VIŠEKRITERIJALNO ODLUČIVANJE I PROCJENA BONITETA HOTELA

Alilović, Mirna

Master's thesis / Diplomski rad

2016

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:124:791347

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 HOTELA

Mentor:

Prof. dr. sc. Zoran Babić

Student:

Mirna Alilović

Split, listopad, 2016.

SADRŽAJ:

1. UVOD.....3

1.1. Problem istraživanja…….3

1.2. Svrha i ciljevi istraživanja……5

1.3. Doprinos istraživanja……...6

2. BONITET PODUZEĆA.....7

2.1.Pojam boniteta.....7

2.2. Razlozi procjene boniteta.....8

2.3.Izvori podataka za procjenu boniteta……9

2.4. Načini procjenjivanja boniteta.....10

2.5.Financijski pokazatelji poslovanja poduzeća i temeljna financijska izvješća…....11

2.6. Procjena boniteta u Republici Hrvatskoj……...23

3. HOTELIJERSTVO.....30

3.1.Pojam hotelijerstva.....30

3.2.Povijesni razvoj hotelijerstva u RH.....36

3.3.Procjena boniteta hotela.....39

4. METODE ZA VIŠEATRIBUTNO ODLUČIVANJE.....40

4.1. Višekriterijalno odlučivanje.....41

4.2. Višeatributno odlučivanje.....44

4.3. Procjena važnosti kriterija……..46

4.3.1. Metoda svojstvenog vektora.....46

4.4. Metode za višeatributno odlučivanje.....52

4.4.1. PROMETHEE metoda……53

5. PRIMJENA METODA VIŠATRIBUTNOG ODLUČIVANJA NA PROBLEM PROCJENE BONITETA HOTELSKIH PODUZEĆA 62

5.1.Analiza boniteta hotela…….....62

5.2.Određivanje težina kriterija metodom svojstvenog vektora.....68

5.3.Odabir najbolje alternative PROMETHEE metodom.....72

6. ZAKLJUČAK.....78

LITERATURA.....79

POPIS TABLICA.....81

POPIS SLIKA.....81

1. UVOD

1.1. Problem istraživanja

Za donošenje kvalitetnih poslovnih odluka koje su ključne za opstanak poduzeća na tržištu, poduzeće mora posjedovati informacije o bonitetu poslovnih partnera. Ta je potreba u nas jako izražena zbog toga što se prijelazom iz plansko-odgovorne u tržišnu privredu mijenjaju karakteristike postojećih poduzeća, ali dolazi i do masovne pojave novih, malih, privatnih poduzeća o kojima nedostaje informacija.[1]

Zbog raznih promjena u gospodarskoj i financijskoj strukturi kao što su novi poslovni i financijski odnosi, novi tokovi i instrumenti, novi sudionici na tržištu, promjene regulative i slično dolazi do povećanja stupnja neizvjesnosti i rizika za svako poduzeće na tržištu.[2] Upravo zbog toga svrha i glavni razlog procjene boniteta je minimaliziranje rizika u poslovanju.

Riječ bonitet ima korijen latinske riječi bonitas koja ima značenje dobrota, valjanost, izvrsnost, a u trgovačkom smislu sposobnost plaćanja.[3]

Bonitet su formalna i materijalna svojstva subjekta koja ga čine sigurnim dužnikom bilo da je riječ o poslovnoj banci u koju se ulažu financijska sredstva ili o poduzeću kojem se odobrava kredit. Pojam nije isključivo vezan uz kreditnu sposobnost nego je obilježje poduzeća tj. trgovačkog društva i njegovog poslovanja, urednosti na tržištu, ugleda koje ima na domaćem i inozemnom tržištu, načina izvršenja obveza i slično. [4]

Vlado Leko u knjizi „procjena boniteta trgovačkog društva“ bonitet definira kao: „Bonitet trgovačkog društva jest njegova ukupna poslovna sposobnost, financijska snaga u okviru koje dobivamo odgovor o financijskim sposobnostima trgovačkog društva da podmiri svoje obveze, te da posluje profitabilno i stabilno na dug vremenski rok, a uz sve to da ima „dobar glas“ (goodwill) u javnosti.“

Informacije o bonitetu poslovnog partnera prikupljamo iz prethodnih poslovnih odnosa, vlastitih evidencija, dnevnog i stručnog tiska, gospodarskih komora i udruga, poslovnih partnera te specijaliziranih institucija za procjenu boniteta.

[1] Leko, V. (1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.5
[2] Leko, V. (1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.5
[3] Anić Š., Klaić N., Domović Ž. (1998); Rječnik stranih riječi a/ž, Nacionalna i sveučilišna knjižnica, Zagreb
[4] Ekonomski leksikon (1995), leksikografski zavod „Miroslav Krleža“ , Masmedia, Zagreb

Ocjena boniteta služi da bi se otkrilo koja poduzeća nemaju sposobnost za plaćanje ili su prezadužena. Upravo zbog toga financijske institucije i fizičke osobe moraju stalno ocjenjivati bonitet svojih komitenata i/ili poslovnih partnera kako bi izbjegli poslovni odnos sa takvim firmama.

Najkvalitetnije procjene boniteta utvrđuju se na dva načina:[5]

- Sama zainteresirana strana obrađuje podatke , standardizirana financijska izvješća i podatke o poslovanju druge osobe.
- Podatke o bonitetu pružaju specijalizirane institucije za procjenu boniteta.

Kod utvrđivanja boniteta, poduzeća koriste razne metode koje moraju sadržavati financijsku i nefinancijsku komponentu. Nefinancijska komponenta sadrži podatke koji se ne mogu novčano izraziti te je ponekad do njih teže doći. S druge strane financijska komponenta tj. financijski pokazatelji (pokazatelji profitabilnosti, likvidnosti, zaduženosti, ekonomičnosti, aktivnosti i pokazatelji investiranja) se računaju iz temeljnih financijskih izvješća, a to su: bilanca, račun dobiti i gubitka, izvješće o novčanom toku, bilješke uz financijska izvješća te izvješće o promjeni glavnice. [6]

Bonitetna izvješća u Republici Hrvatskoj izrađuju: Hrvatska gospodarska komora na temelju upitnika koji šalje tvrtki, financijska agencija FINA koja izdaje bonitetna izvješća u obliku obrazaca BON-1, BON-2 i BONPLUS, te različite privatne agencije.

U ovom radu izvršit će se procjena boniteta hotelskih poduzeća.

Hotelijerstvo je gospodarska aktivnost pružanja usluga smještaja koja posjetiteljima omogućuje privremeni boravak, odmor i razonodu. Hotelijerstvo nudi usluge smještaja i ostale usluge, čime pokušava zadovoljiti potrebe i motive gostiju, a djelatnicima i menadžmentu osigurava životni standard.[7]

Kod procjene boniteta hotela vrijede ista pravila kao kod procjene boniteta bilo kojeg drugog poduzeća. Bonitet hotela se procjenjuje od strane uprave samog hotela s ciljem praćenja vlastitog poslovanja, od strane poslovnih partnera kako bi saznali s kakvim poduzećem stupaju u poslovni odnos, te od strane potencijalnih ulagača kako bi smanjili stupanj rizika i neizvjesnosti.

[5] Leko, V. (1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.6
[6] Vidučić, Lj. (2004); Financijski menadžment, RRIF-plus, Zagreb
[7] Cerović, Z. (2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.67

Kada se radi procjena boniteta hotela koriste se kvantitativni i kvalitativni pokazatelji. Kvantitativni pokazatelji su već spomenuti financijski pokazatelji, a kvalitativni mogu biti razni kao na primjer veličina, lokacija, starost, broj zaposlenih, organizacijska struktura i kultura, ugled itd.

Višekriterijalno odlučivanje (Multiple Criteria Decision Making – MCDM) je proces donošenja odluka uz postojanje dva ili više kriterija. U većini situacija ti kriteriji su u konfliktu i/ili imaju neusporedive mjerne jedinice. U ovom radu kriteriji na temelju kojih će se donositi odluke biti će financijski pokazatelji.

Iz prethodno navedenog je vidljivo da je problem istraživanja procijeniti bonitet izabranih hotela grada Splita pomoću metoda višekriterijalne analize na temelju kriterija (financijskih pokazatelja) , izvršiti rangiranje hotela od najboljeg do najlošijeg i odabrati najbolju alternativu pomoću metode PROMETHEE .

1.2. Svrha i ciljevi istraživanja

Svrha i cilj ovoga istraživanja je, kao što je navedeno u problemu istraživanja, procjena boniteta hotelskih poduzeća Splitsko-dalmatinske županije. Kako bi se utvrdio postavljeni cilj koristit će se PROMETHEE metoda za višekriterijalno odlučivanje kojom će se obaviti odabir najbolje alternative.

Osnovni cilj se može analitički podijeliti na nekoliko pomoćnih ciljeva koji pomažu boljem ostvarivanju temeljnog cilja istraživanja:

- Definiranje pojma boniteta, navođenje razloga i načina procjenjivanja boniteta te izvora podataka potrebnih za procjenu.
- Definiranje pojma hotelijerstva i kratki opis njegovog povijesnog razvoja.
- Analiziranje PROMETHEE metode.
- Objašnjavanje primjene odabrane metode PROMETHEE na problem procjene boniteta tvrtke.

1.3. Doprinos istraživanja

U ovom radu nastoji se teorijski definirati pojam boniteta poduzeća, navesti razloge i izvore podataka za procjenu boniteta te financijskih pokazatelja poslovanja poduzeća. Pomoću opisa povijesnog razvoja hotelijerstva u Republici Hrvatskoj pokušat će se objasniti uzroke zbog kojih poduzeće ostvaruje određene rezultate i financijski položaj na tržištu. Doći ćemo do zaključka koja je najbolja alternativa odnosno hotelsko poduzeće na temelju procjene boniteta izabranih hotela iz uzorka. Tema procjene boniteta posebno je važna i aktualna zbog visokog stupnja neizvjesnosti i mogućnosti nastupa rizika koji kao posljedicu ima velike gubitke za svakog sudionika na tržištu. Kvalitetne odluke se moraju donositi na osnovi sustavnog prikupljanja i analiziranja kvalitetnih informacija kako bi se točno procijenio poslovni partner, klijent, kupac, dobavljač i slično. Prije nego što donesu odluku o sklapanju određenog posla, trgovačka društva žele provjeriti i procijeniti „zdravlje“ potencijalnog partnera.

Važnost procjene boniteta nekog trgovačkog društva bila je predmet istraživanja mnogih znanstvenika, koji su na razne načine olakšali razumijevanje ove tematike. Cilj rada je doprinijeti boljem razumijevanju važnosti i značenja procjene boniteta trgovačkog društva, te redoslijeda postupaka u samom procesu procjene.

2. BONITET PODUZEĆA

2.1. Pojam boniteta

Trgovačko društvo se osniva zbog raznih razloga kao što su dugo i stabilno poslovanje, ostvarivanje dobiti svojim vlasnicima, donošenje koristi zaposlenicima, doprinos razvoju grada, te sveukupnom razvoju države. Da bi se svi ti ciljevi ostvarili, trgovačko društvo stupa u razne poslovne odnose s drugim poduzećima. Upravo ti odnosi stvaraju potrebu za informacijama o bonitetu potencijalnih poslovnih partnera koje su ključne za donošenje kvalitetnih poslovnih odluka.

U današnjem poslovnom svijetu visok je stupanj neizvjesnosti i mogućnosti nastupa rizika koji kao posljedicu ima velike gubitke za svako poduzeće na tržištu. Zbog toga pri zaključivanju raznih poslova nije dovoljan samo „osjećaj" nego je potrebno sustavno prikupljanje i analiziranje informacija kako bi se ocijenilo poslovnog partnera.

Pod pojmom „boniteta" označava se kvaliteta, pouzdanost te poslovna i kreditna sposobnost pravne i fizičke osobe.[8]

Riječ bonitet vuče korijen od latinske riječi bonitas, što znači dobrota, valjanost, izvrsnost tj. u trgovačkom smislu sposobnost plaćanja.[9]

Bonitet trgovačkog društva je ukupna poslovna sposobnost poduzeća unutar koje dobivamo odgovor o financijskim sposobnostima trgovačkog društva da podmiruje svoje obveze, te da posluje profitabilno i stabilno na duži vremenski period uz „dobar glas" u javnosti.[10]

Pojam boniteta se sastoji od dva elementa: materijalnog i nematerijalnog. Nematerijalni element boniteta označava stupanj osobnog rejtinga dužnika (ugled, karakter, pouzdanost osobe, trajnost i stabilnost poslovanja). Pod materijalnim elementom podrazumijeva se kreditni rejting pravne ili fizičke osobe tj. sposobnost da se nekoj osobi odobri kredit te da ga ona iz svojih likvidnih sredstava servisira.[11]

Iz dane definicije boniteta razlikuje se kreditna sposobnost i kreditni rejting. Kreditna sposobnost se dijeli na dva segmenta: pravni i gospodarski. Kreditna sposobnost s pravnog stajališta znači sposobnost neke pravne ili fizičke osobe da može uzeti kredit. Gospodarski segment označava pojam kreditnog rejtinga.

[8] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.5
[9] Anić, Š., Klaić, N., Domović, Ž.(1998); Riječnik stranih riječi a/ž, Nacionalna i sveučilišna knjižnica, Zagreb
[10] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.9
[11] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.9

Kreditne institucije ispituju sposobnosti osobe kako bi joj se odobrio kredit na osnovi bilance, računa dobiti i gubitka, novčanog toka, likvidnosti i stabilnosti poslovanja u prošlosti te investicijskim i financijskim planovima za budućnost.

S problemom naplate potraživanja susreće se većina pravnih ili fizičkih osoba u Republici Hrvatskoj. Krajnji rezultat je začarani krug nelikvidnosti, što direktno utječe na uredno poslovanje, a ponekad i na tržišni opstanak. Osnovni problem neplaćanja dugova (nelikvidnosti) je taj što ne ostavlja posljedice samo na inicijatora nego se eksponencijalno širi te stvara atmosferu nesigurnosti i nepovjerenja. Time se ulazi u začarani krug ograničenja rasta što rezultira padom poslovnih aktivnosti jer dio poslovnih subjekata propada, a ostali znatno opreznije ulaze u poslovne odnose s partnerima.

2.2. Razlozi procjene boniteta

Razlozi obavljanja procjene boniteta mogu biti razni. Tri glavna razloga su:[12]

1. Kontinuirano praćenje vlastite financijske situacije, analiziranje ostvarenih financijskih pokazatelja, planiranje financijskih instrumenata i provođenje financijskog nadzora.
2. Izračun i analiza financijskih pokazatelja poslovnih partnera s kojima trgovačko društvo ostvaruje razne poslovne odnose.
3. Provođenje detaljne provjere boniteta emitenta dugoročnih vrijednosnih papira kod ulaganja u dugoročne vrijednosne papire, tj. da se potencijalnim ulagačima pruže sve potrebne informacije za donošenje odluke o ulaganju kapitala.

Važno je da svako trgovačko društvo javno objavljuje sve relevantne financijske informacije i financijske pokazatelje svog poslovanja, kao što je godišnje izvješće o poslovanju. U godišnjem izvješću potrebno je prezentirati detaljnije financijske informacije od onih koje su dane u bilanci, računu dobiti i gubitka i novčanom toku, a sve to s ciljem dobrog prezentiranja svog financijskog „zdravlja“ i pružanja financijskih podataka koje je moguće analizirati od strane svih zainteresiranih strana.

Korisnici bonitetnih informacija su najčešće banke, osiguravajuća društva, investicijski fondovi, poslovni partneri, konkurenti, sami vlasnici poduzeća itd.

[12] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.10

2.3. Izvori podataka za procjenu boniteta

Najznačajniji izvori podataka za procjenu boniteta poduzeća su:

- Temeljna financijska izvješća
- Obrasci BON1, BON2 i BONPLUS koje izdaje FINA
- Izvješće o dodanoj vrijednosti
- Dokazi o postojanju hipoteke na imovinu potencijalnog dužnika
- Informacije o poslovnom partneru pribavljene od strane postojećih vjerovnika

Zbog visokog stupnja neizvjesnosti i mogućnosti nastupa rizika provode se analize i procjena boniteta. Rizik se na taj način ne može u potpunosti ukloniti, ali se može uvelike smanjiti. Opseg i kvaliteta procjene ovise o prikupljenim podatcima, a osnovni problem je dostupnost tih podataka.

Kao najznačajniji izvori podataka za procjenu boniteta najprije se koriste obrasci BON1, BON2 i BONPLUS, a ukoliko oni ne daju dostatne informacije tada se koriste temeljna financijska izvješća.

Informacija o bonitetu BON1 sadrži opće podatke o poduzetniku, podatke i pokazatelje o njegovu poslovanju u protekle dvije godine, kretanje broja zaposlenih i njihove prosječne plaće, stanje novčanih sredstava tijekom protekle godine, rang tvrtke u djelatnosti te objašnjenja navedenih pokazatelja.[13]

Obrazac BON2 sadrži opće podatke o poslovnom subjektu, stanje sredstava na računu, ukupan iznos primitaka u korist računa u prethodnih 30 dana, prosječno stanje sredstava na računu u prethodnih 30 dana, iznos odobrenog okvirnog kredita, iznos evidentiranih nepodmirenih obveza, broj dana neprekidne blokade računa i broj dana blokade računa u proteklih 6 mjeseci.[14]

Bonitetna informacija BONPLUS je proširena verzija bonitetne informacije koja sadrži još kvalitetnije, jasnije, preglednije te lako razumljive podatke i informacije.[15]

U temeljna financijska izvješća prema Međunarodnim računovodstvenim standardima i Zakonu o računovodstvu spadaju:

1. Bilanca

[13] Financijska agencija – FINA (http://www.fina.hr/)
[14] Financijska agencija – FINA (http://www.fina.hr/)
[15] Financijska agencija – FINA (http://www.fina.hr/)

2. Račun dobiti i gubitka
3. Izvještaj o novčanom toku
4. Bilješke uz financijske izvještaje

Osnovni cilj izrade temeljnih financijskih izvještaja je da pruže informacije o financijskom položaju poduzeća koje su osnovni materijal za analizu. Detaljne informacije o temeljnim financijskim izvještajima, kako i o bonitetnim obrascima, bit će iznesene u narednim poglavljima ovog rada.

2.4. Načini procjene boniteta

Informacije o bonitetu poslovnog partnera obično potječu iz prethodnih poslovnih odnosa, vlastitih mišljenja i evidencija, od poslovnih informatora, iz dnevnog i stručnog tiska, od gospodarskih komora i udruženja, od drugih poslovnih partnera, te od raznih predstavništava u inozemstvu. Međutim, najkvalitetnija saznanja o bonitetu moguće je steći na dva različita načina.

Prvi je kada zainteresirana strana obrađuje opće podatke, standardizirana financijska izvješća i podatke o poslovanju druge tvrtke. Ti podaci predstavljaju primarne izvore, a njih su poduzeća dužna objavljivati zakonskim odredbama, uvjetima burze i dobrim poslovnim običajima. Na temelju analize podataka iz prošlosti i pokazatelja poslovanja procjenjuje se bonitet poslovnog partnera u kratkom razdoblju u budućnosti ili dugoročne perspektive ako se radi o dugoročnim ugovorima.

Drugi način je onaj kada podatke o bonitetu pružaju specijalizirane institucije za procjenu boniteta (Standard & Poar's Corporation, Moody's Investors Service, International Banking Credit Analysis, Keefe, Bruyette & Wood's Inc, Fitch Investor Service, Creditreform i dr.)[16] Navedene institucije i još mnoge druge objavljuju materijale o poduzećima na temelju čega financijski investitori procjenjuju rizik i pouzdanost dužnika pri emisiji vrijednosnih papira.

[16] Poslovni dnevnik web (http://www.poslovni.hr/marketing-i-mediji/analize-boniteta-poduzeca-2984)

2.5. Financijski pokazatelji poslovanja poduzeća i temeljna financijska izvješća

Financijski pokazatelji su najpoznatija i najraširenija analitička sredstva financijske analize. Pokazatelj je odnosni broj tj. prikazuje odnos jedne ekonomske veličine s drugom. Dijelimo ih u dvije skupine s obzirom na vremensku dimenziju:[17]

- Prva skupina su financijski pokazatelji poslovanja poduzeća unutar određenog razdoblja, odnosno godine dana, i temelje se na podacima iz računa dobiti i gubitka.
- Druga skupina su financijski pokazatelji koji se odnose na točno određeni trenutak i govore o financijskom položaju poduzeća na taj dan (najčešće 31.prosinca kako bi se podudaralo s datumom sastavljanja bilance).

Razlog računanja financijskih pokazatelja je taj da se stvori informacijska podloga o likvidnosti, zaduženosti, efikasnosti i profitabilnosti promatrane tvrtke, a krajnji cilj je objektivno donošenje poslovnih odluka. U ovom radu obradit će se pokazatelji poslovanja koji se jednostavno i direktno dobivaju iz podataka koje sadrže financijski izvještaji. Korisnost i upotrebljivost pokazatelja ovise o točnosti financijskih izvještaja i predviđanju na temelju kojeg su sami pokazatelji izračunati.

Najvažniji financijski pokazatelji:

1. ***Pokazatelji likvidnosti***
   - Odnos aktive i pasive (tekući, brzi, radno raspoloživi kapital)
   - Pretvaranje aktive u novac (broj obrtaja zaliha, prosječno vrijeme naplate potraživanja)

   Pokazatelji likvidnosti služe za procjenu sposobnosti tvrtke da kratkoročne obveze podmiruje kratkoročnom imovinom. Likvidnost poduzeća je optimalna kada okretaj obrtnih sredstava omogućuje nabavu, proizvodnju i prodaju bez zastoja i u planiranom vremenskom periodu i obujmu. Ako poduzeće nije likvidno tada posluje s poteškoćama, te nema dovoljno sredstava za nabavu sirovina, materijala, za isplatu plaća, plaćanje poreza itd.

2. ***Pokazatelji profitabilnosti***
   - Profitna marža (bruto, operativna, prije oporezivanja, neto i neto preostalog profita)

[17] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.55

- Povrat na investirano (ukupnu imovinu, uloženi dugoročni kapital, dionički kapital)

Pokazatelji profitabilnosti daju odgovor na djelotvornost poslovne politike i uprave koja je dužna tu politiku provoditi i osigurati stabilan rast i razvoj poduzeća. Niska profitabilnost ukazuje na propast tvrtke u budućnosti.

3. Pokazatelji zaduženosti

- Koeficijent zaduženosti
- Koeficijent vlastitog financiranja
- Koeficijent mogućeg zaduživanja
- Pokriće kamata

Ovi pokazatelji mjere odnos vlastitih i pozajmljenih sredstava tj. koliko se poduzeće financira iz tuđih sredstava. Koriste se za procjenu financijskog rizika tvrtke.

4. Pokazatelji aktivnosti (efikasnosti)

- Koeficijent obrtaja (ukupne imovine, tekuće imovine, dugotrajne imovine, utrživosti zaliha i neto potraživanja)

Pokazatelji efikasnosti koriste se pri ocjenjivanju djelotvornosti kojom menadžment angažira imovinu poduzeća. Upućuju na brzinu cirkulacije imovine u poslovnom procesu, a računaju se na temelju odnosa prometa i prosječnog stanja.

5. Pokazatelji ekonomičnosti

- Ekonomičnost (ukupnog poslovanja, poslovanja, financiranja i izvanrednih aktivnosti)

Ekonomičnost ukupnog poslovanja utvrđuje se stavljanjem u odnos ukupnih prihoda i ukupnih rashoda.

Ekonomičnost poslovanja izračunava se stavljanjem u odnos prihoda od prodaje i rashoda od prodaje. Kada su prihodi od prodaje i rashodi od prodaje dani u pozitivnim veličinama tada je ekonomičnost poslovanja pozitivna.

Ekonomičnost financiranja je odnos financijskih prihoda i financijskih rashoda.

Ekonomičnost izvanrednih aktivnosti izračunava se stavljanjem u odnos izvanrednih prihoda i izvanrednih rashoda.

Ukoliko je vrijednost pokazatelja ekonomičnosti manja od 1 poduzeće tada posluje s gubitkom.

6. ***Pokazatelji investiranja***

- Dobit po dionici
- Dividenda po dionici
- Ukupna rentabilnost dionice
- Dividendna rentabilnost dionice

Pokazatelji investiranja služe za mjerenje uspješnosti ulaganja u obične dionice poduzeća. Za njihovo izračunavanje potrebni su podaci iz financijskih izvještaja i podaci o dionicama.

Da bi se pokazateljima odredila vrijednost za ocjenu boniteta potrebno ih je najprije usporediti sa standardiziranim vrijednostima. Financijski pokazatelji se računaju iz temeljnih financijskih izvještaja, a to su:[18]

- Bilanca
- Račun dobiti i gubitka
- Izvješće o novčanom toku
- Bilješke uz financijske izvještaje

1. ***Bilanca***

Bilanca je sustavni prikaz imovine, kapitala i obveza gospodarskog subjekta na dan bilanciranja (najčešće 31. prosinca).[19] Ukazuje na financijsko stanje tvrtke na određeni datum.

Bilanca je podijeljena na aktivu i pasivu. U aktivi se nalazi imovina, a u pasivi kapital i obveze. Ukupna aktiva uvijek mora biti jednaka ukupnoj pasivi. Aktive hrvatskih bilanci sastavljene su prema načelu rastuće likvidnosti i kreću od dugotrajne prema kratkotrajnoj imovini, gdje je najlikvidnija stavka novac. U pasivi se polazi od vlastitog kapitala, preko dugoročnih do kratkoročnih obveza.

[18] Analiza financijskih izvještaja. 52.str

[19] Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I.(2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb, str.52

Tablica 1: Shema bilance u Republici Hrvatskoj

	AKTIVA		PASIVA
A	POTRAŽIVANJA ZA UPISANI, A NEUPLAĆENI KAPITAL	A	KAPITAL I REZERVE
B	DUGOTRAJNA IMOVINA	B	DUGOROČNA REZERVIRANJA ZA RIZIKE I TROŠKOVE
	1. Nematerijalna imovina	C	DUGOROČNE OBVEZE
	2. Materijalna imovina	D	KRATKOROČNE OBVEZE
	3. Financijska imovina	E	ODGOĐENO PLAĆANJE TROŠKOVA I NEDOSPJELA NAPLATA PRIHODA
	4. Potraživanja		
C	KRATKOTRAJNA IMOVINA		
	1. Zalihe		
	2. Potraživanja		
	3. financijska imovina		
	4. novac		
D	PLAĆENI TROŠKOVI BUDUĆEG RAZDOBLJA I NEDOSPJELA NAPLATA PRIHODA		
E	GUBITAK IZNAD VISINE KAPITALA		

Izvor : Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.66

Zaključno možemo reći da dobra poduzeća imaju dobru, a loša – lošu bilancu. Kroz slike u nastavku objasnit će se njihova razlika te omjeri koji su lako uočljivi a služe za brzu ocjenu potencijalnog poslovnog partnera.



Slika 1. „dobra bilanca“

Izvor: web poslovni info : (http://www.poslovni-info.eu/sadrzaj/menadzment/ocjenite-poslovanje-pomocu-bilance/)

„ Dobra “ bilanca je bilanca poduzeća koje dobro posluje, ostvaruje dobit, te je solventno. Takvo društvo ima dobru strukturu i odnos dugotrajne i kratkotrajne imovine, ima na raspolaganju dovoljno zaliha, novca i druge kratkotrajne imovine, te ima dovoljno dugoročnih izvora za financiranje imovine.

Iz slike 1. je vidljivo da su vlastiti kapital i dugoročne obveze veće od dugotrajne imovine, pa se sva dugotrajna i dio kratkotrajne aktive financiraju iz dugoročnih izvora.



Slika 2. „još bolja bilanca“

Izvor: web poslovni info : (http://www.poslovni-info.eu/sadrzaj/menadzment/ocjenite-poslovanje-pomocu-bilance/)

Na slici 2. vidimo „još bolju bilancu“ od one sa prethodne slike iz razloga što je vrijednost vlastitog kapitala veća od vrijednosti dugotrajne imovine. Što poduzeće raspolaže s više vlastitog kapitala, to je financijski stabilnije, jer ima manji trošak kamata i niže ulazne cijene.



Slika 3. „loša bilanca“

Izvor: web poslovni info : (http://www.poslovni-info.eu/sadrzaj/menadzment/ocjenite-poslovanje-pomocu-bilance/)

„Lošu“ bilancu imaju poduzeća s poteškoćama u poslovanju. Dolazi do nedostatka dugoročnih izvora za financiranje dugotrajne aktive, pa se kratkotrajna imovina i dio dugotrajne financira iz kratkoročnih izvora. Takvo poduzeće stalno kasni s plaćanjem obveza i financira svoju imovinu kratkoročnim obvezama. Kašnjenje plaćanja dobavljačima i kreditorima može uz povećane troškove rezultirati blokadom žiro računa, pa čak i stečajem.

2. *Račun dobiti i gubitka*

Račun dobiti i gubitka je financijski izvještaj koji pokazuje uspješnost poslovanja poduzeća kroz određeno vremensko razdoblje.[20] Sadrži prikaz svih prihoda i rashoda, te ostvarenog financijskog rezultata u određenom obračunskom razdoblju. Daje nam odgovor na pitanje je li poduzeće ostvarilo svoj financijski cilj – profitabilnost.

Prihodi se dijele na:[21]

- Poslovne prihode
- Prihode od financiranja i
- Izvanredne prihode.

Prihodi su vrijednost prodanih dobara i usluga koje su iskazane kroz obračunsko razdoblje. Njihovim povećanjem utječe se na povećanje kapitala.

U ***poslovne prihode*** spadaju: prihodi od prodaje proizvoda i usluga, prihodi od prodaje robe, prihodi od ukidanja dugoročnih rezerviranja, prihodi od kompenzacija, subvencija, dotacija i sl.

Financijske prihode dijelimo na: prihode od udjela u dobiti, prihode od dividendi, prihode od kamata, prihode od tečajnih razlika, te dobitke od prodaje dionica i poslovnih udjela.

Izvanredni prihodi ne pojavljuju se redovito, kao na primjer: prihodi od prodaje dugotrajne imovine, sirovina i materijala, rezervnih dijelova i sitnog inventara, viškovi, prihodi od naplaćenih prethodno otpisanih potraživanja i ostali izvanredni prihodi.

[20] Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I.(2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb, str.75
[21] Jelavić, Ravlić, P., Starčević, A., i Samanović, J.(1993); Ekonomika poduzeća, Ekonomski fakultet Zagreb, Zagreb, str.304

Rashodi se dijele na:[22]

- Poslovne rashode
- Financijske rashode i
- Izvanredne rashode.

Rashodi su troškovi sadržani u prodanim proizvodima i uslugama. Dovode do smanjivanja kapitala.

Poslovni rashodi nastaju kao posljedica obavljanja glavne djelatnosti poduzeća. U njih spadaju troškovi nabave prodane robe i troškovi poslovanja u razdoblju (sirovine, materijali, rezervni dijelovi, energija, plaće, porezi, amortizacija…).

Financijski rashodi nastaju kao posljedica korištenja tuđeg novca, kao što su : kamate na kredite, negativne tečajne razlike, vrijednosna usklađivanja financijske imovine, gubici od prodaje dionica, poslovnih udjela i financijske imovine.

U ***izvanredne rashode*** spadaju: manjkovi, vrijednosna usklađivanja (dugotrajne materijalne i nematerijalne imovine, proizvodnje u tijeku) i ispravci potraživanja od kupaca.

DOBIT

- Dobit prije oporezivanja (bruto dobit) predstavlja pozitivnu razliku između prihoda i rashoda

DOBIT PRIJE OPOREZIVANJA =PRIHODI – RASHODI

- Dobit nakon oporezivanja (neto dobit)

DOBIT NAKON OPOREZIVANJA = BRUTO DOBIT – POREZ NA DOBIT

GUBITAK

- Računovodstveni gubitak je negativna razlika između prihoda i rashoda. Nastaje kada su prihodi u određenom vremenskom razdoblju manji od rashoda tog razdoblja.

[22]Jelavić, Ravlić, P., Starčević, A., i Samanović, J.(1993); Ekonomika poduzeća, Ekonomski fakultet Zagreb, Zagreb, str.302

Tablica 2: Shema računa dobiti i gubitka u Republici Hrvatskoj

	Poduzeće „X“ RAČUN DOBITI I GUBITKA Za razdoblje 1.1.-31.12.20x1.
I.	PRIHOD OD PRODAJE
II.	RASHODI PRODAJE
	a) Promjena vrijednosti zaliha
	b) Troškovi poslovanja
	1. Troškovi sirovina
	2. Troškovi usluga
	3. Troškovi plaća
	4. Troškovi amortizacije
	5. Ostali troškovi
III.	FINANCIJSKI PRIHODI
IV.	FINANCIJSKI RASHODI
V.	UKUPNO REDOVNI PRIHODI (I + III)
VI.	UKUPNO REDOVNI RASHODI (II + IV)
VII.	DOBIT IZ REDOVITOG POSLOVANJA
VIII.	IZVANREDNI PRIHODI
IX.	IZVANREDNI RASHODI
X.	DOBIT OD IZVANREDNIH AKTIVNOSTI
XI.	BRUTO DOBIT
XII.	POREZ NA DOBIT
XIII.	NETO DOBIT

Izvor: Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.80

3. Izvješće o novčanom toku

Izvješće o novčanom toku daje informacije o izvorima i upotrebi gotovine tijekom izvještajnog razdoblja, ali predstavlja i osnovu za planiranje budućih gotovinskih tijekova i potreba za financiranjem.[23]

Priljevi : povećanje obveza, povećanje kapitala i smanjenje nenovčane imovine.[24]

Odljevi: smanjenje obveza, smanjenje kapitala i povećanje nenovčane imovine.[25]

Novčani tokovi se prema aktivnostima dijele na:[26]

- Poslovne aktivnosti
- Investicijske aktivnosti i
- Financijske aktivnosti.

Poslovne aktivnosti su glavne aktivnosti poduzeća koje stvaraju prihod i imaju najveći utjecaj na financijski rezultat poduzeća. Kao primjere navesti ćemo novčane primitke od prodaje robe, novčane primitke od naknada, novčane izdatke dobavljačima, novčane izdatke zaposlenima, novčane izdatke za premije osiguranja itd.

Investicijske aktivnosti rezultat su investiranja i dezinvestiranja u realnu imovinu, te dugoročnog investiranja i dezinvestiranja u financijsku imovinu. Primjeri: novčani primici od prodaje opreme, novčani primici od povrata danih kredita, novčani izdaci za nabavu nekretnina, novčani izdaci po osnovi kredita danih drugima, novčani izdaci zbog povećanja dugotrajnih potraživanja.

Financijske aktivnosti su aktivnosti vezane uz financiranje poslovanja. Obuhvaćaju promjene vezane uz strukturu obveza i kapitala: novčani primici od emisije dionica i obveznica, novčani izdaci za otkup vlastitih dionica, dividendi, kamata itd.

[23] Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I.(2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb, str.83
[24] Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.82
[25] Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.82
[26] Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I.(2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb, str.84

Tablica 3: Izvještaj o novčanom toku (direktna metoda)

	IZVJEŠTAJ O NOVČANOM TOKU za razdoblje 1.1.-31.12.20x1.
A	POSLOVNE AKTIVNOSTI
	1. Primici iz poslovnih aktivnosti
	2. Izdaci iz poslovnih aktivnosti
	3. Neto novčani tok iz poslovnih aktivnosti
B	INVESTICIJSKE AKTIVNOSTI
	1. Primici iz investicijskih aktivnosti
	2. Izdaci iz investicijskih aktivnosti
	3. Neto novčani tok iz investicijskih aktivnosti
C	FINANCIJSKE AKTIVNOSTI
	1. Primici iz financijskih aktivnosti
	2. Izdaci iz financijskih aktivnosti
	3. Neto novčani tok iz financijskih aktivnosti
D	UKUPNO NETO NOVČANI TOK (A+B+C)
E	NOVAC NA POČETKU RAZDOBLJA
F	NOVAC NA KRAJU RAZDOBLJA

Izvor: Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.86

4. Bilješke uz financijske izvještaje

Bilješke uz financijske izvještaje sastavljaju svi poduzetnici i dostavljaju ovlaštenim institucijama. Izrađuju se prema podacima iz ostalih financijskih izvještaja. One čine sastavni dio temeljnih financijskih izvještaja čija je obveza sastavljanja i prezentiranja utvrđena Zakonom o računovodstvu. Prezentiraju računovodstvene politike koje su korištene pri izradi samih financijskih izvještaja te daju dopunu i razradu podataka koje sadrže bilanca i račun dobiti i gubitka.[27]

U bilješkama se opisuju metode koje su korištene, a koje su utjecale na financijski rezultat poslovanja. Sadržaj i oblik bilješki nije propisan, pa se ovisno o specifičnostima poslovanja pojedinog trgovačkog društva procjenjuje koje informacije treba obuhvatiti dodatnim objašnjenjima. Smjernice za sadržaj bilješki daju računovodstveni standardi.

Svode se na dvije osnovne grupe bilješki:[28] prva grupa objašnjava računovodstvene politike koje su korištene u izradi izvješća, a druga obuhvaća sve ostale podatke koji su važni za razumijevanje izvješća. O podacima koji će biti prezentirani u bilješkama, njihovoj potpunosti, točnosti i razumljivosti odlučuje predsjednik upravnog odbora.

[27] Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I.(2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb, str.101

[28] Žager, K., Mamić-Sačer, I., Sever, S. i Žager, L.(2008); Analiza financijskih izvještaja, Masmedia, Zagreb, str.89

2.6. Procjena boniteta u Republici Hrvatskoj

U Republici Hrvatskoj izvješća o bonitetu izrađuju Hrvatska gospodarska komora, financijska agencija FINA i razne privatne agencije. Bonitetna izvješća se izrađuju na temelju podataka dobivenih od poduzeća za koje se izrađuje bonitet (putem upitnika), podataka iz Registra gospodarskih subjekata, podataka iz Sudskog registra te niza drugih informacija koje prikupi sam istražitelj.

Hrvatska gospodarska komora izrađuje bonitetna izvješća, a koristi ih poduzeće-naručitelj kojemu koriste kao podloga za donošenje poslovnih odluka, te nisu za daljnju distribuciju. Hrvatska gospodarska komora ne snosi nikakvu odgovornost za posljedice proizašle iz donesenih poslovnih odluka na temelju bonitetnog izvješća.

Bonitetno izvješće koje izrađuje Hrvatska gospodarska komora sadrži :[29]

1. Opće podatke o poduzeću (naziv, sjedište, komunikacije)
2. Broj i strukturu zaposlenih
3. Podatke o organima društva (Uprava, Nadzorni odbor, Glavna skupština)
4. Podatke o temeljnom kapitalu društva (dionice i njihova struktura)
5. Povijest tvrtke
6. Podružnice
7. Udjele društva u drugim poduzećima i udruživanje društva s drugim društvima
8. Inozemna poduzeća u sastavu društva
9. Strukturu proizvoda i usluga
10. Strukturu kupaca i dobavljača
11. Podatke o konkurentima
12. Uvoz – izvoz
13. Rezultate poslovanja u protekle tri godine (bilanca, račun dobiti i gubitka)
14. Podatke o revizoru
15. Podatke o poslovnim bankama
16. Rokove podmirenja obveza
17. Financijske pokazatelje
18. Ocjenu financijske situacije i kulture plaćanja
19. Procjenu maksimalne vrijednosti kredita

[29] Hrvatska gospodarska komora web (http://www.hgk.hr/)

FINA (financijska agencija) je vodeća hrvatska tvrtka na području financijskog posredovanja. U državnom je vlasništvu, ali posluje isključivo na tržišnom principu. Bavi se raznim poslovima, među kojima je i izdavanje bonitetnih izvještaja u obliku obrazaca BON-1, BON-2 i BONPLUS.[30] Podatke o bonitetu korisnik je dužan čuvati kao poslovnu tajnu.

- **BON – 1 :**

  je obrazac koji se izrađuje na temelju godišnjih izvješća poduzeća. Sadrži opće podatke o poduzetniku, podatke i pokazatelje o njegovu poslovanju u protekle dvije godine, kretanje broja zaposlenih i njihove prosječne plaće, stanje novčanih sredstava tijekom protekle godine, rang tvrtke u razredu i objašnjenja navedenih pokazatelja.[31]
  Njegova prednost je u tome što se pokazatelji analiziranog društva mogu uspoređivati sa pokazateljima ostalih društava iz iste djelatnosti, a nedostatak što ne daje jednu sumarnu ocjenu o vjerojatnosti da društvo može završiti u stečaju.
  Informacija BON – 1 ažurira se krajem travnja prema podacima iz godišnjih financijskih izvještaja poduzetnika za prethodnu godinu, te nakon isteka svakog kvartala za one poduzetnike koji su podnijeli tromjesečni izvještaj.

  Informacija BON-1 sadrži četiri skupine pokazatelja:

  1. Osnovni rezultati poslovanja
  2. Pokazatelji stabilnosti i zaduženosti
  3. Pokazatelji likvidnosti i brzine obrtaja
  4. Pokazatelji uspješnosti

  Prva skupina pokazatelja podrazumijeva osnovne rezultate poslovanja tj. stanje imovine, kapital i rezerve, ukupni prihod, ukupni rashod, te dobitak odnosno gubitak nakon oporezivana. Za procjenu boniteta od ključne je važnosti rezultat poslovanja (dobitak ili gubitak).

  U drugu skupinu pokazatelja spadaju: koeficijent financijske stabilnosti, stupanj samofinanciranja i faktor zaduženosti. Ova skupina pokazatelja pokazuje sposobnost poduzeća da podmiruje svoje kratkoročne i dugoročne obveze.

[30] Financijska agencija – FINA web (http://www.fina.hr)
[31] Financijska agencija – FINA web (http://www.fina.hr/Default.aspx?sec=1278)

- $koeficijent\ financijske\ stabilnosti = \frac{Dugotrajna\ imovina}{Kapital+Dugoročne\ obveze}$ (1)

Idealna iskustvena vrijednost ovog koeficijenta bi trebala iznositi 1. Ako je vrijednost manja od 1 znači da se iz dijela dugoročnih izvora financira kratkotrajna imovina, što znači da je financijska stabilnost tvrtke slaba, pa je i velika vjerojatnost da tvrtka ne može vratiti dugove i podmiriti ostale obveze. Ako je vrijednost veća od 1 tada je dugotrajna imovina financirana iz kratkoročnih obveza.

- $stupanj\ samofinanciranja = \frac{Vlastiti\ kapital}{Ukupna\ imovina}$ (2)

Ovaj pokazatelj govori o tome koliko je imovine financirano iz vlastitog kapitala. Što je pokazatelj veći to je rizik poslovanja s tom tvrtkom manji. Njegova vrijednost bi trebala biti veća od 50%.

- $faktor\ zaduženosti\ (broj\ godina) = \frac{Ukupne\ obveze}{Dobitak+amortizacija}$ (3)

Faktor zaduženosti pokazuje broj godina potrebnih za pokriće postojećih obveza, ako se poslovanje nastavi u jednakim uvjetima. Ovaj pokazatelj bi trebao iznositi 5 godina ili manje, jer će u protivnom tvrtka imati problema sa podmirivanjem svojih obveza.

Treću skupinu čine pokazatelji likvidnosti i brzine obrtaja (koeficijent ubrzane likvidnosti, koeficijent opće likvidnosti, koeficijent obrtaja ukupne imovine, vrijeme naplate kratkotrajnih potraživanja i vezivanje zaliha). Poduzeća u svom poslovanju teže očuvanju likvidnosti odnosno sposobnosti da pravovremeno podmiruju svoje obveze.

- $koeficijent\ ubrzane\ likvidnosti = \frac{Kratkotrajna\ imovina-Zalihe}{Kratkoročne\ obveze}$ (4)

Koeficijent ubrzane likvidnosti pokazuje ima li poduzeće dovoljno kratkoročnih sredstava da podmiri dospjele obveze, a bez prodaje zaliha. Idealna iskustvena vrijednost je 1, jer je tada kratkotrajna imovina jednaka kratkoročnim obvezama. Preporučena minimalna vrijednost je 0.9 jer sve ispod te vrijednosti nas upozorava da može doći do zastoja u plaćanjima, jer su kratkoročne obveze veće od kratkotrajne imovine.

- $koeficijent\ opće\ likvidnosti = \frac{Kratkotrajna\ imovina}{Kratkoročne\ obveze}$ (5)

Mjeri sposobnost poduzeća da podmiri svoje kratkoročne obveze. U odnos stavlja pokriće i potrebe za kapitalom u roku od godine dana. Treba ga usporediti sa pokazateljem opće likvidnosti drugih poduzeća u istoj grani industrije. Ukoliko iznosi 2 velika je vjerojatnost da se sve tekuće obveze podmire na vrijeme, a ako je manji od 2 tada je velika vjerojatnost da poduzeće neće moći izvršiti plaćanja.

- $koeficijent\ obrtaja\ ukupne\ imovine = \frac{Ukupni\ prihod}{Ukupna\ imovina}$ (6)

Ovaj pokazatelj pokazuje koliko se puta ukupna imovina poduzeća obrne u tijeku jedne godine odnosno koliko poduzeće uspješno koristi imovinu s ciljem stvaranja prihoda.

- $vrijeme\ naplate\ kratkotrajnih\ potraživanja = \frac{Kratkoročna\ potraživanja}{ukupno\ naplaćena\ kra.pot\ .tijekom\ 365\ dana}$ (7)

Vrijeme naplate kratkoročnih potraživanja nam pokazuje broj dana potrebnih za naplatu kratkoročnih potraživanja tj. brzinu priljeva gotovine. Vrijednost mora biti što manja, jer to znači da tvrtka brže dolazi do gotovine.

- $dani\ vezivanja\ zaliha = \frac{trenutno\ stanje\ zaliha}{prosječni\ dnevni\ trošak\ prodanih\ dobara}$ (8)
- $prosječni\ dnevni\ trošak\ prodanih\ dobara = \frac{godišnji\ trošak\ prodanih\ dobara}{365}$ (9)

Ovaj pokazatelj mjeri vrijeme potrebno da se jedna kuna potrošena za nabavu zaliha pretvori u jednu kunu sadržanu u prihodima od prodaje ili potraživanjima. Poželjna je što niža vrijednost pokazatelja. Što je prosječno vrijeme investiranja u zalihe duže to su potrebne veće investicije u zalihe, što onda ostavlja manje novčanih sredstava za investiranje u druge svrhe.

U zadnju skupinu spadaju pokazatelji poslovne uspješnosti, a to su: odnos ukupnog prihoda i rashoda, udio dobiti u ukupnom prihodu, udio dobiti u imovini i dobit po zaposlenom.

- $odnos\ ukupnog\ prihoda\ i\ rashoda = \frac{ukupni\ prihod}{ukupni\ rashod}$ (10)

Potrebno je da društvo posluje ekonomično tj. da ostvaruje više prihoda nego rashoda.

- $udio\ dobiti\ u\ ukupnom\ prihodu = \frac{dobitak\ nakon\ oporezivanja}{ukupan\ prihod}$ (11)

Ovaj pokazatelj izražava se u postotcima. Govori o profitabilnosti poslovanja; što je udjel veći, to je veća i profitabilnost poslovanja poduzeća. Pokazuje koliki je postotak prihoda ostao tvrtki nakon odbitka poreza.

- $udio\ dobiti\ u\ imovini\ (stopa\ rentabilnosti\ imovine) = \frac{dobitak\ poslije\ oporezivanja}{ukupna\ imovina}$ (12)

Ovaj pokazatelj pokazuje koliki je dobitak ostvarila tvrtka, u odnosu na ono što je uloženo. Što je udjel veći, to je veća i rentabilnost poslovanja poduzeća.

- $dobit\ po\ zaposlenom$: je važan pokazatelj kada ga usporedimo sa ostvarenim iz usporedne godine ili sa ostvarenim u razredu; ako je vrijednost veća od vrijednosti s kojom je uspoređujemo tada se poduzeće smatra poslovno uspješnim.

Od navedenih pokazatelja najvažniji za procjenu boniteta su udio dobiti u ukupnom prihodu i udio dobiti u ukupnoj imovini.

U slučaju da nismo sigurni u bonitet poduzeća, potencijalnog poslovnog partnera, potražit ćemo dodatne informacije o tom poduzeću iz obrasca BON – 2.

- **BON – 2**

Obrazac BON2 sadrži sljedeće podatke: opće podatke o poslovnom subjektu, stanje sredstava na računu, ukupan iznos primitaka u korist računa u prethodnih 30 dana, prosječno stanje sredstava na računu u prethodnih 30 dana, iznos odobrenog okvirnoga kredita, iznos evidentiranih nepodmirenih obveza, broj dana neprekidne blokade računa i broj dana blokade računa u proteklih 6 mjeseci.

- **BONPLUS**

Bonitetna informacija BONPLUS je pogodna za prezentiranje vlastite financijske sposobnosti, ali isto tako i za procjenu financijske sposobnosti potencijalnog poslovnog partnera. Ona je proširena verzija bonitetne informacije te sadrži tri skupine podataka:

- Osnovne podatke o poduzetniku (podaci o poduzetniku, vlasništvu, djelatnosti poslovanja, osnivačima, nadzornom odboru, predmetu poslovanja i otvorenim računima za trajno poslovanje).
- Financijske informacije (imovina i izvori sredstava krajem poslovne godine, financijski rezultati i pokazatelji poslovanja).
- Ocjena financijskog rejtinga poduzeća.

Ocjena financijskog rejtinga predstavlja procjenu buduće sposobnosti poduzetnika da ispunjava svoje obveze u preuzetim rokovima. Iskazuje se ocjenom od 1 do 10 prema Fininoj rejting skali koja je prikazana u tablici 4.

Tablica 4:Skala ocjena rejtinga

Razred	Fitch	OPIS	Finina ocjena rejtinga
1	AAA AA+	Najviša kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima do 2,5%.	1
2	AA AA-	Vrlo visoka kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima 2,5% do 5,0%.	2
3	A+	Vrlo dobra kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima od 5 do 7,5%.	3
4	A A-	Solidna kvaliteta poslovanja, znatne promjene u okolnostima i okolini mogu oslabjeti poslovni subjekt, vjerojatnost zastoja u plaćanjima 7,5% do 10,0%.	4
5	BBB+ BBB	Prosječna kvaliteta poslovanja, ugroženo plaćanje kamata i dugova kod negativnog razvoja, prihvatljiv rizik, vjerojatnost zastoja u plaćanjima 10,0% do15,0%.	5
6	BBB-	Niža kvaliteta poslovanja, granično prihvatljiv rizik, vjerojatnost zastoja u plaćanjima 15,0% do 20,0%.	6
7	BB+	Nesigurnost poslovanja, potreban oprez, vjerojatnost zastoja u plaćanjima 20,0% do 25,0%.	7
8	BB BB-	Slaba kvaliteta poslovanja, visoka nesigurnost poslovne suradnje, vjerojatnost zastoja u plaćanjima 25,0% do 30,0%.	8
9	B+ B	Nesigurna kvaliteta poslovanja, vrlo visoka nesigurnost poslovne suradnje, vjerojatnost zastoja u plaćanjima 30,0% do 35,0%.	9
10	-	Otežano ispunjavanje obveza, vjerojatnost zastoja u plaćanjima više od 35%.	10

Izvor: Financijska agencija – FINA web (http://www.fina.hr/Default.aspx?art=8786)

3. HOTELIJERSTVO

3.1. Pojam hotelijerstva

Ugostiteljstvo kao privredna djelatnost zadovoljava potrebe ljudi koje uglavnom proizlaze iz putovanja i boravka izvan mjesta stanovanja. Hotelijerstvo je važna gospodarska aktivnost koja se definira kao uži pojam od pojma ugostiteljstva.[32]

Hotelijerstvo je djelatnost koja se bavi pružanjem usluga smještaja, prehrane, točenja pića, prodaje trgovačke robe i rekreacije domicilnom stanovništvu, poslovnim ljudima i turistima u kategoriziranim smještajnim objektima.[33] To je gospodarska aktivnost pružanja usluga smještaja i drugih gore navedenih usluga koje se pružaju na hotelijerski način. Time se želi zadovoljiti potrebe i motive gostiju, a djelatnicima i menadžmentu osigurati životni standard.

Hotelijerstvo je dio globalnog poduzetništva nazvano jednim općim pojmom – turizam. Ono je vrlo važno za gospodarstvo neke države jer osigurava posao velikom broju ljudi na svijetu, kao i u Republici Hrvatskoj. Hotelijerstvo svojim aktivnostima povezuje sve gospodarske grane kao što su: promet, energetika, komunikacije, industriju prehrambenih i industrijskih roba, te ljude i usluge. [34]

Karakteristike usluga koje se pružaju u hotelijerstvu:

- Nedodirljivost usluga: hotelijeri pokušavaju stvoriti zaokružen sustav pružanja svih usluga u hotelijerstvu, kako bi ih mogli standardizirati i izmjeriti njihovu kvalitetu.
- Istovremenost proizvodnje i konzumiranja usluga: usluge u hotelijerstvu ne mogu se proizvesti i uskladištiti, a onda kada gost dođe pružiti ih kao što se to odvija u proizvodnim organizacijama.
- Sudjelovanje gosta u proizvodno-uslužnom procesu: u današnje vrijeme postoje komunikacijsko-informacijski sustavi koji omogućuju gostu da sam kreira usluge koje želi koristiti.
- Raznovrsnost usluga: svaka usluga je individualizirana za svakog pojedinca.

[32] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.68
[33] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.67
[34] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.68

- Prolaznost usluga: usluge koje se pružaju u hotelijerstvu se brzo „troše“ zbog izbirljivih gostiju koji su sklonu izmišljanju novih zahtjeva koje hotelijeri moraju zadovoljiti.
- Odnos povjerenja hotelijera i gosta: glavni cilj hotelijera je da kvalitetnim odvijanjem proizvodno-uslužnog procesa izgradi odnos povjerenja i lojalnosti prema gostu.

U skupinu hoteli, osim samih hotela spadaju:[35]

- Aparthoteli – smještajni objekti u kojima se gostima pružaju usluge smještaja i doručka.
- Turistička naselja – funkcionalne cjeline koje čine više samostalnih građevina za razne namjene, kao što su recepcija, smještaj gostiju, prehrana i slično.
- Turistički apartmani – smještajni objekti u kojima se gostima obavezno pružaju usluge smještaja u smještajnim jedinicama koje su opremljene tako da gost može pripremati jela.
- Pansioni – smještajni objekti u kojima se gostima pružaju usluge smještaja s prehranom.
- Guest house – smještajni objekt u kojemu se gostima pružaju usluge smještaja s prehranom, a mogu se pružati i druge ugostiteljske usluge.

Ostali ugostiteljski objekti za smještaj kao što su kamp, apartman, kuća za odmor, soba za iznajmljivanje, prenoćište, odmaralište i omladinski hotel, ne smatraju se hotelijerstvom nego ugostiteljstvom za pružanje usluga smještaja u ostalim ugostiteljskim objektima za smještaj.

[35] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.68 i 69

HOTEL

Hotel je smještajni i ugostiteljski objekt u kojem se gostima pružaju usluge smještaja i doručka, a mogu se pružati i druge ugostiteljske usluge. [36]

Riječ hotel potiče od francuske riječi „***hote***“ koja znači gost, a izvedena je iz latinske riječi „hospitalis“ koja znači gostinjski.[37] Definicije hotela mogu biti različite, a zajedničko im je da hotel svojim gostima mora osigurati korisne i efikasne usluge, te ugodan boravak.

Temeljne značajke hotela prema hrvatskom zakonodavstvu su slijedeće:[38]

- da je to kategorizirani ugostiteljski objekt,
- da je to ugostiteljski objekt s najmanje 10 soba,
- da se u hotelu gostima izdaju sobe ili hotelski apartmani,
- da se u hotelu pružaju usluge smještaja i doručka (+ostale usluge),
- da pruža punu udobnost (položaj, izgled, uređenje, oprema i usluge).

Hotel mora pružati i razne vrste ugodnosti (ugodnost topline i mirisa, te tehnička i ekonomska ugodnost) koje su osnovni elementi za uspješno vođenje hotela.

Ugodnost topline predstavlja osjećaj ugode koji se ostvaruje klimatizacijom, odnosno grijanjem i hlađenjem. Na ugodnost topline utječu i aktivnosti gostiju u različitim dijelovima hotela (fitness, noćni klub itd.), te način na koji su gosti odjeveni.

Ugodnost mirisa predstavlja uvjerenje gosta da će cijelo vrijeme udisati najkvalitetniji zrak. Ona je povezana s ugodnošću topline.

Tehnička ugodnost je lako i jednostavno korištenje tehničke opreme hotela.

Ekonomska ugodnost je zadovoljstvo koje je posljedica osiguranih gore navedenih ugodnosti (topline, mirisa i tehnike) uz najmanji mogući trošak.

[36] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.70
[37] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.69
[38] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.70

Tablica 5: Pregled tipova hotela prema različitim kriterijima razvrstavanja

	Kriterij	Vrsta / tip hotela	Obilježje	
I)	Veličina	• mali • srednji • veliki	• do 100 kreveta • do 300 kreveta • preko 300 kreveta	ako su pansionski
		• mali • srednji • veliki	• do 150 kreveta • do 400 kreveta • preko 400 kreveta	ako su prolazni
II)	Cjelovitost pružene usluge	• pansionski • garni • prolazni	• smještaj + 3 obroka • smještaj + doručak • smještaj	
III)	Kontinuitet poslovanja	• stalni • sezonski	• cjelogodišnje poslovanje • sezonsko poslovanje	
IV)	Lokacija	• odmarališni • stanični • aerodromski • gradski • usputni	• na moru, planini, toplicama • uz autobusne, željezničke postaje • uz aerodrome • u užem središtu grada • uz velike prometnice	
V)	Globalna tržišna usmjerenost	• turistički • poslovni • športski	• stacionirani boravak gostiju • seminari,	

		• gradski	kongresi • športski sadržaji • raznovrsna tržišna usmjerenost	

Izvor: Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.71

U Hrvatskoj hoteli se kategoriziraju u četiri kategorije, a kategorije se označavaju brojem zvjezdica kao što je prikazano u Tablici 6.

Tablica 6: Pregled kategorija hotela u RH

Kategorija	Broj zvjezdica
I.	*****
II.	****
III.	***
IV.	**

izvor: „Pravilnik o razvrstavanju, kategorizaciji, posebnim standardima i posebnoj kvaliteti smještajnih objekata iz skupine hoteli „ , NN, br.48/2002., članak 59

Hotelska usluga je skup usluga kojima se gostu ispunjavaju njegove potrebe (smještaj, hrana i piće i ostale usluge). Hotelske usluge dijele se na:[39]

1. OSNOVNE HOTELSKE USLUGE
   a) Usluga smještaja
   b) Usluge prehrane i pića
2. OSTALE HOTELSKE USLUGE
   a) Sve usluge koje gost koristi, kao što su : pomoćni krevet u sobi, garaža, pranje rublja, čuvanje vrijednih stvari, telefon, te ostale evidentirane i naplaćene usluge.

[39] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.73

b) Sve usluge koje nisu nigdje evidentirane, gost ih je koristio, ali ih nije posebno platio već su dio neke druge usluge u kojoj su sadržane i plaćene (razne informacije, prijenos prtljage, usluge parkiranja, usluge dobrodošlice npr. piće dobrodošlice, programi animacije, usluge zabave, izložbe i još mnoge druge).

3.2.Povijesni razvoj hotelijerstva u Republici Hrvatskoj

Razvoj hotelijerstva u Republici Hrvatskoj prati razvoj turizma tijekom godina. Razvoj turizma podijelili smo u 6 faza:[40]

1. Prva faza
    - Razdoblje pojava sličnih turizmu.
    - Stari Rimljani koriste ljekovita svojstva mineralnih vrela, što u našim krajevima dovodi do organiziranja lječilišta, npr. Varaždinske i Krapinske toplice.
    - Turizam se na prostoru današnje Hrvatske počeo najprije razvijati u kontinentalnom dijelu.

2. Druga faza
    - Faza znatiželje (kraj 19. stoljeća).
    - Obilježja: prva iskazana znatiželja, prvi ugostiteljski objekti u lokalnom vlasništvu, razvoj jedriličarstva i parobrodarstva, začetak prvih turističkih mjesta, stvaranje prvih većih prostornih obalnih cjelina (rivijere- Opatijska, Crikvenička, Kaštelanska, Dubrovačka), dolazak stranog kapitala i izgradnja željezničke mreže.

3. Treća faza
    - Faza osvješćivanja (razdoblje od početka 20. stoljeća do kraja Prvog svjetskog rata).
    - Unatoč turbulentnim društveno – političkim zbivanjima, pojavljuju se zdravstveno - turistički centri na Jadranu, nastavlja se razvoj društvene turističke organizacije, a neka mjesta definiraju svoju viziju razvoja na razvoju turizma (Brijuni, Opatija, Crikvenica, Mali Lošinj).

4. Četvrta faza
    - Faza prvih postignuća (razdoblje između dva svjetska rata).
    - Obilježja: rast turističkog prometa, otvaranje mnogih smještajnih kapaciteta, unapređenje pravne regulative, inozemni turistički promet nadmašuje domaći.

[40] Vukonić, B. (2005); Povijest Hrvatskog turizma, Prometej, Zagreb, str.23 i 24

- Ključna promjena je zamjena zimske sezone u ljetnu kupališnu sezonu.

5. Peta faza
    - Faza intenzivnog turističkog razvoja (razdoblje nakon Drugog svjetskog rata).
    - Ova faza se dijeli na dvije etape: prva etapa razvoja (do 1965.g.) ,mijenjaju se načini upravljanja gospodarstvom, potiče se industrijalizacija zemlje pa turizam više nije u prvom planu, domaći turisti dobivaju brojne povlastice. Nakon ukidanja tih povlastica inozemni turistički promet zauzima većinu u ukupnom turističkom prometu. Nakon 1965.g. Hrvatska ulazi u drugu etapu intenzivnog razvoja koja se još naziva i „zlatnim dobom hrvatskog turizma". Ona traje do 1975.g. i tada turizam dobiva status strateškog pravca razvoja.
    - Hrvatski turizam vrhunac svog razvoja doseže u razdoblju od 1986.g. do 1988.

6. Šesta faza
    - Faza oporavka i konsolidacije turističkog života u Hrvatskoj (razdoblje od 1991. do početka 21.stoljeća).
    - Obilježja: privatizacija, restrukturiranje turističkog sustava, brojne privatizacijske afere koje su usporile Hrvatsku u hvatanju koraka s konkurencijom.
    - Osnovni problem i dalje ostaje nedefinirana vizija razvoja turizma.

Hrvatsko hotelijerstvo i njegov razvoj može se također podijeliti u 6 faza s obzirom na: razvoj turističke potražnje, oblik i strukturu kadrova i menadžmenta, arhitekturu i urbanizam, društveno političko uređenje, sociološke odnose u društvu, gospodarski razvoj društva, komunalno infrastrukturalne razine opremljenosti te prometnu povezanost.[41] Faze razvoja hotelijerstva u RH, njihova obilježja i godine prikazat ćemo u narednoj tablici. Zaključit ćemo da je hotel kao građevinski objekt kroz cijelu povijest bio pod raznim utjecajima kao što su trendovi u urbanizmu i arhitekturi, te se sam menadžment morao prilagođavati promjenama kako bi opstao na tržištu.

[41] Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.75

Tablica 7: Faze razvoja hotelijerstva u Hrvatskoj

Faze razvoja hotelijerstva u RH	Obilježja	Godine
PRVOBITNO HOTELIJERSTVO	• Prva masovna putovanja na hrvatskom prostoru. • Počeci izgradnje prvih vila, pansiona i objekata za odmor aristokracije.	• 1844.-1884. • 1844. prva Vila Angiolina Opatija • 1848. prvi hotel svratište na Hvaru • 1868. prvi hotel na Hvaru
ELITNO HOTELIJERSTVO	• Prvi hoteli sa jasno definiranim procesnim funkcijama, recepcijom, domaćinstvom i restoranom.	• 1884.-1914. • 1884. prvi suvremeni Hotel Quarnero Opatija
HOTELIJERSTVO IZMEĐU DVA SVJETSKA RATA	• Gradi se jako malo hotela.	• 1918.-1939. • 1925. Hotel Esplanade Zagreb
HOTELIJERSTVO POSLIJE II. SVJETSKOG RATA	• Period obnove i masovnijeg dolaska domaćih turista.	• 1945.-1966. • 1961. Viša ekonomska škola za ugostiteljstvo Opatija
RAZVIJENO TRŽIŠNO HOTELIJERSTVO	• Snažna kvantitativna izgradnja u hotelijerstvu duž cijele obale. • Prevladavaju hoteli B kategorije.	• 1966.-1990. • 1966. Hotel Ambasador Opatija
HRVATSKO HOTELIJERSTVO U	• Osnivanje samostalne države	• 1991.-danas • 1996. Hotel Zagreb

RESTRUKTURIRANJU	Hrvatske te nema izgradnje novih objekata, već rekonstrukcije, adaptacije, sanacije.	Sheraton Zagreb • 2000. Hotel Millenium Opatija

Izvor: Cerović, Z.(2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija, str.80

3.3.Procjena boniteta hotela

Procjena boniteta hotela vrši se na isti način kao i procjena boniteta bilo kojeg poduzeća.

Kod procjene boniteta hotelskih poduzeća postoje dvije vrste pokazatelja: kvantitativni i kvalitativni. Kvantitativni pokazatelji koji su potrebni za procjenu boniteta hotela su već prethodno navedeni u ovom radu, te su isti za sva poduzeća. Što se tiče kvalitativnih pokazatelja oni mogu biti razni kao npr. veličina, starost, lokacija, menadžment, zaposlenici, kvaliteta usluge, organizacijska struktura, organizacijska kultura, ugled itd.

Procjena boniteta hotela provodi se iz tri razloga. Prvi i osnovni razlog je da sama uprava hotela provodi procjenu boniteta kako bi pratila vlastito poslovanje. Upravu bi u svakom trenutku trebala zanimati financijska situacija poduzeća prvenstveno radi nadzora, ali i radi daljnjeg planiranja poslovanja i razvoja strategije.

Poslovni partneri isto tako procjenjuju bonitet hotela jer na taj način saznaju dali će s određenim poduzećem stupiti u poslovne odnose. Npr. banke prilikom davanja kredita rade detaljnu procjenu boniteta hotela kako bi bili sigurni da je poduzeće sposobno se svoje obveze izvršiti na vrijeme.

Potencijalni ulagači također procjenjuju bonitet hotela zbog smanjenja rizika priliko ulaganja u dugoročne vrijednosne papire. Ako hotel ima lošu ocjenu boniteta veći je rizik ulaganja, te postoji mogućnost bankrota.

4. METODE ZA VIŠEATRIBUTNO ODLUČIVANJE

Višekriterijalno odlučivanje (Multiple Criteria Decision Making – MCDM) je proces donošenja odluka uz postojanje mnogih, najčešće konfliktnih kriterija.[42] Situacija sa konfliktnim kriterijima ima napretek u svakodnevnom životu čovjeka, kao što je npr. kupovina nekog proizvoda. U tom slučaju najčešće se javljaju kriteriji maksimalne kvalitete i minimalne cijene što znači da kupac želi kupiti što kvalitetniji proizvod po što nižoj cijeni i tu dolazi do konflikta. Potrošač mora pronaći rješenje koje mu najviše odgovara. Osim svakodnevnih odluka nekog pojedinca, problemi kojima se bavi višekriterijalno odlučivanje se mogu pojaviti i u poslovnom kontekstu. To može biti vidljivo iz primjera u kojem proizvođači automobila moraju maksimizirati efikasnost potrošnje goriva i vozački komfor, minimizirati proizvodne troškove, itd.[43]

Zajedničke karakteristike tih problema su:

1. Višestrukost kriterija
   Svaki problem višekriterijalnog odlučivanja ima minimalno dva kriterija. Donosilac odluke mora izabrati relevantne kriterije kako bi donesena odluka bila kvalitetna.

2. Konflikti među kriterijima
   Izabrani kriteriji su najčešće u konfliktu (suprotnosti) kao što smo prikazali u gore navedenim primjerima.

3. Neusporedive mjerne jedinice
   Kriteriji najčešće imaju različite mjerne jedinice te ih zbog toga nismo u mogućnosti usporediti. Npr. kvaliteta nekog proizvoda je izražena opisno, a cijena tog istog proizvoda brojčano.

Osnovni razlozi sve većeg interesa za višekriterijalnim odlučivanjem su:

- Većina problema odlučivanja sadrži više kriterija.
- Izuzetan razvoj mogućnosti, brzine, kapaciteta i fleksibilnosti računskih strojeva.

[42] Babić, Z.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.27
[43] Babić, Z.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.27

- Važnu ulogu ima donosilac odluke – decision maker (kod jednokriterijalnih problema njegova uloga nije bitna, dok kod višekriterijalnih igra jako važnu ulogu i nijedna metoda ga ne može zamijeniti).

Problemi višekriterijalnog odlučivanja se mogu klasificirati u dvije kategorije:

1. Višekriterijalno programiranje ili višekriterijalno odlučivanje (Multiple Objective Decision Making) - služi za dizajniranje najbolje alternative.
2. Višeatributno odlučivanje (Multiple Attribute Decision Making) – koristi se za odabir najbolje alternative između konačnog broja alternativa.

4.1.Višekriterijalno odlučivanje

Višekriterijalno odlučivanje se bavi rješavanjem problema koji se sastoje od r kriterijalnih funkcija f_1(X), f_2(X), …, f_r(X) pri (r ≥ 2), gdje X predstavlja vektor varijabli odluke tj. X=$[x_1, x_2, \dots, x_n]$. Zadatak višekriterijalnog programiranja je maksimizirati sve zadane kriterije funkcije pri čemu vrijednosti svih varijabli odluke moraju pripadati skupu mogućih rješenja S tj. X ϵ S.

Problem maksimalizacije svih r funkcija cilja istovremeno, matematički se prikazuje na slijedeći način:

$Max\ f(X) = [f_1(\text{X}), f_2(\text{X}), \dots, f_r(\text{X})]$, X ϵ S

Ako su sve funkcije iz tog problema linearne, radi se o problemu višekriterijalnog linearnog programiranja:

$$Max \left[\sum_{j=1}^{n} c_{1j}\, x_j, \sum_{j=1}^{n} c_{2j}\, x_j, \dots, \sum_{j=1}^{n} c_{rj} x_j \right]$$

$$\sum_{j=1}^{n} a_{ij} x_j \le b_i, i = 1,2, \dots, m$$

$$x_j \ge 0, j = 1,2, \dots, n$$

Ili u matričnom obliku:

Max CX

$AX \leq B$

$X \geq 0$

gdje je C kriterijalna matrica, tj. matrica koeficijenata iz svih funkcija cilja, odnosno

$CX = (C^1X, C^2X, \ldots, C^rX)$ gdje su C^k redci matrice C.

- KRITERIJALNI SKUP

  Svakom elementu skupa mogućih rješenja, tj. svakom vektoru $X \in S$, pridružen je kriterijalni vektor f(X)

  $f(X) = [f_1(X), f_2(X), \ldots, f_r(X)]$

  Skup

  $$f(S) = \{f(X): X \in S\}$$

  nazivamo kriterijalni skup.

  To znači da je svakom elementu skupa S pridružen vektor čije su komponente vrijednosti funkcija cilja za to moguće rješenje. Na taj način smo dobili kriterijalni skup, odnosno skup točaka u jednom drugom vektorskom prostoru, čija je dimenzija jednaka broju funkcija cilja r.

- MARGINALNO RJEŠENJE

  Ako označimo maksimum svake komponente vektora f(X) na skupu mogućih rješenja sa

  Max $f_k(X) = f_k(x^{k^*}) = f_k^*$

  $X \in S$

  Vektor X^{k^*} predstavlja marginalno rješenje za funkciju cilja f_k, tj. taj je vektor optimalno rješenje jednokriterijalnog problema matematičkog programiranja sa funkcijom cilja f_k.

  Broj marginalnih rješenja odgovara broju funkcija cilja.

- IDEAL

  Vektor f* čija je k-ta komponenta optimalna vrijednost k-te funkcije cilja naziva se ideal.

- SAVRŠENO RJEŠENJE

  Rješenje X^S višekriterijalnog problema naziva se savršeno rješenje ako za njega sve funkcije cilja istovremeno postižu svoju maksimalnu vrijednost, odnosno

  X^S je savršeno rješenje ako je X ϵ S moguće rješenje, te ako je

  $f_i(X^S) \geq f_i(X)$ za i=1,2,…,r, i za svaki X ϵ S.

  Ako kriteriji nisu međusobno konfliktni, te ako postoji gore navedeno rješenje unutar skupa S tada je vrijednost funkcije cilja za takvo rješenje idealna točka (ideal). S obzirom da se u praksi takva situacija rijetko javlja zbog toga što su uglavnom barem dva kriterija konfliktna, savršeno rješenje najčešće ne postoji pa ga se naziva utopijskim rješenjem.

- EFIKASNO RJEŠENJE (NEDOMINIRANO RJEŠENJE, PARETO OPTIMALNO RJEŠENJE)

  Efikasno rješenje X^E problema višekriterijalnog programiranja je ono moguće rješenje X^E ϵ S za koje ne postoji neko drugo rješenje X ϵ S, takvo da je

  $f_i(X^E) \leq f_i$ (X) za sve i=1,2,…,r,

  i

  $f_i(X^E) < f_i$ (X) za neki i=1,2,…,r

  tj. ne postoji neko drugo moguće rješenje nad kojim dominira X^E. U drugoj nejednakosti je umjesto znaka "$<$ " mogao stati znak "$\neq$ ".

  Zaključno, efikasno rješenje problema višekriterijalnog odlučivanja je ono moguće rješenje za koje ne postoji neko drugo moguće rješenje koje je barem po jednom kriteriju bolje, a po ostalima nije gore od njega.[44]

[44] Babić, Z.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.266

Većinom postoji mnogo efikasnih rješenja, a donosilac odluke odlučuje se za jedno od njih. Donosilac odluke nam mora otkriti svoje preferencije kako bismo odredili koje je to rješenje. To se može postići i funkcijom korisnosti (utility function).
To je funkcija v(f(X)) koja pridružuje realan broj svakom X ϵ S, odnosno definira se novi problem koji više kriterija sadrži u implicitnom obliku:
Max v(f(X))
X ϵ S

Na takav način je višekriterijalni problem preveden u jednokriterijalni, te se dobiveno rješenje naziva najbolje kompromisno rješenje jer je ono kompromis između kriterija i ono je jedno od efikasnih rješenja.

Osnovni problem višekriterijalnog odlučivanja ima dva koraka:

1. Određivanje skupa svih efikasnih točaka.
2. Određivanje najboljeg kompromisnog rješenja iz skupa efikasnih točaka.

4.2.Višeatributno odlučivanje

Problem višeatributnog odlučivanja je karakterističan po tome što postoji ograničen (konačan, relativno malen) broj unaprijed određenih alternativa. Treba odrediti najbolju alternativu na temelju ocjena svih alternativa po više kriterija (atributa, svojstava). Do izbora najbolje alternative ili do poretka alternativa dolazi se usporedbom alternativa po svim kriterijima istovremeno. Klasifikacija metoda se vrši na temelju preferencija donosioca odluke. Najčešće spominjani pojmovi kod metoda i problema višeatributnog odlučivanja su kriteriji, atributi, ciljevi. Kriteriji su numeričke funkcije koje treba maksimizirati ili minimizirati, atributi su osobine ili svojstva pojedinih alternativa, a ciljevi su prethodno zadane vrijednosti koje želimo doseći. Ciljevi često predstavljaju ograničenja.

Jedan od osnovnih pojmova kod višeatributnog odlučivanja je matrica odluke. To je matrica tipa (m, n) čiji element X_{ij} određuje procjenu i-te alternative A_i u odnosu na j-ti kriterij X_j.

Matrica odluke izgleda na slijedeći način:

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

Alternativa A_i određena je i-tim retkom matrice D i daje ocjenu i-te alternative po svim kriterijima, a izgleda ovako:

$$A_i = \begin{bmatrix} x_{i1} & x_{i2} & \cdots & x_{in} \end{bmatrix}$$

Isto tako j-ti stupac matrice D pokazuje ocjene svih alternativa po j-tom atributu i prikazuje se na sljedeći način:

$$X_j = \begin{bmatrix} x_{1j} & x_{2j} & \cdots & x_{mj} \end{bmatrix}^T$$

4.3.Procjena važnosti kriterija

Višekriterijalno odlučivanje temelji se na većem broju kriterija koji su često u konfliktu i obično nisu jednako važni. Za većinu metoda višekriterijalnog odlučivanja potrebne su informacije o relativnoj važnosti svakog kriterija, Relativna važnost kriterija proizlazi iz preferencija donositelja odluke na koje utječe njegov vrijednosni sustav i ostale psihološke karakteristike. Kada donosilac odluke nije zadao težine kriterija, za ocjenjivanje stupnja važnosti kriterija postoji više metoda. To mogu biti metode kod kojih odluku donosi pojedinac ili metode kod kojih odluku donosi grupa. Članovi te grupe bi trebali biti eksperti iz razmatranog područja, te jedan odgovorni donositelj odluke.

U najpoznatije *grupne metode* spadaju : rangiranje, ocjenjivanje, metoda usporedbe po parovima i Delphi metoda.

Najpoznatije *metode za procjenu važnosti kriterija za individualnog donositelja odluke* su: ponderirana metoda najmanjih kvadrata, metoda entropije i metoda svojstvenog vektora koja će se koristiti u ovom radu.

Prednost grupnog donošenja odluka je širok spektar informacija, te unesena stručnost i iskustvo u analizi, a problemi koji postoje kod grupnog odlučivanja su slijedeći: potreban je dulji vremenski period nego kod individualnog donošenja odluka i dominacija autoritativnih pojedinaca koja može usmjeriti diskusiju u sasvim drugom smjeru.

4.3.1. Metoda svojstvenog vektora

U ovom radu procjena važnosti kriterija obavljat će se ***metodom svojstvenog vektora***.

Razvio ju je Thomas L. Saaty. Kod metode svojstvenog vektora donosilac odluke mora prosuditi relativne važnosti dvaju kriterija (tj. usporediti po važnosti sve moguće parove kriterija).

Broj procjena koje se traže od donosioca odluke jednak je:

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

gdje je n broj kriterija.

Ova metoda leži na pretpostavci da je donositelju odluke lakše procijeniti relativne važnosti za svaki par kriterija, nego odjednom odrediti težine ili rangirati sve kriterije zajedno. Donositelj odluke mora za svaki par kriterija (Xi, Xj) procijeniti njihovu relativnu važnost na način da se odluči za jednu od sljedećih tvrdnji:

a) Oba kriterija ima jednaku važnost.
b) Kriterij Xi je važniji od kriterija Xj.
c) Kriterij Xj je važniji od kriterija Xi.

Odabir jedne od ovih tvrdnji povlači za sobom i odgovarajuću kvantifikaciju omjera težina tih kriterija wi i wj na slijedeći način:

a) uzima se da je $a_{ij} = \frac{w_i}{w_j} = 1,$

b) uzima se da je $a_{ij} = \frac{w_i}{w_j} > 1,$

c) uzima se da je $a_{ij} = \frac{w_i}{w_j} < 1.$

Ako se odabere tvrdnja b) ili tvrdnja c) tada je moguće intenzitet preferencije u kojoj se mjeri koliko je jedan kriterij važniji od drugoga izraziti sa više stupnjeva. Saaty-eva skala važnosti prikazana je u slijedećoj tablici.

Tablica 8: Saatyeva skala važnosti i njen opis

INTENZITET VAŽNOSTI	DEFINICIJA	OBJAŠNJENJE
1	Jednaka važnost	Dva kriterija pridonose jednako danom cilju
3	Slaba preferencija jednoga 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.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str.74

Pomoću Saatyeve skale važnosti se određuju omjeri važnosti za sve parove kriterija i formira se matrica omjera važnosti A čiji su elementi upravo 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 pozitivne elemente i pored toga ona je recipročna matrica i za nju vrijedi slijedeće svojstvo:

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

Element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale jer vrijedi odnos

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

Drugo svojstvo koje bi moralo vrijediti za takvu matricu međusobnih usporedbi je da vrijedi relacija:

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

Slijedeći korak je izračunavanje težina kriterija w_j koje se računaju iz matrice omjera važnosti kriterija na način da pomnožimo matricu A s vektorom težina W, odnosno:

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

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

Dobili smo jednadžbu:

$$A \cdot W = n \cdot W$$

tj.

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

Matrica A ima rang 1, pa je to razlog što ima jednu svojstvenu vrijednost (realan broj λ) koja je jednaka n. U realnim procesima odlučivanja javljaju se poteškoće koje su uzrokovane nekonzistentnošću procjena relativnih omjera važnosti kriterija, što kao posljedicu ima gubitak onih svojstava omjera važnosti zbog kojih je matrica A imala samo jednu svojstvenu vrijednost. Od svih svojstvenih vrijednosti odabire se najveća, a razlika između najveće svojstvene vrijednosti matrice A i broja n služi za mjerenje konzistentnosti procjena danih u matrici A.

Potom se računaju vrijednosti indeksa konzistencije (CI) i omjera konzistencije (CR):

$$CI = \frac{\lambda_{max} - n}{n - 1}$$

CR = CI / RI

gdje je RI slučajni indeks konzistencije za matrice reda n slučajno generiranih usporedbi u parovima. Njegove vrijednosti prikazane su u slijedećoj tablici.

Tablica 9: Slučajni indeks koeficijenata konzistentnosti

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

Izvor: Babić, Z.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.76

Pravilo : ako matrica A ima vrijednost omjera konzistencije CR ≤ 0.10 procjene omjera relativnih važnosti kriterija smatraju se prihvatljivima. U suprotnom treba pronaći razloge zbog kojih je inkonzistencija procjena neprihvatljivo visoka.

Da bi sustav jednadžbi $(A - n \cdot I) \cdot W = 0$ imao netrivijalno rješenje, njegova determinanta mora biti jednaka nuli. Potom određivanje svojstvenih vrijednosti matrice A vodi na rješavanje slijedeće jednadžbe:

$$det(A - \lambda \cdot I) = 0$$

Navedena jednadžba je algebarska jednadžba n-tog stupnja koju nije uvijek lako riješiti pa se za određivanje svojstvenih vrijednosti matrice A i vrijednosti vektora W koriste neke približne metode računanja svojstvenih vrijednosti ili gotovi softverski paketi. Zbog toga se težine kriterija, čije omjere važnosti sadrži matrica A dobivaju rješenjem sljedećeg sustava:

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

$$w_i > 0,\ i = 1, 2, ..., n$$

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

Primjena metode svojstvenog vektora prilično je zahtjevna, ali razni softverski paketi (kao što je Expert Choice) čine ju vrlo jednostavnom. Potrebno je prikupiti podatke za matricu međusobnih usporedbi kriterija A, a ostatak posla obavlja računalo.

Računanje normaliziranih svojstvenih vrijednosti može se obaviti i jednim mnogo jednostavnijim aproksimativnim postupkom koji se provodi kroz dva koraka:

1. Matrica međusobnih usporedbi transformira se na način da se svaki element te matrice podijeli sa sumom stupca u kojem se nalazi.
2. Težine (prioriteti) tada se računaju kao prosječne vrijednosti elemenata pojedinih redaka matrice A.

Suma je jednaka 1, tj. dobivene težine su normalizirane, pri čemu će se u slučaju potpuno konzistentne matrice dobiti točne vrijednosti težina.

4.4. Metode za višeatributno odlučivanje

Metode koje se koriste za izbor najbolje alternative se dijele u tri skupine:

1. *Metode za izbor najbolje alternative u slučajevima kada nisu dane nikakve informacije o preferencijama donositelja odluke* : metoda dominacije, maksimin metoda i maksimaks metoda.
2. *Metode za koje postoje informacije o atributima (kriterijima)* :
   a) Metode sa zadanim standardnim nivoom atributa : konjuktivna metoda i disjunktivna metoda.
   b) Metode za koje postoje informacije o preferencijama među atributima: leksikografska metoda, leksikografski parcijalni uređaj, eliminacija po aspektima i metoda permutacija.
3. *Metode s poznatim kardinalnim preferencijama*: metoda jednostavnog zbrajanja težina, TOPSIS metoda, metoda linearne asignacije, Analitički hijerarhijski proces (AHP) i metoda PROMETHEE koja će se koristiti u ovom radu.

   PROMETHEE metoda izabrana je zbog njezinih prednosti koje su navedene u nastavku rada , te zbog toga što problem procjene boniteta hotelskih poduzeća ima karakteristike višekriterijalnog odlučivanja kao što su veći broj kriterija, konflikti među njima i neusporedive mjerne jedinice. Računanje se obavlja putem kompjuterskog programa pa se poredak alternativa dobije brzo i lako.

4.4.1. PROMETHEE metoda

Metodu PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluation) su razvili belgijski profesori J.P. Brans, B. Mareschal i P. Vincke 1984. godine s ciljem da se pomoću nje pomogne donosiocu odluke kod problema višekriterijalnog odlučivanja. Ova metoda vrši usporedbu i rangiranje više alternativa ocjenjenih na temelju više kvantitativnih i kvalitativnih kriterija. Metodu PROMETHEE I koristimo kada želimo prikazati djelomičan poredak alternativa, a metodu PROMETHEE II za potpuni poredak. Njezine prednosti su : jednostavnost, postojanje ekonomskog objašnjenja i značaja korištenih parametara, te potpuna eliminacija efekata rangiranja. Metoda PROMETHEE spada u „ outranking “ metode.

Višekriterijalni problem:

Max $\{f_1(a), f_2(a), ..., f_n(a) \mid a \in A\}$

gdje je A konačan skup alternativa (aktivnosti), tj.

$A = \{ A_1, A_2, ..., A_m \}$,

a f_j su n kriterija koje treba maksimizirati. Svaki kriterij je funkcija iz A u R ili u neki drugi uređeni skup. Neka je za svaku aktivnost A_i, $f_j(A_i)$ vrijednost ili procjena vrijednosti j-tog kriterija za i-tu alternativu.

Ako uspoređujemo dvije alternative, rezultat ćemo iskazati u terminima preferencije jedne alternative prema drugoj. Iz tih razloga se uvodi funkcija preferencije P koja pokazuje intenzitet preferencije jedne alternative nad drugom.

Funkcija preferencije je oblika:

$P : A \times A \rightarrow [0, 1]$

I definirana je na slijedeći način:

- P (a, b) = 0 , ne postoji preferencija između alternativa a i b, ili nepostojanje preferencije od a nad b.
- P (a, b) ≈ 0 , slučaj slabe preferencije od a nad b.
- P (a, b) ≈ 1 , slučaj jake preferencije od a nad b.
- P (a, b) = 1 , slučaj striktne preferencije od a nad b.

U praksi funkcija preferencije predstavlja razliku između vrijednosti dviju alternativa uspoređenih po odgovarajućem kriteriju, tj. uvodimo novu funkciju:

d = f(a) - f(b)

možemo uzeti da je

$P(a,b) = \overline{P}(d)$.

Funkcija preferencije je neopadajuća funkcija, koja je jednaka nuli za negativne vrijednosti od d. Naime, ako je d ≤ 0, tj. f(a) ≤ f(b), tada ne postoji preferencija od a nad b pa je i P(a, b) = 0. Što je razlika u ocjenama tih dviju alternativa (d), veća to je P(a, b) bliži jedinici, a za određenu vrijednost od d funkcija postaje jednaka 1 jer dolazi do striktne preferencije.

Da bi imali bolji pregled područja indiferencije može se promatrati funkcija H(d) koja je direktno vezana sa funkcijom preferencije P na sljedeći način:

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

Za svaki kriterij f_j razmatra se zatim generalizirani kriterij definiran pomoću kriterija f_j i odgovarajuće funkcije preferencije. Metoda PROMETHEE nam nudi 6 različitih tipova funkcija preferencije. Donosilac odluke određuje koju od šest mogućih funkcija preferencije će primijeniti kod određenog kriterija. Pri tom treba odrediti parametre koji će se koristiti u nekim od funkcija i koji imaju stvarno ekonomsko značenje, a to su:

q - prag indiferencije, koji definira područje unutar kojeg je razlika vrijednosti dviju alternativa po nekom kriteriju zanemariva za donosioca odluke

p - prag preferencije**,** koji definira područje stroge preferencije

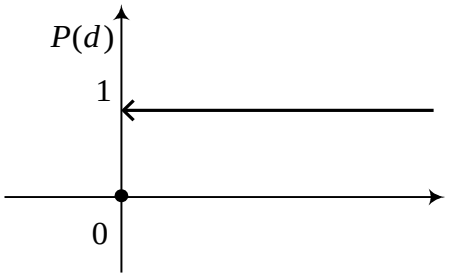
s - parametar čija se vrijednost nalazi između praga indiferencije q i praga preferencije p.

Generalizirani kriteriji funkcije preferencije su:

1. **Obični kriterij**

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

U ovom slučaju indiferencija između alternativa a i b postoji samo ako je f(a) = f(b), tj. za d=0. Ako su procjene dvije alternative različite, donosilac odluke će preferirati onu koja ima veću ocjenu, pa je vrijednost funkcije preferencije jednaka 1.



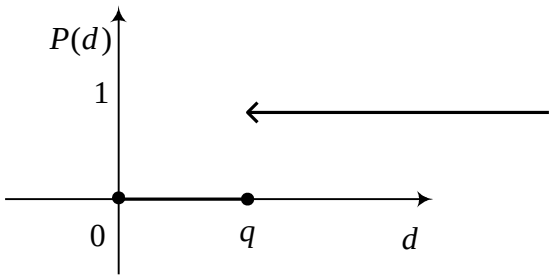
Slika 4. Obični kriterij

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.155

2. **Kvazi kriterij**

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

U ovom slučaju donosilac odluke odredi vrijednost parametra q koji predstavlja prag indiferencije. Njegovo značenje je da su dvije alternative indiferentne sve dok razlika njihovih ocjena ne premaši prag q, a u protivnom postoji stroga preferencija.



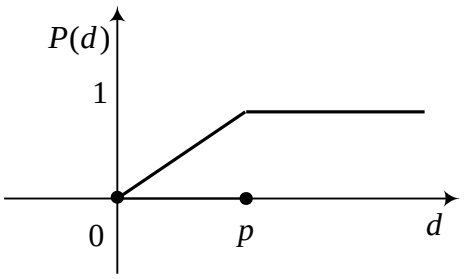
Slika 5.Kvazi kriterij

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.155

3. Kriterij s linearnom preferencijom

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

Kod ovog kriterija je potrebno uvesti novi parametar p koji predstavlja najnižu vrijednost od d, a iznad koje postoji stroga preferencija. Ako je vrijednost d manja od parametra p, preferencija donosioca odluke će rasti linearno s vrijednošću d. Kada razlika d postane veća od p imamo situaciju stroge preferencije. U ovom slučaju će biti potrebno da donosilac odluke odredi vrijednost parametra p – prag preferencije.



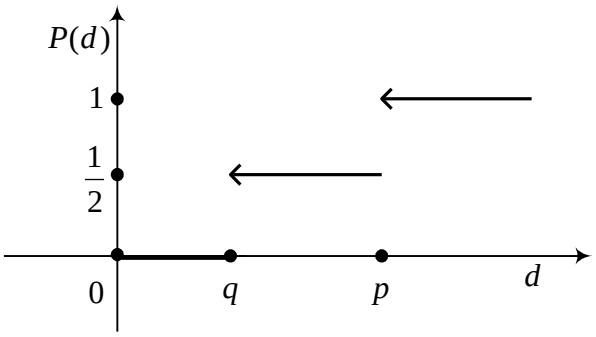
Slika 6.Kriterij sa linearnom preferencijom

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.156

4. Nivo kriterij

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

Kod ovog kriterija je potrebno da donosilac odluke istovremeno odredi oba parametra q i p. Kada se vrijednost d nalazi između pragova imamo slučaj slabe preferencije P(d) = ½.



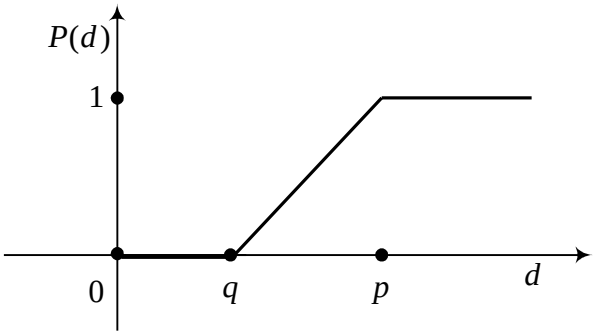
Slika 7. Nivo kriterij

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.156

5. Kriterij s linearnom preferencijom i područjem indiferencije

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

U ovom slučaju područje koje se nalazi između pragova q i p označava da preferencija donosioca odluke raste linearno i to od područja indiferencije do područja stroge preferencije. Potrebno je istovremeno dobiti informacije od donosioca odluke za pragove q i p.



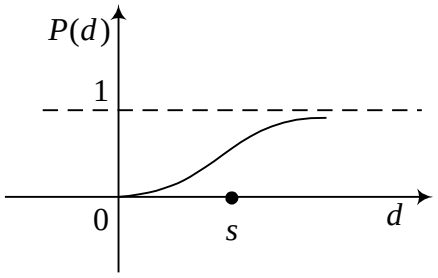
Slika 8.Kriterij s linearnom preferencijom i područjem indiferencije

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.157

6. Gaussov kriterij

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

Kod Gaussov-og kriterija potrebno je odrediti novu vrstu parametra s koji se nalazi u području slabe preferencije, a predstavlja standardnu devijaciju normalne razdiobe. Ta funkcija koja nema prekida ni šiljaka može biti zanimljiva zbog stabilnosti rezultata.



Slika 9.Gaussov kriterij

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.157

Za svaki kriterij potrebno je izabrati jedan od ovih šest tipova funkcije preferencije. Nakon toga potrebno je odrediti težine (relativne važnosti) za svaki kriterij. U ovom radu će se težine kriterija određivati po metodi svojstvenog vektora, koja je već prethodno obrađena.

Nakon ova dva koraka, potrebno je definirati indeks preferencije Π kao ponderiranu (vaganu) sredinu funkcija preferencije P_j:

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

gdje Π (*a,b*) predstavlja jačinu (intenzitet) preferencije donosioca odluke za alternativu *a* nad alternativom *b* promatrajući istovremeno sve kriterije, odnosno kako i s kojim intenzitetom *a* dominira nad *b* po svim kriterijima.

Ako uzmemo u obzir da suma težina kriterija najčešće iznosi 1, tj.

$$\sum_{j=1}^{n} w_j = 1$$

onda Π (*a,b*) možemo pisati i kao

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

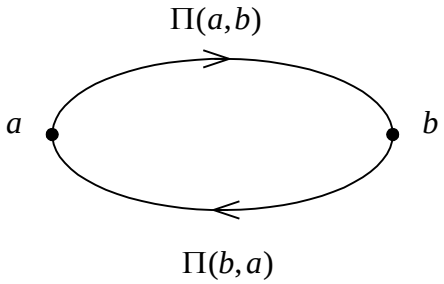
Vrijednost indeksa preferencije varira između vrijednosti 0 i 1, pa ako je ona bliže vrijednosti nula, tj. Π (*a,b*) ≈ 0, označavat će slabu preferenciju *a* nad *b* za sve kriterije, a ako je bliže vrijednosti 1, tj. Π (*a,b*) ≈ 1, označavat će jaku preferenciju *a* nad *b* za sve kriterije. Osim toga vrijednost Π (*a,b*) ne može biti negativna zbog toga što će P_j (*a,b*) biti nula ako *b* dominira nad *a* po j-tom kriteriju, dok će najveća vrijednost P_j (*a,b*) iznositi jedan i to samo u slučaju stroge preferencije, tj.:

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

odnosno

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

Nasuprot tome indeks preferencije $\Pi(b,a)$ izražava kako i sa kojim intenzitetom b dominira nad a u odnosu na sve kriterije. Dakle, između svake dvije alternative **a** i **b** postoje dva luka sa vrijednostima Π(a,b) i Π(b,a).



Slika 10. *Π (a,b) i Π (b,a)*

Izvor: Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.158

Nakon toga za svaku alternativu treba definirati dva „outranking“ toka, izlazni ili pozitivni tok i ulazni ili negativni tok. Izlazni tok $\Phi^+(a)$ predstavlja sumu vrijednosti svih izlaznih lukova iz alternative *a* i iskazuje koliko je alternativa *a* bolja od ostalih alternativa po svim kriterijima, odnosno on mjeri „snagu” alternative *a* :

$$\Phi^+(a) = \sum_{b \in A} \Pi(a,b) \ . \qquad (14)$$

Ulazni tok $\Phi^-(a)$ predstavlja sumu vrijednosti svih ulaznih lukova u alternativu *a* i izražava koliko je alternativa *a* dominirana od ostalih alternativa po svim kriterijima, odnosno on mjeri „slabost” alternative *a* (što je manji to je alternativa bolja) :

$$\Phi^-(a) = \sum_{b \in A} \Pi(b,a) \ .$$

Usporedbom ulaznih i izlaznih tokova dobivaju se dva potpuna uređaja skupa alternativa, tj. jedan po Φ^+(a) i jedan po Φ^-(a). To su:

$$\Phi^+(\text{a}) \ \begin{Bmatrix} aS^+b & ako\ i\ \ samo\ \ ako\ \ je\ \Phi^+(a) > \Phi^+(b) \\ aI^+b & ako\ \ i\ \ samo\ \ ako\ \ \ je\ \ \Phi^+(a) = \Phi^+(b) \end{Bmatrix} \qquad (16)$$

$$\Phi^-(\text{a}) \ \begin{Bmatrix} aS^-b & ako\ i\ \ samo\ \ ako\ \ je\ \Phi^-(a) < \Phi^-(b) \\ aI^-b & ako\ \ i\ \ samo\ \ ako\ \ \ je\ \ \Phi^-(a) = \Phi^-(b) \end{Bmatrix} \qquad (17)$$

pri čemu je S tzv. "**outranking**" relacija, tj **a S b** znači: **a** je barem toliko dobar kao i **b** ili bolji. Presjek tih dvaju uređaja rezultira u parcijalnom uređaju (P, I, R) što je konačan uređaj dobiven metodom PROMETHEE I, a koji je prikazan u tablici.

Tablica 10: PROMETHEE I – parcijalni uređaj

a P b (a dominira nad b)	ako i samo ako $\left\{\begin{array}{c} aS^{+}b \;\; i \;\; aS^{-}b \\ ili \\ aS^{+}b \;\; i \;\; aI^{-}b \\ ili \\ aI^{+}b \;\; i \;\; aS^{-}b \end{array}\right\}$
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: Babić, Z.(2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.160

Ako donosilac odluke želi potpuni uređaj skupa alternativa A može se izračunati „neto“ tok kao razlika „snage“ i „slabosti“ pojedine alternative, tj.

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

Takav uređaj naziva se PROMETHEE II i definira se kao:

a P_{II} b (a dominira nad b) ako je $\Phi(a) > \Phi(b)$;

a I_{II} b (a je indiferentan sa b) ako je $\Phi(a) = \Phi(b)$.

Donositelju odluke je jednostavnije odlučivati na temelju potpunog poretka putem PROMETHEE II, no ipak parcijalni uređaj PROMETHEE I daje realnije, potpunije informacije.

5. PRIMJENA METODA VIŠEATRIBUTNOG ODLUČIVANJA NA PROBLEM PROCJENE BONITETA HOTELSKIH PODUZEĆA

5.1. Analiza boniteta hotela

U ovom radu će biti prikazana procjena boniteta 10 splitskih hotela u svrhu prikazivanja primjene metoda višekriterijalnog odlučivanja na procjenu boniteta. Za procjenu odabrala sam četiri financijska pokazatelja (koeficijent tekuće likvidnosti, stupanj zaduženosti, povrat na ukupnu imovinu i neto profitnu maržu) te četiri kvalitativna kriterija (ukupno zadovoljstvo gostiju, lokacija, dodatni sadržaji i kategorizacija) .

Izračunati financijski pokazatelji su prikazani u slijedećoj tablici:

Tablica 11: Financijski pokazatelji za procjenu boniteta

Ime hotela	Broj zvjezdica	Naziv tvrtke	Koeficijent tekuće likvidnosti	Koeficijent zaduženosti	ROA (%)	Neto profitna marža (%)
1.ATRIUM	*****	Atrium Grupa d.o.o.	3,01	0,20	12,80	2,92
2.PARK	*****	Potestas d.o.o.	3,00	0,62	1,20	0,66
3.ART	****	Hoteli A d.o.o.	0,14	1,00	-8,70	-84,50
4.DALMINA	****	Dalma d.d.	0,07	0,51	-4,00	-126,23
5.FANAT	****	Fanat d.o.o.	1,12	0,55	0,00	0,26
6.GLOBO	****	Eurodom Trgovina d.o.o.	4,06	0,91	1,80	4,62
7.MARMONT	****	Ordesa	2,53	0,67	6,70	11,58

		d.o.o.				
8.PRESIDENT	****	President grupa d.o.o.	0,08	0,53	0,80	-31,11
9.BELLEVUE	***	Laurus – Bellevue d.o.o.	0,68	1,45	0,80	1,28
10.PERISTIL	***	Srebrena vrata d.o.o.	3,69	0,22	12,70	4,32

Izvor: Portal poslovna hrvatska (http://www.poslovna.hr/login.aspx)

- KOEFICIJENT TEKUĆE LIKVIDNOSTI

  Pokazuje u kojoj mjeri kratkotrajna imovina poduzeća pokriva kratkoročne obveze, tj. ima li poduzeće dovoljno likvidnih sredstava da u kratkom roku podmiri svoje tekuće obveze. Optimalna vrijednost pokazatelja nalazi se iznad 1,5 ili 2.

  Iz tablice je vidljivo da hoteli Atrium, Park, Globo, Marmont i Peristil imaju koeficijent tekuće likvidnosti iznad 2 što znači da tvrtke nemaju nikakvih problema sa podmirivanjem svojih obveza. Ako je pokazatelj oko 1 situacija ne mora biti zabrinjavajuća ako tvrtka dobro upravlja s potraživanjima i zalihama, te ako ima raspoloživu kreditnu liniju s bankom koja joj omogućuje da održava ovaj pokazatelj niskim (pr. hotel Fanat 1,12). Hoteli Art, Dalmina, President i Bellevue imaju ovaj pokazatelj manji od 1 što znači da su im kratkoročne obveze veće od kratkotrajne imovine, pa zbog toga imaju velike probleme s likvidnošću.

- STUPANJ ZADUŽENOSTI

  Predstavlja omjer svih obveza poduzeća i ukupne imovine. Stupanj zaduženosti iznad 0,7 sugerira kako je poduzeće prezaduženo, dok je kontrolna mjera stupnja zaduženosti 0,5 pri kojoj su obveze jednake kapitalu poduzeća.

  Iz tablice je vidljivo da hoteli Atrium (0,20) i Peristil (0,22) jako dobro kontroliraju svoje dugove. Stupanj zaduženosti iznad 0,7 imaju hoteli Art, Globo i Bellevue što

znači da su prezaduženi, a hoteli Park, Dalmina, Fanat, Marmont i President imaju vrijednost malo veću od 0,5 što bi značilo da su im obveze približno jednake kapitalu.

- ROA (POVRAT NA UKUPNU IMOVINU)

  Pokazuje koliki je udio dobiti u ukupnoj imovini. Zbog toga bi trebao biti što viši.

  Kod hotela Art (-8,70 %) i hotela Dalmina (-4,00 %) ovaj pokazatelj je u minusu što znači da su ta poduzeća u gubitku. Najvišu vrijednost imaju hoteli Atrium (12,80 %) i Peristil (12,70%).

- NETO PROFITNA MARŽA

  Predstavlja omjer neto dobiti i ukupnih prihoda, odnosno mjeri koliki je udio od ukupno realiziranih prihoda ostao vlasnicima poduzeća na raspolaganju nakon oporezivanja bruto dobiti.

  Ovdje možemo primijetiti da hoteli Art i Dalmina ponovno imaju negativnu vrijednost pokazatelja što znači da su ta poduzeća poslovala s gubitkom. Pridružuje im se još i hotel President (-31,11%). Hotel Marmont (11,58%) ima najvišu vrijednost ovog pokazatelja što znači da menadžment poduzeća na pravi način obavlja kontrolu nad troškovima, rashodima i prihodima. Kod preostalih poduzeća pokazatelj je znatno niži što upućuje na borbu za zadržavanje udjela na tržištu.

Financijski pokazatelji su izračunati putem slijedećih formula:

Koeficijent tekuće likvidnosti = kratkotrajna imovina / kratkoročne obveze
Stupanj zaduženosti = ukupne obveze / ukupna imovina
Neto profitna marža (%) = (neto dobitak / ukupni prihod)*100

1. ***Hotel Atrium***

   Koeficijent tekuće likvidnosti = 3 219 300 / 1 069 700= 3,01
   Stupanj zaduženosti = 1 069 700 / 5 404 900= 0,20
   Neto profitna marža = (721 600 / 24 682 800)*100= 2,92%

2. ***Hotel Park***

Koeficijent tekuće likvidnosti = 19 589 200 / 6 533 400= 3,00

Stupanj zaduženosti = 62 600 300 / 100 219 500= 0,62

Neto profitna marža = (126 000 / 19 181 400)*100= 0,66%

3. ***Hotel Art***

Koeficijent tekuće likvidnosti = 1 726 100 / 12 720 000 = 0,14

Stupanj zaduženosti = 100 095 300 / 88 081 400= 1,14

Neto profitna marža = (-15 661 300 / 18 539 700)*100= -84,50%

4. ***Hotel Dalmina***

Koeficijent tekuće likvidnosti = 5 982 200 / 82 550 300= 0,07

Stupanj zaduženosti = 82 550 300 / 154 044 500 = 0,51

Neto profitna marža = (-7 362 000 / 5 832 000)*100= -126,23%

5. ***Hotel Fanat***

Koeficijent tekuće likvidnosti = 728 200 / 650 300 =1,12

Stupanj zaduženosti = 21 054 900 / 38 077 300 = 0,55

Neto profitna marža = (12 700 / 4 957 100)*100= 0,26%

6. ***Hotel Globo***

Koeficijent tekuće likvidnosti = 2 311 800 / 568 800 = 4,06

Stupanj zaduženosti = 14 144 800 / 15 597900 = 0,91

Neto profitna marža = (285 800 / 6 186 500)*100= 4,62%

7. ***Hotel Marmont***

Koeficijent tekuće likvidnosti = 1 887 500 / 744 700= 2,53

Stupanj zaduženosti = 19 087 000 / 28 283 500= 0,67

Neto profitna marža = (1 106 400 / 9 553 600)*100= 11,58%

8. ***Hotel President***

Koeficijent tekuće likvidnosti = 824 700 / 9 776 900= 0,08

Stupanj zaduženosti = 87 433 900 / 163 829 500 = 0,53

Neto profitna marža = (-3 073 400 / 9 879 500)*100= -31,11%

9. ***Hotel Bellevue***

Koeficijent tekuće likvidnosti = 7 976 400 / 11 793 800 = 0,68

Stupanj zaduženosti = 11 793 800 / 8 125 300= 1,45

Neto profitna marža = (62 700 / 4 891 900)*100= 1,28%

10. ***Hotel Peristil***

Koeficijent tekuće likvidnosti = 704 600 / 191 200 = 3,69

Stupanj zaduženosti = 191 200 / 882 400 = 0,22

Neto profitna marža = (123 900 / 2 868 800)*100= 4,32%

U tablici 12. prikazana su četiri kvalitativna kriterija : ukupno zadovoljstvo gostiju, lokacija, dodatni sadržaji i kategorizacija hotela. Njihove vrijednosti preuzete su sa web stranice booking.com na kojoj posjetitelji ocjenjuju hotel nakon svog boravka u njemu. Ocjene se daju na slijedeći način :

- Jako loše 1-3
- Loše 3-5
- Osrednje 5-7
- Dobro 7-9
- Odlično 9+

Tablica 12. kvalitativni kriteriji

Ime hotela	Ukupno zadovoljstvo gostiju	Lokacija	Dodatni sadržaji	Kategorizacija
1.ATRIUM	8,1	7,4	8,2	5
2.PARK	9	9,2	8,9	5
3.ART	9,6	10	7,7	4
4.DALMINA	7,8	7,3	7	4
5.FANAT	9,2	8,5	9	4
6.GLOBO	8,8	8,4	8,3	4
7.MARMONT	9,3	9,7	9	4
8.PRESIDENT	7,7	8,4	6,8	4
9.BELLEVUE	7	9,2	5,9	3
10.PERISTIL	8,9	9,8	8,2	3

Izvor: www.booking.com

5.2.Određivanje težina kriterija metodom svojstvenog vektora

Slijedeći korak nakon što smo izračunali financijske pokazatelje te preuzeli kvalitativne kriterije je određivanje težina kriterija. U ovom problemu razmatramo osam kriterija (atributa):

C1 – koef. tekuće likvidnosti,

C2 – stupanj zaduženosti,

C3 – ROA,

C4 – neto profitna marža,

C5 – ukupno zadovoljstvo gostiju,

C6 – lokacija,

C7 – dodatni sadržaji i

C8 – kategorizacija.

Procjenu važnosti kriterija određujemo aproksimativnim postupkom metodom svojstvenog vektora (metoda je prethodno objašnjena u poglavlju 4.3.1.). Kod ove metode donositelj odluke treba prvo formirati matricu međusobnih usporedbi prethodno navedenih kriterija, te potom odrediti te težine metodom svojstvenog vektora. Matrica međusobnih usporedbi tih 8 kriterija prikazana je u idućoj tablici, gdje su u zadnjem retku izračunate sume svakog stupca koje služe za primjenu aproksimativnog postupka pomoću MS Excela. Na temelju svojih preferencija sam poredala kriterije po važnosti : **(C1, C2, C3, C4, C8, C5, C6, C7).** Na glavnoj dijagonali su sve jedinice jer kriterije ne možemo uspoređivati sa samim sobom. Elemente iznad glavne dijagonale odredila sam pomoću Saatyeve skale važnosti gdje su vrijednosti omjera ograničene na brojeve od 1 do 9 (prethodno objašnjeno u tablici 8.), odnosno element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale.

Tablica 13: Matrica međusobnih usporedbi

	C1	C2	C3	C4	C5	C6	C7	C8
C1	**1**	2	3	4	6	7	8	5
C2	0,5	**1**	2	3	6	7	8	4
C3	0,333	0,5	**1**	2	4	6	8	3
C4	0,25	0,333	0,5	**1**	4	6	8	2
C5	0,167	0,167	0,25	0,25	**1**	2	4	0,5
C6	0,143	0,143	0,167	0,167	0,5	**1**	2	0,333
C7	0,125	0,125	0,125	0,125	0,25	0,5	**1**	0,25
C8	0,2	0,25	0,333	0,5	2	3	4	**1**
∑	**2,718**	**4,518**	**7,375**	**11,042**	**23,75**	**32,5**	**43**	**16,083**

Izvor: izradila autorica

Kada podijelimo elemente ove matrice sa sumom stupaca dobivamo slijedeću tablicu:

Tablica 14: Transformirana matrica A'

	C1	C2	C3	C4	C5	C6	C7	C8
C1	0,367918	0,442674	0,40678	0,362253	0,252632	0,215385	0,186047	0,310887
C2	0,183959	0,221337	0,271186	0,27169	0,252632	0,215385	0,186047	0,24871
C3	0,122517	0,110668	0,135593	0,181127	0,168421	0,184615	0,186047	0,186532
C4	0,091979	0,073705	0,067797	0,090563	0,168421	0,184615	0,186047	0,124355
C5	0,061442	0,036963	0,033898	0,022641	0,042105	0,061538	0,093023	0,031089
C6	0,052612	0,031651	0,022644	0,015124	0,021053	0,030769	0,046512	0,020705
C7	0,04599	0,027667	0,016949	0,01132	0,010526	0,015385	0,023256	0,015544
C8	0,073584	0,055334	0,045153	0,045282	0,084211	0,092308	0,093023	0,062177

Izvor: izradila autorica

Tablica 15: Težine kriterija

	Wj
	0,318071774
	0,231368068
	0,159440017
	0,123435293
	0,047837542
	0,030133764
	0,020829685
	0,068883857
Suma:	**1**

Izvor: izradila autorica

Težine kriterija dobijemo kao prosječne vrijednosti redaka te tablice i one su prikazane u tablici 14., a njihova suma je jednaka 1. Iz stupca težina Wj je vidljivo da težina koeficijenta tekuće likvidnosti iznosi 0,318071 što znači da taj koeficijent utječe 31,81% na donošenje odluke. Razlog što je njegov utjecaj toliko veći od utjecaja ostalih kriterija je u tome što mjeri likvidnost koja je najvažnija prilikom procjene boniteta jer pokazuje sposobnost podmirivanja kratkoročnih obveza kratkotrajnom imovinom.

Težina kriterija stupanj zaduženosti iznosi 0,231368 što znači da utječe 23,14% na donošenje odluke. Manje je bitan od prvog kriterija, ali je bitniji od preostalih šest.

ROA na donošenje odluke utječe 15,94%, a neto profitna marža 12,34%. ova dva kriterija imaju manje težine od prethodna dva jer pokazuju profitabilnost koja je manje bitna prilikom procjene boniteta.

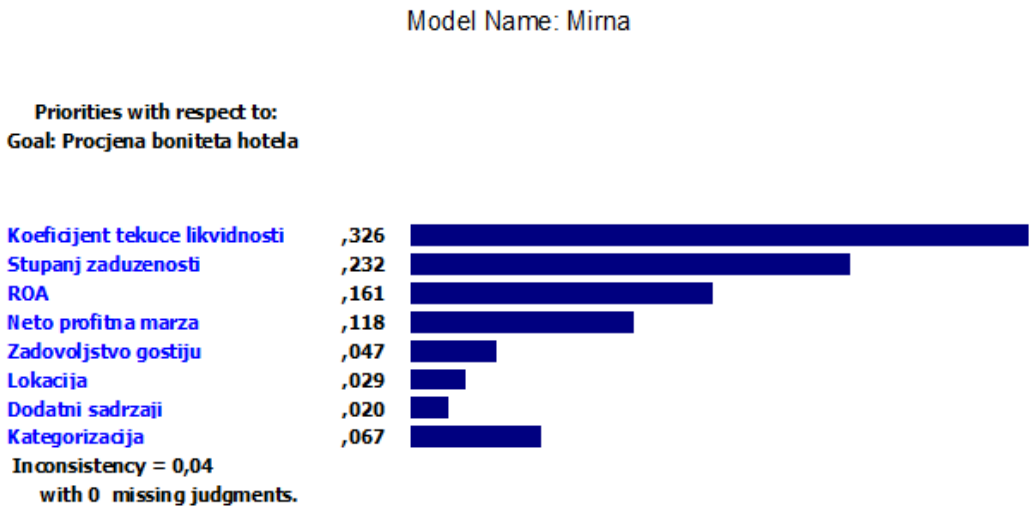
Posljednja četiri kriterija (ukupno zadovoljstvo gostiju, lokacija, dodatni sadržaji i kategorizacija) utječu na donošenje odluke redom 4,78%, 3,01%, 2,08% i 6,89%. Njihov utjecaj je mnogo manji od utjecaja financijskih pokazatelja, a među njima najveću težinu ima kategorizacija hotela.

Vrijednosti dobivene metodom svojstvenog vektora programom Expert Choice su veoma bliske ovima i iznose redom: w1=0,326 , w2=0,232 , w3=0,161 , w4=0,118 , w5=0,047 , w6=0,029 , w7=0,020 i w8=0,067. U PROMETHEE metodi koristit će se težine izračunate pomoću aproksimativnog postupka.

	Koeficijent	Stupanj za	ROA	Neto profitr	Zadovoljstv	Lokacija	Dodatni sa	Kategoriza
Koeficijent tekuce likvidnosti		2,0	3,0	4,0	6,0	7,0	8,0	5,0
Stupanj zaduzenosti			2,0	3,0	5,0	7,0	8,0	4,0
ROA				2,0	4,0	6,0	8,0	3,0
Neto profitna marza					4,0	5,0	8,0	2,0
Zadovoljstvo gostiju						2,0	4,0	2,0
Lokacija							2,0	3,0
Dodatni sadrzaji								4,0
Kategorizacija	Incon: 0,04							

Slika 11:Ulazni podaci u programu Expert Choice

Izvor: izradila autorica



Slika 12:Težine kriterija dobivene programom Expert Choice

Izvor: izradila autorica

5.3.Odabir najbolje alternative PROMETHEE metodom

Kada smo odredili težine kriterija dolazimo do odabira najbolje alternative pomoću metode PROMETHEE. Kod ove metode najprije treba odrediti jednu od šest funkcija preferencije za svaki kriterij. Neke kriterije treba minimizirati, a neke maksimizirati. Svi ti podaci prikazani su u slijedećoj tablici.

Tablica 16: Tablica odluke

		C1	C2	C3	C4	C5	C6	C7	C8
		LIK.	ZAD.	ROA	NPM	UZG	LOK.	DS	KAT.
		Max	Min	Max	Max	Max	Max	Max	Max
A1	Atrium	3,01	0,20	12,80	2,92	8,1	7,4	8,2	5
A2	Park	3,00	0,62	1,20	0,66	9	9,2	8,9	5
A3	Art	0,14	1,00	-8,70	-84,50	9,6	10	7,7	4
A4	Dalmina	0,07	0,51	-4,00	-126,23	7,8	7,3	7	4
A5	Fanat	1,12	0,55	0,00	0,26	9,2	8,5	9	4
A6	Globo	4,06	0,91	1,80	4,62	8,8	8,4	8,3	4
A7	Marmont	2,53	0,67	6,70	11,58	9,3	9,7	9	4
A8	President	0,08	0,53	0,80	-31,11	7,7	8,4	6,8	4
A9	Bellevue	0,68	1,45	0,80	1,28	7	9,2	5,9	3
A10	Peristil	3,69	0,22	12,70	4,32	8,9	9,8	8,2	3
	Wj	0,318	0,231	0,159	0,123	0,048	0,0301	0,0208	0,069
	Tip fun. pref.	VI.	V.	III.	IV.	VI.	II.	I.	VI.
	Q	/	0,18	/	2	/	7	/	/
	P	/	0,70	2	5	/	/	/	/
	S	0,4	/	/	/	6	/	/	2

Izvor: izradila autorica

Za koeficijent tekuće likvidnosti odabrala sam Gaussov kriterij jer je zanimljiv zbog stabilnosti rezultata. Ova funkcija zahtijeva definiranje samo parametra s koji leži negdje u području slabe preferencije, a predstavlja standardnu devijaciju normalne razdiobe. Odredila sam da je s=0,4.

Kod koeficijenta zaduženosti sam odabrala kriterij s linearnom preferencijom i područjem indiferencije jer preferencija donosioca odluke raste linearno u području indiferencije do područja stroge preferencije, tj. u području između pragova q i p. Izabrala sam vrijednosti q=0,18 i p=0,70.

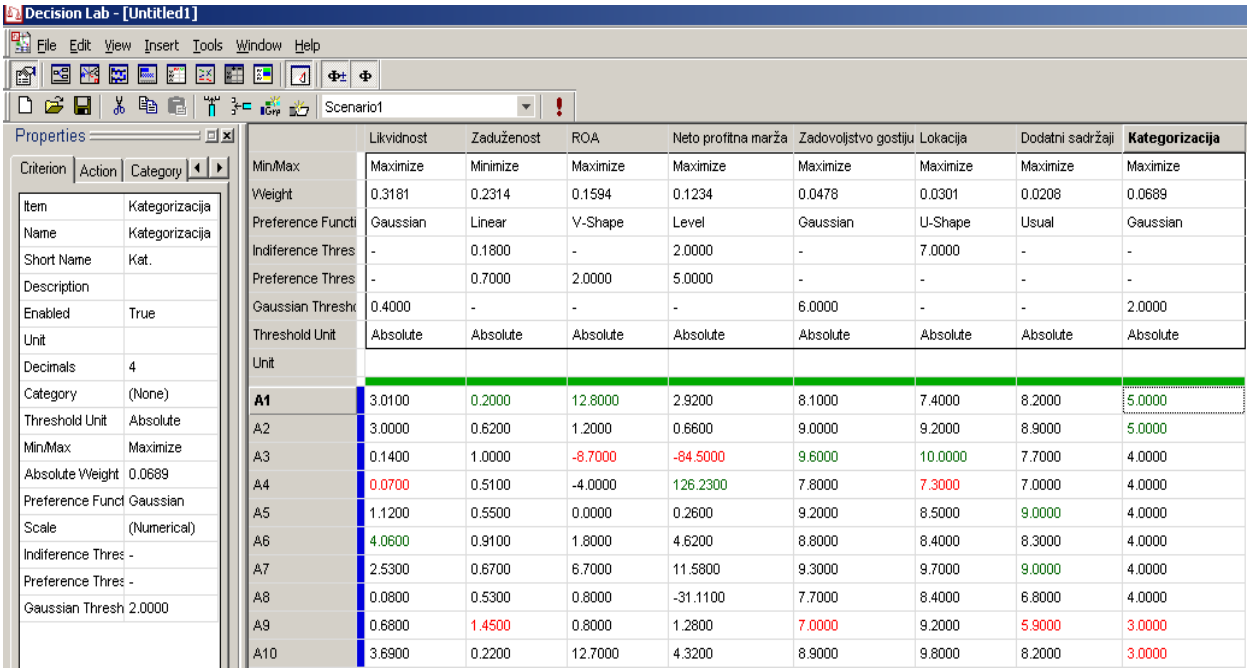
Za koeficijent povrat na imovinu (ROA) odabrala sam kriterij s linearnom preferencijom. Dok je d manji od p preferencija donosioca odluke raste linearno s vrijednošću d. Čim razlika d postaje veća od p postoji situacija stroge preferencije. U ovom slučaju p=2.

Kod neto profitne marže odabrala sam nivo kriterij. Kada se razlika d nalazi između vrijednosti q i p postoji slaba preferencija. Odredila sam da je q=2, a p=5.

Za kriterije C5 i C8 sam odabrala Gaussov kriterij isto kao i kod koeficijenta tekuće likvidnosti. Za kriterij ukupno zadovoljstvo gostiju odredila sam da je s=6, a za kriterij kategorizacije s iznosi 2.

Kod kriterija lokacije odabrala sam kvazi kriterij koji nam govori da su dvije alternative indiferentne sve dok d ne premaši prag q, a u protivnom postoji stroga preferencija. U ovom slučaju prag q=7.

Kod kriterija dodatni sadržaji odabrala sam obični kriterij gdje indiferencija postoji samo ako je d=0. Čim su vrijednosti aktivnosti različite to znači da donosilac odluke preferira aktivnost koja ima veću ocjenu.



	Likvidnost	Zaduženost	ROA	Neto profitna marža	Zadovoljstvo gostiju	Lokacija	Dodatni sadržaji	**Kategorizacija**
Min/Max	Maximize	Minimize	Maximize	Maximize	Maximize	Maximize	Maximize	Maximize
Weight	0.3181	0.2314	0.1594	0.1234	0.0478	0.0301	0.0208	0.0689
Preference Functi	Gaussian	Linear	V-Shape	Level	Gaussian	U-Shape	Usual	Gaussian
Indiference Thres	-	0.1800	-	2.0000	-	7.0000	-	-
Preference Thres	-	0.7000	2.0000	5.0000	-	-	-	-
Gaussian Thresh	0.4000	-	-	-	6.0000	-	-	2.0000
Threshold Unit	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute
Unit								
A1	3.0100	0.2000	12.8000	2.9200	8.1000	7.4000	8.2000	5.0000
A2	3.0000	0.6200	1.2000	0.6600	9.0000	9.2000	8.9000	5.0000
A3	0.1400	1.0000	-8.7000	-84.5000	9.6000	10.0000	7.7000	4.0000
A4	0.0700	0.5100	-4.0000	126.2300	7.8000	7.3000	7.0000	4.0000
A5	1.1200	0.5500	0.0000	0.2600	9.2000	8.5000	9.0000	4.0000
A6	4.0600	0.9100	1.8000	4.6200	8.8000	8.4000	8.3000	4.0000
A7	2.5300	0.6700	6.7000	11.5800	9.3000	9.7000	9.0000	4.0000
A8	0.0800	0.5300	0.8000	-31.1100	7.7000	8.4000	6.8000	4.0000
A9	0.6800	1.4500	0.8000	1.2800	7.0000	9.2000	5.9000	3.0000
A10	3.6900	0.2200	12.7000	4.3200	8.9000	9.8000	8.2000	3.0000

Slika 13 : Ulazni podaci za PROMETHEE metodu – program Decision Lab

Izvor: izradila autorica

Na slici 11 prikazani su ulazni podaci za PROMETHEE metodu tj. kriteriji, težine, funkcije preferencije ,te koje kriterije treba maksimizirati, a koje minimizirati. Alternative su označene od A1 do A10.

Nakon postavljanja problema dobiven je konačan poredak alternativa što je vidljivo iz tablice 15.

Tablica 17: Ulazni, izlazni i neto tokovi

Preference Flows

	Φ+	Φ−	Φ
A1	0.5250	0.0984	0.4266
A2	0.3441	0.1955	0.1486
A3	0.0243	0.6417	-0.6174
A4	0.1995	0.4082	-0.2086
A5	0.2499	0.3362	-0.0863
A6	0.4491	0.1784	0.2708
A7	0.4676	0.1845	0.2831
A8	0.1103	0.4455	-0.3351
A9	0.1392	0.5449	-0.4057
A10	0.5855	0.0613	0.5242

Izvor: izradila autorica

Tablica 18: Rang alternativa

Alternativa	Rang
A1	2.
A2	5.
A3	10.
A4	7.
A5	6.
A6	4.
A7	3.
A8	8.
A9	9.
A10	1.

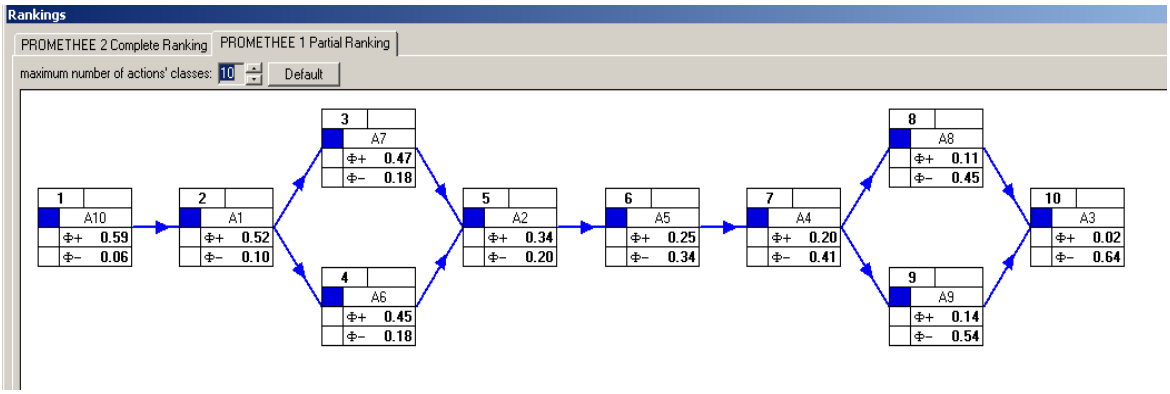
Izvor: izradila autorica

Prema pozitivnom i negativnom tijeku najbolje je alternativa A10 (Hotel Peristil), jer ima najveći pozitivan i najmanji negativan tok.

Parcijalno uređenje PROMETHEE I pokazuje da:

- Alternativa A1 dominira nad svim alternativama samo ne alternativom A10.
- Alternativa A2 dominira nad petom, četvrtom, osmom, devetom i trećom alternativom.
- Alternativa A3 ne dominira ni jednom drugom alternativom.
- Alternativa A4 dominira nad osmom, devetom i trećom alternativom.
- Alternativa A5 dominira nad četvrtom, osmom, devetom i trećom alternativom.
- Alternativa A6 dominira nad drugom, petom, četvrtom, osmom, devetom i trećom alternativom.
- Alternativa A7 dominira nad svima osim desetom i prvom alternativom.
- Alternativa A8 dominira nad devetom i trećom alternativom.
- Alternativa A9 dominira samo trećom alternativom.
- Alternativa A10 dominira nad svim alternativama.

Grafički ćemo rezultat dobiven putem analize metodom PROMETHEE I prikazati na slici 12.

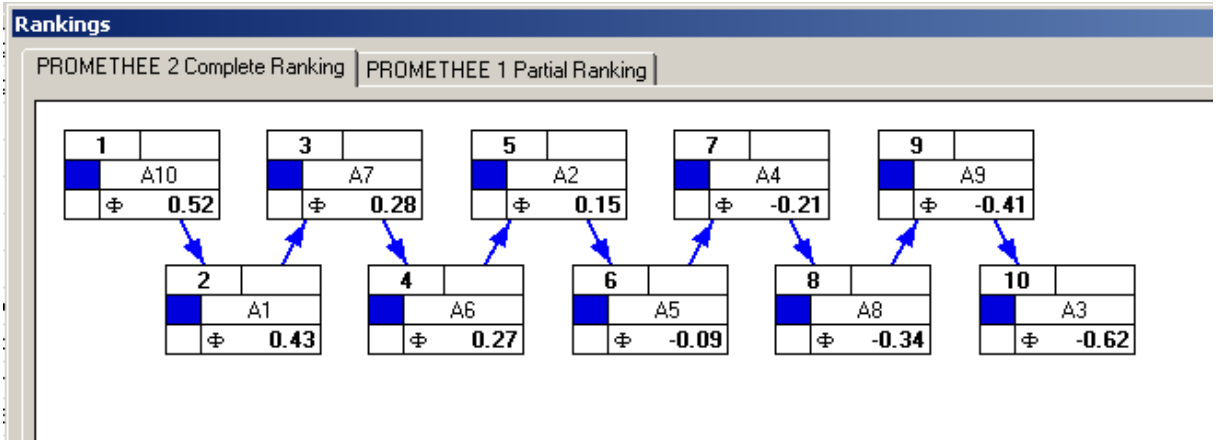


Slika 14: PROMETHEE I – parcijalni uređaj

Izvor: izlazna slika iz programa Decision Lab

Iz slike 12 lako je uočiti da je alternativa A10 (Hotel Peristil) najbolja od svih ostalih i po negativnom i pozitivnom toku. Neke alternative se ne mogu usporediti kao što su npr. alternative A8 i A9 (Hotel President i hotel Bellevue). Alternativa A9 je bolja od alternative A8 po pozitivnom toku, a lošija po negativnom. Ovom metodom je dobiven samo djelomičan poredak alternativa jer PROMETHEE I ne uspoređuje konfliktne alternative

Metoda PROMETHEE II nam daje potpuni poredak alternativa jer računa neto tok kao razliku pozitivnog i negativnog toka, a grafički je prikazan na slici 13.



Slika 15: PROMETHEE II – kompletni poredak alternativa

Izvor: izlazna slika iz programa Decision Lab

Iz rezultata dobivenih metodom PROMETHEE II vidljivo je da je najbolja alternativa A10 (Hotel Peristil), nakon toga redom idu A1 (Hotel Atrium), A7 (Hotel Marmont), A6 (Hotel Globo), A2 (Hotel Park), A5 (Hotel Fanat), A4 (Hotel Dalmina), A8 (Hotel President), A9 (Hotel Bellevue) i A3 (Hotel Art).

Tablica 19: Konačan poredak hotela od najboljeg do najlošijeg

1.	Hotel Peristil
2.	Hotel Atrium
3.	Hotel Marmont
4.	Hotel Globo
5.	Hotel Park
6.	Hotel Fanat
7.	Hotel Dalmina
8.	Hotel President
9.	Hotel Bellevue
10.	Hotel Art

Izvor : izradila autorica

U tablici 19 prikazan je konačan poredak alternativa tj. hotela dobiven metodom PROMETHEE II od hotela Peristil koji ima najbolju procjenu boniteta, pa sve do hotela Art koji ima najlošije pokazatelje.

6. ZAKLJUČAK

Osnovni cilj ovog rada bio je definirati metodiku procjene boniteta poduzeća temeljenu na metodama višekriterijalne analize i primijeniti je na hotelska poduzeća iz grada Splita. Pod bonitetom poduzeća podrazumijevamo sposobnost poduzeća da podmiri svoje obveze u predviđenom vremenskom periodu. Procjena boniteta je od ključne važnosti u poslovanju jer pomaže u smanjenju rizika prilikom stupanja u razne poslovne odnose. Naime, procjena boniteta je stručan i opsežan posao koji zahtjeva detaljnu analizu temeljnih financijskih izvještaja. U prošlosti su se za procjenu boniteta hotela koristili isključivo kvantitativni, financijski pokazatelji, dok se u današnje vrijeme sve više koriste i kvalitativni pokazatelji kao što su podaci o organizacijskoj strukturi, organizacijskoj kulturi, ugledu itd.

Danas postoje razvijeni softverski paketi za korištene metode, te ih se može koristiti vrlo lako i jednostavno, bez ulaženja duboko u matematički dio modela. Izabrani su financijski pokazatelji koji se smatraju presudnim za donošenje odluke tj. oni koji najbolje pokazuju stanje promatranog hotelskog poduzeća. Iz izračunatih podataka se vidi da neki hoteli iz uzorka posluju jako dobro, a neki su u gubitku. Kao razloge navodimo domovinski rat, način privatizacije i situaciju u gospodarstvu.

Da bismo izabrali najbolju alternativu tj. hotel s najboljim bonitetom koristili smo metodu PROMETHEE. Ova metoda vrši usporedbu i rangiranje više alternativa ocjenjenih na temelju više kvantitativnih kriterija. Metodu PROMETHEE I koristimo kada želimo prikazati djelomičan poredak alternativa, a metodu PROMETHEE II za potpuni poredak. Njezine prednosti su : jednostavnost, postojanje ekonomskog objašnjenja i značaja korištenih parametara, te potpuna eliminacija efekata rangiranja. Računanje smo izvršili pomoću kompjuterskog programa Decision Lab.

LITERATURA

KNJIGE:

1. Anić, Š., Klaić, N., Domović, Ž. (1998); Rječnik stranih riječi a/ž, Nacionalna i sveučilišna knjižnica, Zagreb.

2. Babić, Z. (2011); Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split.

3. Cerović, Z. (2003); Hotelski menadžment, Fakultet za turistički i hotelski menadžment, Opatija.

4. Dražić-Lutilsky, I., Gulin, D., Mamić-Sačer, I., Tadijančević, S., Tušek, B., Vašiček, V., Žager, K. (2010); Računovodstvo, Ekonomski fakultet Zagreb, Zagreb.

5. Đikandić, D. (1999); Zakon o porezu na dodanu vrijednost, Informator, Zagreb.

6. Ekonomski leksikon (1995); Leksikografski zavod „Miroslav Krleža“, Zagreb.

7. Figueira, J., Greco, S., Ehrgott, M. (2005); Multiple criteria decision analysis: State of the art surveys, Springer science, Boston.

8. Jelavić, A., Ravlić, P., Starčević, A., Šamanović, J. (1993); Ekonomika poduzeća, Ekonomski fakultet, Zagreb.

9. Leko, V. (1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb.

10. Popović, Ž. (1979); Ekonomska analiza poslovanja, Informator, Zagreb.

11. Saaty, T. (2001); *Decision making for leaders – The analiytic hierarchy process for decisio in a complex world*, RWS Publications, Pitsburgh USA.

12. Vidučić, Lj. (2004); Financijski menadžment, RRIF-plus, Zagreb.

13. Vukonić, B. (2005); Povijest hrvatskog turizma, Prometej, Zagreb.

14. Žager, K., Mamić-Sačer, I., Sever, S., Žager, L. (2008); Analiza financijskih izvještaja, Masmedia d.o.o., Zagreb.

ČASOPISI:

1. Babić, Z., Plazibat, N.(1998): Ranking of enterprises based on multicriterial analysis, International Journal of Production Economics, Vol.56-57, str. 29-35.

2. Behzadian, M., Kazemzadeh, R.B., Albadvi, A., Aghdasi, M.(2010): PROMETHEE: A comprehensive literature review on methodologies and applications, European Journal of Operational Research,Vol. 200, str.198-215.

3. Macharis, C., Springael, J., De Brucker, K., Verbeke, A.(2004): PROMETHEE and AHP: The design of operational synergies in multicriteria analysis. Strengthening PROMETHEE with ideas of AHP, European Journal of Operational Research,Vol. 153, str.307-317.

4. Pavić, I., Babić, Z.(1991): The use of the PROMETHEE method in the location choice of a production system, International Journal of Production Economics, Vol.23, str. 165-174.

5. Vaidya, O.S., Kumar, S.(2006): Analytic hierarchy process: An overview of applications, European Journal of Operational Research, Vol.169, str.1-29.

INTERNET IZVORI:

- Financijska agencija – Fina (http://www.fina.hr/)
- Portal poslovna Hrvatska (https://poslovna.hr/)
- Ministarstvo turizma Republike Hrvatske (http://www.mint.hr/)
- Hrvatska turistička zajednica (http://croatia.hr/hr-HR/)
- Hrvatska gospodarska komora (http://web.hgk.hr/)
- Booking.com (http://booking.com/)

POPIS TABLICA

1. Shema bilance u RH……..14
2. Shema računa dobiti i gubitka u RH…….19
3. Izvještaj o novčanom toku (direktna metoda)……...21
4. Skala ocjena rejtinga…….29
5. Pregled tipova hotela prema različitim kriterijima razvrstavanja…….33
6. Pregled kategorija hotel u RH……...34
7. Faze razvoja hotelijerstva u RH……38
8. Saatyeva skala važnosti i njen opis……...48
9. Slučajni indeks koeficijenata konzistentnosti……...50
10. PROMETHEE I – parcijalni uređaj……..61
11. Financijski pokazatelji za procjenu boniteta…….62
12. Kvalitativni kriteriji……...67
13. Matrica međusobnih usporedbi…….69
14. Transformirana matrica A'……69
15. Težine kriterija……..70
16. Tablica odluke……...72
17. Ulazni, izlazni i neto tokovi……..74
18. Rang alternativa……75
19. Konačan poredak hotela od najboljeg do najlošijeg…….77

POPIS SLIKA

1. „dobra bilanca“……..…15
2. „još bolja bilanca“…….16
3. „loša bilanca“……16
4. Obični kriterij……55
5. Kvazi kriterij…….56
6. Kriterij s linearnom preferencijom……56
7. Nivo kriterij……...57
8. Kriterij s linearnom preferencijom i područjem indiferencije……..58
9. Gaussov kriterij…….58
10. ∏(a,b) i ∏(b,a)…….60
11. Ulazni podaci u programu Expert Choice…….71

12. Težine kriterija dobivene programom Expert Choice……...71
13. Ulazni podaci za PROMETHEE metodu – program Decision Lab……..74
14. PROMETHEE I – parcijalni uređaj……..76
15. PROMETHEE II – kompletni poredak alternativa……...76