PRIMJENA VIŠEKRITERIJALNE ANALIZE NA PROBLEM LOKACIJE ZA IZGRADNJU HOTELA

Lolić, Mislav

Undergraduate thesis / Završni rad

2019

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:124:897353

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

ZAVRŠNI RAD

PRIMJENA VIŠEKRITERIJALNE ANALIZE NA PROBLEM LOKACIJE ZA IZGRADNJU HOTELA

Mentor:

Prof. dr. sc. Zoran Babić

Student:

Mislav Lolić

Split, rujan 2019.

SADRŽAJ:

1. UVOD 4

2. DEFINIRANJE POTENCIJALNIH LOKACIJA 6

2.1. Otok Hvar 6

2.1.1. Stari Grad na otoku Hvaru 6

2.1.2. Jelsa na otoku Hvaru 7

2.2. Split 8

2.2.1. Zapadna obala; Hotel Marjan 9

2.2.2. Žnjan; hotel Amphora 10

2.2.3. Zapadna obala; zgrada Banovine 11

2.2.4. Dalmatia Tower 12

2.3. Podstrana (Gornja Podstrana) 13

2.4. Žrnovnica (Žvoraj) 15

2.5. Omiš (izvan grada uz tok Cetine) 16

3. DEFINIRANJE I OPIS ODABRANIH KRITERIJA 17

3.1. Očekivani prihod 18

3.2. Troškovi 18

3.3. Atraktivnost čestice 18

3.4. Imidž destinacije 19

3.5. Blizina/pristupačnost generatorima ponude i potražnje 19

3.6. Izvedivost 19

3.7. Otvorenost lokalne samouprave za suradnju 19

3.8. Konkurencija 20

3.9. Postojanost potrebnih ljudskih resursa 20

4. VREDNOVANJE LOKACIJA NA TEMELJU ODABRANIH KRITERIJA 21

4.1. Metode vrednovanja alternativnih lokacija 21

4.1.1. Višekriterijalna analiza 21

4.1.2. Osnovni pojmovi višeatributnog odlučivanja 23

4.1.3. Procjena važnosti kriterija 24

4.1.3.1. Rangiranje 26

4.1.3.2. Ocjenjivanje 27

4.1.4. Klasifikacija MCDM metoda 27

4.1.4.1. Metoda AHP 28
4.1.4.2. Metoda ELECTRE 29
4.1.4.3. PROMETHEE 30
4.2. Softver Decision Lab 39
4.3. Postupak vrednovanja alternativnih lokacija na temelju odabranih kriterija.. 41
4.4. Matrica odluke 43
4.5. Analiza rješenja 44
5. ZAKLJUČAK 48
6. LITERATURA 50
7. SAŽETAK 51
8. SUMMARY 52

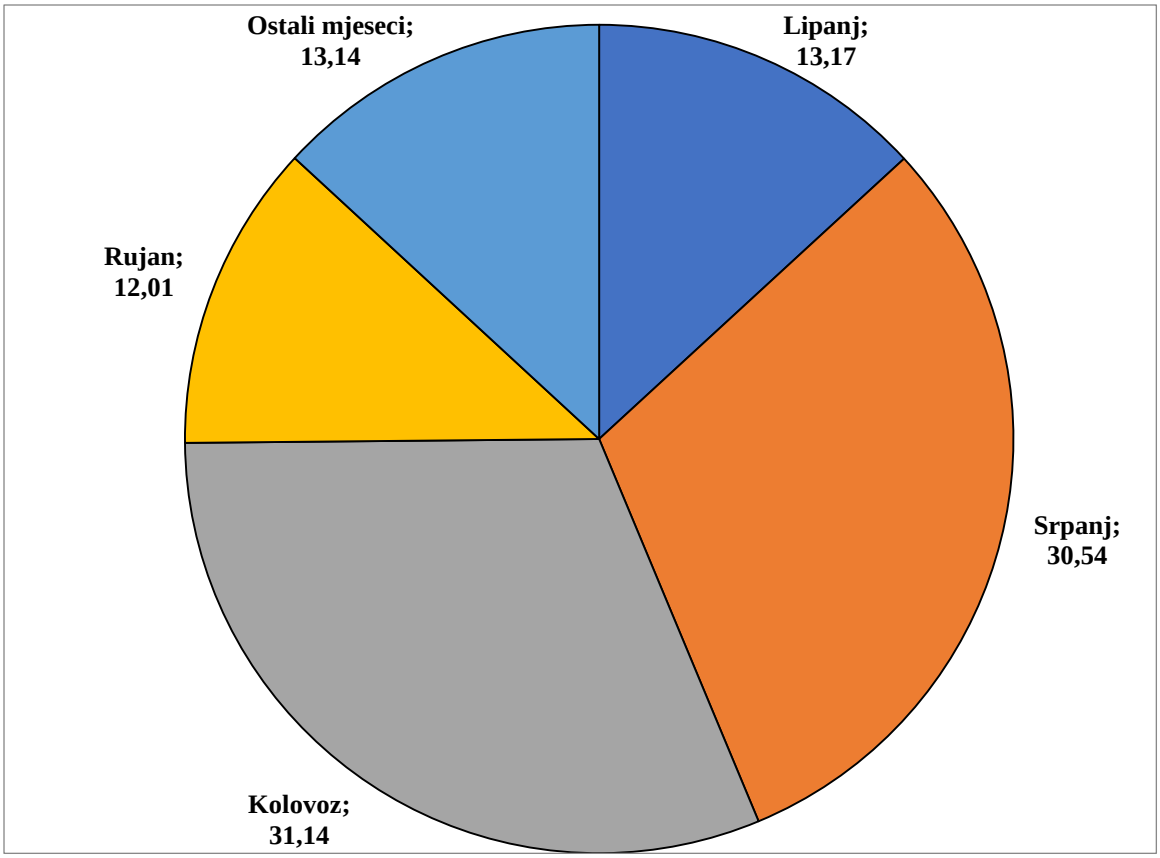
1. UVOD

Lokacija predstavlja jedan od najvažnijih faktora o kojem ovisi uspješnost poslovanja hotela. Uz lokaciju su vrlo važni i kvaliteta same usluge, postojanje dodane vrijednosti u usluzi, ljubaznost osoblja i slično, ali važnost lokacije na uspješnost poslovanja je neupitna. Sama lokacija uvelike utječe i na značajke hotela poput veličine hotela, broja katova, broja i rasporeda soba, dodatne usluge koje će se u hotelu moći pružati gostima i slično. Stoga će se u radu analizirati devet proizvoljno odabranih lokacija za gradnju hotela na području Splitsko-dalmatinske županije. Svaka od devet lokacija će se vrednovati prema devet opisanih kriterija, a odabranom metodom višekriterijalne analize izabrat će se i optimalna lokacija.

Ukupni udio turizma (Travel & Tourism) u BDP-u Hrvatske je prema procjenama WTTC-a[6] za prošlu godinu iznosio čak 25%, a predviđa se kako će utjecaj do 2028. godine sudjelovati sa čak 31,7% BDP-a. U skladu s tim, sve je veća potreba za poboljšanjem i povećanjem ponude, kako sezonske, tako i vansezonske na području Republike Hrvatske. Prema podacima Ministarstva turizma[2], u Hrvatskoj trenutno postoji 746 hotela različite kategorizacije i vrste (hotel, hotel baština, difuzni hotel, integralni hotel te hoteli posebnog standarda), od čega ih je 39 kategorizirano s pet zvjezdica. Ako se taj broj suzi samo na Splitsko-dalmatinsku županiju postoji tek pet hotela ocijenjenih s pet zvjezdica, 77 hotela sa četiri zvjezdice, sedam heritage hotela sa četiri zvjezdice, jedan heritage hotel sa tri zvjezdice, 11 heritage hotela bez zvjezdica i dva integralna hotela.

Podaci kojima se raspolaže iz eVisitor[3,4] sustava iz 2018. godine nam otkrivaju kako je porast turističkog prometa na razini države iznosio 4% u odnosu na 2017. godinu, dok je porast prometa naše županije bio najveći u državi, a iznosio 6% u odnosu na prethodnu godinu. Ti podaci ukazuju na početak zasićenja turista postojećom ponudom, ne samo u našoj županiji, već i na razini Republike Hrvatske, a porastom konkurencije na Mediteranu, te ponovnom afirmacijom Turske i Grčke, potreban je pomak u razini turističke ponude.

Podaci iz sustava eVisitor o broju noćenja po pojedinim mjesecima na području Splitsko-dalmatinske županije i dalje izgledaju poprilično sezonski. Osim toga, sezona je jako kratka jer se odnosi samo na mjesece srpanj i kolovoz koji utječu na broj noćenja sa 61,68% što ipak predstavlja smanjenje u odnosu na prethodnu godinu. Ako period proširimo na lipanj i rujan, ta četiri mjeseca utječu na ukupan broj noćenja sa čak 86,86%, a to znači da na preostalih osam mjeseci otpada svega 13% noćenja što govori o ozbiljnosti potrebe za upotpunjavanjem turističke ponude i izvan sezone.



Graf 1: Struktura noćenja turista po mjesecima 2018. godine

Izvor: Statistička analiza turističkog prometa 2018

Sve navedeno je vidljivo i u istraživanju TOMAS[5] iz 2017. godine koje navodi kako gostima najviše nedostaje sadržaja kada su vremenske prilike loše, biciklističkih staza, bogatstva sportskih sadržaja te prezentacija kulturne baštine; sve faktori na koje je moguće utjecati i pružanjem dodatnih usluga u vrhunskim hotelima.

2. DEFINIRANJE POTENCIJALNIH LOKACIJA

Proizvoljno je izabrano devet potencijalnih lokacija za gradnju hotela na području naše županije. Na sljedećim stranicama one će biti i detaljno definirane.

2.1.Otok Hvar

Otok Hvar prezentirao se kao idilična destinacija i za turiste koji traže samo neprestanu zabavu i izležavanje na plaži, ali i one koji su u potrazi za aktivnim odmorom i željni rekreacije. Dok grad Hvar prednjači po pitanju zabavnih sadržaja, njegovi konkurenti na otoku, Stari Grad i Jelsa, preuzeli primat što se tiče aktivnog odmora, ponajprije po pitanju biciklističkog turizma.

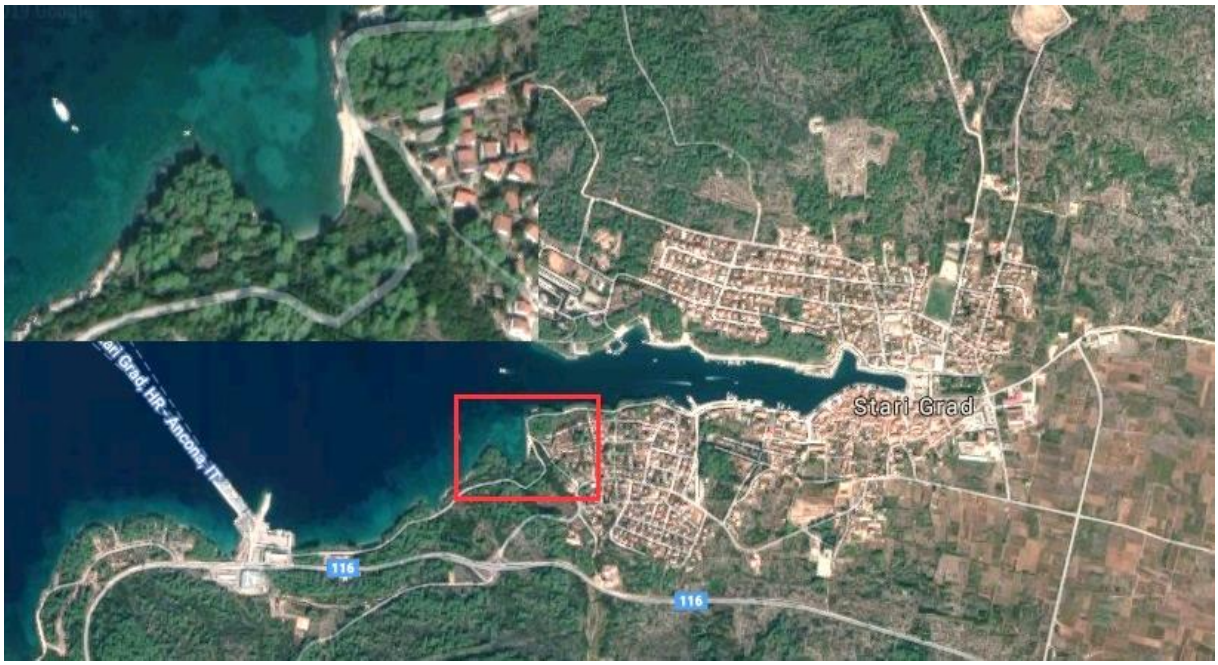
Upravo je biciklistički turizam vrlo popularan vid turizma na otoku Hvaru, a prednost tog tipa turizma je ta što je vrlo atraktivna izvan glavne sezone, ali i izvan četiri toplija mjeseca (lipanj-rujan) što otvara mogućnost za povećanjem vansezonske posjećenosti i potrošnje u sektoru turizma.

Daljnjim ulaganjem u biciklističke staze, ali i šetnice, te specijalizacijom novoizgrađenih hotela ka takozvanim „Bike hotelima“, poput hotela Split u Podstrani, Stari Grad i Jelsa se mogu prometnuti u prva imena kada je biciklistički turizam u pitanju. Prema podacima Ministarstva turizma na otoku Hvaru trenutno postoje četiri hotela s četiri zvjezdice, a sva četiri se nalaze u gradu Hvaru.

2.1.1. Stari Grad na otoku Hvaru

Stari Grad kao trajektno, ali i katamaransko pristanište otoka Hvara odlično je povezan sa gradom Splitom i izvan glavne turističke sezone. Grad je smješten u uvali i okružen prirodom, a s obzirom da prema podacima Ministarstva turizma u gradu postoje samo dva hotela, i to oba sa dvije zvjezdice, Stari Grad se prometnuo u lokaciju koja itekako ima prostora za napredak po pitanju kvalitete smještajnih kapaciteta.

Podaci o broju noćenja iz sustava eVisitor za 2018. godinu Stari Grad svrstavaju tek na treće mjesto po posjećenosti na otoku Hvaru što pokazuje koliko je njegova povezanost slabo iskorištena. Sa 233 062 noćenja u 2018. godini, Stari Grad je zapravo ostvario lošiji rezultat nego u prethodnoj što je prvi primjer zasićenja gostiju postojećom turističkom ponudom na području naše županije.



Slika 1: Lokacija hotela u Starom Gradu, otok Hvar

Izvor: Google karte

Točna lokacija za gradnju hotela bi bila zapadno od centra grada na maloj uvali koja se nalazi u blizini Ulice Augusta Cesarca. Podjednako blizu, ali i daleko od gradske vreve, posebno u ljetnim mjesecima, lociran u uvali, s postojanim, ali i derutnim pristupnim putem te šetnicom, lokacija ima potencijala za gradnju hotela koji bi bio na pola puta od trajektne luke do centra grada, ali samim time imao i svoju privatnost koju većina gostiju i traži na ljetovanju.

2.1.2. Jelsa na otoku Hvaru

Jelsa se prometnula u drugu destinaciju na otoku Hvaru, odmah iza grada Hvara. S brojem noćenja koji je prema podacima sustava eVisitor lani dosegao brojku od 446 749 također bilježi lagani pad u odnosu na 2017. godinu. Jelsa, za razliku od Starog Grada raspolaže sa većim brojem smještajnih kapaciteta. Prema podacima Ministarstva turizma, u Jelsi postoji jedan hotel, ali i dva kampa koja su uređena na vrlo visokoj razini što predstavlja konkurenciju u vidu aktivnog turizma.

Grad je sa ostalim otocima i kopnom, za razliku od Starog Grada, povezan samo katamarnskim linijama, kako Jadrolinije, tako i privatnih brodoprijevoznika. Međutim, ne radi se o prevelikom nedostatku jer katamaranskih linija ima sasvim dovoljno, ali ni trajektna luka

u Starom Gradu nije predaleko, tako da se gosti mogu odvažiti i na samostalnu biciklističku avanturu.



Slika 2: Lokacija hotela u Jelsi, otok Hvar

Izvor: Google karte

Točna lokacija za gradnju hotela u Jelsi bi bila uvala na slici. Lokacija je najbliža ulici Lučica, a prednost joj je, kao i kod lokacije u Starom Gradu to što je dovoljno udaljena od centra mjesta da se uživa u miru i u prirodi, ali isto tako nije predaleko, pa gosti i dalje mogu uživati u večerama u obližnjim vinarijama i restoranima bez da koriste svoje automobile. U neposrednoj blizini se nalazi i pristupna cesta kojom je moguće stići do glavne prometnice na otoku koja povezuje gradove od Hvara sve do Sućurja na drugom kraju otoka.

2.2. Split

Grad Split apsolutni je predvodnik turizma i turističkog razvoja na području naše županije što je i logično s obzirom da je drugi po veličini grad u Republici Hrvatskoj. Odavno poznati problemi prometne infrastrukture koji se iz godine u godinu ponavljaju ostavljaju traga i na dojmu kod turista koji se može vidjeti i na TOMAS istraživanju iz 2017. godine gdje su gosti kao negativno iskustvo naveli i lošu organizaciju prometa u gradu.

Unatoč tome, Split je za razliku od prije spomenutih, Starog Grada i Jelse, ostvario pozitivan pomak po broju noćenja u 2018. godini u odnosu na prethodnu. Tako je 2018.

godine ostvareno 2 510 171 noćenje, dok je u prethodnoj godini taj broj stao na 2 203 315 noćenja. Trajektna luka te autobusni i željeznički kolodvor koji su smješteni u samom centru grada kao i nedavno pokrenuti projekt Splitski metro omogućuju svim posjetiteljima neometanu povezanost, kako sa otocima, tako i s ostatkom Hrvatske. Uz to, zračna luka u Kaštelima koja je ove godine dobila i proširenje terminala, svake sezone ostvaruje sve veći broj putnika, a u 2018. godini ostvarena je brojka od 3 124 067 putnika.

Split kao turistička destinacija omogućuje turistima sve oblike turizma, od onog aktivnijeg do ležernijeg, a prema podacima Ministarstva turizma, grad raspolaže sa 15 hotela s četiri zvjezdice, tri heritage hotela s četiri zvjezdice te dva hotela s pet zvjezdica.

Na području Splita proizvoljno su odabrane četiri lokacije za gradnju hotela, svaka sa svojim manama i prednostima te će se svaku pojedinačno opisati i analizirati, a to su zgrade hotela Marjan i Banovine na Zapadnoj obali, zgrada hotela Amphora na Žnjanu koja je u izgradnji te Dalmatia Tower koji je u izgradnji na Kopilici.

2.2.1. Zapadna obala; Hotel Marjan

Izgrađen sada već davne 2008. godine, zgrada hotela Marjan zjapi prazna već 11 godina. Početkom ove godine hotel je stavljen i na javnu dražbu, a njegova vrijednost je procijenjena na 432,062 milijuna kuna. Lociran na samom središtu Zapadne obale, hotel se nalazi na izvrsnoj lokaciji nedaleko od centra grada, ali i nadomak Marjana, a u okolini se nalazi i popriličan broj ekskluzivnih restorana i kafića.

Osim toga, u blizini je i ACI Marina, poznate splitske plaže Kašjuni i Obojena, te čitav niz agencija koje turistima na raspolaganje stavljaju brojne ture, automobile na najam i ostale usluge koje mogu gostima olakšati njihov boravak u Splitu.



Slika 3: Lokacija hotela Marjan na Zapadnoj obali, Split

Izvor: Google karte

Samim time što se nalazi na Zapadnoj obali, gosti mogu zaobići čvor koji svakodnevno nastaje na križanju Zvonimirove i Zagrebačke ulice jer se do hotela stiže Marjanskim tunelom. Osim toga, ukoliko gosti hotela dolaze na autobusni ili željeznički kolodvor mogu se jednostavno prošetati preko Rive ako im nije do čekanja na javni prijevoz ili korištenja taxi usluga.

2.2.2. Žnjan; hotel Amphora

Iduća splitska lokacija je već u izgradnji, a riječ je o hotelu Amphora čiji bi se završetak gradnje trebao dogoditi u 2020. godini. Jedna od najpoznatijih splitskih plaža o kojoj se mnogo raspravlja i u pogledu javnog natječaja za preuređenje predstavlja ogromni, ali dosad neiskorišteni potencijal u povećanju turističke ponude grada Splita.



Slika 4: Lokacija hotela Amphora na Žnjanu, Split

Izvor: Google karte

Lociran na samom kraju splitske plaže, hotel gostima u isto vrijeme omogućava privatnost, ali i mogućnost vođenja aktivnog odmora zbog šetnica koje se prostiru duž plaže i prema centru grada, ali i prema gradskom kotaru Duilovo.

Za razliku od hotela Marjan, hotel Amphora se nalazi podalje od centra grada, ali je samim time bliže ulazu u grad, pa se mogu izbjeći i nesnošljive gradske gužve. Nedaleko je i od dva gradska shopping centra, City Center One i Mall of Split, a s obzirom da se radi i na velikom preuređenju splitske plaže, navedena lokacija ima brojne prednosti.

2.2.3. Zapadna obala; zgrada Banovine

Zgrada Banovine, dom splitske gradske uprave, već je nekoliko puta spominjana u kontekstu moguće preobrazbe u luksuzni hotel. Smještena na samom kraju Zapadne obale, zgrada je, kao i hotel Marjan, u neposrednoj blizini ACI Marine i park-šume Marjan.

Upravo bi blizina Marjana gostima dala mogućnost uživanja u aktivnom odmoru, a gosti koji žele samo uživati u moru i na suncu mogu posjetiti plaže Kašjuni i Obojena koji su nedaleko od zgrade. Gradska uprava bi se prebacila na neku drugu lokaciju, a Split bi dobio još jedan vrhunski uređen hotel u svojoj turističkoj ponudi.



Slika 5: Lokacija zgrade Banovine na Zapadnoj obali, Split

Izvor: Google karte

Kao i hotel Marjan, eventualna gradnja hotela na lokaciji zgrade Banovine bi gostima omogućila luksuzan boravak dovoljno blizu centra grada da se mogu prošetati do Rive, ali i dovoljno izvan dohvata samog centra i gradske vreve kako bi se gosti mogli u miru odmoriti.

2.2.4. Dalmatia Tower

Prvi Marriott hotel u Hrvatskoj gradi se u Splitu, a otvaranje se očekuje 2020. godine, iako je bilo planirano za ovu godinu. Najviša zgrada u Republici Hrvatskoj je planirana kao business hotel, namijenjen za poslovne ljude, te je s razlogom izabrana lokacija na križanju Dubrovačke ulice i Ulice Domovinskog rata. Zgrada do, centar OTP Banke u Hrvatskoj ima prizemlje i 12 katova, dok će Marriottov hotel imati prizemlje i 27 katova koji se protežu na visinu od 115 metara što ga čini najvišom zgradom u Hrvatskoj.

Udaljen od gradske gužve, ali i nadomak kolodvora na Kopilici koji je u planovima za pretvaranje u moderan autobusni i željeznički kolodvor, omogućio bi gostima brz transport od Splita do zračne luke u Kaštelima. Osim toga, uvođenjem splitskog metroa u funkciju, gosti hotela bi mogli brzo i lako doći do centra grada gdje se nalazi trajektna luka.



Slika 6: Lokacija zgrade Dalmatia Tower na Kopilici, Split

Izvor: Google karte

Dalmtia Tower predstavlja prvu izravnu investiciju Marriott grupacije u Republici Hrvatskoj čime se stječe dojam da turizam u našoj državi ima još mnogo prostora za napredak.

2.3. Podstrana (Gornja Podstrana)

Općina Podstrana smještena je nadomak Splita i svake godine ostvaruje sve bolje rezultate u pogledu dolazaka i broja noćenja turista. Tako je prema podacima eVisitora iz 2018. godine, Podstrana ostvarila 648 139 noćenja što je povećanje u odnosu na 626 907 noćenja iz prethodne godine. Popis registriranih turističkih objekata u Republici Hrvatskoj navodi kako se na području Podstrane nalaze dva hotela sa tri zvjezdice, tri hotela koji imaju četiri zvjezdice te LeMeridien Lav kao jedan od pet hotela sa pet zvjezdica na području Splitsko-dalmatinske županije.

Kao i kod Splita, prometna infrastruktura veliki je nedostatak turističkog razvoja Podstrane. Cijelo mjesto je povezano samo prometnicom D8 koje ima tek po jednu traku u svakom smjeru što uvelike otežava svakodnevan život i gostima i stanovnicima mjesta. Moguća gradnja obilaznice Trogir-Omiš uvelike bi umanjila gustoću prometa i gužve koje su

svakodnevnica, ali i skratila vrijeme potrebno da bi se prešla navedena lokacija. Međutim, nedavno započeti projekti preuređenja plaže od ušća rijeke Žrnovnice do marine te planovi uređenja šetnice i biciklističke staze uz sam tok rijeke Žrnovnice daju poticaj za budućnost turizma na području mjesta.



Slika 7: Lokacija hotela u Gornjoj Podstrani

Izvor: Google karte

Točna lokacija za gradnju hotela bila bi u Gornjoj Podstrani, prema brdu Perun. Na navedenoj lokaciji se ne bi gradio luksuzni hotel od stotinu i više soba, već hotel manjih dimenzija koji bi imao kategorizaciju heritage hotela (hotel baština) uređen u tradicionalnom stilu koji je prikladan za podneblje koje pripada Poljičkoj Republici.

Uz to, nedovoljno istražena priča o kralju Arturu koji je navodno pokopan u Podstrani bila bi jedna od glavnih točaka za promociju hotela i privlačenje gostiju. Blizina Peruna predstavlja idealnu lokaciju i za turiste koji traže aktivan odmor, bilo da se radi o planinarenju ili biciklističkom turizmu.

2.4. Žrnovnica (Žvoraj)

Na području Žrnovnice, koje pripada gradu Splitu ne postoji nijedan hotel. Sukladno tome, podaci kojima raspolažemo iz sustava eVisitor ne prikazuju podatke zasebno za Žrnovnicu kao destinaciju.

Međutim, turizma u mjestu ima, a konkurenciju bi na ovoj lokaciji predstavljali privatni iznajmljivači u vidu apartmana i kuća za odmor. Upravo to je razlog odabira ove lokacije za gradnju hotela.



Slika 8: Lokacija hotela na Žvoraju, Žrnovnica

Izvor: Google karte

Kao i kod Podstrane, u Žrnovnici bi na ovoj lokaciji izgradili manji hotel (hotel baština) koji bi se specijalizirao u aktivni turizam. Zbog položaja na Mosoru, gosti bi se mogli baviti planinarenjem, brdskim biciklizmom i uživanjem u prirodi.

Pristupne ceste zahtijevaju poprilične zahvate kako bi ih se dovelo u red, ali potencijal koji lokacija ima bi opravdao uložen novac.

2.5. Omiš (izvan grada uz tok Cetine)

Nakon Splita i Podstrane, Omiš je još jedan grad koji uvelike pati zbog prometne infrastrukture. Stalne gužve, ceste koje traže obnovu su svakodnevnica i za lokalno stanovništvo i za goste. Međutim, prema brojkama iz sustava eVisitor to ne utječe negativno na broj noćenja koji je prijavljen za Omiš. U 2018. godini ostvareno je 990 513 noćenja što je povećanje u odnosu na 2017. godinu kada je prijavljeno 941 164 noćenje.

Imajući u vidu trend porasta broja noćenja, turistički potencijal Omiša predstavlja ga kao zanimljivu lokaciju za daljnje investicije, ali i predstavlja potrebu za prije spomenutu obilaznicu Trogir-Omiš. Na području Omiša, prema Popisu kategoriziranih turističkih objekata postoji jedan hotel sa tri zvjezdice te dva hotela sa četiri zvjezdice.

Međutim, svaki od njih je građen uz more, zato bi lokacija predviđena za gradnju novog hotela bila posebna u odnosu na postojeće.



Slika 9: Lokacija hotela u Omišu

Izvor: Google karte

Točna lokacija za gradnju hotela bila bi uz tok rijeke Cetine, a kao i u slučaju Podstrane i Žrnovnice, nije planirana gradnja luksuznog hotela već manjeg hotela. Zbog povijesti mjesta, hotel baština se predstavlja kao logičan izbor zbog postojanja Poljičke

Republike. Povijest, tradicija i kultura koju pruža ta činjenica mogli bi se kvalitetno iskoristiti u svrhe marketinga i privlačenja gostiju. Osim toga, prirodne ljepote poput kanjona rijeke Cetine i mogućnosti bavljenja aktivnim turizmom u vidu raftinga, također bi pozitivno utjecale na odluku o gradnji hotela upravo na navedenoj lokaciji.

3. DEFINIRANJE I OPIS ODABRANIH KRITERIJA

Kako bi se došlo do egzaktnih podataka koji bi se mogli uspoređivati, važno je u model unijeti i kriterije po kojima će se vrednovati svaka od mogućih lokacija za gradnju. Navedene lokacije su:

a) Jelsa na otoku Hvaru
b) Stari Grad na otoku Hvaru
c) zgrada Banovine u Splitu
d) zgrada hotela Amphora na Žnjanu u Splitu
e) zgrada hotela Marriott na Kopilici u Splitu
f) zgrada hotela Marjan na Zapadnoj obali u Splitu
g) Gornja Podstrana
h) Žvoraj (Žrnovnica)
i) Omiš.

Sve lokacije imaju određene prednosti i mane, a vrsta hotela koji bi se gradio bi se razlikovala od lokacije do lokacije. U svrhu provedbe evaluacije, u nastavku rada je opisano devet različitih kriterija koji ulaze u obzir pri evaluaciji. Tih devet kriterija su sljedeći:

a) Očekivani prihod
b) Razni troškovi
c) Atraktivnost čestice
d) Imidž destinacije
e) Blizina/pristupačnost generatorima ponude i potražnje
f) Izvedivost
g) Otvorenost lokalne samouprave za suradnju
h) Konkurencija
i) Postojanost potencijalnih ljudskih resursa u blizini

Svakom od navedenih kriterija će biti pridružena određena kvantitativna vrijednost na mjernoj skali od jedan (1) do deset (10). Navedene vrijednosti su kriterijima dodijeljene od strane autora rada u suradnji s ekspertnim timom.

3.1.Očekivani prihod

Prihod koji se očekuje od poslovanja hotela na određenoj lokaciji predstavlja kriterij od najveće važnosti jer likvidnost i rentabilnost svakog poslovnog subjekta, pa tako i hotela je ono čemu se teži. Prihod hotela može biti izravan i neizravan. Izravan prihod bio bi prihod od noćenja gostiju, a neizravan prihod bi bio korištenje usluga kockarnice, teretane, wellnessa, restorana, najam konferencijskih dvorana i slično, u sklopu objekta od strane lokalnog stanovništva, ukoliko su iste usluge prisutne.

3.2.Troškovi

Podjednako važni kao i očekivani prihod hotela, upravo je troškove potrebno kvalitetno analizirati zbog većeg obujma investicija u početnim fazama. Troškovi izrade plana i projekta, dobivanja dozvola predstavljaju početne troškove koji su preduvjet svim ostalim. Nakon toga, troškovi kupnje postojeće zgrade kao u slučajevima Banovine ili hotela Marjan, ili cijena kvadrata u slučaju gradnje na lokacijama u Jelsi, Stari Gradu ili Gornjoj Podstrani predstavljaju poveće troškove u početnoj fazi gradnje hotela. Sama gradnja, cijena i dopremanje građevinskog materijala, plaće građevinara i zaposlenika, pa troškovi održavanja i amortizacije, uglavnom predstavljaju varijabilne troškove koji ponajviše ovise o obujmu posla.

3.3.Atraktivnost čestice

Sama čestica na kojoj bi se gradio hotel bitno utječe i na veličinu hotela, broj soba, samim time i na troškove, ali i prihode koji bi se mogli ostvarivati. Tako na primjer, u Podstrani bi se gradio manji hotel baština sa nekoliko desetaka soba, dok bi se na Žnjanu ili na lokacijama na Zapadnoj obali gradili hoteli resort tipa sa par stotina soba i dodatnim

sadržajima poput kockarnica ili trgovina. Osim toga, na atraktivnost utječe i prirodna vizura susjedstva u kojem bi se hotel nalazio, eventualna buka uzrokovana čestim prometom vozila u neposrednoj blizini te blizina centra mjesta.

3.4.Imidž destinacije

Svaka destinacija ima svoj imidž, svoju prepoznatljivost među raznim agencijama i touroperatorima, ali i samim turistima. Osim toga, marketinški potencijal lokacije i mjesta gdje bi se eventualno gradio hotel, prepoznatljivost među gostima te njihova prethodna iskustva također utječu na ugled koji destinacija ima u turističkom svijetu.

3.5.Blizina/pristupačnost generatorima ponude i potražnje

Generatori ponude i potražnje, povezanost hotela sa istima i njihova prisutnost u blizini hotela također utječe na odluku o lokaciji za gradnju hotela. Među generatore ponude navodimo povezanost lokacije sa zračnom lukom, trajektnom lukom, autobusnim i željezničkim kolodvorom. S druge strane, pod generatore potražnje mogli bi navesti razne ture koje nude obližnje agencije ili hotel u suradnji s istima; plaže, restorane, luke i marine u blizini lokacije ili unutar samoga kompleksa hotela; muzeje, kazališta, znamenitosti, shopping centre i maloprodaju, biciklističke staze, planinarske puteve, bolnice i sve što bi eventualno bilo potrebno turistima za vrijeme njihova boravka u određenoj lokaciji.

3.6.Izvedivost

Velik utjecaj na odluku o lokaciji za gradnju hotela bila bi i izvedivost. Pitanje da li je lokacija u „zelenoj zoni“ ili nije upisana u zemljišnik kao građevinsko zemljište; da li je lokacija već povezana na električnu mrežu, kanalizacijski sustav, vodovod i plinovod; da li je čestica dovoljno velika za izgradnju cijelog hotela sa svim sobama i popratnim sadržajima. Sva ta pitanja zahtijevaju odgovore prije odluke o lokaciji jer i oni utječu na financijski aspekt odabira lokacije, ponajviše u pogledu eventualnih troškova.

3.7.Otvorenost lokalne samouprave za suradnju

Lokalna samouprava predstavlja velikog saveznika kada su u pitanju velike investicije. Svako mjesto na području Splitsko-dalmatinske županije želi podići razinu usluge u mjestu na višu razinu. Stoga su u gradskim vlastima često otvoreni prema većim investicijama poput gradnje hotela. Izmjene GUP-a ukoliko su potrebne, prethodna iskustva investitora sa lokalnom samoupravom u pogledu dobivanja dozvola ili brzine donošenja odluka također utječu na odluku o mjestu gradnje hotela. Lokalna samouprava raspolaže znatnim sredstvima, ali ima i know-how po pitanju povlačenja sredstava iz EU fondova ili ostalih potpora, bilo državne, bilo županijske razine.

3.8.Konkurencija

Konkurencija također predstavlja jednu od varijabli koja utječe na odluku o lokaciji gradnje hotela. Postojeća konkurencija ne moraju biti samo hoteli, već mogu biti i privatni iznajmljivači sa luksuznim kućama za odmor, stoga bi uvidom u njihove poslovne rezultate u proteklom razdoblju investitor dobio okvirnu sliku turista koji posjećuju to mjesto. Osim toga, informacije o planovima za buduću gradnju također su od krucijalne važnosti.

3.9.Postojanost potrebnih ljudskih resursa

Svaki dan svjedoci smo novog vala iseljavanja stanovništva koje pripada radnom kontingentu. Stoga je od velike važnosti za investitora da analizira i trenutnu situaciju na tržištu rada, ne samo na određenoj lokaciji gdje bi gradio hotel, ili samo na području Splitsko-dalmatinske županije, već da ima kompletnu sliku tržišta rada na razini Republike Hrvatske. U slučaju potrebe za uvoženjem radnika iz drugih dijelova Hrvatske ili ostatka svijeta, investitor bi trebao osigurati smještaj i obroke za te radnike. U slučaju lokalnog stanovništva koje je dovoljno kvalitetno za rad u hotelu, voditelj odjela ljudskih resursa bi trebao osigurati da postojeća radna snaga ima dostatnu stručnu spremu i/ili iskustvo kako bi se smanjili troškovi potrebni za trening zaposlenika. Zbog svega navedenog, ova bi se varijabla trebala gledati i u kontekstu ukupnih troškova investicije.

4. VREDNOVANJE LOKACIJA NA TEMELJU ODABRANIH KRITERIJA

4.1. Metode vrednovanja alternativnih lokacija

4.1.1. Višekriterijalna analiza

Pojam višekriterijalnog odlučivanja (Multiple Criteria Decision Making - MCDM) odnosi se na donošenje odluka u prisutnosti više, najčešće konfliktnih kriterija. Većina problema koji pripadaju MCDM-u su često uobičajeni problemi iz svakodnevnog života. Tako je na primjer prilikom izbora posla potrebno razmatrati velik broj kriterija: prestiž, plaću, mogućnosti napredovanja, radne uvjete itd.

Kod kupnje automobila osnovni kriteriji bit će cijena, potrošnja goriva, sigurnost... Jedan od najboljih primjera višekriterijalnog problema u poslovnom kontekstu je izbor strategije poduzeća koju provodi rukovodeći tim. Naime, potrebno je razmatrati prihode kompanije kroz određeni vremenski period, kretanje na tržištu, razvoj konkurencije, razvoj novih tehnologija itd.[1]

Javni i vladini poslovi se također mogu svrstati pod probleme višekriterijalnog odlučivanja. Npr. plan razvoja vodnih resursa za neki predio mora se napraviti u odnosu na troškove, vjerojatnost nedostatka vode, energije, mora se uzeti u obzir i rekreacija, zaštita od poplava, kvaliteta vode, upotreba vode za navodnjavanje itd.

Vladini poslovi također moraju zadovoljavati i razmatrati niz kriterija. Izbor oružja i sredstava za vojsku također se mora temeljiti na nizu kriterija kao što su trošak, amortizacija, domet, brzina i slično.

Očito je da problemi kojima se bavi MCDM mogu biti veoma raznovrsni i pripadati različitim područjima ljudske aktivnosti. Međutim, usprkos raznovrsnosti, svi ti razmatrani problemi imaju neke zajedničke karakteristike. To su prije svega:

a) Višestrukost kriterija

Svaki problem MCDM ima više kriterija. Prvi, i često najvažniji posao donosioca odluke je uopće odabrati relevantne kriterije da bi se problem mogao korektno postaviti.

b) Konflikti među kriterijima

Veći broj kriterija najčešće su u međusobnom konfliktu (suprotnosti). Tako npr. dizajniranje automobila stvara konflikt u smislu da želja za što većim rezervoarom smanjuje komfor i korisni prostor za putnike.

c) Neusporedive jedinice mjere

Svaki kriterij najčešće ima svoju jedinicu mjere. U slučaju izbora automobila to su npr. potrošnja (l/km), komfor (m^3), sigurnost (opisno), troškovi (novčane jedinice) itd.

Postoje mnogi razlozi rastućeg interesa za višekriterijalno odlučivanje. Prvi i najvažniji je saznanje da je većina problema odlučivanja sama po sebi višekriterijalna. Čak i mnogi problemi koji se klasično razmatraju kao jednokriterijalni mogu se promatrati kao višekriterijalni.

Drugi važan razlog pojačanog interesa za višekriterijalno odlučivanje je izuzetan razvoj mogućnosti, brzine, kapaciteta i fleksibilnosti računskih strojeva. Naime, razvijeni su brojni algoritmi za rješavanje višekriterijalnih problema te su integrirani u softvere koji služe kao potpora donosiocu odluke prilikom rješavanja jednostavnijih, a ujedno i kompleksnijih problema.

Pored toga većina višekriterijalnih algoritama zahtijeva interaktivni pristup, tj. komunikaciju donosioca odluke i računara. Taj interaktivni pristup zahtijeva brze odgovore od računara, a i prilagodljivost stroja i programa pomoću kojeg se izvodi algoritam.

U višekriterijalnom odlučivanju važnu ulogu igra i donosilac odluke (decision maker). Donosilac odluke je osoba čije preferencije istraživač - analitičar treba modelirati u namjeri da se odabere najbolje kompromisno rješenje danog višekriterijalnog problema. Uloga donosioca odluke nije toliko bitna u rješavanju jednokriterijalnih problema. Naime, kada je jednokriterijalni problem jednom formuliran njegovo rješenje dobiva se teoretski jednostavno.

Kod višekriterijalnog odlučivanja donosilac odluke ne može se nadomjestiti ma kako dobrom metodom. Nijedna metoda ne može sama za sebe odrediti najbolje rješenje u pojedinoj situaciji. U najboljem slučaju metoda može koristiti donosiocu odluke da ojača osnovu na kojoj se donose odluke i da poboljša kvalitetu procesa odlučivanja.

Rješenje problema višekriterijalnog odlučivanja je uglavnom dvojako:

a) dizajniranje najbolje alternative;

b) izbor najbolje između prethodno specificiranog konačnog broja alternativa.

U skladu s tim može se primijetiti da u odnosu na različito postavljene probleme postoje dva alternativna skupa. Jedan skup sadrži konačan broj elemenata (alternativa), a drugi ih ima beskonačno mnogo. Naime, kupac automobila bira između konačnog broja ponuđenih tipova i modela, dok s druge strane automobil koji neka kompanija proizvede može biti dizajniran između beskonačno mnogo mogućnosti koje su njegovi konstruktori mogli dizajnirati.

U tom smislu najčešća je i klasifikacija takvih problema višekriterijalnog odlučivanja u dvije različite kategorije:

a) Višekriterijalno programiranje (ili odlučivanje), najčešće poznato pod engleskim nazivom Multiple Objective (Criteria) Decision Making – MODM (MCDM), za dizajniranje najbolje alternative;

b) Višeatributno odlučivanje (Multiple Attribute Decision Making - MADM) za izbor ili selekciju najbolje alternative.

4.1.2. Osnovni pojmovi višeatributnog odlučivanja

Osnovna karakteristika problema višeatributnog odlučivanja jest ta da obično postoji konačan (ograničen) broj unaprijed određenih alternativa kao što je i u ovom slučaju riječ.

Na temelju ocjena svih alternativa određenih po više kriterija je potrebno odrediti onu najbolju. Alternative uz sebe imaju pridružen nivo dostizanja svakog atributa koji ne mora nužno biti kvantificiran, na temelju čega se donosi i konačna odluka, tj:

a) izbor najbolje alternative,
b) rang ili poredak alternativa,
c) izbor skupa najboljih alternativa.

Jedan od osnovnih pojmova kod višeatributnog odlučivanja je tzv. tablica (matrica) odluke (decision table – matrix). Tablica odluke je matrica tipa (m, n) (m redaka, n stupaca) čiji element x_{ij} određuje procjenu i-te alternative A_i u odnosu na j-ti kriterij (atribut) X_j, dakle matrica oblika:

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

Alternativa A_i određena je pritom i-tim retkom matrice D, tj.

$$A_i = [x_{i1} \quad x_{i2} \quad \dots \quad x_{in}]$$

daje ocjenu i-te alternative po svim kriterijima (atributima).

Analogno tome, j-ti stupac matrice D pokazuje ocjene svih alternativa po j-tom atributu, odnosno

$$X_j = \begin{bmatrix} x_{1j} \\ x_{2j} \\ x_{mj} \end{bmatrix}$$

4.1.3. Procjena važnosti kriterija

Svaki višekriterijalni problem sadrži više različitih, i najčešće konfliktnih, kriterija koji mogu biti od različite važnosti za donosioca odluke. Većina metoda za odabir najbolje alternative, tj. općenito metoda za višekriterijalno odlučivanje, zahtijeva informacije o relativnoj važnosti svakog atributa, odnosno kriterija.

Za procjenjivanje stupnja važnosti kriterija postoje niz metoda koje u potpunosti ovise o ljudskoj prosudbi. Tehnike u toj kategoriji mogu se odnositi na pojedinca ili na grupu ljudi.

Drugim riječima procjenu važnosti kriterija može dati sam donosilac odluke ili se mišljenje o tome traži od grupe eksperata (sudaca). Članovi te grupe morali bi se sastojati od eksperata iz razmatranog područja, uključujući, po mogućnosti, nekog od odgovornih donosilaca odluke. Metode za grupno procjenjivanje kriterija su: rangiranje, ocjenjivanje, usporedba u parovima, sukcesivne metode te Delphi metoda.

Metode procjene važnosti kriterija za jedinstvenog donosioca odluke se primjenjuju kada postoji samo jedan donosioc odluke, ili kada je preskupo ili komplicirano tražiti ocjene od više eksperata ili sudaca. Iste metode se mogu primjeniti i ako postoji više eksperata, ali se u tom slučaju procjene moraju sintetizirati kako bi se dobile konačne težine kriterija. Najčešće korištene metode za jedinstvenog donosioca odluke su: metoda svojstvenog vektora, ponderirana metoda najmanjih kvadrata, metoda entropije, te LINMAP.

Prednost grupnog nad individualnim mišljenjem je da daje širi spektar informacija i unosi stručnost i iskustvo u analizu. Međutim, postoje i neki problemi kod korištenja ekspertnih grupa kao što su veći utrošak vremena, dominacija pojedinih autoritativnih osoba ili sposobnost uvjeravanja nekog člana grupe, koja može usmjeriti diskusiju u nekom sasvim nebitnom pravcu.

Relativna važnost kriterija može se izraziti u terminima prioriteta ili težina. Prioritet se odnosi na slučaj kada su kriteriji uređeni (poredani) po važnosti. Pri tome, sve dok se kriterij s višeg nivoa (važniji) ne uzme u razmatranje, sljedeći (manje važan) kriterij uopće "ne ulazi u igru". S druge strane, težine (ponderi) se koriste da bi se brojčano (najčešće postotno) izrazila važnost kriterija ili da bi se razlikovala relativna važnost nekoliko kriterija unutar istog prioriteta.

Neka je w_j (j = 1, 2, ..., n) težina pridružena j-tom kriteriju. Uobičajeno je da se ti ponderi normaliziraju, što znači da treba vrijediti:

$$0 < w_j < 1$$

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

pri čemu izraz $w_k > w_m$ znači da je k-ti kriterij važniji od m-tog, a $w_k = w_m$ sugerira njihovu jednaku važnost. Procjena važnosti kriterija je bitna jer je preduvjet za metodu višekriterijalne analize PROMETHEE po kojoj će se vrednovati alternative.

4.1.3.1. Rangiranje

Pretpostavimo da je potrebno ocijeniti n kriterija X_j (j = 1, 2, ..., n) i da u tom poslu sudjeluje l eksperata E_k (k = 1, 2, ..., l).

Svaki sudac (ekspert) mora poredati sve kriterije po važnosti i tada se najvažnijem dodijeli broj n-1, drugom po važnosti n-2, i tako redom do najmanje važnog kriterija koji dobija broj 0.

Tada se računa izraz:

$$R_j = \sum_{k=1}^{l} R_{jk}$$

gdje je

R_{jk} - rang (broj) pridružen kriteriju j od k-tog eksperta, dakle neki od brojeva 0 do n-1,

R_j - suma svih rangova, tj. rangova svih eksperata pridruženih j-tom kriteriju.

Težine kriterija određuju se tada na sljedeći način:

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

gdje je w_j težina (ponder) j-tog kriterija sastavljena od prosudbe svih eksperata za j-ti kriterij.

Ova metoda je relativno jednostavna i troši se malo vremena za dobivanje prosudbi od svih eksperata. Budući da svaki sudac daje samo skup cijelih brojeva ne izvode se težine posebno za svakog pojedinog suca, već se dobivaju samo težine komponirane od rangova svih eksperata.

4.1.3.2. Ocjenjivanje

Kriteriji se prezentiraju svakom sucu i od njih se traži da daju brojčanu ocjenu za svaki kriterij. Pri tome su te ocjene obično u nekom zadanom intervalu, npr. od 0 – 10 ili od 0 – 100. Težine pojedinih kriterija tada se izvode na sljedeći način:

$$w_{jk} = \frac{\varphi_{jk}}{\sum_{j=1}^{n} \varphi_{jk}}$$

$$w_j = \frac{\sum_{k=1}^{l} w_{jk}}{\sum_{j=1}^{n} \sum_{k=1}^{l} w_{jk}}$$

gdje je

φ_{jk} – ocjena k-tog suca j-tom kriteriju,

w_{jk} – težina izraačunata za j-ti kriteriji od k-tog suca (normalizirana),

w_j – konačna (ukupna) težina za j-ti kriterij.

4.1.4. Klasifikacija MCDM metoda

U literaturi se može naći veliki broj MCDM metoda. Svaka od metoda je posebna s obzirom na različite karakteristike istih. Postoji mnogo načina na koje se može vršiti klasifikacija MCDM metoda. Jedna od klasifikacija je klasifikacija prema tipu podataka koje određena metoda koristi. Po istoj razlikujemo determinističke, stohastične ili pak fuzzy MCDM metode, no postoje i situacije koje zahtijevaju kombinaciju svih prethodno navedenih metoda, odnosno tipova podataka. Drugi način klasifikacije je prema broju donosioca odluke koji su uključeni u proces donošenja odluke. Po istoj klasifikaciji razlikujemo MCDM metode za jedinstvenog donosioca odluke te MCDM metode za grupu donosioca odluka.

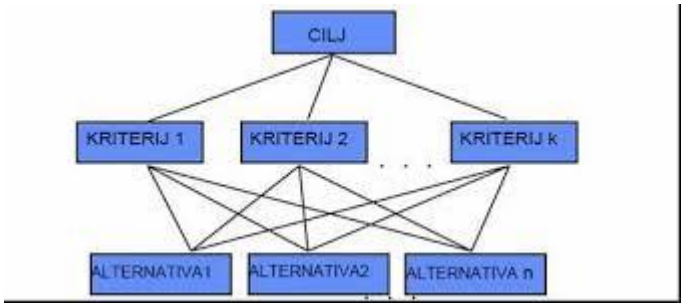
Metode AHP (Analitički Hijerarhijski Proces), ELECTRE (ELimination Et Choix Traduisant la Realité), te PROMETHEE (Metoda PROMETHEE (Preference Ranking Organization METHod for Enrichment Evaluations) su neke od najpoznatijih metoda za uspoređivanje i rangiranje alternativa u problemima višekriterijalnog odlučivanja, a ujedno se i najviše primjenjuju. Upravo je to razlog zbog kojeg će se u nastavku prikazati osnovne značajke prethodno navedenih.

4.1.4.1.Metoda AHP

Analitički hijerarhijski proces ili AHP metoda (Saaty, 1980) spada u najpoznatije i posljednjih godina najviše korištene metode za višekriterijalno odlučivanje. Njezina popularnost temelji se u prvom redu na činjenici da je vrlo bliska načinu na koji pojedinac intuitivno rješava složene probleme rastavljajući ih na jednostavnije. Drugi važan razlog zašto je ta metoda tako popularna je kvalitetan softver Expert Choice koji je dostupan i u demo verziji.

Rješavanje složenih problema odlučivanja pomoću ove metode temelji se na njihovom rastavljanju na komponente: cilj, kriterije (podkriterije) i alternative. Ti elementi se potom povežu u model s više razina (hijerarhijsku strukturu) pri čemu je na vrhu cilj, a na prvoj nižoj razini su glavni kriteriji. Kriteriji se mogu rastaviti na podkriterije, a na najnižoj razini nalaze se alternative. Druga važna komponenta AHP metode je matematički model pomoću kojeg se računaju prioriteti (težine) elemenata koji su na istoj razini hijerarhijske strukture. Primjena ove metode se može objasnit u slijedeća četiri koraka:

1. Razvije se hijerarhijski model problema odlučivanja s ciljem na vrhu, kriterijima i podkriterijima na nižim razinama, te alternativama na dnu modela. Na slici 1. prikazan je jedan takav opći model.



Graf 2: Osnovni AHP model s ciljevima, kriterijima i alternativama

2. U svakom čvoru hijerarhijske strukture pomoću Saatyeve skale43 u parovima se međusobno uspoređuju elementi tog čvora koji se nalaze neposredno ispod njega i izračunaju se njihove lokalne težine. Pritom se kriteriji međusobno uspoređuju u parovima u odnosu na to koliko puta je jedan od njih važniji za mjerenje postizanja cilja od drugog. Alternative se međusobno uspoređuju u parovima po svakom od

kriterija procjenjujući u kojoj mjeri se po tom kriteriju jednoj od njih daje prednost u odnosu na drugu.

3. Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema izračunaju se lokalne težine kriterija i podkriterija, a na posljednjoj razini prioriteti alternativa. Ukupni prioriteti alternativa izračunaju se tako da se njihovi lokalni prioriteti ponderiraju s težinama svih čvorova (težine kriterija) kojima pripadaju gledajući od najniže razine u hijerarhijskom modelu prema najvišoj i zatim zbroje.
4. Provodi se tzv. analiza osjetljivosti s ciljem da se vidi u kojoj mjeri se promjene ulaznih podataka odražavaju na ukupne prioritete alternativa. Analiza osjetljivosti se može provesti na kvalitetan i razumljiv način uz pomoć softvera Expert Choice. Ovaj program, u potpunosti podržava sve korake karakteristične za primjenu AHP metode. Program omogućuje strukturiranje hijerarhijskog modela problema odlučivanja na više načina, te uspoređivanje u parovima također na nekoliko načina. Posebnu vrijednost programu daju različite mogućnosti provođenja analize osjetljivosti koje se temelje na vizualizaciji posljedica promjena ulaznih podataka.

4.1.4.2. Metoda ELECTRE

ELECTRE (ELimination Et Choix Traduisant la REalité) je jedna od metoda višekriterijalnog odlučivanja koja se koristi u svrhu olakšavanje donošenja odluka u izboru najpovoljnijeg rješenja među alternativama. Autor iste je Bernard Roy, a nastala je kao odgovor na nedostatke postojećih metoda za rješavanje problema odlučivanja. ELECTRE je napredovala preko nekoliko verzija (od I do IV); sve verzije su temeljene na istom fundamentalnom konceptu, ali se međusobno razlikuju u koracima.

U svrhu rješavanja problema višekriterijalnog tipa nužno je definirati alternativne pravce (scenarije). Nakon toga se pristupa odabiru kriterija koji su relevantni za donošenje odluke. Kriterijima se dodjeljuju određene težine, u zavisnosti o važnosti pojedinog kriterija, a zbroj svih težina kriterija mora biti jednak 1.

Metoda ELECTRE se sastoji od inputa kojeg čine matrica odlučivanja i težina kriterija, te devet koraka. Koraci u rješavanju su:

1) računanje normalizirane matrice odlučivanja,

2) računanje ponderirane normalizirane matrice odlučivanja,

3) određivanje skupova suglasnosti i nesuglasnosti,

4) računanje matrice suglasnosti,

5) računanje matrice nesuglasnosti,

6) računanje matrice dominacije po suglasnosti,

7) računanje matrice dominacije po nesuglasnosti,

8) računanje agregirane matrice dominacije,

9) eliminiranje najslabijih alternativa.

4.1.4.3. PROMETHEE

Metoda PROMETHEE (Preference Ranking Organization METHod for Enrichment Evaluations) je jedna od MCDM metoda koje se u praksi najčešće primjenjuju. Razlog tomu jest činjenica što je ista metoda poprilično jednostavna za primjenu za razliku od drugih metoda koje se koriste za višekriterijalnu analizu.Metoda vrši usporedbu i rangiranje različitih alternativa (aktivnosti) istodobno vrednovanih na temelju više kvantitativnih ili kvalitativnih kriterija (atributa). Metoda PROMETHEE spada u klasu tzv. „outranking“ metoda za koje se može reći da predstavljaju kompromis između suvišne „siromašne“ relacije dominacije i pretpostavke da je poznata funkcija korisnosti donosioca odluke.

Razmotrimo prvo višekriterijalni problem oblika:

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

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.

Za svaku aktivnost A_i neka je f_j (A_i) vrijednost ili procjena vrijednosti j-tog kriterija za i-tu alternativu. Na taj način dobiva se skup osnovnih podataka prikazan u matrici odluke:

Tablica 1: Shema matrice odluke

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

Kada uspoređujemo dvij alternative a i b (A_k i A_l) moramo biti sposobni rezultat te usporedbe izraziti u terminima preferencija. Iz tih razloga uvodi se funkcija preferencije P:

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

koja predstavlja intenzitet preferencije alternative (aktivnosti) a u odnosu na alternativu b na sljedeći način:

P (a,b) = 0 znači indiferenciju između *a* i *b*, ili nepostojanje preferencije od *a* nad *b*,

P (a,b) ≈ 0 znači slabu preferenciju od *a* nad *b*,

P (a,b) ≈ 1 znači jaču preferenciju od *a* nad *b*,

P (a,b) = 1 znači striktnu preferenciju od *a* nad *b*.

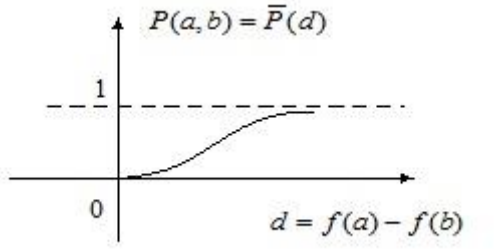
Može se reći da se za svaki par alternativa *a i b* određuje broj iz intervala [0,1] koji je to bliži jedinici što je alternativa *a* prihvatljivija donosiocu odluke nego alternativa *b*. Problem naravno predstavlja što se ta „prihvatljivost“ mora mjeriti preko više kriterija i to istovremeno.

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

Stavimo li

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

možemo uzeti da je $P(a,b) = \bar{P}(d)$ i tada graf funkcije preferencije (koja je sad funkcija jedne a ne dviju varijabli) ima sljedeći oblik:



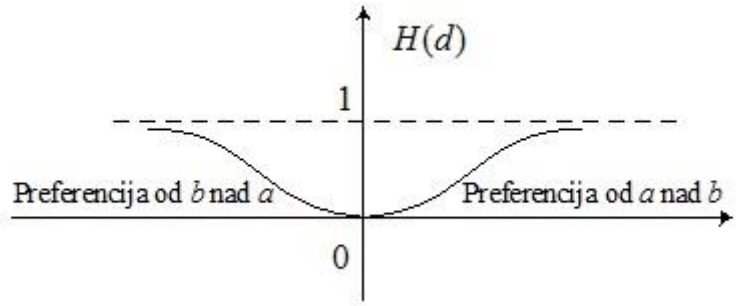
Graf 3: Funkcija preferencije

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

Što je *d*, tj. razlika u ocjenama tih dviju aktivnosti (alternativa) veća to je $P(a,b)$ bliži jedinici, a za određenu vrijednost od *d* funkcija postaje jednaka 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:

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

Ta funkcija izgleda ovako:



Graf 4: Funkcija preferencije H(d)

Za svaki kriterij f_j razmatra se zatim generalizirani kriterij definiran pomoću kriterija f_j i odgovarajuće funkcije preferencije. Autori metode predložili su šest različitih tipova generaliziranog kriterija. To, naravno, ne iscrpljuje sve mogućnosti, ali se za praktičnu primjenu pokazuje i više nego dovoljnim.

Od tih šest funkcija analitičar i donosilac odluke dogovorno biraju po jednu za svaki kriterij u odnosu na njihova saznanja o intenzitetu i smjeru preferencije. U svakom

ponedinom slučau treba eventualno unaprijed odrediti i neke parametre, od kojih svaki ima stvarno ekonomsko značenje. 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,

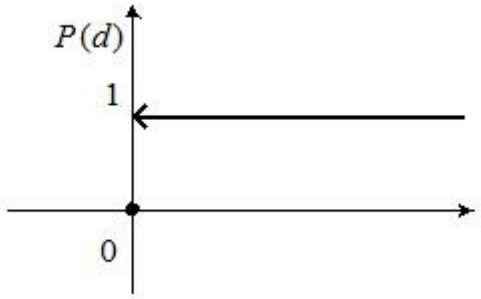
s **-** parametar čija vrijednost se nalazi između praga indiferencije q i praga preferencije *p*.

Tih šest tipova generaliziranog kriterija su:

(1) Obični kriterij

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

U tom slučaju indiferencija između *a* i *b* postoji ako i samo ako je *f(a) = f(b)*, tj. za *d=0*. Čim su procjene po tim dvjema aktivnostima različite to znači da donosilac odluke striktno preferira aktivnost koja ima veću ocjenu, pa je vrijednost funkcije preferencije jednaka 1. Ta funkcija preferencije prikazana je na sljedećem grafu.

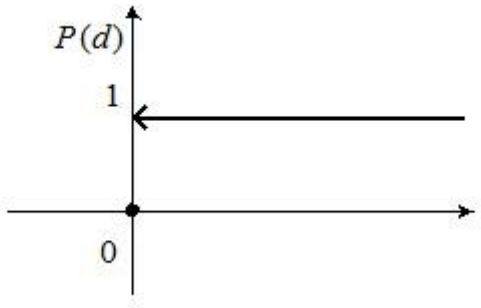


Graf 5: Funkcija preferencije po običnom kriteriju

(2) Kvazi kriterij

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

Kod kvazi kriterija se uvodi prag indiferencije *q*, tj. dvije alternative su indiferentne tako dugo dok razlika njihovih ocjena ne premaši prag *q*, a u protivnom postoji stroga preferencija. Dakle, ako donosilac odluke želi upotrijebiti takvu funkciju preferencije potrebno je odrediti vrijednost parametra *q* koji ima strogo ekonomsko značenje.

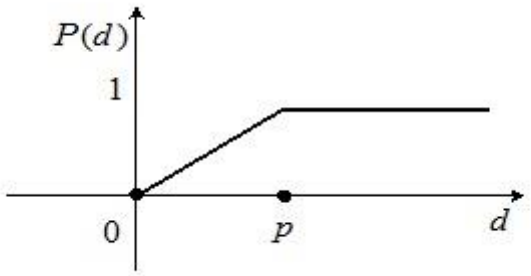


Graf 6: Funkcija preferencije po kvazi kriteriju

(3) Kriterij s liearnom preferencijom

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

Dok je *d* manji od parametra *p* (praga preferencije) preferencija donosioca odluke raste linearno s vrijednošću *d*. Čim razlika *d* postaje veća od *p* postoji situacija stroge preferencije. Za taj kriterij treba dakle odrediti također samo jedan parametar *p* koji predstavlja najnižu vrijednost razlike u ocjenama dviju alternativa iznad koje imamo strogu preferenciju.

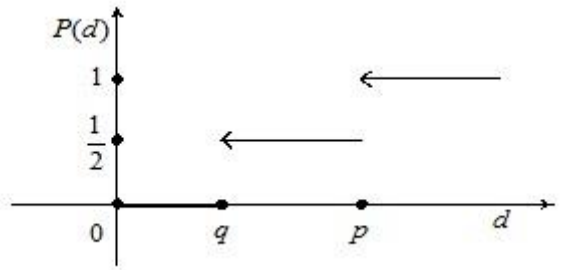


Graf 7: Funkcija kriterija s linearnom preferencijom

(4) Nivo kriterij

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

U tom slučaju potrebno je definirati oba praga *q* i *p* i kada se razlika *d* nalazi između njihovih vrijednosti postoji tzv. slaba preferencija (P(d) = ½).

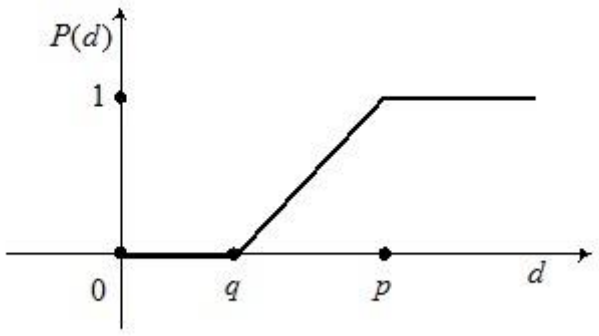


Graf 8: Funkcija preferencije po nivo kriteriju

(5) Kriterij s linearnom preferencijom i područjem indiferencije

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

Preferencija donosioca odluke, u tom slučaju, raste linearno u području indiferencije do područja stroge preferencije, tj. u području između pragova q i p.

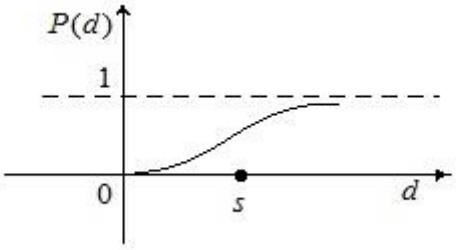


Graf 9: Funkcija preferencije po kriteriju s linearnom preferencijom i područjem indiferencije

(6) Gaussov kriterij

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

Ta funkcija zahtijeva defeniranje samo parametra *s* koji leži negdje u području slabe preferencije, a predstavlja ustvari standardnu decijaciju normalne razdiobe. Ta funckija koja nema prekida ni „šiljaka“ može biti interesantna zbog eventualne stabilnosti rezultata. Parametar *s* ustvari predstavlja apscisu točke infleksije (prijevoja) na grafu te funkcije.



Graf 10: Funkcija preferencije po Gaussovom kriteriju

Za svaki kriterij potrebno je, dakle, izabrati jedan od predloženih tipova funkcije preferencije. S obzirom da potrebni parametri imaju stvarno ekonomsko značenje potrebno je donosioca odluke upoznati sa svim tim mogućnostima i u dogovoru s njim odlučiti se za jedan od tipova funkcije preferencije.

Nakon odabira kriterija potrebno je odrediti i relativne važnosti (pondere, težine) za pojedine kriterije. Naravno da je problem određivnja težina w_j za svaki kriterij f_j veoma težak i važan problem i njemu treba posvetiti izuzetnu pažnju.

Pretpostavimo da je analitičar, u dogovoru s donosiocem odluke, odredio funkcije preferencije P_j (po jednu od 6 mogućih tipova za svaki kriterij) itežine w_j. Definirajmo nadalje indeks preferencije π kao ponderiranu sredinu funkcija preferencije P_j, tj.

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

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

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

Indeks preferencije π *(a,b)* izražava intenzitet preferencije donosioca odluke za alternativu *a* nad alternativom *b* simultano razmatrajući sve kriterije. Drugim riječima π *(a,b)* izražava kako i s kojim intenzitetom *a* dominira nad *b* u odnosu na sve kriterije.

Napomenimo da, budući da je P_j *(a,b) = 0* ako *b* dominira nad *a* po *j*-tom kriteriju, indeks preferencije ne može nikad biti negativan. S druge strane najveća vrijednost od P_j *(a,b)* može biti 1 i to u slučaju stroge preferencije. Iz toga slijedi:

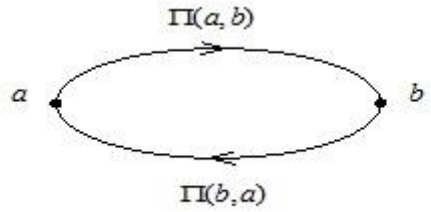
$$\pi\,(a,b) = \sum_{j=1}^{n} w_j P_j(a,b) \leq \sum_{j=1}^{n} w_j = 1$$

odnosno

$$\pi\,(a,b)\,\epsilon\,[0,1]$$

Nasuprot tome indeks preferencije $\pi(b,a)$ izražava kako i s kojim intenzitetom *b* dominira nad *a* u odnosu na sve kriterije.

Dakle, između svake dvije alternative *a* i *b* postoje dva luka s vrijednostima $\pi(a,b)$ i $\pi(b,a)$.



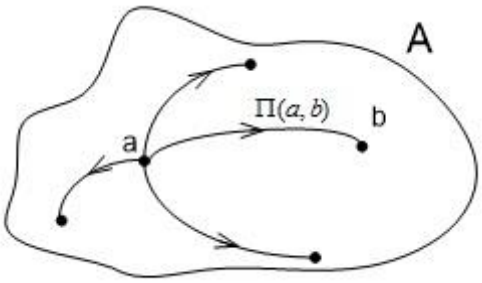
Slika 10: Indeks preferencije $\pi(a,b)$ i $\pi(b,a)$

Za svaku alternativu (aktivnost) definiraju se, nadalje dva „outranking" toka $\phi^{+}(a)$, izlazni ili pozitivni tok, i $\phi^{-}(a)$, ulazni ili negativni tok.

Izlazni ili pozitivni tok

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

predstavlja sumu vrijednosti svih lukova koji izlaze iz čvora (alternative, aktivnosti) *a*, i zato izražava mjeru koliko alternativa *a* dominira nad svim ostalim alternativama ($b \in A$) po svim kriterijima, odnosno pokazuje koliko je alternativa *a* bolja od svih ostalih alternativa. Možemo reći da $\phi^{+}(a)$ mjeri „snagu" alternative *a*.



Slika 11: Izlazni ili pozitivni tok

Nasuprot tome, definiramo ulazni ili negativni tok $\boldsymbol{\phi}^{-}(a)$ kao sumu vrijednosti svih lukova koji ulaze u čvor *a*, tj.

$$\boldsymbol{\phi}^{-}(a) = \frac{1}{m-1}\sum_{b\in A}\pi(b,a)$$

Ulazni ili negativni tok pokazuje koliko je *a* dominirana od svih ostalih alternativa i po svim kriterijima. Dakle, $\boldsymbol{\phi}^{-}(a)$ mjeri „slabost" alternative *a*, odnosno što je $\boldsymbol{\phi}^{-}(a)$ manji to je alternativa bolja.

Usporedbom ulaznih i izlaznih tokova dobivaju se dva potpuna uređaja skupa alternativa, tj. jedan po $\boldsymbol{\phi}^{+}(a)$ i jedan po $\boldsymbol{\phi}^{-}(a)$. To su:

$$\boldsymbol{\phi}^{+}(a)\ \begin{Bmatrix} aS^{+}b\ ako\ i\ samo\ ako\ je\ \phi^{+}(a) > \phi^{+}(b) \\ aI^{+}b\ ako\ i\ samo\ ako\ je\ \phi^{+}(a) = \phi^{+}(b) \end{Bmatrix}$$

$$\boldsymbol{\phi}^{-}(a)\begin{Bmatrix} aS^{-}b\ ako\ i\ samo\ ako\ je\ \phi^{-}(a) < \phi^{-}(b) \\ aI^{-}b\ ako\ i\ samo\ ako\ je\ \phi^{-}(a) = \phi^{-}(b) \end{Bmatrix}$$

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. Taj uređaj prikazan je u sljedećoj tablici.

a P b (*a* dominira nad *b*)	ako i samo ako $\begin{Bmatrix} aS^{+}b\ i\ aS^{-}b \\ ili \\ aS^{+}b\ i\ aI^{-}b \\ ili \\ aI^{+}b\ i\ aS^{-}b \end{Bmatrix}$
a I b (*a* je indiferentan sa *b*)	ako i samo ako $a\ I^{+}b\ i\ aI^{-}\ b$
a R b (*a* i *b* su neusporedivi)	u ostalim slučajevima

Tablica 2: PROMETHEE I – parcijalni uređaj

pri čemu *P* podrazumijeva dominaciju, *I* indiferentnost, te *R* neusporedivost, odnosno:

$a\ P\ b \rightarrow a$ dominira nad b ako i samo ako je a bolji od b i po pozitivnom i po negativnom toku, ili ako je a bolji od b po pozitivnom toku, a indiferentan po negativnom toku, ili ako je a bolji od b po negativnom toku, a indiferentan po pozitivnom toku;

$a\ I\ b \rightarrow a$ je indiferentan sa b ako i samo ako su vrijednosti za a i b po pozitivnom i negativnom toku jednake;

$a\ R\ b \rightarrow a$ i b su neusporedivi u svim ostalim slučajevima.

Ako donosilac odluke želi potpuni uređaj skupa alternativa A može se izračunati tzv. neto tok $\boldsymbol{\phi}$,kao razlika „snage“ i „slabosti“ pojedine alternative, tj.

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

Takav uređaj se naziva PROMETHEE II. Iako je donositelju odluke jednostavnije odlučivati na temelju potpunog poretka (PROMETHEE II) ipak parcijalni uređaj (PROMETHEE I) daje mnogo realnije informacije, pogotovo one vezane za neusporedivost koje često mogu biti od velike važnosti za konačno donošenje odluke.

4.2. Softver Decision Lab

DECISON LAB je trenutna softver implementacija PROMETHEE i GAIA metoda. Softver je razvila i plasirala na tržište kanadska kompanija Visual Decision u suradnji s autorima PROMETHEE metoda. Decision Lab ja zamjena za PROMCALC kojeg su prethodno razvili Brans i Mareschal. PROMCALC je podržavao obradu svih tipova multikriterijalnih problema, odnosno korisnik je imao mogućnost izvođenja svih PROMETHEE metoda (I, II, V, VI) kao i GAIA vizualnog modula u svrhu potpore pri odlučivanju.

Glavni razlog zbog kojeg je Visual Decision uveo tehnološko rješenje za multikriterijalno donošenja odluka jest činjenica što internacionalno poznate znanstvene metode, kao što je PROMETHEE, povećavaju kredibilitet i vrijednost rješenja koji su preporučeni donosiocu odluke od strane određenog softvera. Decision Lab je jedan od najnovijih alata koje je Visual Decision ponudio tržištu kao potporu pri odlučivanju.

Isti softver je primjeren korisnicima koji će se prilikom svog rada služiti tek osnovnim funkcijama programa kao i onima koji traže više snage, pogodnosti, te koristi od naprednih analiza osjetljivosti. Jedna od velikih prednosti dotičnog softvera jest što je primjenjiv i za grupno donošenje odluka. Naime, korištenje funkcije scenarija analize omogućuje komparaciju radnih hipoteza različitih donosioca odluke.

Decision Lab 2000 jest softversko rješenje koje uvelike olakšava rješavanje multikriterijalnih problema. Naime, njegove napredne funkcije pružaju dokaze o snagama vs slabostima, konfliktima i konsenzusima. Koristeći "What if" scenario korisnik će znatno poboljšati kvalitetu i pouzdanost procesa donošenja odluka.

Na temelju konkretnih rezultata akademskih istraživanja koji su priznati na svjetskoj razini, PROMETHEE i GAIA metode, Decision Lab 2000 je dizajniran na način da se može primijeniti na razne tipove multikriterijalnih problema. Odnosno, Decision Lab multikriterijalni modeli mogu igrati ulogu financijskog savjetnika (izbor dionica i drugih vrijednosnih papira), strateškog planera (određivanje prioriteta projekata), bankovnog činovnika (kreditna evaluacija) te mnoge druge uloge.

Decision Lab je dizajniran na način da je kompatibilan sa svim Windows platformama, te ne traži posebne vještine rada s kompjutorom. Korisnik koji se zna služiti MS Excelom neće imati nikakvih problema sa savladavanjem rada u Decision Lab-u. Korisnik Decision Lab-a manipulira podacima višekriterijalnog problema koristeći specifični radni list istog programa pomoću kojeg može jednostavno unositi relevantne podatke vezane uz PROMETHEE metode.

Osim toga, dotični softver pruža korisniku i dodatne pogodnosti kao što su kvantifikacija kvalitativnih kriterija, te tretman nedostajućih vrijednosti u multikriterijalnoj tablici. Isto tako, bilo koja promjena podataka se instantno reflektira na sve output prozore, a to je posebno korisno kada donosioc odluke nema jasnu predodžbu o težini kriterija jer na taj način može istražiti alternativna rješenja problema s obzirom na promijenjene težine istih. S obzirom na sve rečeno može se zaključiti da je Decision Lab najmoćniji i najjednostavniji alat u kategoriji softvera koji služe donosiocu odluke kao potpora u procesu odlučivanja.

4.3. Postupak vrednovanja alternativnih lokacija na temelju odabranih kriterija

Vrednovanje kriterija, tj. određivanje njihovih težina će se provesti pomoću metode rangiranja na temelju stručnog mišljenja eksperata. U nastavku ovoga poglavlja će se predočiti i matrica odluke koja je od vitalne važnosti za provođenje PROMETHEE analize. Podaci iz te matrice će se unijeti u Decision Lab, te će se rezultati te obrade analizirati i interpretirati u svrhu iznalaženja optimalnog rješenja.

U svrhu evaluacije alternativnih rješenja nužna je izgradnja modela pomoću kojeg će se ustanoviti razlike između mogućih lokacija za gradnju hotela. Moguće lokacije za gradnju hotela su sljedeće: Stari Grad i Jelsa na otoku Hvaru; zgrade Banovine i hotela Marjana na Zapadnoj obali u Splitu te zgrade Dalmatia Towera i hotela Amphora, također u Splitu; lokacije u Gornjoj Podstrani, Žrnovnici i Omišu. Navedenih devet lokacija će se vrednovati po isto toliko kriterija. Ti kriteriji su: očekivani prihod, troškovi, atraktivnost čestice, imidž destinacije, blizina/pristupačnost generatorima ponude i potražnje, izvedivost, otvorenost lokalne samouprave za suradnju, konkurencija i postojanost potrebnih ljudskih resursa.

Važno je naglasiti da ovi kriteriji nisu svi mogući koji se mogu pojaviti u stvarnom projektu radi kompleksnosti problema.

Svakom od navedenih kriterija će biti pridružena određena kvantitativna vrijednost na mjernoj skali od jedan (1) do deset (10). Kriteriji su ocijenjeni od strane autora rada, u suradnji s ekspertnim timom.

Izbor optimalne lokacije za gradnju hotela će se vrednovati na temelju prethodno navedenih devet kriterija. Važno je naglasiti kako nisu svi kriteriji od jednake važnosti, stoga se javlja potreba određivanja njihove važnosti, tj. težine kriterija koja će se procijeniti pomoću metode rangiranja.

U rangiranju navedenih kriterija, u svrhu procjenjivanja težina istih pomoću metode rangiranja će sudjelovati tri eksperta:

1) prvi ekspert (E_1), autor diplomskog rada,
2) drugi ekspert (E_2), rangirat će kriterije s profitnog aspekta,
3) treći ekspert (E_3), rangirat će kriterije s obzirom na društveni interes.

Kriterijima su dodijeljene sljedeće oznake:

A. Očekivani prihod,
B. Troškovi,
C. Atraktivnost čestice,
D. Imidž destinacije,
E. Blizina/pristupačnost generatorima ponude i potražnje,
F. Izvedivost,
G. Otvorenost lokalne samouprave za suradnju,
H. Konkurencija,
I. Postojanost potrebnih ljudskih resursa.

Eksperti su izvršili rangiranje navedenih kriterija, i to na sljedeći način:

1) $E_1 \rightarrow$ (A, D, C, B, F, E, H, G, I)
2) $E_2 \rightarrow$ (A, B, D, C, H, F, E, I, G)
3) $E_3 \rightarrow$ (I, F, G, B, A, C, D, E, H)

Najvažnijem kriteriju se pridružuje broj **n-1** (s time da je **n** broj kriterija, odnosno devet), drugom po važnosti **n-2**, i tako redom do najmanje važnog kriterija koji dobiva broj nula. Prethodno navedeni brojevi su prikazani u sljedećoj tablici kao i suma $Rj \sum_{k=1}^{l} R_{jk}$ koji je izračunat u zadnjem stupcu tablice i koji predstavlja sumu svih rangova, tj. rangova svih eksperata pridruženih j-tom kriteriju.

Kriteriji	**Eksperti**			**R_j**
	E_1	**E_2**	**E_3**	
A	8	8	4	**20**
B	5	7	5	**17**
C	6	5	3	**14**
D	7	6	2	**15**
E	3	2	1	**6**
F	4	3	7	**14**
G	1	0	6	**7**
H	2	4	0	**6**
I	0	1	8	**9**

Kako je $Rj \sum_{k=1}^{l} R_{jk}$ = 108 jednostavno dolazimo do konačne težine kriterija, tj:

$W_A = \frac{20}{108} = 0{,}185$, $W_B = \frac{17}{108} = 0{,}157$, $W_C = \frac{14}{108} = 0{,}129$, $W_D = \frac{15}{108} = 0{,}139$,

$W_E = \frac{6}{108} = 0{,}055$, $W_F = \frac{14}{108} = 0{,}129$, $W_G = \frac{7}{108} = 0{,}065$, $W_H = \frac{6}{108} = 0{,}055$,

$W_I = \frac{9}{108} = 0{,}083$.

Metodom rangiranja utvrđeno je da je najvažniji kriterij za istraživanje kriterij Očekivani prihod, a najmanje bitni su kriteriji Konkurencija i Blizina/pristupačnost generatorima ponude i potražnje.

4.4. Matrica odluke

Analiza provedena ovim završnim radom uključuje devet različitih alternativa (scenarija) koji su potom evaluirani na temelju postavljenih kriterija. Za sve je kriterije određena ljestvica ocjena, kao i funkcija preferencije. U ocjenjivanju svake od devet ponuđenih alternativa po devet različitih kriterija sudjelovali su autor rada i članovi ekspertne skupine.

S obzirom da su u matrici odluke samo bodovi, a pragovi su određeni kao razlika najvećeg i najmanjeg broja (ili za jedan manji) po svakom kriteriju, za svaki od kriterija se uzela funkcija preferencije (broj III), odnosno Kriterij s linearnom preferencijom.

Alternative/ Kriteriji	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**
Stari Grad	5	6	5	5	6	8	8	8	2
Jelsa	6	7	6	6	5	8	8	6	2
Hotel Marjan	9	10	10	9	8	9	6	6	8
Hotel Amphora	8	9	8	9	8	9	6	6	8
Zgrada Banovine	9	9	10	9	8	7	6	6	8
Dalmatia Tower	7	8	7	9	8	10	6	8	8
Gornja Podstrana	5	5	5	4	3	6	9	8	4

Žrnovnica	4	5	4	3	3	5	5	8	6
Omiš	4	6	4	5	2	5	7	9	4
TIP	III max	III min	III max	III max	III min	III min	III max	III min	III max
PARAMETAR	p=4	p=4	p=5	p=5	p=5	p=4	p=3	p=2	p=5

Legenda:

A. Očekivani prihod,
B. Troškovi,
C. Atraktivnost čestice,
D. Imidž destinacije,
E. Blizina/pristupačnost generatorima ponude i potražnje,
F. Izvedivost,
G. Otvorenost lokalne samouprave za suradnju,
H. Konkurencija,
I. Postojanost potrebnih ljudskih resursa.

4.5. Analiza rješenja

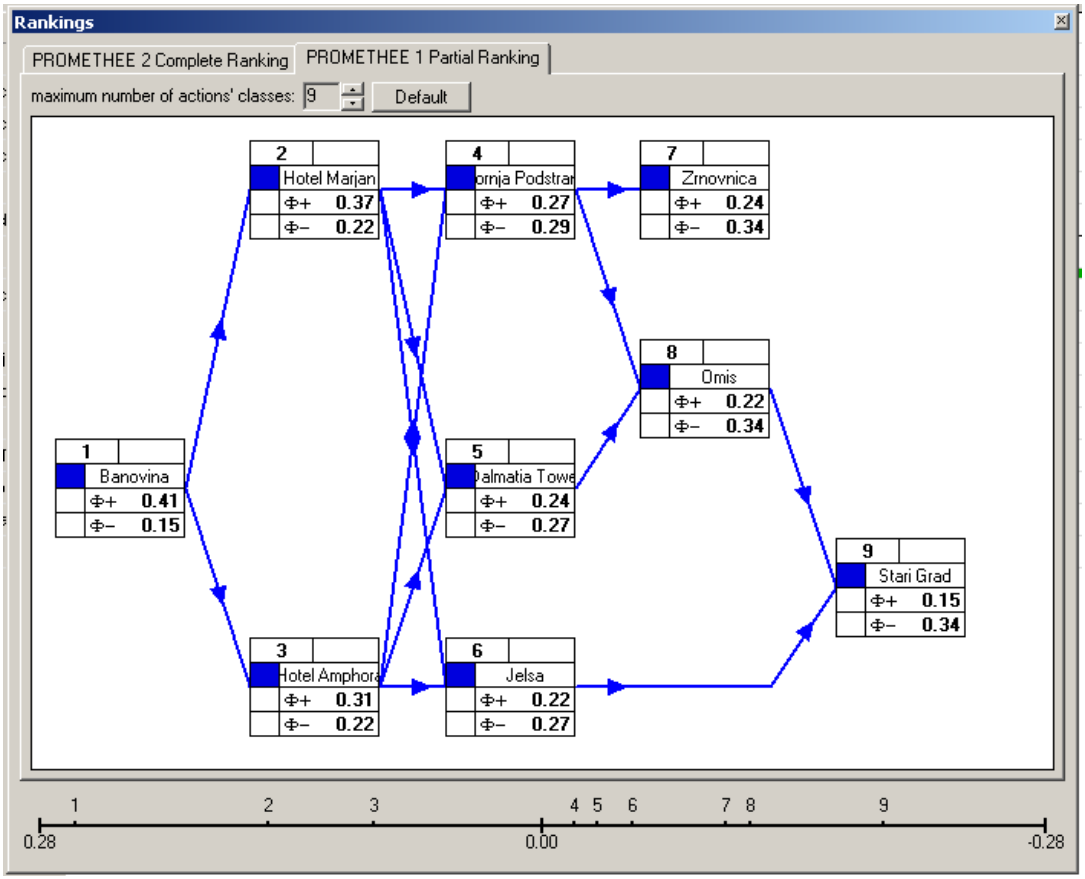
U nastavku teksta će se analizirati rezultati dobiveni upotrebom softverskog rješenja Decision Lab. Ulazne podatke za analizu predstavlja prethodna matrica odluke.

	A	B	C	D	E	F	G	H	I
Min/Max	Maximize	Minimize	Maximize	Maximize	Minimize	Minimize	Maximize	Minimize	Maximize
Weight	185.0000	157.0000	129.0000	139.0000	55.0000	129.0000	65.0000	55.0000	83.0000
Preference Functi	V-Shape	V-Shape	V-Shape	V-Shape	V-Shape	V-Shape	V-Shape	V-Shape	V-Shape
Indiference Thres	-	-	-	-	-	-	-	-	-
Preference Thres	4.0000	4.0000	5.0000	5.0000	5.0000	4.0000	3.0000	2.0000	5.0000
Gaussian Thresh	-	-	-	-	-	-	-	-	-
Threshold Unit	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute
Unit									
Stari Grad	5.0000	6.0000	5.0000	5.0000	6.0000	8.0000	8.0000	8.0000	2.0000
Jelsa	6.0000	7.0000	6.0000	6.0000	5.0000	8.0000	8.0000	6.0000	2.0000
Hotel Marjan	9.0000	10.0000	10.0000	9.0000	8.0000	9.0000	6.0000	6.0000	8.0000
Hotel Amphora	8.0000	9.0000	8.0000	9.0000	8.0000	9.0000	6.0000	6.0000	8.0000
Banovina	9.0000	9.0000	10.0000	9.0000	8.0000	7.0000	6.0000	6.0000	8.0000
Dalmatia Tower	7.0000	8.0000	7.0000	9.0000	8.0000	10.0000	6.0000	8.0000	8.0000
Gornja Podstrana	5.0000	5.0000	5.0000	4.0000	3.0000	6.0000	9.0000	8.0000	4.0000
Zrnovnica	4.0000	5.0000	4.0000	3.0000	3.0000	5.0000	6.0000	8.0000	6.0000
Omis	4.0000	6.0000	4.0000	5.0000	2.0000	5.0000	7.0000	9.0000	4.0000

Graf 11: Ulazni podaci za PROMETHEE metodu - program Decision Lab

Kao što je već navedeno, za svaki od kriterija se uzela funkcija preferencije (broj III), odnosno Kriterij s linearnom preferencijom. Isto tako, težine kriterija su pomnožene sa 1000 kako bi se pojednostavnilo čitanje dobivenih rezultata.

Iz narednog grafa je lako uočiti da je alternativa Banovina najbolja od svih navedenih, i po negativnom, i po pozitivnom toku. S druge strane, gradnja hotela na lokaciji u Starom Gradu na otoku Hvaru je prema rezultatima analize najlošija. Unatoč činjenici da ima jednake vrijednosti po negativnom toku kao i alternative Žrnovnica i Omiš, alternativa Stari Grad ima najmanje vrijednosti po pitanju pozitivnog toka, stoga je Stari Grad najgora alternativa.



Graf 12: Poredak alternativa prema parcijalnom uređaju PROMETHEE I

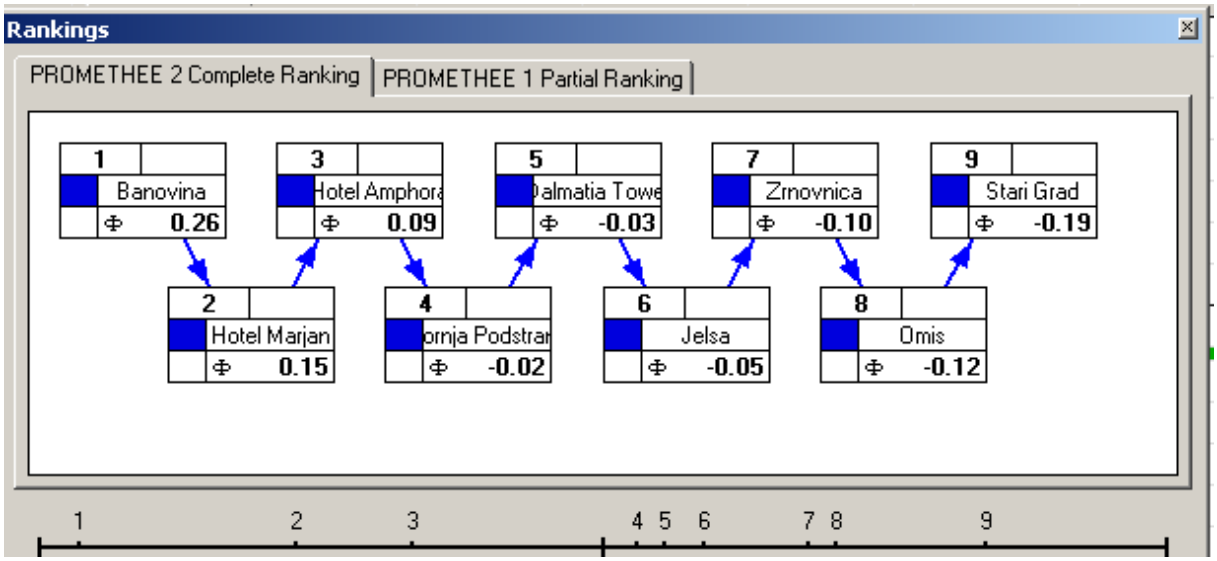
Međutim, na grafu se može primijetiti i nemogućnost usporedbe nekoliko različitih alternativa. Kako je alternativa Hotel Marjan bolja od alternative Hotel Amphora po pozitivnom toku, ali ne i po negativnom toku, tako dolazi do prethdono spomenute nemogućnosti usporedbe tih dviju alternativa.

Nadalje, alternativa Gornja Podstrana je po pozitivnom toku bolja od alternative Dalmatia Tower i alternative Jelsa, ali je po negativnom toku lošija od obje alternative, stoga ni navedene tri mogućnosti nisu međusobno usporedive. Konačno, alternativa Žrnovnica je po

pozitivnom toku bolja od alternative Omiš, ali po negativnom toku su jednake, stoga i u ovom slučaju postoji neusporedivost alternativa. Ta neusporedivost alternativa može stvarati probleme u slučaju da korisnik želi izabrati podskup najboljih alternativa za gradnju hotela.

Hotel Marjan je druga najbolja alternativa jer, za razliku od Hotela Amphore koji ima jednaku vrijednost po negativnom toku, ima veću vrijednost u pozitivnom toku. Lokacija u Gornjoj Podstrani je bolja od alternativa Dalmatia Tower, Jelsa, Žrnovnica, Omiš i Stari Grad. Alternativa Dalmatia Tower je po rezultatima analize bolja lokacija od Jelse, Žrnovnice, Omiša i Starog Grada.

Jelsa kao lokacija za gradnju hotela je prema narednom grafu bolja od lokacija u Žrnovnici, Omišu i Starom Gradu. Alternativa Žrnovnice kao lokacije za gradnju hotela je bolja od alternativa u vidu Omiša i Starog Grada, dok je lokacija za gradnju hotela u Omišu bolja samo od lokacije u Starom Gradu.

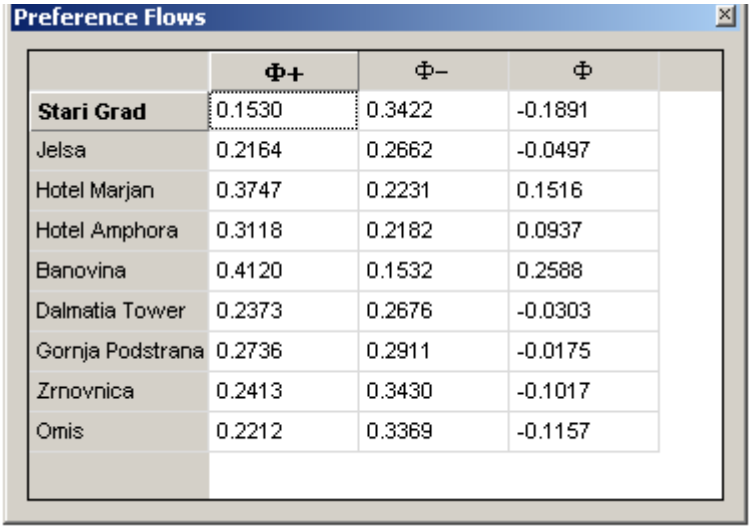


Graf 13: Poredak alternativa po neto toku – PROMETHEE II

Prethodni grafikon pokazuje potpuni poredak alternativa jer izračunava neto tok (ϕ) kao razliku pozitivnog i negativnog toka za svaku alternativu. Naime, alternativa koja ima najveći neto tok je ujedno i najbolja alternativa, dok ona koja ima najmanji predstavlja najgoru, odnosno najlošiju alternativu.

Kao što se može iščitati iz prethodnog grafikona, najbolja alternativa je alternativa Banovina, kao i u slučaju parcijalnog uređaja PROMETHEE I, jer ima najveći neto tok vrijednosti od 0,26. Najlošijom od alternativa se pokazala alternativa Stari Grad na otoku Hvaru s neto tokom od -0,19.

U Tablici su prikazani pozitivni (Φ+) i negativni tok (Φ-) koji su relevantni za PROMETHEE I, te neto tok (Φ) koji je preduvjet konačnog ranga alternativa karakterističnog za uređaj PROMETHEE II.



	Φ+	Φ−	Φ
Stari Grad	0.1530	0.3422	-0.1891
Jelsa	0.2164	0.2662	-0.0497
Hotel Marjan	0.3747	0.2231	0.1516
Hotel Amphora	0.3118	0.2182	0.0937
Banovina	0.4120	0.1532	0.2588
Dalmatia Tower	0.2373	0.2676	-0.0303
Gornja Podstrana	0.2736	0.2911	-0.0175
Zrnovnica	0.2413	0.3430	-0.1017
Omis	0.2212	0.3369	-0.1157

Tablica 3: Ulazni, izlazni i neto tokovi

5. ZAKLJUČAK

Predmet ovog završnog rada je odrediti optimalnu lokaciju za gradnju hotela koristeći se metodama poslovnog odlučivanja. U prvom redu tu je riječ o višekriterijalnoj analizi, ponajprije korištenoj PROMETHEE metodi, no osim te metode, u radu su ukratko objašnjene metode ELECTRE i AHP, svaka sa svojim prednostima i manama.

Problem istraživanja je u poboljšanju kvalitete turističkog smještaja na području Splitsko-dalmatinske županije, točnije odabir lokacije za potencijalnu gradnju luksuznog hotela, bilo da je riječ o resort tipu ili o manjem boutique hotelu ili hotelu koji je u obiteljskom vlasništvu. Naime, rezultati eVisitora i Turističke zajednice Splitsko-dalmatinske ukazuju na slabljenje rasta broja noćenja stranih, ali i domaćih državljanja u smještajnim jedinicama na području naše Županije. Naravno, isto se događa i na razini cijele RH, ali ovim radom se htjelo fokusirati na Splitsko-dalmatinsku županiju.

Naglo povećanje broja smještajnih jedinica, a samim time i registriranih kreveta, dovelo je do zasićenja ponude u tom segmentu, a uz to, veliki broj tih novoregistriranih smještajnih kapaciteta nisu doprinijeli poboljšanju iste. Ni prisutnost iznajmljivanja neregistriranih objekata, tj. iznajmljivanja „na crno“ nije dobro utjecala na statističke rezultate kojima se raspolaže. Površno provođenje Strategije razvoja turizma, bilo na državnoj, bilo na lokalnoj razini, i oslanjanje na prirodne ljepote, sunce, more i plaže nije dugoročno održivo.

U radu se pomoću navedene PROMETHEE metode vrednovalo devet proizvoljno izabranih alternativa (Stari Grad, Jelsa, Banovina, Hotel Marjan, Hotel Amphora, Dalmatia Tower, Žrnovnica, Podstrana, Omiš) prema devet različitih kriterija (Očekivani prihod, Troškovi, Atraktivnost čestice, Imidž destinacije, Blizina/pristupačnost generatorima ponude i potražnje, Izvedivost, Otvorenost lokalne samouprave za suradnju, Konkurencija, Postojanost ljudskih resursa). Svi navedeni kriteriji su prethodno bili rangirani od strane autora rada i članova ekspertne skupine kako bi se dobila težina svakoga od njih. Potom se izradila matrica odluke koja je skupa sa težinama kriterija predstavljala ulazne podatke u softverskom rješenju Decision Lab.

Provedenom analizom dobiveni su rezultati koji su u prethodnom poglavlju i detaljno analizirani. Alternativa Banovina je prema PROMETHEE analizi najbolja alternativa, i po pozitivnom, i po negativnom toku. S druge strane, alternativa Stari Grad na otoku Hvaru predstavlja najgoru od mogućih alternativa. Kao što je i prethodno u radu navedeno, na lokaciji Banovine koja trenutno predstavlja sjedište gradske uprave, bi se gradio luksuzni

hotel nedaleko od centra grada, ali i dovoljno daleko da gostima pruži privatnost i miran odmor izvan gradske buke…

Rezultati istraživanja, kao i njihova obrazloženja mogu uvelike olakšati donosiocu odluke odabir konačnog rješenja u obliku jedne ili više altrenativa. Doprinos rezultata istraživanja, kao i ovog rada se očituju i u činjenici što mogu poslužiti kao smjernica djelovanja poduzeća u turističkoj grani djelatnosti.

6. LITERATURA

1. Babić, Z. (2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split.
2. Ministarstvo turizma (2019): Popis kategoriziranih turističkih objekata u Republici Hrvatskoj, dostupno na: https://mint.gov.hr/pristup-informacijama/kategorizacija-11512/arhiva-11516/11516.
3. Turistička zajednica Splitsko-dalmatinske županije: Statistička analiza turističkog prometa u 2018. godini, dostupno na: https://www.dalmatia.hr/hr/statistike.
4. Turistička zajednica Splitsko-dalmatinske županije: Statistička analiza turističkog prometa u 2017. godini, dostupno na: https://www.dalmatia.hr/hr/statistike.
5. Institut za turizam: TOMAS 2017 Ljeto-stavovi i potrošnja turista u Hrvatskoj-prezentacija, dostupno na: http://www.iztzg.hr/hr/institut/projekti/istrazivanja/
6. World Travel and Tourism Council: The Economic Impact of Travel & Tourism, Croatia 2018, dostupno na: https://www.wttc.org/economic-impact/country-analysis/country-data/

7. SAŽETAK

U ovom radu je predstavljen problem izbora lokacije za gradnju hotela primjenom višekriterijalne analize. Alternativne lokacije su vrednovane s obzirom na odabrane kriterije pomoću PROMETHEE metode. Rangiranje kriterija, kao i ocjenjivanje lokacija po odabranim kriterijima od strane autora rada i članova ekspertne skupine je prethodilo samoj provedbi analize. U svrhu što točnije obrade podataka korišten je softverski paket posebne namjene Decision Lab. Analiza je ukazala na superiornost lokacije Banovina u odnosu na ostalih osam mogućih alternativa. S druge strane, alternativa Stari Grad je provedbom analize ostvarila porazne rezultate.

Ključne riječi: višekriterijalna analiza, rangiranje, ocjenjivanje, PROMETHEE metoda

8. SUMMARY

The thesis focuses on the application of mulitple-criteria decision analysis to the problem of hotel location. Alternatives are evaluated by selected criteria using the PROMETHEE method. Ranking of the criteria and evaluation of locations by the selected criteria precedes the implementation of the analysis. To gain the most accurate results of the analysis, software Decision Lab was used. Results showed the superiority of location Banovina compared to the rest, while location Stari Grad got the worst results out of all the alternatives.

Key words: multiple-criteria decision analysis, ranking, evaluation, PROMETHEE method