OCJENA EFIKASNOSTI DRUŠTAVA ZA OSIGURANJE U HRVATSKOJ METODOM ANALIZE OMEĐIVANJA PODATAKA

Brkljača, Božica

Master's thesis / Diplomski rad

2018

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:287446

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET



DIPLOMSKI RAD

OCJENA EFIKASNOSTI DRUŠTAVA ZA OSIGURANJE U HRVATSKOJ METODOM ANALIZE OMEĐIVANJA PODATAKA

Mentor:

Prof.dr.sc. Maja Pervan

Studentica: Božica Brkljača

Broj indeksa: 2150999

Split, veljača, 2018.

SADRŽAJ:

1. UVOD 2

1.1. Definicija problema 2

1.2. Cilj rada 3

1.3. Metode rada 4

1.4. Struktura diplomskog rada 4

2. TRŽIŠTE OSIGURANJA U RH 6

2.1. Pojam osiguranja i subjekti osiguranja 6

2.2. Vrste osiguranja 10

2.3. Regulatorni i nadzorni okviri 13

2.4. Osiguravajuća društva u Republici Hrvatskoj 15

3. DEA (ANALIZA OMEĐIVANJA PODATAKA) 22

3.1. Modeli AOMP-a 22

3.1.1. CCR 24

3.1.2. BCC 26

3.2. Prethodna istraživanja 28

3.2.1. Prethodna istraživanja u RH 28

3.2.2. Prethodna istraživanja izvan RH 30

4. OCJENA EFIKASNOSTI OSIGURANJA 33

4.1. Pojmovna, prostorna i vremenska definicija uzorka 33

4.2. Metodologija i opis analiziranih varijabli 33

4.3. Analiza efikasnosti društava za osiguranje primjenom metode omeđivanja podataka - empirijsko testiranje hipoteze 36

4.4. Analiza i interpretacija dobivenih rezultata 41

5. ZAKLJUČAK 48

LITERATURA 49

SAŽETAK 57

SUMMARY 57

1. UVOD

1.1. Definicija problema

Goronec (1997) definira osiguranje kao pravni odnos između osiguranika i osiguravatelja u kojem se na načelu zajedničkog snošenja određenog rizika osiguravatelj obvezuje osiguraniku, isplatom određenog novčanog iznosa ili priznanjem nekog drugog prava, nadoknaditi štetu proizašlu iz nastupa osiguranog rizika, a osiguranik se obvezuje da će platiti premiju osiguranju kojom se prikupljuju sredstva za podmirenje prava koja proizlaze iz nastupa osiguranog rizika. Osiguranjem se smanjuju gubici koje pojedinac ima iz nastupa štetnog događaja.

Osiguranje je ekonomski institut društvenog i gospodarskog života kojim se zaštićuje pojedinac, poslovni subjekt i gospodarski razvoj od ekonomski štetnih posljedica prirodnih sila i nesretnog slučaja. Smisao i svrha zaštite ostvaruje se unaprijed prikupljenim sredstvima koja se kasnije koriste za nadoknadu materijalnih i nematerijalnih gubitaka ili šteta (Ćurak i Jakovčević, 2007).

Uloga društava za osiguranje kao zasebne industrije osiguranja u ekonomiji je vrlo bitna. Ona je jedan od katalizatora ekonomskog rasta. Pojedincima i poslovnim subjektima nudi širok spektar proizvoda, a ima i važnu ulogu u financijskom posredovanju što doprinosi financijskom i ukupnom gospodarskom razvoju (Karim i Jhantansana, 2005).

Zbog njihove sve veće uloge u novije vrijeme povećalo se mjerenje efikasnosti društava za osiguranje. Mjerenje se može vršiti na makro i mikro razini. Makro razina podrazumijeva usporedbu osiguranja na razini država, dok mikro razina uspoređuje osiguranja unutar države. U ovom radu će se vršiti usporedba na mikro razini, dakle, na razini države. Mjerenjem efikasnosti dobit će se uvid u konkurentnost različitih društava za osiguranje, kako bi se dobila detaljnija slika o njihovim dobrim ili lošim praksama. Tako bi se postojeći problemi ili nedostaci u nekoj praksi barem djelomično riješili ili ublažili, što bi povoljno utjecalo ne samo na sustav osiguranja neke zemlje, već i na njen cjelokupni gospodarski razvoj (Karim i Jhantansana, 2005).

Kako bi se na istražene dobre ili loše prakse ponudila određena rješenja problema, u istraživanju će se koristit metoda omeđivanja podataka (AOMP), koja je u svijetu prihvaćena kao kvalitetan alat za ocjenu efikasnosti društava za osiguranje te međusobnu usporedbu

društava za osiguranje. Za uspješno korištenje alata potrebno je odabrati adekvatne inpute i outpute na kojima će se temeljiti istraživanje.

S obzirom na izloženo, problem istraživanja ovog diplomskog rada jest ispitati i ocijeniti efikasnost poslovanja osiguravajućih društava u Republici Hrvatskoj primjenom metode analize omeđivanja podataka. Rad će se temeljiti na devet društava za osiguranje koji su aktivno djelovali na području Republike Hrvatske u 2016. godini.

1.2. Cilj rada

Cilj istraživanja je pokazati koja društva za osiguranje se nalaze na granici efikasnosti odnosno koja društva za osiguranje dobro rade svoj posao, te odrediti što bi ostala društva za osiguranje trebala promijeniti u svom poslovanju da dostignu tu granicu. Također, pokazat će se na koje probleme nailaze društva za osiguranje u modernom vremenu i predložiti rješenje tih problema kako bi društva mogla što efikasnije poslovati u današnjem poslovnom okruženju. Cilj istraživanja je i dati odgovore na određena pitanja:

1. Na koje se načine može ocijeniti efikasnost u poslovanju društava za osiguranje?
2. Koja društva za osiguranje posluju efikasno?
3. Poslovanje kojih društava za osiguranje se nalazi ispod granice efikasnosti?

Na temelju postavljenog problema definirana je sljedeća hipoteza diplomskog rada:

H0: Ne postoji statistički značajna razlika u efikasnosti između osiguravajućih društava u Republici Hrvatskoj.

Njoj alternativna hipoteza glasi:

H1: Postoji statistički značajna razlika u efikasnosti između osiguravajućih društava u Republici Hrvatskoj.

Različitosti u efikasnosti između osiguravajućih društava u Republici Hrvatskoj mogu proizaći iz njihove veličine, likvidnosti, starosti, brzini obrada šteta i nekim drugim faktorima.

1.3. Metode rada

Metode istraživanja Zelenika (2000) opisuje kao sve postupke i procese koji se koriste u znanstvenom istraživačkom radu u svrhu pronalaska rezultata istraživanja unutar određenog znanstvenog područja. Istraživanje koje je provedeno unutar ovog rada temelji se na sekundarnim podacima, koje Renko (2009) definira kao podatke koji su prije prikupljeni u nekom drugom istraživačkom projektu, i istraživač ih može koristiti kao gotove analizirane informacije. Oni su dostupni iz nekih vanjskih izvora (izvještajima vlade, online izvora, javnim i sveučilišnim knjižnicama, enciklopedijama itd.).

Kako bi se provelo kvalitetno istraživanje koje će biti u skladu s postavljenom hipotezom i ciljevima rada, koristit će se sljedeće metode istraživanja:

- metoda analize, pomoću koje će se raščlanjivati složeni pojmovi i zaključci na jednostavnije dijelove te izučavati svaki dio istraživanja za sebe u odnosu na druge dijelove rada i naspram njoj metoda sinteze (Zaječaranović,1973),
- metoda dedukcije i metoda indukcije kojom će se donijeti određeni zaključci i tvrdnje.
- povijesna metoda, koja će se koristiti u empirijskom dijelu kako bi pomoću dostupnih podataka i programa Open Source DEA ocijenili efikasnost društava za osiguranje u Hrvatskoj, te
- metoda komparacije pomoću koje će dobiveni podaci svakog osiguravajućeg društva međusobno uspoređivati.

1.4. Struktura diplomskog rada

Diplomski rad je podijeljen u pet poglavlja.

U prvom dijelu rada definirani su problem i predmet istraživanja. Postavljena je glavna i alternativna hipoteza te je objašnjen cilj istraživanja. Navedene su metode koje su korištene u istraživanju i doprinos istraživanja. Na samom kraju poglavlja prikazana je struktura diplomskog rada.

Drugo poglavlje definira pojam osiguranja i svih elemenata vezanih za osiguranje. Objašnjavaju se i članovi koji sudjeluju u osiguranju, odnosno subjekti osiguranja. Također, navode se vrste osiguranja koja postoje u Hrvatskoj. Opisuju se i osiguravajuća društva koja posluju na području Republike Hrvatske te se opisuju regulatorni i nadzorni okvir koji definira osiguravajuća društva i način njihovog djelovanja.

U trećem poglavlju definira se analiza omeđivanja podataka koja se koristi u empirijskom dijelu rada te njezini modeli BCC i CCR. Na kraju ovog poglavlja navode se i prethodna istraživanja koja su proučena i istražena i na temelju kojih se došlo do ideje istraživanja navedene teme.

Četvrto poglavlje odnosi se na empirijski dio rada. U tom poglavlju odabiru se ulazni i izlazni podaci za analizu efikasnosti osiguravajućih društava, navode se empirijski podaci za analizu efikasnosti osiguravajućih društava, odabire se model metode AOMP te se iznose rezultati analize.

U posljednjem poglavlju diplomskog rada prikazana su zaključna razmatranja koja su proizašla iz provedenog istraživanja. Navedena je literatura koja se koristila u radu te popis slika i tablica. Na samom kraju nalazi se sažetak diplomskog rada na hrvatskom i engleskom jeziku.

2. TRŽIŠTE OSIGURANJA U RH

2.1. Pojam osiguranja i subjekti osiguranja

Osiguranje je djelatnost posredstvom koje se na načelu uzajamnosti i solidarnosti pruža ekonomska zaštita od rizika koji ugrožavaju imovinu i osobe (Marović i Mrkić, 1996).

Ćurak i Jakovčević (2007) definiraju osiguranje kao uzajamno namirivanje potreba mnogobrojnih i na isti način ugroženih subjekata, a koje nastaju slučajno i mogu se procijeniti. Sa stajališta društva u cjelini, osiguranje je gospodarski instrument kojim se kombiniranjem i homogeniziranjem rizika sukladno zakonu velikih brojeva smanjuju ukupni gubitci društva planiranom dinamikom troškova i premija.

Osiguranje je metoda transfera rizika s osiguranika na osiguravatelja koji prihvaća da nadoknadi slučajne štete onima kod kojih su nastale i raspodijeli ih na sve članove rizične zajednice na načelima uzajamnosti i solidarnosti (Andrijašević i Petranović, 1999).

Sukladno Zakonu o osiguranju (2016) društvo za osiguranje je pravna osoba sa sjedištem u Republici Hrvatskoj koja obavlja poslove životnog ili neživotnog osiguranja i ima odobrenje Agencije za obavljanje poslova osiguranja i upisana je u sudski registar nadležnog trgovačkog suda.

Osiguranje je, dakle, kompleksan sustav s dva temeljna obilježja:

- prijenos rizika od pojedinca na skupinu ili zajednicu rizika,
- raspodjela gubitaka na sve članove skupine.

Za pojedinca se nikad ne može točno utvrditi hoće li i kada biti izložen ostvarenju nekog štetnog događaja, dok za veći skup pojedinaca nastupanje određenih štetnih događaja može se predvidjeti uz veliku vjerojatnost. Djelatnost osiguranja obavlja se zaključivanjem ugovora o osiguranju i izvršavanjem određenih preuzetih obveza (Rafaj, 2009).

Vaughan (2000) definira osiguranje sa stajališta pojedinca kao ekonomski instrument kojim pojedinac zamjenjuje relativno malu svotu premije za relativno velik i neizvjestan financijski gubitak (neizvjesnost od koje se osiguravamo) koji bi postojao da nema osiguranja.

S motrišta društva, osiguranje je gospodarski instrument za smanjivanje i uklanjanje rizika procesom kombiniranja dovoljnog broja istovjetnih izlaganja u skupinu, kako bi se mogli predvidjeti gubitci za skupinu kao cjelinu (Vaughan, 2000).

Cijena osiguranja je premija osiguranja koja se izračunava na principu velikih brojeva, odnosno vjerojatnosti nastupanja osiguranog slučaja. Premija se prikuplja od velikog broja osoba (ugovaratelja osiguranja) koji se osiguravaju od istog rizika pri čemu je osnovna pretpostavka da će samo mali broj osoba (osiguranika) zaista imati štetu koja može biti materijalna ili nematerijalna.

U slučaju nastupanja osiguranog slučaja odnosno štete, društvo za osiguranje isplatit će odštetu osobi koja se osigurala od tog štetnog događaja (Mishkin i Eakins, 2005).

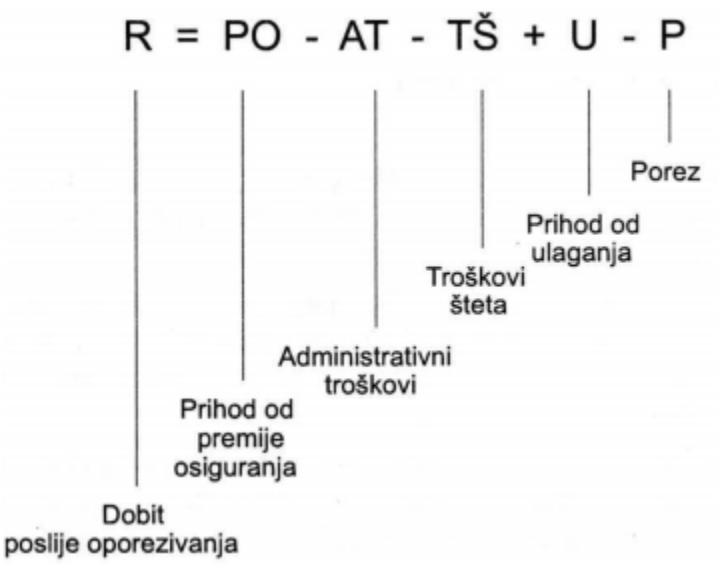
Da bi društva za osiguranje očuvala integritet odnosno postigla stabilnost i kontinuitet u poslovanju, svoj investicijski portfelj moraju oblikovati prema sljedećim načelima:

- osiguravajuće društvo mora imati veliki broj osiguranika tako da rizik može biti raspoređen na veliki broj različitih polica,
- ako treća stranka osiguraniku nadoknadi gubitak, obveza osiguravajućeg društva umanjuje se za iznos te naknade,
- osiguravatelj mora biti sposoban u svakom trenutku ispuniti svoje obveze iz ugovora o osiguranju odnosno isplatiti osigurane svote,
- ugovorne stranke su obvezne dostaviti jedna drugoj potpune i točne podatke,
- u slučaju da se polica osiguranja sklapa za treću osobu, mora postojati veza između osiguranika i korisnika osiguranja,
- osiguravatelj mora voditi brigu da sredstva budu uložena u sigurne plasmane, kako bi mogao pokriti svoje obveze prema osiguranicima, makar i uz niži prinos na ta ulaganja (Mishkin i Eakins, 2005).

Društva za osiguranje pružaju ekonomsku zaštitu pojedincima kao i pravnim subjektima na način da im prodaju police osiguranja za koje naplaćuju premiju osiguranja te iz tako prikupljenih sredstava, uvažajući načela društveno odgovornog poslovanja, kreiraju portfelj životnih i neživotnih osiguranja. Prikupljena sredstva koriste za ulaganja u različite financijske instrumente na tržištima kapitala pri čemu nastoje optimizirati investicijski portfelj kako bi osigurali ispunjenje obveza proizašlih iz sklopljenih polica osiguranja te ispunili očekivanja dioničara o povećanju vrijednosti njihovih dionica (Rafaj, 2009).

Klasić i Andrijanić (2013) navode četiri strane koje sudjeluju u osiguranju, a to su: osiguravatelj, ugovaratelj osiguranja, korisnik osiguranja (osiguranik) i reosiguravatelj.

Prema njima osiguravatelj je društvo za osiguranje (osiguravajuće društvo ili osiguravajuća kompanija) odnosno pravna osoba s kojom je sklopljen ugovor o osiguranju i koja se obvezuje da će ugovaratelju osiguranja, odnosno korisniku osiguranja, u skladu s uvjetima osiguranja nadoknaditi štetu, odnosno isplatiti osigurninu. Njegove glavne obveze su izdavanje police osiguranja i isplata osigurnine, a u životnim osiguranjima i što uspješnije investiranje prikupljenih premija i ostvarenje dobiti, koja se pod dogovorenim uvjetima raspodjeljuje osiguranicima.



Slika 1: Formula uspješnosti osiguravatelja

Izvor: Klasić, K. (2003): Utjecaj psihologije pojedinca na izbor vrsta osiguranja

Kako bi osiguravajuće društvo moglo ostvariti što bolji poslovni rezultat, ono mora povećati prihod od premije osiguranja, smanjiti administrativne troškove i troškove šteta i povećati prihode od ulaganja. Osiguravatelj je obvezan redovito plaćati porezne obveze koje određuje država (Klasić, 2003).

Klasić (2003) definira da je glavna zadaća osiguravajućih društava jest uredno podmirenje obveza iz osiguranja, odnosno isplata šteta svojim osiguranicima i jamstvo da će im osigurani rizici biti isplaćeni ako se i kada dogode, na osnovi uplaćenih premija osiguranja za pokriće tih rizika. Vjera pojedinca da će osiguravatelj biti sposoban isplatiti ugovorenu svotu osiguranja presudna je pri izboru osiguravajućega društva s kojim pojedinac sklapa policu životnog osiguranja na rok od deset i više godina.

Osiguravatelji mogu prihod od premije osiguranja povećati samo ako neprekidno unapređuju prodajnu mrežu, razvijaju jaku podršku prodajnoj mreži, istodobno se koriste različitim kanalima prodaje uz modernu komunikacijsku tehnologiju, prodaju atraktivne i kvalitetne proizvode prihvatljive cijene te neprekidno unapređuju odnose s klijentima (Klasić, 2003).

Klasić i Andrijanić (2013) definiraju ugovaratelja osiguranja kao osobu s kojom je osiguravatelj sklopio osiguranje. Ugovaratelj treba plaćati premiju osiguranja i ispunjavati ostale obveze iz ugovora prema osiguravatelju, ali on nužno ne mora biti i osiguranik.

Osiguranik je osoba iz ugovora o osiguranju kojoj pripadaju prava iz osiguranja. U slučaju njegove smrti ta prava mogu pripasti korisniku osiguranja. Korisnika određuju ugovaratelj u dogovoru s osiguranikom. Tijekom trajanja osiguranja postoji mogućnost i da se polica vinkulira u korist treće osobe na koju se onda prenose prava iz osiguranja. Također osiguranik može biti i ugovaratelj osiguranja pa osim prava iz osiguranja ima i obveze koje mora ispunjavati prema osiguravajućem društvu.

Reosiguravatelj je osiguravajuće društvo koje vrši reosiguranje koje zakon o osiguranju definira kao prenošenje viška rizika iznad samopridržaja društva za osiguranje društvu za osiguranje koje obavlja poslove reosiguranja. Reosiguravatelj se obvezuje da će platiti izravnom osiguravatelju iznos štete koju bi on treba platiti svom osiguraniku, a za uzvrat osiguravatelj plaća određenu premiju reosiguranja reosiguravatelju. Ukratko, reosiguranje je osiguranje osiguravatelja.



Slika 2: Svi sudionici u poslovima osiguranja

Izvor: http://optimarisk.hr/osiguranje-2

2.2. Vrste osiguranja

Osiguranja se mogu klasificirati prema nekoliko kriterija poput: načina pokrića rizika, načinu sklapanja ugovora, predmetu osiguranja, srodnosti rizika, subjektu (ugovaratelju) osiguranja, strukturi premije i prema bilanciranju poslova osiguranja i utvrđivanja rezultata. Vrste osiguranja prema navedenim kriterijima su:

Ćurak i Jakovčević (2007) navode kriterije klasifikacije osiguranja.

Prema načinu pokrića rizika osiguranja imamo podjelu na:

- *Premijsko osiguranje* – formiranje sredstava osiguranja unaprijed za razdoblje trajanja obveza iz osiguranja. Premija se određuje prema veličini rizika i naplaćuje unaprijed.
- *Uzajamno osiguranje* – uplaćuju se predujmovi, što je ujedno i početna uplata, a konačni rezultat se utvrđuje i uplaćuje na kraju ugovorenog trajanja. Članovi uzajamne rizične zajednice obvezuju se unaprijed da će na kraju ugovorenog razdoblja utvrditi ukupnu vrijednost svih šteta za koje su ugovorili zajedničko pokriće i raspodjelu.
- *Socijalno osiguranje* – pokrivaju se razni oblici socijalne zaštite, a sredstva se prikupljaju doprinosima, koji su najvažnije obilježje socijalnog osiguranja.

Prema načinu sklapanja ugovora o osiguranja razlikuju se dobrovoljno i obvezno osiguranje.

- *Dobrovoljno osiguranje* – osiguranje imovine i osoba koje se ugovara slobodnom voljom ugovaratelja. Najčešće su to životna i kasko osiguranja, koja ukazuju na to da postoji svijest pojedinca i zajednice o njihovoj izloženosti rizicima.
- *Obvezno osiguranje* – osiguranje po Zakonu i propisima neke države kojoj je u interesu da razvija zaštitnu funkciju preventive i represije. U interesu zaštite svojih građana država u pravilu propisuje obvezna osiguranja, kao osiguranja od autoodgovornosti, osiguranje putnika u javnom prijevozu, opće odgovornosti itd.

Prema predmetu osiguranja Ćurak i Jakovčević (2007), dijele osiguranje na sljedeće vrste:

- *Osiguranje osoba* – osiguranje kojim se provodi zaštita zdravlja čovjeka, njegove radne sposobnosti i života. U strukturi osiguranja osoba ključno je razlikovati osiguranje osoba od nezgode od osiguranja života. Osiguranje od nezgode se klasificira u skupinu neživotnih osiguranja koja se temelje na izračunu rizikopremije.
- *Osiguranje transporta i kredita*
- *Osiguranje imovine u širem smislu*

- *Osiguranje stvari* – odštetno osiguranje za koje se unaprijed zna konkretno obilježje i vrijednost nekretnine ili pokretnine koja je predmet osiguranja, a u isto vrijeme i premijska osnovica
- *Osiguranje imovinskih interesa* – svotu osiguranja određuje ugovaratelj osiguranja, a osiguratelj isplaćuje stvarnu štetu, ali samo do ugovorenog limita.

Prema srodnosti rizika, osiguranje se dijeli na:

- *Osiguranja imovine u užem smislu*
- *Osiguranja motornih vozila*
- *Osiguranja transporta i kredita*
- *Osiguranja osoba.*

Prema osobnosti ugovaratelja osiguranja, osiguranje se dijeli na:

- *Osiguranje pravnih osoba*
- *Osiguranje fizičkih osoba.*

Prema strukturi premije, osiguranje se dijeli na:

- *Riziko osiguranja*
- *Mješovita osiguranja.*

Imamo i klasičnu podjelu vrste osiguranja prema Zakonu o osiguranju koja dijeli osiguranje na životno i neživotno.

Životno osiguranje je dugoročno i štedno osiguranje na danu svotu kojom se koristi osobno osiguratelj ili se, za slučaj smrti njome koriste njegovi nasljednici. Zato i polica životnog osiguranja u suvremenim financijama dobiva važnost vrijednosnog papira, kvalitetnoga jamstva. Osim toga, životno je osiguranje zbog svoje osobitosti dugoročnosti bitan izvor investicijskog ulaganja značajno vrijednog prinosa.

Životno osiguranje je financijsko pokriće rizika života, vjerojatnosti života. Zajedničko je svim rizicima to što je korisnik osiguranja za slučaj nastupanja osiguranog slučaja obeštećen do ugovorene svote, ili osiguratelj doživljenjem dobiva ukamaćene uplaćene premije.

Životno osiguranje (Ćurak i Jakovčević, 2007*)* dijeli se na sljedeće vrste osiguranja:

1. *osiguranje života*
2. *rentno osiguranje*

3. *dodatna životna osiguranja*
4. *ostala životna osiguranja*
   4.1. tontine
   4.2. osiguranje s kapitalizacijom
5. *osiguranja povezana s ulaganjima u investicijske fondove*

Neživotno osiguranje dijeli se na sljedeće vrste osiguranja:

1. *osiguranje od nezgode* (osiguranje osoba od nezgode pri i izvan redovnog zanimanja, osoba od nezgode u motornim vozilima, djece i školske mladeži, gostiju, izletnika i turista, potrošača, pretplatnika, putnika u javnom prijevozu, ostala osiguranja od posljedica nezgode)
2. *zdravstveno osiguranje* (obvezno osiguranje naknade troškova za slučaj ozljede na radu i profesionalne bolesti, ostala dopunska osiguranja zdravstvenih usluga)
3. *osiguranje cestovnih vozila – kasko*
4. *osiguranje tračnih vozila – kasko*
5. *osiguranje zračnih letjelica – kasko*
6. *osiguranje plovila – kasko*
7. *osiguranje robe u pomorskom, avionskom, kopnenom prijevozu te robe za vrijeme uskladištenja*
8. *osiguranje od požara i elementarnih šteta*
9. *ostala osiguranja imovine* (osiguranje strojeva od loma, provalne krađe i razbojstva, stakla od loma, stvari kućanstva, građevinskih objekata u montaži i izgradnji, informatičke opreme, zaliha u hladnjačama, usjeva i nasada, životinja)
10. *osiguranje od automobilske odgovornosti* (obvezno i dragovoljno te odgovornosti vozača za robu primljenu na prijevoz), osiguranje od odgovornosti za upotrebu zračnih letjelica
11. *osiguranje od odgovornosti u zračnom prometu*
12. *osiguranje od odgovornosti brodara*
13. *ostala osiguranja od odgovornosti* (osiguranje ugovorne odgovornosti izvođača građevinskih radova, montažnih radova, proizvođača za proizvode, odvjetnika, javnih bilježnika, opće odgovornosti, osiguranje troškova pravne zaštite)
14. *osiguranje kredita*
15. *osiguranje jamstva i garancija*

16. osiguranje različitih financijskih gubitaka

17. osiguranje troškova pravne zaštite

18. putno osiguranje.

Neka neživotna osiguranja moramo obvezno sklopiti, a neka su dobrovoljna pa ćemo ih sklopiti ako za njima imamo potrebu i želju. Postoje mnoge vrste obveznih osiguranja, npr. osiguranje vlasnika odnosno korisnika vozila od odgovornosti za štete nanesene trećim osobama (kraće nazvano i osiguranje od automobilske odgovornosti ili autoosiguranje), osiguranje od odgovornosti odvjetnika ili osiguranje od odgovornosti za štetu na okolišu (hanfa.hr).

2.3. Regulatorni i nadzorni okviri

Djelatnost osiguranja u Republici Hrvatskoj reguliraju sljedeći propisi (Rafaj, 2009):

1. Zakon o osiguranju (NN broj 151/05, 87/08, 82/09, 54/13),
2. Zakon o obveznim osiguranjima u prometu (NN broj 151/05, 36/09, 75/09, 76/13),
3. Zakon o Hrvatskoj agenciji za nadzor financijskih usluga (NN broj 140/05, 154/11, 12/12),
4. Zakon o računovodstvu (NN broj 109/07, 54/13),
5. Zakon o trgovačkim društvima (NN broj 111/93, 34/99, 121/99, 50/00, 118/03, 107/07, 146/08, 137/09, 152/11, 111/12, 144/12, 68/13),
6. Zakon o reviziji (NN broj 146/05, 139/08, 144/12),
7. Zakon o obveznim odnosima (NN broj 35/05, 41/08, 125/11),
8. Podzakonski akti doneseni temeljem navedenih zakona.

Prema Rafaj (2009), Zakonom o osiguranju uređeno je „osnivanje i poslovanje društva za osiguranje, društva za reosiguranje, obavljanje poslova unutarnje revizije i revizije društva za osiguranje te obavljanje poslova zastupanja u osiguranju odnosno poslova posredovanja u osiguranju i reosiguranju“. Isto tako, uređena je zaštita potrošača, kao i Hrvatski ured za osiguranje (udruživanje društava za osiguranje).

Zakonima se uređuju uvjeti i način obavljanja poslova u društvima koja se bave osiguranjem imovine i osoba, jednako kao i nadzor nad njihovim poslovanjem, uvjeti i način obavljanja poslova posredovanja i zastupanja u osiguranju ili reosiguranju te nadzor nad obavljanjem tih

poslova. Osiguravajuća društva koja posluju na području Hrvatske obvezna su redovito dostavljati statističke podatke Direkciji za nadzor društava za osiguranje Republike Hrvatske, uključivši podatke o zaračunatoj bruto premiji osiguranja. Direkcija za nadzor ovlaštena je za nadzor poslovanja osiguravatelja i za davanje odobrenja za početak njihova rada, ali i za oduzimanje dozvola za rad kada ocijeni da je to potrebno. Broj osiguravajućih društava u Hrvatskoj naglo je rastao u razdoblju 1991. – 1999. godine, pa se stabilizirao do 2002. godine (Klasić, 2003).

Prema Zakonu o obveznim osiguranjima u prometu (2014), poslove osiguranja u Republici Hrvatskoj obavljaju društva za osiguranje sa sjedištem u Republici Hrvatskoj kao i podružnice stranih društva za osiguranje, koje su dobile dozvolu Hrvatske agencije za nadzor financijskih usluga (HANFA) za obavljanje poslova osiguranja. U širem smislu posao društva za osiguranje svodi se na primanje periodičnih uplata u obliku premije od ugovaratelja osiguranja u zamjenu da će istima nadoknaditi potencijalne buduće štete na osiguranoj imovini ili životu. Prikupljena sredstva osiguratelji investiraju u financijske instrumente odnosno nekretnine, u skladu s odredbama Zakona o osiguranju. Cilj im je ostvariti povrat od tih ulaganja, kako bi u budućnosti mogli podmiriti svoje obveze.

Hrvatska agencija za nadzor financijskih usluga (HANFA) je nadzorno tijelo u čiji djelokrug i nadležnost spada nadzor financijskih tržišta, financijskih usluga te pravnih i fizičkih osoba koje te usluge pružaju.

Hanfa je osnovana 2005. godine spajanjem triju postojećih nadzornih institucija: Komisije za vrijednosne papire, Agencije za nadzor mirovinskih fondova i osiguranja te Direkcije za nadzor društava za osiguranje.

Hanfa je samostalna pravna osoba s javnim ovlastima u okviru svog djelokruga i nadležnosti propisanih Zakonom o Hrvatskoj agenciji za nadzor financijskih usluga i drugim zakonima. Odgovorna je Hrvatskom saboru.

Temeljni su ciljevi Hanfe promicanje i očuvanje stabilnosti financijskog sustava i nadzor zakonitosti poslovanja subjekata nadzora, a u ostvarivanju svojih ciljeva Hanfa se rukovodi načelima transparentnosti, izgradnje povjerenja među sudionicima financijskih tržišta i izvješćivanja potrošača (hanfa.hr).

Hrvatski ured za osiguranje je neprofitna pravna osoba koja u pravnom prometu s trećim osobama predstavlja udruženje društava za osiguranje sa sjedištem u Republici Hrvatskoj.

Poslovi Hrvatskog ureda za osiguranje utvrđeni su Zakonom o osiguranju, Zakonom o obveznim osiguranjima u prometu te drugim propisima:

1. poslovi Udruženja društava za osiguranje sa sjedištem u Republici Hrvatskoj,
2. poslovi predstavljanja i zastupanja interesa društva za osiguranje u međunarodnim institucijama,
3. poslovi nacionalnog Ureda zelene karte osiguranja i druge poslove utvrđene međunarodnim sporazumima o osiguranju vlasnika vozila od odgovornosti za štete nanesene trećim osobama,
4. poslovi vođenja Garancijskog fonda,
5. poslovi provođenja graničnog osiguranja od automobilske odgovornosti,
6. poslovi vođenja Informacijskog centra,
7. poslovi Ureda za naknadu,
8. poslovi statistike osiguranja,
9. poslovi rješavanja pritužbi osiguranika odnosno oštećenih osoba – Pravobranitelj osiguranja,
10. poslovi izvansudskog rješavanja sporova između osiguranika odnosno ugovaratelja osiguranja (potrošača) i društava za osiguranje kao ponuditelja usluge osiguranja – Centar za mirenje.

Ured obavlja i druge poslove od općeg i zajedničkog interesa za djelatnost osiguranja. Tijela upravljanja Hrvatskog ureda za osiguranje su Skupština koju čine predstavnici svih članova Ureda, Upravni odbor kojeg čine članovi Ureda sukladno odredbama Statuta Ureda te direktor Ureda (huo.hr).

2.4. Osiguravajuća društva u Republici Hrvatskoj

Pojam osiguranja te zaštita ekonomskih interesa i zajednice sežu u daleku prošlost. Prvi organizirani oblici izbjegavanja rizika zabilježeni su oko 3000. godina prije Krista. Tada su kineski trgovci prevozili teret preko rijeke Jangtze preko područja u kojima su stijene, vrtlozi i vodene struje ugrožavale plovidbu. Kako bi umanjili mogućnost potonuća i oštećenja robe, prebacivali su je s većih na manje brodove. Ukoliko bi došlo do nesreće, trgovci koji nisu imali štete bi dijelom svoje robe nadoknađivali štetu trgovcima kojima je roba bila oštećena. Tim činom po prvi put provedena je zamisao raspodjela rizika na više manjih.

Prvi pisani tragovi o dvije striktne obveze u slučaju štetnog događaja nalaze su u zakoniku koji je donio babilonski kralj Hamurabi (1729. – 1686. godine prije Krista). Prva obveza je da ako prilikom transporta robe kroz pustinju ista bude oštećena ili ukradena od strane pustinjskih razbojnika, šteta se mora prema načelima solidarnosti raspodijeliti na sve trgovce iz karavane.

Druga obveza odnosila se na graditeljstvo i ukoliko sagrađeni objekt ne bi bio čvrst i dođe do urušavanja to bi značilo smrtnu kaznu za graditelja. U indijskom pravu spominju se začetci osiguranja od kreditnog rizika.

Početci pomorskog prava imaju korijene u zbirci Talmuda (2. – 4. stoljeće) koju čine židovski propisi, predaje i rasprave. Po njemu zajednica brodara trebala je drugom brodaru dati brod ukoliko bi on ostao bez svog.

Tijekom 11. stoljeća dogodio se veliki iskorak u razvoju osiguranja. Pojavljuju se prvi oblici uzajamnog osiguranja i osiguranja od poplave, požara, bolesti i drugi.

1347. godine u obliku javnobilježničke isprave sastavljen je prvi poznati ugovor iz poslova osiguranja. 1384. godine u Pizi je izdana prva polica osiguranja.

Otkriće tržišta Amerike i Indije, dovodi do ekspanzije svjetske trgovine u srednjem vijeku, što je rezultiralo povećanim opasnostima i rizicima. Tada se razvio koncept ekonomske zaštite koji se temelji na premijskom osiguranju. Mnogi trgovci okreću se poslu osiguranja, a za preuzimanje rizika naplaćuju premiju koja mora biti dovoljna za pokriće rizika, troškova i ostvarenje profita. Ta inovacija i danas predstavlja temeljnu filozofiju osiguruteljnog posla u kapitalističkom sustavu.

1690. godine Edward Lloyd u svojoj kavani privlačio je trgovce i brodovlasnike te im nudio najvažnije informacije iz njihovog područja djelovanja. U toj kavani skupljali su se i individualni osiguravatelji koji su se zbog obima posla spojili u prvo osiguravajuće društvo-Lloyd's Underwriters Association. Danas je Lloyd vodeći svjetski osiguravatelj i reosiguravatelj i pokriva tržište od preko 200 zemalja (Ćurak, 2007 i optimarisk.hr).

1884. godine u Zagrebu je osnovana osiguravajuća zadruga Croatia i s njom je započelo osiguranje u Hrvatskoj. U svom početku bavila se osiguranjem od požara za grad Zagreb, a kasnije se proširila na druge vrste osiguranja (fortius.hr).

To društvo je dominiralo na hrvatskom tržištu do 1990. godine, no tada dolaze novi investitori na tržište i u 1994. godini je bilo 12 društava. Najraniji podaci o hrvatskom tržištu osiguranja datiraju iz 1994. godine kada je osnovana Direkcija za nadzor društava za osiguranja odnosno današnja HANFA. Nastavilo se daljnje kretanje broja društava do 2001. godine kada su integracijski procesi zahvatili hrvatsku industriju osiguranja (Tipurić, 2007).

U Hrvatskoj u 2017. godini djeluje 20 osiguravajućih društava. Od toga se 5 bavi životnim osiguranjem, 7 neživotnim, 1 reosiguranjem te 8 složenim. U 2016. godini za koju se radila analiza djelovala su 22 osiguravajuća društva (njih 5 se bavilo životnim, 8 neživotnim, 1 za reosiguranje te 8 složenim osiguranjem).

Tablica 1: Osiguravajuća društva u Hrvatskoj

Društvo za osiguranje	Poslovi osiguranja
AGRAM LIFE osiguranje d.d.	Životno
ALLIANZ ZAGREB d.d.	Složeno
BNP Paribas Cardif osiguranje d.d.	Neživotno
CROATIA osiguranje d.d.	Složeno
CROATIA LLYOD	Reosiguranje
CROATIA zdravstveno	Neživotno
ERGO osiguranje d.d.	Neživotno
ERGO životno osiguranje d.d.	Životno
ERSTE osiguranje Vienna Insurance Group d.d.	Životno
EUROHERC osiguranje d.d.	Neživotno
GENERALI osiguranje d.d.	Složeno
GRAWE Hrvatska d.d.	Složeno
HOK – osiguranje d.d.	Neživotno
Hrvatsko kreditno osiguranje d.d.	Neživotno
IZVOR osiguranje d.d.	Neživotno
JADRANSKO osiguranje d.d.	Neživotno
MERKUR osiguranje d.d.	Složeno
SOCIÉTÉ GÉNÉRALE Group d.d.	Životno
TRIGLAV osiguranje d.d.	Složeno
UNIQA osiguranje d.d.	Složeno
WIENER osiguranje Vienna Insurance Group d.d.	Složeno
WÜSTENORT životno osiguranje d.d.	Životno

Izvor: Izrada autorice prema podacima preuzetim sa www.hanfa.hr

U 2016. godini na tržištu osiguranja dogodio se rast zaračunate bruto premije od 0,4% u odnosu na 2015. godinu i iznosila je 8,76 milijardi kuna.

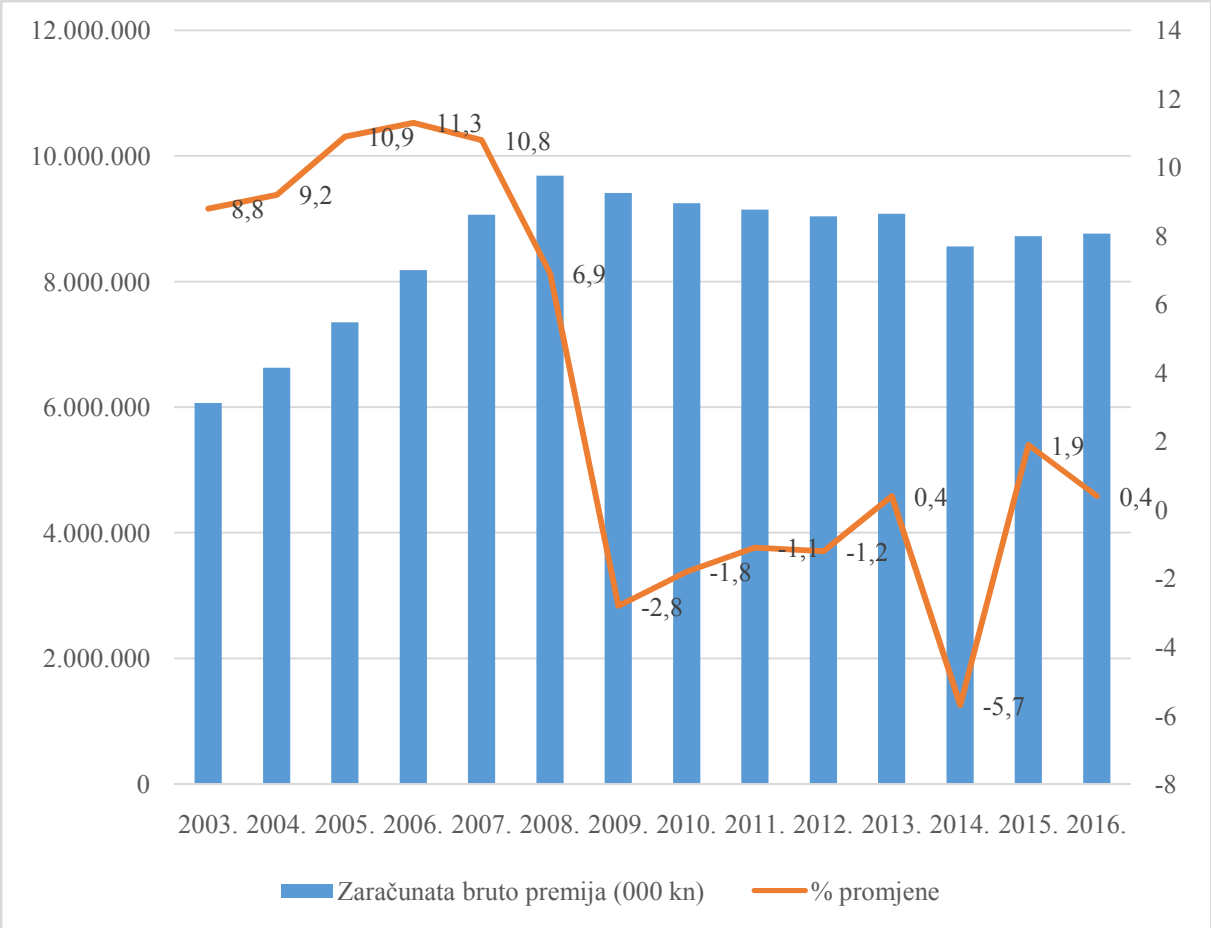
Tablica 2: Zaračunata bruto premija od 2003. do 2016. godine

Godina	Zaračunata bruto premija (000 kn)	% promjene
2003.	6.067.042	8,8
2004.	6.626.867	9,2
2005.	7.350.074	10,9
2006.	8.180.156	11,3
2007.	9.064.932	10,8
2008.	9.686.102	6,9
2009.	9.411.336	-2,8
2010.	9.245.543	-1,8
2011.	9.145.245	-1,1
2012.	9.038.475	-1,2
2013.	9.076.600	0,4
2014.	8.561.358	-5,7
2015.	8.724.673	1,9
2016.	8.761.130	0,4

Izvor: Izrada autorice prema podacima preuzetim iz financijskih izvještaja društava za osiguranje

U razdoblju od 2003. do 2009. godine ukupna zaračuna bruto premija je rasla. Od 2009. godine tržište osiguranja doživljava pad zaračunate bruto premije te je do kraja 2015. izgubljeno 9,69 milijardi kuna zaračunate bruto premije zbog utjecaja financijske i gospodarske krize.

Premije u 2016. godini rastu za 336.457.000 kuna, u odnosu na prethodnu godinu. U 2008. godini ukupna zaračunata bruto premija bila je najveća od promatranih razdoblja i iznosila je 9,67 milijardi kuna.



Graf 1: Zaračunata bruto premija od 2003. do 2016. godine

Izvor: Izrada autorice prema podacima preuzetim iz financijskih izvještaja društava za osiguranje

Tablica 3: Zaračunate bruto premije životnog i neživotnog osiguranja

Godina	Životno (000 kn)	% promjene	Neživotno (000 kn)	% promjene
2003.	1.349.981	17,1	4.717.061	6,6
2004.	1.569.421	16,3	5.057.446	7,2
2005.	1.895.769	20,8	5.454.305	7,8
2006.	2.165.061	14,2	6.015.094	10,3
2007.	2.482.743	14,7	6.582.189	9,4
2008.	2.545.775	2,5	7.140.327	8,5
2009.	2.488.675	-2,2	6.922.661	-3,0
2010.	2.457.683	-1,2	6.787.860	-1,9
2011.	2.431.268	-1,1	6.713.977	-1,1
2012.	2.461.154	1,2	6.577.321	-2,0

2013.	2.538.414	3,1	6.538.186	-0,6
2014.	2.637.784	3,9	5.923.573	-9,4
2015.	2.934.421	11,2	5.790.252	-2,3
2016.	2.918.441	-0,5	5.842.689	0,9

Izvor: Izrada autorice prema podacima preuzetim s www.huo.hr

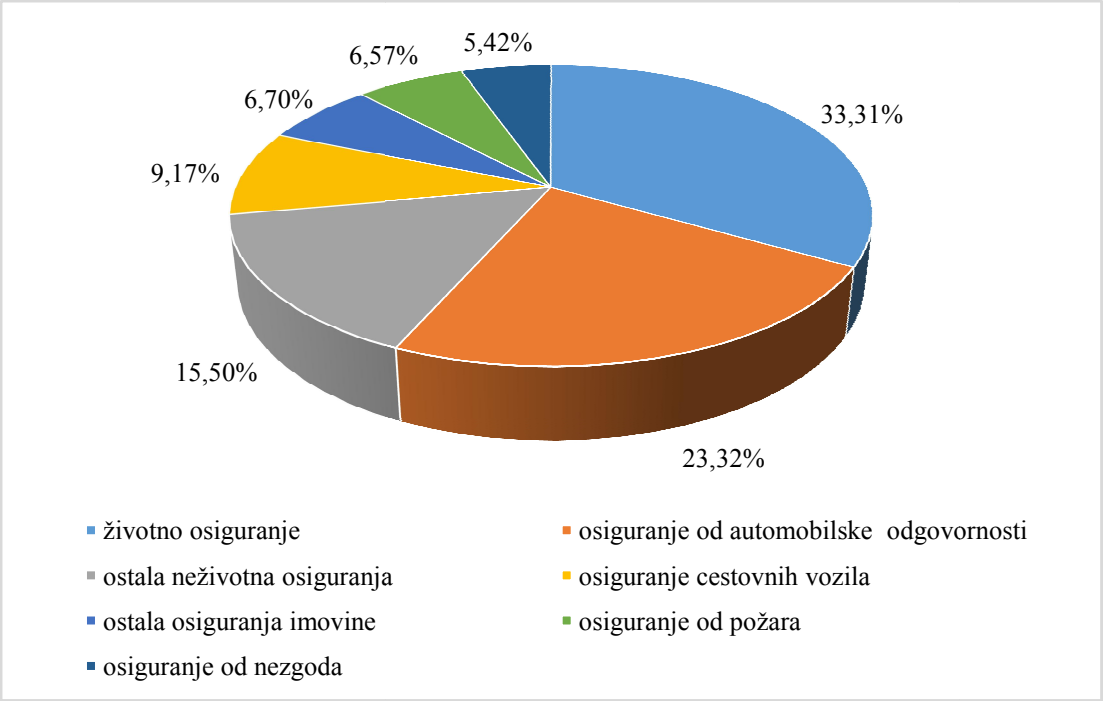
Zaračunate bruto premije neživotnog osiguranja rasle su u razdoblju od 2003. do 2009. godine. Tada počinju padati i taj pad se ne zaustavlja sve do 2016. godine. U 2016. godini događa se tek blagi rast u odnosu na 2015. godinu od 0,9% te zaračunata bruto premija je iznosila 5,84 milijarde kuna (udio od 66,67% u ukupnoj premiji).

Zaračunate bruto premije životnog osiguranja također su rasle u razdoblju od 2003. do 2009. godine. Pad premije životnog osiguranja od 2009. godine, zaustavljen je u 2012. godini. U narednim godinama dogodio se rast pa su premije u 2015. godini narasle za čak 11,2%. U 2016. godini dolazi do blagog pada na tržištu životnog osiguranja od 0,5% i tada bruto premija je iznosila 2,92 milijarde kuna.

Udio ukupne premije u BDP-u za 2016. godinu iznosio je 2,6%, što ukazuje da Hrvatska zaostaje u usporedbi s razvijenim zemljama Europske Unije.

Ukupna premija po stanovniku u 2016. godini iznosila je 2.100 kuna (1.400 kn za neživotno osiguranje i 700 kn za životno osiguranje). Po ovom pokazatelju Hrvatska također zaostaje za razvijenim zemljama Europske Unije što ukazuje na potencijal daljnjeg rasta tržišta osiguranja (huo.hr).

Po strukturi ukupne premije osiguranja, najznačajniju skupinu predstavljaju životna osiguranja s udjelom od 33,31% (2,92 milijarde kuna). Slijedi ga osiguranje od automobilske odgovornosti s udjelom od 23,32% (2,04 milijarde kuna). Ono nastavlja imati trend pada koje je rezultat liberalizacije cijena na tržištu. Iza njega nalaze se ostala neživotna osiguranja s 15,50%, osiguranje cestovnih vozila s 9,17%, ostala osiguranja imovine s 6,70%, osiguranje od požara i elementarnih šteta s 6,57% te osiguranje od nezgode s 5,42%.



Graf 2: Struktura ukupne premije osiguranja

Izvor: Izrada autorice prema podacima preuzetim s www.huo.hr

U 2016. godini u ukupno zaračunatoj bruto premiji, Croatia osiguranje d.d. zauzima vodeće mjesto s ukupnom premijom od 2.268.662.137 kn i ima udjel od 25,90%. Na drugom mjestu nalazi se Allianz Zagreb d.d. s udjelom od 12,74% i ukupnom premijom od 1.116.062.876 kn, a Euroherc osiguranje d.d. našlo se na trećem mjestu s udjelom od 9,62% i ukupnom premijom od 842.516.304 kn.

3. DEA (ANALIZA OMEĐIVANJA PODATAKA)

3.1. Modeli AOMP-a

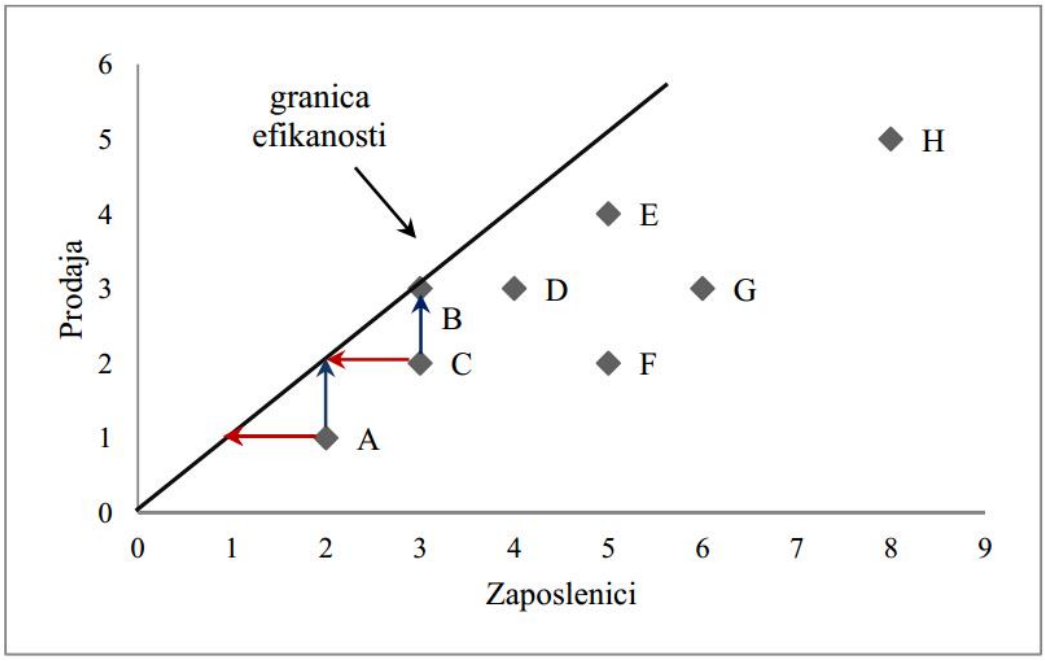
U ovom diplomskom radu će se pomoću metode analize omeđivanja podataka (skraćeno AOMP ili AOP) ili na engleskom poznate kao Data Envelompent Analysis (skraćeno DEA) ocijeniti efikasnost 9 društva za osiguranje.

Model CCR je prvi model AOMP-a koji se pojavio 1978. godine u radu koji je objavljen u European Jornual of Operational Research. Charnes, Cooper i Rhodes su predstavili kvantitativni model za procjenu relativne efikasnosti donositelja odluka (DO) u kojem je moguće obuhvatiti više ulaza i više izlaza pri čemu se u njihovom najpovoljnijem omjeru određuju ekstremne točke izlaza s obzirom na raspoložive ulaze (Cooper i Ray, 2008).

Rabar (2010) definira analizu omeđivanja podataka (AOMP) kao neparametarsku metodu koja se zasniva na linearnom programiranju, a njome se koristi za ocjenjivanje relativne efikasnosti usporedivih entiteta na osnovi empiričkih podataka o njihovim inputima i outputima.

Analiza omeđivanja podataka jest skup modela i metoda zasnovanih na matematičkom programiranju. Podaci o korištenim inputima i outputima uvrštavaju se za sve promatrane donositelje odluke (DO) u linearni program koji predstavlja odabrani model AOMP. Na taj se način ocjenjuje efikasnost pojedinoga DO unutar skupa usporedivih DO, tj. takvih koji pretvaraju višestruke inpute u višestruke outpute istovrsne kao i one promatranoga DO.

Budući da se efikasnost pojedinoga DO mjeri u odnosu na druge DO, govorimo o relativnoj efikasnosti iznos koje se kreće između 0 i 1, a njegova se odstupanja od jedinice pripisuju višku inputa ili manjku outputa.



Slika 3: Grafički prikaz primjera AOMP

Izvor: Bogović, T. (2014): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP)

AOMP određuje empirijsku granicu efikasnosti (granicu proizvodnih mogućnosti) omeđujući inpute odozdo, a outpute odozgo, a kako je određuju (najbolji) postojeći DO, granica efikasnosti predstavlja ostvariv cilj kojemu moraju težiti neefikasni DO. Oni efikasnost postižu projekcijom na efikasnu granicu. Tako se, za razliku od tipičnih statističkih pristupa koji se zasnivaju na prosječnim vrijednostima, AOMP bazira na ekstremnim opažanjima, uspoređujući svaki DO samo s onim najboljima.

Na primjeru gdje se kao input koriste zaposlenici, a output prodaja, točka B predstavlja efikasnu jedinicu, dok su ostale jedinice neefikasne. Ukoliko jedinica A želi dostići granicu efikasnosti, trebala bi povećati output (prodaja) na 2 ili smanjiti input (zaposlenici) na 1.

Analiza omeđivanja podataka obuhvaća skup metoda i modela koji pripadaju području matematičkog programiranja, u glavnu svrhu ocjene učinkovitosti različitih jedinica koje se promatraju. Uobičajen nazivi za te jedinice jesu donositelji odluke (decision making units), pri čemu svaka koristi jedan ili više inputa u svrhu proizvodnje jednog ili više outputa. Informacije o tim inputima i outputima se koriste u modelima koji ocjenjuju relativnu efikasnost svih analiziranih donositelja odluka, s obzirom da se efikasnog jednog mjeri u odnosu na druge donositelje odluka. Iako relativno mlado područje operacijskih istraživanja,

analiza omeđivanja podataka posljednjih nekoliko godina postaje sve popularnija u istraživanju efikasnosti različitih jedinica promatranja (Škrinjarić, 2013).

3.1.1. CCR

Charnes-Cooper-Rhodesov model (CCR model) je jedan od osnovnih i najčešće primjenjivanih modela koji se temelji na pretpostavci o konstantnim prinosima. To znači da izvedivost aktivnosti (X,Y) povlači izvedivost aktivnosti (X_t, Y_t) za svaki pozitivan broj t. Osnovna ideja modela je sljedeća. Za svakog donositelja odluka formiraju se, pomoću težina outputa (u_r) (r = 1, ..., s) i težina inputa (v_i) (i = 1, ..., m), virtualni *output* i *input*. Cilj je određivanje težina koje maksimiziraju njihov omjer.

Charnes, Cooper i Rhodes su predložili model za optimizaciju svakog DO koji se može izraziti kao:

$$Max\ h_{k=} \sum_{j=1}^{n} \mu_j y_{jk} \Big/ \sum_{i=1}^{m} v_i x_{ik}$$

uz uvjet da:

$$\sum_{j=1}^{n} \mu_j y_{jk} \leq \sum_{i=1}^{m} v_i x_{ik}$$

odnosno:

$$\sum_{j=1}^{n} \mu_j y_{jk} \Big/ \sum_{i=1}^{m} v_i x_{ik} \leq 1$$

pri čemu:

$$\mu_j \geq 0, \qquad j = 1, 2, \dots, n; kao\ i\ \mu_j \geq \varepsilon$$

$$v_i \geq 0, \qquad i = 1, 2, \dots, m; kao\ i\ v_i\ \geq \varepsilon$$

gdje je:

h_k relativna učinkovitost k-te DO

k broj jedinica odlučivanja

m broj ulaza (*x*)

n broj izlaza (*y*)

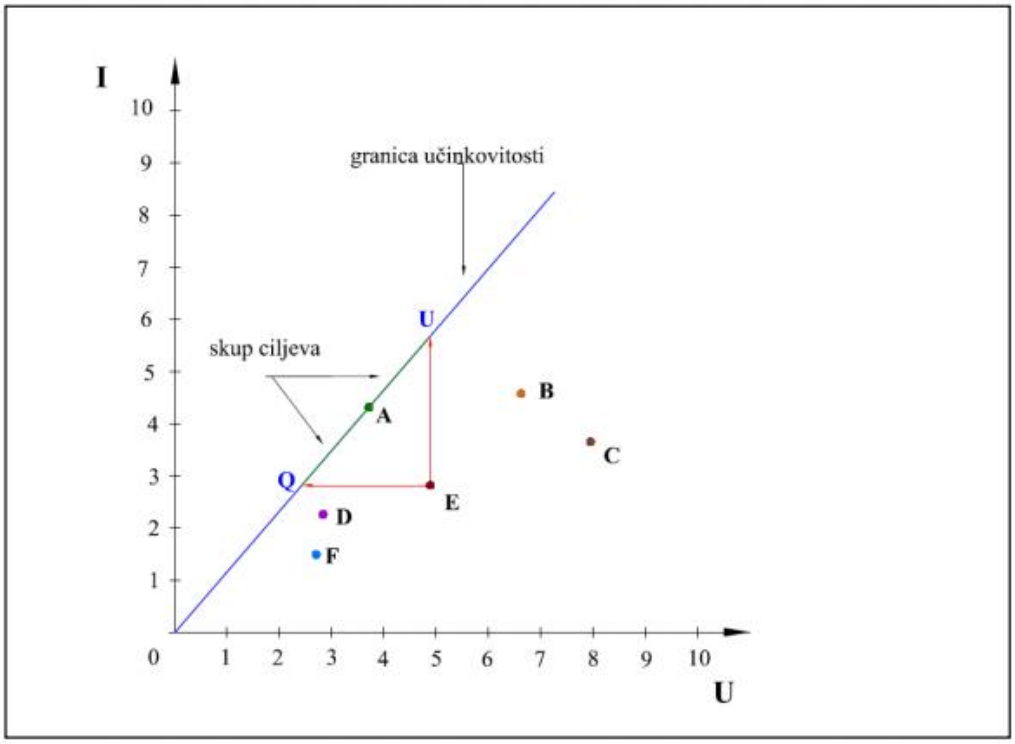
v težinski koeficijent ulaza (*x*)

μ težinski koeficijent izlaza (*y*)

ε mala pozitivna vrijednost (najčešće $\varepsilon = 10^{-6}$)

H_k nalazi se između 0 i 1. ukoliko je h_k=1, tada je *k*-ti DO relativno učinkovit. Ako je h_k manji od 1, onda je *k*-ti DO relativno neučinkovit. Vrijednost h_k pokazuje koliko je potrebno povećati rezultate ili smanjiti potrošnju resursa kako bi *k*-ti DO postao učinkovit. Učinkovitost svakog DO-a je maksimizirana odabirom optimalnih težinskih koeficijenata za svaku varijablu, a DO je učinkovit ako ne postoji ni jedan drugi DO iz promatranog skupa, koji sa svojim optimalnim težinskim koeficijentima i njegovim ulazima postiže bolje izlaze.

Granica efikasnosti takvoga modela prikazana je na primjeru s jednim inputom i jednim outputom (Bogović, 2014).



Slika 4: Prikaz granice efikasnosti prema CCR modelu

Izvor: Bogović, T. (2014): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP)

Na slici 4. granicu učinkovitosti definira DO „A“ koja je označena pravcem. Donositelji odluka (B, C, D, E, F) nalaze se ispod granice učinkovitosti. Nju mogu dostići ukoliko smanje svoje inpute ili povećaju svoje outpute.

Prema input usmjerenom CCR modelu, točka Q predstavlja točku na granici učinkovitosti za DO „E“, a točka U predstavlja točku na granici učinkovitosti prema output usmjerenom CCR modelu (Bogović, 2014).

3.1.2. BCC

U slučaju rastućega ili opadajućega prinosa, kod kojega proporcionalno povećanje inputa rezultira više ili manje nego proporcionalnim povećanjem outputa, radi se o varijabilnom prinosu kod kojega valja odabrati model BCC (Banker - Charnes-Cooperov model).

Model BCC objavljen je u članku *Management Science* 1984. godine. BCC modelom mjerimo čistu tehničku efikasnost tako što se j-ta jedinica DO-a uspoređuje samo s jedinicama sličnog opsega (Bogović, 2014).

Može se definirati sljedećim izrazom:

$$(Max)h_k = \sum_{j=1}^{n} \mu_j y_{jk} + u_*$$

$$\sum_{i=1}^{m} v_i x_{ik} = 1$$

$$\sum_{j=1}^{n} \mu_j y_{jk} - \sum_{i=1}^{m} v_i x_{ik} + u_* \leq 0, \qquad k = 1, 2, \dots, n$$

$$\mu_j \geq \epsilon, \qquad j = 1, 2, \dots, n \quad i \quad v_i \geq \epsilon, \qquad i = 1, 2, \dots, m$$

gdje je:

h_k – rezultat učinkovitosti *k*-te jedinice DO-a,

y_j predstavlja *j*-ti izlaz (*output*) *k*-tog DO,

x_i je težinski koeficijent *i*-tog ulaza (*inputa*),

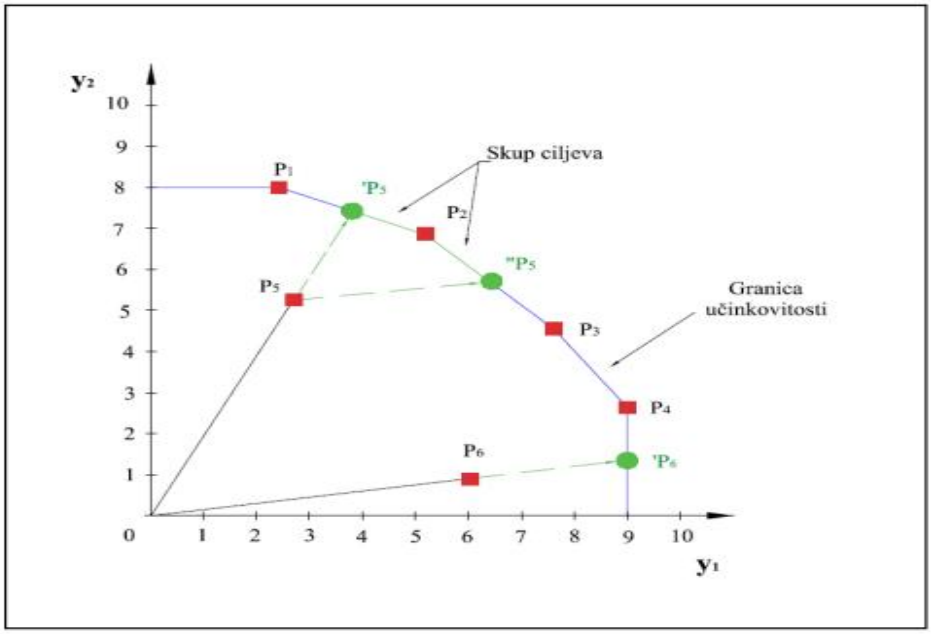
μ_j je težinski koeficijent *j*-tog izlaza,

n broj izlaza

m broj ulaza

u_* je dodatna varijabla koja definira utjecaj opsega poslovanja.

BCC modelom analizira se učinkovitost jedinica koje ostvaruju varijabilni prinos u odnosu na opseg. Granica efikasnosti u ovome slučaju je konveksna krivulja.



Slika 5: Granica efikasnosti prema BCC modelu

Izvor: Bogović, T. (2014): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP)

Na slici je prikazana analiza omeđivanja podataka u skupu od šest jedinica (P_1, P_2, ... P_6) koje djeluju u sličnim okolnostima, koristeći se istom količinom resursa za proizvodnju različitih količina učinaka (y_1 i y_2).

Učinkovitije su one jedinice koje za određeni iznos ulaza (resursa) pružaju veći iznos izlaza (učinaka). Analiza omeđivanja podataka identificirala je jedinice P_1, P_2, P_3 i P_4 kao efikasne i one određuju granicu učinkovitosti ispod koje se nalaze jedinice P_5 i P_6 koje su neučinkovite. Za jedinicu P_6 proporcionalno povećanje izlaza dovodi do ciljeva $'P_6$, međutim P_4 unatoč tomu jasno dominira jer ostvaruje istu razinu y_1, ali veću razinu y_2 izlaza. U tome slučaju povećanje izlaza mora biti dopunjeno proporcionalnim porastom izlaza y_2.

U tome okviru moguće je procijeniti ex post (ne)učinkovitost određenoga entiteta pomoću njegove udaljenosti do empirijske granice učinkovitosti. DO koji se nalazi na granici je učinkovit dok su svi ostali ispod granice neučinkoviti.

Neučinkoviti DO svoju efikasnost postiže projekcijom na granicu efikasnosti, a nju može postići reduciranjem ulaza (resursa) ili povećanjem izlaza (rezultata). Za svaki neučinkoviti DO postoji veliki broj rješenja kako bi poboljšale učinkovitost.

Učinkovitost prema CCR modelu je uvijek manja ili jednaka učinkovitosti koju daje BCC model, odnosno svaki DO koji je učinkovit prema CCR modelu, učinkovit je i prema BCC modelu, dok obrnuto ne vrijedi (Bogović, 2014).

3.2. Prethodna istraživanja

Model AOMP je važan operativni alat koji se može koristiti za analizu učinkovitosti u privatnom i javnom sektoru. Koristi se za ocjenu efikasnosti poduzeća, država, gradova, dioničkih fondova, fakulteta, bolnica i u mnogim drugim područjima.

3.2.1. Prethodna istraživanja u RH

Iako će uskoro proći četrdeset godina otkad je model AOMP-a prvi put upotrijebljen, u Republici Hrvatskoj se njegova primjena očituje tek zadnjih petnaestak godina.

Metoda omeđivanja podataka postaje sve popularnija metoda za ocjenu efikasnosti u raznim područjima. Do sada se analiza omeđivanja podataka primjenjivala u analiziranju efikasnosti poslovanja hrvatskih bolnica (Rabar, 2010), šumarstva (Šporčić et al., 2008), ocjenjivanja efikasnosti hrvatskih županija s aspekta turizma (Rabar i Blažević, 2011) i drugih gospodarskih grana.

Kratki pregled navedenih, ali i drugih istraživanja dan je u nastavku.

Jurjević i Žaja (2013) mjerili su efikasnost banaka i osiguravajućih društava putem AOMP-a u razdoblju prije i nakon izbijanja financijske krize u Republici Hrvatskoj. Za inpute su koristili neto operativne troškove, troškove investiranja i nastale štete, a za outpute su koristili zarađenu premiju i prihod od ulaganja. Analiza se provodila u razdoblju od 2005. do 2010. godine. i najnižu vrijednost je pokazala u 2007. godini.

Rabar (2010) je analizirala efikasnost poslovanja hrvatskih bolnica putem AOPM-a. U radu je koristila broj liječnika i broj postelja kao inpute te broj slučajeva bolničkog liječenja i broj dana bolničkog liječenja kao outpute. Prema CCR metodi 8 bolnica je identificirano kao efikasno, a prema BCC njih 19.

Šporčič et al. (2008) putem AOMP-a analizirali su efikasnost radnih jedinica u šumarstvu. Kao inputi korišteni su broj zaposlenika i broj radnih sredstava (ukupan broj mehaniziranih sredstava za rad), a za outpute količina opasnog otpada i dobit/gubitak radnih jedinica. Analiza obuhvaća 13 radnih jedinica. Prema CCR modelu efikasne su samo 2 jedinice, dok je prema BCC modelu efikasno njih 7.

Rabar i Blažević (2011) analizirali su efikasnost hrvatskih županija s aspekta turizma pomoću metode omeđivanja podataka. U radu za inpute koristili su broj sjedala, broj postelja i broj zaposlenika, a za outpute broj dolazaka, broj noćenja i iznos prometa u tisućama kuna. Prema CCR metodi 10 županija je ocijenjeno kao efikasno, dok BCC metoda ocjenjuje njih 13 kao efikasno.

Bogović (2014) je metodu analize omeđivanja podataka koristio kod ocjene učinkovitosti upravljanja hrvatskim gradovima. Istraživanje je provedeno na populaciji petnaest velikih gradova na temelju 3 inputa (stopa nezaposlenosti, prosječne plaće, investicijski potencijal) i 4 outputa (porez i prirez na dohodak, komunalni doprinos i druge naknade, prosječan broj radno aktivnog stanovništva, dohodak po stanovniku). CCR modelom 6 velikih gradova od 15 je efikasno. To su Dubrovnik, Pula, Slavonski Brod, Varaždin, Velika Gorica, Vinkovci. Iste rezultate dao je i BCC model.

Korent et al. (2015) primjenom AOMP-a identificirali su efikasne županije koje predstavljaju primjere dobre prakse u poduzetništvu (benchmarking) te neefikasne hrvatske županije. Za analizu su korišteni ukupni rashodi i investicije u dugotrajnu imovinu kao inputi, a ukupni prihodi i priznati patenti kao outputi. Prema BCC modelu, 9 županija je efikasno, a prema CCR modelu 4.

Šegota (2008) je analizirala 57 trgovina maloprodajnog lanca. Za analizu je korišteno 7 inputa (vrijednost robe, prosječan broj zaposlenih na puno radno vrijeme, veličina prodajnog prostora, prosječno stanje zaliha, broj blagajni, trošak rada, ostali troškovi poslovanja) te 3 outputa (prodaja, ostvarena marža, profit). CCR model je pokazao da je 13 trgovina efikasno, a BBC model 19.

Jemrić i Vujćić (2002) pomoću metode analiziranja podataka ocjenjivali su učinkovitost hrvatskih banaka u periodu od 1995. do 2000. godine. Dobili su rezultat da su veće banke lokalno učinkovitije, a manje globalno te da su novije banke učinkovitije od starih.

3.2.2. Prethodna istraživanja izvan RH

Metoda analize omeđivanja podataka koristi se za ocjenu efikasnost raznih gospodarskih grana, kako u svijetu tako i u Europi. U sljedećoj tablici navedeni su recentni radovi u analizi industrije osiguranja.

Tablica 4: Recentni radovi u analizi industrije osiguranja

Autor / godina	Naslov rada	Input	Output	Vrsta osiguranja
Tihana Škrinjarić (2016)	Analiza relativne efikasnosti industrije osiguranja europskih zemalja korištenjem analize omeđivanja podataka	udio zaposlenih, isplaćene premije, broj poslovnica	naplaćene premije, uložena sredstva u investicijske portfelje, udio naplaćenih premija u bdp-u	složeno
Anirban Dutta (2013)	Impact of Privatization on Productivity: A Non-Parametric Analysis of Indian Insurance Sector	troškovi rada, troškovi materijala i poslovnih usluga, ukupna ulaganja	zarađene premije, prihod od ulaganja	složeno
Sumninder Kaur Bawa, Miss Ruchita (2011)	Efficiencies of Health Insurance Business in India: An Application of DEA	temeljni kapital, zaposlenici	neto premije	zdravstveno
Pervez Zamurrad Janjua, Muhammad Akmal (2015)	Comparative Analysis of Economic Efficiency of Conventional and Islamic Insurance Industry in Pakistan	dužnički kapital, troškovi poslovnih usluga, temeljni kapital, trošak rada, broj podružnica	neto premije, prihod od ulaganja, neto potraživanja	složeno
Branka Jurčević, Maja Mihelja Žaja (2013)	Banks and Insurance companies efficiency indicators in the period of financial crisis: The case of The Republic of Croatia	neto operativni troškovi, troškovi investiranja, nastale štete	zarađene premije, prihod od investiranja	složeno

Wen-Yen Hsu, Pongpitch Petchsakulwong (2010)	The Impact of Corporate Governance on the Efficiency Performance of the Thai Non-Life Insurance Industry	administrativni troškovi, temeljni kapital, troškovi materijala i poslovnih usluga	nastali gubici, posrednici	neživotno
Joy Chakraborty (2016)	Efficiency and Productivity Analyses of Public Sector General Insurance Firms in India	operativni troškovi, investicije	neto premija, prihod od investiranja	neživotno
Martin Eling, Wei Huang (2013)	An Efficiency Comparison Of The Non-Life Insurance Industry In The Bric Countries	broj zaposlenika, temeljni kapital, dužnički kapital	napaćene neto premije, ukupna uložena sredstva	neživotno
Joy Chakraborty (2016)	Efficiency Analysis of Indian Life Insurance Firms: A DEA Investigation	operativni troškovi, troškovi provizija, investicije	neto premije, plaćene naknade, prihod od investiranja	životno
Milton Nektarios, Carlos Pestana Barros (2010)	A Malmquist Index for the Greek Insurance Industry	troškovi rada, operativni troškovi, temeljni kapital	investirana sredstva, nastali gubici, rezerve reosiguranja, vlastite rezerve	složeno
Semra Turkan, Esra Polat, Suleyman Gunay (2012)	The Effi ciency Analysis of Non-life Insurance Companies Active in Turkey	broj agenata, broj brokera, dugotrajna imovina, dionički kapital	prihod od ulaganja, premije	neživotno
Vesna Micajkova (2015)	Efficiency of Macedonian Insurance Companies: A DEA Approach	administrativni troškovi, troškovi provizije, ukupni kapital	bruto zaračunata premija, bruto podmirene štete	složeno

Izvor: Izrada autorice

Jurčević i Žaja (2013) mjerili su efikasnost banaka i osiguravajućih društava u razdoblju prije i nakon izbijanja financijske i ekonomske krize u Republici Hrvatskoj putem metode AOMP-a i računovodstvenih pokazatelja. Za inpute su koristili neto operativne troškove, troškove investiranja te nastale štete, a za outpute zarađene premije i prihod od investiranja. Analiza se provodila u razdoblju od 2005. do 2010. godine te je pokazala najniže vrijednosti u 2007. godini za osiguravajuća društva, a u 2008. za bankarski sektor.

Haas et al. (2004) mjerili su efikasnost njemačkih nogometnih klubova u sezoni 1999/2000. kao inpute koristili su: trošak plaća za trenere, trošak plaća za igrače, a za outpute: ostvarene bodove, broj gledatelja i ukupne prihode. Analizom je utvrđeno da efikasnost klubova nije povezana s plasmanom u ligi.

Nektarios i Barrosb (2010) analizirali su grčka društva za osiguranja u razdoblju od 1994. do 2003. godine. Za inpute su koristili troškove rada, operativne troškove i temeljni kapital, dok su za outpute koristili investirana sredstva, nastale gubitke, rezerve reosiguranja i vlastite rezerve. Analiza je pokazala da je najproduktivnije tržište životnih osiguranja s prosječnim godišnjim proizvodnim rastom od 16,1%, a slijede ga neživotna osiguranja s rastom od 6,5% i složena osiguranja s 3,3%.

Tuškan i Stojanović (2016) koristili su analizu omeđivanja podataka za ocjenu ekonomičnosti europskog bankarskog sektora na uzorku od 28 europskih banaka u razdoblju od 2008. do 2013. godine. Za inpute korišteni su trošak kamata i ukupne ukupni troškovi poslovanja, a za outpute korišteni su prihodi od kamata i ukupni prihodi od poslovanja. Prema CCR modelu najniža prosječna relativna efikasnost bila je u 2012. godini, a najviša u 2008. godini. Najmanji broj efikasnih DO bio je u 2009. godini i iznosio je 3, a najveći u 2008. i iznosio je 5 efikasnih DO. BCC model najnižu prosječnu efikasnost bilježi u 2009. godini, a najveću u 2008. godini. U 2008. godini bilo je najviše efikasnih DO, čak njih 15, a u 2012. najmanje, njih 11.

Škrinjarić (2016) je ocjenjivala efikasnost industrije osiguranja u 29 europskih zemalja u razdoblju od 2004. do 2013. godine. Za inpute je koristila udio zaposlenih, isplaćene premije, broj poslovnica, a za outpute naplaćene premije, uložena sredstva u investicijske portfelje te udio naplaćenih premija u BDP-u. Analiza je pokazala kako u nijednoj od promatranih godina Hrvatska nije efikasna te je predloženo više mogućnosti kako bi se to ispravilo.

Micajkova (2015) je analizirala makedonski osiguravajući sektor u razdoblju od 2009. do 2013. godine putem metode omeđivanja podataka. Za inpute je koristila administrativne troškove, troškove provizije i ukupni kapital, a za outpute bruto zaračunatu premiju te bruto podmirene štete. Analiza je pokazala da su Eurolink, Sava i Triglav osiguranje najefikasnije tijekom čitavog promatranog razdoblja.

4. OCJENA EFIKASNOSTI OSIGURANJA

4.1. Pojmovna, prostorna i vremenska definicija uzorka

U ovom istraživanju, analiza ocjene efikasnosti društava za osiguranje provodi se za 2016. godinu kada su prema HUO-u industriji osiguranja djelovala 22 osiguravajuća društva. U teoretskom dijelu rada objašnjeni su poslovi životnih i neživotnih osiguranja, dok se u empirijskom dijelu rada, za analiziranje ocjene efikasnosti društava za osiguranje koriste osiguranja koja se bave poslovima složenog osiguranja, odnosno životnim i neživotnim. Ta društva predstavljat će donositelje odluka (DO) i njihov ukupni broj iznosi n=9. Svakom društvu dodijeljena je oznaka DO_1, DO_2…DO_9 (sukladno abecednom redoslijedu).

Donositelji odluka za 2016. godinu definirani su u tablici 5.

Tablica 5: Donositelji odluka

Donositelji odluka	Osiguravajuća društva
DO1	ALLIANZ ZAGREB d.d..
DO2	CROATIA osiguranje d.d.
DO3	ERGO osiguranje d.d.
DO4	GENERALI osiguranje d.d.
DO5	GRAWE Hrvatska d.d.
DO6	MERKUR osiguranje d.d.
DO7	TRIGLAV osiguranje d.d..
DO8	UNIQA osiguranje d.d.
DO9	WIENER osiguranje Vienna Insurance Group d.d.

Izvor: www.hanfa.hr

4.2. Metodologija i opis analiziranih varijabli

Nakon odabira donositelja odluka, potrebno je definirati inpute i outpute. Za analiziranje društava za osiguranje može se koristiti veliki broj podataka i zato treba izabrati one outpute koji najbolje održavaju željene ciljeve i inpute koji se koriste u postizanju tih ciljeva.

Njihov odabir temelji se na subjektivnoj odluci i to je osnovno ograničenje AOMP modela.

Škrinjarić (2016) navodi ako je model inputno orijentiran, cilj donositelja odluka jest uz danu razinu outputa što više smanjiti korištenje inputa, dok je u slučaju outputne orijentiranosti suprotno, cilj je uz danu razinu inputa proizvesti što više outputa.

U ovom radu koristi se isti princip kao kod Škrinjarić (2016), odnosno CCR model uz inputnu orijentaciju (nadalje CCR-I) te CCR model uz outputnu orijentaciju (CCR-O), BCC model uz inputnu orijentaciju (BCC-I) te BCC model uz outputnu orijentaciju (BCC-O).

Prema Rabar (2010), treba voditi računa o broju varijabli inputa i outputa i broja jedinica koji se analiziraju kako bi rezultati analize bili što stvarniji i realniji. Autorica navodi kako bi broj jedinica trebao biti 3 – 5 puta veći od ukupnog broja varijabli inputa i outputa. Slično navedenom, Hunjak i Jakovčević (2003) navode kako bi broj jedinica trebao biti najmanje tri puta veći od ukupnog broja varijabli. Vođeni navedenim pretpostavkama, u ovom radu koristit će se dva inputa i jedan output za analiziranje efikasnosti devet društava za osiguranje.

Autori Dutta (2003), Jurčević & Žaja (2013), Chakraborty (2016), Bawa & Ruchita (2011), u svojim radovima koristili su troškove ulaganja i troškove pribave kao inpute te zarađene premije kao output, koji su prema njima korišteni u empirijskom dijelu za ocjenu efikasnosti društava za osiguranje.

Za ocjenu efikasnosti osiguravajućih društava definirani su sljedeći inputi:

Y_{1j} = troškovi pribave

Y_{2j} = troškovi ulaganja

Tablica 6: Definirani inputi po svakoj jedinici (DO)

OSIGURAVAJUĆE DRUŠTVO (DO)	TROŠKOVI PRIBAVE (I) (u kn)	TROŠKOVI ULAGANJA (I) (u kn)
ALLIANZ	174.936.000	42.442.000
CROATIA	403.655.000	105.540.000
ERGO	18.814.000	1.156.000
GENERALI	112.202.000	8.978.000
GRAWE	89.314.000	33.415.000
MERKUR	55.560.660	30.178.000
TRIGLAV	62.048.000	2.051.000
UNIQA	115.129.000	4.0160.000
WIENER	106.054.871	35.613.000

Izvor: Izrada autorice prema podacima preuzetim iz financijskih izvještaja društava za osiguranje

Troškovi pribave uključuju sve troškove nastale izravno i neizravno u vezi sa zaključivanjem novih ugovora o osiguranju i obnovom postojećih ugovora. Razgraničeni troškovi pribave za neživotna osiguranja odnose se na provizije koje su plaćene agentima i plaće djelatnika zaposlenih u pribavi nastale pri zaključivanju polica osiguranja tijekom financijske godine, ali koje se odnose na iduću financijsku godinu, kao i varijabilne troškove izdavanja polica. Opći troškovi prodaje se ne razgraničavaju.

Za poslove neživotnih osiguranja, razgraničeni troškovi pribave na datum izvještavanja izračunavaju se usporedbom pričuva za prijenosne premije na datum izvještavanja s bruto premijama policiranim tijekom godine razgraničavajući usporedivi dio troškova pribave.

Za poslove životnih osiguranja, troškovi pribave uključeni su u izračun pričuva životnog osiguranja temeljem Zillmerizacije te se ne priznaju kao posebna pozicija na datum izvještavanja.

Nadoknadivi iznos razgraničenih troškova pribave se procjenjuje na svaki datum izvještavanja kao dio testa adekvatnosti obveza (grawe.hr).

U ***troškove ulaganja*** spadaju troškovi kamata, gubitak od prodaje financijske imovine, umanjenje vrijednosti – zajmovi i potraživanja, umanjenje vrijednosti – imovina raspoloživa za prodaju, gubici od fer vrednovanja investicijskih nekretnina, negativne tečajne razlike te ostali troškovi ulaganja koji se odnose na režijske troškove investicijskih nekretnina i plaća zaposlenika sektora financija angažiranih na ulaganjima.

Troškovi ulaganja uključuju neto gubitke od promjene fer vrijednosti financijske imovine po fer vrijednosti kroz račun dobiti i gubitka te realizirane neto gubitke kod prestanka priznavanja financijske imovine raspoložive za prodaju i neto negativne tečajne razlike od preračunavanja financijske imovine i obveza na tečaj na datum izvještavanja (grawe.hr).

Prilikom ocjene efikasnosti, kao output (x_{1j}) odabrana je zarađena premija. U tablici 6. je prikazan output po svakoj jedinici (DO).

Tablica 7: Definirani outputi po svakoj jedinici (DO)

OSIGURAVAJUĆE DRUŠTVO (DO)	ZARAĐENA PREMIJA (O) (u kn)
ALLIANZ	985.907.000
CROATIA	1.986.312.000
ERGO	55.159.000
GENERALI	435.978.000
GRAWE	351.648.000
MERKUR	257.956.000
TRIGLAV	299.710.000
UNIQA	400.801.000
WIENER	423.282.000

Izvor: Izrada autorice prema podacima preuzetim iz financijskih izvještaja društava za osiguranje

Zarađena premija je ukupna zaračunata premija iz određenog razdoblja, umanjena za prijenosnu premiju aktualnog razdoblja i uvećana za prijenosnu premiju iz prethodnog razdoblja (zaračunata premija korigirana za promjenu pričuve prijenosne premije) (grawe.hr).

U današnje vrijeme kada na tržištu djeluje veliki broj društava za osiguranje, društva moraju kontinuirano pratiti kretanje svojih troškova i obveza i vršiti potrebne korekcije, kako preveliki troškovi i obveze u konačnici ne bi doveli do gubitaka u poslovanju te da ostave dovoljno mogućnosti za ostvarivanje dobiti. Također trebaju se boriti s drugim društvima da prisvoje što veći broj osiguranika kako bi mogli ostvariti velike premije.

4.3. Analiza efikasnosti društava za osiguranje primjenom metode omeđivanja podataka - empirijsko testiranje hipoteze

Prema Chakaborty (2016) vrijednosti inputa i outputa trebaju biti pozitivni, broj DO treba biti tri puta veći od zbroja inputa i outputa, a korelacija između inputa i outputa treba biti pozitivna i jaka. Ukoliko korelacija nije jaka i pozitivna to ukazuje da ta varijabla nije prikladna za model.

U tablici 8. vidljivo je kako je korelacija između inputa i outputa pozitivna, što znači da su isti dobro odabrani.

Tablica 8: Korelacija inputa i outputa

	Trošak pribave	Trošak ulaganja	Zarađena premija
Trošak pribave	1		
Trošak ulaganja	0,925106514	1	
Zarađena premija	0,990110156	0,907524555	1

Izvor: Izrada autorice

Kako bi se definirala granica efikasnosti, odabrani inputi i outputi analizirani su metodom omeđivanja podataka. Najbolje osiguravajuće društvo dobilo je ocjenu 1 (100%), a ostali se nalaze u rasponu od 0 do 1 (0 – 99,9%). Analiza efikasnosti društava za osiguranje vršena je pomoću dva modela, CCR i BCC modela input i output orijentirani.

CCR model orijentiran na inpute i outpute daje iste rezultate analize efikasnosti društava za osiguranje, pa je u radu prikazana samo jedna tablica. Tablica 9. prikazuje rezultate korištenjem CCR - I modela.

Tablica 9: Efikasnost osiguravajućih društava prema CCR - I modelu

Osiguravajuća društva	Vrijednost	Efikasnost	Vrijednost do granice efikasnosti
ALLIANZ	1	DA	0
CROATIA	0,873		0,127
ERGO	0,594		0,406
GENERALI	0,775		0,225
GRAWE	0,699		0,301
MERKUR	0,824		0,29
TRIGLAV	1	DA	0
UNIQA	0,618		0,382
WIENER	0,708		0,292

Izvor: Izrada autorice

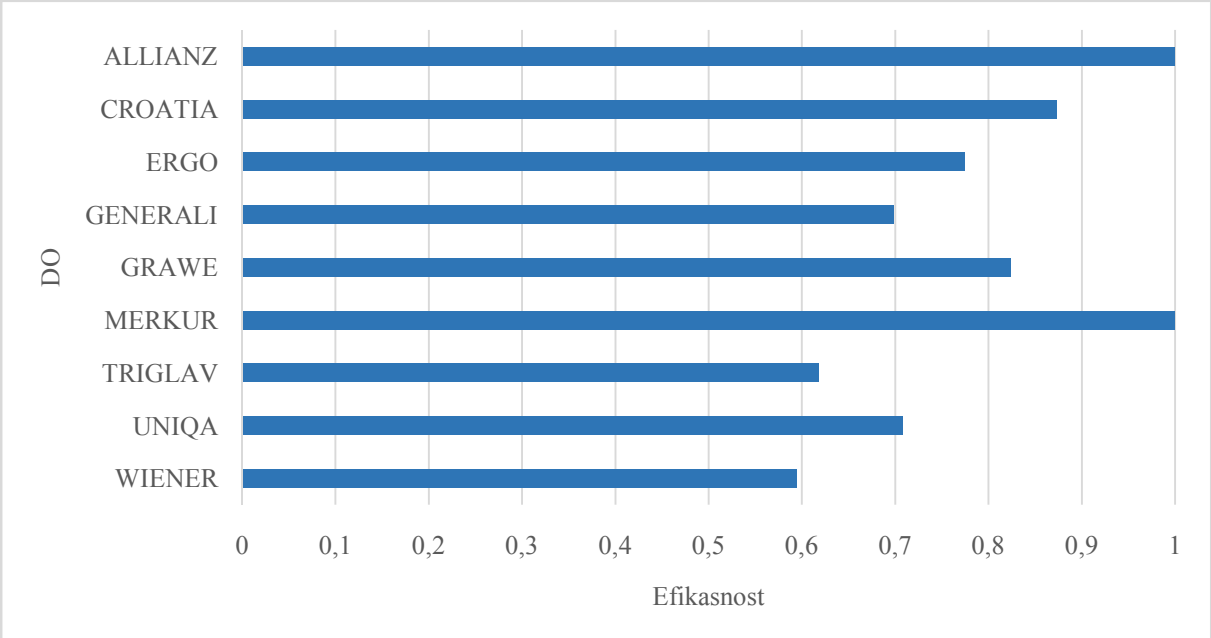
U tablici 9. nalaze se osiguravajuća društva i njihove relativne efikasnosti. Korištenjem CCR - I modela, dva osiguravajuća društva imaju relativnu efikasnost 1, što znači da su Allianz i Triglav efikasni. Ostala društva imaju relativnu efikasnost ispod 1 te se zbog toga ona smatraju neefikasnima. Interval efikasnosti u ovom modelu nalazi se u rasponu od 0,594 do 1.

U tablici 9. navedeno je koliko svakom donositelju odluke nedostaje do granice efikasnosti, odnosno do vrijednosti 1. Osiguravajuće društvo Ergo, s relativnom efikasnošću od 0,594 je najneefikasnije i zbog toga ono je najudaljenije od granice efikasnosti.

Na grafikonu 3. vidljivo je da od ostalih neefikasnih osiguravajućih društava, Croatia osiguranju najmanje nedostaje do granice efikasnosti, točnije 0,127 poena. Navedeno društvo treba poraditi na racionalizaciji svojih inputa ili maksimalizaciji outputa uz zadane inpute kako bi doseglo granicu efikasnosti.

CCR – I model koristi se kada se želi zadržati ista razina outputa uz promjenu inputa. U konkretnom slučaju ukoliko donositelji odluka koji su ocjenjeni kao neefikasni žele postati efikasnu uz istu zarađenu premiju trebaju racionalizirati, odnosno smanjiti svoje troškove pribave (smanjiti proviziju agentima ili nekih varijabilnih troškova vezanih uz izdavanje troškova) ili troškove ulaganja.

CCR – O model koristi se kada su korišteni inputi (trošak pribave i trošak ulaganja) zadani, odnosno njihova vrijednost ostaje ista, ali se racionalizacijom i boljim iskorištavanjem povećava output, u ovom slučaju zarađena premija.



Graf 3: Efikasnost donositelja odluke (CCR – I model)

Izvor: Izrada autorice

U nastavku se nalaze rezultati primjene BCC modela.

Tablica 10: Efikasnost osiguravajućih društava prema BCC - I modelu

Osiguravajuća društva	Vrijednost	Efikasnost	Vrijednost do granice efikasnosti
ALLIANZ	1	DA	0
CROATIA	1	DA	0
ERGO	1	DA	0
GENERALI	1	DA	0
GRAWE	0,767		0,233
MERKUR	0,951		0,049
TRIGLAV	1	DA	0
UNIQA	0,667		0,333
WIENER	0,76		0.24

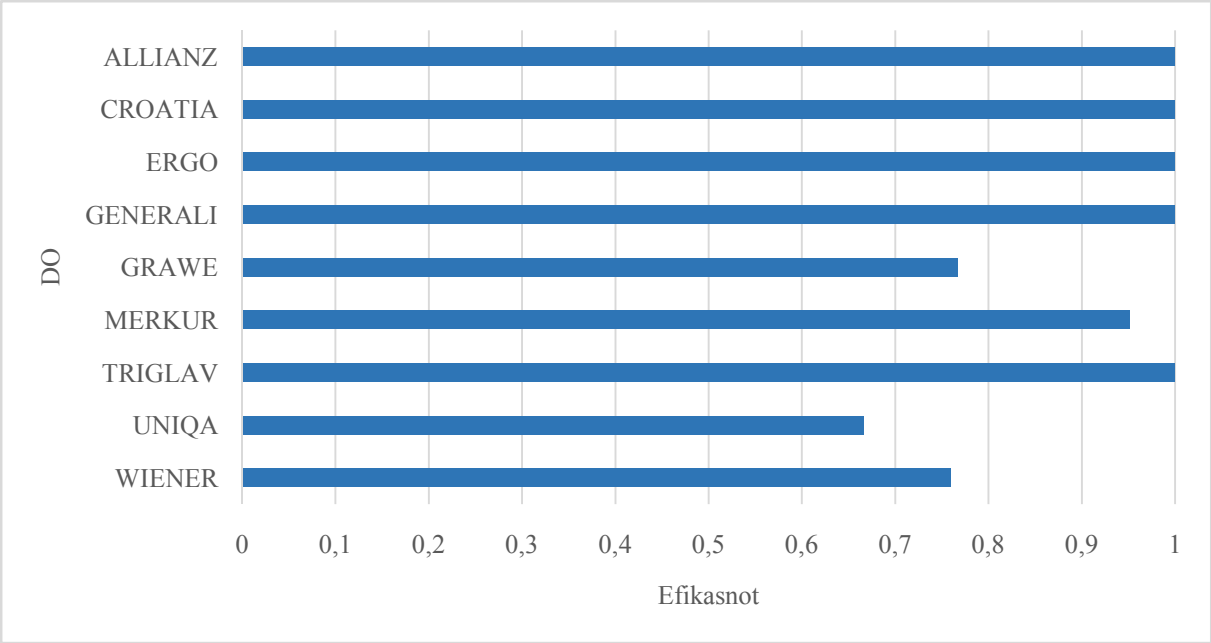
Izvor: Izrada autorice

Tablica 10. prikazuje rezultate analize društava za osiguranje prema BCC modelu usmjerenom na inpute. BCC model ocijenio je više društava kao efikasno od CCR modela, točnije njih 5 što je za 3 više od CCR modela. U ovom modelu društva koja imaju relativnu efikasnost 1 su efikasna i to su: Allianz osiguranje, Croatia osiguranje, Ergo osiguranje, Generali osiguranje te Triglav osiguranje.

Ostala društva imaju relativnu efikasnost manju od 1 što znači da su neefikasna. Po ovom modelu interval efikasnosti ide u rasponu od 0,667 do 1. Na grafikonu 4. vidi se da je Uniqa osiguranje s relativnom efikasnošću od 0,667 je najneefikasnije i najudaljenije od granice efikasnosti.

U tablici 10. i na grafu 4. prikazano je koliko svakom društvu za osiguranje nedostaje do vrijednosti 1 kako bi postalo učinkovito. Merkur osiguranje s relativnom efikasnošću od 0,951 najbliže je granici od svih neefikasnih društava.

Model BCC – I koristi se kad se želi racionalizirati inputi uz zadržavanje iste razine outputa. U ovom slučaju preostala neefikasna društva, njih 4 trebaju smanjiti svoje troškove pribave i ulaganja kako bi njihova zarađena premija ostala nepromijenjena.



Graf 4: Efikasnost donositelja odluke (BCC – I model)

Izvor: Izrada autorice

Tablica 11: Efikasnost osiguravajućih društava prema BCC – O modelu

Osiguravajuća društva	Vrijednost	Efikasnost	Vrijednost do granice efikasnosti
ALLIANZ	1	DA	0
CROATIA	1	DA	0
ERGO	1	DA	0
GENERALI	1	DA	0
GRAWE	0.74		0,26
MERKUR	0,941		0,059
TRIGLAV	1	DA	0
UNIQA	0,637		0,363
WIENER	0,736		0,264

Izvor: Izrada autorice

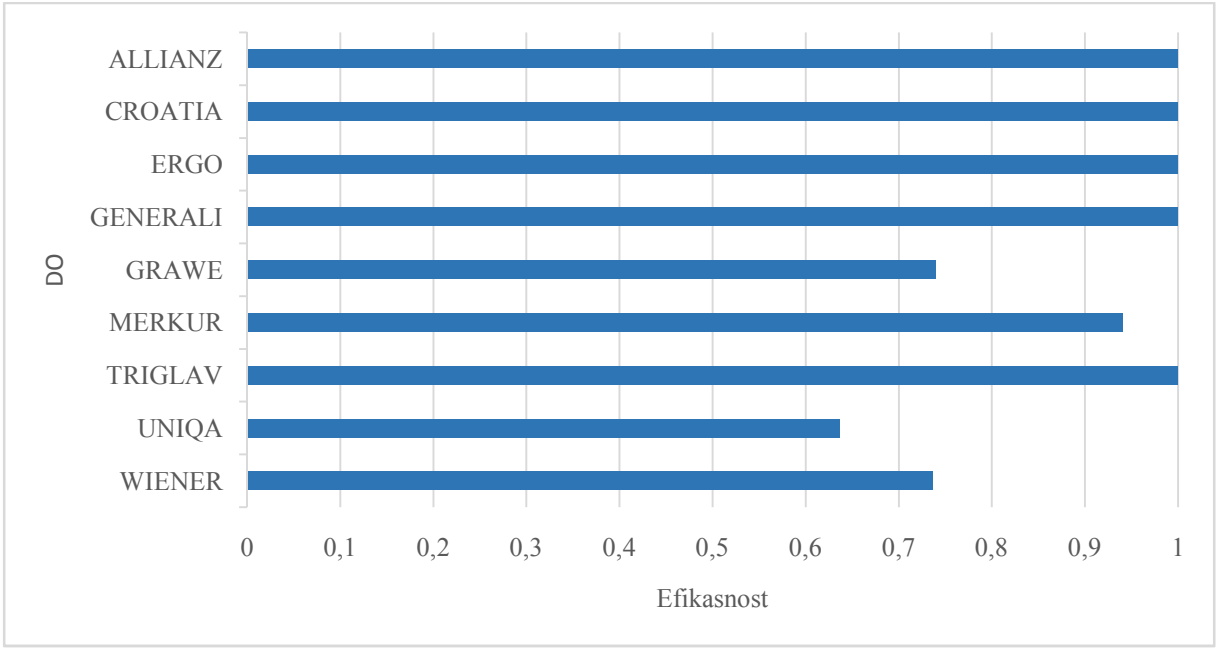
U tablici 11. nalaze se efikasna društva za osiguranje prema BCC – O modelu. Kao i kod BCC – I modela ostao je isti broj efikasnih društava, njih 5, a to su: Allianz osiguranje, Croatia osiguranje, Ergo osiguranje, Generali osiguranje te Triglav osiguranje.

Na grafikonu 5. vidljivo je kako Merkur osiguranju ponovno nedostaje najmanje do granice efikasnosti, točnije 0,059 poena. U tablici 11. nalaze se ostale vrijednosti koliko kojem neefikasnom društvu nedostaje do granice učinkovitosti, odnosno do vrijednosti 1.

BCC – O model koristi se kada se želi da neefikasna društva za osiguranje ostvare što veći output uz definirane razine inputa. Tako se želi postići bolje iskorištavanje inputa koji će voditi većem output odnosno većim iznosima zarađenih premija.

Gledajući inpute i outpute korištene u ovom radu zaključuje se da su obje orijentacije modela pogodne za analizu. Ponekad društva za osiguranje trebaju motivirati svoje zaposlene nagradama i bonusima kako bi oni što uspješnije odrađivali svoj posao te privukli što veći broj osiguranika što u konačnici dovodi do zarađivanja željenih premija i većoj konkurentnosti društva. Neka društva željet će povećati svoje zarađene premije uz to da inpute ostave nepromijenjene. To mogu kad sa svojim zaposlenicima imaju lojalan odnos te će oni uz nepromijenjene plaće uspješno obavljati svoj posao i svom društvu dovesti veliki broj osiguranika.

U stvarnosti efikasnost je najlakše i najrealnije dosegnuti efikasnost istodobnim mijenjanjem i smanjivanje inputa te povećavanjem outputa.



Graf 5: Efikasnost donositelja odluke (BCC – O model)

Izvor: Izrada autorice

4.4. Analiza i interpretacija dobivenih rezultata

Nakon analize donositelja odluka putem Open Source Dea programa izdvojena su efikasna društva za osiguranje od neefikasnih. Od efikasnih društava treba izdvojiti ono društvo koje je

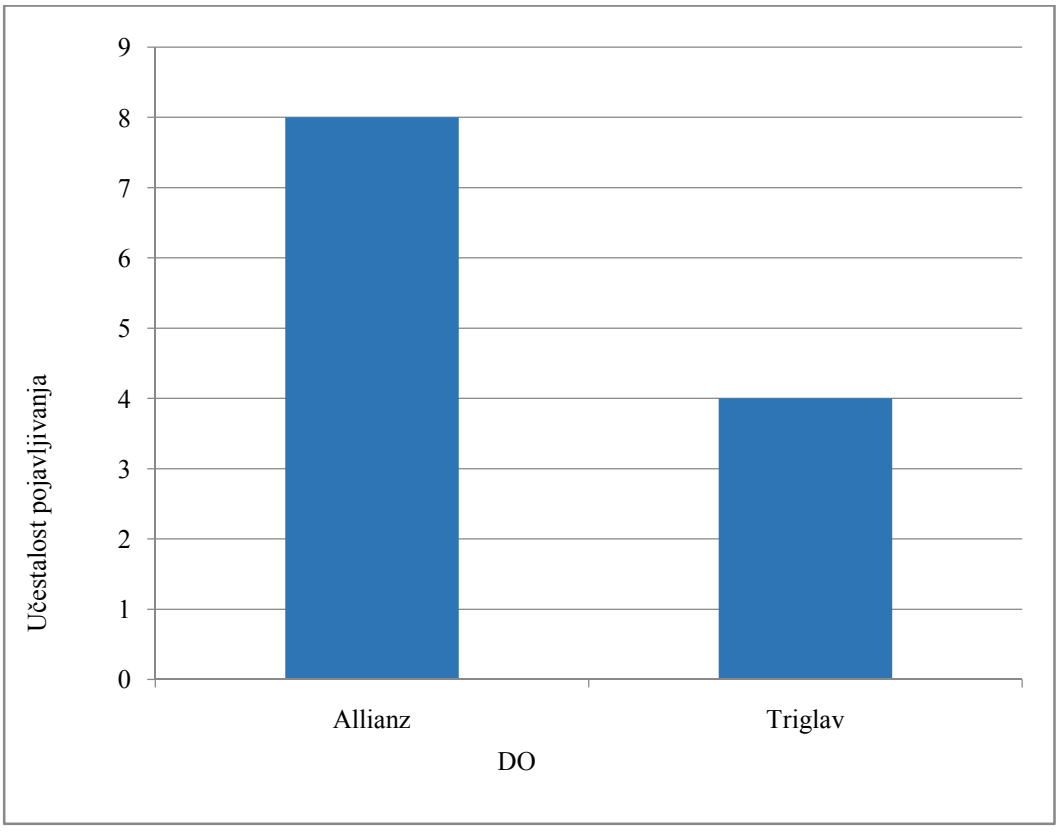
najefikasnije i čije će poslovne prakse biti primjer drugim društvima. Ono se izdvaja tako da se vidi koliko se puta pojedino efikasno društvo pojavljuje u referentnim skupovima. Referentni skupovi predstavljaju skupove efikasnih društava gdje se svakom društvu dodjeljuje neefikasno. Ovisno o modelu, neefikasna društva trebaju mijenjati svoje inpute i outpute po primjeru efikasnog društva kojem su dodijeljeni. Korištenjem CCR modela za analizu efikasnosti osiguravajućih društava, 2 društva ocijenjena su kao efikasna.

Tablica 12: Učestalost pojavljivanja u referentnim skupovima prema CCR modelu

DO	Učestalost pojavljivanja u referentnim skupovima
Allianz	8
Triglav	4

Izvor: Izrada autorice

Tablica 12. pokazuje njihovu učestalost pojavljivanja u referentnim skupovima. Allianz osiguranje pojavljuje se 8 puta, a Triglav osiguranje 4 puta. Pošto se Allianz osiguranje pojavljuje najviše puta, ono je najefikasnije od svih navedenih.



Graf 6: Učestalost pojavljivanja u referentnim skupovima (CCR model)

Izvor: Izrada autorice

Prema grafu 6. vidimo da je Allianz osiguranje najefikasnije društvo prema CCR modelu, a Triglav osiguranje je duplo lošije. Promjenama u poslovanju, Triglav osiguranje moglo bi postati najefikasnije.

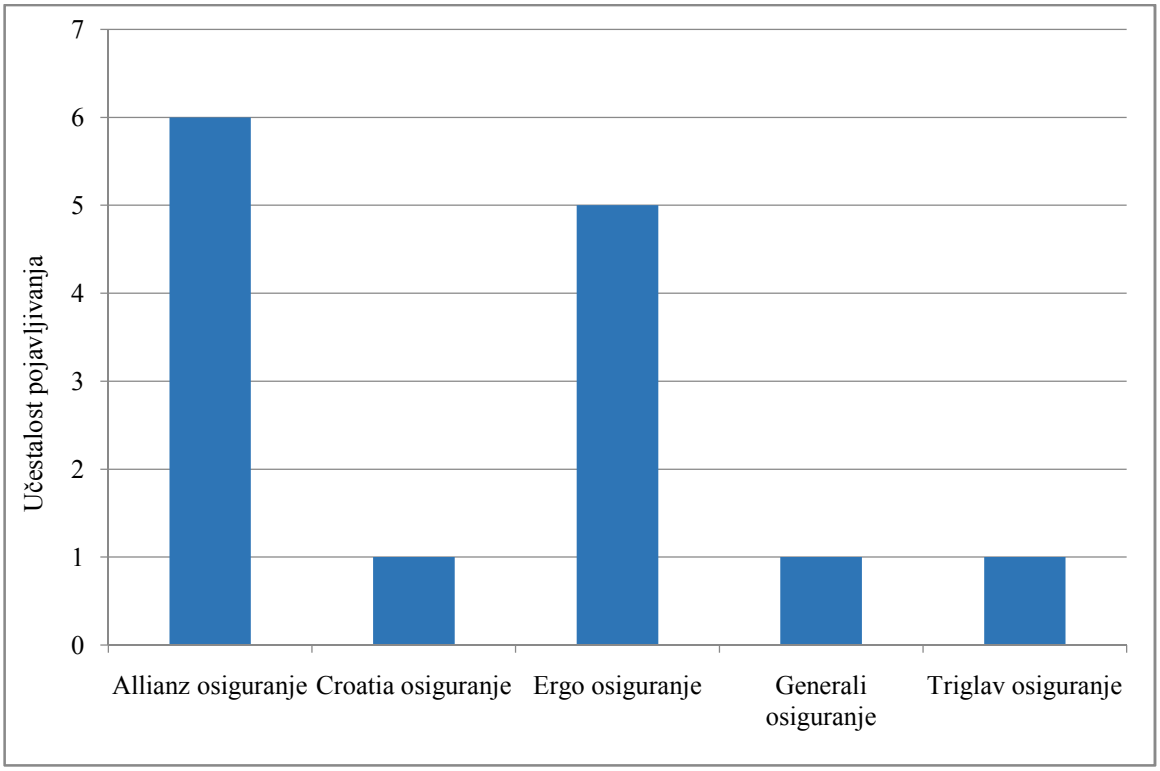
BCC model ocjenjuje 5 osiguravajućih društava kao efikasne.

Tablica 13: Učestalost pojavljivanja u referentnim skupovima prema BCC - I modelu

DO	Učestalost pojavljivanja u referentnim skupovima
Allianz osiguranje	6
Croatia osiguranje	1
Ergo osiguranje	5
Generali osiguranje	1
Triglav osiguranje	1

Izvor: Izrada autorice

Allianz osiguranje se 6 puta pojavljuje u referentnim skupovima, iako se pojavljuje manje puta nego u CCR modelu, ostaje i dalje najefikasniji i najbolji primjer ostalim osiguravajućim društvima.



Graf 7: Učestalost pojavljivanja u referentnim skupovima (BCC – I model)

Izvor: Izrada autorice

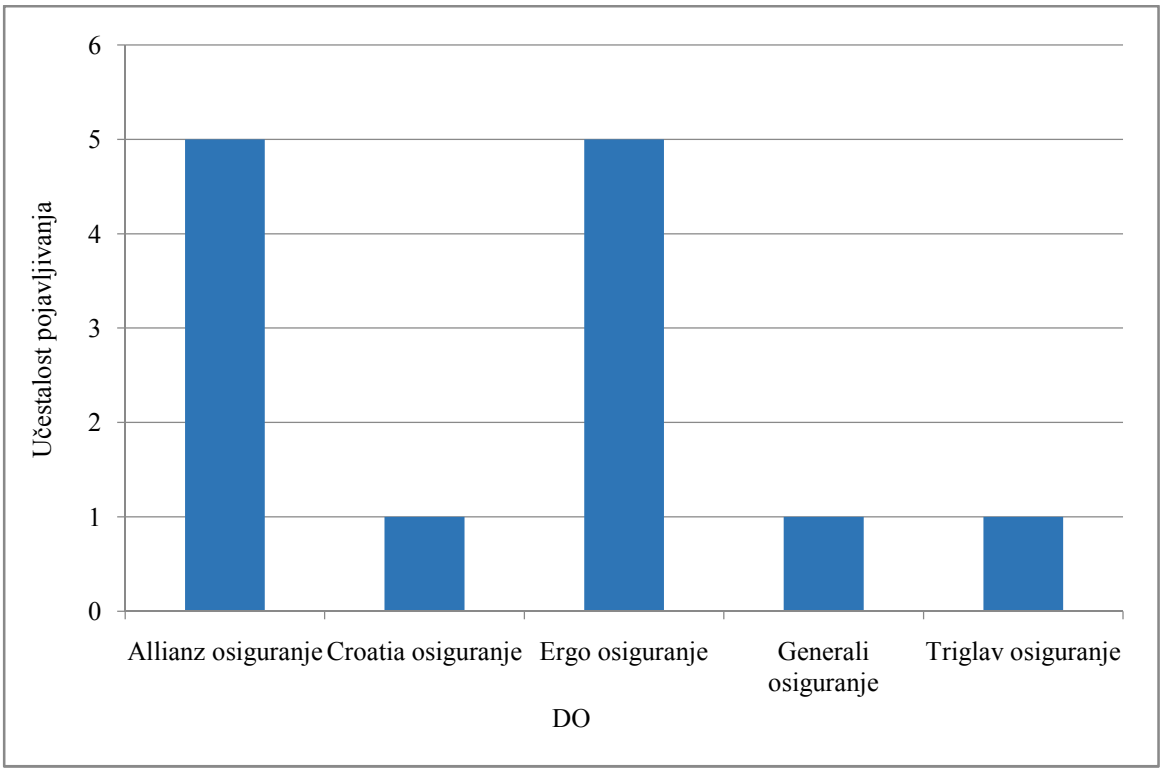
Iz grafikona 7. može se vidjeti da je Allianz osiguranje najefikasnije društvo, a slijedi ga Ergo osiguranje koje se pojavljuje 5 puta u referentnim skupovima. Ostala društva zauzimaju jednak dio grafa i pojavljuju se po 1 put.

Tablica 14: Učestalost pojavljivanja u referentnim skupovima prema BCC - O modelu

DO	Učestalost pojavljivanja u referentnim skupovima
Allianz osiguranje	5
Croatia osiguranje	1
Ergo osiguranje	5
Generali osiguranje	1
Triglav osiguranje	1

Izvor: Izrada autorice

Allianz osiguranje te Ergo osiguranje se pojavljuju po 5 puta u referentnim skupovima, te predstavljaju najbolji primjer ostalim osiguravajućim društvima.



Graf 8: Učestalost pojavljivanja u referentnim skupovima (BCC – O model)

Izvor: Izrada autorice

Iz grafikona 8. vidljivo je da Allianz i Ergo osiguranje predstavljaju najbolje poslovne prakse ostalim društvima, a ostala osiguravajuća društva trebaju napraviti dosta promjena u svom poslovanju ukoliko žele postati najefikasnija.

Tablica 15: Usporedba CCR i BCC modela

	CCR – I/ CCR - O	BCC - I	BCC - O
Broj relativno efikasnih osiguravajućih društava	2	5	5
Broj relativno neefikasnih osiguravajućih društava	7	4	4
Prosječna relativna efikasnost	0,787826	0,904997	0,904997
Standardna devijacija	0,14989	0,134125	0,147201
Najveća vrijednost efikasnosti	1	1	1
Najniža vrijednost efikasnosti	0,594	0,667	0,637

Izvor: Izrada autorice

Tablica 15. pokazuje usporedbu CCR i BCC modela. U oba modela analiza se vršila za 9 društva za osiguranje koji su djelovali u 2016. godini. CCR model ocijenio je 2 društva kao efikasna, a 7 kao neefikasna, dok je BCC model 5 društava ocijenio kao efikasno, a ostalih 4 kao neefikasno.

Prosječna relativna efikasnost u CCR modelu je 0,787826, dok je u BCC modelu viša i iznosi za BCC – I 0,904997, a za BCC – O 0,904997. U svim modelima najveća vrijednost efikasnosti iznosi 1, ali najniža vrijednost efikasnosti je u CCR modelu niža i iznosi 0,594, a u BCC - I modelu iznosi 0,667, a u BCC – O modelu 0,637.

Iz navedene usporedbe vidljivo je da postoji razlika između korištenja ova dva modela, te da BCC model daje više efikasnih društava i veću efikasnost.

Gledajući dobivene rezultate vidljivo je da postoji značajna razlika u efikasnosti osiguravajućih društava. Analizom su utvrđena efikasna i neefikasna društva. I CCR i BCC modeli prikazuju Allianz osiguranje kao najefikasnije osiguravajuće društvo. Ovo društvo ima najbolji omjer inputa (trošak pribave i trošak ulaganja) i outputa (zarađena premija) i kao takvo predstavlja poduzeće s najboljom poslovnom praksom i njega bi trebala slijediti ostala društva.

Ostala društva trebala bi poraditi na svojim inputima i outputima kako bi se postigla efikasnost. U istraživanju se prema CCR modelu najneefikasnije društvo pokazalo Ergo osiguranje, a prema BCC modelu Uniqa osiguranje.

Za najneefikasnija društva vršila se usporedba između projiciranih i empirijskih vrijednosti te su na taj način utvrđeni izvori neefikasnosti. Što je veća postotna razlika između empirijskih i projiciranih vrijednosti inputa ili outputa, tim je taj input ili output veći izvor neefikasnosti.

Prema CCR modelu, Ergo životno osiguranje je najneefikasnije. U tablici 16. nalaze se sve vrijednosti za navedeno osiguranje te ukoliko osiguranje izvrši sve promjene kako bi empirijske vrijednosti uskladio s projiciranim vrijednostima ono će postati efikasno.

Tablica 16: Potrebne promjene za Ergo osiguranje

Input/output	Empirijska vrijednost	Projicirana vrijednost	Razlika	% promjena
Trošak pribave	18.814.000	11.167.111,73	-7.646.888,27	-40,64
Trošak ulaganja	1.156.000	686.147,611	-469.852,389	-40,64
Zarađena premija	55.159.000	55.159.000	0	0

Izvor: Izrada autorice

Ukoliko Ergo osiguranje želi dostići granicu efikasnosti, treba mijenjati samo svoje inpute. Treba smanjiti troškove pribave za 40,64%, to jest za 7.646.888,27 kuna. Također treba smanjiti troškove ulaganja za isti postotak, odnosno u iznosu od 469.852,389 kuna. Ukoliko učini zahtijevane promjene uz iste vrijednosti outputa, ovo osiguravajuće društvo postat će efikasno.

Prema BCC – I modelu, Uniqa osiguranje je najneefikasnije. Ukoliko ovo osiguranje želi postati efikasno u svom poslovanju treba uskladiti svoje empirijske vrijednosti s projiciranim vrijednostima. Njihova razlika te postotna promjena prikazana je u tablici 17.

Tablica 17: Potrebne promjene za Uniqa osiguranje

Input/output	Empirijska vrijednost	Projicirana vrijednost	Razlika	% promjena
Trošak pribave	115.129.000	76.791.369,09	-38.337.630,91	-33,3
Troškovi ulaganja	40.160.000	16.487.943,35	-23.672.056,65	-58,94
Zarađena premija	400.801.000	400.801.000	0	0

Izvor: Izrada autorice

Promatrajući rezultate iz tablice 17., troškovi ulaganja Uniqa osiguranju predstavljaju najveći izvor neefikasnosti. Za dostizanje granice efikasnosti, Uniqa osiguranje trebalo bi smanjiti troškove pribave za 33,3% odnosno sa stvarnog troška od 115.129.00 kuna smanjiti na 76.791.369,09 kuna te troškove ulaganje za 58,94% tj. za 38.337.630,91 kunu za postizanje efikasnosti. Uniqa osiguranju zarađena premija nije izvor neefikasnosti te ova varijabla može ostati nepromijenjena.

Prema BCC – O modelu Uniqa osiguranje je također najneefikasnije. Potrebne promijene kako bi društvo postalo efikasno prema navedenom modelu nalaze se u tablici 18.

Tablica 18: Potrebne promjene za Uniqa osiguranje

Input/output	Empirijska vrijednost	Projicirana vrijednost	Razlika	% promjena
Trošak pribave	115.129.000	115.129.000	0	0
Troškovi ulaganja	40.160.000	26.626.216,18	-13.533.783,82	-33,7
Zarađena premija	400.801.000	629.357.342,5	228.556.342,5	57,02

Izvor: Izrada autorice

Iz tablice 18. vidljivo je da prema BCC – O modelu Uniqa osiguranje, ukoliko želi postati efikasno, treba povećati premije za 57,02% točnije za 288.556.342,5 kuna. Troškove ulaganja treba smanjiti za 57,02%, odnosno sa stvarnih troškova od 40.160.000 kuna na 26.626.216,18 kuna. Kako bi ovo poduzeće postalo efikasno input trošak pribave može ostaviti nepromijenjeno.

5. ZAKLJUČAK

U radu je definiran pojam osiguranja, kao i subjekti koji sudjeluju u osiguranju. U Republici Hrvatskoj je u 2016. godini djelovalo 22 osiguravajuća društva, od čega se 5 bavilo životnim, 8 neživotnim, 1 za reosiguranje te 8 složenim osiguranjem. Osiguravajuća društva su jedan od katalizatora ekonomskog rasta i nude veliki spektar proizvoda.

Kao temeljni cilj rada postavljeno je određivanje efikasnih i neefikasnih osiguravajućih društava. Na temelju teorijskog dijela provedeno je empirijsko istraživanje pomoću metoda AOMP-a (CCR i BCC). Analiza efikasnosti provedena je na temelju odabranih inputa i outputa. Kao inputi korišteni su trošak pribave i trošak ulaganja, dok je za output korištena zarađena premija i uz pomoć njih došlo se do zaključka koja osiguravajuća društva djeluju u Republici Hrvatskoj efikasno.

Za analizu efikasnosti osiguravajućih društava korišteni su CCR i BCC modeli (input i output orijentirani). CCR model ocjenjuje dva osiguravajuća društva kao efikasna, dok BCC model ocjenjuje njih pet.

Prema CCR modelu efikasni su Allianz i Triglav osiguranje, dok su prema BCC modelu efikasni Allianz, Croatia, Ergo, Generali i Triglav osiguranje. Sva navedena efikasna društva tvore referentne skupove čije bi prakse trebale slijediti neefikasna društva.

Prema CCR modelu najefikasnije društvo je Allianz, jer se pojavljuje u 8 referentnih skupova, također najefikasnije je po BCC – I modelu gdje se pojavljuje 6 puta u referentnim skupovima, dok su prema BCC – O modelu najefikasniji Allianz i Ergo osiguranje (pojavljuju se u 5 referentnih skupova).

Prema provedenoj analizi vidljivo je da se prihvaća alternativna hipoteza pa se donosi zaključak da postoji statistički značajna razlika u efikasnosti društava za osiguranje u Republici Hrvatskoj.

LITERATURA

1. Andrijašević, S., Petranović V. (1999): Ekonomika osiguranja, Alfa, Zagreb.
2. Bawa, S. K. Ruchita, M. (2011): Efficiencies of health insurance business in India: An application of DEA , American Journal of Social and Management Sciences 2 (2), pp. 237-247.
3. Bogović, T. (2014): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP), Doktorski rad, Fakultet organizacije i informatike, Varaždin.
4. Chakraborty, J. (2016): Efficiency and Productivity Analyses of Public Sector General Insurance Firms in India, The IUP Journal of Applied Economics, Vol. XV, No. 4, pp. 74-92.
5. Chakraborty, J. (2016): Efficiency Analysis of Indian Life Insurance Firms: A DEA Investigation, SCMS Journal of Indian Management, Vol. 13 Issue 3, pp. 5-24.
6. Cooper, W. W., Ray, S. (2008): A response to M. Stone: How not to measure the efficiency of public services (and how one might), Journal of the Royal Statistical Society, 171, 443-448.
7. Ćurak, M., Jakovčević, D. (2007): Osiguranje i rizici, RRIF, Zagreb.
8. Dutta, A., (2013): Impact of Privatization on Productivity: A Non-Parametric Analysis of Indian Insurance Sector, Global Business Review, 2013, Vol. 14, No. 2, pp. 297-314.
9. Eling, M., Huang, W. (2013): An efficiency comparison of the non-life insurance industry in the BRIC countries, European Journal of Operational Research**,** Vol. 226, Issue 3, pp. 577-591
10. Gorenc, V. (1997): Rječnik trgovačkog prava, Masmedia, Zagreb.
11. Haas, D., Kocher, M.G., Sutter, M. (2004): Measuring Efficiency of German Football Teams by Data Envelopment Analysis." Central Euro J Oper Res 12(3): 251-268.
12. Hunjak, T., Jakovčević, D. (2003): Višekriterijski modeli za rangiranje i uspoređivanje banaka, Zbornik Ekonomskog fakulteta u Zagrebu, 1, 43-60.
13. Hsu, W. Y., Petchsakulwong, P. (2010): The Impact of Corporate Governance on the Efficiency Perfomance of the Thai Non – Life Insurance Industry, The Geneva papers on Risk and Insurance – Issues and Practice, Vol. 35, No. 1, pp. 28-49.

14. Janjua, P. Z., Akmal, M. (2015): Comparative Analysis of Economic Efficiency of Conventional and Islamic Insurance Industry in Pakistan, Pakistan Business Review, Vol. 17, No. 1, 21-44.
15. Jemrić, I., Vujčić, B. (2002): Efficiency of Banks in Croatia: A Dea Approach, Comparative Economic Studies, Vol. 44, Issue 2-3, pp. 169-193.
16. Jurčević, B., Žaja, M. M. (2013):Banks and Insurance Companies Efficiency Indicators in the Period of Financial Crisis: The Case of the Republic of Croatia, Economic research- Vol. 26 No.1, pp. 203-224.
17. Karim, M. Z. A., Jhantansana, C. (2005): Cost efficiency and profitability in Thailand's life insurance industry: a stochastic cost frontier approach, International Journal of Applied Econometrics and Quantitative Studies, 2 (4), str. 19-36.
18. Klasić, K. (2003): Utjecaj psihologije pojedinca na izbor vrsta osiguranja, Economic Review, vol. 54 No. 7 – 8.
19. Klasić, K., Andrijanić, I. (2013): Osnove osiguranja načela i praksa (3 izmijenjeno i dopunjeno izdanje), Zagreb.
20. Korent, D., Detelj, K., Vuković, K. (2015): Ocjenjivanje efikasnosti hrvatskih županija u poduzetništvu primjenom analize omeđivanja podataka, Varaždin.
21. Marović, B., Mrkić, D. (1996): Osiguranje i reosiguranje, Financing centar, Novi Sad.
22. Micajkova, V. (2015): Efficiency of Macedonian Insurance Companies: A DEA Approach, Journal of Investment and Management, Vol.4, No. 2, pp. 61-67.
23. Mishkin, F. S., Eakins, S. G. (2005): Financijska tržišta i institucije, Mate d.o.o., Zagreb.
24. Narodne novine, (2016): Zakon o osiguranju, Narodne novine d.d. Zagreb, broj 30/15.
25. Nektarios, M., Barros, C.P. (2010): A Malmquist Index for the Greek Insurance Industry, The Geneva Papers on Risk and Insurance – Issues and Practice, Vol. 35, No. 2, pp. 309-324.
26. Rabar, D. (2010): Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka, Ekonomski pregled, 61(9-10), str. 511-533.
27. Rabar, D., Blažević, S. (2011): Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka, Privredna kretanja i ekonomska politika, 21(127), str. 25-56.
28. Rafaj, J. (2009): Tržište osiguranja priručnik, HANFA, Zagreb.
29. Renko, N.(2009): Strategije marketinga, Naklada Ljevak, Zagreb.

30. Šegota, A. (2008): Evaluating shops efficiency using data envelopment analysis: Categorical approach, Zbornik radova Ekonomskog fakulteta u Rijeci : časopis za ekonomsku teoriju i praksu, 26(2), str. 325-343.
31. Škrinjarić, T. (2013): Ocjena učinkovitosti dioničkih fondova u Hrvatskoj primjenom analize omeđivanja podataka, Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business and Economic Issues, 26 (1), str. 283-297.
32. Škrinjarić, T. (2016): Analiza relativne efikasnosti industrije osiguranja europskih zemalja korištenjem analize omeđivanja podataka, Ekonomski pregled, 67(1), str. 3-26.
33. Šporčić, M., Martinić, I., Landekić, M., Lovrić, M. (2008): Analiza omeđivanja podataka kao metoda efikasnosti – mogućnosti primjene u šumarstvu, Nova mehanizacija šumarstva : Časopis za teoriju i praksu šumarskoga inženjerstva, 29(1), str. 51-59.
34. Tipurić, D. (2007): Strateška analiza hrvatske industrije osiguranja, Ekonomski fakultet, Zagreb.
35. Turkan, S., Polat, E., Gunay, S. (2012): The Efficiency Analysis of Non-life Insurance Companies Active in Turkey, Zagreb International Review of Economics & Business, Vol.15 No.2, pp. 1-14.
36. Tuškan, B., Stojanović, A. (2016): Measurement of cost efficiency in the European banking industry, Croatian Operational Research Review, Vol.7 No.1.
37. Vaughan, E., Vaughan, T. (2000): Osnove osiguranja: Upravljanje rizicima, Mate, Zagreb.
38. Zaječaranović, G. (1973): Osnovi metodologije nauke, Naučna knjiga, Beograd.
39. Zakon o obveznim osiguranjima u prometu (NN 151/05, 36/09, 75/09, 76/13, 152/14).
40. Zelenika, R. (2000): Metodologija i Tehnologija Izrade Znanstvenog i Stručnog Dijela, Ekonomski Fakultet Sveučilišta u Rijeci, Rijeka.

Internet izvori:

1. Agram life osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.agramlife.hr/wp-content/uploads/2017/06/Financijsko-izvjesce-i-godisnje-izvjesce-Uprave-za-2016.-godinu.pdf, [15.09.2017.]
2. Allianz Zagreb d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://www.allianz.hr/media/541641/Allianz%20Zagreb%20konsolidirani_HR_2016_final_signed.pdf, [15.09.2017.]
3. BNP Paribas Cardif osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://media.bnpparibascardif.com/file/64/0/godisnje_izvjesce_2016.45640.pdf, [15.09.2017.]
4. Croatia zdravstveno osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.czo.hr/file/69/ , [15.09.2017]
5. Croatia osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.crosig.hr/media/godi%C5%A1nje_izvje%C5%A1%C4%87e.pdf, [15.09.2017]
6. Croatia Lloyd (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.crosig.hr/media/godisnje_izvjesce_-_nekonsolidirano_2016.pdf, [15.09.2017]
7. Ergo životno osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://ergoosiguranje.hr/fileadmin/user_upload_hr/images_hr/O_nama/Godisnja_izvjesca/EZO/Godi%C5%A1nje_izvje%C5%A1%C4%87e_za_2016._godinu_E%C5%BDO.pdf, [16.09.2017.]
8. Ergo osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://ergo-osiguranje.hr/fileadmin/user_upload_hr/images_hr/O_nama/Godisnja_izvjesca/EO/Godi%C5%A1nje_izvje%C5%A1%C4%87e_za_2016._godinu_EO.pdf, [16.09.2017.]

9. ERSTE osiguranje Vienna Insurance Group d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://www.erste-osiguranje.hr/files/file/sfcr-2016-1496145331.pdf,[18.09.2017.]
10. Euroherc osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.euroherc.hr/wp-content/uploads/2017/08/EH-godi%C5%A1nje-izvje%C5%A1%C4%87e-2016.pdf, [18.09.2017.]
11. Generali osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.generali.hr/__static__/pdf/Godisnji_i_financijski_izvjestaji_2016_HRV.pdf, [18.09.2017.]
12. Grawe Hrvatska d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.grawe.hr/static_files/grawe_hr/images/media/Godisnje_izvjesce_osiguravajuceg_drustva_GRAWE_Hrvatska_dd_za_2016_godinu_.pdf, [18.09.2017.]
13. Hok osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.hok-osiguranje.hr/Download.ashx?FileID=2225820e-1525-42eb-b69d-3dbe3770e0e8, [22.09.2017.]
14. Hrvatsko kreditno osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://hkosig.hr/wpcontent/uploads/Financijsko_izvje%C5%A1%C4%87e_za_2016._godinu.pdf, [22.09.2017.]
15. Izvor osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://www.izvorosiguranje.hr/EasyEdit/UserFiles/financijskiizvjestaji/2016/godisnje-izvjesce-i-fin-izvjestaji-2016.pdf, [22.09.2017.]
16. Jadransko osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.jadransko.hr/o-nama/dokumenti/publikacije/2016/Revidirano_Godisnje_izvjesce_i_financijski_izvjestaji_za_2016.pdf, [22.09.2017.]

17. Merkur osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.merkur.hr/cms/dokumente/1010727_45705/523eda25/Merkur_2016_hr_kona%C4%8Dna_27.2.2017_signed.pdf, [22.09.2017.]
18. Triglav osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.triglav.hr/wps/wcm/connect/2cf6f701-ff39-46df-95b1-9394e8278ace/Triglav+osiguranje+Zagreb%2C+Financijska+izvje%C5%A1%C4%87a+za+2016%2C+IFRS%2C+s+mi%C5%A1ljenjem+neovisnog+revizora%2C+HRV-1.pdf?MOD=AJPERES&CONVERT_TO=url&CACHEID=2cf6f701-ff39-46df-95b1-9394e8278ace, [22.09.2017.]
19. Uniqa osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na:https://www.uniqa.hr/UserDocsImages/dokumenti/fin-izvj/2016/Godi%C5%A1nje%20izvje%C5%A1%C4%87e%20za%202016.pdf, [23.09.2017.]
20. Wiener osiguranje Vienna Insurance Group d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: https://www.wiener.hr/EasyEdit/UserFiles/pdf/wiener-osiguranjehrv31122016final.pdf, [23.09.2017]
21. Wüstenort životno osiguranje d.d. (2016): Financijski izvještaji na dan 31. prosinca 2016. godine, [Internet], raspoloživo na: http://www.wuestenrot-osiguranje.hr/UserDocsImages/pdf/WZO_FS_2016_signed_HRV_final.pdf, [23.09.2017.]
22. *Fortius d.o.o (2003):* [Internet], raspoloživo na: http://www.fortius.hr/vise-o-osiguranju/osnovni-podaci-o-osiguranju/povijesni-razvoj-osiguranja/, [04.10.2017.]
23. Hrvatska agencija za nadzor financijskih usluga (HANFA), [Internet], raspoloživo na: http://www.hanfa.hr/trziste-osiguranja/, [04.10.2017.]
24. Optimarisk d.o.o., (2005), [Internet], raspoloživo na: http://optimarisk.hr/povijest-osiguranja, [04.10.2017]
25. Hrvatski ured za osiguranje, [Internet], raspoloživo na: http://www.huo.hr/Listanje_PDF/Trziste_osiguranja_RH_2016/index.html#/126, [15.10.2017.]

Popis tablica

Tablica 1: Osiguravajuća društva u Hrvatskoj 17
Tablica 2: Zaračunata bruto premija od 2003. do 2016. godine 18
Tablica 3: Zaračunate bruto premije životnog i neživotnog osiguranja 19
Tablica 4: Recentni radovi u analizi industrije osiguranja 30
Tablica 5: Donositelji odluka 33
Tablica 6: Definirani inputi po svakoj jedinici (DO) 34
Tablica 7: Definirani outputi po svakoj jedinici (DO) 36
Tablica 8: Korelacija inputa i outputa 37
Tablica 9: Efikasnost osiguravajućih društava prema CCR - I modelu 37
Tablica 10: Efikasnost osiguravajućih društava prema BCC - I modelu 39
Tablica 11: Efikasnost osiguravajućih društava prema BCC – O modelu 40
Tablica 12: Učestalost pojavljivanja u referentnim skupovima prema CCR modelu 42
Tablica 13: Učestalost pojavljivanja u referentnim skupovima prema BCC - I modelu 43
Tablica 14: Učestalost pojavljivanja u referentnim skupovima prema BCC - O modelu 44
Tablica 15: Usporedba CCR i BCC modela 45
Tablica 16: Potrebne promjene za Ergo osiguranje 46
Tablica 17: Potrebne promjene za Uniqa osiguranje 46
Tablica 18: Potrebne promjene za Uniqa osiguranje 47

Popis slika

Slika 1: Formula uspješnosti osiguravatelja 8
Slika 2: Svi sudionici u poslovima osiguranja 9
Slika 3: Grafički prikaz primjera AOMP 23
Slika 4: Prikaz granice efikasnosti prema CCR modelu 25
Slika 5: Granica efikasnosti prema BCC modelu 27

Popis grafova

Graf 1: Zaračunata bruto premija od 2003. do 2016. godine 19
Graf 2: Struktura ukupne premije osiguranja 21
Graf 3: Efikasnost donositelja odluke (CCR – I model) 38
Graf 4: Efikasnost donositelja odluke (BCC – I model) 40

Graf 5: Efikasnost donositelja odluke (BCC – O model)..... 41
Graf 6: Učestalost pojavljivanja u referentnim skupovima (CCR model)..... 42
Graf 7: Učestalost pojavljivanja u referentnim skupovima (BCC – I model)..... 43
Graf 8: Učestalost pojavljivanja u referentnim skupovima (BCC – O model)..... 44

SAŽETAK

U ovom radu se analizira efikasnost društava za osiguranje pomoću analize omeđivanja podataka (AOMP). U relativno kratkom vremenskom razdoblju od prvog pojavljivanja metoda AOMP je narasla u moćan analitički alat za mjerenje efikasnosti različitih gospodarskih grana. Cilj rada je identificirati efikasna i neefikasna društva za osiguranje i procijeniti dobre prakse te oblikovati smjernice za poboljšanje učinkovitosti neefikasnih društava. U radu je analizirano 9 osiguravajućih društava koji se su se bavili poslovima složenog osiguranja u 2016. godini. Za analizi su korišteni CCR i BCC model input i output orijentirani. CCR model je identificirao dva društva kao efikasna: Allianz i Triglav, dok je BCC model identificirao pet društava: Allianz, Croatia, Ergo, Generali i Triglav. Rezultati analize su ukazali na postojanje statistički značajne razlike između efikasnih i neefikasnih društava za osiguranje, temeljem čega je alternativna hipoteza prihvaćena.

Ključne riječi: *AOMP, društva za osiguranje, efikasnost*

SUMMARY

This paper analyses the efficiency of insurance companies using Data Envelopment Analysis method (DEA). In a relatively short period of time from first appearance DEA has grown into a powerful analytical tool for measuring efficiently of different economic sectors. The purpose of this paper is to identify efficient and non – efficient insurance companies and evaluate good practices and to form guidelines for efficiency improvements for non – efficient insurance companies This paper analyses the group of 9 composite insurance companies operated in 2016. The analysis used CCR and BCC model, input and output oriented. CCR model identified 2 efficient companies: Allianz and Triglav, whiles BCC model identified five of them: Allianz, Croatia, Ergo, Generali and Triglav. The result of the analysis indicated on statistically significant differences between efficient and inefficient insurance companies, on the basic of which the research alternative hypothesis was accepted.

Key words: *DEA, insurance companies, efficiency*