VIŠEKRITERIJALNO ODLUČIVANJE I PROCJENA BONITETA OSIGURAVAJUĆIH DRUŠTAVA

Vučković, Ana

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:124:931160

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

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

VIŠEKRITERIJALNO ODLUČIVANJE I PROCJENA BONITETA OSIGURAVAJUĆIH DRUŠTAVA

Mentor:

Prof. dr. sc. Zoran Babić

Student:

Ana Vučković

Split, rujan, 2018.

SADRŽAJ

1. UVOD 4

1.1. Problem istraživanja 4

1.2. Predmet istraživanja 6

1.3. Ciljevi i svrha istraživanja 6

1.4. Metode istraživanja 7

1.5. Doprinos istraživanju 8

1.6. Struktura rada 9

2. BONITET 10

2.1. Definicija boniteta 10

2.2. Važnost i razlozi procjene boniteta 11

2.3. Financijski izvještaji 12

2.3.1. Bilanca 12

2.3.2. Račun dobiti i gubitka 14

2.3.3. Izvješća o novčanom toku 15

2.3.4. Izvještaj o promjenama vlasničke glavnice 17

2.3.5. Bilješke uz financijske izvještaje 17

2.4. Financijski pokazatelji 18

2.5. BON-1, BON-2, BONPLUS 19

3. OSIGURAVAJUĆE DRUŠTVO 21

3.1. Povijest osiguravajućih društava 21

3.2. Značenje i pojam osiguravajućeg društva 22

3.3. Osiguravajuća društva u financijskom pogledu 23

3.4. Osiguravajuća društva u Hrvatskoj 23

3.5. Bonitet osiguravajućih društava 24

3.5.1. Specifični pokazatelji 24

4. VIŠEKRITERIJALNO ODLUČIVANJE 26

4.1. Uvod u višekriterijalno odlučivanje i osnovni pojmovi 26

4.2. Metoda svojstvenog vektora 27

4.3. Metoda jednostavnog zbrajanja težina 30

4.4. TOPSIS metoda 31

4.5. PROMETHEE metoda 34
5. PRIMJENA METODA VIŠEATRIBUTNOG ODLUČIVANJA NA PROBLEM PROCJENE POSLOVANJA (BONITETA) OSIGURAVAJUĆIH DRUŠTAVA 45
5.1. Uvod 45
5.2. Procjena težina kriterija – metoda svojstvenog vektora 46
5.3. Određivanje ranga osiguravajućih društava metodom jednostavnog zbrajanja težina - SAW .. 48
5.4. Određivanje ranga osiguravajućih društava TOPSIS metoda 50
5.5. Određivanje ranga osiguravajućih društava PROMETHEE metodom 54
5.6. Usporedba rezultata dobivenih SAW metodom, TOPSIS metodom i PROMETHEE metodom .. 59
6. ZAKLJUČAK 61
SAŽETAK 62
SUMMARY 63
POPIS LITERATURE 64
POPIS SLIKA 66
POPIS TABLICA 67

1. UVOD

1.1. Problem istraživanja

Osiguravajuće društvo možemo definirati kao instituciju koja postoji kako bi se ljudi mogli zaštiti od opasnosti koje (eventualno) prijete te zbog mogućih šteta na imovini.[1] Sama riječ osiguranje daje određenu dozu sigurnosti da će se u slučaju raznih nevolja (poput požara, prirodnih katastrofa, urušavanja i ostalih nepovoljnih događaja) dobiti određena naknada. Uz osiguranje usko vežemo i pojam rizik te zaključujemo da iz određene rizične situacije proizlazi potreba za osiguranjem. U suprotnom nema smisla niti potrebe za osiguravanjem niti sebe niti imovine. U trenutku kad se sklapa ugovor platitelj, koji može biti pojedinac, poduzeće ili zajednica, uplaćuje premiju da bi u slučaju nezgode dobio barem dio naknade. [2] Osim osiguranja u slučaju nezgode u osiguravajućim društvima osobe mogu uplaćivati štednju koja se može isplaćivati periodično ili na kraju ugovorenog razdoblja ovisno o dogovoru.[3] Ova društva uglavnom posluju na temelju ugovora.[4]

S obzirom na postojanje rizika u svakom poslovanju pa tako i kod osiguravajućih društava potrebno je proučiti njihovo poslovanje. Uvidom u bonitet bilo kojeg poduzeća procjenjujemo uspješnost poslovanja. Za osiguranika bolji bonitet osiguravatelja znači manji rizik da se neće naplatiti u slučaju nevolje ili da neće dobiti osiguranu svotu nakon ugovorenog razdoblja.

Da bi neko poduzeće donijelo dobru poslovnu odluku potrebna mu je informacija o bonitetu njegovih partnera. Svaki menadžer zna da je okolina promjenjiva te da je potrebno pratiti što se događa i zato često i oni sami imaju "osjećaj rizika" u vezi donošenja odluka. Ipak sam osjećaj nije dovoljan već odluka treba biti temeljena i na pouzdanim informacijama. Stoga je procjena boniteta iznimno važna kako bi se saznalo, između ostalog, što više financijskih informacija o partnerima, klijentima, kupcima i ostalima te ostale informacije i podaci. Prije dogovora oko posla, tj. prije nego li se sklopi ugovor s drugom stranom određeno poduzeće nastoji utvrditi sposobnost tog poduzeća tako da može ocijeniti isplatili li se ulaziti u posao.

Sam pojam bonitet u ekonomskom, tj. trgovačkom smislu označava sposobnost plaćanja. Šire značenje boniteta se odnosi na cijelu poslovnu sposobnost, financijsku moć koju poduzeće ima

[1] Ćurak M., Jakovčević D., (2007): Osiguranje i rizici, M.A.K. Golden d.o.o., Zagreb,str. 17
[2] Vukičević M., Odobašić S., (2011): Osnove financija, Visoka škola za poslovanje i upravljanje "Baltazar Adam Krečelić" ,Zaprešić, str. 249
[3] https://www.allianz.hr/privatni-korisnici/pojmovi-u-osiguranju/zivotno-osiguranje-kao-stednja-kako-ustedjeti-novac/
[4] Nikolić N., Pečarić M., (2012): Uvod u financije, Ekonomski fakultet Split, Split, str. 167

da podmiri svoje obveze u zadanom vremenskom roku i da održava svoju profitabilnost. Tako bi poduzeće trebalo moći ocijeniti svoju solventnost za sve što ga očekuje u određenom budućem razdoblju. Da bi uspjeli biti solventni potrebno je pažljivo planirati svoje korake i prikupljati kvalitetne informacije.[5] Najjednostavnije rečeno bonitet je sposobnost plaćanja svojih financijskih obveza na vrijeme.[6]

Informacije o bonitetu sadrže: BON 1 koji sadrži opće informacije kao što su naziv poduzetnika, adresa, OIB, oblik vlasništva, poslovanju u zadnje dvije godine i slično. BON 2 sadrži informacije kao što su stanje sredstva na računu, primitci na račun u zadnjih 30 dana, iznosi odobrenih kredita, prosječno stanje sredstava u proteklih 30 dana i slično. BONPLUS sadrži jasnije i bolje informacije kako bi se što lakše donijela odluka. BONPLUS sadrži ocjenu financijskog rejtinga što se konkretno odnosi na mogućnost poduzetnika da plati svoje obveze u dogovorenom roku. Ocjena ide od 1-10.[7]

Ovaj rad nastojat će pokazati uspješnost poslovanja izabranih osiguravajućih društava u Republici Hrvatskoj na temelju određenih kriterija te još detaljnije objasniti pojmove vezane uz bonitet. Osim toga bit će prikazan način donošenja odluka putem nekoliko metoda višekriterijalnog odlučivanja.

[5] Leko V., Milinović A., Potkonjak M., (1996): Procjena boniteta trgovačkog društva, MASMEDIA, Zagreb, str.5-9.
[6] http://financije-plus.com/Osnovni-pojmovi/Sto-je-bonitet.php
[7] http://www.fina.hr/default.aspx?sec=1278

1.2. Predmet istraživanja

Rad će istražiti poslovanje nekoliko poznatih osiguravajućih društava u Hrvatskoj te tako nastojati procijeniti kvalitetu poslovanja istih i ukupnu ocjenu poslovanja.[8] Teorijski dio će objasniti povijest osiguravajućih društava, njihovu definiciju te kriterije za mjerenje uspješnosti poslovanja.

U empirijskom dijelu da bi se došlo do izbora između nekoliko alternativa analizirat će se nekoliko osiguravajućih društava pomoću višekriterijalnog odlučivanja. Sam pojam podrazumijeva donošenje odluka između nekoliko kriterija. Kriteriji su često konfliktni.[9] Tako na početku imamo jednostavan primjer kod izbora osiguranja gdje platitelj razmatra kriterije poput kamate, broja godina, osigurane svote i raznih drugih te na temelju onoga što je spomenutom platitelju važno izabire odgovarajuće osiguravajuće društvo. Za izbor između alternativa koristit ćemo PROMETHEE metodu te tako doći do najbolje alternative. Uz PROMETHEE metodu bit će korištena metoda svojstvenog vektora kako bismo dobili težine za svaki kriterij, metoda jednostavnog zbrajanja težina i TOPSIS metoda. Na temelju dobivenih rezultata svake metode pojedinačno, usporedit će se rezultati između metoda. Usporedbom i komentiranjem rezultata navedenih metoda dobiva se uvid u razlike kod konačnih odabira. Izbor metoda za usporedbu odabire autor.

1.3. Ciljevi i svrha istraživanja

Cilj i svrha rada su pomoću višekriterijalnog odlučivanja izabrati najbolju alternativu između osiguravajućih društava na temelju financijskih pokazatelja i pokazatelja koji su karakteristični za spomenuta društva.

Rad će objasniti pojam boniteta i bonitet u poduzeću, pojam osiguravajućih društava te metodama višekriterijalne analize prikazati najbolji izbor.

[8] http://www.poslovni.hr/leksikon/bonitet-44
[9] [9] Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str. 27

1.4. Metode istraživanja

Metodologija kao termin svoje podrijetlo nalazi u grčkom jeziku (meta=po, kroz; hodos=put; logos=riječ). Iz toga zaključujemo da metodologiju možemo definirati kao put kojim se dolazi do spoznaje onog što istražujemo. I stoga definiramo metode u ovom radu.[10]

U radu će biti korištene iduće metode:

- induktivna metoda (na temelju analize pojedinih pojava ili činjenica donosi se opći zaključak tj. sud);
- deduktivna metoda (metoda u kojoj se iz općih sudova izvode pojedinačni sudovi. Ima svrhu objašnjavanja činjenica, predviđanja, otkrivanja novih zakona, pojava i činjenica, dokazivanje hipoteza.);
- metoda analize (gdje se sudovi, pojmovi i zaključci razgranavaju na jednostavnije dijelove i elemente. Donošenje općeg zaključka.);
- metoda sinteze (objašnjavanje stvarnosti putem sinteze jednostavnih sudova u složenije)[11];
- metoda deskripcije (metoda opisivanja pojave ili činjenica koje istražujemo);
- metoda kompilacije (metoda se odnosi na preuzimanje i razmatranje tuđih stavova, zaključaka, znanja i spoznaja);
- metoda ispitivanja (prikupljanje podataka putem razgovora između istraživača i osoba koje bi mogle imati potrebne podatke)

Rad uključuje nekoliko metoda višekriterijalnog odlučivanja prilikom rangiranja i ocjenjivanja kriterija među osiguravajućim društvima.

[10] Žugaj, M.,Dumičić K., Dušak V. (2006): Temelji znanstvenoistraživačkog rada, Metodologija i metodika, TIVA Tiskara Varaždin, Varaždin, str. 35

[11] http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf

1.5. Doprinos istraživanju

Doprinos ovog istraživanja se temelji na analizi uspješnosti poslovanja osiguravajućih društava na području Hrvatske na način da se sagleda poslovanje određenih osiguravajućih društava te da se putem nekoliko metoda višekriterijalnog odlučivanja osiguravajuća društva poredaju od najprihvatljivijeg do najmanje prihvatljivog te tako prikaže koji je izbor najbolji na temelju određenih kriterija.

Prvi dio nastoji pobliže objasniti sam pojam boniteta, razloge zbog čega je uopće važan za bilo koje poduzeće, zašto ga proučavaju osiguravajuća društva te zašto menadžeri trebaju osim boniteta pratiti i ostale okolnosti kako bi znali koju strategiju primijeniti da se ostvari željeni cilj. Rad će nastojati objasniti koje su to važne informacije te zašto bonitet predstavlja „zdravlje“ svakog poduzeća. Rad će prikazati važnost financijskih izvještaja na temelju kojih se dobiva ocjena o poslovanju.

Drugi dio rada će se odnositi na važnost višekriterijalnog odlučivanja kod konfliktnih kriterija. Korištenjem nekoliko metoda višekriterijalnog odlučivanja pokazat će se najbolja alternativa među osiguravajućim društvima, koje društvo je najdjelotvornije i koje je eventualni najbolji izbor. Kriteriji i izbor osiguravajućih društava su proizvoljan odabir autora.

1.6. Struktura rada

Diplomski rad se sastoji od 6 poglavlja, koji kreću od uvoda zatim objašnjavanja pojmova u teoriji, prikaza problema i rješavanje istih u praksi te zaključka.

Prvi dio definira sam problem istraživanja te ciljeve i svrhu rada. Rad prikazuje sve metode koje će se koristiti u svrhu istraživanja odabrane teme te doprinos istraživanju.

Drugi dio rada se odnosi na bonitet. Prvo se upoznaje sam termin boniteta, njegovo značenje i koje značenje ima u poslovanju. Nakon toga se objašnjavaju financijski izvještaji.

Treći dio se odnosi na osiguravajuća društva. Prikazuje se povijest osiguravajućih društava i njihovo značenje. Upoznat će se i povijest istih u Hrvatskoj te objasniti način njihovog poslovanja kao i specifični pokazatelji.

Četvrti dio rada objašnjava višekriterijalno odlučivanje i metode koje će se koristiti u nastavku rada.

Peti dio rada se odnosi na praktični dio gdje će se putem SAW, TOPSIS i PROMETHEE metode dobiti izbor najbolje alternative, a da bi se mogle izračunati te metode prije toga će se odrediti težine za svaki kriterij pomoću metode svojstvenog vektora. Ovaj dio rada prikazuje i usporedbu rezultata dobivenih navedenim metodama.

Zadnji dio je zaključak koji objašnjava ukratko rad te što se kroz rad istražilo te pokazalo. Osim zaključka bit će prikazan sažetak na hrvatskom i engleskom jeziku te popis literature, popis slika i tablica.

2. BONITET

2.1. Definicija boniteta

Svaka osoba ili poduzeće prije upuštanja u poslovni poduhvat, bilo s drugim poduzećem bilo zasebno, treba imati pouzdane informacije o poslovanju konkurencije, o okolini, te informacije o financijskom stanju partnera ili konkurenata. Da bi se donijela dobra poslovna odluka potrebno je imati uvid u poslovanje tj. potrebna je informacija o bonitetu. Sam pojam bonitet definiramo kao sposobnost subjekta da plati svoje obveze u dogovorenom razdoblju. Obično se temelji na povijesti plaćanja ili trenutnom kreditnom rejtingu.[12] Označava sposobnost, kvalitetu i pouzdanost pravne i fizičke osobe.

Svakim danom, zbog promjenjive okoline, raste neizvjesnost rizika o potencijalnim gubicima. Sama pretpostavka o nepovoljnom ishodu nije dovoljna već se odluka treba temeljiti i na pouzdanim informacijama o poslovnim rezultatima. Kad se sazna informacija o bonitetu lakše se donosi odluka jer se dobiva uvid u poslovanje. Saznajemo je li poduzeće pouzdano, hoće li plaćati obveze na vrijeme. Dobiva se uvid u profitabilnost poduzeća. Dobivamo jasniji pogled o stanju poduzeća sagledavanjem njegovog poslovanja kroz povijest i danas. Poduzeće treba biti sposobno platiti obveze u svakom trenutku.

Informacije o bonitetu moguće je dobiti na više načina. Pregledavanjem povijesnih podataka o poslovanju, preko gospodarskih komora, od konzultanata, iz vlastitog vođenja evidencije i slično. Ipak dva su glavna i najbolja načina dolaska do informacije o bonitetu.

- Osoba kojoj trebaju informacije proučava podatke
- Specijalizirane institucije za pružanje podataka o bonitetu

Prvim načinom osoba proučava podatke vezane za poslovanje i financijska izvješća. [13] Financijska izvješća imaju svrhu dati korisne informacije zainteresiranim subjektima.[14] Korisne informacije se očituju prije svega u njihovoj relevantnosti i vjerodostojnosti. Da bi informacije bile ispravne o tome se brinu revizori. Revizori ispituju i ocjenjuju ispravnost financijskih izvještaja, te na temelju toga daju svoje neovisno i stručno mišljenje o realnom financijskom stanju, rezultatima poslovanja i novčanim tokovima. [15]

[12] http://www.businessdictionary.com/definition/creditworthiness.html
[13] Leko V., Milinović A., Potkonjak M., (1996): Procjena boniteta trgovačkog društva, op.cit. str. 5
[14] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb., Str. 52
[15] Filipović I., (2009): Revizija, Sinergija, Zagreb, str. 11-12.

Drugi način prikupljanja informacija o bonitetu je onaj kojeg pružaju specijalizirane institucije uz određenu naknadu ili bez nje. U Hrvatskoj jedna od najpoznatijih takvih agencija je FINA.

2.2. Važnost i razlozi procjene boniteta

Poduzeća su također predmet trgovine te je za uspješnost tog trgovanja potrebno procijeniti njegovu vrijednost - cijenu. Ne postoji jednostavan način za ocjenu poduzeća, ali se sastoji od nekoliko kriterija.[16] Jedan od najvažnijih kriterija je sposobnost i profitabilnost poduzeća, njihova solventnost.

Važnost procjene boniteta očituje se u nekoliko razloga. Osnovni i glavni razlog naravno obuhvaća činjenicu da želimo izbjeći rizik poslovanja s tvrtkama koje su previše zadužene i nemaju sposobnost vratiti te dugove. Iz toga proizlazi potreba za ocjenom boniteta. Ocjena boniteta tako pokazuje je li tvrtka prezadužena, ima li sposobnost plaćanja dospjelih obveza na vrijeme i kakvo je njezino financijsko "zdravlje".[17]

Dva se temeljna razloga izdvajaju kad se govori o procjeni boniteta. Prvi razlog se očituje u potrebi da se sazna što više važnih informacija o partnerima, dobavljačima i svima koji sudjeluju u poslovnom odnosu. Važno je znati s kime se posluje, koji su uvjeti poslovanja, koji i koliki je rizik.

Drugi razlog je kad trgovačko društvo izda dugoročne vrijednosne papire. Kod emisije dionica ili vrijednosnih papira važno je da to dioničko društvo ima dobro ocijenjen bonitet. [18]Kad se dioničko društvo odluči emitirati nove dionice, razlog tome ne smije "ležati" u prijevari. Prevara bi se očitovala tako da financijske knjige pokazuju nerealnu sliku poduzeća. Krivo prezentirani podaci, lažirani, kako bi se privukli novi investitori te tako na prevaru ulagali u poduzeća za koja misle da su uspješna zbog lažiranih izvještaja. Opet dolazi do izražaja revizorska struka. Do krivog prikazivanja može doći zbog pogreške ili prijevare. Jasno da se pogreška odnosi na nenamjeran čin dok je prijevara svjesni čin namjernog zataškavanja ili falsificiranja podataka. Postoje razni oblici prijevare kao što je:

- manipuliranje, krivotvorenje računovodstvenih spisa

[16] Kopun V., Slade J., (1991): Metode procjene vrijednosti i ocjene boniteta poduzeća., Kopun i Kopun, Zagreb., str. 11
[17] http://www.poslovnaucinkovitost.eu/edukacije/predavanje/ocjena-boniteta-poduzeca
[18] Leko V., Milinović A., Potkonjak M., (1996): Procjena boniteta trgovačkog društva, op.cit. str. 7

- pogrešno prikazivanje ili namjerno ne prikazivanje događaja, transakcija i ostalih važnih informacija
- svjesna pogrešna upotreba računovodstvenih načela u vidu iznosa, klasificiranja te objavljivanja istih

Najpoznatije afere po krivotvorenju podataka su Enron i Arthur Anderson.[19]

2.3. Financijski izvještaji

Jedan od načina na koje se može procijeniti bonitet poduzeća je analizom financijskih izvještaja. Računovodstvo ima ulogu prvo prikupiti podatke i obraditi ih te iste prezentirati korisnicima koji potražuju informacije. To je ujedno i cilj financijskog izvještavanja – prikupiti i obraditi informacije te ih prezentirati u razumljivom obliku zainteresiranim korisnicima.[20] Financijska izvješća predstavljaju glavni izvor informacija o poslovanju.[21]

Financijski izvještaji su:

- bilanca
- račun dobiti i gubitka
- izvještaj o promjenama vlasničke glavnice
- izvještaj o novčanom toku
- bilješke uz financijske izvještaje

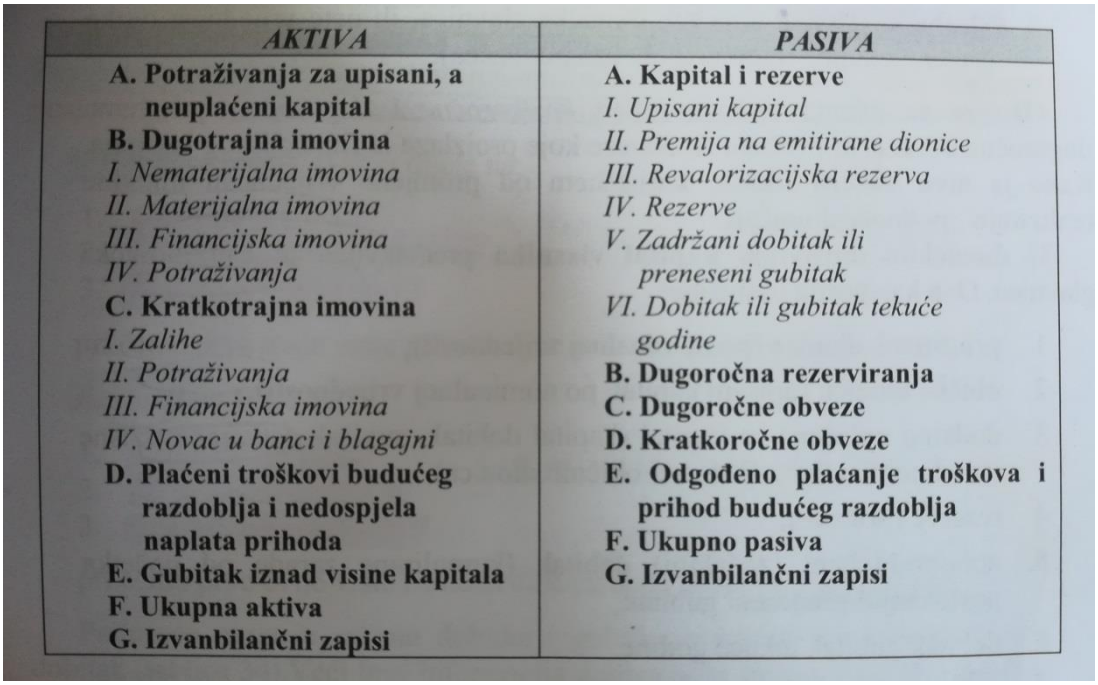
Navedeni izvještaji su međusobno povezani i pokazuju stanje unutar određenog poduzeća.[22]

2.3.1. Bilanca

Bilanca se sastoji od 3 elementa, a to su imovina, obveze i kapital. Bilanca sustavno prikazuje spomenuta tri elementa na određeni datum koji je najčešće na kraju godine. Prije donošenja zaključka o poslovanju treba uzeti u obzir da su podaci u bilanci temeljeni na povijesnim troškovima, a ne na tržišnim vrijednostima. [23]

Bilanca se sastoji od dva dijela – aktive i pasive.

[19] Soltani B., (2009): Revizija: Međunarodni pristup., MATE d.o.o., Zagreb., str.533-560.
[20] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 52
[21] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, RriF, Zagreb, str. 423
[22] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 52
[23] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, RriF, Zagreb, str. 425



AKTIVA	PASIVA
A. Potraživanja za upisani, a neuplaćeni kapital	**A. Kapital i rezerve**
B. Dugotrajna imovina	*I. Upisani kapital*
I. Nematerijalna imovina	*II. Premija na emitirane dionice*
II. Materijalna imovina	*III. Revalorizacijska rezerva*
III. Financijska imovina	*IV. Rezerve*
IV. Potraživanja	*V. Zadržani dobitak ili preneseni gubitak*
C. Kratkotrajna imovina	*VI. Dobitak ili gubitak tekuće godine*
I. Zalihe	**B. Dugoročna rezerviranja**
II. Potraživanja	**C. Dugoročne obveze**
III. Financijska imovina	**D. Kratkoročne obveze**
IV. Novac u banci i blagajni	**E. Odgođeno plaćanje troškova i prihod budućeg razdoblja**
D. Plaćeni troškovi budućeg razdoblja i nedospjela naplata prihoda	**F. Ukupno pasiva**
E. Gubitak iznad visine kapitala	**G. Izvanbilančni zapisi**
F. Ukupna aktiva	
G. Izvanbilančni zapisi	

Slika 1: Prikaz skraćene bilance

Izvor: Vidučić Lj., Pepur S., Šimić Šarić M., (2015): Financijski menadžment,op.cit. str. 425

Gornja slika pokazuje skraćeni izgled bilance. Bilanca poduzeća treba dati odgovore na pitanja o likvidnosti poduzeća, o financijskoj snazi, o zaduženosti, horizontalnoj strukturi, kakvo je sadašnje stanje poduzeća u odnosu na prethodno razdoblje i odgovor na slična pitanja. Bilanca tako predstavlja temelj za financijsku analizu poduzeća te daje uvid u snage i slabosti poduzeća. Imovina poduzeća se dijeli na materijalnu i nematerijalnu. Materijalna imovina je svaki onaj oblik koji ima fizički oblik poput zgrade, zaliha i slično, dok nematerijalna imovina nije opipljiva već su to najčešće razna zakonska i ugovorna prava poput licence ili patenta.

Imovina se također dijeli i prema vremenskom kriteriju. Tako imamo dvije grupe – kratkotrajna i dugotrajna imovina. Slika 1. prikazuje što spada u dugotrajnu, a što u kratkotrajnu imovinu. Kod kratkotrajne imovine se očekuje da će se ta imovina pretvoriti u novac u vremenu unutar godine dana, dok se kod dugoročne imovine ne očekuje da će se pretvoriti u novac u razdoblju kraćem od godine.

U pasivu bilance spadaju obveze i kapital. Obveze dijelimo na kratkoročne i dugoročne. Dugoročne su one obveze koje bi se trebale isplatiti kroz godinu dana (npr. obveze prema dobavljačima), dok su dugoročne obveze sve one koje će dospjeti na naplatu nakon jedne godine. (npr. obveza za dugoročni kredit).

S računovodstvenog aspekta kapital je dio imovine koji pripada vlasnicima. Primarno se formira pri osnivanju poduzeća. Sastoji se od uloženog kapitala i zarađenog kapitala. [24]

Suma aktive treba biti jednaka sumi pasive. Jednakost proizlazi iz toga da su to dva različita pogleda na imovinu koju poduzeće ima. [25]

2.3.2. Račun dobiti i gubitka

Račun dobiti i gubitka prikazuje prihode, rashode i financijski rezultat u određenom vremenskom periodu.[26] U usporedbi sa bilancom koja pokazuje financijski položaj poduzeća u nekom vremenskom trenutku, račun dobiti i gubitka prikazuje stanje u nekom vremenskom razdoblju. Jasno je da svako poduzeće ide prema određenim ciljevima od kojih je profitabilnost najvažniji. Odgovor na pitanje, je li poduzeće profitabilno i koliko, daje račun dobiti i gubitka.

Iz gore navedenog proizlazi jednostavna definicija računa dobiti i gubitka kao financijskog izvještaja koji pokazuje koliko prihoda i rashoda je ostvareno u određenom razdoblju te koliko iznosi dobit/gubitak. [27]

Prihode dijelimo na:

- poslovne prihode
- prihode od financiranja
- izvanredne prihode

Poslovni prihodi i prihodi od financiranja spadaju pod prihode iz redovnog poslovanja.[28]

Prihode jednostavno definiramo kao svako povećanje imovine ili smanjenje obveza gdje je završni ishod povećanje zarade. Prihodi iz redovnog poslovanje se realiziraju prodajom proizvoda tj. realizacijom proizvoda na tržištu. Ovi prihodi se odnose i na prodaju robe kao i na pružanje usluga. S obzirom da se ovi prihodi pojavljuju gotovo svaki dan, u strukturi prihoda predstavljaju najznačajniji dio. Iznos prihoda jednak je prodajnoj vrijednosti proizvoda ili usluga bez PDV-a.

[24] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 53-54.
[25] http://www.poslovni.hr/leksikon/aktiva-479
[26] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, op.cit. str. 427
[27] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 67
[28] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, op.cit. str. 427

Financijski prihodi predstavljaju onaj višak novca kojeg poduzeće može uložiti u dionice, obveznice, posuditi novac kome treba i slično. Svrha toga je postizanje prava na naknadu (npr. kamata ili dividenda) te ta naknada predstavlja financijski prihod.

Izvanredni prihodi su oni koji se ne mogu planirati jer se ne pojavljuju redovito. Ti se prihodi javljaju nakon prodaje dugotrajne imovine, sirovina, otpisa obveza i ostalih vanrednih oblika povećanja imovine ili smanjenja obveza. [29]

Kako prihodi, tako se i rashodi dijele na:

- poslovne rashode
- financijske rashode
- izvanredne rashode

gdje se poslovni i financijski rashodi odnose na rashode iz redovitog poslovanja.[30]

Rashodi su rezultat trošenja tj. smanjenja imovine ili povećanja obveza. Za razliku od prihoda, rashodi za posljedicu imaju smanjenje glavnice ili kapitala poduzeća. Rashodi uključuju vrijednost sirovina, materijala, plaćanje ljudske snage kako bi se stvorio proizvod.

Poslovni rashodi se pojavljuju redovito, a čine troškove koji su sadržani u prodanim proizvodima, troškovi nabavne vrijednosti robe i drugo.

Financijski rashodi su rezultat korištenja tuđih novčanih sredstava. Ponekad poduzeće bez toga ne može poslovati. Primjer kad poduzeće plaća kamate za korištenje tuđeg novca (npr. Kredit od banke te se trebaju otplaćivati i kamate).

Izvanredni rashodi, jednako kao i izvanredni prihodi, se ne mogu unaprijed planirati niti predvidjeti. To su neočekivane situacije poput kazne, štete, ispravka rashoda iz prošlih godina i slično. [31]

2.3.3. Izvješća o novčanom toku

Razlog zbog kojeg se sastavlja izvještaj o novčanom toku stoji u samoj važnosti novca jer izvještaj o novčanom toku prikazuje priljev i odljev novca i novčanih ekvivalenata tijekom obračunskog razdoblja.[32] Važnost novca očituje se svakodnevno kako kod pojedinca tako i u

[29] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 70-71.
[30] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, op.cit. str. 427
[31] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 70-71.
[32] http://www.propisi.hr/print.php?id=13765

poduzećima. Potreban je za kupnju materijala, za plaćanje radne snage, za podmirenje obveza, za uslugu, za kupovinu gotovih proizvoda i ostalog te je jasno da svako poduzeće najveću važnost pridaje novcu. Vlasnike poduzeća i sve ostale zanima izvor i izdaci novca. Iz tog razloga se sastavlja izvještaj koji govori o stanju novčanih sredstava u poduzeću tj. daje uvid u "zdravstveno stanje poduzeća".

Račun dobiti i gubitka često prikazuje poslovanje poduzeća kao uspješno, dok je realno stanje takvo da poduzeće ima probleme s podmirenjem obveza. Razlog proizlazi iz evidentiranja prihoda i rashoda. Naime prihodi i rashodi se knjiže onda kad su nastali, kad su zarađeni, a ne u trenutku kad je nastao primitak ili izdatak novca. Iz ove spoznaje o razlici između prihoda i rashoda te primitka i izdatka dolazi jasna potreba za navedenim izvještajem.[33] Tvrtke koje se pouzdaju samo u dobre rezultate iz računa dobiti i gubitka mogu upasti u probleme ako im je slab novčani tok jer im manjka sredstava te ne mogu naplatiti potraživanja.[34]

Da bi poduzeće znalo je li sposobno stvarati novac iz redovnog poslovanja, potrebno je primitke i izdatke klasificirati. Aktivnosti se tako klasificiraju na:

- poslovne aktivnosti
- investicije aktivnosti
- financijske aktivnosti[35]

Važno je utvrditi iz koje aktivnosti dolazi novac kako bi se dobio pravi temelj za analizu i odlučivanje. [36]

Pod pojmom poslovnih aktivnosti podrazumijevaju se glavne aktivnosti koje stvaraju prihod te imaju najveći utjecaj na dobit ili gubitak poduzeća. Najčešći primjeri su novčani primici od pružanja usluga ili prodaje robe, od određenih naknada, od osiguravajućih društava te izdaci prema dobavljačima, prema zaposlenima i slično. Jasno je da poduzeće ostvaruje najviše novca na redovnim aktivnostima, a ako to nije tako trebalo bi vidjeti simptome i preispitati potom uzroke.

Investicijske aktivnosti su one koje se odnose na promjene na dugotrajnoj imovini. Kao primjeri navode se novčani primici od prodaje nekretnina, imovine, strojeva, novčani primici od povrata

[33] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 81.
[34] http://www.poslovni.hr/tips-and-tricks/znate-li-cemu-sluze-informacije-o-novcanom-toku-229364
[35] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 83.
[36] http://www.poslovni.hr/tips-and-tricks/znate-li-cemu-sluze-informacije-o-novcanom-toku-229364

danih kredita, od prodaje dionica, obveznica. Novčani izdaci mogu biti za nabavu nekretnine, opreme, izdaci za kredit, za kupnju dionica i ostalo.

Financijske aktivnosti se odnose na one koje financiraju poslovanje kao što su primici od emisije dionica, obveznica, primici od primljenih kredita dok se izdaci odnose na izdatke za otkup vlastitih dionica, dividenda i ostalo.

Novčani tijekovi se mogu prikazati pomoću dvije metode:

a) direktne metode

b) indirektne metode

razlika između ovih metoda stoji u tome da se kod direktne bruto primici i izdaci razvrstavaju po trima gore navedenim aktivnostima[37], dok se kod indirektne metode novčani tijek prikazuje na temelju bilance i računa dobiti i gubitka. Zbog svoje jednostavnosti češće se koristi direktna metoda.

2.3.4. Izvještaj o promjenama vlasničke glavnice

Izvještaj o promjenama vlasničke glavnice prikazuje sve promjene koje su se na glavnici dogodile te podatke o kapitalu i pričuvama koje se preuzimaju iz knjigovodstva zadnji dan obračunskog razdoblja. [38]

2.3.5. Bilješke uz financijske izvještaje

Uz gore navedena 4 izvještaja postoje razni dokumenti koji nadopunjuju spomenute izvještaje. Jedan od tih dokumenata su bilješke uz financijske izvještaje koje objašnjavaju pojedine strukture i vrijednosti u izvještajima tj. objašnjavaju one podatke koji se ne mogu iščitati iz spomenutih izvještaja. Ti podaci su važni kako bi se predstavile potpune informacije i donijelo ocjenu o poslovanju poduzeća.

Bilješke koriste menadžeri, potencijalni investitori, kreditori i državne institucije stoga informacije u bilješkama trebaju biti pouzdane i razumljive te sastavljene po određenim pravilima. Jasno je da postoji razlika između bilješki koje se dostavljaju menadžerima (u odnosu

[37] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 83-86.
[38] Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, op.cit. str. 430-434.

na ostale korisnike istih) u vidu detaljnijih informacija, učestalosti sastavljanja i slično, a koje će se informacije prikazati ovisi o zahtjevima korisnika.[39]

2.4. Financijski pokazatelji

Nakon što se dobiju na uvid financijski izvještaji mogu se izračunati financijski pokazatelji. Financijski pokazatelji stavljaju u odnos jednu ekonomsku veličinu s drugom gdje svaki pokazatelj treba dati određenu informaciju o stanju unutar poduzeća i biti podloga za donošenje kvalitetne odluke.[40] S obzirom na vrijeme financijske pokazatelje možemo svrstati u dvije skupine:

a) razmatraju se pokazatelji unutar određenog vremenskog perioda i temelje se na podacima o dobiti i gubitku (najčešće je to godina).
b) financijski pokazatelji se temelje na određenom vremenu koje je jednako vremenu kad se sastavila bilanca i pokazuje stanje unutar poduzeća u tom razdoblju.

Jedan od najčešćih klasifikacija pokazatelja je:

- Pokazatelj likvidnosti – mjeri sposobnost poduzeća da podmiri kratkoročne obveze kratkoročnom imovinom. Razlikuju se 4 pokazatelja (koeficijent trenutne likvidnosti, ubrzane likvidnosti, tekuće likvidnosti i financijske stabilnosti). Općenito govoreći likvidnost definiramo kao svojstvo imovine da se u pretvori u gotovinu u razdoblju koje je potrebno da bi se pokrile obveze. Ako poduzeće nije likvidno posluje s poteškoćama.[41]
- Pokazatelj zaduženosti – tri najvažnija pokazatelja (koeficijent zaduženosti, vlastitog financiranja i koeficijent financiranja) prikazuju koliko je imovine financirano iz vlastitog, a koliko iz tuđeg kapitala.
- Pokazatelj aktivnosti - ovi pokazatelji govore kolika je brzina cirkulacije imovine. Najvažniji pokazatelji su koeficijent obrta ukupne imovine, obrta kratkotrajne imovine, obrta potraživanja i trajanje naplate potraživanja u danima.
- Pokazatelj ekonomičnosti – pokazuju koliko se prihoda ostvari po jedinici rashoda te se tako dobiva ocjena ekonomičnosti poslovanja. Poželjno je da je koeficijent ekonomičnosti što veći. Pokazatelji su: ekonomičnost ukupnog poslovanja,

[39] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 89-90.
[40] http://www.efos.unios.hr/financiranje-poduzetnickog-pothvata/wp-content/uploads/sites/224/2013/04/8_financijski-pokazatelji.pdf
[41] http://profitiraj.hr/financijski-pokazatelji-pokazatelji-likvidnosti/

ekonomičnost poslovanja tj. prodaje, ekonomičnost financiranja i ekonomičnost izvanrednih aktivnosti

- Pokazatelj profitabilnosti – ovi pokazatelji pokazuju moć tvrtke da zaradi tj. pokazuju kako poduzeće upravlja imovinom i dugom da bi ostvarila profit. Razlikujemo slijedeće pokazatelje: neto marža profita, bruto marža profita, neto rentabilnost imovine, bruto rentabilnost imovine, rentabilnost vlastitog kapitala.
- Pokazatelj investiranja – ovi pokazatelji mjere koliko je uspješno bilo ulaganje u dionice gdje se gleda dobit po dionici. Pokazatelji su: dobit po dionici, dividenda po dionici, odnos cijene i dobiti po dionici, ukupna rentabilnost dionice, dividenda rentabilnost dionice.[42]

Za ocjenu boniteta prema FINI po polugodišnjim i godišnjim obračunima pokazatelji se dijele u iduće skupine:

- Pokazatelji financijske stabilnosti
- Pokazatelji likvidnosti
- Pokazatelji poslovne uspješnosti[43]

2.5. BON-1, BON-2, BONPLUS

BON-1, BON-2 i BONPLUS uglavnom sadrže podatke o procjeni boniteta, a ako nisu dovoljne tad je potrebno posjetiti određeno poduzeće i tražiti informacije koje se nalaze u financijskim izvještajima[44] koji su gore objašnjeni.

BON-1 uspoređuje ostvarenja poduzeća u odnosu na poduzetnike u podrazredu i poduzetnike koji imaju istu veličinu u podrazredu.

BON-1 je podijeljen na pet osnovnih dijelova:

- Opći podaci o poduzetniku (sadrži informacije o nazivu poduzetnika, adresi, OIB-u, matičnom broju, obliku vlasništva, veličini poduzeća, nazivu razreda djelatnosti, broju poduzetnika u razredu, broju poduzetnika iste veličine u razredu, broju gubitnika i broju dobitnika u razredu)

[42] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 243-244.
[43] Vujević I., (2003) : Financijska analiza, Ekonomski fakultet Split, Split, str. 147.
[44] Leko V., Milinović A., Potkonjak M., (1996): Procjena boniteta trgovačkog društva, op.cit. str. 13-14.

- Podaci i pokazatelji poslovanja za prošlu godinu (podaci o imovini i izvorima sredstava, financijski rezultati, pokazatelji financijske stabilnosti, zaduženosti i likvidnosti, pokazatelji poslovne uspješnosti)
- Podaci o zaposlenima (podaci o broju zaposlenih i prosječnoj bruto plaći po zaposlenom za prethodne četiri godine)
- Podaci o poslovanju za prethodno razdoblje
- Stanje novčanih sredstava (stanje na žiro računima)[45]

BON-2 sadrži podatke o subjektu i stanju sredstava na računu, iznos primitaka i stanje na računu u proteklih 30 dana, koliko iznosi odobreni kredit, a koliko su nepodmirene obveze. Sadrži podatke o blokadi računa u proteklih 6 mjeseci.

BONPLUS sadrži još kvalitetnije i podobnije informacije koje daju razumljivi pogled na situaciju u poduzeću te tako mogu donijeti jasniju odluku u poslovanju. BONPLUS sadrži ocjenu financijskog rejtinga odnosno pokazuje procjenu sposobnosti poduzeća da u budućem vremenu podmiri svoje obveze na vrijeme. Skala ide od 1 do 10.[46]

[45] Dropulić I., (2013): Skripta za vježbe, Menadžersko računovodstvo, Ekonomski fakultet Split, Split, str. 34-39.
[46] https://www.fina.hr/Default.aspx?sec=1278

3. OSIGURAVAJUĆE DRUŠTVO

3.1. Povijest osiguravajućih društava

Čovjek od davnina vidi razne katastrofe uzrokovane bilo prirodom bilo ljudskom rukom te nastoji zaštiti svoj život i/ili imovinu. Takva potreba za zaštitom uz pomoć tehnološkog napretka dovela je do sustava osiguranja kakvog danas poznajemo.

Još iz 15. stoljeća poznati hrvatski znanstvenik Benedikt Kotruljević u u svojoj knjizi "O trgovini i savršenom trgovcu" naglašava kako nikad nijedan trgovac nije propao ako je plaćao osiguranje, dok mnogi jesu kad su se upuštali u rizik bez plaćanja osiguranja. Ipak ideja o osiguranju ide u još dalju povijest. 3000. godina prije Krista kad su kineski trgovci prevozili robu na rijeci, zbog struja su prekrcavali robu s većih brodica na manje kako bi se smanjio rizik od potapanja i uništavanja cijelog broja paketa. Ako bi se dogodio rizik, one trgovce koje nepogoda "nije pogodila" nadoknadili su štetu trgovcima koji su ostali bez robe. Tako je prvi put došla ideja o raspodjeli rizika. Osim Kineza postoje i brojni drugi zapisi poput zakona koji je donio babilnoski kralj Hamurabi koji također nalaže što se treba napraviti u slučaju štete. U Indiji se nalazi početak osiguranja kod kreditnog rizika gdje su se uračunavale kamate s obzirom na rizičnost putovanja. Ipak u 11. Stoljeću dolazi do konkretnijeg razvoja osiguranja u vidu staleških udruga koje su propisale određene pomoći kod požara, bolesti, smrti. 1234. godine katolička crkva daje zabranu dekretom o sklapanju pomorskih zajmova smatrajući ih lihvarstvom.[47] U to vrijeme i Toma Akvinski, talijanski dominikanac i poznati filozof u svom djelu također kritizira lihvarenja kod robno-novčane razmjene.[48] Ipak to nije zaustavilo razvoj pomorskog osiguranja.

1384. godine izdana je prva polica osiguranja u Pizi.

1536. godine sklopljen je prvi ugovor o životnom osiguranju

1568. godine Zakon o pomorskom osiguranju

Otkrićem Amerike te prekomorskim vezama nastaje sve veća potreba za osiguranjima i razvija se premijsko osiguranje.

1693. godine konstruirana je prva tablica smrtnosti

[47] Ćurak M., Jakovčević D., (2007): Osiguranje i rizici, op.cit. str. 17-18.
[48] Reić Z., Mihaljević Kosor M., šimić V., (2017):Ekonomija, Ekonomski fakultet Split, Split, str.17.

3.2. Značenje i pojam osiguravajućeg društva

Sam pojam osiguranje proizlazi iz činjenice da bi nešto što nam je važno trebalo zaštiti - osigurati zbog postajanja rizika. Zato se osiguranje uvijek odnosi na zaštitu od rizika nastupanja nekog nepovoljnog događaja. Pojedinac, tvrtka ili društvena zajednica plaća određenu svotu novca - premiju tako da bi uslijed određene nevolje dobio novac. U pravilu osiguravaju se ljudi izloženi istim rizicima koji imaju cilj da zajednički podnesu nevolju koja neće pogoditi sve njih, već samo neke. U osiguranju sudjeluju četiri subjekta: osiguravatelj, ugovaratelj osiguranja, osiguranik, reosiguravatelj.

Osiguravatelj je osiguravajuće društvo koje se obvezuje da će osiguraniku isplatiti određeni iznos ukoliko dođe do štete. Ugovaratelj osiguranja je posrednik koji ugovara osiguranje i plaća premiju za osiguranika. Nema pravo koristiti prava iz ugovora bez pristanka osiguranika. Osiguranik je osoba čija se imovina ili život osigurava. Reosiguravatelj je osiguravajuće društvo koje od drugih osiguravajućih društava preuzima dio ili čitav rizik tj. obvezu za isplatu naknade osiguraniku, a reosiguravatelj time dobiva premiju koju plaća osiguravajuće društvo.[49] Kod svakog osiguranja treba biti definiran predmet osiguranja, opasnost od koje se osigurava, vrijeme trajanja osiguranja i način na koji će se podmiriti šteta. Predmet osiguranja može biti neki objekt, materijalni predmeti, poljoprivredni objekti, čovjek i sve ostalo što može biti oštećeno, ukradeno ili uništeno. Sve što je osobi važno može se osigurati. Opasnosti mogu biti razne (od požara, poplava, udara groma, provala, krađe i ostalog). Treba definirati vrijeme trajanja osiguranja te odrediti u kojem obliku će biti isplaćena naknada. Definirati isplaćuje li se ukupna naknada, primjenjuje li se načelo proporcije i slično. Da bi se osiguranje bilo valjano trebaju se ispuniti uvjeti:

- Da je događaj budući, da nije izvjestan i da je neovisan o volji ugovaratelja
- Da se rizik može procijeniti
- Da je šteta procjenjiva[50]

Da bi se moglo ugovoriti osiguranje, korisnik osiguranja plaća premiju. Premija je iznos što ga isti plaća prilikom sklapanja ugovora. Premija je ubiti cijena osiguranja.

Jedan dio premije se koristi da bi se pokrili troškovi obavljanja djelatnosti osiguranja kao što su plaće zaposlenika, troškovi održavanja, marketinški troškovi i ostalo. Ipak glavni dio premije

[49] Vukičević M., Odobašić S., (2011): Osnove financija, op.cit. str. 249 - 250.
[50] Bijelić M., (2002): Osiguranje i reosiguranje, Tectus, Zagreb, str.28-29.

je namijenjen za nadoknadu štete i isplatu određene naknade ukoliko bude nepovoljan ishod bilo da je riječ o imovini ili ljudskom životu.[51] Koliko će iznositi premija ovisi kolika je svota, rizik, koliko traje samo osiguranje te kolika je kamatna stopa. Hoće li se i kada dogoditi nepovoljan događaj osiguravajuće društvo (vrijedi za životna osiguranja gdje se koriste tablice smrtnosti) predviđa uz pomoć dviju znanosti – statistike i matematike čiji je doprinos u ovoj djelatnosti izuzetan i nezamisliv ovakvim kakvim danas poznajemo osiguranja. Koristeći zakon velikih brojeva i račun vjerojatnosti formirale su se gore spomenute tablice smrtnosti.

Osim plaćanja premije od strane osiguranika osiguravatelju, korisnik može uplatiti štednju te tim ugovorom osiguravatelj isplaćuje odgovarajući novčani iznos – rentu. Renta se može isplaćivati godišnje, ispod godišnje i kontinuirano ovisno o tome kakav je sklopljeni ugovor.[52]

Osiguravajuća društva dijelimo na životna i neživotna osiguranja.

3.3. Osiguravajuća društva u financijskom pogledu

Osiguravajuća društva spadaju u nebankovne institucije. Princip njihovog poslovanja je dosta sličan bankama gdje se novac prikuplja i plasira između suficitarnih i deficitarnih jedinica čime nebankovne institucije imaju posredničku ulogu.

Osiguravajuća društva posluju na temelju ugovora. Ova društva karakterizira stalan priljev novca – premija na temelju čega osiguranje i posluje. Ova sredstva imaju dugoročan karakter što omogućava osiguravajućim društvima plasman slobodnih novčanih sredstava u svakojake oblike investicijskog osiguranja.[53]

3.4. Osiguravajuća društva u Hrvatskoj

Osiguravajuće društvo postoji u Hrvatskoj od 1884. godine u Zagrebu kao osiguravajuća zadruga pod imenom "Croatia" gdje je zagrebačko poglavarstvo dalo kapital zbog borbe protiv ekonomske ovisnosti o strancima. Od 1945. godine do Hrvatske neovisnosti 1991. godine sama organizacija osiguranja ima nekoliko faza, ali sve ih obilježava državni monopol. 1991. godine osiguranja prelaze na poslovanje u modernim tržišnim uvjetima. Krajem 1999. godine djeluje 26 društava za osiguranje.[54] 2017. godine djeluju 24 osiguravajuća društva.[55]

[51] http://www.moj-bankar.hr/Kazalo/P/Premija-osiguranja
[52] Pivac S., Marasović B., Skripta, Aktuarska matematika, Ekonomski fakultet Split, Split
[53] Nikolić N., Pečarić M., (2012): Uvod u financije, op.cit. str.166-171.
[54] Bijelić M., (2002): Osiguranje i reosiguranje, Tectus, Zagreb, str. 33-34.
[55] https://www.huo.hr/hrv/arhiva/1/trziste-osiguranja-u-rh-za-studeni-2017-/602/detalji/

3.5. Bonitet osiguravajućih društava

Bonitet osiguravajućih društava se dobiva na temelju financijskih izvještaja koji su pojašnjeni u drugom djelu ovog rada. Kod osiguravajućih društava iznimno je važno naglasiti da je njihovo poslovanje specifično te osim spomenutih financijskih izvještaja, ova društva obvezna su Hrvatskoj agenciji za nadzor financijskih usluga dostaviti i idućih 8 izvještaja:

1. Izvještaj o pregledu ulaganja

2. Izvještaj o registru imovine za pokriće tehničkih pričuva

3. Izvještaj o starosnoj strukturi potraživanja iz poslova izravnog osiguranja

4. Izvještaj o prihodima i troškovima ulaganja prema izvoru sredstava

5. Račun dobiti i gubitka po vrstama i rizicima osiguranja

6. Račun dobiti i gubitka za poslove reosiguranja

7. Izvještaj o ročnoj usklađenosti imovine za pokriće matematičke pričuve s obvezama iz matematičke pričuve

8. Izvještaj o ročnoj usklađenosti imovine za pokriće tehničkih pričuva osim matematičke pričuve s obvezama iz tehničkih pričuva osim matematičke pričuve [56]

3.5.1. Specifični pokazatelji

Zbog spomenutog specifičnog poslovanja banka koriste se posebni pokazatelji kako bi se analiziralo osiguravajuće društvo, a ti pokazatelji su:

- Razmjer šteta- ovaj pokazatelj se računa kao zbroj likvidirane štete, promjena pričuve za štete i promjena ostalih tehničkih pričuva u odnosu na zarađenu premiju. Za osiguranja je uobičajeno da se ovaj pokazatelj kreće između 50 do 70%. Povoljno je za osiguravajuća društva da ovaj pokazatelj postupkom komparativne analize pokazuje tendenciju padanja.
- Razmjer troškova – računa se kao zbroj poslovnih rashoda i ostalih osigurateljno – tehničkih izdataka u odnosu na zarađenu premiju umanjenu za dio premije predane u reosiguranje. Uobičajeni raspon ovog pokazatelja za djelatnost osiguranja je između 20 i 30%.

[56] https://www.hanfa.hr/uploads/2016/04/22/1461315083_2de84389b28e2a283443845895671d0d.pdf

- Kombinirani razmjer - računa se kao zbroj prethodna dva pokazatelja, a prikazuje koji je rezultat poslovanja prije uključivanja prihoda od ulaganja sredstava. Idealna je situacija kad kombinirani razmjer ne prelazi 100%, ali moguće je da ako prethodna dva pokazatelja premašuju zarađenu premiju da će osiguravajuće društvo ostvariti pozitivan rezultat na temelju neto prihoda od ulaganja i ostalih prihoda.
- Pokazatelj rezultata ulaganja – računa se kao odnos prihoda od ulaganja umanjenih za troškove ulaganja i stanje ulaganja.
- Pokazatelj rezultata ulaganja kao postotak zarađene premije (pokazatelj se može pratiti za životna i neživotna osiguranja).
- Pokazatelj odnosa poslovnih rashoda i zarađene premije – poslovni rashodi uključuju troškove uprave i pribave te provizije od reosiguranja dok troškovi pribave uključuju troškove nastale nakon sklopljenog ugovora o osiguranju. Troškovi uprave su troškovi koji su vezani uz upravljanje portfeljom, obradu police i uz ostale administrativne troškove.
- Pokazatelj odnosa troškova pribave i bruto premije.
- Pokazatelj zaduženosti – pokazuje koliko se poduzeće financira iz vlastitih, a koliko iz tuđih izvora financiranja.
- Pokazatelj odnosa tehničkih pričuva i kapitala.
- Pokazatelj profitabilnosti - utvrđivanje poslovnog rezultata posebno se računa za neživotna, a posebno za životna osiguranja te za iskazivanje jedinstvenog rezultata na razini društva uobičajeno se računa marža profita. Rentabilnost imovine (ROA) stavlja u odnos neto dobit i ukupnu aktivu. Osim marže profita i rentabilnosti imovine značajna je i rentabilnost kapitala (ROE) koja stavlja u odnos neto dobit i kapital.[57]

[57] Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, op.cit. Str. 320 - 325.

4. VIŠEKRITERIJALNO ODLUČIVANJE

4.1. Uvod u višekriterijalno odlučivanje i osnovni pojmovi

Svakodnevno donosimo odluke, bilo da riječ o "nevažnim stvarima", sve do bitnih situacija. Tako su i menadžeri u poslovanju suočeni sa donošenjem odluka gdje jedna odluka može promijeniti cijeli tijek poslovanja. Tako se razlikuju dobre i loše odluke gdje dobra odluka može imati loš ishod, ali svakako ako je ispravno donesena ostaje dobra odluka. Kao i što loša odluka može imati dobar ishod, ali je i dalje loša odluka.

Pod pojmom višekriterijalnog odlučivanja podrazumijevamo donošenje odluke o najboljem izboru kad postoji nekoliko kriterija koji su uglavnom u konfliktu. Primjer je izbor ljetovanja gdje uzimamo kriterije poput cijene, lokacije, udaljenosti do mora i slično. Tako i poduzeće tj. menadžer nailazi na nekoliko kriterija koji su u konfliktu npr. kod izbora adekvatne strategije.

Problemi su različiti, ali uglavnom imaju nekoliko zajedničkih obilježja:

- **Višestrukost kriterija** – jasno je da svaki odabir ima nekoliko kriterija te je prvi korak izabrati kriterije koji su važni za donosioca odluke
- **Konflikti među kriterijim**a - Kriteriji su uglavnom u konfliktu
- **Neusporedive jedinice mjere** – ako uzmemo za primjer automobil i kriterije poput potrošnje, sigurnosti i troškova uočava se da su mjerne jedinice različite (potrošnja se mjeri u litrama po kilometru, sigurnost kroz opis, a troškovi su izraženi u novčanim jedinicama)

Važnost višekriterijalnog odlučivanja proizlazi iz činjenice da je većina problema odlučivanja višekriterijalna. Iz toga proizlazi veća zainteresirnost za višekriterijalno odlučivanje. Osim navedenog razloga pojačani interes za višekriterijalno odlučivanje je u izuzetnom razvoju mogućnosti, brzine, kapaciteta i fleksibilnosti računarskih strojeva. Postoji komunikacija između računala i donosioca odluke.

Kod višekriterijalnog odlučivanja postoji uglavnom određen broj alternativa koje su unaprijed poznate te je za konačnu odluku potrebno odrediti najbolju alternativu nakon što smo ocijenili sve alternative po zadanim kriterijima. Konačna odluka (izbor najbolje alternative, rang alternativa i izbor skupa najboljih alternativa) se donosi na temelju usporedbi svih alternativa po odabranim kriterijima u isto vrijeme.

Postoji više metoda za odabir najbolje odluke, a u nastavku rada bit će prikazana metoda za određivanje težina i tri metode za izbor najbolje alternative. [58]

4.2. Metoda svojstvenog vektora

Ovu metodu je razvio Thomas L. Saaty koja se koristi za određivanje težina kriterija i jedna je od najpoznatijih metoda za izbor najbolje alternative – AHP metoda. U ovoj metodi donosilac odluke treba prosuditi relativne važnosti kriterija tj. usporediti po važnosti sve moguće parove kriterija. Broj procjena je jednak broju kombinacija bez ponavljanja drugog razreda od n elemenata (n=broj kriterija)

$$\binom{n}{2} = \frac{n \cdot (n-1)}{2}$$

Pretpostavlja se da je donosiocu odluke lakše procijeniti relativne važnosti za svaki par kriterija, nego odjednom odrediti težine ili rangirati sve kriterije zajedno, a da bismo došli do težina kriterija potrebno je za svaki par kriterija (X_i, X_j) procijeniti njihovu relativnu važnost tako da se donosilac odluke odluči za jednu od idućih tvrdnji:

a) $a_{ij} = \frac{w_i}{w_j} = 1$ oba kriterija su jednako važna

b) $a_{ij} = \frac{w_i}{w_j} > 1$ kriterij X_i je važniji od kriterija X_j

c) $a_{ij} = \frac{w_i}{w_j} < 1$ kriterij X_j je važniji od kriterija X_i

Kod b) ili c) tvrdnje intezitet preferencije moguće je izraziti sa više stupnjeva. Originalna skala sadrži pet stupnjeva i četiri međustupnja.

[58] Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, op.cit. str. 1-27.

Tablica 1. Saatyeva skala važnosti i njen opis

INTENZITET VAŽNOSTI	DEFINICIJA	OBJAŠNJENJE
1	Jednaka važnost	Dva kriterija doprinose jednako danom cilju
3	Slaba preferencija jednog nad drugim	Iskustvo i prosudbe slabo favoriziraju jedan kriterij nad drugim
5	Bitna ili jaka preferencija	Iskustvo i prosudbe jako favoriziraju jedan kriterij nad drugim
7	Uvjerljiva preferencija	Jedan kriterij je u prednosti nad drugim i njegova dominacija je dokazana u praksi
9	Apsolutna preferencija	Očita prednost najvišeg mogućeg ranga jednog kriterija nad drugim
2,4,6,8	Međuvrijednosti između dviju susjednih procjena	Kada je potreban kompromis

Izvor: Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, op.cit. str. 74

Pomoću skale određuju se omjeri važnosti za sve parove kriterija i formira se matica omjera važnosti A čiji su elementi te procjene a_{ij}.

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} w_1 / w_1 & w_1 / w_2 & \dots & w_1 / w_n \\ w_2 / w_1 & w_2 / w_2 & \dots & w_2 / w_n \\ \dots & \dots & \dots & \dots \\ w_n / w_1 & w_n / w_2 & \dots & w_n / w_n \end{bmatrix}$$

gdje je

$$a_{ij} = \frac{w_i}{w_j}$$

Matrica A ima sve ima sve elemente pozitivne te za istu vrijedi svojstvo reciprociteta

$$a_{ij} = \frac{1}{a_{ji}}$$

tj. element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale jer vrijedi ovaj odnos:

$$\frac{w_i}{w_j} = \frac{1}{w_j / w_i}$$

Drugo svojstvo koje treba vrijediti za takvu matricu međusobnih usporedbi je da vrijedi ova relacija

$$a_{ij} = a_{ik} \cdot a_{kj}$$

Nakon ovoga računamo težine W_j na način da pomnožimo matricu A sa vektorom težina W, tj.

$$A \cdot W = \begin{bmatrix} w_1/w_1 & w_1/w_2 & \dots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \dots & w_2/w_n \\ \dots & \dots & \dots & \dots \\ w_n/w_1 & w_n/w_2 & \dots & w_n/w_n \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} w_1 + w_1 + \dots + w_1 \\ w_2 + w_2 + \dots + w_2 \\ \dots \\ w_n + w_n + \dots + w_n \end{bmatrix} =$$

$$= n \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = n \cdot W$$

Dobivamo jednadžbu

$$A \cdot W = n \cdot W \qquad (n \text{ je svojstvena vrijednost matrice } A)$$

tj. $(A - n \cdot I) \cdot W = 0$

Matrica A ima rang 1. Poteškoće koje se pojavljuju u procesima odlučivanja uzrokovane su nekonzistentnošću procjena relativnih omjera važnosti kriterija te je posljedica gubitak svojstava omjera važnosti zbog kojih je matrica A imala samo jednu svojstvenu vrijednost. Tad se od svih svojstvenih vrijednosti odabire najveća, a razlika između najveće svojstvene vrijednosti matrice A i broja n koristi se za mjerenje konzistentnosti procjena u danoj matrici A.

Zato se računa indeks konzistencije:

$$C\ I = \frac{\lambda_{\max} - n}{n - 1}$$

te se računa omjer konzistencije CR

$$\mathbf{CR = CI / RI}$$

RI je slučajni indeks tj. indeks konzistencije za matrice reda slučajnih generiranih usporedbi u parovima (koristi se tablica koja ima izračunate vrijednosti)

n	1	2	3	4	5	6	7	8	9	10
RI	0	0	0.52	0.89	1.11	1.25	1.35	1.40	1.45	1.49

Ako za matricu A vrijedi CR ≤ 0.10 procjene omjera relativnih važnosti kriterija se smatraju prihvatljivim. Određivanje λmax je komplicirano, a da bi sustav jednadžbi $(\boldsymbol{A - n \cdot I}) \cdot \boldsymbol{W = 0}$ imao netrivijalno rješenje njegova determinanta mora biti jednaka nuli. Zbog toga određivanje svojstvenih vrijednosti matrice A vodi na rješavanje jednadžbe

$$\mathbf{det}\,(\boldsymbol{A - \lambda \cdot I}) = \mathbf{0}$$

ova algebarska jednadžba n-tog stupnja nije jednostavna za rješavanje te se zbog toga za određivanje vrijednosti matrice A (i vrijednosti vektora W) koriste približne metode računanja svojstvenih vrijednosti ili gotovi softverski paketi. Težine kriterija se računaju na sljedeći način

$$(\boldsymbol{A - \lambda_{max} \cdot I}) \cdot \boldsymbol{W} = \mathbf{0}$$

$$\boldsymbol{w_i > 0,\ i = 1, 2, \ldots\ldots, n}$$

$$\sum_{i=1}^{n} \boldsymbol{w_i} = \mathbf{1}$$

tj. traže se rješenja sustava uz dodatne uvjete nenegativnosti i normalizacije vrijednosti komponenata rješenja.[59]

4.3. Metoda jednostavnog zbrajanja težina

Ova metoda jedna je od najpoznatijih te se vrlo često koristi. Metoda se koristi tako da se svakom kriteriju pridruži ponder važnosti – težina koji je dobiven ili direktno od donosioca odluke ili nekom od metoda za određivanje težine kriterija. Ukupni skor za svaku alternativu

[59] Ibid., str. 73 - 82.

se dobije tako da se pomnože podaci iz matrice odluke za svaki kriterij s težinom tog kriterija. Kad se sumiraju umnošci svih alternativa pojedinačno dobiva se konačna ocjena svake alternative, a ona alternativa s najvećim skorom (najvećim ponderiranim prosjekom) je ona koja se predlaže donosiocu odluke.

Matematički se metoda postavlja na način da prvo pretpostavimo da imamo skup težina za sve atribute:

$$\mathbf{W = \{ w_1, w_2, \ldots, w_n \}}$$

Te je najbolja alternativa A* za koji vrijedi:

$$A^* = \{ A_i \mid \max_i \frac{\sum_{j=1}^{n} w_j x_{ij}}{\sum_{j=1}^{n} w_j} \}$$

gdje je x_{ij} je procjena *i*-te alternative po *j*-tom atributu u nekoj numerički usporedivoj skali što znači da je potrebno provesti transformaciju atributa ako nisu zadani u istim mjernim jedinicama. Ipak uglavnom imamo normalizirane težine pa vrijedi $\sum w_j = 1$.[60]

4.4. TOPSIS metoda

Ovu metodu su razvili Hwang i Yoon, a temelji se na tome da je najbolja alternativa ona koja ima najmanju udaljenost od idealne alternative i najveću udaljenost od antiidealne alternative. Istovremeno se razmatra udaljenost s idealnim i antiidealnim rješenjem koristeći pojam relativne bliskosti te se tako određuje konačan rang alternativa.

Dana je matrica odluke D:

$$D = \begin{array}{c} \\ A_1 \\ A_2 \\ \cdot \\ A_m \end{array} \begin{array}{c} \begin{array}{cccc} X_1 & X_2 & & X_n \end{array} \\ \begin{bmatrix} x_{11} & x_{12} & \ldots\ldots\ldots & x_{1n} \\ x_{21} & x_{22} & \ldots\ldots\ldots & x_{2n} \\ \ldots & \ldots & \ldots\ldots\ldots & \ldots \\ x_{m1} & x_{m2} & \ldots\ldots\ldots & x_{mn} \end{bmatrix} \end{array}$$

[60] Ibid., str. 128.

gdje je $\{A_1, A_2, \ldots, A_m\}$ skup razmatranih alternativa, a $\{ X_1, X_2, \ldots, X_n\}$skup kriterija na temelju kojih se rangiraju ili odabiru najbolje alternative.

Ova metoda pretpostavlja da su svi kriteriji ili "benefit" ili "troškovni" te ako je neki kriterij izražen opisno da ga treba kvantificirati i pretpostavlja se da postoji skup težina koji je dobiven od strane donosioca odluke.

Algoritam TOPSIS metode:

1. **Korak – odrediti idealno i antiidealno rješenje**

Idealna alternativa je ona koja sadrži najbolje vrijednosti po svakom atributu tj.

$$A^+ = \{ (\max x_{ij} \mid j \in J), (\min x_{ij} \mid j \in J'), i = 1, 2, \ldots, m \} =$$

$$= \{ x_1^+, x_2^+, \ldots , x_n^+ \}$$

gdje je *J* skup indeksa benefit, a *J'* skup indeksa troškovnih atributa.

Antiidealna alternativa izgleda ovako:

$$A^- = \{ (\min x_{ij} \mid j \in J), (\max x_{ij} \mid j \in J'), i = 1, 2, \ldots, m \} =$$

$$= \{ x_1^-, x_2^-, \ldots , x_n^- \}$$

Ovako napisane alternative prikazuju najviše preferiranu i najmanje preferiranu alternativu tj. idealno i negativno rješenje. Ovakve alternative ne postoje unutar ponuđenog skupa jer bi to značilo da je problem već riješen.

2. **Korak – Transformacija atributa**

Atributi se trebaju transformirati da se dobiju bezdimenzionalne veličine kako bi se ti atributi (kriteriji) mogu usporediti. Jedan od načina transformacije je vektorska normalizacija gdje se svaki stupac u matrici –vektor X_j dijeli s normom tog vektora.

$$\overline{X_j} = \frac{X_j}{\| X_j \|} = \frac{X_j}{\sqrt{\sum_{i=1}^{m} x_{ij}^2}}, \quad j = 1, 2, \ldots, n$$

gdje je $\|X_j\|$ Euklidska norma vektora X_j. Na taj način će novi vektori atributa svi imati jediničnu dužinu.

Time je dobivena transformirana matrica odluke $\boldsymbol{R} = [r_{ij}]$, gdje je

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^{m} x_{ij}^2}}, \; za \forall \, i, j.$$

O ovime su transformirani i reci matrice odluke koji postaju alternative pa imamo:

$$\overline{A_i} = (t_{i1}, t_{i2}, \ldots, t_{in}) = \left(\frac{x_{i1}}{\|X_1\|}, \frac{x_{i2}}{\|X_2\|}, \ldots, \frac{x_{in}}{\|X_n\|} \right), \quad za \quad i = 1, \ldots, m.$$

Analogno

$$\overline{A^+} = (t_1^+, t_2^+, \ldots, t_n^+) = \left(\frac{x_1^+}{\|X_1\|}, \frac{x_2^+}{\|X_2\|}, \ldots, \frac{x_n^+}{\|X_n\|} \right)$$

$$\overline{A^-} = (t_1^-, t_2^-, \ldots, t_n^-) = \left(\frac{x_1^-}{\|X_1\|}, \frac{x_2^-}{\|X_2\|}, \ldots, \frac{x_n^-}{\|X_n\|} \right)$$

3. Korak – izračunavanje udaljenosti

Ako uzmemo za pretpostavku da je skup težina dobiven od donosioca odluke dan sa:

$$\boldsymbol{W} = \{ w_1, w_2, \ldots, w_n \}$$

možemo definirati udaljenost bilo koje alternative A_i od A^+ i A^- kao ponderiranu Euklidsku udaljenost na sljedeći način:

$$S_{i+} = d(A_i, A^+) = \left\| w \; (\overline{A_i} - \overline{A^+}) \right\| = \sqrt{\sum_{j=1}^{n} \left[w_j \cdot (t_{ij} - t_j^+) \right]^2} =$$

$$= \sqrt{\sum_{j=1}^{n} \left[\frac{w_j (x_{ij} - x_j^+)}{\|X_j\|} \right]^2}$$

Udaljenost od negativnog ideala dana je sa

$$S_{i-} = d(A_i, A^-) = \left\| w\,(\overline{A_i} - \overline{A^-}) \right\| = \sqrt{\sum_{j=1}^{n} \left[w_j \cdot (t_{ij} - t_j^-) \right]^2} =$$

$$= \sqrt{\sum_{j=1}^{n} \left[\frac{w_j (x_{ij} - x_j^-)}{\left\| X_j \right\|} \right]^2}$$

4. Korak izračunavanje relativne bliskosti s idealnim rješenjem

$$RC_i = \frac{S_{i-}}{S_{i+} + S_{i-}} \rightarrow$$ Relativna bliskost alternative A_i u odnosu ma idealno rješenje A^+

RC_i – indeks relativne bliskosti. Očito je $RC_i = 1$ ako je $A_i = A^+$ i $RC_i = 0$ ako je $A_i = A^-$. Alternativa je bolja - bliža idealnom rješenju što je RCi bliži jedinici. Na kraju dobivamo konačan poredak alternativa. [61]

4.5. PROMETHEE metoda

Ova metoda istodobno vrši usporedbu i rangiranje različitih alternativa na temelju više kvantitativnih ili kvalitativnih kriterija. Cilj metode je pomoći donosiocu odluke kod problema višekriterijalnog odlučivanja. Metodu su razvili Belgijanci J.P. Brans, Ph. Vincke i B. Mareschal.

Višekriterijalni problem ima sljedeći oblik:

Max {f1(a), f2(a), ..., fn(a) | a∈ A }

A je konačan skup alternativa tj. A= { A1, A2, ..., Am }, a f_j su *n* kriterija koje treba maksimizirati. Svaki kriterij je funkcija iz *A* u *R* ili u neki drugi uređeni skup. Za svaku aktivnost A_i neka je $f_i(A_i)$ vrijednost ili procjena vrijednosti *j*-tog kriterija za *i*-tu alternativu. Tako se dobiva skup osnovnih podataka koji je prikazan u matrici odluke:

[61] Ibid., str. 128 – 141.

Tablica 2. PROMETHEE – matrica odluke

Alternative (aktivnosti)	**KRITERIJI**			
	f_1	f_2	.....	f_n
A_1	$f_1(A_1)$	$f_2(A_1)$	.....	$f_n(A_1)$
A_2	$f_1(A_2)$	$f_2(A_2)$	.....	$f_n(A_2)$
....	.....	.....	.....	....
A_m	$f_1(A_m)$	$f_2(A_m)$	.....	$f_n(A_m)$

Izvor: Ibid., str. 152.

Kad se uspoređuju dvije alternative a i b (A_k i A_l) onda trebamo taj rezultat izraziti u terminima preferencije. Tako funkcija preferencije P izgleda ovako:

P : A X A → [0, 1]

koja predstavlja intezitet preferencije jedne alternative u odnosu na drugu (alternative a u odnosu na alternativu b) na sljedeći način:

P (a, b) = 0 → indiferencija ili nepostojanje preferencije alternative a u odnosu na alternativu b

P (a, b) ≈ 0 → slaba preferencija a nad b

P (a, b) ≈ 1 → jaka preferencija a nad b

P (a, b) = 1 → striktna preferencija a nad b

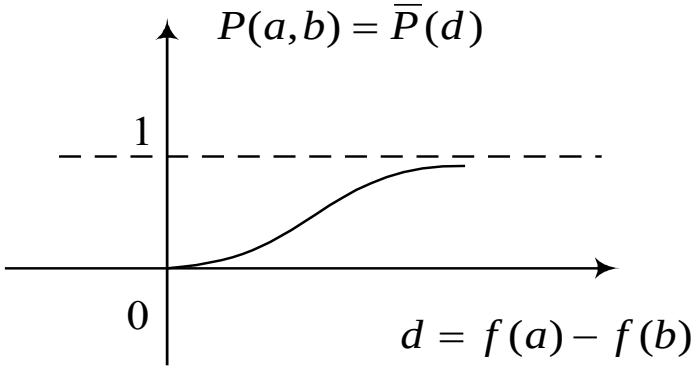
Kažemo da se za svaki par alternativa *a* i *b* određuje broj iz intervala [0, 1] koji je to bliži jedinici što je alternativa ***a*** prihvatljivija donosiocu odluke nego alternativa ***b***. Problem je u tome što se ta prihvatljivost treba mjeriti preko više kriterija istovremeno.

U praksi će funkcija preferencije biti funkcija razlike između vrijednosti (ocjena) tih dviju alternativa po nekom kriteriju.

Ako napišemo da je:

$$d = f(a) - f(b)$$

možemo uzeti da je $P(a,b) = \overline{P}(d)$ i onda graf preferencije koji sad ima funkciju jedne varijable izgleda ovako:



Slika 2. Funkcija preferencije
Izvor: Ibid., str. 153.

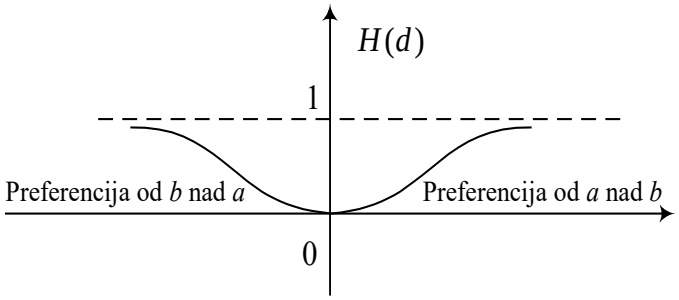
Iz grafa uočavamo da je funkcija preferencije neopadajuća funkcija koja je jednaka nuli za negativne vrijednosti od d. Jer ako je $d \leq 0$, tj. $f(a) \leq f(b)$, tada ne postoji preferencija od ***a*** nad ***b*** pa je i $P(a, b) = 0$.

Što je razlika u ocjenama dviju aktivnosti tj. alternativa veća (d), to je P (a, b) bliži jedinici, a za određenu vrijednost od *d* funkcija postaje jednaka 1 jer dolazi do striktne preferencije.

Da bi jasnije razumjeli područje indiferencije se može promatrati kroz funkciju H(d) koja je direktno vezana s funkcijom preferencije P na idući način:

$$H(d) = \begin{cases} P(a,b), & d \geq 0 \\ P(b,a), & d < 0 \end{cases}$$

Te dobivamo graf funkcije preferencije H (d) koji izgleda ovako:



Slika 3. Funkcija preferencije H(d)
Izvor: Ibid., str. 154.

Za svaki kriterij f_j razmatra se zatim generalizirani kriterij definiran pomoću kriterija f_j i odgovarajuće funkcije preferencije. Autori ove metode su predložili šest tipova kriterija koji su sasvim dovoljni za praktičnu primjenu.
Od tih šest funkcija analitičar i donosilac odluke dogovorno biraju po jednu za svaki kriterij u odnosu na njihova saznanja o intenzitetu i smjeru preferencije.

U svakom pojedinačnom slučaju treba odrediti iduće parametre:

q – prag indiferecije (odnosi se na područje gdje je razlika između dvije vrijednosti alternativa zanemariva donosiocu odluke)

p – prag preferencije (područje stroge preferencije)

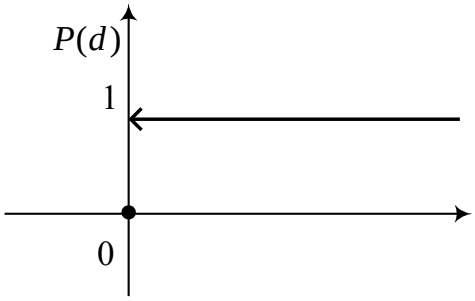
s – parametar čija se vrijednost nalazi između praga indiferencije q i praga preferencije p

Šest je tipova generaliziranog kriterija:

1. **Obični kriterij**

$$P(d) = \begin{cases} 0, & d \leq 0 \\ 1, & d > 0 \end{cases}$$

Indiferencija između a i b postoji ako i samo ako je je $f(a) = f(b)$, tj. za $d = 0$. Onog trenutka kad su procjene po tim aktivnostima različite odnosno kad donosilac odluke jasno, striktno preferira aktivnost koja ima veću ocjenu tad je vrijednost funkcije preferencije jednaka 1.



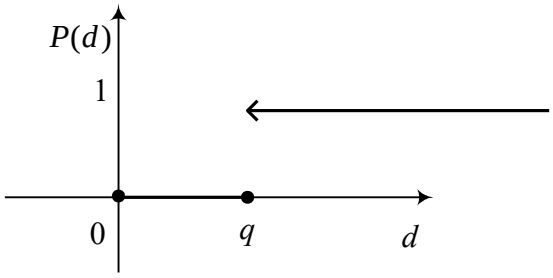
Slika 4. Obični kriterij
Izvor: Ibid., str. 155.

2. **Kvazi kriterij**

$$P(d) = \begin{cases} 0, & d \le q \\ 1, & d > q \end{cases}$$

Kod ovog kriterija uvodi se prag indiferencije q što znači da su dvije alternative indiferentne tako dugo dok razlika njihovih ocjena ne premaši prag q. U protivnom postoji stroga preferencija.

Ako donosilac odluke želi upotrijebiti takvu funkciju preferencije potrebno je odrediti vrijednost parametra q koji ima strogo ekonomsko značenje.

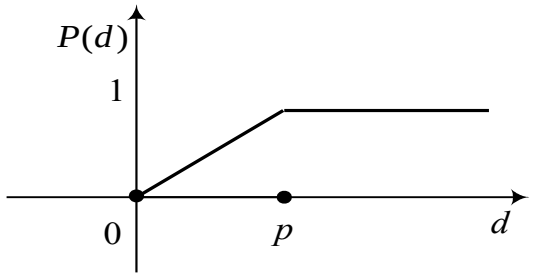


Slika 5. Kvazi kriterij
Izvor: Ibid.

3. **Kriterij s linearnom preferencijom**

$$P(d) = \begin{cases} 0 \ , \ d \leq 0 \\ \frac{d}{p} \ , \ d < p \\ 1 \ , \ d \geq p \end{cases}$$

Dok je *d* manji od parametra *p* preferencija donosioca odluke raste linearno s vrijednošću d, ali čim razlika *d* postaje veća od *p* to je situacija stoge preferencije. Za taj kriterij treba odrediti samo jedan parametar *p* koji predstavlja najnižu vrijednost razlike u ocjenama dviju alternativa iznad koje se nalazi stroga preferencija.

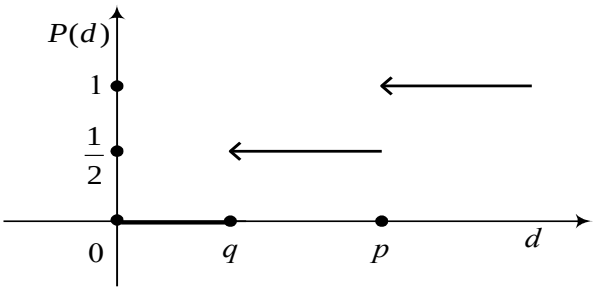


Slika 6. Kriterij s linearnom preferencijom
Izvor: Ibid., str. 156.

4. **Nivo kriterij**

$$P(d) = \begin{cases} 0 \ , \ d \leq q \\ \frac{1}{2} \ , \ q < d \leq p \\ 1 \ , \ d > p \end{cases}$$

Kod ovog slučaja potrebno je definirati i prag *q* i prag *p*. Kad se razlika *d* nalazi između njihovih vrijednosti postoji slaba preferencija ($P(d) = 1/2$).

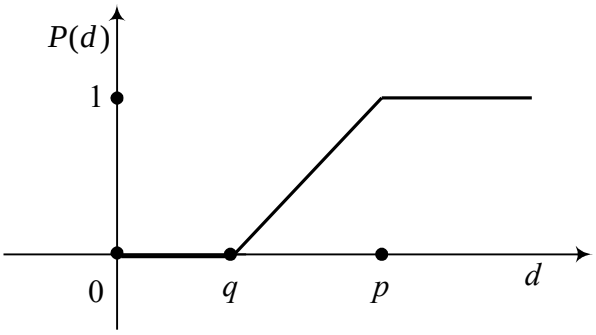


Slika 7. Nivo kriterij
Izvor: Ibid.

5. Kriterij s linearnom preferencijom i područjem indiferencije

$$P(d)=\begin{cases} 0\ ,\ d\le q \\ \dfrac{d-q}{p-q}\ ,\ q<d\le p \\ 1\ ,\ d>p \end{cases}$$

U ovom slučaju preferencija donosioca odluke raste linearno u području indiferencije pa do područja stroge preferencije – područje između praga q i praga p.

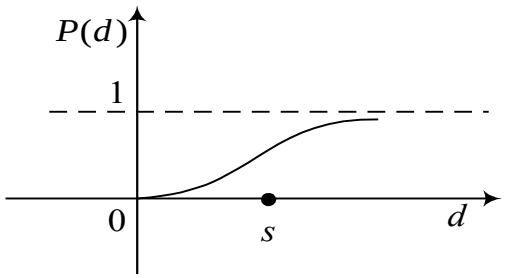


Slika 8. Kriterij s linearnom preferencijom i područjem indiferencije
Izvor: Ibid. str. 157.

6. Gaussov kriterij

$$P(d)=\begin{cases} 0\ ,\ d\le 0 \\ 1-e^{-d^2/2s^2}\ ,\ d>0 \end{cases}$$

Kod ove funkcije potrebno je definirati parametar *s* koji se nalazi u području slabe preferencije, a predstavlja devijaciju normalne razdiobe. Parametar *s* nema prekida niti tzv. šiljaka te je zbog toga zanimljiv s obzirom na stabilnost rezultata.



Slika 9. Gaussov kriterij
Izvor: Ibid.

Za svaki kriterij je potrebno izabrati jedan od predloženih tipova funkcije preferencije. Nakon odabira kriterija potrebno je odrediti relativne važnosti tj. pondere težine za pojedine kriterije. Nakon toga računamo indeks preferencije *Π* kao ponderiranu sredinu funkcija preferencije P_j, tj.

$$\Pi(a,b) = \frac{\sum_{j=1}^{n} w_j P_j(a,b)}{\sum_{j=1}^{n} w_j}$$

Budući da je najčešće $\sum_{j=1}^{n} w_j = 1$ imamo:

$$\Pi(a,b) = \sum_{j=1}^{n} w_j P_j(a,b)$$

Indeks preferencije Π (a, b) predstavlja intezitet preferencije donosioca odluke alternative a u odnosu na alternativu b promatrajući u isto vrijeme sve kriterije. Indeks preferencije pokazuje jačinu dominacije a nad b u odnosu na sve kriterije.

Budući da je P_j $(a,b) = 0$ ako b dominira nad a po j-tom kriteriju, indeks preferencije ne može biti negativan. Nasuprot tome najveća vrijednost od P_j (a,b) može biti 1 i to u slučaju stroge preferencije.

Iz toga slijedi:

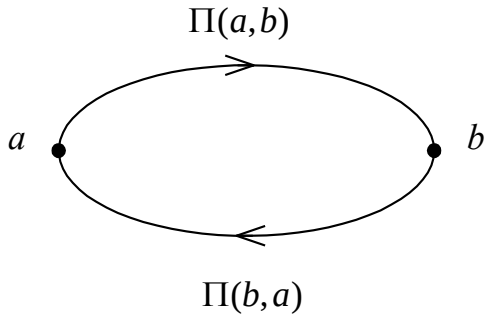
$$\Pi(a,b) = \sum_{j=1}^{n} w_j P_j(a,b) \leq \sum_{j=1}^{n} w_j = 1$$

tj.

$$\Pi(a,b) \in [0,1] .$$

U ovom slučaju indeks preferencije Π (b, a) pokazuje kako i s kojom jačinom tj. intezitetom je b dominantan nad a u odnosu na sve kriterije.

Sljedeća slika pokazuje da za alternative a i b postoje dva luka s vrijednostima Π(a, b) i Π(b, a)



Slika 10. Lukovi Π(a, b) i Π(b, a)
Izvor: Ibid., str. 158.

Nadalje se za svaku alternativu definiraju dva "outranking" toka $\Phi^{+}(a)$, izlazni ili pozitivni tok, i $\Phi^{-}(a)$, ulazni ili negativni tok. Izlazni tok predstavlja sumu vrijednosti svih lukova koji izlaze iz čvora tj. aktivnosti a te tako izražava koliko alternativa a dominira nad ostalim alternativama ($b \in A$) tj. koliko je bolja od drugih alternativa po svim kriterijima.

$$\Phi^{+}(a) = \frac{1}{m-1}\sum_{b \in A} \Pi(a,b)$$

Osim pozitivnog toka imamo i ulazni ili negativni tok $\Phi^{-}(a)$ kojeg definiramo kao sumu vrijednosti svih lukova koji ulaze u čvor a. Ovaj tok pokazuje koliko je *a* dominirana od svih ostalih alternativa i po svim kriterijima što znači da se mjeri slabost alternative *a* u odnosu na ostale alternative.

$$\Phi^{+}(a) = \frac{1}{m-1}\sum_{b \in A} \Pi(a,b)$$

Kad se usporede ova dva toka dobivaju se dva potpuna uređaja skupa alternativa:

$\Phi^{+}(a)$ $\quad \left\{ \begin{array}{l} aS^{+}b \quad ako\ i\ samo\ ako\ je\ \Phi^{+}(a) > \Phi^{+}(b) \\ aI^{+}b \quad ako\ i\ samo\ ako\ je\ \Phi^{+}(a) = \Phi^{+}(b) \end{array} \right\}$

$\Phi^{-}(a)$ $\quad \left\{ \begin{array}{l} aS^{-}b \quad ako\ i\ samo\ ako\ je\ \Phi^{-}(a) < \Phi^{-}(b) \\ aI^{-}b \quad ako\ i\ samo\ ako\ je\ \Phi^{-}(a) = \Phi^{-}(b) \end{array} \right\}$

Pri tome je S "outstanding" relacija tj. *a* S *b* znači da je *a* barem toliko dobar kao i *b* ili bolji. Presjek tih dvaju uređaja rezultira u parcijalnom uređaju (P, I, R) što je konačno uređaj dobiven metodom PROMETHEE I.

Tablica 3. PROMETHEE I – parcijalni uređaj

a P b (a dominira nad b)	ako i samo ako
a I b (a je indiferentan sa b)	ako i samo ako $a\ I^{+}\ b$ i $a\ I^{-}\ b$
a R b (a i b su neusporedivi)	u ostalim slučajevima

Izvor: Ibid., str. 160.

Ako donosilac odluke želi potpuni uređaj skupa alternativa može izračunati neto tok Φ na sljedeći način:

$$\Phi(a) = \Phi^{+}(a) - \Phi^{-}(a)$$

Takav uređaj se naziva PROMETHEE II. Donosiocu odluke je lakše odlučivati na temelju ovog uređaja, ali PROMETHEE I daje puno realnije informacije koje imaju veliku važnost kod donošenja konačne odluke.[62]

[62] Ibid., str. 152 – 162.

5. PRIMJENA METODA VIŠEATRIBUTNOG ODLUČIVANJA NA PROBLEM PROCJENE POSLOVANJA (BONITETA) OSIGURAVAJUĆIH DRUŠTAVA

5.1. Uvod

Istraživanje uzima 10 osiguravajućih društava u Hrvatskoj te odabir najboljeg osiguravajućeg društva koristeći metodu jednostavnog zbrajanja težina, TOPSIS metodu i PROMETHEE metodu. Izabrano je 10 osiguranja koji u 2011. godini nisu poslovali s gubitkom. 2011. godina je izabrana zbog podataka koji su dostupni i izračunati, a preuzeti su sa stranice HANFA. (Neka osiguranja više ne posluju pod istim imenom već su dio nekog drugog vlasnika tj. osiguravajućeg društva).

Kriteriji su odabrani proizvoljno. Kako je spomenuto u poglavlju 3. osiguravajuća društva dužna su na određeni datum predati financijske izvještaje. Osim tih financijskih izvještaja potrebni su i predati dodatna izvješća (poglavlje 3.5) kako bi se procijenilo poslovanje. Od kriterija izabrani su razmjer šteta, razmjer troškova, kombinirali razmjer i rezultat ulaganja koji su karakteristični za osiguravajuća društva te koeficijent zaduženosti, rentabilnost vlastitih sredstava i rentabilnost imovine koji su karakteristični i za sva ostala poduzeća. Stoga je ovo procjena poslovanja po navedenim kriterijima po izboru autorice te su uzeti ovi kriteriji zbog zanimljivosti rezultata koji će se dobiti višekriterijalnom analizom.

Za procjene poslovanja (boniteta) jasno je da su potrebni svi izvještaji i sama ocjena boniteta je dostupna na stranicama FINE uz određenu naknadu.

Osiguravajuća društva koja su uzeta za višekriterijalnu analizu su: Allianz Zagreb d.d. (A1), Croatia osiguranje d.d. (C2), Euroherc osiguranje d.d. (C3), Generali osiguranje d.d. (C4), Grawe Hrvatska d.d. (C5), Helios VIG d.d.(A6), HOK osiguranje d.d. (A7), Jadransko osiguranje d.d. (A7), Merkur osiguranje d.d. (A9), Uniqa osiguranje d.d. (A10). Ova društva se bave neživotnim osiguranjima.

Kriteriji koji su izabrani su poredani sljedećim redoslijedom:

C1 – razmjer šteta

C2 – razmjer troškova

C3 – kombinirani razmjer

C4 – rezultat ulaganja

C5 – koeficijent zaduženosti

C6 – rentabilnost vlastitih sredstava

C7 – rentabilnost imovine

Tablica 4. Osiguravajuća društva i kriteriji

		C1	C2	C3	C4	C5	C6	C7
Allianz Zagreb d.d.	**A1**	46,98	47,31	94,29	5,44	0,74	27,95	5,69
Croatia osiguranje d.d.	**A2**	57,78	45,55	103,33	3,56	0,74	5,1	1,27
Euroherc osiguranje d.d.	**A3**	34,94	51,08	**86,02**	4,05	0,68	25,17	**6,46**
Generali osiguranje d.d.	**A4**	49,1	58,1	107,2	6,03	0,84	3,86	0,59
Grawe Hrvatska d.d.	**A5**	56,81	55,46	112,27	6,33	0,81	15,81	2,66
Helios VIG d.d.	**A6**	**30,94**	84,32	115,26	4,41	0,83	**35,6**	4,41
HOK osiguranje d.d.	**A7**	51,41	**41,24**	92,65	3,07	0,84	34,69	4,14
Jadransko osiguranje d.d.	**A8**	37,06	51,69	88,75	3,15	**0,61**	15,93	5,31
Merkur osiguranje d.d	**A9**	45,4	61,6	107	**6,96**	0,62	13,85	4,66
Uniqa osiguranje d.d.	**A10**	60,4	102,95	163,35	5,46	0,90	0,15	0,01

Izvor: https://www.hanfa.hr/

5.2. Procjena težina kriterija – metoda svojstvenog vektora

Metoda svojstvenog vektora jedan je od načina za procjenjivanje važnosti kriterija za jedinstvenog donosioca odluke. Procjenu o važnosti kriterija u ovom slučaju donosi jedna osoba. S obzirom da svaki višekriterijalni problem ima više kriterija isti nisu od jednake važnosti donosiocu odluke te ih on mora procijeniti tj. odrediti težinu svakog kriterija. Težina brojčano izražava važnost kriterija.[63] Cilj metode je dobiti/odrediti težinu za svaki kriterij.

Kod ove metode prvi korak je poredati kriterije po važnosti. Po izboru autorice poredani su na sljedeći način: C5, C6, C7, C1, C2, C3, C4. Nakon toga potrebno je formirati matricu međusobnih usporedbi navedenih kriterija. Nakon toga se određuju težine.

Proračun je napravljen u MS Excel-u.

[63] Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, op. cit. str. 54

Tablica 5. Matrica međusobnih usporedbi

	C1	**C2**	**C3**	**C4**	**C5**	**C6**	**C7**
C1	**1**	2	3	4	0,2	0,25	0,5
C2	0,5	**1**	2	4	0,166667	0,2	0,333333
C3	0,333333	0,5	**1**	2	0,111111	0,125	0,166667
C4	0,25	0,25	0,5	**1**	9	0,142857	0,166667
C5	5	6	9	0,111111	**1**	2	3
C6	4	5	8	7	0,5	**1**	2
C7	2	3	6	6	0,333333	0,5	**1**
Suma	13,08333	17,75	29,5	24,11111	11,31111	4,217857	7,166667

Izvor: Izrada autorice

Na glavnoj dijagonali se nalazi broj 1. Iznad dijagonale brojevi su dobiveni izborom autora (čiji brojevi idu od 1 do 9) koristeći se Saatyevom skalom. Ispod glavne dijagonale nalaze se recipročne vrijednosti tj. element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale.

Da bi dobili transformiranu matricu potrebno je podijeliti elemente sa sumom svakog stupca.

Tablica 6. Transformirana matrica A`

	C1	C2	C3	C4	C5	C6	C7	Wj - težine
C1	0,076433	0,112676	0,101695	0,165899	0,017682	0,059272	0,069767	0,086203
C2	0,038217	0,056338	0,067797	0,165899	0,014735	0,047417	0,046512	0,062416
C3	0,025478	0,028169	0,033898	0,082949	0,009823	0,029636	0,023256	0,033316
C4	0,019108	0,014085	0,016949	0,041475	0,795678	0,03387	0,023256	0,134917
C5	0,382166	0,338028	0,305085	0,004608	0,088409	0,474174	0,418605	0,287296
C6	0,305732	0,28169	0,271186	0,290323	0,044204	0,237087	0,27907	0,244185
C7	0,152866	0,169014	0,20339	0,248848	0,02947	0,118544	0,139535	0,151667

Izvor: Izrada autorice

Težine kriterija smo dobili tako da smo uzeli prosječnu vrijednost svakog retka.

Suma svih težina kriterija je 1 te je ispunjena relacija $\sum_{i=1}^{7} \text{wi} = 1$.

Težina kriterija C5 (koeficijent zaduženosti) iznosi 0,287296 tj. 28,73%. S obzirom da je ovaj kriterij po na prvom mjestu po važnosti on ima i najveću težinu, a sam koeficijent zaduženosti pokazuje koliko se poduzeće financira iz svojih, a koliko iz tuđih izvora. Ovaj kriterij utječe 28,73% na donošenje odluke.

Idući kriterij C6 (rentabilnost vlastitih sredstava) iznosi 24, 42% što je manje od prethodnog kriterija, ali i dalje veliki udio. Veći od preostalih kriterija.

Kriterij C7 i C4 imaju manje težine od prethodna dva kriterija. Zadnja tri kriterija su "stavljena" na zadnje mjesto važnosti jedino iz razloga što kod procjene poslovanja bilo kojeg poduzeća krećemo od pokazatelja koje koriste sva društva, a ovo su pokazatelji koji su karakteristični za osiguravajuća društva i za njih imaju iznimno važnu ulogu. U ovom slučaju (zbog poredane važnosti) imaju male težine tj. redom C1-8, 62%, C2 – 6,24%, C3 – 3,33%.

5.3. Određivanje ranga osiguravajućih društava metodom jednostavnog zbrajanja težina - SAW

U ovoj metodi svakom prethodno određenom kriteriju treba biti pridružen ponder važnosti tj. težina koja je dobivena metodom svojstvenog vektora. Tablica 7. prikazuje početne podatke koje je potrebno transformirati.

Tablica 7. Tablica odluke – osiguravajuća društva

	C1	C2	C3	C4	C5	C6	C7
A1	46,98	47,31	94,29	5,44	0,74	27,95	5,69
A2	57,78	45,55	103,33	3,56	0,74	5,1	1,27
A3	34,94	51,08	**86,02**	4,05	0,68	25,17	**6,46**
A4	49,1	58,1	107,2	6,03	0,84	3,86	0,59
A5	56,81	55,46	112,27	6,33	0,81	15,81	2,66
A6	**30,94**	84,32	115,26	4,41	0,83	**35,6**	4,41
A7	51,41	**41,24**	92,65	3,07	0,84	34,69	4,14
A8	37,06	51,69	88,75	3,15	**0,61**	15,93	5,31
A9	45,4	61,6	107	**6,96**	0,62	13,85	4,66
A10	60,4	102,95	163,35	5,46	0,90	0,15	0,01
	min	min	min	max	min	max	max

Izvor: https://www.hanfa.hr/

Tablica 8. Linearna transformacija – osiguravajuća društva

	C1	C2	C3	C4	C5	C6	C7
A1	0,6585781	0,8716973	0,9122919	0,7816092	0,8243243	0,7851124	0,880805
A2	0,5354794	0,9053787	0,8324785	0,5114943	0,8243243	0,1432584	0,1965944
A3	0,885518	0,807361	1	0,5818966	0,8970588	0,7070225	1
A4	0,6301426	0,7098107	0,8024254	0,8663793	0,7261905	0,108427	0,0913313
A5	0,5446224	0,743599	0,7661887	0,9094828	0,7530864	0,4441011	0,4117647
A6	1	0,4890892	0,7463127	0,6336207	0,7349398	1	0,6826625
A7	0,6018284	1	0,9284404	0,441092	0,7261905	0,9744382	0,6408669
A8	0,8348624	0,7978332	0,9692394	0,4525862	1	0,4474719	0,8219814
A9	0,6814978	0,6694805	0,8039252	1	0,983871	0,3890449	0,7213622
A10	0,5122517	0,4005828	0,5265993	0,7844828	0,6777778	0,0042135	0,001548
	min	min	min	max	min	max	max
	0,0862	0,06242	0,03332	0,13492	0,2873	0,24419	0,15167

Izvor: Izrada autorice

Svi atributi su prikazani u "benefit" obliku što znači da veći broj označava da je alternativa po tom atributu bolja. Za razmjer šteta (C1), razmjer troškova (C2), kombinirani razmjer (C3) i koeficijent zaduženosti (C5) je bolje da su što manji dok su za preostala tri kriterija – rezultat ulaganja (C4), rentabilnost vlastitih sredstava(C6) i rentabilnost imovine (C7) bolje da su što veći. Nakon ovog postupka potrebno je rangirati alternative da bi dobili najbolji izbor.

Tablica 9. Konačan poredak alternativa metodom jednostavnog zbrajanja težina

	Poredak
A3	0,820583
A1	0,809152
A6	0,785948
A9	0,749302
A7	0,748511
A8	0,736347
A5	0,628844
A2	0,501038
A4	0,491206
A10	0,388531

Izvor: Izrada autorice

Konačni rezultat dobili smo skalarnim množenjem vrijednosti za svaku alternativu i sa dobivenim težinama. Iz ovoga proizlazi da je najbolja alternativa A3 tj. Euroherc osiguranje d.d., a najgora alternativa A10 tj. Uniqa osiguranje d.d.

5.4. Određivanje ranga osiguravajućih društava TOPSIS metoda

Svrha ove metode je naći alternativu koja je najsličnija idealnoj i najmanje slična antiidealnoj, a sličnost se odnosi na razinu udaljenosti tj. najbolja alternativa ima najmanju udaljenost od idealne i najveću udaljenost od antiidealne. Kod ove metode koristimo jednaku početnu tablicu kao i kod prethodne metode.

Tablica 10. Tablica odluke – osiguravajuća društva

	C1	C2	C3	C4	C5	C6	C7
A1	46,98	47,31	94,29	5,44	0,74	27,95	5,69
A2	57,78	45,55	103,33	3,56	0,74	5,1	1,27
A3	34,94	51,08	**86,02**	4,05	0,68	25,17	**6,46**
A4	49,1	58,1	107,2	6,03	0,84	3,86	0,59
A5	56,81	55,46	112,27	6,33	0,81	15,81	2,66
A6	**30,94**	84,32	115,26	4,41	0,83	**35,6**	4,41
A7	51,41	**41,24**	92,65	3,07	0,84	34,69	4,14
A8	37,06	51,69	88,75	3,15	**0,61**	15,93	5,31
A9	45,4	61,6	107	**6,96**	0,62	13,85	4,66
A10	60,4	102,95	163,35	5,46	0,90	0,15	0,01
	min	min	min	max	min	max	max

Izvor:https://www.hanfa.hr/

Tablica 11. Kvadrati i norma

	C1	C2	C3	C4	C5	C6	C7
A1	2207,1204	2238,2361	8890,6041	29,5936	0,5476	781,2025	32,3761
A2	3338,5284	2074,8025	10677,089	12,6736	0,5476	26,01	1,6129
A3	1220,8036	2609,1664	7399,4404	16,4025	0,4624	633,5289	41,7316
A4	2410,81	3375,61	11491,84	36,3609	0,7056	14,8996	0,3481
A5	3227,3761	3075,8116	12604,553	40,0689	0,6561	249,9561	7,0756
A6	957,2836	7109,8624	13284,868	19,4481	0,6889	1267,36	19,4481
A7	2642,9881	1700,7376	8584,0225	9,4249	0,7056	1203,3961	17,1396
A8	1373,4436	2671,8561	7876,5625	9,9225	0,3721	253,7649	28,1961
A9	2061,16	3794,56	11449	48,4416	0,3844	191,8225	21,7156
A10	3648,16	10598,703	26683,223	29,8116	0,81	0,0225	0,0001
	min	min	min	max	min	max	max
SUMA	23087,6738	39249,35	118941,2	252,1482	5,8803	4621,963	169,6438
NORMA	151,9462859	198,1145	344,8785	15,87918	2,424933	67,98502	13,02474

Izvor: Izrada autorice

Vektorsku transformaciju smo dobili tako da smo svaki element u tablici kvadrirali. Nakon toga smo izračunali sumu za svaki kriterij te normu koja se dobije kao korijen iz sume. Nakon što smo dobili normu možemo izračunati iduću tablicu.

Tablica 12. Vektorska transformacija – osiguravajuća društva

	C1	C2	C3	C4	C5	C6	C7
A1	0,309188209	0,2388013	0,2734006	0,3425871	0,3051631	0,41112	0,436861
A2	0,380265958	0,2299176	0,2996127	0,224193	0,3051631	0,0750165	0,0975068
A3	0,229949681	0,2578307	0,2494212	0,255051	0,2804201	0,3702286	0,4959793
A4	0,323140508	0,2932648	0,3108341	0,3797426	0,3464013	0,0567772	0,0452984
A5	0,373882123	0,2799392	0,3255349	0,3986353	0,3340298	0,2325512	0,2042268
A6	0,203624589	0,4256125	0,3342046	0,2777222	0,3422775	0,5236448	0,3385865
A7	0,338343249	0,2081625	0,2686453	0,193335	0,3464013	0,5102595	0,3178567
A8	0,24390198	0,2609098	0,257337	0,198373	0,2515533	0,2343163	0,4076857
A9	0,298789798	0,3109313	0,3102542	0,4383099	0,2556772	0,2037213	0,3577807
A10	0,397508894	0,5196491	0,473645	0,3438466	0,3711443	0,0022064	0,0007678
	min	min	min	max	min	max	max
A+	0,203624589	0,208162	0,249421	0,43831	0,251553	0,523645	0,495979
A-	0,397508894	0,519649	0,473645	0,193335	0,371144	0,002206	0,000768
Wj	0,086203	0,06242	0,03332	0,13492	0,2873	0,24419	0,15167

Izvor: Izrada autorice

U ovoj tablici 12 smo dobili idealnu A^+ i antiidealnu alternativu A^- za svaki kriterij. Tako primjerice kod prvog kriterija imamo da je idealno da je razmjer šteta što manji – minimum te je idealno kod alternative A6 dok je antiidealno kod alternative A10.

Tablica 13. Udaljenost alternativa od idealne alternative

Težina * razlika za A+							
	C1	C2	C3	C4	C5	C6	C7
A1	0,009099901	0,001912	0,000799	-0,01291	0,015402	-0,02748	-0,00897
A2	0,015227016	0,001358	0,001672	-0,02889	0,015402	-0,10955	-0,06044
A3	0,002269302	0,0031	0	-0,02472	0,008293	-0,03746	0
A4	0,010302631	0,005312	0,002046	-0,0079	0,027249	-0,114	-0,06835
A5	0,01467671	0,00448	0,002536	-0,00535	0,023695	-0,07108	-0,04425
A6	0	0,013572	0,002825	-0,02167	0,026065	0	-0,02387
A7	0,011613153	0	0,00064	-0,03305	0,027249	-0,00327	-0,02702
A8	0,003472032	0,003292	0,000264	-0,03237	0	-0,07065	-0,01339
A9	0,008203526	0,006414	0,002027	0	0,001185	-0,07812	-0,02096
A10	0,016713409	0,019442	0,00747	-0,01274	0,034358	-0,12733	-0,07511
	min	min	min	max	min	max	max

Izvor: Izrada autorice

U tablici 13. smo izračunali udaljenost od S_{i+} tako da smo težinu svakog kriterija pomnožili sa vrijednošću dobivenoj u vektorskoj transformaciji koja je umanjena za idealnu alternativu A^{+}.

Podaci u dobivenoj tablici 13. se kvadriraju kako bi se kasnije izračunala relativna bliskost i dobio konačan poredak alternativa. Suma se dobije kao zbroj svih kriterija kod svake pojedine alternative. Si + se dobije kao korijen od sume. Prikaz u tablici 14.

Tablica 14. Kvadrati, suma i S i +

	C1	C2	C3	C4	C5	C6	C7	SUMA	S i +
A1	0,0000828	0,0000037	0,0000006	0,0001668	0,0002372	0,0007550	0,0000804	0,0013265	0,0364209
A2	0,0002319	0,0000018	0,0000028	0,0008345	0,0002372	0,0120008	0,0036524	0,0169615	0,1302362
A3	0,0000051	0,0000096	0,0000000	0,0006113	0,0000688	0,0014034	0,0000000	0,0020982	0,0458066
A4	0,0001061	0,0000282	0,0000042	0,0000624	0,0007425	0,0129965	0,0046722	0,0186122	0,1364264
A5	0,0002154	0,0000201	0,0000064	0,0000287	0,0005615	0,0050525	0,0019580	0,0078425	0,0885578
A6	0,0000000	0,0001842	0,0000080	0,0004694	0,0006794	0,0000000	0,0005698	0,0019108	0,0437128
A7	0,0001349	0,0000000	0,0000004	0,0010924	0,0007425	0,0000107	0,0007298	0,0027107	0,0520644
A8	0,0000121	0,0000108	0,0000001	0,0010479	0,0000000	0,0049914	0,0001793	0,0062416	0,0790037
A9	0,0000673	0,0000411	0,0000041	0,0000000	0,0000014	0,0061028	0,0004393	0,0066561	0,0815849
A10	0,0002793	0,0003780	0,0000558	0,0001624	0,0011805	0,0162123	0,0056411	0,0239094	0,1546266
	min	min	min	max	min	max	max		

Izvor: Izrada autorice

Tablica 15. Udaljenost alternativa od antiidealne alternative

	Težina * razlika za A-						
	C1	C2	C3	C4	C5	C6	C7
A1	-0,007613508	-0,01753	-0,00667	0,020137	-0,01896	0,099851	0,066141
A2	-0,001486393	-0,01808	-0,0058	0,004163	-0,01896	0,017779	0,014672
A3	-0,014444107	-0,01634	-0,00747	0,008327	-0,02606	0,089866	0,075107
A4	-0,006410778	-0,01413	-0,00542	0,02515	-0,00711	0,013325	0,006754
A5	-0,002036698	-0,01496	-0,00493	0,027699	-0,01066	0,056247	0,030858
A6	-0,016713409	-0,00587	-0,00465	0,011385	-0,00829	0,127327	0,051236
A7	-0,005100256	-0,01944	-0,00683	0	-0,00711	0,124059	0,048092
A8	-0,013241377	-0,01615	-0,00721	0,00068	-0,03436	0,056678	0,061716
A9	-0,008509882	-0,01303	-0,00544	0,033051	-0,03317	0,049207	0,054147
A10	0	0	0	0,020307	0	0	0
	min	min	min	max	min	max	max

Izvor: Izrada autora

U tablici 15. smo izračunali udaljenost od S_{i-} tako da smo težinu svakog kriterija pomnožili sa vrijednošću dobivenoj u vektorskoj transformaciji koja je umanjena za antiidealnu alternativu A^-.

Podaci u dobivenoj tablici 15. se kvadriraju kako bi se kasnije izračunala relativna bliskost i dobio konačan poredak alternativa. Suma se dobije kao zbroj svih kriterija kod svake pojedine alternative. Si - se dobije kao korijen od sume. Prikaz u tablici 16.

Tablica 16. Kvadrati, suma i S i –

	C1	C2	C3	C4	C5	C6	C7	SUMA	S i -
A1	0,0000580	0,0003073	0,0000445	0,0004055	0,0003593	0,0099701	0,0043746	0,0155193	0,1245766
A2	0,0000022	0,0003270	0,0000336	0,0000173	0,0003593	0,0003161	0,0002153	0,0012709	0,0356496
A3	0,0002086	0,0002670	0,0000558	0,0000693	0,0006794	0,0080758	0,0056411	0,0149971	0,1224626
A4	0,0000411	0,0001997	0,0000294	0,0006325	0,0000505	0,0001776	0,0000456	0,0011764	0,0342985
A5	0,0000041	0,0002239	0,0000243	0,0007672	0,0001137	0,0031637	0,0009522	0,0052492	0,0724511
A6	0,0002793	0,0000344	0,0000216	0,0001296	0,0000688	0,0162123	0,0026251	0,0193712	0,1391804
A7	0,0000260	0,0003780	0,0000466	0,0000000	0,0000505	0,0153906	0,0023128	0,0182046	0,1349245
A8	0,0001753	0,0002608	0,0000519	0,0000005	0,0011805	0,0032124	0,0038089	0,0086902	0,0932215
A9	0,0000724	0,0001697	0,0000296	0,0010924	0,0011005	0,0024213	0,0029319	0,0078178	0,0884186
A10	0,0000000	0,0000000	0,0000000	0,0004124	0,0000000	0,0000000	0,0000000	0,0004124	0,0203066
	min	min	min	max	min	max	max		

Izvor: Izrada autora

Tablica 17 pokazuje konačan poredak alternativa od najbolje do najlošije

Tablica 17. Relativna bliskost i konačan poredak alternativa

	Rci
A1	0,77378
A6	0,760993
A3	0,727778
A7	0,721564
A8	0,541277
A9	0,520099
A5	0,449982
A2	0,214904
A4	0,200899
A10	0,116082

Izvor: Izrada autora

Nakon što smo sve izračunali, možemo uočiti da je u TOPSIS metodi najbolja alternativa A1 (Allianz Zagreb d.d.) dok je najgora alternativa A10 (Uniqa osiguranje d.d.)

5.5. Određivanje ranga osiguravajućih društava PROMETHEE metodom

Rangiranje osiguravajućih društava izvršit ćemo i putem PROMETHEE metode. Rangiranje se vrši na temelju prethodno (gore) odabranih kriterija i na temelju težina koje su prethodno dobivene metodom svojstvenog vektora. Svakom kriteriju potrebno je odrediti funkciju preferencije. Nakon što se za svaki kriterij odabere jedna od šest funkcija preferencije potrebno je odrediti ili prag indiferencije *q* ili prag preferencije *p* ili oboje ovisno o funkciji preferencije. Osim ta dva parametra postoji i parametar *s* koji se nalazi između praga *q* i praga *p* koji se određuje samo za Gaussov kriterij. Svaki kriterij treba maksimizirati ili minimizirati. Tablica odluke prikazana je u tablici 18.

Tablica 18. Tablica odluke

		C1 (%)	C2 (%)	C3 (%)	C4 (%)	C5	C6 (%)	C7 (%)
		min	min	min	max	min	max	max
A1	Allianz Zagreb d.d.	46,98	47,31	94,29	5,44	0,74	27,95	5,69
A2	Croatia osiguranje d.d.	57,78	45,55	103,33	3,56	0,74	5,1	1,27
A3	Euroherc osiguranje d.d.	34,94	51,08	**86,02**	4,05	0,68	25,17	**6,46**
A4	Generali osiguranje d.d.	49,1	58,1	107,2	6,03	0,84	3,86	0,59
A5	Grawe Hrvatska d.d.	56,81	55,46	112,27	6,33	0,81	15,81	2,66
A6	Helios VIG d.d.	**30,94**	84,32	115,26	4,41	0,83	**35,6**	4,41
A7	HOK osiguranje d.d.	51,41	**41,24**	92,65	3,07	0,84	34,69	4,14
A8	Jadransko osiguranje d.d.	37,06	51,69	88,75	3,15	0,61	15,93	5,31
A9	Merkur osiguranje d.d	45,4	61,6	107	**6,96**	**0,62**	13,85	4,66
A10	Uniqa osiguranje d.d.	60,4	102,95	163,35	5,46	0,90	0,15	0,01
	Wj	0,0862	0,06242	0,033316	0,134917	0,287296	0,244185	0,151667
	Tip funk. Preferencije	**V**	**V**	**VI**	**IV**	**V**	**III**	**III**
	q	10	10		1	0,1		
	p	30	30		3	0,6	30	6
	s			20				

Izvor: Izrada autorice

Za C1 (razmjer šteta) i C2 (razmjer troškova) izabran je kriterij s linearnom preferencijom i područjem indiferencije. Donositelj odluke je indiferentan do praga q koji iznosi 10. Između 10 i 30 (p=30) preferencija raste linearno dok je sve iznad 30 područje stroge preferencije određenog osiguravajućeg društva nad drugim.

Za C3 (kombinirani razmjer) odabran je Gaussov kriterij gdje je potrebno odrediti parametar s. Ovaj parametar s leži u području slabe preferencije i iznosi 20.

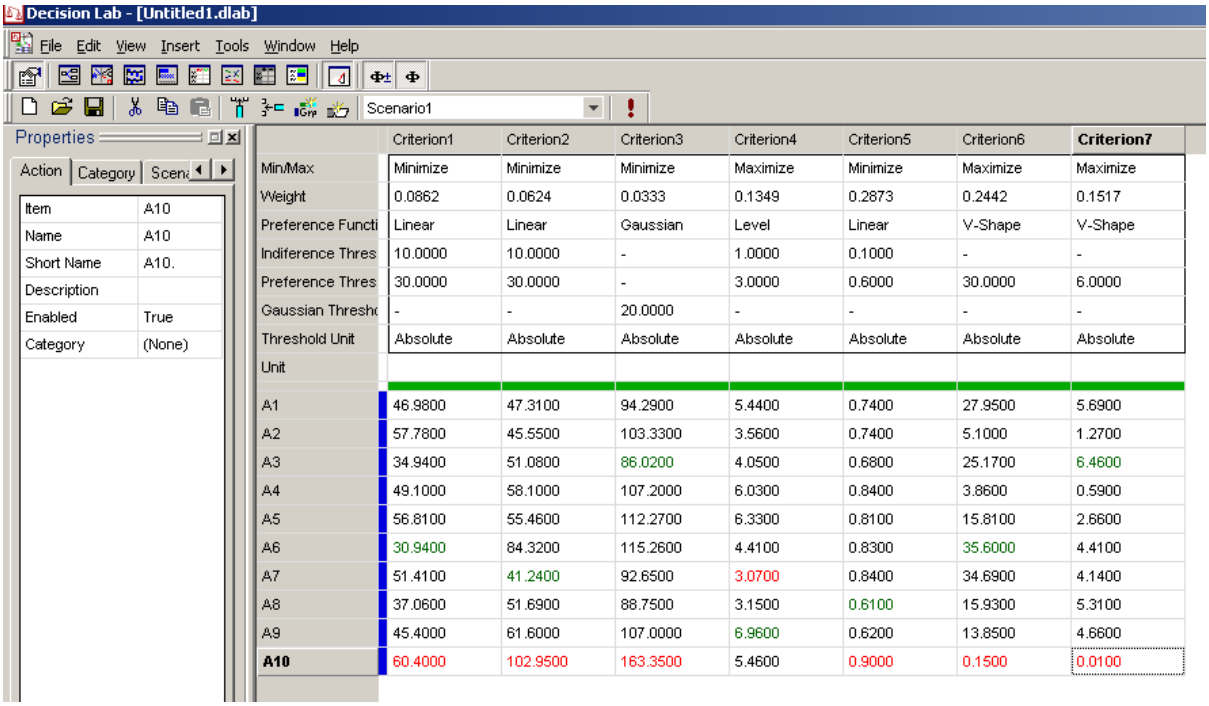
Za C4 (rezultat ulaganja) odabran je nivo kriterij gdje je potrebno odrediti oba praga. Prag q iznosi 1, a prag p iznosi 3. Kad se razlika u ocjenama nalazi između vrijednosti ovih pragova postoji slaba preferencija.

Za C5 (koeficijent zaduženosti) izabran je kriterij s linearnom preferencijom i područjem indiferencije. Donositelj odluke je indiferentan dok je zaduženost između dva osiguravajuća

društva manja od 0,1 (q=0,1). Između 0,1 i 0,6 (p=0,6) preferencija raste linearno dok je sve iznad 0,6 područje stroge preferencije.

Za C6 (rentabilnost vlastitih sredstava) kao i za C7 (rentabilnost imovine) odabran je kriterij s linearnom preferencijom. Za ovaj kriterij potrebno je odrediti p. Za kriterij C6 p iznosi 30 dok za kriterij C7 p iznosi 6. Preferencija raste linearno sve dok razlika u rentabilnosti ne dosegne 30 (za C6) ili 6 (za C7). Nakon zadanih iznosa nalazi se područje stroge preferencije.

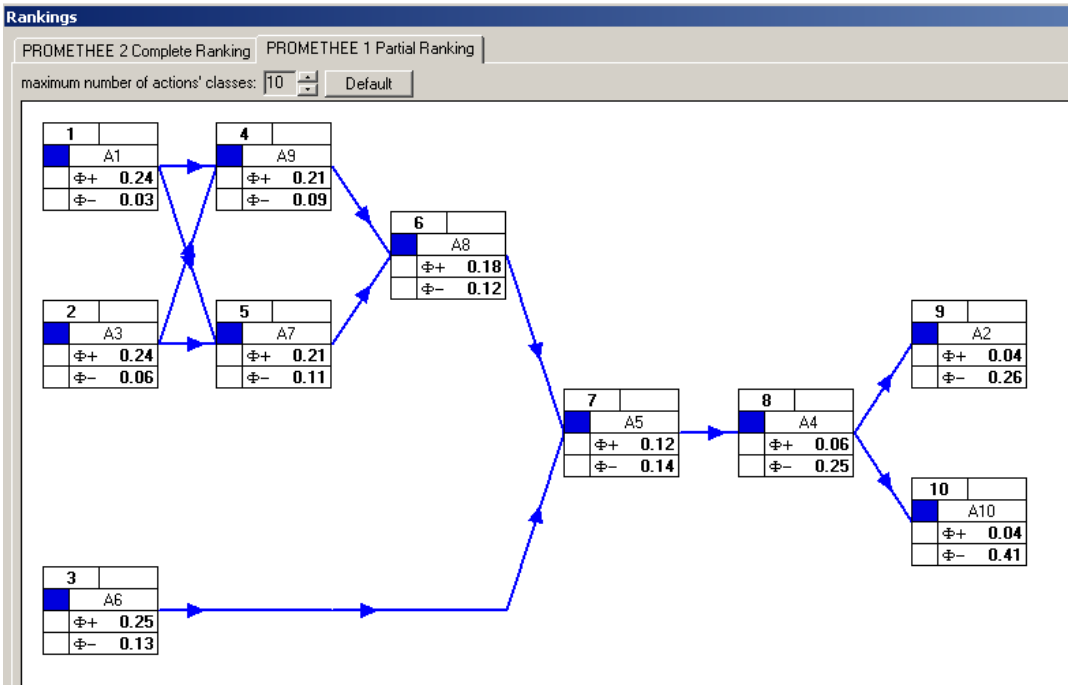
Da bi se riješio problem PROMETHEE metodom koristio se poseban program – Decision Lab. U program su uneseni podaci o 10 osiguravajućih društava (alternative A1- A10) te kriteriji (C1 – C7). Za svaki kriterij unesena je vrijednost težine. Kriterij C1,C2,C3,C5 su minimizirani dok su ostala tri kriterija maksimizirana. Slika 11. Prikazuje ulazne podatke za PROMETHEE metodu.



	Criterion1	Criterion2	Criterion3	Criterion4	Criterion5	Criterion6	Criterion7
Min/Max	Minimize	Minimize	Minimize	Maximize	Minimize	Maximize	Maximize
Weight	0.0862	0.0624	0.0333	0.1349	0.2873	0.2442	0.1517
Preference Functi	Linear	Linear	Gaussian	Level	Linear	V-Shape	V-Shape
Indiference Thres	10.0000	10.0000	-	1.0000	0.1000	-	-
Preference Thres	30.0000	30.0000	-	3.0000	0.6000	30.0000	6.0000
Gaussian Thresh	-	-	20.0000	-	-	-	-
Threshold Unit	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute
Unit							
A1	46.9800	47.3100	94.2900	5.4400	0.7400	27.9500	5.6900
A2	57.7800	45.5500	103.3300	3.5600	0.7400	5.1000	1.2700
A3	34.9400	51.0800	86.0200	4.0500	0.6800	25.1700	6.4600
A4	49.1000	58.1000	107.2000	6.0300	0.8400	3.8600	0.5900
A5	56.8100	55.4600	112.2700	6.3300	0.8100	15.8100	2.6600
A6	30.9400	84.3200	115.2600	4.4100	0.8300	35.6000	4.4100
A7	51.4100	41.2400	92.6500	3.0700	0.8400	34.6900	4.1400
A8	37.0600	51.6900	88.7500	3.1500	0.6100	15.9300	5.3100
A9	45.4000	61.6000	107.0000	6.9600	0.6200	13.8500	4.6600
A10	60.4000	102.9500	163.3500	5.4600	0.9000	0.1500	0.0100

Slika 11. Ulazni podaci za PROMETHEE metodu – program Decision Lab
Izvor: Izrada autorice

Nakon što su uneseni podaci koristi se opcija “Ranking“ da bi dobili parcijalni uređaj PROMETHEE I i PROMETHEE II.



Slika 12. PROMETHEE I – parcijalni uređaj
Izvor: Izrada autorice

Da bi bolje objasnili PROMETHEE I gledat ćemo sliku 12. i sliku 14. (jer su na slici 14. prikazane 4 decimale dok su na slici 12. zaokružene na dvije decimale te nije toliko jasno koja je alternativa bolja po kojem toku).

Alternativa A1 (Allianz Zagreb d.d.) i Alternativa A3 (Euroherc osiguranje d.d.) međusobno su neusporedive jer je A1 lošija po pozitivnom toku (Φ+ iznosi 0,2350) u odnosu na A3 (Φ+ iznosi 0.2415), a bolja po negativnom toku, jer je za negativni tok bolji što manji iznos (za A1 Φ- iznosi 0.0302 dok za A3 Φ- iznosi 0.0580).

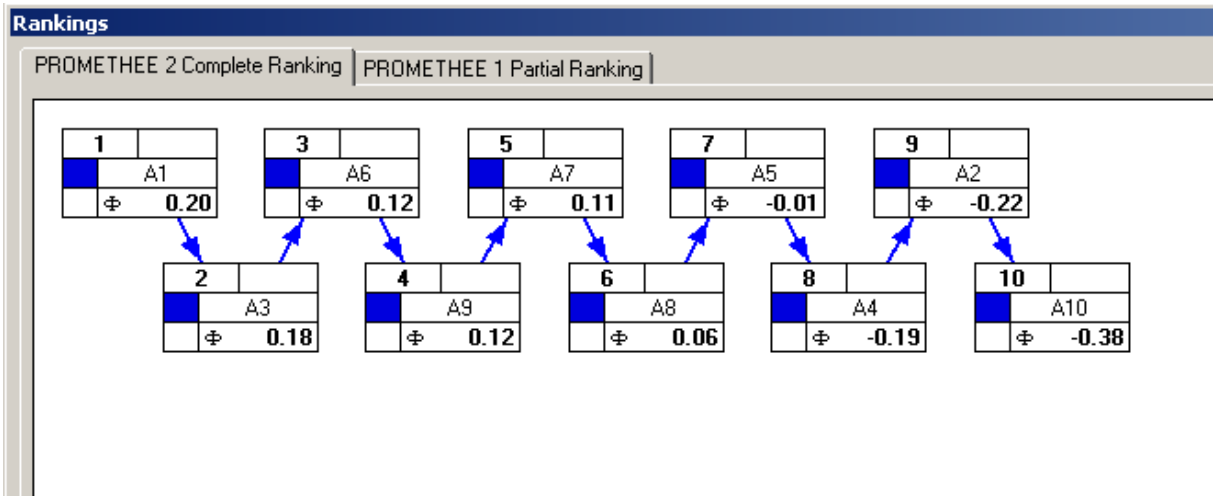
Isto tako alternative A9 (Merkur osiguranje d.d.) i A7 (HOK osiguranje d.d.) su međusobno neusporedive jer je A9 lošija po pozitivnom toku (Φ+ iznosi 0.2078) od A7 (Φ+ iznosi 0.2129), a A9 je bolja po negativnom toku (Φ- iznosi 0.0891) od A7 (Φ- iznosi 0.1074).

Alternativa A6 (Helios VIG d.d) je međusobno neusporediva sa A1, A3, A9, A7, A8 jer je bolja po pozitivnom toku, a lošija po negativnom toku.

Alternativa A5 (Grawe Hrvatska d.d) je bolja od A4 (Generali osiguranje d.d.) jer ima bolji i pozitivni i negativni tok.

Zadnje dvije alternative A2 (Croatia osiguranje d.d.) i A10 (Uniqa osiguranje d.d.) isto ne možemo usporediti jer A2 ima lošiji pozitivni tok od A10, a bolji negativni tok u odnosu na A10.

Da bi dobili potpuni poredak alternativa od najbolje do najlošije koristimo metodu PROMETHEE II.

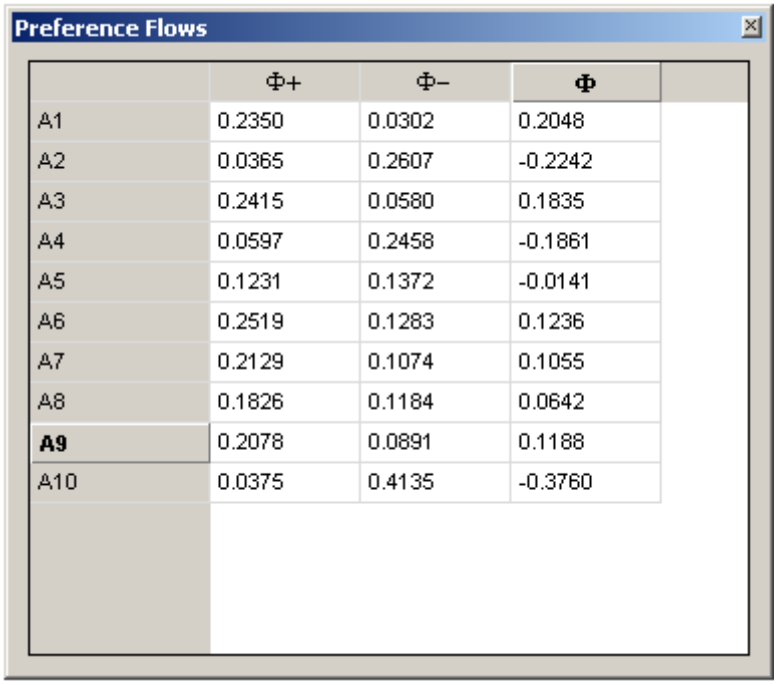


Slika 13. PROMETHEE II-Kompletni poredak
Izvor: Izrada autorice

PROMETHEE II – prikazuje potpuni poredak alternativa i prikazuje neto tok dobiven kao razlika pozitivnog i negativnog neto toka za svaku alternativu.

Iz slike 13. Možemo vidjeti da je alternativa A1 (Allianz Zagreb d.d.) najbolja jer je neto tok bolji od svih ostalih. Iza nje slijede redom ostale alternative poredane od najbolje do najlošije: A3 (Euroherc osiguranje d.d.), A6 (Helios VIG d.d), A9 (Merkur osiguranje d.d.), A7 (HOK osiguranje d.d.), A8 (Jaddransko osiguranje d.d), A5 (Grawe Hrvatska d.d), A4 (Generali osiguranje d.d.), A2 (Croatia osiguranje d.d.) i A10 (Uniqa osiguranje d.d.).

Iz slike 14. se može vidjeti pozitivan, negativan i neto tok za svaku alternativu



	Φ+	Φ−	Φ
A1	0.2350	0.0302	0.2048
A2	0.0365	0.2607	-0.2242
A3	0.2415	0.0580	0.1835
A4	0.0597	0.2458	-0.1861
A5	0.1231	0.1372	-0.0141
A6	0.2519	0.1283	0.1236
A7	0.2129	0.1074	0.1055
A8	0.1826	0.1184	0.0642
A9	0.2078	0.0891	0.1188
A10	0.0375	0.4135	-0.3760

Slika 14. Pozitivan, negativan i neto tok
Izvor: Izrada autorice

5.6. Usporedba rezultata dobivenih SAW metodom, TOPSIS metodom i PROMETHEE metodom

Kod SAW metode kao najbolja alternativa je A3 (Euroherc osiguranje d.d.), te nakon nje slijede A1 (Allianz Zagreb d.d), A6 (Helios VIG d.d), A9 (Merkur osiguranje d.d.), A7 (HOK osiguranje d.d.), A8 (Jaddransko osiguranje d.d), A5 (Grawe Hrvatska d.d), A2 (Croatia osiguranje d.d.), A4 (Generali osiguranje d.d.), A10 (Uniqa osiguranje d.d.).

Kod TOPSIS metode alternative su poredane ovako: A1 (Allianz Zagreb d.d), A6 (Helios VIG d.d), A3 (Euroherc osiguranje d.d.), A7 (HOK osiguranje d.d.), A8 (Jaddransko osiguranje d.d), A9 (Merkur osiguranje d.d.), A5 (Grawe Hrvatska d.d), A2 (Croatia osiguranje d.d.), A4 (Generali osiguranje d.d.), A10 (Uniqa osiguranje d.d.).

Kod PROMETHEE metode alternative su poredane: A1 (Allianz Zagreb d.d.),A3 (Euroherc osiguranje d.d.), A6 (Helios VIG d.d), A9 (Merkur osiguranje d.d.), A7 (HOK osiguranje d.d.), A8 (Jaddransko osiguranje d.d), A5 (Grawe Hrvatska d.d), A4 (Generali osiguranje d.d.), A2 (Croatia osiguranje d.d.) i A10 (Uniqa osiguranje d.d.).

Iz ovih rezultata vidimo da TOPSIS i PROMETHEE metoda navode alternativu A1 kao najbolju, dok je kod SAW metode ista rangirana na drugom mjestu kao najbolji izbor. SAW metoda ističe A3 kao najbolji izbor, dok se kod TOPSIS metode A3 nalazi na trećem mjestu, a kod PROMETHEE metode na drugom.

SAW i PROMETHEE metoda alternativu A6 rangiraju na treće mjesto, dok se kod TOPSIS metode nalazi na drugom mjestu.

Nadalje SAW i PROMETHEE alternativu A9 ističu kao četvrtu najbolju, dok se kod TOPSIS metode ona nalazi na šestom mjestu kao najbolji izbor. TOPSIS kao četvrti najbolji izbor rangira metodu A7 dok se kod preostale dvije metode ista alternativa nalazi na petom mjestu izbora. SAW i PROMETHEE alternativu A8 pozicioniraju na šesto mjesto kao najbolju, dok je u TOPSIS metodi alternativa A8 na petom mjestu.

Kod sve tri metode alternativa A5 se nalazi na sedmom mjestu.

SAW I TOPSIS metoda pozicionira A2 na osmo mjesto, dok se kod PROMETHEE metode ista nalazi na devetom mjestu kao najbolji izbor. Isto tako SAW i TOPSIS alternativu A4 rangiraju kao deveti izbor, dok se kod se kod PROMETHEE metode ista nalazi na osmom mjestu.

Sve tri metode ističu A10 kao najlošiji izbor od ponuđenih alternativa.

Usporedbom rezultata jasno se uočava da nema velike razlike između metoda jer su rezultati jako slični. Prva tri mjesta “drže“ alternative A1, A3 i A6. Ipak kao najbolja alternativa može se uzeti A1 iz razloga jer su istu dvije metode poredale na prvo mjesto, a kao najlošiji izbor A10 bez sumnje jer tu odluku potvrđuju sve tri metode.

6. ZAKLJUČAK

Osiguravajuća društva imaju specifično poslovanje te je utvrđivanje njihovog financijskog poslovanja zahtjevnije zbog brojnih specifičnosti. Prihod se ostvaruje od zarađene premije dok najveći dio rashoda ide za pokrivanje štete jer je osnovi cilj svakog korisnika osiguranja da mu se isplati šteta ukoliko dođe do određene nevolje, štete i slično. Cijela bit poslovanja istih se temelji na tome da je osiguranik skoro siguran da će se na njegovoj imovini dogoditi šteta i zato uplaćuje premiju, dok je osiguravajuće društvo gotovo sigurno da se to neće dogoditi i zato nastoji privući što više korisnika i tako ostvaruje profite što je primarni cilj svakog profitnog poduzeća.

Da bi se utvrdio bonitet poduzeća koriste se financijski izvještaji i 8 dodatnih izvještaja koja su ova društva obvezna donijeti Hrvatskoj agenciji za nadzor financijskih usluga – HANFA.

Cilj ovog rada je prikazati metode kojima se odabire najbolja alternativa. Za ovaj rad je izabrano 10 osiguravajućih društava koje su u 2011. godine poslovali u "plusu". Primjenom višekriterijalnog odlučivanja navedena osiguranja se rangiraju po procjeni uspješnosti poslovanja. Prilikom procjene odabrani su kriteriji zbog njihove važnosti i zbog zanimljivosti rezultata prilikom korištenja istih. Od kriterija su odabrani oni koji su specifični za ova društva (razmjer štete, razmjer troškova, kombinirani razmjer i rezultat ulaganja) te oni pokazatelji koje koriste sva društva prilikom procjene poslovanja (koeficijent zaduženosti, rentabilnost vlastitih sredstava i rentabilnost imovine). Da bi rangirali navedena društva koristile su se iduće metode: Metoda jednostavnog zbrajanja težina - SAW, TOPSIS metoda i PROMETHEE metoda. Da bi se mogle provesti metode potrebno je odrediti težinu za svaki kriterij. Određivanje težina dobilo se metodom svojstvenog vektora.

Usporedbom rezultata dobivenih navedenim metodama kao najbolji izbor između alternativa proizlazi alternativa A1(Allianz Zagreb d.d.) koju TOPSIS i PROMETHEE metoda rangiraju kao najbolju. Rezultati dobiveni ovim metodama su poprilično slični te se uglavnom radi u razlikama od jednog mjesta. Sve tri metode kao najlošiji izbor ističu alternativu A10 (Uniqa osiguranje d.d.).

SAŽETAK

Osiguravajuća društva, kao i ostala poduzeća dužna su voditi poslovne knjige i sastavljati financijske izvještaje. Financijski izvještaji predstavljaju glavni izvor informacija o poslovanju. Na temelju istih saznajemo kako poduzeće posluje. Osim financijskih izvještaja osiguravajuća društva, zbog posebnosti svog poslovanja, trebaju dostaviti još određena dodatna izvješća. Iz izvještaja dobiveni su pokazatelji poslovanja koji se u ovom radu koriste kao kriteriji za procjenu poslovanja (boniteta) osiguravajućih društava. Rad prikazuje kako se osiguravajuća društva rangiraju od najboljeg do najlošijeg izbora pomoću višekriterijalnog odlučivanja. 10 osiguravajućih društava se rangira tako da se prvo odrede težine koristeći se metodom svojstvenog vektora. Nakon dobivenih težina, odaberu se kriteriji (razmjer troškova, razmjer šteta, kombinirani razmjer, rezultat ulaganja, koeficijent zaduženosti, rentabilnost vlastitih sredstava i rentabilnost imovine) te se dobiju rezultati po svakoj pojedinoj metodi koja je korištena – SAW metoda, TOPSIS metoda i PROMETHEE metoda. Svaka metoda je pojedinačno objašnjena i pokazana u praksi. Navedeni kriteriji su odabrani da se pokaže specifičnost poslovanja osiguravajućih društava i da se pokaže koje osiguravajuće društvo najbolje posluje. Rezultati dobiveni po ovim metodama su poprilično slični, ne razlikuju se puno. TOPSIS i PROMETHEE metoda ističu A1 (Allianz Zagreb d.d.) kao najbolju alternativu, dok je kod SAW metode ista rangirana na drugo mjesto. SAW metoda kao najbolji izbor prikazuje A3 (Euroherc osiguranje d.d.) alternativu koja se kod PROMETHEE metode nalazi na drugom mjestu, a kod TOPSIS metode na trećem. SAW metoda i PROMETHEE metoda alternativu A6 (Helios VIG d.d.) rangiraju kao treću najbolju, dok se ista nalazi na drugom mjestu u TOPSIS metodi. Ipak kao najbolju možemo uzeti alternativu A1 jer ju dvije metode stavljaju na prvo mjesto. Kao najlošiju alternativu sve tri metode ističu alternativu A10 (Uniqa osiguranje d.d.).

Ključne riječi: višekriterijalno odlučivanje, osiguravajuća društva, bonitet

SUMMARY

Insurance companies as well as other companies are obliged to maintain business books and companies also have to prepare financial statements. The financial statements are the main source of business informations. Based on it, we know how company operates. In addition to the financial statements, insurance companies need to provide certain additional reports, due to the particular nature of their business. From the report we count business indicators that are used in this paper as criteria for assessing the business performance (creditworthiness) of the insurance companies. This work shows how insurance companies rank from the best to the worst choice through multi-criteria decision making. 10 insurance companies are ranked in the way thaht the weights are first determined using a vector-specific method. After the weight gained, we choose criteria (cost ratio, ratio of damage, combined ratio, investment result, indebtedness coefficient, profitability of own resources and asset profitability), and results are obtained for each particular method used - SAW method, TOPSIS method and PROMETHEE method . Each method is individually explained and demonstrated in practice. These criterias were chosen to show the specificity of insurance companies and to show which insurance company operates best. The results obtained by these methods are quite similar, there are not big differences in results. TOPSIS and PROMETHEE methods point out A1 (Allianz Zagreb d.d.) as the best alternative, while the SAW method ranked A1 alternative as the second best. The SAW method as the best option displays the A3 (Euroherc insurance d.d.) alternative. This alternative is positioned od second place in PROMETHEE method, and by using TOPSIS method it is on the third place. SAW Method and PROMETHEE Method Alternative A6 (Helios VIG d.d.) rank as the third best, while this alternative is ranked as second best in TOPSIS method. However, as the best alternative we can say that is A1 because two metods rang this alternative in the first place. As the worst alternative, all three methods emphasize alternative A10 (Uniqa Insurance d.d.).

Keywords: multi-criteria decision making, insurance companies, creditworthiness

POPIS LITERATURE

Knjige

1. Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split
2. Bijelić M., (2002): Osiguranje i reosiguranje, Tectus, Zagreb
3. Ćurak M., Jakovčević D., (2007): Osiguranje i rizici, M.A.K. Golden d.o.o., Zagreb
4. Dropulić I., (2013): Skripta za vježbe, Menadžersko računovodstvo, Ekonomski fakultet Split, Split
5. Filipović I., (2009): Revizija, Sinergija, Zagreb
6. Kopun V., Slade J., (1991): Metode procjene vrijednosti i ocjene boniteta poduzeća., Kopun i Kopun, Zagreb
7. Leko V., Milinović A., Potkonjak M., (1996): Procjena boniteta trgovačkog društva, MASMEDIA, Zagreb
8. Nikolić N., Pečarić M., (2012): Uvod u financije, Ekonomski fakultet Split, Split
9. Pivac S., Marasović B., Skripta, Aktuarska matematika, Ekonomski fakultet Split, Split
10. Reić Z., Mihaljević Kosor M., Šimić V., (2017): Ekonomija, Ekonomski fakultet Split, Split
11. Soltani B., (2009): Revizija: Međunarodni pristup., MATE d.o.o., Zagreb.
12. Vidučić Lj., Pepur S., Šimić Šarić M., (2015) : Financijski menadžment, RriF, Zagreb
13. Vujević I., (2003) : Financijska analiza, Ekonomski fakultet Split, Split
14. Vukičević M., Odobašić S., (2011): Osnove financija, Visoka škola za poslovanje i upravljanje "Baltazar Adam Krečelić" , Zaprešić
15. Žugaj, M., Dumičić K., Dušak V. (2006): Temelji znanstvenoistraživačkog rada, Metodologija i metodika, TIVA Tiskara Varaždin, Varaždin
16. Žager K., Mamić Sačer I., Sever s., Žager L., (2008): Analiza financijskih izvještaja, MASMEDIA, Zagreb

Izvori s Interneta

1. https://www.allianz.hr/privatni-korisnici/pojmovi-u-osiguranju/zivotno-osiguranje-kao-stednja-kako-ustedjeti-novac/
2. http://www.businessdictionary.com/definition/creditworthiness.html
3. http://www.fina.hr/default.aspx?sec=1278
4. http://financije-plus.com/Osnovni-pojmovi/Sto-je-bonitet.php
5. https://www.hanfa.hr/uploads/2016/04/22/1461315083_2de84389b28e2a283443845895671d0d.pdf
6. http://www.moj-bankar.hr/Kazalo/P/Premija-osiguranja
7. http://www.poslovni.hr/leksikon/bonitet-44
8. http://www.poslovnaucinkovitost.eu/edukacije/predavanje/ocjena-boniteta-poduzeca
9. http://www.poslovni.hr/tips-and-tricks/znate-li-cemu-sluze-informacije-o-novcanom-toku-229364
10. http://www.propisi.hr/print.php?id=13765
11. http://profitiraj.hr/financijski-pokazatelji-pokazatelji-likvidnosti/
12. http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf

POPIS SLIKA

Slika 1: Prikaz skraćene bilance 13
Slika 2. Funkcija preferencije 36
Slika 3. Funkcija preferencije H(d) 37
Slika 4. Obični kriterij 38
Slika 5. Kvazi kriterij 38
Slika 6. Kriterij s linearnom preferencijom 39
Slika 7. Nivo kriterij 40
Slika 8. Kriterij s linearnom preferencijom i područjem indiferencije 40
Slika 9. Gaussov kriterij 41
Slika 10. Lukovi Π(a, b) i Π(b, a) 42
Slika 11. Ulazni podaci za PROMETHEE metodu – program Decision Lab 56
Slika 12. PROMETHEE I – parcijalni uređaj 57
Slika 13. PROMETHEE II-Kompletni poredak 58
Slika 14. Pozitivan, negativan i neto tok 59

POPIS TABLICA

Tablica 1. Saatyeva skala važnosti i njen opis 28
Tablica 2. PROMETHEE – matrica odluke 35
Tablica 3. PROMETHEE I – parcijalni uređaj 43
Tablica 4. Osiguravajuća društva i kriteriji 46
Tablica 5. Matrica međusobnih usporedbi 47
Tablica 6. Transformirana matrica A` 47
Tablica 7. Tablica odluke – osiguravajuća društva 48
Tablica 8. Linearna transformacija – osiguravajuća društva 49
Tablica 9. Konačan poredak alternativa metodom jednostavnog zbrajanja težina 49
Tablica 10. Tablica odluke – osiguravajuća društva 50
Tablica 11. Kvadrati i norma 51
Tablica 12. Vektorska transformacija – osiguravajuća društva 51
Tablica 13. Udaljenost alternativa od idealne alternative 52
Tablica 14. Kvadrati, suma i S i + ... 52
Tablica 15. Udaljenost alternativa od antiidealne alternative 53
Tablica 16. Kvadrati, suma i S i – 53
Tablica 17. Relativna bliskost i konačan poredak alternativa 54
Tablica 18. Tablica odluke 55