umanjenje u iznosu 14,8 mil. kn dok je u istom razdoblju prethodne godine iskazan trošak ispravka vrijednosti u iznosu 96,5 mil. kn.

Tablica 5.2.1. Usporedni prikaz računa dobiti i gubitka leasing društava u razdoblju 01.01.-31.03.2011. i 01.01.-31.03.2012. godine (u kn)

Opis	01.01.-31.03.2011.	01.01.-31.03.2012.	Indeks 2012./2011.
Prihodi od kamata	267.101.058	256.328.219	95,97
Rashodi po osnovi kamata	165.347.163	176.277.007	106,61
Dobit/gubitak od kamata	**101.753.895**	**80.051.212**	**78,67**
Prihodi od provizija i naknada	21.718.079	15.188.787	69,94
Rashodi za provizije i naknade	8.667.733	8.835.569	101,94
Dobit/gubitak od provizija i naknada	**13.050.346**	**6.353.219**	**48,68**
Ostali poslovni prihodi	791.722.589	665.567.813	84,07
Ostali poslovni rashodi	690.587.322	619.244.799	89,67
Dobit/gubitak iz ostalih prihoda i rashoda	**101.135.267**	**46.323.014**	**45,80**
Dobit/gubitak prije troškova ispravka vrijednosti za gubitke od umanjenja	215.939.508	132.727.444	61,47
Troškovi ispravka vrijednosti za gubitke od umanjenja (troškovi vrijednosnog usklađenja)	96.487.515	-14.479.801	-
Dobit/gubitak prije poreza na dobit	119.451.993	147.207.245	123,24
Porez na dobit	23.314.806	20.425.623	87,61
Dobit/gubitak nakon poreza na dobit	**96.137.186**	**126.781.622**	**131,88**

Izvor: HANFA

5.3. Struktura portfelja leasing društava

Udjel financijskog leasinga u strukturi broja novozaključenih ugovora razdoblju 01.01.-31.03.2012. iznosi 59,3%, dok udjel operativnog leasinga iznosi 40,7%. Navedena struktura razlikuje se u odnosu na isto razdoblje 2011., kada se na financijski leasing odnosilo 48,7%, a na operativni leasing 51,3% ukupnog broja novozaključenih ugovora.

Došlo je i do promjene u strukturi vrijednosti novozaključenih ugovora. Udjel financijskog leasinga u ukupnoj vrijednosti novozaključenih ugovora porastao je sa 58,4% u prvom tromjesečju 2011. na 68,1% u istom razdoblju 2012. godine, dok se istovremeno udjel operativnog leasinga smanjio sa 41,6% na 31,9%. Prosječna vrijednost novozaključenih ugovora u financijskom leasingu smanjila se sa 208,1 tis. kn u 2011. na 189,5 tis. kn u 2012. godini. Istodobno se prosječna vrijednost novozaključenih ugovora u operativnom leasingu smanjila sa 140,8 tis. kn u 2011. na 129,6 tis. kn u 2012. godini.

Tablica 5.3.1. Broj i vrijednost novozaključenih ugovora u razdoblju 01.01.-31.03.2011. i 01.01.-31.03.2012. godine (u kn)

Leasing društvo	Broj novozaključenih ugovora u razdoblju od 01.01. do		Vrijednost novozaključenih ugovora u razdoblju od 01.01. do	
	31.03.2011.	31.03.2012.	31.03.2011.	31.03.2012.
ALD Automotive d.o.o.	134	180	24.675.794	30.032.389
ALFA LEASING d.o.o.	39	58	5.058.389	7.133.260
AUSTROFIN leasing d.o.o.	158	0	12.359.129	0
BKS - leasing Croatia d.o.o.	68	103	13.203.620	28.008.962
CROATIA LEASING d.o.o.	0	0	0	0
Erste & Steiermärkische S-Leasing d.o.o.	442	612	111.882.049	147.684.153
ERSTE GROUP IMMORENT LEASING d.o.o.	1	0	14.153.025	0
EUROLEASING d.o.o.	203	213	22.470.110	23.284.198
HYPO - LEASING STEIERMARK d.o.o.	86	172	19.674.736	40.948.118
HYPO ALPE-ADRIA-LEASING d.o.o.	10	344	3.340.821	53.754.635
HYPO-LEASING KROATIEN d.o.o.	34	4	4.927.867	1.512.251
i4next leasing Croatia d.o.o.	7	2	6.077.781	4.435.932
IMPULS-LEASING d.o.o.	517	599	72.114.773	90.916.016
KBM Leasing Hrvatska d.o.o.	68	92	17.666.535	24.242.712
Mercedes-Benz Leasing Hrvatska d.o.o.	372	407	79.176.988	75.870.331
OPTIMA LEASING d.o.o.	6	9	451.791	1.092.727
OTP Leasing d.d.	367	410	46.989.767	66.472.499
PBZ-LEASING d.o.o.	345	383	47.830.970	66.006.965
PORSCHE LEASING d.o.o.	775	986	63.772.893	79.546.741
PROleasing d.o.o.	10	0	20.050.466	0
Raiffeisen Leasing d.o.o.	514	515	109.279.126	69.920.539
SCANIA CREDIT HRVATSKA d.o.o.	24	15	6.147.716	7.268.551
SG Leasing d.o.o.	748	162	121.050.120	39.315.154
UniCredit Leasing Croatia d.o.o.	1.231	1.015	220.649.451	198.492.506
VB LEASING d.o.o.	633	862	136.343.369	123.866.216
UKUPNO	6.792	7.143	1.179.347.285	1.179.804.855

Izvor: HANFA

Grafikon 5.3.1. Struktura portfelja leasing društava - usporedba vrijednosti novozaključenih ugovora u razdoblju 01.01.-31.03.2011. i 01.01.-31.03.2012. godine (u mil. kn)

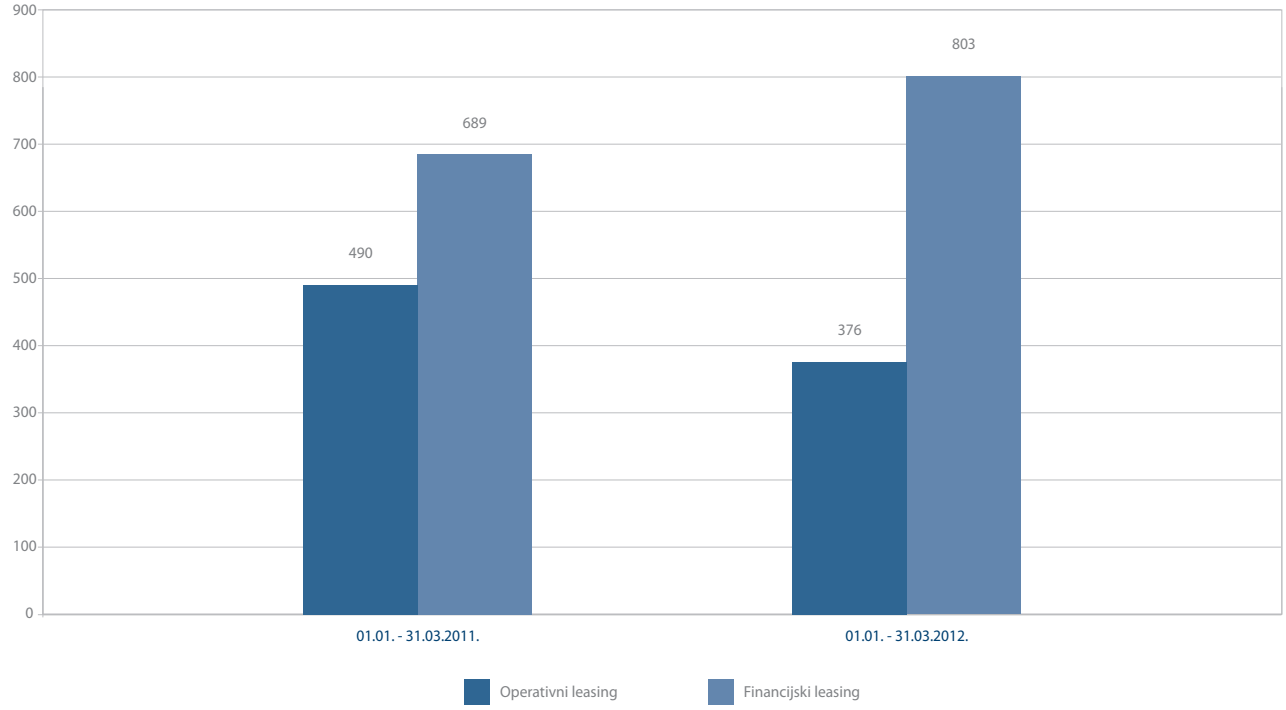

Izvor: HANFA

Broj aktivnih ugovora na dan 31.03.2012. iznosi 136.176 te u odnosu na isti dan prethodne godine bilježi smanjenje od 10.154 ugovora ili 6,9%. Istodobno vrijednost aktivnih ugovora iznosi 18,4 mlrd. kn, što predstavlja smanjenje od 2,3 mlrd. kn ili 11,1% u odnosu na prethodnu godinu.

U strukturi broja aktivnih ugovora udjel financijskog leasinga povećan je sa 46,8% na dan 31.03.2011. na 50,6%, koliko iznosi na dan 31.03.2012. godine. Istovremeno udjel operativnog leasinga u ukupnom broju aktivnih ugovora na dan 31.03.2012. iznosi 46,5%, dok je na dan 31.03.2011. godine iznosio 48,5%. Zajmovi bilježe smanjenje udjela u ukupnom broju aktivnih ugovora sa 4,7% na dan 31.03.2011. na 2,9% na dan 31.03.2012. godine.

U strukturi vrijednosti aktivnih ugovora udjel financijskog leasinga bilježi povećanje sa 63,5%, koliko je iznosio na dan 31.03.2011., na 67,7% na dan 31.03.2012. godine. Udjel operativnog leasinga u ukupnoj vrijednosti aktivnih ugovora iznosi 28,2%, što je smanjenje u odnosu na 31.03.2011., kada je iznosio 31,5%. Udjel zajmova u ukupnoj vrijednosti aktivnih ugovora smanjen je sa 4,9% na dan 31.03.2011., na 4,1% na dan 31.03.2012. godine.

Grafikon 5.3.2. Struktura portfelja leasing društava - usporedba vrijednosti aktivnih ugovora na dan 31.03.2011. i 31.03.2012. godine (u mil. kn)

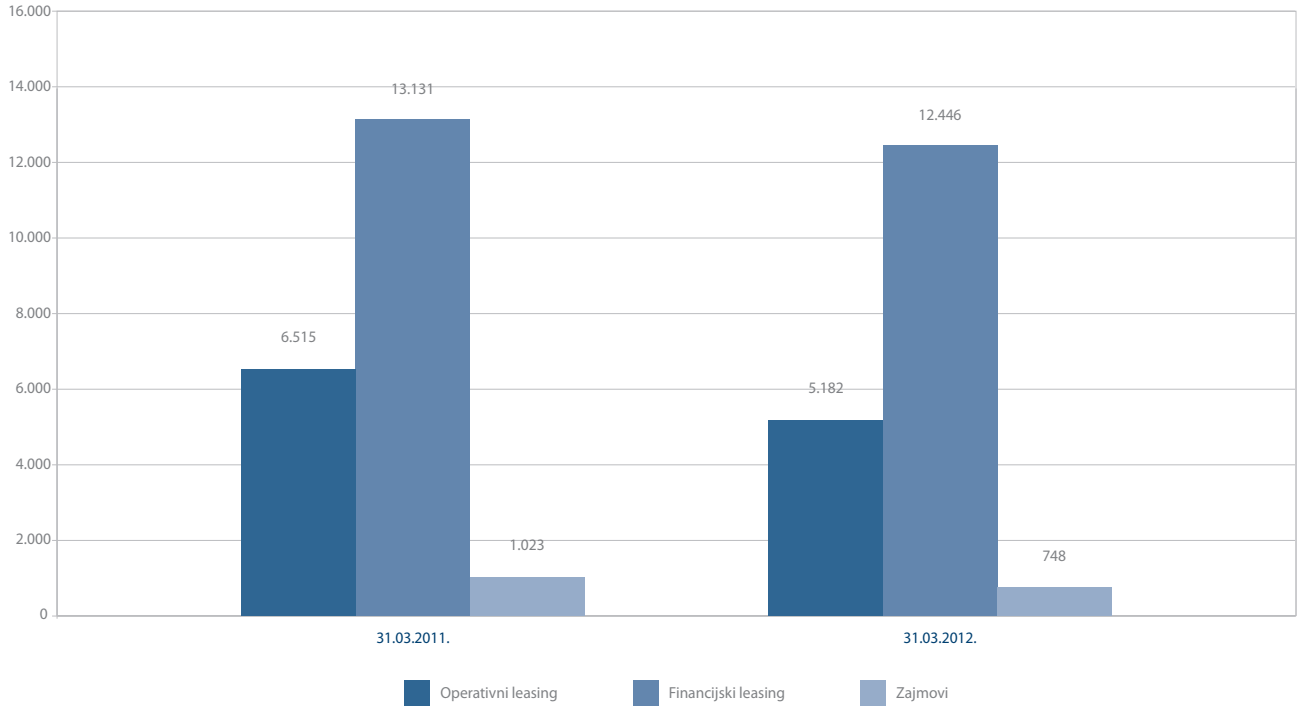

Izvor: HANFA

5.3.1. Struktura portfelja leasing društava prema objektima leasinga/zajma

U strukturi portfelja novozaključenih ugovora prema objektima leasinga u prvom tromjesečju 2012. došlo je do povećanja ukupne vrijednosti novozaključenih ugovora uz istovremeno povećanje ukupnog broja novozaključenih ugovora u odnosu na isto razdoblje prethodne godine. Najveće povećanje vrijednosti novozaključenih ugovora bilježe osobna vozila (za 25,1 mil. kn), dok istovremeno najveće smanjenje vrijednosti novozaključenih ugovora bilježe nekretnine (za 29,3 mil. kn)

Tablica 5.3.2. Broj novozaključenih ugovora leasing društava prema objektima leasinga u razdoblju 01.01.-31.03.2011. i 01.01.-31.03.2012. godine

Objekt leasinga	Broj novozaključenih ugovora u razdoblju				
	01.01.-31.03. 2011.	Udjel	01.01.-31.03. 2012.	Udjel	Indeks 2012./2011.
Nekretnine	24	0,35%	15	0,21%	62,50
Osobna vozila	5.309	78,17%	5.543	77,60%	104,41
Gospodarska vozila	855	12,59%	974	13,64%	113,92
Plovila	56	0,82%	92	1,29%	164,29
Letjelice	0	0,00%	0	0,00%	0,00
Postrojenja, strojevi, transportni uređaji i oprema	407	5,99%	409	5,73%	100,49
Ostalo	141	2,08%	110	1,54%	78,01
UKUPNO	**6.792**	**100,00%**	**7.143**	**100,00%**	**105,17**

Izvor: HANFA

Tablica 5.3.3. Vrijednost novozaključenih ugovora leasing društava prema objektima leasinga u razdoblju 01.01.-31.03.2011. i 01.01.-31.03.2012. godine (u kn)

Objekt leasinga	Vrijednost novozaključenih ugovora u razdoblju				
	01.01.-31.03. 2011.	udjel	01.01.-31.03. 2012.	udjel	Indeks 2012./2011.
Nekretnine	83.579.566	7,09%	54.320.113	4,60%	64,99
Osobna vozila	643.651.725	54,58%	668.748.327	56,68%	103,90
Gospodarska vozila	219.152.619	18,58%	214.785.514	18,21%	98,01
Plovila	52.563.366	4,46%	68.415.078	5,80%	130,16
Letjelice	0	0,00%	0	0,00%	0,00
Postrojenja, strojevi, transportni uređaji i oprema	166.431.230	14,11%	159.971.686	13,56%	96,12
Ostalo	13.968.778	1,18%	13.564.137	1,15%	97,10
UKUPNO	**1.179.347.285**	**100,00%**	**1.179.804.855**	**100,00%**	**100,04**

Izvor: HANFA

Struktura broja i vrijednosti novozaključenih ugovora na razini djelatnosti leasinga prema objektima leasinga u razdoblju 01.01.-31.03.2012. prikazana je sljedećim grafikonom.

Grafikon 5.3.3. Usporedba strukture broja i vrijednosti novozaključenih ugovora prema objektima leasinga u razdoblju 01.01.-31.03.2012. godine (u %)

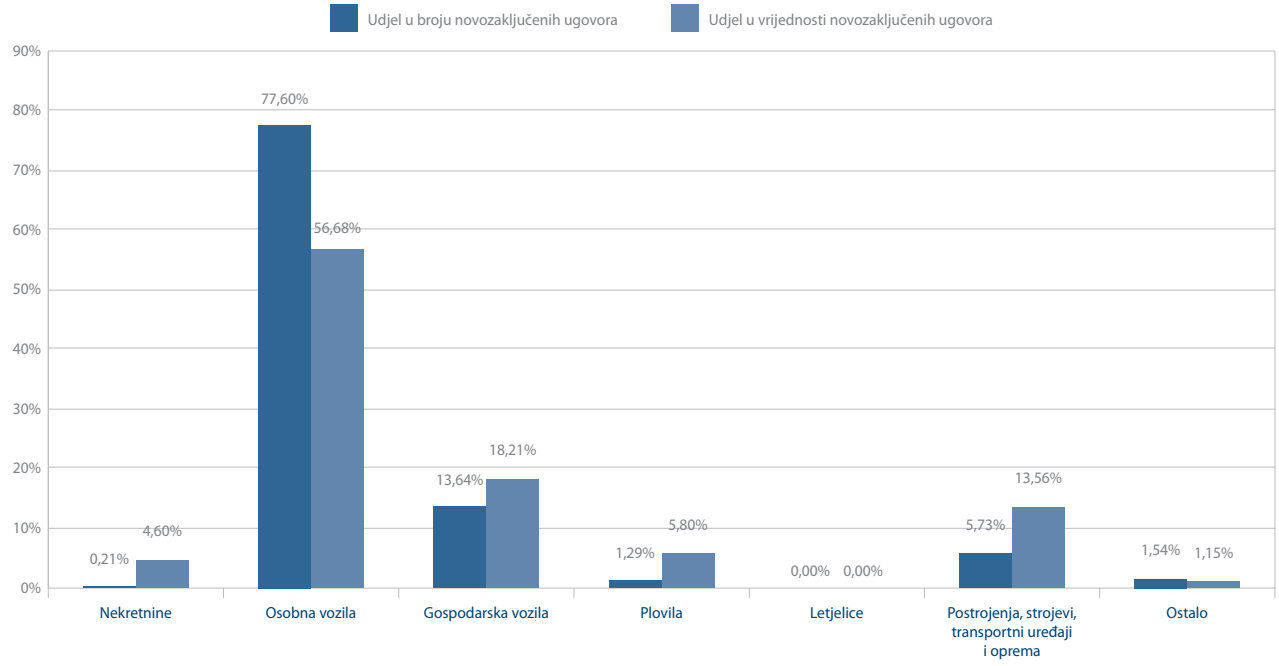

Izvor: HANFA

Najveći broj aktivnih ugovora prema objektima leasinga/zajma na dan 31.03.2012. odnosi se na 96.478 ugovora o leasingu/zajmu za osobna vozila, koji čine 70,8% broja aktivnih ugovora, dok se na gospodarska vozila odnosi 22.768 ugovora, koji čine 16,7% broja aktivnih ugovora.

Najveća vrijednost aktivnih ugovora prema objektima leasinga/zajma na dan 31.03.2012. odnosi se na nekretnine i iznosi 5,9 mlrd. kn ili 32,1% vrijednosti aktivnih ugovora, dok vrijednost aktivnih ugovora za osobne automobile iznosi 5,2 mlrd. kn ili 28,5% vrijednosti aktivnih ugovora.

5.4. Indeksi koncentracije u djelatnosti leasinga u RH

Herfindahl-Hirschmanovi indeksi koncentracije (u daljnjem tekstu: HH indeksi) čine osnovu za sustavno praćenje tržišne strukture, odnosno koncentracije djelatnosti leasinga u Republici Hrvatskoj. Oni su posebno izračunati za aktivu, vrijednost aktivnih i novozaključenih ugovora.

Grafikon 5.4.1. HH indeksi djelatnosti leasinga na dan 31.03.2011. i 31.03.2012.

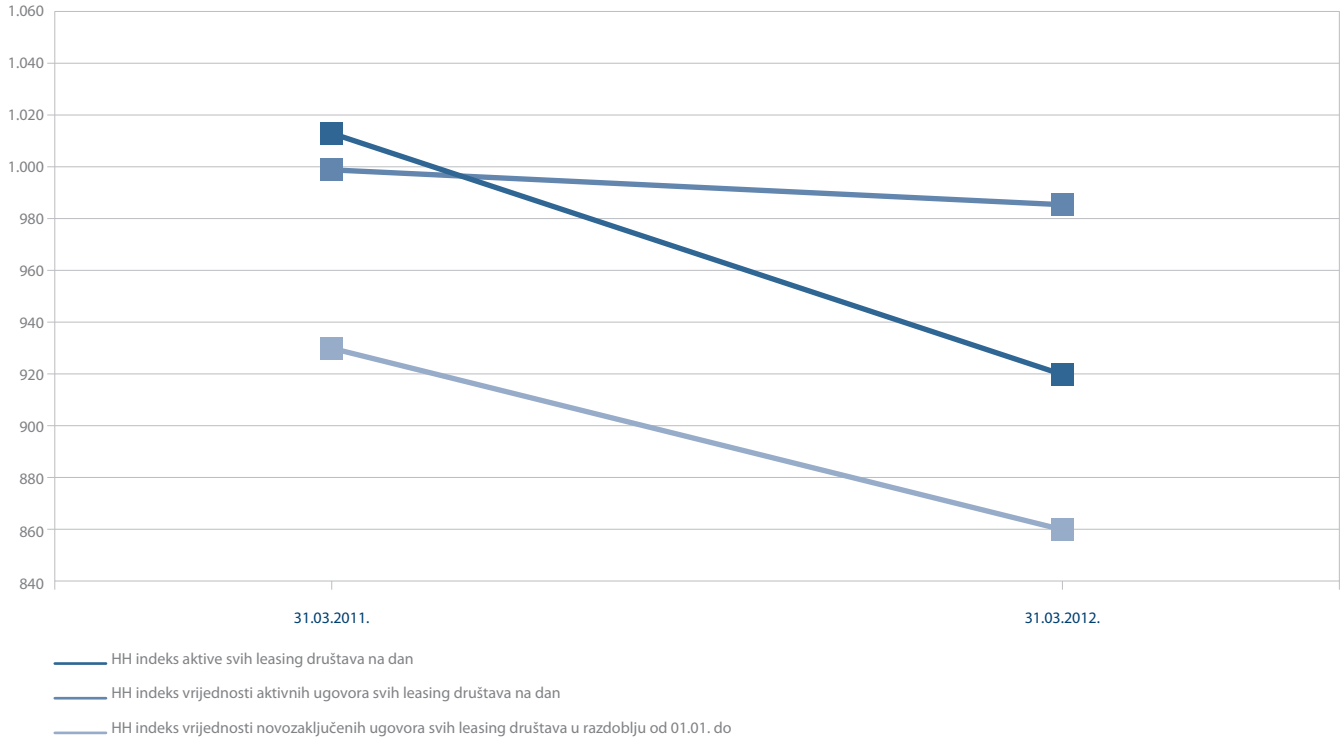

Izvor: HANFA

Koncentriranost tržišta leasinga mjerena HH indeksima koncentracije aktive te vrijednosti aktivnih i novozaključenih ugovora pokazuje trend smanjivanja u prvom tromjesečju 2012. u odnosu na isto razdoblje prethodne godine. Na navedeno su u najvećoj mjeri utjecale promjene u strukturi tržišnih udjela najvećih leasing društava u vrijednosti aktivnih i novozaključenih ugovora te aktivi djelatnosti leasinga po razdobljima.

Impresum

Izdavač:

Hrvatska agencija za nadzor financijskih usluga
Miramarska 24b
10 000 Zagreb
web: www.hanfa.hr
telefon: +385 1 6173 200
fax: +385 1 4811 406

Suradnici:

Ksenija Andelfinger
Jelena Dostal Pilipić
Jadranka Grubešić
Ksenija Jozić
Željko Kovačić
Damir Maričić
Ana Peručić
Jasminka Plenković-Pastuović
Ivana Sivrić

Dizajn

Printera Grupa
www.printera.hr

Printera Grupa

www.printera.hr