Primjena metode višekriterijske analize pri donošenju odluka

Vinovrški, Danijela

Master's thesis / Diplomski rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:761020

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JURJA DOBRILE U PULI

FAKULTET ZA EKONOMIJU I TURIZAM

"DR. MIJO MIRKOVIĆ"

PRIMJENA METODE VIŠEKRITERIJSKE ANALIZE PRI DONOŠENJU ODLUKA

Diplomski rad

Danijela Vinovrški

Pula, prosinac 2016.

SVEUČILIŠTE JURJA DOBRILE U PULI

FAKULTET ZA EKONOMIJU I TURIZAM

"DR. MIJO MIRKOVIĆ"

PRIMJENA METODE VIŠEKRITERIJSKE ANALIZE PRI DONOŠENJU ODLUKA

Diplomski rad

Kolegij: Informacijski sustavi u potpori upravljanju i odlučivanju

Nositelj kolegija: prof. dr. sc. Vanja Bevanda

Izradila:

Ime i prezime: Danijela Vinovrški

Broj indeksa: 470-ED

Smjer: Poslovna informatika (diplomski studij)

prosinac, 2016.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, _____, kandidat za prvostupnika ekonomije/poslovne ekonomije, smjera _____ ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

_____

U Puli, _____, _____ godine

IZJAVA

o korištenju autorskog djela

Ja, _____ dajem odobrenje Sveučilištu Jurja Dobrile

u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom _____
_____

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, _____ (datum)

Potpis

_____

Sadržaj

Uvod 1
1. Odlučivanje 3
1.1. Definiranje odluke 5
1.2. Donošenje odluka 6
1.3. Sustavi za potporu odlučivanju DSS 8
2. Situacije kod donošenja odluka 10
3. Višekriterijsko odlučivanje 19
3.1. Procjena važnosti kriterija 20
3.2. Grupno procjenjivanje težina 21
4. Metode višekriterijske analize 30
5. Primjer primjene PROMETHEE metode 54
5.1. D–Sight 54
5.2. Smart–Picker Pro 59
6. Zaključak 65
7. Literatura: 66
8. Dodaci 68

Uvod

Čovjek se svakodnevno susreće s odlučivanjem. Donošenje odluke je zahtjevan proces, a posljedice pogrešno donesene odluke mogu imati negativan utjecaj na život. Ponekad je teško donijeti odluku i za najjednostavnije probleme. Odluka se može donijeti u trenutku, a neki ljudi znaju odložiti donošenje odluka i uzeti si vremena i otići u potragu za novim informacijama. Zato je donošenje odluka, vještina koja se usavršava vremenom.

Za učinkovito donošenje odluka, osoba mora biti u stanju predvidjeti ishod svake opcije te utvrditi koja je opcija najbolja za određenu situaciju. Činjenica je da u današnje vrijeme pristup informacijama daleko lakši nego što je to bilo prije pa je samim time i olakšano donošenje odluka. Prvenstveno je skraćeno vrijeme traženja informacija ali i razvoj tehnologije ima svoj veliki utjecaj. Razvoj novih tehnologija, umreženost i novi načini komuniciranja uvelike olakšavaju izbor odluke. Stoga donositelj odluka mora biti svjestan razvoja novih tehnologija pa će se s lakoćom uhvatiti ukoštac s problemima. Problemi s kojima se donositelj odluka suočava nisu uvijek jednostavni i na njih se nekad ne može utjecati. Situacije kao što su nedostatak vremena ili financijskih sredstava mogu usporiti ili onemogućiti odlučivanje. Donositelj odluka mora biti spreman suočiti se s izazovima koji mu pokušavaju usporiti njegov rad i reagirati na vrijeme da bi njegova odluka imala pozitivan ishod. Računalni sustav koji podupire proces odlučivanja tako što pomaže donositelju odluka u organizaciji informacija, izboru odgovarajućih modela potrebnih za rješavanje problema odlučivanja i izvođenju modela jest sustav potpore odlučivanju. Takav sustav će omogućiti rješavanje složenih problema odlučivanja, korištenje velike količine informacija i skraćenog vremena potrebnog za donošenje odluke broja metoda rješavanja problema.

Cilj rada je prikazati softversku podršku donositelju odluka u primjeni višekriterijske metode odlučivanja. Temeljna pretpostavka rada jeste da se za korištenje pojedinih softverskih alata potrebno prethodno poznavanje temeljnih koncepata metoda odlučivanja.

Višekriterijsko odlučivanje je složen proces ali uz pomoć kvalitetnih računalnih programa moguće je brzo i uspješno riješiti probleme kao i provesti analizu rješenja. Kod predmeta istraživanja vršen je postupak istraživanja i ispitivanja traženog problema, te je korištena znanstvena hipoteza. Osnovne značajke znanstvene metode koje je ujedno koristio donositelj odluke su: objektivnost, pouzdanost, preciznost, sustavnost i općenitost. Uključuje matematičke

metode i logičko razmišljanje donositelja odluke. Isto tako, primijenjena je metoda induktivnog zaključivanja kojim se na temelju analize pojedinačnih činjenica dolazi do zaključka, metoda analize raščlanjivanjem složenih pojmova, zaključaka na njihove jednostavnije elemente kao i Delphi metoda koja je i obrađena, Svrha istraživanja jest prikazati višekriterijsko odlučivanje kao znanstvenu disciplinu uz pomoć računalnih programa.

Odabir pravilne metode predstavlja jedna od najvažnijih problema donositelju odluke. Budući da ne postoji jedinstvena metoda koja je jednako uspješna za sva područja, donositelj odluke je taj koji će na osnovi svojih sposobnosti procijeniti koju metodu izabrati i gdje je primijeniti. Glavni cilj metode višekriterijskog odlučivanja je poduprijeti donositelja odluka kada postoji veliki izbor alternativa za problem koji je potrebno riješiti. U literaturi se može naci veliki broj metoda višekriterijske analize. Nisu sve jednako interesantne i važne. U radu su nabrojane i opisane neke od poznatijih metoda.

Razlika između jednokriterijskog i višekriterijskog modela odlučivanja je da kod prve metode postoji jedna funkcija cilja koja je definirana nad skupom ograničenja, a kod višekriterijske metode problemi imaju dvije ili više funkcija.

Rad se sastoji od 8 poglavlja. U prvom poglavlju su dane definicije odlučivanja i donošenja odluka i objašnjen je sustav za potporu donošenju odluka.

U drugom poglavlju su navedene situacije kod donošenja odluka što je potkrijepljeno primjerima.

U trećem poglavlju su opisane višekriterijske metode za odlučivanje, procjena važnosti kriterija i pripadajući primjeri.

U četvrtom poglavlju su opisane neke od metoda iz literature.

U petom poglavlju su uzeti primjeri PROMEETHE metode i opisani koraci njihovog nastanka. Opisano je korištenje D–Sight softvera i Smart Picker Pro softvera koji mogu pomoći donositelju odluka pri odabiru svoje odluke.

U šestom poglavlju iznosi se zaključak, te je navedena literatura koja je korištena u izradi ovog rada i dodani su prilozi slika i tablica.

1. Odlučivanje

Odlučivanje bi se moglo definirati kao proces izbora između dvije ili više mogućnosti rješavanja problema (*Sikavica, 2014*). Čovjek se u životu, u svakodnevnim situacijama susreće s odlučivanjem i dok one jednostavne, rutinske odluke donosi brzo i s lakoćom. S druge strane će se susreti s kompliciranijim odlukama, gdje treba više vremena za razmišljanje i odabir, te upravo zbog tih razloga sam proces će duže trajati.

- **Proces odlučivanja**

Odlučivanje je stalan proces koji može trajati kraće ili duže i u kojem se vrši izbor između dvije ili više mogućnosti (*Sikavica, 1999*). Cilj procesa donošenja odluke podrazumijeva pod zadanim uvjetima riješiti postavljeni zadatak pri raspoloživim alternativama na optimalan način na vlastitom cilju i vrijednosnim prosudbama (*Barković, 2009*). Zato je potrebno kritički razmišljati, biti kreativan te trezveno određivati. Nije moguće da se sva tri navedena svojstva budu aktivirana u isti čas, nego se raščlanjivanjem procesa na korake izbjegavaju prepreke. Prema *H. A. Simonu* postoje tri elementa u procesu donošenja odluke:

	Proces odlučivanja
Faza obavještavanja	1. Organizacijski ciljevi 2. Procedura istraživanja i skeniranja 3. Sakupljanje podataka 4. Identifikacija problema 5. Klasifikacija problema 6. Izvješće o problemu
Faza oblikovanja	7. Formulacija problema 8. Skup kriterija za izbor 9. Istraživanje alternativa 10. Predviđanja i mjerenja outputa
Faza izbora	11. Rješenje modela 12. Analiza osjetljivosti 13. Izbor najbolje alternative 14. Plan primjene 15. Oblikovanje sustava kontrole

U **fazi obavještavanja** se utvrđuje problem odlučivanja koji se klasificira i eksplicitno formulira. U **fazi oblikovanja** se izabire model za rješavanje problema, traže se moguće aktivnosti poslovanja te se provode predviđanja. U zadnjoj fazi, **fazi izbora** izabire se jedno rješenje, posebno se izabiru potrebne aktivnosti poslovanja. Pogled različitih autora na određivanje broja faza pri procesu odlučivanja možemo klasificirati u dvije skupine: prva skupina autora kod kojih proces odlučivanja završava sa „donošenjem odluke" i kod kojih postoji manji broj faza u samom procesu, dok kod druge skupine autora sam proces odlučivanja gledaju šire pa će i zbog toga imati veći broj faza, čak i nakon donošenja odluke (*Barković, 2009*).

Neovisno o tipu odluke koja se treba donijeti, postoji šest koraka za donošenje odluka:

- Definirati problem,
- Razmotriti moguće alternative,
- Identificirati moguće ishode,
- Razmotriti isplate ili profit svake kombinacije alternativa i mogućih ishoda,
- Izabrati jedan od modela teorije odlučivanja,
- Primijeniti model i donijeti odluku (*Babić, 2011*).

Donositelji odluka, odnosno menadžeri u svojem poslovnom svijetu mogu se ponašati na dva načina. Prvi način ponašanja jest po „**modelu ekonomskog čovjeka"** a drugi način ponašanja jest po **„modelu administrativnog čovjeka**".

Kod **modela ekonomskog čovjeka** donositelji odluka su potpuno racionalni, što znači da se bira ona alternativa koja će postići najbolji rezultat uz dane uvjete. Racionalna odluka će se donijeti ako su sve informacije raspoložive, te ako je jasno određen cilj koji se želi ostvariti. Racionalnost može biti **objektivna i subjektivna.** Kada je riječ o modelu ekonomskog čovjeka tada se govori o objektivnoj racionalnosti koja se još i naziva normativna ili matematička teorija odlučivanja. Ona se temelji na poznavanju svih mogućnosti pri odlučivanju. Za razliku od modela ekonomskog čovjeka *H. Simon* uvodi **model administrativnog čovjeka** kao alternativni model ljudskog ponašanja. Odlučivanje se vrši u okolnostima subjektivne racionalnosti što znači da donositelj odluke ne traži najbolje rješenje jer ne posjeduje sve parametre za izbor najboljeg rješenja, nego se zadovoljava sa „zadovoljavajućim rješenjem".

Racionalnost je vrlo važan čimbenik u analizi ljudskog ponašanja. Razlikovanje racionalnog ponašanja od neracionalnog je vrlo bitno kada se radi o tome kako se donose. Racionalno odlučivanje ne može biti zasnovano na nasumičnom odabiru. Da li je neka odluka racionalna ili ne najprije ovisi o informacijama koje su raspoložive u datom trenutku i o ciljevima koje se žele postići. Klasična teorija pretpostavlja da je donositelj odluke racionalan kada teži donošenju optimalne odluke. **Optimalna odluka** je najbolja akcija kojom se maksimizira korist kod donošenja odluke. Kod optimalne odluke donositelj odluke nakon što je utvrdio da postoji nesklad između stvarnog i željenog stanja mora prepoznati, postaviti, organizirati ili rangirati ciljeve sa kojima će taj nesklad ukloniti. Na temelju ciljeva mora identificirati pravce akcija te mora biti sposoban usporediti sve raspoložive akcije te odabrati onu pravu koja će mu maksimizirati korist.

1.1. Definiranje odluke

Dok je odlučivanje definirano kao proces, odluka predstavlja rezultat tog procesa (*Sikavica,1999*). Da bi odluka mogla riješiti problem bitno je da bude precizna, jasna i nedvosmislena. Na donošenje odluke često i utječu drugi čimbenici kao npr. emotivno stanje donositelja odluke, stoga je nužno da odluka ne bude pod utjecanjem raspoloženja donositelja odluke. Čim je odluka donesena proces odlučivanja završava. Postoje brojne podjele od strane domaćih i inozemnih autora. Tako npr. *H.Simon* razlikuje **programirane odluke od neprogramiranih**. **Programirane odluke** su one koje se koriste za rješavanje problema koji su rutinski i to u situacijama koje se ponavljaju, dok **neprogramirane odluke** se koriste za one situacije koje se ne ponavljaju i koje nisu rutinske. Prema *J.R. Gordonu* odluke se djele na **rutinske i nerutinske**. **Rutinske** odluke se primjenjuju na nižim razinama menadžmenta, dok **nerutinske** su u nadležnosti top menadžmenta. *W. J. Gore* odluke dijeli na **rutinske, adaptivne i inovativne**. **Rutinske odluke** se donose po uobičajenim kriterijima odlučivanja, **adaptivne odluke** se više bave problemom nego zadatkom, dok **inovativne odluke** se odnose pri velikoj promjeni u poduzeću. *M.J. Hatch* odluke dijeli na **institucijske, organizacijske i operativne**. **Institucijske odluke** se tiču poslovne strategije poduzeća, **organizacijske odluke** se odnose na problem diferencijacije u poduzeću, dok **operativne odluke** se tiču redovnih situacija u poduzeću. *Dahl* i *Lindblom* odluke dijele na **strukturirane** i **nestrukturirane**. **Strukturirane odluke** se donose u okviru određene strukture, dok se **nestrukturirane odnose** u situacijama gdje nema stalnih uloga. *S. Marjanović* odluke dijeli prema **cilju** koji želi postići**, prema donositelju** (individualne i kolektivne), **prema funkcijama u poduzeću** (upravljačke,

organizacijske, rukovoditeljske, izvršne i kontrolne) i **prema načinu izvršenja** (strateške, operativne, uopćene, načelne, hitne i uvjetne). *J. Kralj* odluke dijeli na **političke** koje utječu na poslovanje poduzeća i **operativne** za koje postoje određena pravila kod donošenja i kod kojih se provodi zacrtana politika.

1.2. Donošenje odluka

Donošenje odluka je prisutno u svim djelatnostima. Odlučivanje je proučavanje i odabira alternativa da bi se pronašlo najbolje rješenje na temelju očekivanja donositelja odluka. Donositelj odluka (*engl. decision maker - DM*) se odlučuje za odabir s tim da mora biti upoznat sa svim ograničenjima te na osnovu tih podataka donese konačnu ispravnu odluku. Ako postoji mali broj kriterija lako je donijeti odluku. U većini slučajeva tada kriteriji i nisu konfliktni. S obzirom na trenutak u kojem donositelj odluke može intervenirati postoje tri kategorije:

- *a priori metode*

Omogućavaju donositelju odluke da intervenira prije samog procesa. Proces ne može početi ako donositelj odluke ne osigura neke potrebne podatke, kao na primjer, težine kriterija;

- *interaktivne metode*

Postupak rješavanja je učestao tj. metode koje omogućavaju donositelju odluke da posreduje tijekom pronalaženja rješenja i gdje je sam proces iterativan. Svaka iteracija osigurava donositelju odluke neko rješenje koje ne mora nužno biti i najbolje rješenje. Tada će donositelj odluke dati potrebnim parametrima neke nove vrijednosti te će se tako usmjeravati dalje proces;

- *a posteriori metode*

Omogućavaju donositelju odluke da posreduje nakon pronalaženja rješenja. Donositelj odluke odabire rješenje koje njemu odgovara iz skupa zadovoljavajućih rješenja *(T'Kindt, Billaut, 2002).*

Pogreške u odlučivanju

Posljedice pogrešno donesenih svakodnevnih odluka u pravilu će biti male i beznačajne, za razliku od pogrešno donesenih odluka koje su od važnog interesa za pojedinca, koje mogu biti dugotrajne. Najčešće zamke kod donošenja odluka: *(Barković, 2009).*

- neprepoznavanje prioriteta;
- nekonzultiranje;
- nekorištenje iskustva od prethodnika;
- nepriznavanje pogreške;
- žaljenje za donesenim odlukama;
- obećavanje nemogućega;
- neprovjeravanje podataka koji su podloga za odlučivanje.

Ovakve zamke su česte kod donošenja odluka. Kvalitetan menadžer će biti svjestan ovakvih pogrešaka te će ih nastojati izbjeći. Najčešće pogreške kod donošenja odluka: *(Barković, 2009).*

- ignoriranje problema;
- prihvaćanje prvog rješenja:
- uporno korištenje starih rješenja;
- traženje savršenog rješenja;
- pretjerana sigurnost i optimizam;
- otpornost uvjerenja;
- pogreška dostupnosti;
- način prezentacije.

Danas se sve više pažnje posvećuje donošenju odluke i to je proces koji samo izgleda jednostavno ali je zapravo vrlo zahtjevan i složen. Donošenje odluka je postalo najteži i najodgovorniji dio rukovođenja. Svaki pojedinac redovito odlučuje između jedne ili više mogućnosti. Zaposlenici u poduzećima svakodnevno donose odluke, bilo da se radi o odlukama

na vrhu, ili o odlukama na nižim pozicijama. Menadžerske odluke utječu na cijelu organizaciju te imaju znatnu odgovornost. Bez obzira na razinu u poduzeću, svakoj se odluci mora pristupiti s jasno određenim ciljem i mora joj se posvetiti puna pažnja. Kvalitetne odluke su osnova uspješnog poslovanja.

1.3. Sustavi za potporu odlučivanju DSS

Sustavi za potporu odlučivanju DSS (engl. *decision suport system*) su se razvijali kako bi omogućili i olakšali samostalno donošenje odluka, te osigurali dinamičan rad u timovima. Postoji jako puno definicija sustava za potporu odlučivanja. Jedna od definicija koju definira *Little, 1970* glasi da je DSS „ skup podataka za obradu podataka i procjena koji je baziran na modelima i pomaže menadžerima u donošenju odluka. Sustavi za potporu odlučivanju (u daljnjem tekstu DSS) nude mogućnost odabira rješenja uz pomoć odgovarajuće metode na temelju informacija od strane donositelja odluke. Sustav nudi prijedlog rješenja kad se prikupe svi relevantni podaci, te omogućava planiranje i kontrolu provođenja procesa i dovodi do fleksibilnosti u odlučivanju. Također, služi za organiziranje informacija, identifikaciju i dohvat informacija, analizu i transformaciju informacija, izbor modela odlučivanja i analizu dobivenih rezultata. DSS predstavlja koristan alat za menadžment, ali se njime menadžeri ne mogu zamijeniti. Njegova primarna funkcija je podržavanje nestrukturiranog poslovnog odlučivanja u poduzeću. Zapravo, to je fleksibilan i adaptivan sustav koji omogućava interaktivnu primjenu odlučivanja, modela i baza modela zajedno s bazama podataka i vlastitim pristupom donositelj odluka (*Sikavica,1999*).

Vrste sustava za podršku odlučivanju

Primjena sustava za podršku odlučivanju može biti u tri oblika:

Specifični DSS-ovi: aplikacija koja sadrži opcije koje korisnicima dopuštaju pronalaženje potrebnih informacija za područja koja ih zanimaju. Može biti programiran od same organizacije koja je ujedno i skuplja opcija ili putem DSS generatora.

DSS generatori: dizajnirani su za uporabu u brzom kreiranju različitih aplikacija, a može ih se definirati kao kombinaciju jezika, korisničkog interesa te grafičkih i izvještajnih podataka. Zapravo, to je hardverski i softverski paket koji dopušta pojedincu da lako i brzo izgradi specifični DSS.

DSS alati: čine ih elementi hardvera, softvera, procedura i podataka koji omogućavaju izgradnju navedenih specifičnih DSS-ova ili DSS generatora

Komponente sustava za podršku odlučivanju

Sustav za podršku odlučivanju sastoji se od tri podsustava:

Podsustav za upravljanje modelima: glavni element koji korisniku pruža potporu u izgradnji modela. Omogućuje integraciju pristupa podacima i modelima odlučivanja. U tabelarnom programskom paketu, npr. Excel to su različite varijable, parametri i formule koje su povezani radi postizanja nekog cilja. Zapravo, ovaj sustav omogućava da korisnik sam definira kombinaciju odrednica radi samostalnog formuliranja složenog modela. Temelj podsustava je baza u kojoj se čuvaju osnovni modeli sustava. Ta baza se sastoji od različitih vrsta modela s osnovnim ciljevima koje ima i baza podataka. Što znači, kada korisnik želi dobiti određene podatke na temelju pristupa bazi modela može odabrati vrstu modela kojeg će koristiti. Baza podataka sastoji se od gotovih kompjuterskih programa i modelskih blokova koji korisniku omogućavaju da gradi *ad hoc* aplikacije (*Turban i Meredith, 1991*). U sustavima za podršku vrlo je bitna veza među različitim modelima, isto kao i brz i efikasan pristup modelima. Sustav za upravljanje modelima dizajnira se radi osiguravanja podrške donošenju odluka te centraliziranog upravljanja modelima. Njegova bitna uloga je u premošćivanja između baze modela i baze podataka, da bi se bilo kakav utjecaj na model što više sadržajno eliminirao.

Podsustav za upravljanje podacima: osigurava kombinaciju različitih izvora podataka, čuvanje, procesuiranje i brisanje podataka. Podaci koji se koriste u sustavima dolaze iz transakcijske obrade, ili se skupljaju eksterno. Sustavi za podršku odlučivanju uključuju dvije vrste podataka. Prva je temeljna baza organizacije, dok druga koja je ujedno i manja, namjensko pravljena baza u sustavu za podršku odlučivanju.

Podsustav za vođenje dijaloga: osigurava korisniku komunikaciju sa sustavom za podršku odlučivanju. Komunikacija se odvija pomoću različitih ulaznih uređaja kao npr. tipkovnica, glasovne komande i sl. Osnovna funkcija podsustava je kreiranje prezentacije podataka u raznim formatima i u različitim kompjuterskim uređajima, npr. monitori, pisaći i sl. Unos podataka se vrši preko programskog paketa, npr. *Excel* gdje korisnik unosi podatke koje mu trebaju za preračunavanje traženih veličina.

DSS ima mnoge prednosti ali i nedostatke. Prednosti su: ušteda vremena, povećana efektivnost, poboljšana interpersonalna komunikacija, konkurentna prednost, smanjenje

troškova itd, a nedostaci: pretpostavka važnosti, transfer moći, nepredvidivi učinci, prebacivanje odgovornosti, smanjenje autoriteta, itd.

2. Situacije kod donošenja odluka

Kod donošenja odluka mogu se identificirati različite situacije ovisno o tome koliko se znanja ili informacija posjeduje:

Kod **odlučivanja u uvjetima sigurnosti** se može točno predvidjeti rezultat svake mogućnosti odluke. Odluka se donosi u uvjetima sigurnosti gdje se precizno može predvidjeti ishod, a donositelj odluke zna sa sigurnošću posljedice izbora odluke. U takvom slučaju se donosi ona odluka koja maksimizira njegovo zadovoljstvo. Problem kod ovakvog odlučivanja leži u tome što se najmanje najvažnijih odluka donosi u uvjetima sigurnosti, zapravo najvažnije odluke kod budućnosti organizacije odluke se gotovo nikad ne donose u uvjetima sigurnosti. Čak i one odluke koje se donose u uvjetima sigurnosti, donose se više u uvjetima relativne nego apsolutne sigurnosti (*Kreitner, 1998*).

Rizik je jedna situacija koja se nalazi između sigurnosti i nesigurnosti. **Kod situacije rizika** donositelju odluka poznate su vjerojatnosti nastupanja svake moguće situacije te se pokušava maksimizirati očekivano zadovoljstvo. Vjerojatnost da će se neka situacija ostvariti ovisi o donositelju odluke, ali i informacija kojima on raspolaže. Dijele se prema dva kriterija:

- Očekivana novčana vrijednost EMV (*engl. expected monetary value*)

EMV za svaku alternativu je suma mogućih isplata za svaku alternativu. EMV je ponderirani rezultat (isplata) koja je povezana s odlukom koja se odražava na alternativne događaje mogućih isplata. To je matematički izraz za umnožak vjerojatnosti pojavljivanja nekog događaja koji će rezultirati dobitkom ili gubitkom. Ako je dana tablica odluke s mogućim situacijama te pripadajućim alternativama moguće je odrediti EMV za svaku alternativu. U daljnjem tekstu naveden je primjer. Pretpostavimo da postoje mogućnosti, povoljne, osrednje i nepovoljno tržište koji imaju istu vjerojatnost događanja 1/3, i tada je:

EMV (veliki): (1/3) * 50 000 + (1/3) * 30 000 + (1/3) * (-50 000) = 10 000 €, EMV (mali): (1/3) * 20 000 + (1/3) * 20 000 +(1/3) * (-22 000) = 6 000 €, EMV (prazno): (1/3) * 0 + (1/3) * 0 + (1/3) * 0 = 0 €. Što je prikazano u tablici :

Tablica 1. EMV s jednakim vjerojatnostima

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	EMV
Veliko skladište	50 000	20 000	-40 000	**10 000**
Malo skladište	20 000	10 000	-12 000	6 000
Ne raditi ništa	0	0	0	0
Vjerojatnost	1/3	1/3	1/3	

(Izvor: Babić, 2011).

U tablici 1. Prikazane su alternative, situacije i efekti odluke, te je najbolja odluka otvaranje velikog skladišta.

- Očekivani gubitak EOL (*engl. expected opportunity loss*)

Očekivani gubitak (u daljnjem tekstu EOL) je suprotno od očekivane novčane vrijednosti (EMV). Žaljenje (gubitak prilike) mjeri se kao razlika između "*payoffa*" dane alternative i "*payoffa*" najbolje alternative u okviru iste moguće situacije (*Babić, 2011*).

U sljedećem primjeru prikazana je tablica EOL-a za svaku alternativu. EOL se određuje u dva vrlo jednostavna koraka. **U prvom koraku** kreira se tablica tako da se za svaku situaciju najprije odredi gubitak prilike za alternative koje su neizabrane. Gubitak prilike se računa tako da se odbije svaki ishod u stupcu od najboljeg ishoda u stupcu. Najbolji ishod se odnosi na 50 000 € koji se nalazi u prvom stupcu (povoljno tržište), i kao rezultat prve alternative (veliko skladište). Žaljenje u prvom stupcu se dobiva tako da se oduzmu sve isplate. Iznos koji smo dobili zapravo pokazuje koliko možemo izgubiti ako izaberemo neku drugu alternativu, a nastupi takva situacija. Ako je odabrano otvaranje malog skladišta pri situaciji povoljnog tržišta, prihod bi bio 20 000 €. Druga mogućnost koja je nepovoljna bili bi otvaranje velikog skladišta i time bi izgubili zaradu od 30 000 € (50 000 - 20 000).

Za primjer osrednjeg tržišta i prve alternative (veliko skladište) najbolji ishod je 30 000, te se žaljenje dobiva tako da se oduzmu sve veličine od 20 000 €. Za primjer nepovoljnog tržišta i alternative praznog skladišta najbolji ishod je 0 €, te se žaljenje dobiva na taj način da se sve veličine oduzmu od 0 € što je prikazano u sljedećoj tablici:

Tablica 2. Tablica žaljenja

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište
Veliko skladište	50 000 – 50 000 = 0	20000 – 20 000=0	0 – (- 40 000) = 40 000
Malo skladište	50000 – 20000= 30000	20 000 – 10 000=10000	0 – (-12 000) = 12 000
Ne raditi ništa	50 000-0=50000	20 000 – 0 =20 000	0 – 0 = 0

(Izvor: *Babić, 2011*).

U drugom koraku, za svaku alternativu EOL se dobiva množenjem vjerojatnosti svake mogućnosti situacije s odgovarajućom vrijednošću gubitka prilike što je prikazano u sljedećem primjeru:

EOL (veliki)= 1/3*0 + 1/3 * 0 + 1/3 * 40 000 = 13 333.33€, EOL (mali) = (1/3) * 30000 + (1/3) * 10000 + (1/3) * 12000 =17 333.33€, EOL (prazno skladište) = 1/3 * 50 000 + 1/3 * 20 000 + 1/3 * 0 = 23 333.33 €.

Tablica 3. EOL s vjerojatnostima 1/3

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	
Veliko skladište	0	0	40 000	**13 333.33**
Malo skladište	30000	10000	12000	17 333.33
Ne raditi ništa	50000	20000	0	23 333.33
Vjerojatnost	1/3	1/3	1/3	

(Izvor: Babić, 2011).

U tablici 3. Prikazane su alternative, situacije i efekti odluke, te je najbolja prva alternativa, tj. odluka otvaranje velikog skladišta. Navedene dvije tvrdnje prikazane su tablicom odluke (*payoff*) gdje su alternative A_1 ,...A_m, a moguće situacije S_1,..., S_n. Elementi a_{ij} koji su uvjetne vrijednosti koje prikazuju stvarne isplate (dobitak ili gubitak).

Tablica 4. Tablica odluke ili payoff

Situacije / Alternative	S_1	S_2	.....	S_n
A_1	a_{11}	a_{12}	.....	a_{1n}
A_2	a_{21}	a_{22}	.....	a_{2n}
⋮	⋮	⋮	⋮	⋮
A_m	a_{m1}	a_{m2}	.....	a_{mn}
Vjerojatnosti	p_1	p_2	.....	p_n

(Izvor: Babić, 2011).

Da bi se odredio EOL potrebno je prvo dobiti izračun tablice žaljenja, a ona se računa tako se oduzmu elementi svakog stupca *payoff* tablice od najboljeg ishoda, tj. a_j*

gdje je $a_j * = \max_i a_{ij}$ maksimalni element u *j*-tom stupcu *payoff* tablice. Elementi tablice žaljenja su $e_{ij} = a_j * - a_{ij}$.

EOL za svaku alternativu se računa tako da se elementi tablice žaljenja skalarno pomnože s vjerojatnostima, tj.

EOL $(A_i) = \sum_{j=1}^{n} e_{ij} \cdot p_j = \sum_{j=1}^{n} (a_j * - a_{ij}) \cdot p_j = \sum_{j=1}^{n} a_j * \cdot p_j - \sum_{j=1}^{n} a_{ij} \cdot p_j$.

Ako se promjeni vjerojatnost pojavljivanja mogućih situacija 0.20, 0.40 i 0.40 dobije se ista tablica, ali s drugim vjerojatnostima, kao što je prikazano u sljedećem primjeru tablice 5.

Tablica 5. EOL s vjerojatnostima 0.20, 0.40 i 0.40

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	EOL
Veliko skladište	0	0	40 000	16 000
Malo skladište	30 000	10 000	12 000	**14 800**
Ne raditi ništa	50 000	20 000	0	18 000
Vjerojatnost	0.20	0.40	0.40	

(Izvor: Babić, 2011).

EOL (veliki)= 0.20 * 0 + 0.40 * 0 + 0.40 * 40000 = 16 000 €, EOL (mali)= 0.20 * 30000 + 0.40 * 0.40 10 000 + 0.40 * 12 000= 14 800 € EOL (prazno)= 0.20 * 50 000 + 0.40 * 20 000 + 0.40 * 0 = 18 000 €.

Kod **odlučivanja pri neizvjesnosti** donositelj odluka nedovoljno poznaje stvarnost koja mu nije pod kontrolom, a može oblikovati ishod odluke. U ovoj situaciji promjene su brze, a nestabilnost okoline veća. *E.F. Harrison* nesigurnost smatra jazom između onoga što znamo i što bi trebali znati. Donositelj odluke nema nikakvih znanja o pojedinoj situaciji niti može procijeniti vjerojatnost pojavljivanje iste. Kada se vjerojatnost situacije može procijeniti primjenjuju se kriteriji EMV i EOL, a kada se javi situacija kod koje se ne može procijeniti vjerojatnost ishoda s povjerenjem, onda se radi o situaciji o odlučivanju pri neizvjesnosti. Ovakva situacija je pogodna za istraživačke projekte, uvođenje nove tehnologije, osvajanje novog tržišta i sl., zapravo gdje god se nedovoljno poznaje problem. Kriteriji koji se koriste pri ovakvom problemu su:

- Maksimin kriterij
- Maksimaks kriterij
- Laplaceov kriterij
- Kriterij realizma
- Minimaks kriterij žaljenja

- **Maksimin kriterij**

Kod ovog kriterija pretpostavka je da će se svaka alternativa odvijati u uvjetima koji su najnepovoljniji. Odabrat će se ona alternativa koja maksimizira minimlan tj. najlošiji ishod za svaku alternativu. Pretpostavlja se da donositelj odluke pretpostavlja najgori mogući ishod svake alternative.

Prvo se locira najlošiji ishod za svaku alternativu te se potom izabire ona najmanje loša alternativa. Budući da promatrani kriterij odabire alternativu koja ima najmanji mogući gubitak tretira se kao pesimistički kriterij odlučivanja i smatra se kao jedno od konzervativnijih pravila odlučivanja (odabire ga onaj donositelj odluke koji nije sklon riziku) (*Babić, 2011*). U sljedećem primjeru tj. u tablici 6. Prikazane su alternative, situacije i efekti odluke, te je najbolja alternativa „ne raditi ništa“:

Tablica 6. Maksimin izbor projekta

Situacije / Alternative	**Povoljno tržište**	**Orednje tržište**	**Nepovoljno tržište**	**Najlošiji ishod**
Projekt A	50 000	20 000	-40 000	-40 000
Projekt B	20 000	10 000	-12 000	-12 000
Ne raditi ništa	0	0	0	**0**

(*Izvor: Babić, 2011).*

- **Maksimaks kriterij**

Prema ovom kriteriju se odabire ona strategija ili alternativa koja maksimizira najbolji rezultat. Donositelj odluke izabire alternativu koja ima najveći dobitak te donosi odluku „sve ili ništa“. Kod ovog kriterija veliki je rizik stoga su donositelji odluke oni koji su taj rizik spremni i podnijeti. U sljedećem primjeru maksimaks izbor je prva alternativa tj. Projekt A jer je maksimum od maksimalnih brojeva po svakoj alternativi.

Tablica 7. Maksimaks izbor projekta

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	Maksimalni ishod
Projekt A	50 000	20 000	-40 000	**50 000**
Projekt B	20 000	10 000	-12 0000	20 000
Ne raditi ništa	0	0	0	0

(Izvor: Babić, 2011).

- **Laplaceov kriterij**[1]

Pretpostavlja se da su vjerojatnosti pojavljivanja svih mogućih situacija jednake i da su sve situacije jednako vjerojatne, odnosno jednako moguće (*Babić, 2011*). Bira se ona alternativa s najvećim prosječnim ishodom. U sljedećem primjeru prva alternativa tj. Projekt A je najbolje rješenje:

Tablica 8. Laplaecov izbor projekta

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	Prosječne vrijednosti
Projekt A	50 000	20 000	-40 000	**10 000**
Projekt B	20 000	10 000	-12 000	6 000
Ne raditi ništa	0	0	0	0

(Izvor: Babić, 2011).

Vrijednosti su izračunate na sljedeći način:

Alternativa 1 = (50 000 + 20000 + (-40000)) / 3 = 10000, Alternativa 2 = (20 000 + 10 000 + (-22 000)) / 3 = 6 000, Alternativa 3 = (0 + 0 + 0) / 3 = 0.

[1] Pierre-Simon Laplace (1749-1827), francuski matematičar i astronom

- **Kriterij realizma (Hurwiczov kriterij[2])**

Kriterij koji je naziva i kriterijem ponderiranog prosjeka. Donositelj odluke odlučuje da li naginje optimizam ili pesimizam pri donošenju odluke. Prvi korak je odabir koeficijenta realizma α koji može biti broj između 0 i 1. Što je koeficijent bliže 0 to je odluka pesimističnija, a što je bliže 1, odluka je optimističnija. Maksimalan element u retku predstavlja najbolji ishod za strategiju, a najmanji element u retku predstavlja najgori ishod za tu strategiju. Ovaj kriterij je zapravo kombinacija maksimin i maksimaks metode i računa se po formuli:

Ponderirani prosjek = α · (maksimum u retku) + (1-α) · (minimum u retku), i nakon što se izračunaju svi ponderirani prosjeci odabire se ona alternativa koja ima maksimalan ponderirani prosjek. U sljedećem primjeru uzeti je koeficijent realizma $\alpha = 0.6$, gdje je najbolja opcija izbor 2, odnosno Projekt B jer ima najveći ponderirani prosjek što je prikazano u tablici 9.

Tablica 9. Hurwiczov kriterij za vrijednost α=0.6

Situacije / Alternative	Povoljno tržište	Osrednje tržište	Nepovoljno tržište	Ponderirani prosjek
Projekt A	50 000	20 000	-40 000	-4 000
Projekt B	20 000	10 000	-12 000	**800**
Ne raditi ništa	0	0	0	0

(*Izvor: Babić, 2011*).

H (Projekt A) = 0.4 * 50 000 + 0.6 * (-40 000) = -4 000, H

(Projekt B) = 0.4 * 20 000 + 0.6* (-12 000) = 800, H

(Ne raditi ništa) = 0.4 * 0 + 0.6 * 0 = 0.

[2] Leonid Hurwicz (1917-2008), dobitnik Nobelove nagrade za ekonomiju 2007

- **Minimaks kriterij žaljenja**

Ovaj kriterij se odnosi na biranje one strategije koja minimizira maksimalno žaljenje loše odluke u bilo kojoj mogućoj situaciji. Žaljenje (gubitak prilike) mjeri se kao razlika između *payoffa* dane alternative i *payoffa* najbolje alternative u okviru iste moguće situacije *(state of nature*) (*Babić, 2011*). U sljedećem primjeru je prikazano kako je alternativa 2. ili projekt B taj koja minimizira maksimalan gubitak prilike (žaljenja).

Tablica 10. Minimaks kriterija žaljenja za projekte

Situacije / **Alternative**	**Povoljno tržište**	**Osrednje tržište**	**Nepovoljno tržište**	**Maksimalno žaljenje**
Projekt A	0	0	40 000	40 000
Projekt B	30 000	10 000	12 000	**30 000**
Ne raditi ništa	50 000	20 000	0	50 000

(*Izvor: Babić, 2011*).

Navedeni kriteriji se razmatraju kad postoji odlučivanje pri neizvjesnosti tj. kad ne može procijeniti vjerojatnost ishoda. Donositelji odluka često prikupljanjem dodatnih informacija pokušavaju umanjiti neizvjesnost. Ali to prikupljanje nije besplatno i taj se trošak tretira kao investicija, te menadžeri moraju dobro razmisliti da li se žele upuštati u takav posao. Pod dodatnim informacijama se smatra istraživanje tržišta, pilot projekti, itd. Koliko vrijedi ta dodatna informacija procijeniti će sam donositelj odluke.

3. Višekriterijsko odlučivanje

Višekriterijske metode za donošenje odluka prikladne su za rješavanje složenih problema s različitim oblicima podataka i informacija, za više interese i perspektive. Metoda je dalje podijeljena u višeobjektivno odlučivanje i višeatributno odlučivanje. Zajednička karakteristika su im konflikni kriteriji. Glavna razlika između ove dvije skupine metoda se temelji na broju alternativa kod procjene. Višeatributne metode se odnose na odluke koje su dizajnirane za odabir diskretne alternative, a višeobjektivne metode su prikladnije kad su u pitanju višeobjektivni problemi planiranja. Kod višeobjektivnog odlučivanja (također poznato kao višeobjektivno programiranje) alternative nisu unaprijed određene, već podliježu nizu ograničenja. Ove metode omogućuju bolje razumijevanje problema odlučivanja, te također mogu dati rješenja za povećanje kompleksnih problema upravljanja. Svaka metoda ima svoja ograničenja, što znači da metode i rezultati nisu nužno usporedivi. Kod problema višeatributnog odlučivanja za razlikovanje inačica razlikujemo: kriterije, atribute i ciljeve.

- kriteriji: numeričke funkcije koje treba maksimizirati ili minimizirati,
- atributi: osobine svojstva pojedinih inačica,
- ciljevi: razine koje želimo postići (*Sikavica, 2014).*

Kod problema odlučivanja postoje inačice koje su poznate te se za njihovo uspoređivanje upotrebljavaju različiti atributi. Svaka inačica atributa sadrži svojstva koja su bitna za ostvarivanje ciljeva. I da bi ti atributi mogli poslužiti kao kriterij u odlučivanju, moraju biti mjerljivi. Svi kriteriji ne moraju biti jednako važni i to predstavlja dodatnu složenost.

Ne postoji dobra ili loša tehnika, postoji ona tehnika koja je prilagođena za situaciju i koja je u specifičnim okolnostima bolja od druge. Izbor neke MCDA (*engl. Multiple-criteria decision aid*) metode se ne dešava na početku procesa već se pristupa problemu kad donositelj odluke u potpunosti razumije problem, alternative moraju biti ostvarive i mora postojati svjesnost mogućnosti sukoba između kriterija. MCDA je engleski naziv za znanstveno područje koja pomaže donositeljima odluke pri odlučivanju u situacijama koje su zahtjevne i kompleksne i gdje postoji više konfliktnih ciljeva, odnosno kriterija. Kao disciplina obuhvaća područje matematike, upravljanja, informatike, psihologije i ekonomije. Zapravo, primjena je šira i može se koristiti za rješavanje bilo kakvih problema. Ne spada u metode koje su automatske i koje će dovesti do istog rješenja, nego spada u subjektivne metode koje dovode do kompromisa. Istraživači i komercijalne tvrtke u posljednjih deset godina su razvili različite programe kako

bi pomogli korisnicima riješiti svoje probleme. S obzirom na broj MCDA metoda na raspolaganju, donositelj odluke suočen je s teškom zadaćom odabirom odgovarajućeg alata za donošenje odluka. Niti jedan od načina nije savršeni, niti se mogu primijeniti na sve probleme. Svaka metoda je posebna i ima svoje granice i perspektive. Na slici 11. su prikazane neke od MCDA metoda.

Tablica 11. MCDA softverski programi

MCDA metode	Softver
PROMETHEE- GAIA	D-Sights, Decision Lab, Smart Picker Pro
ELECTRE	Electre IS, ELECTRE III-IV
AHP	ExpertChoice, RightChoiceDSS, MakeItRational, EasyMind
ANP	Super Decisions, Decision Lens
DEA	Win4DEAP, EfficiencyMeasurement System, DEASolver Online, DEAFrontier,DEA-Solver PRO, FrontierAnalyst
UTA	Right Choice, UTA+, DECERNS
MACBETH	M-MACBETH
TOPSIS	DECERNS

(Izvor: Ishizaka, Nemery, 2013).

U višekriterijskom odlučivanju važnu ulogu igra i donositelj odluke. On je istraživač koji treba odabrati najbolje kompromisno rješenje danog problema. Njegova uloga nije toliko bitna kad se radi o jednokriterijskom problemu. Jednokriterijski problem kad je jednom formuliran, njegovo rješenje dobiva se jednostavno.

3.1. Procjena važnosti kriterija

Problem koji je višekriterijski sadrži više različitih kriterija koji mogu biti od različite važnosti za donosioca odluke. Za procjenu kriterija odlučuje ili sam donositelj odluke ili to može biti grupa eksperata (stručnjaka). Za odabir najbolje alternative potrebne su sve informacije koje će zadovoljiti odabir svakog atributa tj. kriterija. To znači da se informacije prikupljaju na različite načine počevši od informacija koje ima pojedinac ili da se te iste informacije dobivaju od izvjesnog broja ljudi tj. eksperata. Prednost kod uzimanja mišljenja kod veće grupe ljudi u odnosu na pojedinačno mišljenja donosi niz dobrih pozitivnih učinaka

kao što su: širi spektar informacija zbog iskustva pojedinaca, manji utrošak vremena i diskusije iz kojih se mogu stvoriti razne ideje. Kod važnosti kriterija postoje dva gledišta:

- Prioritet: što se odnosi kada su kriteriji poredani po važnosti. Drugi po redu kriterij (koji je manje važan kriterij) se ne uzima u obzir sve dok se kriterij koji je na višem nivou (više važan) ne uzme u razmatranje;
- Težine: koristi se kako bi se brojčano izrazila važnost kriterija ili da bi se razlikovala važnost kriterija unutar istog prioriteta.

Ako je w_j (j = 1, 2, ..., n) težina pridružena j-tom kriteriju. Ponderi se normaliziraju te tada vrijedi: $0 \leq w_j \leq 1$, $\sum_{j=1}^{n} w_j = 1$, pri čemu izraz $w_k > w_m$ znači da je k-ti kriterij važniji od m-tog, a izraz $w_k = w_m$ navodi da su jednako važni.

3.2. Grupno procjenjivanje težina

Metode za određivanje važnosti kriterija na temelju mišljenja ili ocjena više eksperata:

Rangiranje

Ova metoda ne traži puno vremena za provedbu. Potrebno je odrediti težine n kriterija X_j (j = 1, 2, ..., n) na temelju njihovog sudjelovanja od strane l eksperata E_k (k = 1, 2, ..., l).

Postupak pri rangiranju je sljedeći:

- Svaki ekspert mora poredati kriterije po važnosti gdje najvažnijem kriteriju dodjeli broj n-1, drugom po važnosti n-2, sve tako do najmanje važnog kriterija kojem se dodjeli broj 0;
- Potom se računa izraz:

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

gdje je:

R_{jk} — broj koji je pridružen kriteriju j od k-tog eksperta tj. neki od brojeva 0 *do* n-1,

R_j— suma svih rangova tj. svih eksperata koji su pridruženi j-tom kriteriju.

- Težine kriterija se određuju na sljedeći način:

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

gdje je: w_j težina j-tog kriterija koji su sastavljeni od prosudbe svih eksperata za taj kriterij.

Primjer težine kriterija na temelju njihovog rangiranja od 20 eksperata prema sljedećoj tablici:

Tablica 12. Rangiranje prema težini

Rang / Kriteriji	1	2	3
z_1	10	10	0
z_2	6	7	7
z_3	4	3	13

(Izvor: Babić, 2011).

Dakle, za 10 eksperata kriterij z_1 je najvažniji (postavljen je na prvo mjesto rang liste), za 10 sljedećih eksperata z_2 drugi je po važnosti, a na trećoj poziciji ništa nije stavljeno po važnosti.

Kriterij z_2 je za 6 eksperata najbolji, za sljedećih 7 eksperata je drugi po važnosti, a za zadnjih 7 eksperata on je najmanje važan kriterij.

Kriterij z_3 je najbolji za 4 eksperta, za 3 eksperata je drugi po važnosti, a za zadnjih 13 eksperata to je najmanje važan kriterij.

10 eksperata procjenilo je da je z_1 najvažniji kriterij, njemu se 10 puta pridružuje broj 2 (n-1 = 3-1 = 2). Kod ostalih 10 eksperata procjena je da je z_1 drugi po važnosti tj. 10 puta se kriteriju z_1 pridružuje $n - 2 = 1$. Na temelju tih rangiranja izraz R_1 se računa na sljedeći način:

$R_1 = \sum_{k=1}^{20} R_{1k} = 2 \cdot 10 + 1 \cdot 10 + 0 \cdot 0 = 30,$

$R_2 = \sum_{k=1}^{20} R_{2k} = 2 \cdot 6 + 1 \cdot 7 + 0 \cdot 7 = 19,$

$R_3 = \sum_{k=1}^{20} R_{3k} = 2 \cdot 4 + 1 \cdot 3 + 0 \cdot 13 = 11.$

Dok je suma tih brojeva:

$\sum_{j=1}^{n} R_j = R_1 + R_2 + R_3 = 30 + 19 + 11 = 60.$

a težine za pojedine kriterije su:

$w_1 = \frac{R_1}{\sum_{j=1}^{3} R_j} = \frac{30}{60} = 0.50,\ \ w_2 = \frac{R_2}{\sum_{j=1}^{3} R_j} = \frac{19}{60} = 0.317$ i $w_3 = \frac{R_3}{\sum_{j=1}^{3} R_j} = \frac{11}{60} = 0.183.$

gdje vrijedi:

$\sum_{j=1}^{3} w_j = 1.$

Ipak, rangiranje će zavisiti o vremenu na raspolaganju, veličini poduzeća te o stručnim znanjima. Metoda je prigodna kada je za određivanje težina kriterija relevantno mišljenje veće broja osoba.

Ocjenjivanje

Kriteriji se brojčano ocjenjuju za svaki kriterij gdje je poostupak sljedeći:

- Ocjene su zadane u intervalu npr. 0-10 ili od 0-100 (gdje je 0 najmanja ocjena);
- Težine pojedinih kriterija iznose:

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

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

gdje je:

p_{jk} – ocjena *k*-tog broja *j*–tom kriteriju,

w_{jk}– težina izračunata za *j*–ti kriterij od *k*–tog eksperta (normalizirana),

w_j – ukupna težina za *j*–ti kriterij.

Uzet je primjer gdje četiri eksperta moraju procjeniti tri kriterija z_1, z_2 i z_3 sa ocjenama p_{jk} . Ocjene su prikazane u tablici od 0 – 100.

Tablica 13. Ocjene kriterija

Eksperti / Kriteriji	A	B	C	D
z_1	15	50	45	40
z_2	30	40	30	80
z_3	65	25	10	30
$\sum_{j=1}^{n} p_{jk}$	110	115	85	150

(Izvor: Babić, 2011).

Težina svakog eksperta dobivena je po formuli:

$w_{jk} = \frac{p_{jk}}{\sum_{j=1}^{n} p_{jk}}$, gdje se dobiju rezultati prikazani u tablici 14.

Tablica 14. Norminirane ocjene kriterija

Ekperti / Kriteriji	A	B	C	D	$\sum_{k=1}^{l} w_{jk}$
z_1	15 /110= 0.1364	50/115= 0,4348	45/85= 0.5294	40/150= 0.2667	1.3672
z_2	30/110= 0.2727	40/115= 0.3478	30/85= 0.3529	80/150= 0.5333	1.5068
z_3	65/110= 0.5909	25/115= 0.2174	10/85= 0.1176	30/150= 0.2	1.1259
$\sum_{j=1}^{n} p_{jk}$	1	1	1	1	4

(Izvor: Babić, 2011).

Pri tome $\sum_{j=1}^{n} w_{jk}$ je suma težina za sve kriterije po *k*–tom ekspertu, a $\sum_{k=1}^{l} wjk$ suma težina za *j*–ti kriterij od svih eksperta. Konačne težine dobivene su po formuli:

$wj = \frac{\sum_{k=1}^{l} wjk}{\sum_{j=1}^{n} \sum_{k=1}^{l} wjk}$, gdje se dobije:

$w_1 = \frac{1.3672}{4} = 0.3418, \quad w_2 = \frac{1.5068}{4} = 0.3767, \quad w_3 = \frac{1.1259}{4} = 0.2815.$

Metoda usporedbe po parovima

Prema ovoj metodi svaki ekspert uspoređuje svaki kriterij sa svim ostalima da bi izrazio svoje preferencije. Sve metode usporedbi su u pravilu jednake jer ekspert ako npr. ocjenjuje dva kriterija A i B, rezultat može biti da je kriterij A važniji od kriterija B ili obratno. Postupak se odvija na sljedeći način:

- Prvo se izračuna izraz:

$$f_{jk} = \sum_{j' \neq j} f\left(\frac{j}{j'}\right)k$$

gdje je: $f_{(j/j')k}$ = 0 ako je *j*—ti kriterij lošiji od *j* ' tog za *k*—tog eksperta

1 ako je *j*—ti kriterij bolji od *j* ' tog za *k*—tog eksperta.

- Potom se računaju težine koje *k*—ti ekspert dao *j*—tom kriteriju:

$w_{jk} = \frac{f_{jk}}{J}$, gdje je:

J – broj svih mogućih usporedbi po parovima koje treba dati ekspert, tj. broj kombinacija bez ponavljanja, odnosno $J = \binom{n}{2}$.

- Konačne težine se računaju kao i kod metode ocjenjivanja po formuli, odnosno $w_j = \frac{\sum_{k=1}^{l} wjk}{\sum_{j=1}^{n}\sum_{k=1}^{l} wjk}$, gdje je *n* broj kriterija, a *l* broj eksperata.

U sljedećem primjeru (*Babić, 2011*). dana su 5 kriterija A, B, C, D i E i eksperti E_1, E_2 i E_3, te se dobiju sljedeći rezultati:

1.	A>B	6.	B>D
2.	A>C	7.	B<E
3.	A>D	8.	C>D
4.	A>E	9.	C<E
5.	B<C	10.	D<E

Znak " >" znači da je A "više preferiran" nego B,

Znak " <" znači da je B "manje preferiran" nego A.

gdje je f_{jk}:

Kriterij	$f_{jk} = f_{j1}$
A	4 (toliko puta je važniji od drugih kriterija)
B	1
C	2
D	0
E	3

Dva kriterija ne mogu biti ocijenjeni jednako važnima. Tako broj f_{jk} može biti i decimalan (npr. 3.5) . Tada je: $w_{jk}=\frac{fjk}{J}$, odnosno dobiju se ujedno i ocjene za prvog eksperta gdje slijedi:

$w_{AK}=\frac{4}{10}=0.4$, $w_{BK}=\frac{1}{10}=0.1$, $w_{CK}=\frac{2}{10}=0.2$, $w_{DK}=\frac{0}{10}=0$, $w_{EK}=\frac{3}{10}=0.3$.

Drugi ekspert ima sljedeće ocjene:		odnosno, Kriterij	$f_{jk} = f_{j2}$
1. A < B	6. B > D	A	2
2. A > C	7. B > E	B	4
3. A < D	8. C < D	C	1
4. A > E	9. C > E	D	3
5. B > C	10. D > E	E	0

$w_{A2}=\frac{2}{10}=0.2$, $w_{B2}=\frac{4}{10}=0.4$, $w_{C2}=\frac{1}{10}=0.1$, $w_{D2}=\frac{3}{10}=0.3$, $w_{E2}=\frac{0}{10}=0$.

Treći ekspert ima sljedeće ocjene, odnosno, Kriterij $f_{jk} = f_{j3}$

1. A < B	6. B > D	A	1
2. A < C	7. B > E	B	4
3. A > D	8. C > D	C	3
4. A < E	9. C > E	D	0
5. B > C	10. D < E	E	2

$w_{A3}= \frac{1}{10} = 0.1$, $w_{B3} = \frac{4}{10} = 0.4$, $w_{C3}= \frac{3}{10} = 0.3$, $w_{D3}= \frac{0}{10} = 0$, $w_{E3}= \frac{2}{10} = 0.2$.

- Kada su sve težine prikupljene primjenjuje se formula: $wj= \frac{\sum_{k=1}^{l} wjk}{\sum_{j=1}^{n}\sum_{k=1}^{l} wjk}$.
- gdje je:

$w_A= \frac{wA1+wA2+wA3}{3} = 0.233,$

$w_B = \frac{wB1+wB2+wB3}{3} = 0.3,$

$w_C = \frac{wC1+wC2+wC3}{3} = 0.2,$

$w_D = \frac{wD1+wD2+wD3}{3} = 0.1,$

$w_E = \frac{wE1+wE2+wE3}{3} = 0.166,$

gdje je : $w_A + w_B + w_C + w_D + w_E = 1$.

Metoda usporedbe u parovima spada u najčešće primjenjivane analitičke procjena grupe poslova.

Delphi metoda (engl. ***Delphi Method*****)**

Delphi metodu odlučivanja prvi su upotrijebili u „ *Rand Corporation*“ u SAD-u kako bi predvidjeli kakav bi utjecaj imao nuklearni napad na SAD. Delphi metoda se često koristi te je prihvaćena metoda za prikupljanje podataka od ispitanika u području stručnosti. Metoda je osmišljena kao komunikacijski proces grupe kojem je cilj postizanje konvergencije mišljenja u određenom području. Delphi je široko korištena u raznim područjima kao što su planiranje programa, istraživanje raznih postupaka, korištenje resursa i sl. Delphi metoda se danas koristi

u dva različita oblika. Prvi oblik koji se još naziva i „ Delphi vježba“ (engl. *Delphi Exercise*) i koristi se uz pomoć papira i olovke. Tu se radi o tome da nadzorni tim pošalje upitnik većoj grupi. Nakon što je upitnik ispunjen on se vraća nadzornom timu koji zatim rezimira rezultate i na temelju odgovora sastavlja novi upitnik za novu skupinu ljudi. Grupi je nakon toga pružena barem jedna prilika ponovno procijeniti originalne odgovore temeljene na ispitima za grupno odgovaranje. Drugi oblik metode spada pod novije strukture ponekad zvane „Delphi konferencija“ (engl. *Delphi Conference*). Zamjenjuje glavno promatranje u velikom postotku koje je programirano da iznese cijelu kompilaciju najtočnijih rezultata. Ovaj pristup eliminira kašnjenje koje nastaje zbog sumiranja svakog kruga odgovora. Delphi tehnika se koristi u ovim situacijama:

- kad se u rješavanju problema ne koriste specijalne analitičke tehnike;
- kad osobe koje provode istraživanje nemaju mogućnost adekvatne konkurencije;
- kad u donošenju odluka treba ispitati više osoba nego što se može obaviti direktnom komunikacijom;
- kad česti sastanci nisu mogući zbog troškova i vremena;
- kad se u odlučivanju želi izbjeći dominacija jedne osobe.

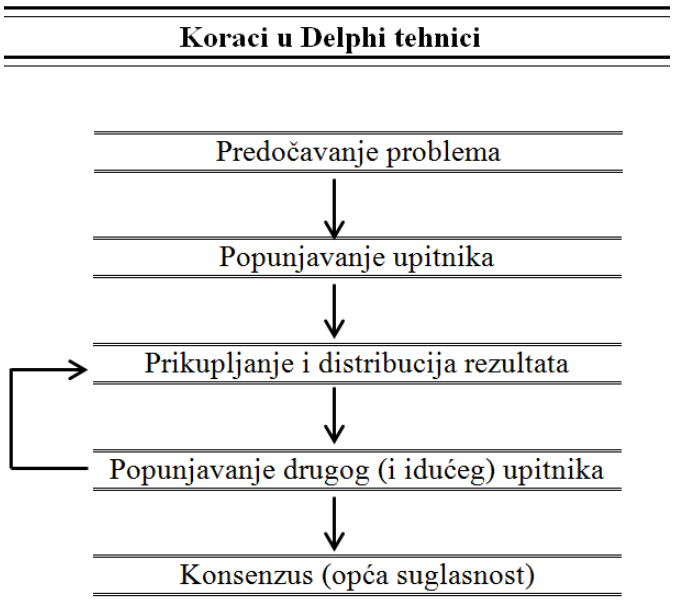
Iako Delphi metoda izgleda jednostavna, mnogi pojedinci su doživjeli razočaravajuća iskustva primjenjujući ovu metodu. Neki od razloga su:

- Pretpostavku da Delphi može biti nadomjestak za komunikaciju u određenoj situaciji;
- Loše tehnike sažimanja i nametanje odgovora grupi;
- Ignoriranje i neistraživanje neslaganja,
- Podcjenjivanje metode (*Linstone, 2002*).

Odlučivanje u Delphi tehnici se odvija kroz nekoliko faza:

U **prvoj fazi** pripremaju se upitnici zbog problema koji se želi riješiti. Upitnici se šalju odabranim stručnjacima za područje koje se istražuje. Upitnik služi kao kamen temeljac traženja specifične informacije. U **drugoj fazi** stručnjaci ispunjavaju upitnik i vraćaju ga vlasniku istraživanja. U nekim slučajevima stručnjaci su zamoljeni da navedu razloge u vezi ocjenjivanja prioriteta među stavkama (*Jacobs, 1996*). U **trećoj fazi** se vrši obrada pristiglih upitnika s rezultatima koji se koji se predstavljaju u novom upitniku, koji se opet dostavlja članovima skupine. U **četvrtoj fazi** stručnjaci odgovaraju na drugi upitnik. Postupak se

ponavlja toliko puta dok se ne postigne jednoglasna odluka. Koraci Delphi tehnike prikazani su na slici 1.



Slika 1. Koraci delphi tehnike
(Izvor: Sikavica, 1999).

Provođenje Delphi tehnike može biti dugotrajan proces. *Delbecq, Van de Ven* i *Gustafson (1975), Ulschak (1983)* i *Ludwig (1994)* preporučuju da je neophodno najmanje 45 dana za provedbu Delphi tehnike. *Delbecq (1975)* ističe da je potrebno najmanje dva tjedna za provedbu svake runde.

Korištenje elektroničkih tehnologija npr. e-mail može olakšati korištenje Delphi tehnike. *Witkin i Altschuld (1995)* napominju da elektronička tehnologija ima brojne prednosti kao što su skladištenje, obrada i brzina prijenosa, anonimnost i brza povratna informacija.

Prednost Delphi tehnike jest što se zasniva na mišljenjima velikog broja ljudi i što je lakše provesti u djelo odluku koju je donijela skupina nego pojedinac. Skupina posjeduje veće znanje i veći broj informacija potrebnih za odlučivanje, što znači bolje shvaćanje problema.

Slabosti Delphi tehnike su ponajprije spor proces odlučivanja, neslaganje među članovima, subjektivan karakter, moguća popuštanja kod eksperata i anketna pitanja nisu dovoljno korektna.

4. Metode višekriterijske analize

- **Metoda jednostavnog zbrajanja težina (**engl **.** ***Simple Additive Weighting Method - SAW*****)**

Najpoznatija metoda višeatributnog odlučivanja. Kod ove motode specifično je to da donositelj odluke mora dodijeliti težinske koeficijente svakom kriteriju koji može biti dobiven direktno od donositelja odluke ili od neke metode za određivanje težina kriterija. Da bi dobili najbolju alternativu potrebno je elemente matrice pomnožiti sa težinskim koeficijentima za svaki kriterij. Alternativa koja ima najveći ponderirani prosjek je najprihvatljivija alternativa. Može se postaviti na jednostavan način. Ako imamo skup težina:

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

Gdje je najbolja alternativa A^* za koju vrijedi:

$A^* = \{ A_i \mid \frac{max}{i} \frac{\sum_{j=1}^{n} w_j x_{ij}}{\sum_{j=1}^{n} w_j} \}$, gdje je x_{ij} procjena *i*–te alternative po *j*–tom kriteriju u nekoj usporedivoj numeričkoj skali. Primjer metode na primjeru lokacije termoelektrane pokazuje:

Matrica odluke izgleda ovako:

$$D = \begin{array}{c} \begin{matrix} X_1 & X_2 & X_3 & X_4 & X_5 & X_6 \end{matrix} \\ \begin{bmatrix} 80 & 90 & 600 & 54 & 8 & 5 \\ 65 & 58 & \mathbf{200} & 97 & \mathbf{1} & 1 \\ 83 & 60 & 400 & 72 & 4 & 7 \\ \mathbf{40} & 80 & 1000 & 75 & 7 & \mathbf{10} \\ 52 & 72 & 600 & \mathbf{20} & 3 & 8 \\ 94 & \mathbf{96} & 700 & 36 & 5 & 6 \end{bmatrix} \\ \begin{matrix} \min & \max & \min & \min & \min & \max \end{matrix} \end{array} \begin{matrix} A_1 \\ A_2 \\ A_3 \\ A_4 \\ A_5 \\ A_6 \end{matrix}$$

Nakon linearne transformacije atributa iznosi:

$$R = \begin{bmatrix} 0.50 & 0.94 & 0.33 & 0.37 & 0.12 & 0.5 \\ 0.62 & 0.60 & 1 & 0.21 & 1 & 0.1 \\ 0.48 & 0.63 & 0.5 & 0.28 & 0.25 & 0.7 \\ 1 & 0.83 & 0.2 & 0,27 & 0.14 & 1 \\ 0.77 & 0.75 & 0.33 & 1 & 0.33 & 0.8 \\ 0.43 & 1 & 0.29 & 0.56 & 0.2 & 0.6 \end{bmatrix} \begin{matrix} A_1 \\ A_2 \\ A_3 \\ A_4 \\ A_5 \\ A_6 \end{matrix}$$

Postupak je dobiven dijeljenjem svakog broja u Max stupcu s najvećim brojem u tom stupcu. Isti princip se primjenjuje za Min stupac.

Ako su težine kriterija: $W = \{ w_1, w_2, w_3, w_4, w_5, w_6\}=\{5, 7, 4, 6, 3, 8\}$. Tada ponderirane vrijednosti iznose:

$A_1 \rightarrow \sum_{j=1}^{6} w_j x_{1j}$ = 0.5·5 + 0.94·7 + 0.33·4 + 0.37·6 + 0.125·3 + 0.5·8 = 16.995

$A_2 \rightarrow \sum_{j=1}^{6} w_j x_{2j} = 16.335$, $A_3 \rightarrow \sum_{j=1}^{6} w_j x_{3j}$=16.84, $A_4 \rightarrow \sum_{j=1}^{6} w_j x_{4j} = 21.65$,

$\boldsymbol{A_5 \rightarrow \sum_{j=1}^{6} w_j x_{5j}}$ **= 23.81**, $A_6 \rightarrow \sum_{j=1}^{6} w_j x_{6j}$ = 19.07. Rješenje na kraju postupka glasi:

$A_5, A_4, A_6, A_1, A_3, A_2$. Najprihvatljivija alternativa je A_5 jer ima najveći ponderirani prosjek.

- **PROMETHEE metoda (**engl**.** ***Preference Ranking Organization Method for Enrichment of Evaluation***)

Budući da ne postoje najbolja rješenja kada je riječ o problemima s više kriterija, problem se svodi na određivanje skupa dobrih alternativa, sustava, lokacija, projekata, itd. PROMETHEE se smatra jednom od najznačajnije metode. Njegove karakteristike su:

• Pokrivenost kriterija – svaki se kriterij promatra kroz šest mogućih funkcija na temelju intenziteta preferencija. Te funkcije su prisutne u praksi gdje donositelj odluke mora definirati ne više od dva parametra. Svaki parametar sadrži stvarne ekonomske vrijednosti;

• Procijenjeni odnos višeg ranga – primjena kriterija oblikovana je da omogućuje konstrukciju odnosa višeg ranga. Takav odnos je manje osjetljiv na manje promjene parametara i zato je njegova interpretacija jednostavna;

• Upotreba odnosa višeg ranga – odnosi na specifičnu uporabu procijenjenog odnosa višeg ranga, to se osobito odnosi na slučajeve kada se akcije rangiraju od najgorih do najboljih.

Spada među najmlađe metode, nastala 1984. godine od strane *J. P. Brans, B. Mareschal, P. Vincke,* te je jedna od metoda za višekriterijsko odlučivanje u skupu alternativa opisanih s više atributa. Problemi koji se rješavaju ovom metodom prema osnovi broja kriterija, odnose se na rangiranje alternativa i izbor najprihvatljivije alternative. Svoj uspjeh metoda može zahvaliti lakoći primjene te svojim matematičkim svojstvima.

Ako postoji višekriterijski problem:

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

Gdje je A konačni skup aktivnosti, a f_j su n kriteriji koje treba maksimizirati ili zadovoljiti. Svaki kriterij je funkcija iz A u R.

Svakoj aktivnosti A_i pripada $f_i(A_i)$ vrijednost j-tog kriterija za i-tu alternativu što je prikazano u matrici odluke, te na taj način se dobiva skup osnovnih podataka:

Tablica 15. PROMETHEE – matrica odluke

Kriteriji / Alternative	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	$f_1(A_m)$	$f_2(A_m)$	⋯	$f_n(A_m)$

(Izvor: Babić, 2011).

Ako se uspoređuju dvije alternative a i b, rezultat se izražava u obliku preferencije funkcijom P:

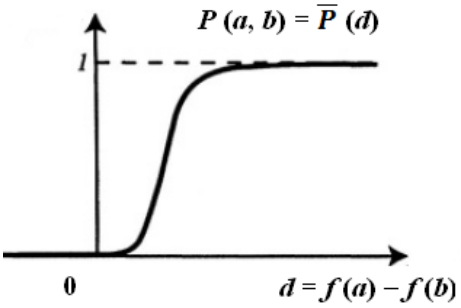
$P : A \times A \rightarrow [0, 1]$

Kojom se izražava intezititet preferencije alternative a u odnosu na alternativu b sa sljedećom interpretacijom:

- $P(a, b) = 0$ znači indiferenciju između a i b, tj. nema preferencije a nad b,
- $P(a, b) \approx 0$ znači slabu preferenciju a nad b,
- $P(a, b) \approx 1$ znači jaku preferenciju a nad b,
- $P(a, b) = 1$ znači strogu preferenciju a nad b.

Funkcija preferencije je razlika između vrijednosti tih dviju alternativa po nekom kriteriju, gdje je: $d = f(a) - f(b)$.

Funkcija preferencije je neopadajuća funkcija koja poprima vrijednost nula za negativne vrijednosti od d što je prikazano na slici broj 2.



Slika 2. Funkcija preferencije
(Izvor: Figueira, Greco, Ehrgott, 2005).

Postoji šest tipova funkcija tzv. općih kriterija koji se najčešće koriste rješavanje praktičnih problema, a analitičar i donositelj odluke dogovorom biraju po jednu funkciju za svaki kriterij, a parametri se unaprijed biraju, i to:

q – prag indiferencije,

ρ – prag preferencije,

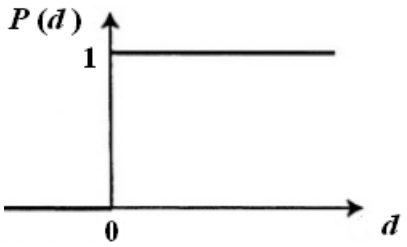
s – parametar.

U nastavku će biti prikazani specifični slučajevi preferencije.

- **Običan kriterij**

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

U ovom slučaju postoji indiferencija između alternativa *a* i *b* ako samo ako je *f(a)=f(b*). Ako se te vrijednosti razlikuju, donositelj odluke ima strogu preferenciju za aktivnost koja ima veću vrijednost. Funkcija preferencije je prikazana slikom 3.

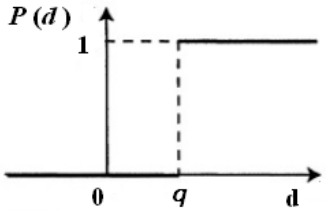


Slika 3. Obični kriterij
(Izvor: Figueira, Greco, Ehrgott, 2005).

- **Kvazi kriterij**

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

Ako donositelj odluke želi upotrijebiti funkciju preferencije potrebno je odrediti vrijednost parametra q što je prikazano na slici 4. Dvije aktivnosti su za donositelja odluke indiferentne, sve dok razlika između njihovih vrijednosti ne prekorači prag indiferencije q, a u slučaju kada ga prekorači, radi se o strogoj preferenciji.

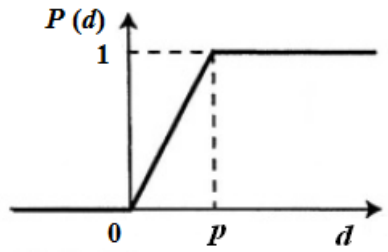


Slika 4. Kvazi kriterij
(Izvor: Figueira, Greco, Ehrgott, 2005).

- **Kriterij s linearnom preferencijom**

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

Sve dok je d manji od ρ preferencija donositelja odluke linearno raste s d, a kad d postane veći od ρ nastaje stroga preferencija. Donositelj odluke mora odrediti samo jedan parametar ρ, odnosno najnižu vrijednost.

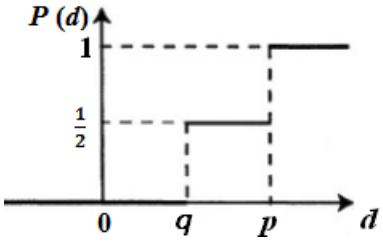


Slika 5. Kriterij s linearnom preferencijom
(Izvor: Figueira, Greco, Ehrgott, 2005).

- **Razinski kriterij**

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

Potrebno je definirati oba praga q *i* ρ i ukoliko se između njihovih vrijednosti nalazi d postoji slaba preferencija.

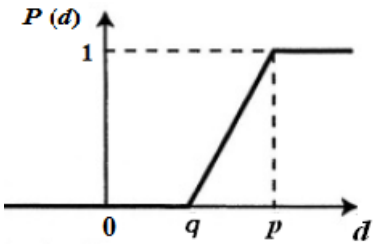


Slika 6**.** Razinski kriterij
(Izvor: Figueira, Greco, Ehrgott, 2005).

- **Kriterij s linearnom preferencijom i područjem indiferencije**

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

Kod ovog slučaja donositelj odluke smatra da njegova preferencija raste linearno u području između pragova q i p, i to u području od indiferentnosti do stroge preferencije.

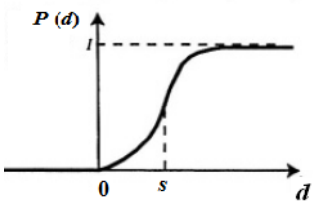


Slika 7. Kriterij s linearnom preferencijom i područjem indiferencije
(Izvor: Figueira, Greco, Ehrgott, 2005).

- **Gaussov kriterij**

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

Ova funkcija zahtjeva samo definiranje parametra s koji se nalazi negdje na području slabe preferencije. Kako nema prekida, interesantna je zbog stabilnosti rezultata.



Slika 8. Gaussov kriterij
(Izvor: Figueira, Greco, Ehrgott, 2005).

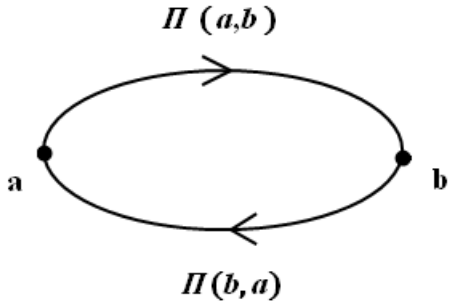
Dakle, za svaki kriterij je potrebno izabrati neki od predloženih funkcija preferencije s kojim smo prethodno upoznali donositelja odluke. Nakon odabira kriterija f_j potrebno je odrediti i težine za pojedine kriterije w_j, gdje je w_j mjera relativne važnosti kriterija f_j. Ako je donositelj odluke odredio funkcije P_j (od 6 mogućih tipova po jednu funkciju) i težine w_j. Indeks preferencije Π se definira kao ponderirana sredina funkcije p_j, tj.

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

Indeks preferencije $\Pi(a,b)$ predstavlja intenzitet (jakost) preferencije donositelja odluke za alternativu *a* nad alternativom *b* kad istovremeno uspoređujemo sve ostale kriterije. Gdje je:

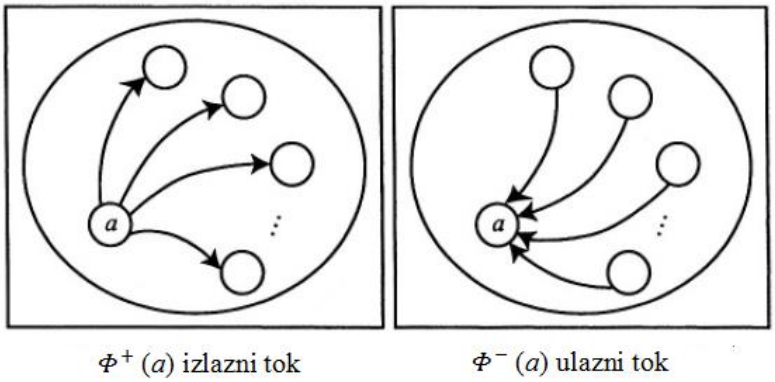
$\Pi(a, b) \approx 0$ slaba preferencija *a* nad *b* za sve kriterije,
$\Pi(a, b) \approx 1$ jaka preferencija *a* nad *b* za sve kriterije.

Nasuprot tome, indeks preferencije $\Pi(b, a)$ izražava intezititet alternative *b* nad alternativom *a* u odnosu na druge kriterije. Slika 9. prikazuje kako između dvije alternative *a* i *b* postoje dva luka s vrijednostima $\Pi(a, b)$ i $\Pi(b, a)$.



Slika 9. Lukovi $\Pi(a,b)$ i $\Pi(b, a)$
(Izvor: Babić, 2011).

Dalje kako slijedi, za svaku alternativu definiraju se dva toka $\Phi^{+}(a)$ izlazni i $\Phi^{-}(a)$ ulazni ili negativni tok.



Slika 10. Izlazni i ulazni tok
(Izvor: Figueira, Greco, Ehrgott, 2005).

Slika predstavlja sumu vrijednosti svih lukova koji izlaze iz čvora i pokazuje kako alternativa *a* dominira nad svim ostalim alternativama, te što je veći Φ^{+} to je aktivnost bolja. Nasuprot tome, negativni ili ulazni tok $\Phi^{-}(a)$ pokazuje dominaciju drugih alternativa nad

alternativom *a*, te što je Φ^- manji to je alternativa bolja. Ako se uporedi ulazni i izlazni tok rezultat koji se dobije su dva skupa alternativa, kako slijedi u nastavku:

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

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

Pri čemu je *S* tzv. „*outranking*“ relacija, tj. *a S b* znači: *a* je barem toliko dobar kao i *b* ili bolji.

PROMETHEE I (parcijalno rangiranje)

Presjek parcijalnog rangiranja (*P, I, R*) prikazan je u sljedećoj tablici:

Tablica 16. PROMETHEE I – parcijalno rangiranje

a P b (*a* dominira nad *b)*	ako i samo ako	aS^+b i aS^-b *ili* sS^+b i aI^-b *ili* aI^+b *i* aS^-b
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, 2011).

PROMETHEE II (potpuno rangiranje)

Ako donositelj odluke želi potpuni poredak skupa alternativa *A* izračunava se neto tok Φ, kao razlika „snage“ i „slabosti“ pojedine alternative na sljedeći način:

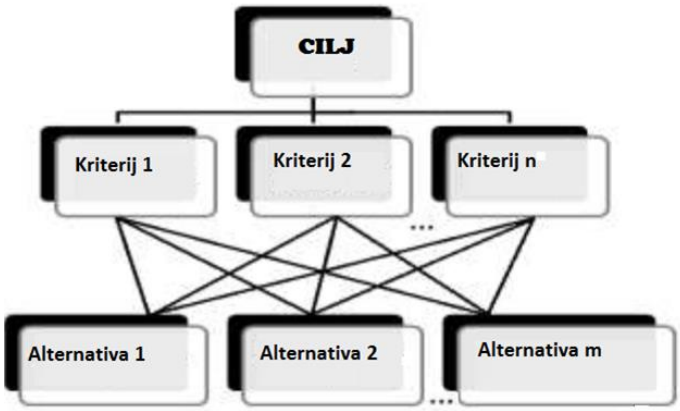
$\Phi(a) = \Phi^+(a) - \Phi^-(a)$.

Jednostavnije je odlučivati na temelju PROMETHEE II jer daje realnije informacije vezane za donošenje odluka.

- **Analitički hijerarhijski proces (*engl*. AHP – Analiytic Hierarchy Process)**

AHP je pristup višekriterijskom odlučivanju koji pomaže donositelju odluke riješiti problem odlučivanja na temelju međusobnog uspoređivanja alternativa. Spada u najpoznatije i najviše korištene metode za višekriterijskog odlučivanja. Ovu metodu je razvio prof. dr. *Thomas L. Saaty* na Državnom Sveučilištu Pittsburg 1971. godine. Nakon istraživanja i revizije objavio ju je 1980. godine. Svoju popularnost temelji na pristupu odlučivanja koji ljudi koriste intuitivno razlažući ih na jednostavnije aspekte. Isto tako, sadrži matematički model koji omogućava detaljniju analizu problema. Rješavanje tih složenih problema temelji se na rastavljanju na komponente: cilj, kriteriji i alternative. Kriteriji se mogu rastaviti na podkriterije, a na najnižoj razini nalaze se alternative. Druga važna komponenta je matematički model metoda svojstvenog vektora pomoću kojeg se računaju težine elemenata. Primjena AHP metode može se prikazati u četiri koraka:

- Kreira se model koji je strukturiran hijerarhijski s ciljem na vrhu, na nižim razinama se nalaze kriteriji i podkriteriji, te na dnu modela nalaze se alternative kao što pokazuje slika 11.



Slika 11.Osnovni AHP model
(Izvor:Babić, 2011).

- Pomoću Saatyeve skale u svakom čvoru se međusobno uspoređuju elementi i izračunavaju se njihove lokalne težine. Prvo se kriteriji međusobno uspoređuju u parovima u odnosu koliko je jedan važniji od drugog za mjerenje postizanja cilja. Zatim

se alternative međusobno uspoređuju u parovima po svakom od kriterija gledajući koliko je prednost jednoga u odnosu na drugi kriterij. Zatim se izračunavaju lokalne težine kriterija i podkriterija, a na posljednjoj razini prioriteti alternativa.

- Provodi se analiza osjetljivost

Metoda svojstvenog vektora

- Donositelj odluke polazi od pretpostavke da je lakše procijeniti relativne važnosti za svaki par kriterija, nego ocijeniti sve kriterije zajedno. Osim za određivanje težina kriterija koristi se i za izbor najbolje alternative. Donositelj odluke mora po važnost usporediti sve moguće parove kriterija. Broj procjena je jednak formuli: $\binom{n}{2}=\frac{n\cdot(n-1)}{2}$, gdje je *n* broj kriterija. Da bi se izračunala težina kriterija potrebno je procijeniti relativnu važnost za svaki par kriterija ovisno od odluke za jednu od ovih tvrdnji:
- oba kriterija su jednako važna;
- kriterij x_i je važniji od x_j kriterija;
- x_j je važniji od x_i kriterija.

Kvantifikacija omjera težina tih kriterija w_i i w_j zavisi od izbora:

a) $a_{ij} = \frac{w_i}{w_j} = 1$, kriteriji su jednako važni;

b) $a_{ij} = \frac{w_i}{w_j} > 1$, kriterij x_i je važniji od x_j kriterija;

c) $a_{ij} = \frac{w_i}{w_j} < 1$, kriterij x_j je važniji od x_j kriterija.

U koliko se odabere b) ili c) opcija, intezitet preferencije se može izraziti pomoću Saatyeve ljestvice koja je prikazana u tablici 17

Tablica 17. Saatyeva ljestvica mjerenja

Značaj	Definicija	Objašnjenje
1	Istog značaja	Dva kriterija su identičnog značaja u odnosu na cilj
3	Slaba dominantnost	Iskustvo ili rasuđivanje neznatno favoriziraju jedan kriterij u odnosu na drugi
5	Jaka dominantnost	Iskustvo ili rasuđivanje znatno favoriziraju jedan kriterij u odnosu na drugi
7	Demonstrirana dominantnost	Dominantnost jednog kriterija potvrđena u praksi (jaka dominantnost)
9	Apsolutna dominantnost	Dominantnost najvišeg stupnja
2,4,6,8	Međuvrijednosti	Potreban kompromis ili daljnja podjela

(Izvor:Babić, 2011).

Strukturiranje hijerarhije omogućava donositelju odluka dvije stvari. Prvo, daje mu uvid u situaciju među elementima hijerarhije, a drugo, ima pregled da li su svi elementi homogeni. *T. L. Saaty* je razvio potrebu davanja procjena koja sadržava pet stupnjeva intenziteta i četiri međustupnja gdje je najveća vrijednost 9, a najmanja vrijednost 1. Ovom ljestvicom se određuju omjeri važnosti za sve parove kriterija te se formira matrica omjera važnosti *A* čiji su elementi a_{ij}.

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

gdje je: $a_{ij} = \frac{w_i}{w_j}$.

Matrica *A* ima pozitivne elemente i recipročna je, odnosno, $a_{ij} = \frac{1}{a_{ji}}$, odnosno element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale, gdje potom vrijedi odnos $\frac{w_i}{w_j} = \frac{1}{w_j/w_i}$. Ako je *i*—kriterij važniji od *j*– tog za 3 puta ($a_{ij} = w_i/w_j = 3$) onda je sigurno da je

j —ti kriterij lošiji 3 puta od *i*–tog kriterija ($w_j/w_i = a_{ji} = 1/3$). Drugo svojstvo koje vrijedi za matricu glasi $a_{ij} = a_{ik} \cdot a_{kj}$. Ako je *i*–ti kriterij važniji 2 puta od *k*-tog kriterija ($a_{ik} = 2$), a *k*–ti kriterij 3 puta važniji od toj *j*–tog kriterija (a_{kj}) tada vrijedi da je *i*-ti kriterij 6 puta važniji

od j-tog kriterija. U slučaju kad bi elementi iz matrice *A* predstavljali omjere težina kriterija, tada bi uvjet glasio:

$$a_{ij} = \frac{w_i}{w_j} = \frac{w_i/w_k}{w_j/w_k} = \frac{w_i}{w_k} * \frac{w_k}{w_j} = a_{ik} * a_{kj} .$$

Kriterij w_j se računa na sljedeći način:

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

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

Dobivena je jednadžba $A \cdot W = n \cdot W$, odnosno $(A - n \cdot I) \cdot W = 0$.

Matrica *A* ima rang 1. Drugi redak matrice *A* dobije se množenjem prvog retka sa $w_2 \ / \ w_1$, a treći red množenjem prvog sa w_3/w_1 itd. i stoga matrica *A* ima svojstvenu vrijednost koja je jednaka *n*. Teškoće koje se mogu javiti u procesima odlučivanja su uzrokovane nekonzisentnošću procjena relativnih važnosti kriterija radi kojih je matrica *A* imala svojstvenu vrijednost. Tada će se od svih vrijednosti (*n*) koje su svojstvene odabrati najveća, a razlika između matrice *A* i broja *n* koristiti će se za mjerenje konzistentnosti procjena danih u matrici *A*. U tu svrhu se računa vrijednost indeksa konzistencije:

CI= $\frac{\lambda_{max-n}}{n-1}$ i omjera konzistencije *CR:*

CR = CI / RI, gdje je*:*

RI – slučajni indeks konzistencije za matrice *n* koji su slučajno generirani usporedbom u parovima (prikazane su izračunate vrijednosti):

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

Pravilo: Ako za matricu *A* vrijedi $CR \leq 0.10$ procjene omjera relativnih važnosti kriterija se smatraju prihvatljivima. U suprotnoj situaciji treba istražiti razloge inkozinstetnosti.

Određivanje vrijednosti je dosta kompliciran problem pa određivanje svojstvene vrijednosti matrice *A* se dobije rješavanjem jednadžbe: $det\ (A - \lambda \cdot I) = 0$.

Težine kriterija (koje sadrži matrica *A*) dobiju se sljedećim načinom:

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

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

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

gdje se traže rješenja sustava uz uvjete nenegativnosti i normalizacije vrijednosti komponenata rješenja. Dan je primjer matrice *A* gdje treba usporediti 3 kriterija te na temelju njih odrediti težinu tih kriterija:

$$A = \begin{bmatrix} 1 & 1/3 & 1/2 \\ 3 & 1 & 3 \\ 2 & 1/3 & 1 \end{bmatrix}$$

Potrebno je zatim izračunati λ_{max} rješavanjem jednadžbe $\det (A - \lambda \cdot I) = 0$.

$$\det(A - \lambda \cdot I) = \begin{bmatrix} 1-\lambda & 1/3 & 1/2 \\ 3 & 1-\lambda & 3 \\ 2 & 1/3 & 1-\lambda \end{bmatrix} = 0$$

Rješavanje ove jednadžbe dovodi do algebarske jednadžbe trećeg stupnja:

$2(1 - \lambda)^3 - 6(1 - \lambda) + 5 = 0,$

Jednadžba ima 3 rješenja, a najveće λmax je= 3.0536.

Indeks konzinstencije se računa na sljedeći način:

$CI = \frac{\lambda_{max} - n}{n-1} = \frac{3.0536-3}{2} = 0.0268,$

$CR = \frac{CI}{RI} = \frac{0.0268}{0.52} = 0.0515 < 0.1$, te smo jednadžbom dobili:

$-2.0536\ w_1 + (1/3)\ w_2 + (1/2)\ w_3 = 0$

$3\ w_1 - 2.0536\ w_2 + 3\ w_3 = 0$

2 w_1+ (1/3) w_2- 2.0536 w_3= 0

Sustav ima beskonačno puno rješenja jer je determinanta jednaka nuli, ali kako se traži rješenje za koje vrijedi: $\sum_{j=1}^{n} w_i = 1$, uz uvjet nenegativnosti na sve varijable rješenje je sljedeće:

w_1= 0.1571, w_2 = 0.5936, w_3= 0.2493.

Metoda svojstvenog vektora zahtijeva puno posla ali kako danas postoje softverski paketi uporaba postaje jednostavna (*Expert Choise*). Potrebno je samo prikupiti podatke za matricu međusobnih usporedbi kriterija *A*, te će računalni program obaviti sav posao koji će dati težine kriterija.

- **Vrijednost λ_{max}**

Za vrijednost riješava se jednadžba *det (A - λI)* = 0.

Ako jednadžba glasi $2(1 - \lambda)^3 - 6(1 - \lambda) + 5 = 0$, koja ima 3 rješenja, a najveće je: $\lambda_{max} = 3.0536$.

Iz $AW = \lambda_{max} W$ za svaku komponentu svojstvenog vektora vrijedi $\lambda_{max} = \frac{1}{w_i} \sum_{j=1}^{n} a_{ij} w_j$. gdje

$$A \cdot W = \begin{bmatrix} a_{11} & a_{11} & \cdots & a_{1n} \\ a_{21} & a_{22} & & a_{2n} \\ \vdots & & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \lambda_{max} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix}$$

na taj se način dobiva *n* različitih relacija za izračunavanje λ_{max} pa se približna vrijednost računa kao njihov prosjek. Dakle, približna vrijednost se računa na sljedeći način:

- Stupce matrice *A* pomnoženi su s pripadajućim težinama (prvi sa w_1, drugi sa w_2 , treći sa w_3). Gdje je:

$$\mathrm{A} = \begin{bmatrix} 1 & 1/3 & 1/2 \\ 3 & 1 & 3 \\ 2 & 1/3 & 1 \end{bmatrix}$$

w_1 = 0.1593, w_2= 0.5889,w_3= 0.2518.

- Izračunaju se sume pojedinh redaka: (0.4815, 1.8222, 0.7667),

- Sume redaka podjele se s težinama: (0.4815/0.1593, 1.8222/0.5889, 0.7667/0.2518) = = (3.022599, 3.094244, 3.044877),
- Izračuna se λ_{max} kao prosječna vrijednost dobivenih veličina:
- = (3.022599 + 3.094244 + 3.044877)/3 = 3.053906.

Indeks konzistencije je: CI = $\frac{\lambda_{max-n}}{n-1} = \frac{3.053906}{3-1}$ = 0.026953,

a omjer konzistencije CR = $\frac{CI}{RI} = \frac{0.026953}{0.52}$ = 0.051833.

Kako je *CR* < 0.1 procjene iz matrice *A* su zadovoljavajuće konzistentne.

Prednosti i nedostaci AHP metode

AHP metoda je najrasprostranjenija metoda pri procesu rješavanja kompleksnih problema odlučivanja zbog boljih uporabnih svojstva, ali i ta metoda ima određene nedostatke.

Prednosti

- Donositelj odluke uključen je u sve faze strukturiranja;
- Omogućuje integriranje kvantitativnih i kvalitativnih faktora u odlučivanju;
- Provjerava konzistentnost;
- Uspoređivanje u parovima što smanjuje mogućnost pogrešaka;
- Kratko vrijeme donošenja odluke uz manje troškove;
- Postojanje kvalitetnih programskih alata (npr. *Expert Choice, SuperDecisionLens).*

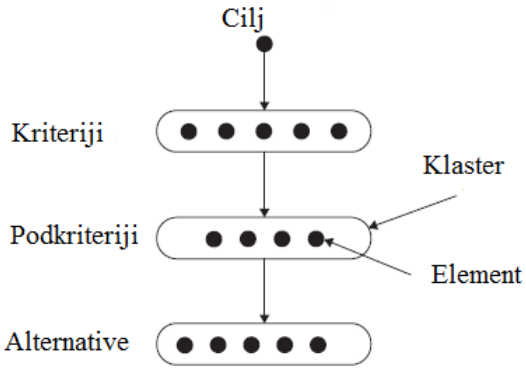
Nedostaci

- Nedovoljno velika ljestvica pri uspoređivanju elemenata za neke specifične probleme;
- Velik broj potrebnih uspoređivanja kod složenih problema;
- Teško postizanje zadovoljavajućeg omjera konzistentnosti;
- Nisu dozvoljene neusporedive inačice (*Sikavica 2014*).

ANP- Analitički mrežni proces (*engl. **Analytic Network Process***)

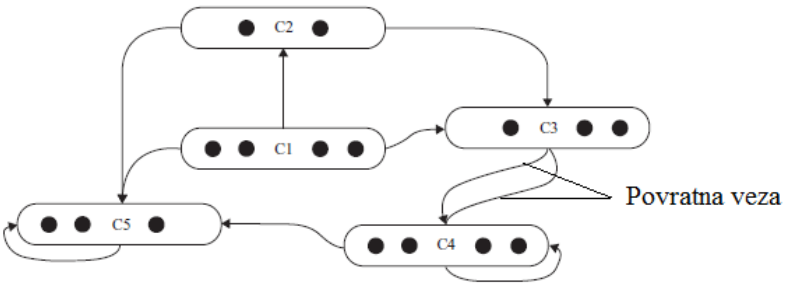
ANP metodu je razvio Thomas Saaty 1996. godine. Novija je metoda za odlučivanje te uključuje određenu nadogradnju u odnosu na AHP metodu. ANP je generalizacija AHP-a, s obzirom na ovisnost između elemenata hijerarhije. Mnogi problemi odluke ne mogu biti strukturirani hijerarhijski jer uključuju interakciju i ovisnost elemenata na višim razinama u hijerarhiji na elementima na nižoj razini. Stoga, ANP predstavlja mrežu, a ne hijerarhiju. Struktura povratnih informacija nema oblik hijerarhije *top-to-bottom*, nego izgleda više kao mreža povezana s elementima koje ne možemo nazvati razinom nego petljom koja povezuje. Omogućuje mrežno definiranje problema te se razlikuje od AHP-a jer ne predstavlja linearnu hijerarhiju već modelira utjecaje između elemenata mreže. Struktura ANP-a je vrlo slična onoj u AHP, s tri razine: cilj, kriterije i alternative. U hijerarhiji težine kriterija služe kako bi se vrednovale alternative i odredili njihovi prioriteti. Odluka se donosi na temelju postojećeg znanja. Postoji razlika između hijerarhije i mreže. Hijerarhija je linearna *top-down* struktura koja sadrži cilj koji se nalazi na vrhu hijerarhije, kriterije na prvoj razini, podkriterije na drugoj razini, alternative na trećoj razini i petlju gdje svaki element ovisi sam o sebi. Mreža je tzv. *feedback* struktura (struktura povratne veze) koja sadrži komponente i elemente unutar komponenata, tj. klastere i čvorove unutar klastera te petlje i lukove kojima se komponente mreže povezuju. Osnovni element mreže je klaster, a klasteri se sastoje od čvorova koji su međusobno povezani. Ovisnost između dva čvora se prikazuju strelicom koja povezuje dva elementa. Ishodišni čvor (*engl. source*) je onaj iz kojeg strelica izlazi i on utječe na odredišni čvor (*engl. sink*) prema kojem je strelica usmjerena tj. odredišni čvor ovisi od ishodišnog čvora. Postoje dvije vrste utjecaja (interakcija) na mrežu: unutarnji i vanjski. U vanjskom se uspoređuje utjecaj elemenata u klasteru na elemente u drugom klasteru i označavamo je lukom između klastera. U unutarnjem se uspoređuje utjecaj elemenata jedan na drugi u grupi i naziva se još i petljom (*engl. loop*).

Na slici 12. su prikazane ovisnosti između čvorova. Strelica prikazuje koliko jedan element utječe na drugi. Onaj čvor iz kojeg strelica izlazi je ishodišni i on utječe na čvor prema kojem je strelica usmjerena tj. ishodišni čvor. Interakcije i ovisnosti počinju od gornje razine pa sve do niže. Svi elementi mreže mogu komunicirati jedni s drugima. Vidljivo je i da je hijerarhija specijalan oblik mreže koji ide u jednom smjeru.



Slika 12. Linearna hijerarhija u ANP
(Izvor: Ishizaka, Nemery, 2013).

Slika 13. prikazuje klastere i čvorove, unutarnje i vanjske ovisnosti između elemenata, kao i petlje. Postoje tri vrste klastera u mreži. Klaster koji nema ulazne strelice je C1, C5 nema izlazne strelice, te C2, C3 i C4 koji imaju izlazne i ulazne strelice.



Slika 13. Klasteri u ANP mreži
(Izvor: Ishizaka, Nemery, 2013).

ANP ima dvije mane: teško je dati točnu strukturu mreže među kriterijima čak i za stručnjake, a različite strukture mogu dovesti do različitih rezultata. Drugo, da bi se kreirala super matrica kriteriji moraju biti u paru u odnosu na sve druge kriterije, što je teško ali i neprirodno. Jedna važna prednost ANP-a je sposobnost rješavanja problema u kojima alternative i kriteriji imaju takve interakcije koje se ne mogu prikazati u hijerarhiji.

DEA- Analiza omeđenih podataka (engl. ***Data Envelopment Analysis*****)**

DEA se koristi za mjerenje performansi tvrtki ili osoba (drugim imenom jedinica za donošenje odluka, DMUs (engl. *decision-makingUnits*) koje pretvaraju više ulaza u više izlaza. Formalno je razvijena od strane *Charnes, Cooper i Rhodes* 1981. godine kako bi se ocijenio američki savezni program vlade u obrazovanju pod nazivom „program praćen putem“ (engl. *Program Follow Through*). DEA je snažna *benchmarking* tehnika te postoje dva osnovna modela koja se koriste:

- **CRS (engl. *constant returns to scale*)**: model izračunava ocjenu efikasnosti pod nazivom konstantni povrat na nivo tehničke učinkovitosti- *CRSTE* (engl. *constant returns to scale technical efficiency)*. Odvija se u savršeno konkurentnom okruženju, što je rijetko.
- **VRS (engl. *variable returns to scale*)**: model izračunava ocjenu efikasnosti pod nazivom promjenjivi povrat na nivo tehničke učinkovitosti- *VRSTE* (engl. *variable returns to scale technical efficiency*) odvija se uvjetima nesavršene konkurencije.

DEA može biti izlazno i ulazno orijentirana:

- ulazno orijentirana DEA smanjuje input za danu razinu outputa, tj. donositelj odluke može smanjiti razinu inputa za određen dio outputa,
- izlazno orijentirana DEA povećava proizvodnju za određenu razinu inputa, tj. donositelj odluke može smanjiti razinu outputa za određen dio inputa.

DEA izračunava težinu inputa i outputa dodjeljivanjem najveće ocjene učinkovitosti što omogućuje fleksibilnost težina. Ponekad se mogu dobiti nerazumni rezultati te se stoga koriste ograničenja težina u DEA metodi. Postoje četiri glavne skupine podjele:

- Izravno ograničavanje težina (inputi i outputi su pod nekim ograničenjem);
- Model stožastog omjera (engl. *Cone Ratio Model*): može se koristiti kao CCR model koji vrednuje DMUs s transformiranim podacima;
- Područje sigurnosti (engl. *Assurance Region*): AR se može podijeliti u dvije skupine: Ar1 i Ar2. Granične vrijednosti za Ar1 ovise o razini ulaznih i izlaznih varijabli dok Ar2 nameće ograničenja na odnos između ulaznih i izlaznih varijabli;
- Virtualna ograničenja na težine inputa i outputa.

DEA pomaže donositelju odluke na sljedeći način:

- izračunavanje učinkovitosti (ako je tvrtka učinkovita ili za povećanje učinkovitosti);

- postavljanje ciljne vrijednosti na inpute i outpute (izračunava koliko input mora biti smanjen ili povećan output, tj proizvodnja kako bi postala učinkovita);
- utvrđivanje stanja (pokazuje kako tvrtka mora smanjiti kriterije da bi smanjila prosječnu ukupnu cijenu);
- za utvrđivanje niz mjerila (analiziranje drugih tvrtki da bi povećala svoju konkurentnost).

DEA je moćan alat ali može stvoriti određene probleme kao što su :

- greške mjerenja mogu uzrokovati značajne probleme;
- dobra je u procjenjivanju relativne učinkovitosti ali to može dovesti do apsolutne učinkovitosti;
- statistički testovi testiranja hipoteze su teško izvedivi;
- standardna formulacija DEA stvara posebni linearni program za svaku DMU, veliki problemi mogu biti računalno intenzivni (*Trick M. A).*

- **ELECTRE (**engl**.** ***ELimination and Choice Expressing the Reality)***

Korijeni ELECTRE metode datiraju iz 1965. godine na Europskoj savjetodavnoj kompaniji *SEMA* (koja još i danas postoji). U to vrijeme, istraživački tim iz *SEMA* kompanije je radio na konkrentnom višekriterijskom problemu vezano za razvoj tvrtke. Za rješenje problema stvoren je *MARSAN* (*Méthode d'Analyse, de Recherche, et de Sélection d'Activités Nouvelles*), generalizirana višekriterijska metoda koja se bazirala na težinama izbora. No ta se metoda pokazala kao neefikasnom, pa su stručnjaci stupili u kontakt s matematičarom *Bernard Roy*- em koji je započeo rad na metodi bez imitacija *MARSAN* metode. Tako je 1956. godine nastala *ELECTRE* metoda za izbor najbolje aktivnosti iz skupa aktivnosti, koju danas znamo pod imenom *ELECTRE I*. U srpnju te godine nova metoda je prvi put predstavljena na konferenciji (les journées sur les méthodes de calcul les sciences de l'homme) u Rimu. ELECTRE I je postala vrlo popularna i primjenjivana na mnogim područjima. U međuvremenu, evoluirala je u „neslužbenu" verziju ELECTRE Iv, a nakon nje, slijedi verzija ELECTRE IS koja se koristila za modeliranje situacija u kojima su podaci bili nepotpuni. Ova metoda je i danas službena ELECTRE metoda za rješavanje problema izbora.

Kratica ELECTRE označava ELimination Et Choix Traduisant la REalité (*ELimination and Choice Expressing the REality*), što u prijevodu znači „Eliminacija i izbor u prikazu stvarnosti". ELECTRE metoda kreirana za rješavanje problema izgleda autoceste u jednoj

francuskoj regiji nazvana „Netipična ELECTRE metoda kreirana za rješavanje problema izgleda autoceste u jednoj francuskoj regiji nazvana *the meaningful compensation method* (smislena metoda kompenzacija) i bazirana je na učestalosti izmjene i definiranih neizrazitih (*fuzzy)* relacija. U kasnim šezdesetima primjenjena je na novi problem oglašavanja reklamnog planiranja u medijima. Tako je nastala ELECTRE II metoda koja je rješavala problem rangiranja alternativa od najbolje do najgore. Samo nekoliko godina kasnije osmišljena je nova metoda rangiranja alternativa ELECTRE III kod koje je glavna značajke bila korištenje pseudo-kriterija i neizrazitih *fuzzy* binarnih relacija bile su glavne značajke nove metode. ELECTRE IV proizašla je iz problema vezanog uz podzemnu željeznicu Pariza gdje je postalo moguće rangiranje alternativa bez korištenja koeficijenta kriterija relativne važnosti. Ovo je jedina ELECTRE metoda koja ne koristi takav koeficijent.

ELECTRE metode su važne kada se suočavaju sa sljedećim karakteristikama: (*Figueira J. i ostali, 2005*.)

- Donositelj odluke (DM) želi uključiti u model najmanje tri kriterija. Međutim, postupci agregacije su više prilagođeni situacijama kada modeli odlučivanja uključuju više od pet kriterija (do dvanaest ili trinaest);
- Alternative su evaluirane (za barem jedan kriterij) na uobičajenoj ili intervalnoj skali koje nisu prikladne za usporedbu različitosti;
- Među kriterijima postoji snažna nejednakost vezana uz prirodu evaluacije (što čini teškim za sastavljanje svih kriterija na jedinstvenoj ljestvici);
- Nadoknada izgubljenog na jednom kriteriju uz dobitak na drugom kriteriju nije prihvatljiva od strane donositelja odluka.

U tablici 18. navode se neke verzije od ELECTRE metode i vrste problema za koje se one primjenjuju. Na osnovi ove metode razvijene su i druge verzije metode. Osnivači su išli za tim da se uklone nekonzistentnosti u pojedinim verzijama.

Tablica 18. ELECTRE metode

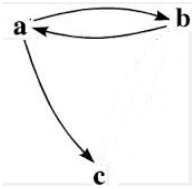
Problem odlučivanja	**Metode**	**Primjeri**
Odabir najbolje alternative	ELECTRE I, ELECTRE Iv,ELECTRE IS	odabir jednog kandidata za posao, odabir vozila
Rangiranje alternativa	ELECTRE II, ELECTRE III, ELECTRE IV	rangiranje kandidata za posao, rangiranje sportaša ili umjetnika
Sortiranje alternativa	ELECTRE TRI	sortiranje klijenata u skupine (dobri, manje dobri, loši)

(Izvor: P. Sikavica, 2014).

Osnivanjem ove metode težilo se da se zadovolje zahtjevi koji će osigurati što kvalitetnije modeliranje složenijih problema odlučivanja. ELECTRE metoda je drugačija metoda, upravo zato što omogućuje usporedbu alternativa na način da se nedostaci neke alternative ne mogu kompenzirati prednostima u drugim aspektima. Izdvaja se od drugih metoda kod situacija gdje postoji izrazit konflikt među kriterijima ili kad postoje specifična svojstva alternativa, a u postupku odlučivanja ih je potrebno „prepoznati". Informacije koje su potrebne su tablica odlučivanja i težine kriterija. Temelji se na ideji da je za izbor alternative bitno modeliranje odnosa između dvaju alternativa *a* i *b*. Za svaki par alternativa (*a*, *b*) ispituje se koliko su jaki njeni argumenti, te koliko jedan dominira nad drugim. Do zaključka se dolazi uz pomoć uređajne relacije (engl. *outranking relation*) S_A koja sadrži sljedeća svojstva:

- aS_Ab: (*a* dominira nad *b*) vrijedi, ako, postoji razlog da se prihvati stav „*a* je najmanje toliko dobro kao i *b*",
- aS_Ab: ne vrijedi ako se stav „*a* je najmanje toliko dobar kao i *b*" smatra nedovoljnim.

Na temelju te relacije moguća su tri odnosa: ***preferencija***, ***indiferencija*** i ***neusporedivost***. Na slici 14. su prikazani odnosi između alternativa *a, b* i *c* na temelju definirane relacije gdje je :



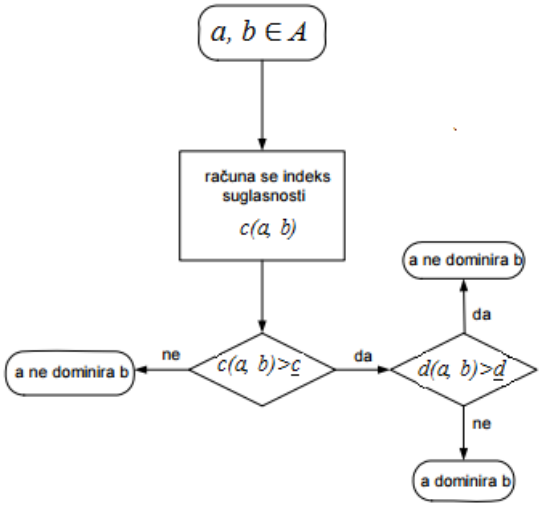
- *a* je indiferentna u odnosu na *b*

- *b* se preferira u odnosu na *c*

- *b* i *c* su neusporedive

Slika 14. odnosi alternativa
(Sikavica, 2014).

U modeliranju *outranking relacije* se provjerava da li za alternative (*a, b*) vrijedi tvrdnja $S_A b$, tj. da li dominira *a* nad *b*, te se primjenjuju koncepti suglasnosti s dominacijom i nesuglasnosti s dominacijom. Suglasnost $aS_A b$ se temelji na prednosti koju *a* alternativa ima u odnosu na *b*, a mjeri se *indeksom suglasnosti s dominacijom*. Neslaganje s tvrdnjom $aS_A b$ temelji se na obilježjima alternative *b* koja se opire dominaciji alternativa *a*, pri čemu se primjenjuje *indeks nesuglasnosti s dominacijom*. Rezultat testiranja prikazan je na slici 15.



Slika 15. Modeliranje *outranking* relacije
(*Izvor: Sikavica, 2014*).

ELECTRE metodu je moguće prikazati prema sljedećim koracima: (*Sikavica, 2014*).

- računanje normalizirane tablice odlučivanja;
- računanje ponderirane normalizirane tablice odlučivanja;
- određivanje skupova suglasnosti i nesuglasnosti;
- računanje matrice suglasnosti;

- računanje matrice nesuglasnosti;
- uspostavljanje *outranking* relacije;
- eliminiranje dominiranih alternativa.

Metoda ima deset koraka ali ju se može prikazati i na formalniji način, tj. sedam koraka.

5. Primjer primjene PROMETHEE metode

U ovom poglavlju prikazano je korištenje D-Sight softvera i Smart Picker Pro softvera koji mogu pomoći donositelju odluka pri odabiru svoje odluke.

Definiranje problema

Poduzeće X je u svrhu poboljšanja komunikacije između odjela odlučilo zaposlenicima priuštiti nove mobitele. Između 20-tak mobitela odluka je pala na pet mobitela. Menadžer (donositelj odluke) je pri izboru mobitela najprije preferirao cijenu, gledajući da su i ostale karakteristike dovoljno zastupljene.

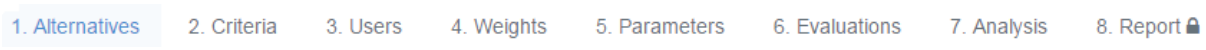
5.1. D–Sight

D-Sigh softver distribuiran je od strane D-Sight društva razvijenog na Sveučilištu *Libre de Bruxelles* 2010. godine. Tvrtka, je još uvijek snažno povezana sa Sveučilištem , te se i dalje nastavlja suradnja za razvoj softvera dodavanjem novih značajki ili novih algoritama. Sjedište tvrtke nalazi se u Bruxellesu u Belgiji. Projekt je proveden u *CoDE-SMG* laboratoriju fakulteta, a njegov razvoj je omogućen zahvaljujući priznanju regije Valonije. D-Sight je dostupan od veljače 2010. širom svijeta za nastavu i istraživačke svrhe.

Cilj D-Sight-a je da pomogne donositelju odluke da riješi problem odlučivanja gdje se moraju usporediti različite alternative, s obzirom na više kriterija. Vrlo se lako može pronaći najbolje rješenje i kao posljedica toga uštedjeti vrijeme. D-Sight je programiran u Javi i trenutno je dostupan samo za Windows platforme. Njegova struktura je dizajnirana tako da bi se osigurao nesmetan razvoj i održavanje, a podatkovni sloj je jasno definiran čime se omogućen lakši pristup za vanjske aplikacije. Softver je integriran s ostalim sustavima što znači da baze podataka automatski izravno vrše analizu podataka. D-Sight provodi klasične funkcionalnosti kao što su PROMETHEE I i II , GAIA ravnina, analiza osjetljivosti i sustav za grupnu potporu odlučivanju (GDSS). U odnosu na prethodnu verziju softvera načinjeno je nekoliko poboljšanja kao što je moderno korisničko sučelje.

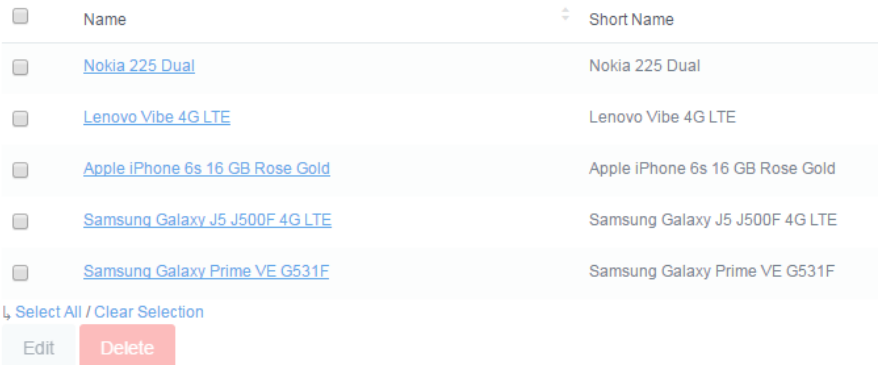
Opis programa

- Aplikacija se sastoji od pet stavki kako pokazuje slika 16. **:** Alternative, Kriteriji, Korisnici, Težine, Parametri, Procjene i Analize.



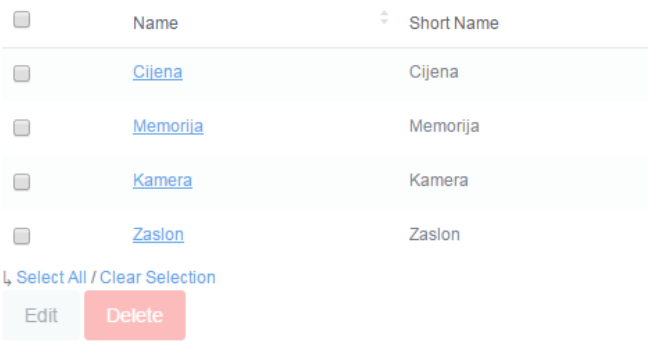
Slika 16. Početni izgled programa
(Izvor: Autor, 2016).

- Sljedeći korak kojeg je izbor Alternative između pet mobitela. Slika 17. pokazuje izbor mobitela između kojih donositelj odluke mora izabrati najboljeg.



Slika 17: Alternative
(Izvor: Autor, 2016).

- Drugi korak pokazuje Kriterije po kojima će se vršiti izbor odluke.



Slika 18. Kriteriji odluke
(Izvor: Autor, 2016).

- Treći korak pokazuje Korisnika koji će vršiti izbor odluke.



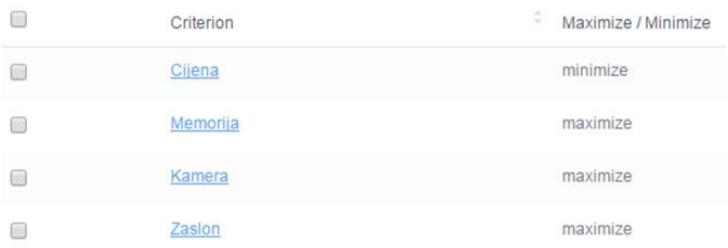
Slika 19. Korisnik
(Izvor: Autor, 2016).

- Četvrti korak su Težine koje pripadaju pojedinim alternativama, odnosno važnosti procjenjivanja svake stavke alternative, gdje spadaju: cijena, memorija, kamera i zaslon.



Slika 20. Težine
(Izvor: Autor, 2016).

- Peti korak se odnosi na Parametre.



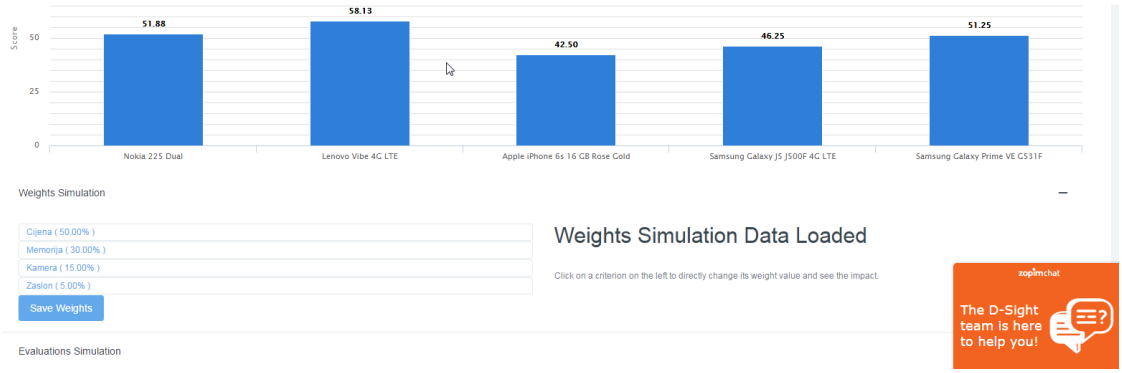
Slika 21. Parametri odluke
(Izvor: Autor, 2016).

- Šesti korak se odnosi na Evaluaciju (procjenu) podataka gdje se vide točni iznosi i sama usporedba.

	Cijena	Memorija	Kamera	Zaslon
Nokia 225 Dual	499.0	2.0	2.0	2.8
Lenovo Vibe 4G LTE	698.0	8.0	2.0	5.0
Apple iPhone 6s 16 GB Rose Gold	5,499.0	16.0	12.0	4.7
Samsung Galaxy J5 J500F 4G LTE	1,399.0	8.0	13.0	5.0
Samsung Galaxy Prime VE G531F	1,199.0	8.0	8.0	5.0

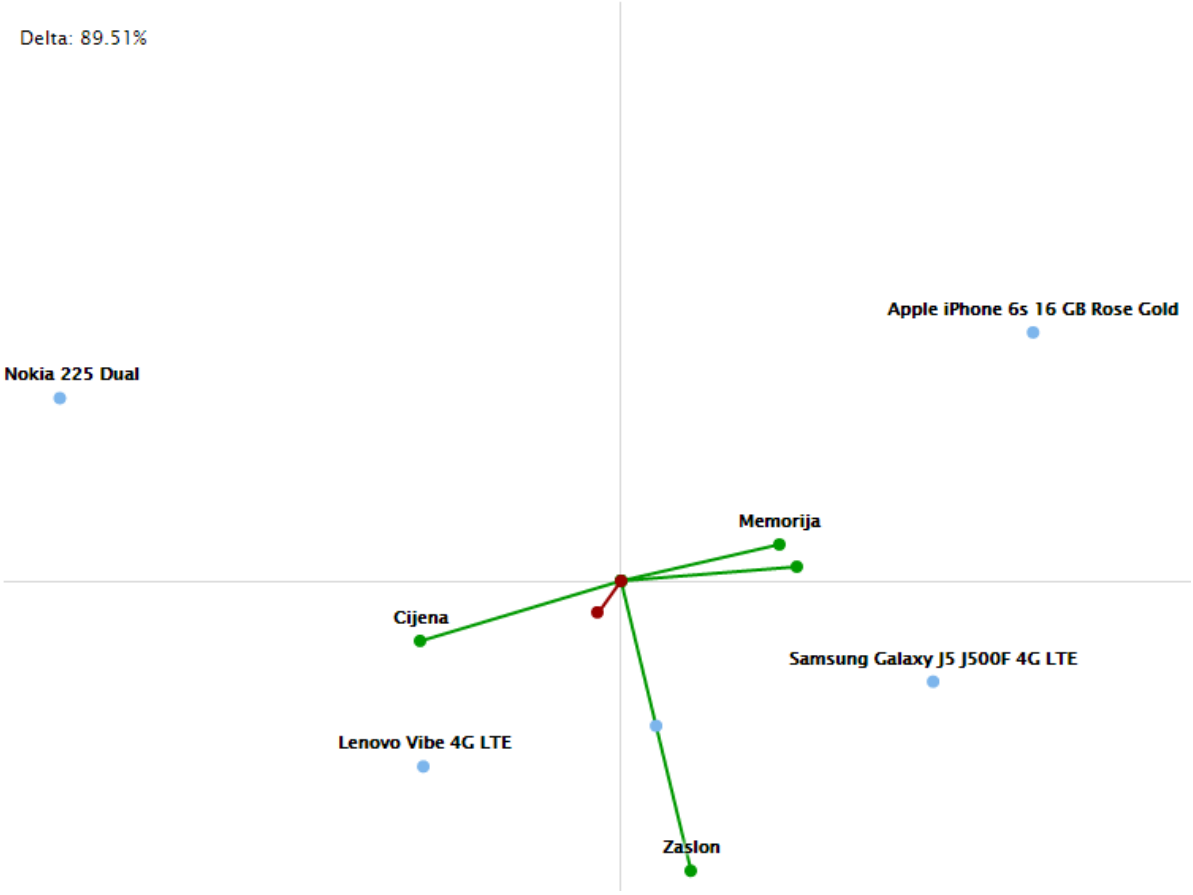
Slika 22. Procjena podataka
(Izvor: Autor, 2016).

- Sedmi korak je Analiza podataka gdje se vidi koji će mobitel izabrati donositelj odluke. Pošto je donositelj odluke odlučio da mu je na prvom mjestu cijena, odnosno 50 % se odnosi na cijenu, 30 % na memoriju, 15% na kameru i 5% na zaslon neovisno o modelu i marki mobitela. Izračunom, zaključak je da se na prvom mjestu nalazi Lenovo Vibe. Na drugom i trećem mjestu se nalaze Nokia i Samsung Galaxy Prime, te su oni tu negdje po težinama koje je odredio sam korisnik odluke. Na četvrtom mjestu se nalazi Galaxy J5, a na posljednjem mjestu koje je ujedno i neprihvatljivo se nalazi iPhone.



Slika 23. Analiza podataka
(Izvor: Autor, 2016).

- Global Visual Analysis



Slika 24. Global Visual Analysis
(Izvor: Autor,2016).

GAIA ravnina je dvodimenzionalni prikaz problema odlučivanja. Sadrži sve aspekte problema odlučivanja prema radnjama, kriterijima i odlukama. Same akcije su predstavljene točkama i strelicama. Položaj točke daje donositelju odluke uvid u rješavanje njegove nedoumice. U ovom primjeru, bitne stavke kao što su Memorija i Kamera su u neposrednoj blizini. S druge strane, Cijena i Zaslon su daleko jedan od drugoga, dakle Cijena je općenito daleko od drugih parametara. Sve ovisi o željama donositelja odluke, što znači da GAIA ovisi o parametrima koje je unio sam donositelj odluke. Što se tiče samog grafa, relativni položaj kriterija nam pokazuje povezanost i nepovezanost (ili sukob) kriterija. Što su strelice bliže, to su više povezanije. Zanimljivo je spomenuti da Orijentacija osi, tj os odluke (obojano u zeleno) pokazuje koji kriteriji su kompatibilni, a koji nisu. Cijena je čini se u sukobu s Memorijom i Kamerom pošto idu u različitim pravcima. Stoga, nije lako naći mobitel koji postiže dobre rezultate na svim kriterijima. Međutim Cijena je okomito postavljena na Zaslon, što ukazuje da

je ona neovisna. U ovom slučaju svi kriteriji osi imaju dobre veličine, što znači da predstavlja značajnu varijaciju između različitih procjena. Drugi važan aspekt grafa s o odluci je štapić (obojan crveno) pokazuje važnost kriterija donositelju odluke. U ovom slučaju prednost se daje Cijeni (uključujući i druge težine) pa je stoga štapić okrenut prema tom smjeru. Ako dva kriterija idu u istom pravcu znači da su slični, ako idu u suprotnim smjerovima, znači da su u sukobu. Za odabir najbolje odluke mobitel Lenovo Vibe, s obzirom na cijenu, memoriju, 15% na kameru i 5% na zaslon

Kod odabira druge metode tj. Smart-Picker Pro uzet je isti primjer radi usporedbe podataka.

5.2. Smart–Picker Pro

Smart-Picker Pro je razvijen od strane Smart-Picker tima koji je započeo 2011. godine s ciljem da olakša proces donošenja odluka. Sjedište se nalazi u Bruxellesu (*Engineering Department*). Softver je dostupan svima i vrlo lagan za korištenje. Smart-Picker Pro koristi dvije metode:

- PROMEETHE metoda: tako da rangira i vrednuje svaku opciju uspoređujući sve alternative;
- FlowSort metoda: nova metoda sortiranja gdje se dodaju opcije potpuno uređenim kategorijama.

Besplatna verzija (trial verzija) dostupna je na www.smart-picker.com i može se neograničeno koristiti. Međutim, pokusna verzija je ograničena na pet akcija i četiri kriterija. Važni pojmovi koji se koriste u softveru:

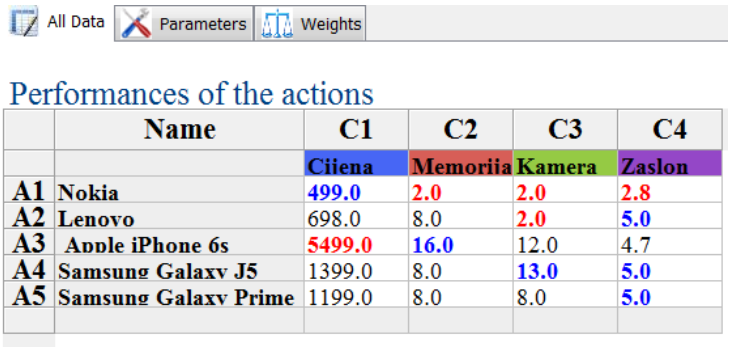
- Akcije: akcijom se smatra opcija ili alternativa u samom problemu. U ovom slučaju problem je izbor mobitela;
- Kriteriji: svojstva ili značajke koje definiraju akcije (mogu biti numeričke ili nenumeričke vrijednosti);
- Vrijednosti: Vrijednosti kriterija ukazuju rad na akcijama;
- Profil: poseban postupak koji definira skupinu. Profil može igrati ulogu primjer skupine (središnji profil) ili granicu od skupina (ograničavajući profil);
- Težina kriterija: odnosi se na važnost kriterija u odnosu na druge kriterije;
- Min/max: odnosi se na smjer kriterija gdje želimo npr. minimizirati cijenu;

- Parametri: na osnovu njih dobivamo težine;
- Tok: postoji pozitivni tok, negativni tok , te ukupni tok;
- Kategorija: grupa;
- Sortiranje: grupiranje;
- Poredak: naručivanje, određivanje prioriteta.

(*Smart-Picker Pro.com*)

Opis programa:

- Program započinje dodavanjem parametra. Crvena vrijednost u određenom stupcu pokazuje najgoru ocjenu za taj kriterij, dok je plava najbolja vrijednost.



	Name	C1	C2	C3	C4
		Cijena	Memorija	Kamera	Zaslon
A1	Nokia	499.0	2.0	2.0	2.8
A2	Lenovo	698.0	8.0	2.0	5.0
A3	Apple iPhone 6s	5499.0	16.0	12.0	4.7
A4	Samsung Galaxy J5	1399.0	8.0	13.0	5.0
A5	Samsung Galaxy Prime	1199.0	8.0	8.0	5.0

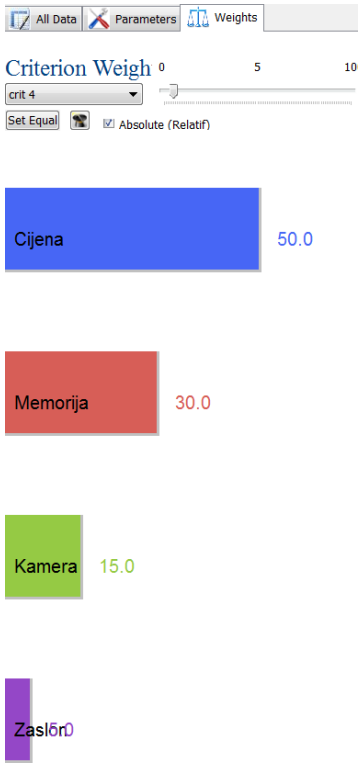
Slika 25. Parametri
(Izvor: Autor, 2016).

- U sljedećem koraku su dodane Težine i druge vrijednosti.

	Cijena	Memorij	Kamera	Zaslon
new name	Cijena	Memorija	Kamera	Zaslon
min_max	min	max	max	max
weight	0.5	0.3	0.15	0.05
Type (L/S)	L	L	L	L
p	700.0	8.0	10.0	5.0
q	300.0	5.0	5.0	2.0
Abs/Rel	Abs	Abs	Abs	Abs

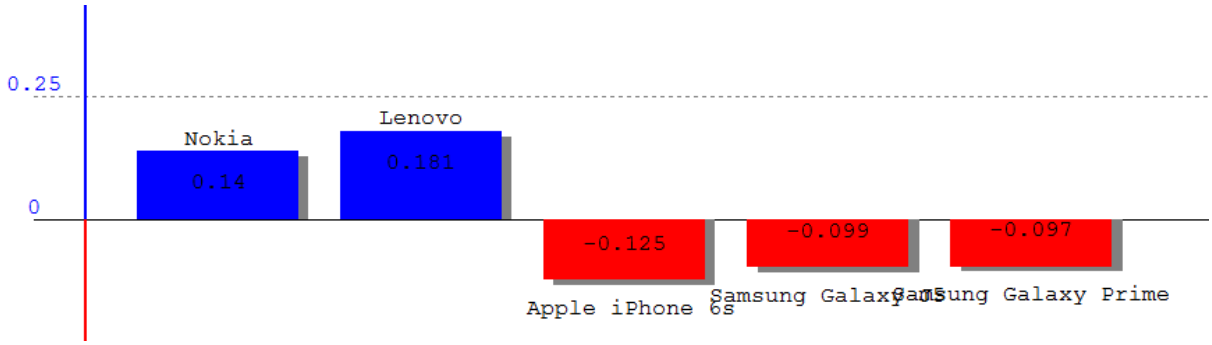
Slika 26. Parametri i težine odluke
(Izvor: Autor, 2016).

- Slika 27. pokazuje Težine kriterija.



Slika 27. Težina kriterija
(Izvor: Autor, 2016).

- Rangiranje ljestvice.



Slika 28. Rangiranje podataka
(Izvor: Autor, 2016).

- Pozitivni, negativni i neto tokovi

Results | Processed Data

	Actions	Pos Flows	Neg Flows	Net Flows
	A1 - Nokia	0.375	0.1575	0.2175
	A2 - Lenovo	0.31281	0.0825	0.23031
	A3 - Apple iPl	0.15	0.5	-0.35
	A4 - Samsung	0.2	0.25	-0.05
	A5 - Samsung	0.14	0.18781	-0.04781

Slika 29. Pozitivni, negativni i neto tokovi
(Izvor: Autor, 2016).

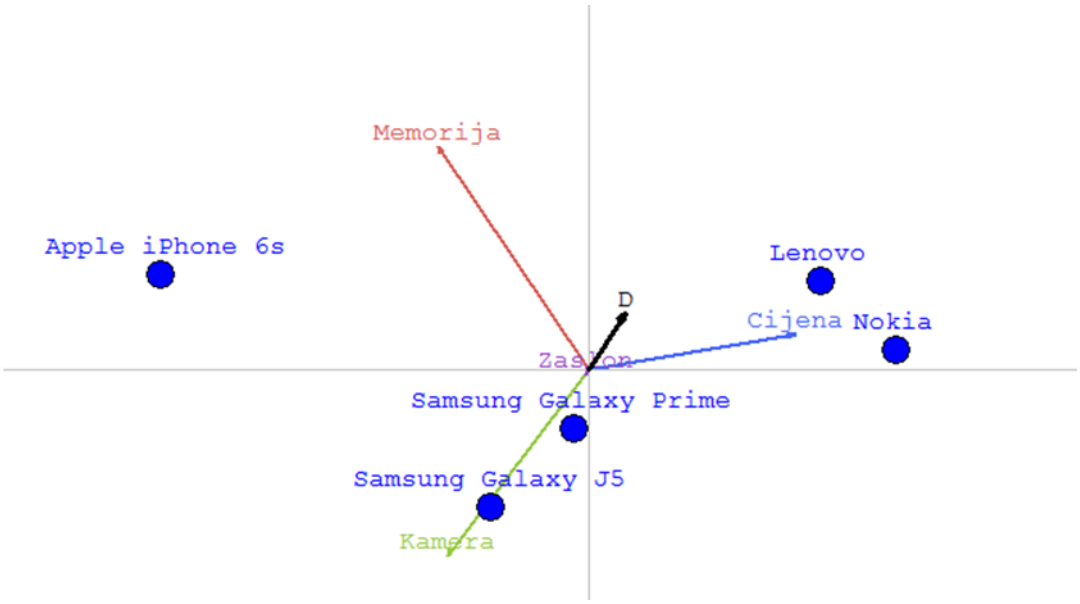
Pozitivan tok (engl. *Positive flows*) ili izlazi tok akcije je rezultat između 0 i 1. Pokazuje koliko je poželjna akcija nad svim drugim akcijama na tom kriteriju. Što je veći pozitivan tok, više se preferira radnja u usporedbi s drugima. Dakle, pozitivni tok je normalizirani zbroj svih elemenata u redu i uvijek se nalazi između 0 i 1.

Negativni tok (engl. *Negative flows)* predstavlja prosječno ponašanje. On mjeri koliko su ostali postupci u prednosti na ovu akciju. Negativni tok je dobiven uzimajući prosjek svih povlaštenih akcija u odnosu na određenu akciju. Rezultat se uvijek nalazi između 0 i 1.

Neto tokovi (engl. *Net flows*) uzimajući u obzir obje pozitivne i negativne aspekte mogu se koristiti neto tokovi radnje koje su dobiveni oduzimanjem negativnih tokova od pozitivnih tokova. Oni moraju biti maksimizirani jer predstavljaju ravnotežu između globalna snaga i slabosti akcije. Neto rezultat od akcije uvijek se nalazi između -1 i 1.

- GAIA ravnina.

Kako je već spomenuto, GAIA predstavlja grafički prikaz odlučivanja i dopušta brzo otkrivanje slabosti i prednosti uspoređujući ih. Vrlo brzo se otkriju sličnosti između ponuđenih akcija. Točke u plavom predstavljaju radnje između kojih donositelj odluke vrši odabir, dok strelice u boji predstavljaju kriterije koje opisuju mobitele. Strelica s oznakom D, štapić odluke, (engl. *decision stick*) čini kompromisno rješenje izabran od strane donositelja odluke jer odgovara njegovim zahtjevima. Slika 30. prikazuje grafički prikaz GAIA ravnine.



Slika 30. Grafički prikaz GAIA
(Izvor: Autor, 2016).

Isto kao i u prošlom primjeru, položaj točaka označava sličnosti, što su točke bliže to su sličnije, i obrnuto, što su dalje to su različitije. Kao što se vidi Lenovo i Nokia su veoma blizu jedno drugom što znači da su slični, dok s druge strane iPhone i Samsung su daleko jedan od drugog, a isto tako i od Lenova i Nokie.

Što se tiče dobivenog rješenja, ono je isto u oba dva primjera. Donositelj odluke će se odlučiti za Lenovo Vibe uzimajući u obzir prvenstveno cijenu, ali i uz druge karakteristike kao što je memorija dok su kamera i zaslon zastupljeni u manjoj mjeri.

Glavne prednosti uporabe ovih programskih paketa je mogućnost izvedivosti analize osjetljivosti. To omogućuje donositelju odluke da promjeni vrijednosti parametra. Ako donositelj odluke ne navede nikakve informacije preferencija D-Sight softver će dodijeliti zadane vrijednosti, tako da se broj bodova još uvijek može izračunati. Jedna od glavnih značajki D-Sight-a je u tome što omogućuje donositelju odluke da promijeni sve parametre, a istovremeno analizira različite ljestvice. Tako se mogu izravno mijenjati svi parametri po želji.

S druge strane, Smart Picker Pro je dizajniran da bi omogućio najbolje rješenje u procesu donošenja odluka, odnosno omogućit će najbolji izbor između opcija ili alternativa.

Osim primjera odabira mobitela, može se koristiti i za druge probleme odlučivanja npr. odabir osobe koja je najprikladnija za posao s obzirom na svoje radno iskustvo, socijalne

vještine, fleksibilnost i motivaciju, kao i pri odabiru savršenog automobila, gdje će se uzeti u obzir cijena (smanjena na minimum), moć (koja će se maksimizirati), prostor (koji će se maksimizirati), i slični primjeri. Lijepi i razumljivi grafovi omogućuju brze zaključke, te pružaju bolji uvod u probleme. Dobivena rješenja se mogu pregledati u Excel-u, Word-u i PDF-u.

6. Zaključak

Cilj završnog rada bio je opisati primjenu metode višekriterijske analize pri donošenju odluka. Metoda treba biti odabrana tako da se prvo usmjeri na kvalitetu i dostupnost informacija, a kao drugo treba se razumjeti kako primijeniti te informacije na sam model. Višekriterijsko donošenje odluka može se smatrati složenim i dinamičnim procesom koji uključuje menadžersku razinu odlučivanja ali isto tako mogu se primijeniti na odluke u svakodnevnom životu. Iako se odluke donose se kontinuirano i često nesvjesno, jasno je da su neke od njih su važnije od drugih. Postoje različite metode koje se mogu koristiti i često daju različite rezultate, čak i kada se primjenjuju na isti problem koristeći iste podatke. Donositelj odluke ima bitnu ulogu u samom procesu odlučivanja. Ali bez donositelja odluke ne može se primijeniti metoda odlučivanja. Metoda pomaže donosiocu odluka da donese odluku. Isto tako, može dati rješenja za povećanje kompleksnih problema upravljanja i bolje razumijevanje problema odlučivanja. Problem donošenja odluka bi trebao početi jasno definiranjem problema, razlikujući alternative, identificiranjem akcija i ciljeva u sukobu. Odabirom metode se olakšava donošenje odluke. Ne postoji loša metoda ili bolja metoda, treba samo pronaći metodu koja se razumije te će onda postati laka za korištenje i koja će odgovarati određenoj situaciji.

PROMEETHE metoda koja je uzeta kao primjer. Koristi se širom svijeta u mnogim različitim područjima. Metoda PROMETHEE I koristi se da se dobije djelomično rangiranje svih mogućih razmatranih alternativa, dok PROMETHEE II se koristi za dobivanje kompletnog ranga. Metoda se primjenjuje jer dozvoljava izravno korištenje podataka za odabrani problem. Donositelj odluke sam određuje kriterije te na osnovi rezultata dobiva analitičko i grafičko rješenje. U radu su korištena dva softvera koja su lagana za korištenje: SmartPicker Pro i D-Sight.

Kod postojanja više kriterija koriste se metode višekriterijske analize koje se mogu lako primijeniti za sva područja, kao i u ovom radu gdje se radilo o izboru mobitela za poduzeće „X“. Kako konačna odluka uvelike ovisi o važnostima tj. težinama pojedinih kriterij gdje donositelj odluke mora odrediti važnost svakog kriterija. Kod odabira, uz cijenu su se gledali i ostali kriteriji kao što je memorija, kamera i zaslon. Konačna odluka je dobivena na osnovi težina pojedinih kriterija. Prikazan je i dvodimenzionalni prikaz problema odlučivanja tj. GAIA ravnina koja sadrži sve aspekte problema odlučivanja prema radnjama, kriterijima i odlukama.

7. Literatura:

Knjige:

- Babić Z., (2011), Modeli i metode poslovnog odlučivanja, Split;
- Barković. D., (2009), Menadžersko odlučivanje, Osijek;
- Sikavica P. , Bebek B. , Skoko H. , Tripunić D. (1999), Poslovno odlučivanje, Zagreb;
- Sikavica P., Hunjak T, Nina B. R, Hernaus T., (2014), Poslovno odlučivanje, Zagreb;
- Ishizaka A., Nemery P., (2013), Multi-Criteria Decision Analysis, United Kingdom;
- Malczewski J., Rinner C., (2015), Multicriteria Decision Analysis in Geographic Information Science, Canada;
- Figueira J., Greco S., Ehrgott M., (2005), Multiple criteria decision analysis: state of the art surveys, Boston;
- Linstone H. A, Turoff M., Helmer O., (2002), The Delphi Method Techniques and Applications, University of Southern California

Internet:

- Saaty T.L., (n.g), The Analytic Network Process ,University of Pittsburgh, http://www.iors.ir/journal/article-1-27-en.pdf ; (vrijeme pristupa: 10.06.2016.)
- Sadeghi M., Rashidzadeh M., SOUKHAKIAN , Soukhakian M.,(2012), Using Analytic Network Process in a Group, Decision-Making for Supplier Selection, Vilnius University, http://www.mii.lt/informatica/pdf/INFO870.pdf ; (vrijeme pristupa: 10.06.2016.)
- Mazurek J., Kiszová S., (2012), Modeling dependence and feedback in ANP with fuzzy cognitive maps, Češka, http://mme2012.opf.slu.cz/proceedings/pdf/096_Mazurek_K.pdf ; (vrijeme pristupa: 10.06.2016.)
- Trick M. A, (1998), Strengths and Limitations of DEA, http://mat.gsia.cmu.edu/classes/QUANT/NOTES/chap12/node7.html ; (vrijeme pristupa: 10.06.2016.)
- Hsu C.,(2007)The Delphi Technique: The Ohio State University & Brian A. Sandford,

http://essentialsofmedicine.com/sites/default/files/Delphi%20Technique_%20Making%20Sense%20Of%20Consensus.pdf , (vrijeme pristupa: 10.06.2016.)

- Vincová K., (2005), Using DEA models to measure efficiency, http://www.nbs.sk/_img/Documents/BIATEC/BIA08_05/24_28.pdf ; (vrijeme pristupa: 10.06.2016.)

8. Dodaci

Tablice

TABLICA 1. EMV S JEDNAKIM VJEROJATNOSTIMA 11
TABLICA 2. TABLICA ŽALJENJA 12
TABLICA 3. EOL S VJEROJATNOSTIMA 1/3 12
TABLICA 4. TABLICA ODLUKE ILI PAYOFF 13
TABLICA 5. EOL S VJEROJATNOSTIMA 0.20, 0.40 I 0.40 14
TABLICA 6. MAKSIMIN IZBOR PROJEKTA 15
TABLICA 7. MAKSIMAKS IZBOR PROJEKTA 16
TABLICA 8. LAPLAECOV IZBOR PROJEKTA 16
TABLICA 9. HURWICZOV KRITERIJ ZA VRIJEDNOST A=0.6 17
TABLICA 10. MINIMAKS KRITERIJA ŽALJENJA ZA PROJEKTE 18
TABLICA 11. MCDA SOFTVERSKI PROGRAMI 20
TABLICA 12. RANGIRANJE PREMA TEŽINI 22
TABLICA 13. OCJENE KRITERIJA 24
TABLICA 14. NORMINIRANE OCJENE KRITERIJA 24
TABLICA 15. PROMETHEE – MATRICA ODLUKE 32
TABLICA 16. PROMETHEE I – PARCIJALNO RANGIRANJE 38
TABLICA 17. SAATYEVA LJESTVICA MJERENJA 41
TABLICA 18. ELECTRE METODE 51

Slike

SLIKA 1. KORACI DELPHI TEHNIKE 29
SLIKA 2. FUNKCIJA PREFERENCIJE 33
SLIKA 3. OBIČNI KRITERIJ 34
SLIKA 4. KVAZI KRITERIJ 34
SLIKA 5. KRITERIJ S LINEARNOM PREFERENCIJOM 35
SLIKA 6. RAZINSKI KRITERIJ 35
SLIKA 7. KRITERIJ S LINEARNOM PREFERENCIJOM I PODRUČJEM INDIFERENCIJE 36
SLIKA 8. GAUSSOV KRITERIJ 36
SLIKA 9. LUKOVI $\Pi(A,B)$ I $\Pi(B, A)$ 37
SLIKA 10. IZLAZNI I ULAZNI TOK 37
SLIKA 11.OSNOVNI AHP MODEL 39
SLIKA 12. LINEARNA HIJERARHIJA U ANP 47
SLIKA 13. KLASTERI U ANP MREŽI 47
SLIKA 14. ODNOSI ALTERNATIVA 52
SLIKA 15. MODELIRANJE *OUTRANKING* RELACIJE 52
SLIKA 16. POČETNI IZGLED PROGRAMA 55
SLIKA 17: ALTERNATIVE 55
SLIKA 18. KRITERIJI ODLUKE 55
SLIKA 19. KORISNIK 56
SLIKA 20. TEŽINE 56
SLIKA 21. PARAMETRI ODLUKE 56
SLIKA 22. PROCJENA PODATAKA 57
SLIKA 23. ANALIZA PODATAKA 57
SLIKA 24. GLOBAL VISUAL ANALYSIS 58
SLIKA 25. PARAMETRI 60
SLIKA 26. PARAMETRI I TEŽINE ODLUKE 60
SLIKA 27. TEŽINA KRITERIJA 61
SLIKA 28. RANGIRANJE PODATAKA 61
SLIKA 29. POZITIVNI, NEGATIVNI I NETO TOKOVI 62