IZBOR DOBAVLJAČA I VIŠEKRITERIJALNA ANALIZA

Muschter, Andre Thomas

Master's thesis / Diplomski rad

2016

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:881254

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split







SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

IZBOR DOBAVLJAČA I VIŠEKRITERIJALNA ANALIZA

MENTOR:

Prof. dr. sc. Babić, Zoran

STUDENT:

Muschter, André Thomas

Br. indeksa: 2140756

Split, prosinac 2016.

Sadržaj

Sadržaj **1**

1. UVOD **2**

1.1 Problem i predmet istraživanja 2

1.2 Metode i doprinos istraživanja 3

2. TEORIJSKE PRETPOSTAVKE RADA **6**

2.1 Poslovno odlučivanje pomoću AHP metode 6

2.1.1 Izbor kriterija za izbor dobavljača 8

2.1.2 Formuliranje hijerarhije u AHP metodi 9

2.1.3 Određivanje relativnih težina elemenata u AHP metodi 10

2.2 Višekriterijalno odlučivanje - PROMETHEE metoda 13

2.3 Linearno programiranje 21

2.3.1 Standardni problem 21

2.3.2 Kanonski problem 22

2.3.3 Rješavanje problema izbora dobavljača pomoću linearnog programiranja ... 23

3. PRIMJENA NA STUDIJU SLUČAJA **25**

3.1 Općenito o nabavljanju sirovina u automobilskoj industriji 25

3.2 Kriteriji za izbor dobavljača 26

3.2.1 Kriteriji o performansi logistike 26

3.2.2 Kriteriji o komercijalnoj strukturi 27

3.2.3 Kriteriji o proizvodnji 29

3.3 Određivanje težina kriterija za izbor dobavljača pomoću usporedbe u parovima 32

3.4 Primjena PROMETHEE metode za izbor dobavljača 42

3.4.1 Konačno rangiranje dobavljača pomoću PROMETHEE II 46

3.4.2 Analiza osjetljivosti 46

3.5 Izbor dobavljača pomoću linearnog programiranja 50

4. ZAKLJUČAK **54**

Sažetak **56**

Summary **56**

Literatura **57**

Popis slika **61**

Popis tablica **62**

1. UVOD

1.1 Problem i predmet istraživanja

Globalizacijom ekonomskih tržišta i razvojem informacijske tehnologije dobro osmišljen i primijenjen «Supply Chain menadžment» (SCM) sustav smatra se bitnim alatom za povećanje kompetitivne prednosti. (Chopra i Meindel 2006) Temelj SCM-a su zajednički interesi koji, ako se usklade, vode do smanjivanja troškova i vode do ostvarenja zajedničkih ciljeva. Izbor dobavljača jedan je od ključnih elemenata u procesu industrijske proizvodnje, a i jedna je od glavnih aktivnosti profesionalaca u industriji, te bitan za uspješni SCM (Telgen 1994). Izbor i evaluacija dobavljača proces je traženja prikladnih dobavljača koji mogu opskrbiti proizvođača sirovinama ili poluproizvodima odgovarajuće kvalitete i/ili uslugama odgovarajuće cijene u odgovarajućim količinama i pravom vremenu (Mandal & Deshmukh, 1994). Problem izbora dobavljača pojavljuje se u mnogobrojnim poslovima kao što su proizvodnja automobila, kemijska industrija, građevina, bolnice i telekomunikacije (Diaz-Madronero et. al., 2010). Suma troškova za nabavljenu robu u industrijskim poduzećima varira između 50 – 90% (Boer; Labro & Morlacchi, 2000). U današnje vrijeme tvrtke zahtijevaju viši nivo performansi od svojih dobavljača, a u isto vrijeme i dobar poslovni odnos. U ovom kontekstu, problem izbora dobavljača povezan je s odlučivanjem o izboru samo jednog dobavljača u lepezi potencijalnih alternativa. Stoga izbor dobavljača postaje vrlo bitna strateška odluka(Diaz-Madronero et. al., 2010).

U principu postoje dvije vrste problema oko izbora dobavljača (Perić & Babić, 2007):

Prvi je onaj kada u izboru dobavljača ne postoji ograničenje – svi dobavljači mogu ispuniti zahtjeve kupca za potražnjom, kvalitetom, dostavom itd. Kod ovakve vrste izbora dobavljača management jedino treba odlučiti koji je dobavljač najbolji.

Drugi je tip problema oko izbora dobavljača onaj kada postoje ograničenja u kapacitetu dobavljača. Drugim riječima – nijedan dobavljač ne može ispuniti sve kupčeve zahtjeve te kupac mora nabaviti dio potražnje od jednog dobavljača, a ostatak od drugog kako bi kompenzirao nedostatak ili nisku kvalitetu prvog dobavljača.

Međutim, postoji i mogućnost da kupac na svoju inicijativu zahtijeva nabavu kod više dobavljača. U tom slučaju bi se kupac odlučio protiv nabave kod jednog dobavljača iako bi on po izbornim kriterijima predstavljao najbolju opciju za kupnju ukupne količine potrebnih proizvoda.

Kako je prethodno navedeno, izbor dobavljača vrlo je bitan dio uspješnog poslovanja. Međutim, racionalan izbor je moguć samo ako se donosi odluka po svim kvalitativnim i kvantitativnim kriterijima koje su tvrtci bitni. To je razlog zbog čega će se u ovom radu koristiti metode višekriterijalnog odlučivanja pri rješavanju svakodnevnog problema koji se javlja u automobilskoj industriji – gdje nabaviti potrebne dijelove? Tako su, na primjer, Weber, Current i Benton nabrojali 23 različita kriterija koja se koriste u procesu izbora dobavljača (Weber et. al., 1991).

Predmet je istraživanja proizvođač automobila u Njemačkoj koji nabavlja spremnike goriva od materijala HDPE preko nekoliko dobavljača za proizvodnju lakših automobila. Smatra se da se pomoću AHP i PROMETHEE metode može optimizirati izbor dobavljača spremnika goriva od HDPE materijala. Ukoliko postoje i dodatna ograničenja, izbor optimalne kombinacije dobavljača vrši se pomoću linearnog programiranja.

Iz definiranog problema i predmeta istraživanja proizlazi sljedeća hipoteza :

H1: Pomoću metoda višekriterijalnog odlučivanja može se postići optimalan izbor jednog ili više dobavljača. U konkretnom slučaju, radi se o izboru dobavljača spremnika goriva od HDPE-a za proizvođača automobila.

U skladu s definiranim problemom i predmetom istraživanja te postavljenom hipotezom moguće je odrediti ciljeve ovog rada.

Glavni je cilj pokazati da se pomoću AHP i PROMETHEE metode te maksimalizacije prema «total value of purchasing» (TVP) može postići racionalno dobar izbor najboljeg dobavljača ili kombinacija najboljih dobavljača za nabavu spremnika goriva.

1.2 Metode i doprinos istraživanja

U teorijskom dijelu istraživanja koristit će se opće znanstvene metode (Zelenika, 2000):

- metoda dokazivanja – utvrđivanje istinitosti stavova na temelju činjenica i spoznaja,
- metoda analize – raščlanjivanje složenih pojmova, sudova i zaključaka na njihove jednostavnije dijelove, te izučavanje svakog dijela za sebe,
- metoda sinteze – povezivanje jednostavnijih pojmova, sudova i zaključaka u složene,

- metoda deskripcije – jednostavno opisivanje činjenica i procesa te njihovih empirijskih potvrđivanja odnosa i veza,
- statističke metode – prikupljanje podataka i informacija, grafičko i tabelarno prikazivanje, donošenje zaključaka, tumačenje rezultata i postavljanje hipoteza,
- metoda studije slučaja – istraživanje slučaja na poduzeću XY u automobilskoj industriji,
- metoda kompilacije – preuzimanje tuđih opažanja, stavova, zaključaka i spoznaja,
- komparativna metoda – postupak uspoređivanja pojmova i utvrđivanje njihovih sličnosti i razlika.

U praktičnom dijelu rada koristit će se metoda intervjua i analiza poslovne dokumentacije (promatranje) te metode višekriterijalne analize i metode rješavanja problema linearnog programiranja.

Analiza i sinteza problematike izabrane AHP metode i maksimizacije TVP-a za izbor dobavljača teorijski su doprinos rada.

Cilj je teorijskog istraživanja dati odgovore na brojna pitanja, od kojih se ističu

sljedeća:

- Kako izabrati relevantne kriterije za jednu odluku?
- Kako odrediti važnosti pojedinih kriterija?
- Kako rangirati alternative?
- Kako rješavati problem optimizacije pomoću linearnog programiranja (maksimizacija TVP)?

Praktični je doprinos simulacija primjene modela na studiji slučaja nabava spremnika goriva kod jednog proizvođača automobila u Njemačkoj. Praktično istraživanje trebalo bi odgovoriti na sljedeća pitanja:

- Kako izabrati relevantne kriterije za odabir dobavljača?
- Kako dodijeliti težine relevantnim kriterijima po važnosti za odabir dobavljača?

- Kako rangirati dobavljače? Od kojeg dobavljača kupiti proizvod?
- Kako rješavati problem izbora dobavljača s ograničenjima pomoću linearnog programiranja (maksimizacija TVP)?

2. TEORIJSKE PRETPOSTAVKE RADA

2.1 Poslovno odlučivanje pomoću AHP metode

AHP metoda od utemeljenja je postala najviše korišten alat donositelja odluka i istraživača za višekriterijalno odlučivanje. Do današnjeg dana publiciralo se mnogo vrhunskih radova povezano uz AHP (Omkarprasad & Kumar, 2006). AHP metoda svestrano se primijenjuje u državnim upravama za npr. ispravnu implementaciju planova ili smjer politike te u industriji za planiranje, alokaciju resursa ili, kao u ovom radu, izbor dobavljača (Ramanathan, 1999).

Kao što je prethodno navedeno, izbor dobavljača jedna je od najvažnih aktivnosti organizacije. Kompetitivna tržišta prisiljavaju mnoge organizacije na plasman proizvoda ili usluga brže, jeftinije i bolje od konkurencije (Bayazit; Karpak, 2005). To navodi organizacije na promišljanje njihove kupovne strategije i znatno povećava važnost znanstvene literature o nabavi (Ellram, 1990).

Ghodsypour i O'Brien (1998) proučavali su konflikte između kvantitativnih i kvalitativnih faktora temeljenih na AHP metodi radi određivanja najboljeg dobavljača. Integrirali su AHP i linearno programiranje kako bi izračunali optimalne količine koje treba naručiti. Kako bi to uspjelo, maksimizirali su TVP. Ovaj model može se primijeniti na izbor dobavljača sa ili bez ograničenja kapaciteta. Akarte (2001) koristi AHP kako bi odabrao najbolje dobavljače iz grupe evaluiranih dobavljača. Proces evaluacije uključio je 18 različitih kriterija koji su bili podijeljeni u četiri grupe: sposobnost razvijanja proizvoda, sposobnost proizvodnje, sposobnost kvalitete i trošak te dostava. Šest od osamnaest kriterija bili su objektivnog tipa, dok je ostatak subjektivnog tipa. Metoda evaluacije ovog modela temeljena je na mjerenju relativne izvedbe za svakog dobavljača za subjektivni (kvalitativni) kriteriji, koji se dobije pretvaranjem kvalitativnih kriterija u kvantitativne. Dobavljač s najvišim rezultatom bit će izabran.

Tam i Tummala (2001) koristili su AHP u izboru dobavljača telekomunikacijskog sustava. Autori su došli do zaključka da je AHP vrlo koristan u uzimanju u obzir nekoliko donositelja odluke u odnosu na različite sukobljavajuće faktore, a sve da bi se stvorio konsenzus oko odluke. Proces donošenja odluke, kao rezultat prethodno navedenoga, sistematičan je i smanjuje vrijeme izbora dobavljača.

Izbor dobavljača bitan je proces u svakoj tvrtki neovisno o tome je li to dugoročno ulaganje ili kratkoročna kupovina materijala, a uspjeh tvrtke izravno je povezan uz odluku izbora dobavljača.

Korištenje AHP-a indicira da se navedeno može upotrijebiti kako bi se unaprijedilo grupno donošenje odluka o izboru dobavljača koji će zadovoljiti uvjete koje je kupac postavio na tržištu. Također se zaključuje da je proces donošenja odluke sistematičan, a korištenje AHP modela znatno smanjuje vrijeme koje se utroši u izboru dobavljača.

AHP se koristi u različitim situacijama kako bi se donijele odluke (Saaty, 2008):

- 2001. godine metoda je korištena kako bi se odredila najbolja točka za preseljenje grada nakon potresa u turskom gradu Adapazari
- British Airways koristio ju je 1998 za odabir dobavljača za multimedijski sustav za cijelu flotu zrakoplova
- Proces je primijenjen u konfliktu između SAD-a i Kine oko prava na intelektualno vlasništvo 1995. kada su državljani Kine kopirali glazbu, video i CD-e. AHP analiza, koja je uključivala tri hijerarhije za korist, trošak i rizik, pokazala je da je za SAD najbolje da ne sankcioniziraju Kinu
- Xerox korporacija koristila je AHP kako bi rasporedila gotovo milijardu dolara na svoje istraživačke projekte
- 1999. Ford Motor Company tvrtka koristila je AHP da utvrdi prioritete za kriterije koji služe poboljšanju zadovoljstva kupaca. Ford je dodijelio Exepert Choice Inc nagradu za izvrsnost za pomaganje kako bi postigli veći uspjeh kod klijenata
- 1986. Institut strateških studija u Pretoriji, organizacija koju podupire vlada, koristio je AHP da analizira konflikt u Južnoj Africi i predloži radnje koje se kreću od oslobođenja Nelsona Mandele do povlačenja apartheida i osiguravanja punopravnog državljanstva i jednakih prava za sve ljude. Sve od preporučenih radnji bile su brzo primijenjene.
- IBM je koristio AHP 1991. kod dizajniranja uspješnog AS400 kompjutera srednje klase te je zato dobio prestižnu Malcolm Baldrige nagradu za izvrsnost

Zbog svega navedenoga ovaj pristup odabran je od strane određenog proizvođača automobila kako bi se odabrao najbolji dobavljač zA HPDE spremnike goriva.

2.1.1 Izbor kriterija za izbor dobavljača

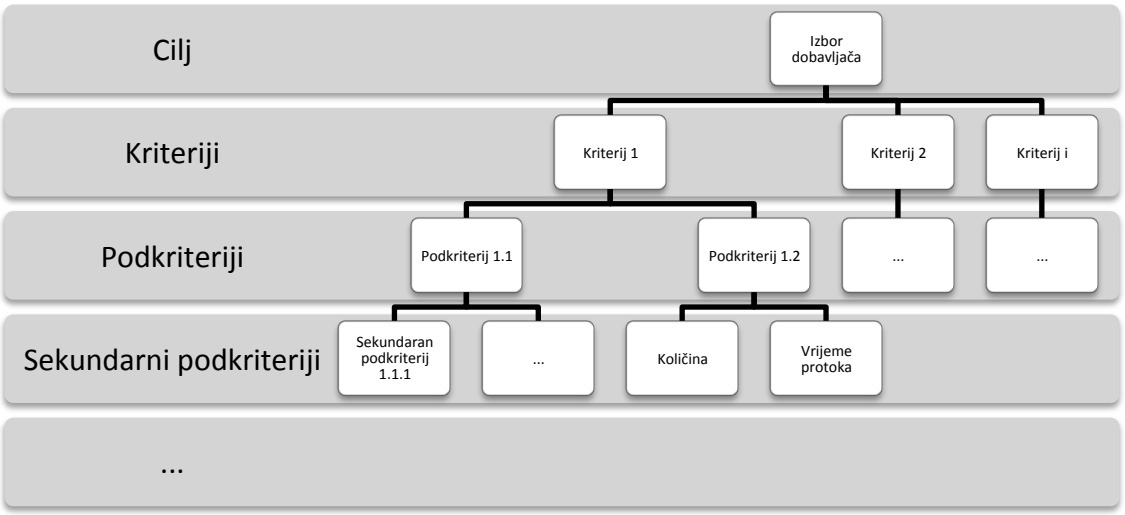
Jedan od bitnijih faktora uspjeha efikasna je kupovina. (Cakravastia & Takahashi, 2004; Porter & Millar, 1985)

Tvrtka koristi kriterij za odabir dobavljača da procijeni uklapa li se dobavljač u njihovu strategiju tehnologije ili ne. Jedna od poznatih studija koja se bavi odabirom dobavljača ona je autora Dicksona (1966) koji je identificirao 23 bitna kriterija evaluacije za odabir dobavljača. Studije Arbela i Seidmanna (1984), Becka i Lina (1981), Barda (1986) i Liberatorea (1987) identificirale su određeni broj kriterija imajući u vidu financijski, tehnički i operacijski aspekt. Weber, Current, i Benton (1991) klasificirali su 74 članka koji se također bave istom problematikom. Prema Weberu et. al. (1991), kvaliteta je najbitniji kriterij, a slijedi performansa dostave i cijena. Nadalje, Cardozo i Cagaley (1971), Chapman i Carter (1993), Dempsey (1978), Hackkansson i Wootz (1975) i Wagner et. al. (1989) identificirali su 3 najbitnija kriterija: kvalitetu, trošak i performansu dostave proizvoda. Koncept svih tih članaka koji se bave ovim problemom jest da voditelji ne trebaju odlučivati o dobavljaču samo na temelju niske cijene, nego trebaju uzeti i druge atribute. (Petroni & Bagrila, 2000). Ovakva razmatranja većinom su neovisna o proizvodu i usluzi. Kriteriji za dobavljače su razvijeni da se izmjere bitni aspekti poslovanja dobavljača – financijska snaga, pristup managementa, tehnička sposobnost, resursi podrške i sistemi za provjeru kvalitete. (Kahraman; Cebeci & Ulukan, 2003). Bayazit i Karpak pišu da faktori troška uključuju kapitalne investicije, trošak po jedinici, trošak sustava naplaćivanja, trošak održavanja mreže sustava managementa, operativni trošak i trošak održavanja. S druge strane, tehnički faktori sastoje se od tehničkih karakteristika – kapacitet, performansi, pouzdanost i dostupnost sustava, ujednačenost s internacionalnim standardima te budući razvoj tehnologije. Slično tome, operativni faktori uključuju jednostavnost izvedbe, mogućnost nadzora performansi, mogućnost detekcije grešaka, mogućnost obavijesti o statističkim podacima, detaljne računovodstvene informacije, karakteristike sigurnosti sustava i izrada prilagođenih izvještaja.

Mišljenja su podijeljena – to je rezultat različitih potražnji od kupaca koji koriste ovakve metode za odabir dobavljača. Tako će kriteriji koji su navedeni u literaturi morati biti prilagođeni – onaj koji odlučuje o dobavljaču morat će ih pažljivo analizirati i odlučiti koji su kriteriji potrebni, a koje još treba dodati.

2.1.2 Formuliranje hijerarhije u AHP metodi

Ova faza uključuje izgradnju AHP hijerarhijskog modela i izračun težina kriterija na svakoj razini modela odabira dobavljača. Razvijeni AHP model temeljen je na identificiranim kriterijima, podkriterijima i sekundarnim podkriterijima i sadrži nekoliko razina: cilj, kriterij, podkriterij, sekundarni podkriterij i alternative. AHP hijerarhijski model može se, na primjer, dalje razložiti na tercijarnu razinu podkriterija. Npr. slika 2.1 pokazuje ilustrativnu hijerarhiju s 5 razina za problem odabira dobavljača. Cilj rješavanja, problem izbora dobavljača, identificiran je na prvoj razini. Druga razina, „kriteriji" sadrži općenite kriterije za izbor dobavljača, kao što je navedeno u 2.1.1. Treći i četvrti nivo hijerarhije sadrži nekoliko podkriterija i sekundarnih podkriterija koji objašnjavaju predhodne kriterije. Najniži nivo hijerarhije sastoji se od alternativa, a radi se o tome da različiti dobavljači trebaju biti evaluirani da bi se došlo do najboljeg dobavljača. Broj alternativa jednak je broju dobavljača koji tvrtka želi evaluirati. AHP model koji se može vidjeti na slici 2.1 općenito se može primijeniti na bilo koji problem odabira dobavljača.



Slika 2.1 Općenita struktura hijerarhije u AHP modelu

(Bayazit & Karpak, 2005)

Nadalje, kako bi se nastavio model od ove faze, potrebno je odrediti prioritetne težine svakog kriterija u svakom nivou. O tome će biti više u sljedećem poglavlju.

2.1.3 Određivanje relativnih težina elemenata u AHP metodi

Model se nastavlja intervjuem koji sadrži usporedbu u parovima svih kriterija u svakom nivou hijerarhije. Ovaj se pristup pokazao vrlo korisnim kada se radi o prikupljanju podataka o procjenama specijalista.

Kako bi se izračunala težina za različite kriterije, AHP stvara matricu usporedbi u parovima ***A*.** Matrica ***A*** je *mxm*, gdje je *m* broj evaluacijskih kriterija koji se razmatraju. Svaki element a_{jk} matrice ***A*** predstavlja važnost j-tog kriterija u odnosu na k-ti kriterij. Ako je a_{jk} veće od 1, onda je *j*-ti kriteriji bitniji od *k*-tog kriterija, a ako je a_{jk} manji od jedan, onda je *j*-ti kriteriji manje važan od *k*-tog. Ako oba kriterijia imaju istu važnost, onda je element a_{jk} jednak jedan. Elementi a_{jk} i a_{kj} zadovoljavaju sljedeće ograničenje:

$$a_{jk} \cdot a_{kj} = 1 \qquad (2.1.3.1)$$

Relativna važnost između dva kriterija mjeri se u odnosu na numeričku skalu od 1 do 9, kao što je prikazano u tablici 2.1. U tablici se pretpostavlja da je *j*-ti kriteriji jednako bitan ili bitniji od *k*-tog kriterija.

Intenzitet vanosti (vrijednost a_{jk})	Definicija	Objašnjenje	Interpretacija
1	Jednaka važnost	Dva atributa jednako doprinose cilju	*j-ti* i *k-ti* kriterij su jednako bitni
2	Slaba ili blaga važnost		
3	Umjerena važnost	Eksperimenti i prosudba blago favoriziraju jedan atribut ispred drugog,	*j-ti* kriterij je malo bitniji od *k-tog*
4	Umjereno plus		
5	Jaka važnost	Ekspermenti i prosudba jako favoriziraju jednan atribut ispred drugog.	*j-ti* kriterij je važniji od *k-tog*
6	Jaka plus		
7	Vrlo jaka važnost	Jedan atribut se favorizira puno više od drugog, njegova dominacija demonstrirana je u praksi.	*j-ti* kriterij je bitno važniji od *k-tog*
8	Vrlo, vrlo važna		
9	Ekstremna važnost	Dokazi favoriziraju jedan atribut najviše moguće.	*j-ti* je apsolutno bitniji od *k-tog*
Recipročne vrijednosti brojki navedenih iznad.	Ako atribut j ima jednu od pripisanih vrijednosti kada se uspoređuje s atributom k, onda k ima recipročnu vrijednost kada se usporedi s j.	Razumna pretpostavka	

Tablica 2.1 Saatyeva skala važnosti i njezin opis te interpretacija

(Wild & Saaty, 2009)

Prema tome matrica uspredbe u parovima je:

$$\boldsymbol{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1k} \\ a_{21} & a_{22} & & a_{2k} \\ \vdots & & \ddots & \vdots \\ a_{j1} & a_{j2} & \cdots & a_{jk} \end{bmatrix} \qquad (2.1.3.2)$$

U sljedećem se koristi aproksimativni postupak određivanja težina kriterija koji se temelji na metodi svojstvenog vektora (detaljnije o metodi svojstvenog vektora pogledati Babic, 2011). Kada se matrica ***A*** izgradi, moguće je izvesti normaliziranu usporedbu u parovima matrice A_{norm}, na način da se svaki element matrice A podijeli stupcom gdje se nalazi, tako da se svaki unos a_{jk} iz matrice A_{norm} računa kao:

$$\bar{a}_{jk} = \frac{a_{jk}}{\sum_{l=1}^{m} a_{lk}} \qquad (2.1.3.3)$$

Na kraju, vektor težine kriterija ***w*** (koji je m-dimenzionalni vektor stupac) izgrađuje se tako da se izvuče prosjek A_{norm}. u svakom redu za npr.:

$$w_j = \frac{\sum_{l=1}^{m} \bar{a}_{jl}}{m} \qquad (2.1.3.4)$$

Vrijednosti u matrici ***A*** po definiciji su konzistentne u parovima, vidjeti (2.1.3.2). Kada se izvrše mnoge usporedbe u parovima, mogu nastati neke nekonzistentnosti. Npr. pretpostavimo da se uzimaju u ozbir tri kriterija, a onaj koji donosi odluke odredi da je prvi kriteriji *malo* bitniji od trećeg kriterija, te drugi kriteriji *malo* bitniji od trećeg kriterija. Nekozistentnosti pojavljuje se ako onaj koji donosi odluku krivo evaluira da je treći kriteriji jednako bitan ili bitniji. S druge strane, manja nekonzistentnost nastaje ako onaj koji donosi odluku evaluira da je prvi kriterij također malo bitniji od trećeg. Konzistentna evaluacija podrazumijevala da je prvi kriterij bitniji od trećeg kriterija.

AHP uključuje efikasnu tehniku za provjeru konzistentnosti evaluacija koje pravi onaj koji donosi odluku. Tehnika se bazira na kalkulaciji odgovarajućeg indeksa konzistentnosti. Saaty (1980) je dokazao da je svojstvna vrijednost konzistentne recipročne matrice jednaka redu matrice:

$$\lambda_{max} = n \qquad (2.1.3.5)$$

U idućem koraku je koristio sljedeću formulu za izračun stupnja konzistentnosti (CI):

$$CI = \frac{\lambda_{max} - n}{n-1} \qquad (2.1.3.6)$$

Savršeno konzistentan donositelj odluke uvijek treba dobiti *CI=0*, ali male vrijednosti nekonzistentnosti mogu se tolerirati. Naime, ako je:

$$\frac{CI}{RI} \leq 0{,}1 \qquad (2.1.3.7)$$

nekonzistentnosti se toleriraju. Vrijednosti RI (random index – slučajni indeks) za male probleme ($n \leq 10$) prikazane su u sljedećoj tablici:

n	2	3	4	5	6	7	8	9	10
RI	0	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,51

Tablica 2.2 Vrijednosti slučajnog indexa (RI).

(Wild & Saaty, 1980)

Konačno, izračunava se težina za različite nivoe kriterija unutar AHP modela. Ovo će omogućiti računanje konačnih rangiranja, o čemu će više biti riječi u sljedećem poglavlju.

2.2 Višekriterijalno odlučivanje - PROMETHEE metoda

Nakon što se saznaju težine kriterija, cilj ovog poglavlja bit će određivanje konačnog rangiranja alternativa.

U klasičnom AHP modelu provodi se usporedba u parovima pomoću Saatyeve skale. Međutim, u studiji slučaja su skupljeni podaci (atributi) detaljni i broj dobavljača (alternativa) visok. Stoga će se koristiti PROMETHEE metoda za konačno rangiranje alternativa.

Pomoću PROMETHEE metode donositelj odluke rješava probleme višekriterijanog odlučivanja te vrši usporedbu i rangiranje različitih alternativa na temelju više kvalitativnih i kvantitativnih atributa. PROMETHEE metodu razvili su belgijski autori Brans, Vincke i Mareschal 1984. Višekriterijalni problem u ovoj metodi glasi:

$$Max\,\{f_1(a), f_2(a), \dots, f_n(a) \mid a \in A\} \qquad (2.1.4.1)$$

gdje je A konačni skup alternativa, te f_j su n kriterija koji se moraju maksimizirati. Za svaku alternativu A_i postoji kriterij $f_j(A_i)$ koji je kombinacija j-tog kriterija za i-tu alternativu. Na taj način se formira matrica odluke:

Alternative	Kriteriji			
	f_1	f_2	...	f_n
A_1	$f_1(A_1)$	$f_2(A_1)$	...	$f_j(A_1)$
A_2	$f_1(A_2)$	$f_2(A_2)$	...	$f_j(A_2)$
...	...	...	...	...
A_i	$f_1(A_i)$	$f_2(A_i)$	...	$f_j(A_i)$

Tablica 2.3 PROMETHEE – matrica odluke.

Za usporedbu dvije alternative a i b ($A_k\ i\ A_b$) uvodi se funkcija preferencije P:

$$P: A\ X\ A\ \rightarrow\ [0\ ,1] \tag{2.1.4.2}$$

Funkcija preferencije predstavlja intenzitet preferencija između alternativa na sljedeći način:

P (a, b) = 0 indiferencija između a i b,

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

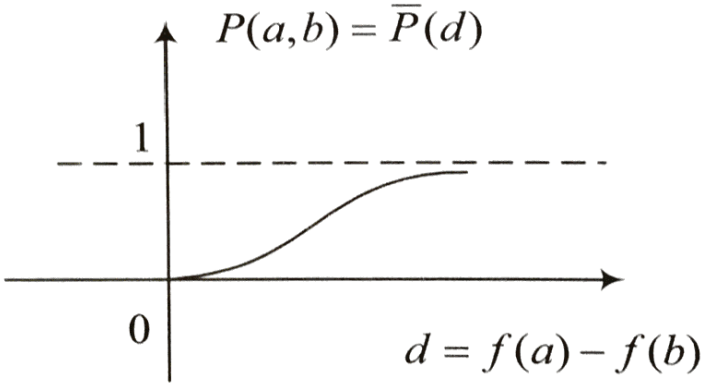
P (a, b) ≈ 1 jača preferencija od a nad b,

P (a, b) = 1 striktna preferencija od a nad b.

U praksi je funkcija preferencije razlika vrijednosti između dviju alternativa po nekom atributu:

$$d = f(a) - f(b) \tag{2.1.4.3}$$

Stoga je $P(a,b) = \bar{P}(d)$ što vodi do sljedećeg oblika grafa funkcije:



Slika 2.2 Funkcija preferencije

Što je razlika u ocjenama dviju alternativa veća (d veći) to je P(a,b) bliži jedinici. Ako je $d \leq 0$ ne postoji preferencija od a nad b pa je $P(a,b) = 0$.

Nadalje se promatra funkcija H(d) koja je direktno vezana s funkcijom preferencije P:

$$H(d) = \begin{cases} P(a,b), d \geq 0 \\ P(b,a), d \leq 0 \end{cases} \quad (2.1.4.4)$$

Tako se dobije generalizirani kriterij pomoću kriterija f_j i odgovarajuće funkcije preferencije. Autori su identificirali šest različitih tipova generaliziranog kriterija. Da bi analitičar i donositelj odluke dogovorno birali jednu od šest funkcija, trebaju u svakom pojedinačnom slučaju odrediti neke od sljedećih parametara:

q prag indiferencije,

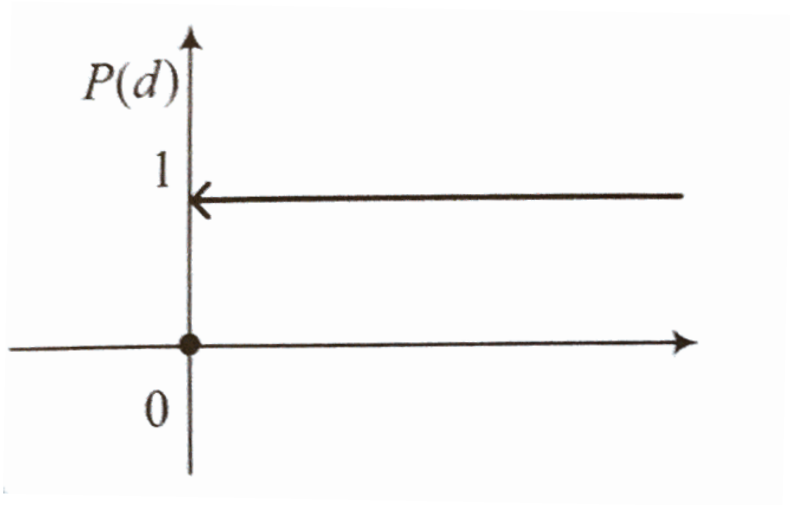
p prag preferencije,

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

Prvi od tih šest tipova generaliziranog kriterija je obični kriterij s funkcijom:

$$P(d) = \begin{cases} 0, d \leq 0 \\ 1, d > 1 \end{cases} \quad (2.1.4.5)$$

U ovom slučaju postoji indiferencija isključivo ako je $d = 0$, te ako je $f(a) = f(b)$. U konačnici to znači da donositelj odluke strogo preferira jednu alternativu nad drugom čim su procjene između alternativa različite. Sljedeća slika 2.3 prikazuje navedenu funkciju preferencije:

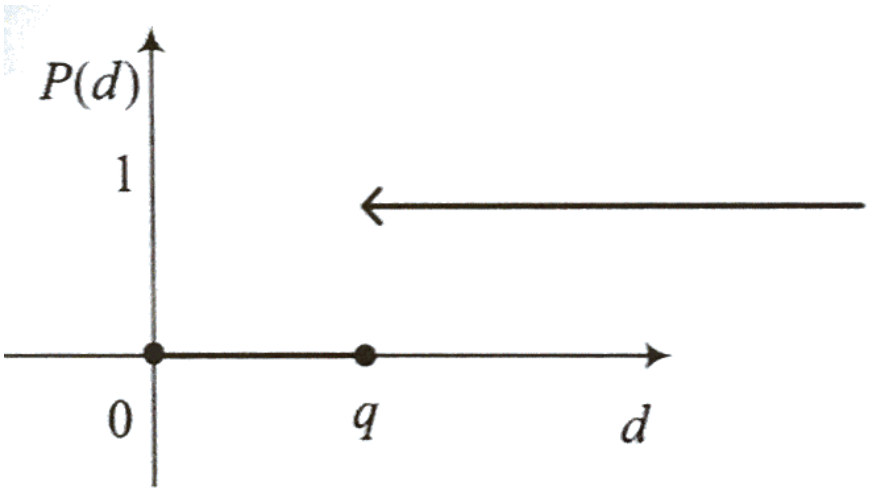


Slika 2.3 Obični kriterij

Drugi je tip generaliziranog kriterija kvazi kriterij s funkcijom:

$$P(d) = \begin{cases} 0, d \leq q \\ 1, d > q \end{cases} \quad (2.1.4.6)$$

Kod ovog kriterija alternative su toliko dugo indiferentne dok njihova ocijenjena razlika premašuje prag indiferencije q. Donositelj odluke mora odrediti vrijednost parametra q. Sljedeća slika 2.4 prikazuje navedenu funkciju preferencije:

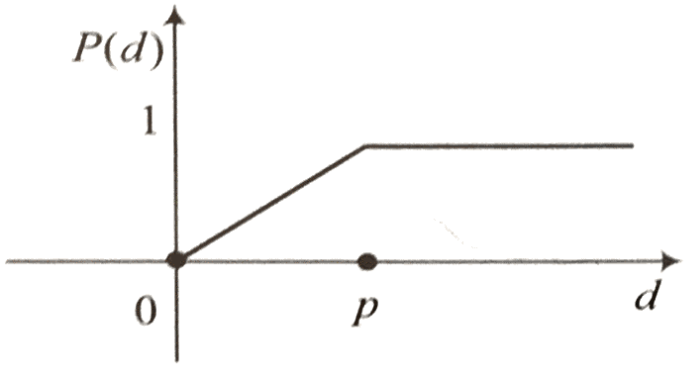


Slika 2.4 Kvazi kriterij

Treći tip generaliziranog kriterija kriterij je s linearnom preferencijom sa sljedećom funkcijom:

$$P(d) = \begin{cases} 0, d \leq q \\ \frac{d}{p}, d < p \\ 1, d \geq p \end{cases} \quad (2.1.4.7)$$

Ova funkcija objašnjava kako preferencija donositelja odluke raste linearno dok je *d* manji od parametra *p.* Čim razlika *d* postaje veća od *p* postoji stroga preferencija.

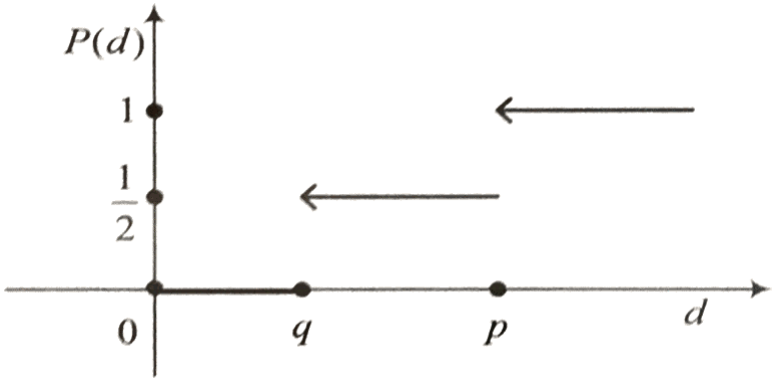


Slika 2.5 Kriterij s linearnom preferencijom

Četvrti je tip generaliziranog kriterija nivo kriterij s funkcijom:

$$P(d) = \begin{cases} 0, d \leq q \\ \frac{1}{2}, q < d \leq p \\ 1, d > p \end{cases} \quad (2.1.4.8)$$

Kada se razlika *d* nalazi između *q* i *p,* postoji slaba preferencija. Slika 2.6 prikazuje ovu funkciju preferencije:

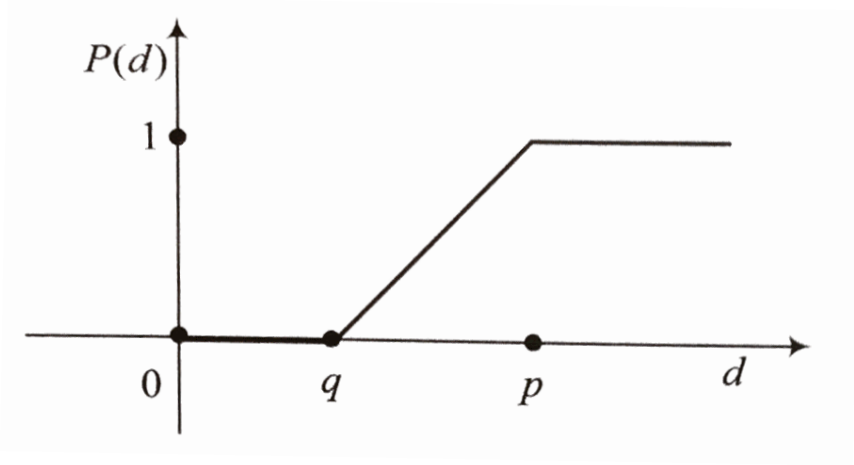


Slika 2.6 Nivo kriterij

Peti tip generaliziranog kriterija kriterij je s linearnom preferencijom i područjem indiferencije s funkcijom:

$$P(d) = \begin{cases} 0, d \leq q \\ \frac{d-q}{p-q}, q < d \leq p \\ 1, d > p \end{cases} \quad (2.1.4.9)$$

Preferencija donositelja odluke raste linearno između pragova p i q. Funkcija ima sljedeći oblik:

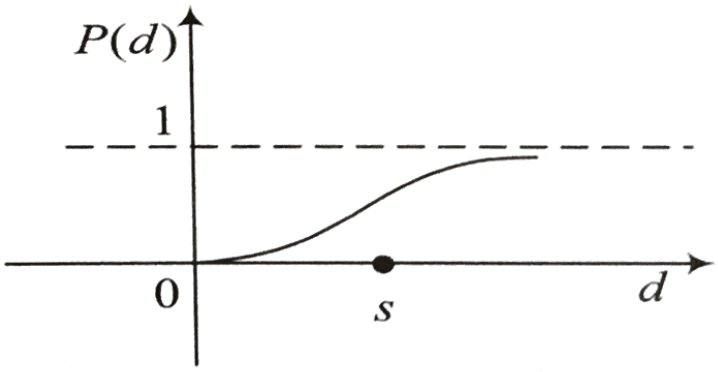


Slika 2.7 Kriterij s linearnom preferencijom i područjem indiferencije

Šesti i zadnji tip generaliziranog kriterija Gaussov je kriterij s funkcijom:

$$P(d) = \begin{cases} 0, d \leq q \\ 1 - e^{-d^2/2s^2}, d > 0 \end{cases} \quad (2.1.4.10)$$

Ovaj tip generaliziranog kriterija zahtijeva definiranje parametra s koji predstavlja standardnu derivaciju normalne razdiobe. Parametar s predstavlja prijevoj na sljedećem grafu:

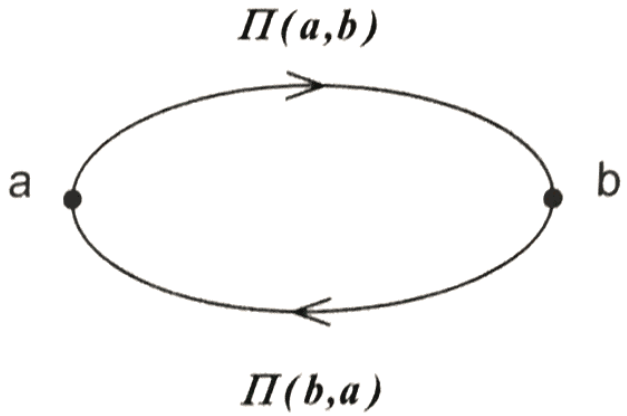


Slika 2.8 Gaussov kriterij

Nakon odabira jedne od nadležnih funkcija za svaki kriterij, u PROMETHEE metodi određuje se indeks preferencije Π kao ponderirana sredina funkcija preferencije P_j. Obzirom da je suma dobivenih težina iz AHP modela jednaka 1, koristi se sljedeća formula:

$$\Pi\,(a,b) = \sum_{j=1}^{n} w_j P_j(a,b) \qquad (2.1.4.11)$$

Ovo izražava intenzitet preferencije donositelja odluke za alternativu a nad alternativom b tijekom simultanog razmatranje svih kriterija. Kako je $\Pi(a,b) \in [0,1]$ indeks preferencije $\Pi(b,a)$ izražava kako i s kojim intenzitetom b dominira nad a. Iz toga slijedi da između svake dvije alternative a i b postoje dva luka s vrijednostima $\Pi(a,b)$ i $\Pi(b,a)$ prikazano na sljedećoj slici:



Slika 2.9 Lukovi $\Pi(a,b)$ i $\Pi(b,a)$

Svakoj alternativi definiraju se dva „outranking“ toka:

$\Phi^+(a)$ izlazni tok i

$\Phi^-(a)$ ulazni tok.

Izlazni ili pozitivan tok izračuna se na sljedeći način:

$$\Phi^+(a) = \frac{1}{m-1}\sum_{b\in A}\Pi(a,b) \qquad (2.1.4.12)$$

$\Phi^+(a)$ predstavlja sumu vrijednosti svih lukova koji izlaze iz alternative a. Dakle, pokazuje snagu alternative a te koliko je bolja od svih ostalih alternativa.

Nasuprot izlaznom ili pozitivnom toku mora se definirati ulazini ili negativni tok $\Phi^-(a)$ na sljedeći način:

$$\Phi^-(a) = \frac{1}{m-1}\sum_{b\in A}\Pi(b,a) \qquad (2.1.4.13)$$

$\Phi^-(a)$ predstvalja sumu vrijednosti svih lukova koji ulaze u alternativu a. Drugim riječima, pokazuje slabost alternative a, te koliko je alternativa a dominirana od svih ostalih alternativa.

U 2.1.4.14 i 2.1.4.15 prikazi potpunih sustava se dobiju pomoću usporedbe ulaznih i izlaznih tokova pri čemu je S tzv. „outranking“ relacija:

$$\Phi^+(a)\begin{Bmatrix} aS^+b\ ako\ je\ \Phi^+(a) > \Phi^+(b) \\ aI^+b\ ako\ je\ \Phi^+(a) = \Phi^+(b) \end{Bmatrix} \tag{2.1.4.14}$$

$$\Phi^-(a)\begin{Bmatrix} aS^-b\ ako\ je\ \Phi^-(a) < \Phi^-(b) \\ aI^-b\ ako\ je\ \Phi^-(a) = \Phi^-(b) \end{Bmatrix} \tag{2.1.4.15}$$

Sljedeća tablica prikazuje parcijalan uređaj (P, I, R) dobiven presjekom predhodna dva uređaja:

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

Tablica 2.4 PROMETHEE I – parcijalni uređaj

Da bi donositelj odluke dobio potpuni uređaj skupa alternativa, izračunat će se neto tok Φ koji predstavlja razlike snage i slabosti pojedine alternative (PROMETHEE II):

$$\Phi(a) = \Phi^+(a) - \Phi^-(a) \tag{2.1.4.16}$$

Izračun vodi do potpunog poretka alternativa (PROMETHEE II). Dakle, omogućava donositelju odluke jednostavnije odlučivanje za jednu alternativu. Parcijalni uređaj daje realnije informacije jer uključuje neusporedivosti alternativa.

2.3 Linearno programiranje

*Linearno programiranje grana je matematike koja se bavi problemom optimizacije sustava unutar zadanih ograničenja. Uveo ga je Leonid Kantorovič kasnih 1930-ih godina kao metodu rješavanja problema planiranja proizvodnje. U SAD-u je linearno programiranje razvijeno tijekom Drugog Svjetskog rata prvenstveno za probleme vojne logistike, kao što je optimiziranje prijevoza vojske i opreme konvojima. Važan je i doprinos ekonomista Tjallinga Koopmansa. Kantorovič i Koopmans 1975. god. podijelili su Nobelovu nagradu za ekonomiju za njihov pionirski rad u linearnom programiranju.

Linearno programiranje može se primijeniti na razna područja. Uglavnom se koristi u poslovanju i ekonomiji, a pojavljuje se i tijekom rješavanja određenih inženjerskih problema. Industrije koje koriste linearno programiranje bave se transportom, telekomunikacijama, energijom ili manufakturskom proizvodnjom.

2.3.1 Standardni problem

Standardni problem maksimuma i standardni problem minimuma dvije su vrste problema linearnog programiranja u kojem su sva ograničenja izražena sustavom nejednadžbi.

Oblik standardnog problema maksimuma se sastoji od *n* varijabli i *m* ograničenja, koja su tipa "≤", te se javlja u sljedećem obliku:

Maksimum	$Max\sum_{j=1}^{n} c_j\, x_j$	(2.2.1.1)
Ograničenja	$\sum_{j=1}^{n} a_{ij} \leq b_i$, i = 1,2,...,$m$	(2.2.1.2)
Uvjet nenegativnosti	$x_j \geq 0$, j=1,2,...,n	(2.2.1.3)

Standardni problem maksimuma u matričnom obliku:

Maksimum	C^TX	(2.2.1.1')
Ograničenja	$AX \leq B$	(2.2.1.2')
Uvjet nenegativnosti	$X \geq 0$	(2.2.1.3')

U 2.2.1.1', 2.2.1.2' i 2.2.1.3' navedeni izraz X predstavlja vektor varijabli (n,1), C vektor koeficijenata uz varijable u funkciji cilja (n,1), A matrica sustava ograničenja (m, n) i B vektor desne strane ograničenja (m,1).

Kod standardnog problema minimuma su sva ograničenja tipa "≥", osim uvjeta nenegativnosti, te ima oblik s *n* varijabli i *m* ograničenja:

Minimum	Max $\sum_{i=1}^{m} b_i y_i$	(2.2.1.4)
Ograničenja	$\sum_{i=1}^{m} b_{ij} y_i$, j=1,2,...,*m*	(2.2.1.5)
Uvjet nenegativnosti	$y_i \geq 0$, i=1,2,...,*n*	(2.2.1.6)

Standardni problem minimuma u matričnom obliku:

Minimum	$Y^T B$	(2.2.1.4')
Ograničenja	$Y^T A \geq C^T$	(2.2.1.5')
Uvjet nenegativnosti	$Y \geq 0$	(2.2.1.6')

Uspostaviti problem linearnog programiranja moguće je ako postoji barem jedan vektor X koji zadovoljava uvjete 2.2.1.2 i 2.2.1.3 ili 2.2.1.5 i 2.2.1.6, tzv. moguće rješenje je optimalan ako maksimizira odnosno minimizira linearnu funkciju 2.2.1.1 ili 2.2.1.4.

Svaki problem maksimuma ima dual problem minimuma. Dual standardnog problema minimuma je standardni problem maksimuma.

2.3.2 Kanonski problem

Razlika kanonskog oblika linearnog programiranja i standardnog problema je što sva ograničenja dolaze u obliku jednadžbi (osim uvjeta nenegativnosti).

PROBLEM MAKSIMUMA

Standardni	Kanonski	
$Max\ C^T$X	$Max\ C^T$X	(2.2.2.1)
$AX \leq B$	$AX+U=B$	(2.2.2.2)
$X \geq 0$	$X, U \geq 0$	(2.2.2.3)

Ukoliko se standardni problem pretvori u kanonski, potrebno je nejednadžbu zamijeniti s jednadžbom, te na lijevu stranu nejednadžbe dodati nenegativnu veličinu, odnosno vektor U≥0, tipa (m,1), koji se naziva vektor dodatnih ili oslabljenih varijabli. Oslabljene varijable ui neće se pojavljivati u funkciji ciljate neće utjecati na određivanje optimalnog rješenja.

PROBLEM MAKSIMUMA

Standardni	Kanonski	
$Max\ C^T\mathrm{X}$	$Max\ C^T\mathrm{X}$	(2.2.2.4)
$AX \leq B$	$AX + U = B$	(2.2.2.5)
$X \geq 0$	$X, U \geq 0$	(2.2.2.6)

Ukoliko želimo standardni problem pretvoriti u kanonski, potrebno je nejednadžbu zamijeniti jednadžbom, te na lijevu stranu nejednadžbe dodati nenegativnu veličinu, odnosno vektor U≥0, tipa (m,1), koji se naziva vektor dodatnih ili oslabljenih varijabli. Oslabljene varijable ui, neće se pojavljivati u funkciji cilja te neće utjecati na određivanje optimalnog rješenja.

PROBLEM MINIMUMA

Standardni	Kanonski	
$Min\ Y^T B$	$Min\ Y^T B$	(2.2.2.7)
$Y^T B \geq C^T$	$Y^T B - V^T = C^T$	(2.2.2.8)
$\mathrm{Y} \geq 0$	$\mathrm{V} \geq 0$	(2.2.2.9)

Transformacija standardnog problema minimuma u kanonski oblik izvodi se na sličan način. Pošto je kod ograničenja minimuma lijeva strana veća od desne, na lijevu (n, 1). Komponente vektora V ponekad se nazivaju i varijablama viška iz razloga što pokazuju koliko je lijeva strana ograničenja veća od desne.

2.3.3 Rješavanje problema izbora dobavljača pomoću linearnog programiranja

U ovom poglavlju razmotrit će se opcija maksimiziranja potpune vrijednosti nabave (TVP) kako bi riješio nekoliko ograničenja. Prije maksimiziranja potrebno je definirati problem linearnog programiranja (Jurun; Tomić-Plazibat & Babić, 2001). Varijabla s je preferencijalna vrijednost dobivena npr. iz AHP, kao što je objašnjeno u poglavlju 2.1.4.

Cilj: $Max\ TVP = \sum_{i=1}^{n} s_i * Q_i$ (2.2.3.1)

Nadalje, moraju se postaviti ograničenja. Tipično ograničenje kada se radi o dobavljačima maksimalna je kvantiteta ***q*** koju mogu prodati kupcu u određenom periodu. Sljedeća formula pokazuje općeniti primjer za takvo ograničenje kvantitete.

$$\text{Ograničenja kapaciteta: } \begin{matrix} x_1 \leq q_1 \\ x_2 \leq q_2 \\ \vdots \\ x_n \leq q_i \end{matrix} \qquad (2.2.3.2)$$

Konačno, potražnja ***d*** koju ima tvrtka mora biti definirana

$$\text{Ograničenje potražnje: } \sum_{i=1}^{n} x_i = d \qquad (2.2.3.3)$$

$$\text{Ograničenje nenegativnosti: } Q_i \geq 0 \qquad (2.2.3.4)$$

d potražnja za naručenom robom

i indeks dobavljača, $i = 1, 2, \dots, s$

Q_i varijabla odluke koja predstavlja količinu naručene robe

q_i kapacitet dobavljača

s_i indeks performanse dobavljača *i* dobiven preko AHP-a

n broj dobavljača

Maksimizirajući totalnu vrijednost kupovine kupac se osigurava da dobije optimalnu kvantitetu robe od nekoliko dobavljača poštivajući njihova ograničenja kao npr. kvaliteta, količina i/ili slično.

3. PRIMJENA NA STUDIJU SLUČAJA

3.1 Općenito o nabavljanju sirovina u automobilskoj industriji

Povećana kompetitivnost, ubrzano mijenjanje tehnologije i skraćeni vijek proizvoda samo su neke od konstanti kompetitivnog tržišta s kojima su suočene tvrtke danas. Mnoge od njih odgovaraju takvim uvjetima tako da se fokusiraju na svoje temeljne kompetencije i tako odgovaraju outsorcingom netemeljnih aktivnosti koje su prije obavljali.

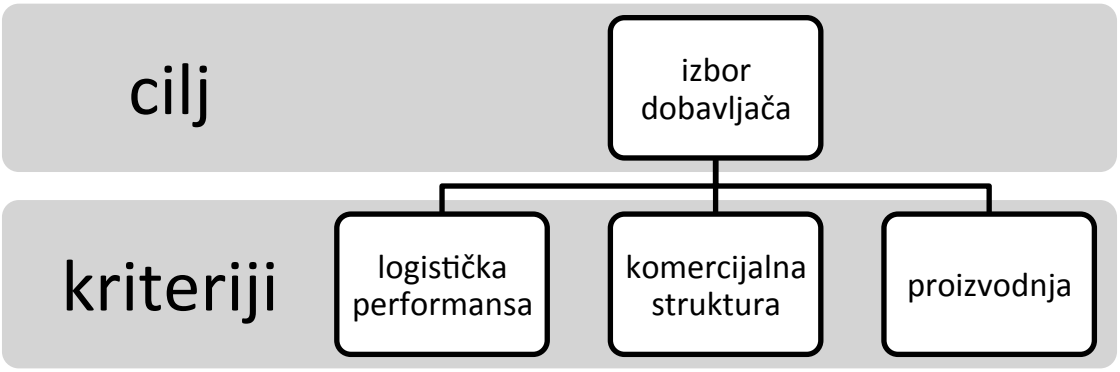
Globalna proizvodnja vozila više se nego udvostručila od 1975, s 33 na 73 milijuna u 2007. Otvaranje novih tržišta u Kini i Indiji pomoglo je uspostaviti taj rast. 1975. sedam je zemalja držalo ukupno 80% svjetske produkcije, dok je 2005 brojka porasla na 11 zemalja za isti postotak.

Vodeće su tvrtke u automobilskoj industriji proizvođači auta i oni proizvode većinu motora i transmisija, kao i većinu dijelova vozila u svojim postrojenjima. Oni zapošljavaju mnogo ljudi te su inovatori i odlični trgovci. Analiza lanaca vrijednosti u industriji tipično počinje podjelom industrija na dva šira pojma tvrtki: vodeće tvrtke i dobavljači. Vodeće tvrtke imaju znatnu kupovnu moć u cjelokupnom lancu i tako u automobilskoj industriji lancima vrijednosti upravlja proizvođač automobila (Gereffi, 2005). Međutim, od ranih 1990.-tih outsorcing vodi stvaranju velikih globalnih dobavljača koji preuzimaju znatniju ulogu u području dizajna, proizvodnje i stranih ulaganja u industriji. Najveći dobavljači, locirani u razvijenim zemljama, postali su globalni dobavljači s multinacionalnim operacijama te su u mogućnosti da priskrbe dobra i usluge širokom rasponu vodećih tvrtki (Sturgeon and Lester, 2004). Najvećih 20 do 30 dobavljača preuzelo je balans moći od vodećih autoproizvođača, iako na djelomičan i nepotpun način. (Sturgeon et. al., 2008). Kako se raznolikost i nesigurnost u okolini povećava, kompanije odgovaraju dodavanjem novih metoda u njihove operacijske strategije.

Ovaj će rad pokazati kako prilagoditi AHP model pomoću PROMETHEE metode pri odabiru najboljeg dobavljača, a pomoću linearnog programiranja će se odrediti najbolja količinska kombinacija kod više dobavljača pod ograničenjima od strane proizvođača ili dobavljača u autoindustriji.

3.2 Kriteriji za izbor dobavljača

Općeniti cilj ovog rada odabir je najboljeg dobavljača za proizvođača automobila, dakle, najbitniji kriteriji su odabrani i poslagani u hijerarhiju na pet razina. Ovaj je cilj postavljen na vrh hijerarhije. Ona kreće od više općenitih kriterija na drugoj razini, do podkriterija i sekundarnih podkriterija na trećoj i četvrtoj razini te završava alternativama na donjoj razini. Druga razina hijerarhija uključuje tri najbitnija kriterija: logistička performansa, komercijalna struktura i proizvodnja.



Slika 3.1 Kriteriji u AHP modelu.

Ovi kriteriji još su previše općeniti da bi se napravila čvrsta odluka kada se radi o izboru dobavljača, dakle, potrebno je razdijeliti ih na još podkriterija i sekundarnih podkriterija. Podkriteriji i sekundarni podkriteriji odabrani su tijekom intervjuiranja voditelja nabave.

Subkriteriji i sekundarni podkriteriji bit će pojašnjeni tijekom sljedeća tri poglavlja, 3.2.1, 3.2.2 i 3.2.3.

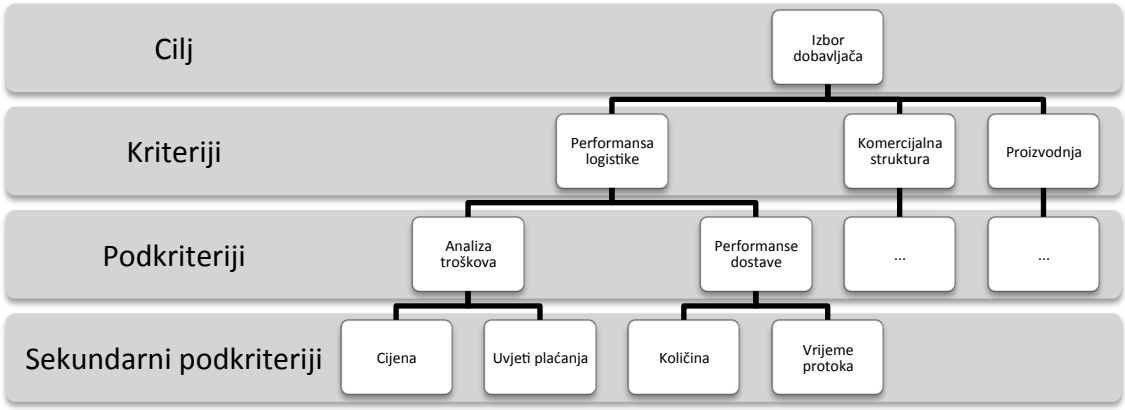
3.2.1 Kriteriji o performansi logistike

Kod kriterija performansa logistike u cilju je bilo skupiti sve cjenovne i dostavne podkriterije te sekundarne podkriterije povezane uz proizvod koji se nabavlja. Performanse dostave i analize troška locirane su po kriteriju logističke performanse u trećoj razini hijerarhije. Ove sekundarne podkriterija potrebno je dodatno razložiti na specifične sekundarne podkriterije na

četvrtoj razini. Performansa dostave razložila se na kvantitetu dostave i vrijeme protoka dok se analiza troška razložila na cijenu i uvjete plaćanja.

Cijena, prvi sekundarni podkriteriji kategoriziran pod podkriterij analize troška indicira cijenu po jednom spremniku HDPE goriva. Drugi sekundarni podkriterij, uvjeti plaćanja, objašnjava kada proizvođač auta mora platiti narudžbu. Dobavljači nude plaćanje dobara u rasponu od 15 do 60 dana nakon dostave. Cilj proizvođača auta je platiti što kasnije i što manje moguće. Zaključno, dobavljač s kasnijim rokom plaćanja preferirat će se pod stavkom sekundarnog podkriterija „uvjeti plaćanja“. Kako bi bio preferirani odabir u sekundarnom subkriteriju „cijena“, potrebno je da ponudi što manju cijenu.

Nadalje, kvantiteta i vrijeme protoka kategorizirani su pod podkriteriji performansa dostave. Kvantiteta oznavača maksimalan mogući broj predmeta po svakom dobavljaču. U ovom slučaju proizvođač preferira dobavljača s većim kapacitetima. Vrijeme protoka objašnjava trajanje ciklusa proizvodnje u satima, i to na količinu od 10 predmeta. U ovom trenutku proizvođač preferira kraće vrijeme protoka. Na sljedećoj slici vidi se hijerarhija pod kriterijem „performansa logistike“:



Slika 3.2 Podkriteriji i sekundarni podkriteriji performanse logistike.

3.2.2 Kriteriji o komercijalnoj strukturi

Pod kriterijem "komercijana struktura" skupljeni su svi podkriteriji i sekundarni podkriteriji koji objašnjavaju opću, nevezanu performansu dobavljača. Podkriteriji komunikacijski sistem, struktura troškova i povijest performansi smješteni su pod kriterij komercijalne strukture na trećoj razini hijerarnije. Za razliku od podkriterija koji se nalazi pod logističkim performansama daljnje razlaganje komunikacijskih sistema i povijesti performanse nije

potrebno. Postojala je potreba daljnjeg razlaganja strukture troška. Ovdje su financijska mogućnost i udio u tržištu navedeni kao sekundarni podkriteriji. Dva subkriterija koja se nisu dalje razlagala su komunikacijski sistem i povijest performanse, a oni su ocijenjeni od strane proizvođača na ljestvici perfomansa koja ima 5 razina. Ljestvica je prikazana u tablici 3.1.

Razina performanse (1-5)	Ocjena	Opis
5	Izuzetno (E)	Performansa daleko premašuje očekivanja zbog visoke kvalitete obavljanja posla.
4	Premašuje očekivanja (EE)	Performansa premašuje očekivanja u svim bitnim područjima .
3	Odgovara očekivanjima (ME)	Performansa odgovara očekivanjima u svim bitnim područjima.
2	Potrebno poboljšanje (I)	Performansa nije konzistentno susrela očekivanja, i to u jednom ili više bitnih područja.
1	Ne zadovoljava (U)	Performansa je bila ispod očekivanja u većini bitnih područja.

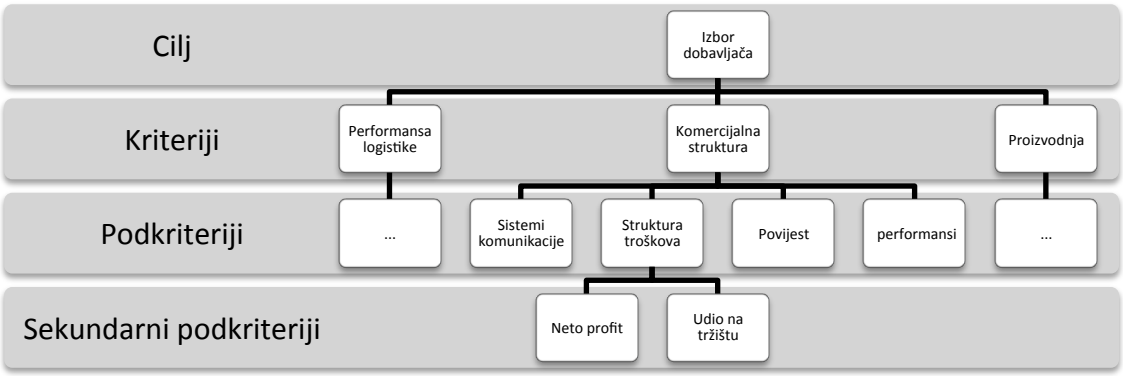
Tablica 3.1 Ljestvica performanse sa pet razina.

Dobavljač s višom razinom bit će preferiran na temelju tablice od 5 razina. Kako bi se dobila visoka ocjena performanse u podkriteriju komunikacijski sistem, proizvođač zahtjeva pristupačne i direktne pregovarače za proces nabave te specijalizirano osoblje za daljnju kolaboraciju kada se radi o materijalu, robi ili poluzavršenim proizvodima. Da bi se dobila oznaka E ili EE, proizvođač zahtjeva potpunu integraciju u njihov softver za lanac dobavljača.

Kako bi se dobila visoka ocjena performanse u podkriteriju povijest performansi, proizvođač zahtjeva poslovne reference ili prošla iskustva dobavljača tijekom sličnih narudžbi.

Na kraju, struktura troška se razlaže na financijsku sposobnost i udio na tržištu. Sekundarni podkriterij, udio na tržištu, indicira udio dobavljača u specifičnom segmentu. Proizvođač

preferira dobavljača s višim udjelom u tržištu. Iako monopolistički dobavljači nisu u interesu proizvođača, visoki udio dobavljača na tržištu indicira da je to pouzdan i jak partner. Kako bi se identificirale financijske mogućnosti, proizvođač može koristiti širok raspon financijskih indikatora za performans (KPI), kao što su, neto dobit i bruto dobit. Kako bi se zadržalo u okviru rada, prikazat će se financijske mogućnost kroz neto profit dobavljača. Slično kao i kod udjela na tržištu, proizvođač preferira jakog partnera, dakle, dobavljača s jačim financijskim mogućnostima (ili u ovom slučaju s višim neto profitom). Sljedeća tablica pokazuje hijerarhiju pod kriterijem komercijalne strukture.



Slika 3.3 Podkriteriji i sekundarni podkriteriji komercijalne strukture.

3.2.3 Kriteriji o proizvodnji

Treća kategorija koja se smatra bitnom za izbor dobavljača sama je proizvodnja. Kategorija „proizvodnja“ obuhvaća sve podkriterije i sekundarne podkriterije vezane za proizvodni proces, kvalitetu i specifikaciju proizvoda. Potrebno je bilo daljnje razlaganje kriterija na: sposobnost procesa, politika skladištenja, oprema, menadžment kvalitete i materijalne specifikacije. Posljednje navedene materijalne specifikacije moraju se razložiti na tri sekundarna podkriterija: varijacije u veličini, točka tališta i gustoća. Da bi dobavljač dobio odgovarajuću ocjenu, proizvođač koristi različite skale, numeričke vrijednosti.

Za identifikaciju performansa potencijalnog najboljeg dobavljača slijedi podkriterij: politika skladištenja i oprema su skalirani na isti način kao i prethodno spomenuti podkriterij komunikacijskog sustava i povijesti performanse. Tablica 3.1 pokazuje moguće ocjene.

Kada se pogledaju detalji, proizvođač zahtjeva visoku ocjenu u podkriteriju politika skladištenja, dakle, valjano skladištenje za naručenu robu. Za primjer se može uzeti vlažnost ili temperatura unutar skladišta. Kako bi se dobila još veća ocjena, proizvođač traži odvojeno skladištenje svoje robe.

Nadalje, ocjenjivat će se i oprema dobavljača. Proizvođač zahtijeva pouzdane i moderne metode, dakle, starost i kvaliteta uređaja za proizvodnju ocjenjuje se po skali na tablici 3.1.

Kako bi se usporedili dobavljači u odnosu na podkriterij Kapacitet procesa, proizvođač koristi skalu od četiri koraka koja je prikazana u nastavku:

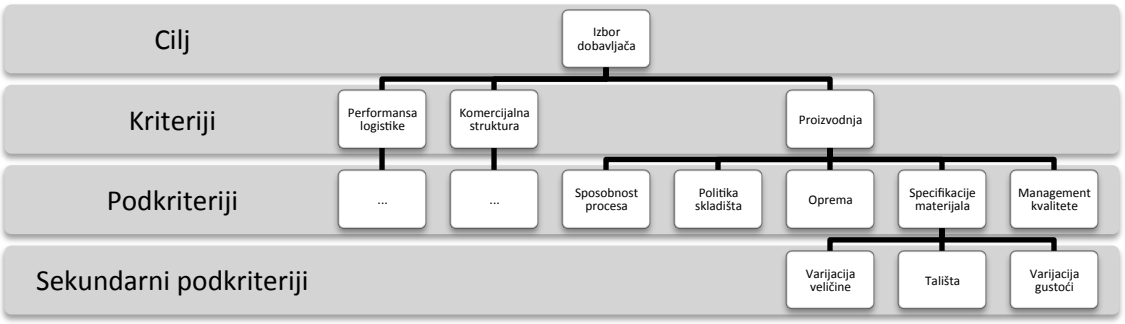
Level performanse	Rating	Description
4	Visok rast	Linija proizvodnje ima visoki prioritet (temeljna djelatnost dobavljača), visoke investicije su vjerojatne.
3	Slab rast	Kapacitet proizvodnje povećat će se kroz daljnje investicije.
2	Konstanto	Konstantni kapacitet proizvodnje, nepostojeća ili niska ulaganja su moguća.
1	Pad	Kapacitet proizvodnje će se smanjiti, ne postoje daljnje investicije u liniju proizvodnje, završetak proizvodnje moguć.

Tablica 3.2 Ljestvica za procjenu kapaciteta procesa.

Posljedično, proizvođač preferira dobavljača s visokim ocjenama kako bi njegove potrebe bile zadovoljene.

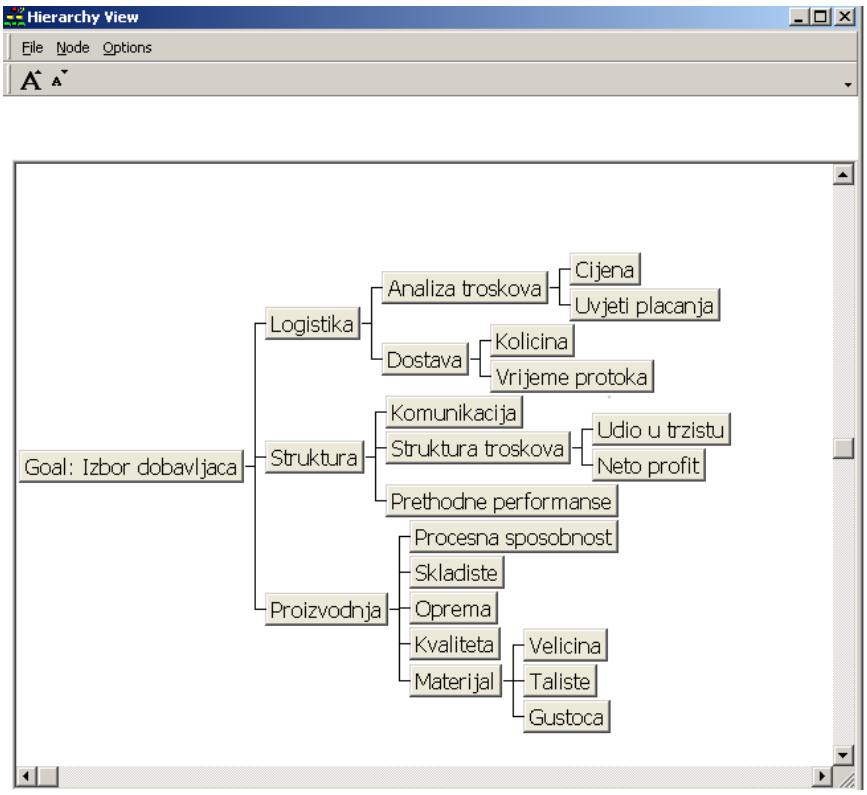
Nadalje, sustav kvalitete proizvođača zahtijeva ISO/TS16949. **ISO/TS16949** je ISO tehnička specifikacija kojoj je cilj razvoj sustava kvalitete koji omogućuje kontinuirano usavršavanje, a naglašava prevenciju pogrešaka i smanjenje varijacije i otpada u opskrbnom lancu automoobilske industrije (ISO/TS16949:2009).

Na kraju, proizvođač zahtijeva posebne materijalne specifikacije. Podkriteriji zahtijevaju razlaganje na tri sekundarna podkriterija zbog kompkeksnosti upravo navedenih materijalnih specifikacija. Radi se o podkriterijima varijacija veličine, tališta i varijacija u gustoći. Najbitniji faktor za odabir je minalno odstupanje od optimuma.



Slika 3.4 Podkriteriji i sekundarni podkriteriji komercijalne strukture

Svrha ovoga poglavlja identificiranje je svih potrebnih kriterija, subkriterija i sekundarnih subkriterija da bi se postigao cilj proizvođača – odabir najboljeg dobavljača. Sljedeća slika (3.5) prikazuje potpunu hijerarhiju unesenu u program Expert Choice:



Slika 3.5 Potpuna hijerarhija

(Expert Choice)

3.3 Određivanje težina kriterija za izbor dobavljača pomoću usporedbe u parovima

Nakon što je formirana hijerarhija svih bitnih kriterija za proces odabira dobavljača, bitno je odrediti težinu kriterija. Potrebno je i napraviti prioritetne kriterije u svim fazama. Dake, svi kriteriji, podkriteriji i sekundarni podkriteriji bit će uspoređeni u parovima u odnosu na sljedeću višu hijerarhiju. Usporedbe u parovima koriste Saatyjevu skalu koja seže od jednako preferiranih do ekstremno preferiranih. Sljedeće preference prikupljene su tijekom intervjua s voditeljem nabave. Tablica prikaže kako je voditelj nabave usporedio svaki kriterij u paru i intenzitet preferencije pomoću cjelobrojnih vrijednosti po Saaty-evoj skali važnosti iz tablice 2.1. Ako je križič upisan na ljevoj strani tablice (pod plavim brojkama) izražena je preferencija kriteriju na ljevoj strani tablice, obrnuto (pod crvenim brojkama), voditelj nabave preferira kriterij na desnoj strani tablice i ako bi križič bio upisan u sredini važnost kriterija bi bila jednaka. Slijedi prikaz preferencija kriterija:

Kriteriji	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Performansa Logistike								X										Komercijalna struktura
Performansa Logistike													X					Proizvodnja
Proizvodnja						X												Komercijalna struktura

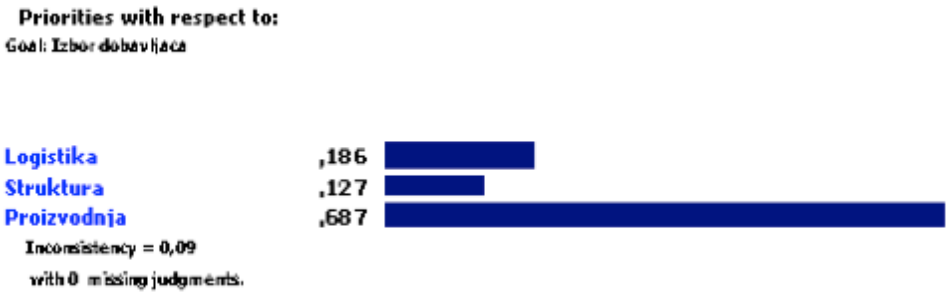
Tablica 3.3 Odgovori u anketi voditelja nabave na drugoj razini hijerarhije.

Odgovori iz ankete pretvaraju se u matrični oblik. Matrica prikazana u tablici 3.4 sadrži sve usporedbe u parovima za kriterije. Budući da postoje 3 kriterija, matrica mora imati veličinu 3x3. Vrijednosti „jednako preferiranoga“ koje su prikazane u dijagonali uspoređuju svaki kriterij s njim samim, i tako, po definiciji, moraju biti jednaki jedan. Recipročne vrijednosti zrcale se po dijagonali.

	Performansa Logistike	Komercijalna struktura	Proizvodnja
Performansa Logistike	1	2	1/5
Komercijalna struktura	1/2	1	1/4
Proizvodnja	5	4	1

Tablica 3.4 Usporedba u parovima na drugoj razini hijerarhije.

Pomoću Expert Choice-a se izračunavaju lokalne težine. U ovom slučaju, kriterij „proizvodnja“ je najbitniji (slika 3.6). Suma svih težina mora biti 1.



Slika 3.6 Težine kriterija

(Expert Choice)

Na kraju je potrebno provjeriti jesu li ocjene preferenci voditelja nabave konzistentne. Zato služi omjer konzistentnosti (CR) prikazan kao „Inconsistency“ u rezultatu Expert Choice-a na slici 3.6. Omjer konzistentnosti *CR* govori donositelju odluke koliko je konzistentan bio tijekom uspoređivanja u parovima. Viši broj znači da je donositelj odluke bio manje konzistentan, dok niži broj govori da je bio više konzistentan. Ako je omjer konzistentnosti *CR* manji od *0.10*, onda znači da su usporedbe u paru koje je provodio donositelj odluke bile relativno konzistentne. U ovom slučaju, *CR* je jednak *0,09*, što znači da su usporedbe u paru bile relativno konzistentne i nepotrebna je korekcija. Ako je omjer konzistentnosti *CR* veći od *0.10*, donositelj odluke bi trebao razmotriti reevaluaciju usporedbe u paru – izvori nekonzistentnosti moraju se identificirati i ukloniti te ponovno napraviti analiza.

Kako razvijena hijerarhija ima tri razine kriterija mora se izračunati sve lokalne težine. Izračun je napravljen za sve podkriterije u odnosu na kriterije i sekundarne podkriterije na podkriterije. Sljedeća tablica pokazuje ocjene važnosti koje je odredio voditelj nabave podkriteriju „performansa logistike“:

Podkriteriji																		
(performansa logistike)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Anliza troškova				X														Performansa dostave

Tablica 3.5 Ocjene važnosti u anketi pod kriterijom „performansa logistike“

Odgovore iz ankete se, nadalje, pretvaraju u matrični oblik te se pomoću Expert Choice-a izračunavaju težine:

Podkriteriji performanse logistike	Performansa dostave	Analiza troškova	Vektor težina ***w***
Performansa dostave	1	1/6	0,143
Analiza troškova	6	1	0,857

Tablica 3.6 Matrica odluke i težine pod kriterijem „performanse logistike“

Težina podkriterija performansa dostave i analiza troška su *0,143* i *0,857* u odnosu na kriterij „performansa logistike“.

Sljedeća tablica pokazuje ocjene važnosti za podkriterije pod kriterijem „komercijalne strukture“:

Podkriteriji																		
(komercijalna struktura)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Sistem komunikacije						X												Predhodne performanse
Sistem komunikacije											X							Struktura troškova
Predhodne performanse														X				Struktura troškova

Tablica 3.7 Ocjene važnosti u anketi pod kriterijem „komercijalna struktura“

Odgovori iz ankete se opet pretvore u matrični oblik te se pomoću Expert Choice-a izračunavaju težine i omjer konzistencije:

Podkriteriji komercijalne strukture	Sistem komunikacije	Struktura troškova	Predhodne performanse	Vektor težina ***w***
Sistem komunikacije	1	1/3	4	0,271
Struktura troškova	3	1	6	0,644
Predhodne performanse	1/4	1/6	1	0,085
			CR= 0,05	

Tablica 3.8 Matrica odluke, težine i omjer konzistentnosti pod kriterijem „performanse logistike“

Težine podkriterija sistem komunikacije, struktura troškova i prethodne performanse su *0,271*, *0,644* i *0,085* u odnosu na podkriterij komercijalna struktura.

Sljedeća tablica pokazuje ocjene važnosti za podkriterije pod kriterijem „proizvodnja“:

Podkriteriji (proizvodnje)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Specifikacije materijala				X														Process capability
Specifikacije materijala					X													Inventory policy
Specifikacije materijala						X												Oprema
Specifikacije materijala			X															Management kvalitete
Process capability										X								Inventory policy
Process capability											X							Oprema
Process capability							X											Management kvalitete
Inventory policy									X									Oprema
Inventory policy						X												Management kvalitete
Oprema							X											Management kvalitete

Tablica 3.9 Ocjene važnosti u anketi pod kriterijem „proizvodnja“

Odgovori iz ankete su pretvoreni u matrični oblik i lokalne težine izračunate pomoću Expert Choice-a:

Podkriteriji proizvodnje	Procesna sposobnost	Politika skladišta	Oprema	Management kvalitete	Specifikacije materijala	Vektor težina ***w***
Procesna sposobnost	1	1/2	1/3	3	1/6	0,087
Politika skladišta	2	1	1	4	1/5	0,153
Oprema	3	1	1	3	1/4	0,166
Management kvalitete	1/3	1/4	1/3	1	1/7	0,048
Specifikacije materijala	6	5	4	7	1	0,546
				CR= 0,05		

Tablica 3.10 Matrica odluke i težine pod kriterijem „proizvodnja“

Ovdje su lokalne težine podkriterija procesna sposobnost jednak *0,087*, politika skladištenja *0,153*, oprema *0,166*, management kvalitete *0,048* i specifikacije materijala *0,546* u odnosu na kriterij „proizvodnja“, te omjer konzistentnosti manji od 1.

Sljedeća tablica pokazuje ocjene važnosti za sekundarne podkriterije pod podkriterijem „analiza troškova“:

Sekundarni podkriteriji																		
(Analize troškova)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Cijena			X															Uvjeti plaćanja

Tablica 3.11 Ocjene važnosti u anketi pod podkriterijem „analiza troškova“

Odgovori iz ankete pretvaraju se u matrični oblik i lokalne težine izračunate su pomoću Expert Choice-a:

Sekundarni podkriteriji analize troškova	Cijena	Uvjeti plaćanja	Vektor težina ***w***
Cijena	1	7	0,875
Uvjeti plaćanja	1/7	1	0,125

Tablica 3.12 Matrica odluke i težine pod podkriterijem „analiza troškova“

Težine sekundarnih podkriterija cijena i uvjeti plaćanja su *0,875* i *0,125* u odnosu na podkriterij analiza troškova.

Sljedeća tablica pokazuje ocjene važnosti za sekundarne podkriterije pod podkriterijem „analiza troškova“:

Sekundarni podkriteriji																		
(performansa dostave)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Količina														X				Vrijeme protoka

Tablica 3.13 Ocjene važnosti u anketi pod podkriterijem „performansa dostave“

Odgovori iz ankete pretvoreni su u matrični oblik i lokalne težine izračunate su pomoću Expert Choice-a:

Sekundarni podkriterij performansi dostave	Količina	Lead time	Vektor težina ***w***
Količina	1	1/6	0,143
Vrijeme protoka	6	1	0,857

Tablica 3.14 Matrica odluke i težine pod podkriterijem „performanse dostave“

Težine sekundarnih podkriterija količina i vrijeme protoka su *0,143* i *0,857* u odnosu na podkriterij performansa dostave.

Sljedeća tablica pokazuje ocjene važnosti za sekundarne podkriterije pod podkriterijem „analiza troškova“:

Sekundarni podkriteriji																		
(struktura troškova)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Market share										X								Net profit

Tablica 3.15 Ocjene važnosti u anketi pod podkriterijem „struktura troškova“

Odgovori iz ankete pretvoreni su u matrični oblik i lokalne težine izračunate su pomoću Expert Choice-a:

Sekundarni podkriteriji struktura troškova	Market share	Net profit	Vektor težina ***w***
Market share	1	2	0,333
Net profit	1/2	1	0,667

Tablica 3.16 Matrica odluke i težine pod sekundarnim podkriterijem „struktura troškova“

Težine sekundarnog podkriterija udio na tržištu i neto profit su *0,333* i *0,667* u odnosu na podkriterij struktura troška.

Sljedeća i zadnja tablica pokazuje ocjene važnosti za sekundarne podkriterije pod podkriterijem „specifikacije materijala“:

Sekundarni podkriteriji																	
(specifikacije materijala)	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	
Varijacija u veličini									X									Varijacija u gustoči
Varijacija u veličini									X									Talište
Varijacija u gustoči									X									Talište

Tablica 3.17 Ocjene važnosti u anketi pod podkriterijem „specifikacije materijala“

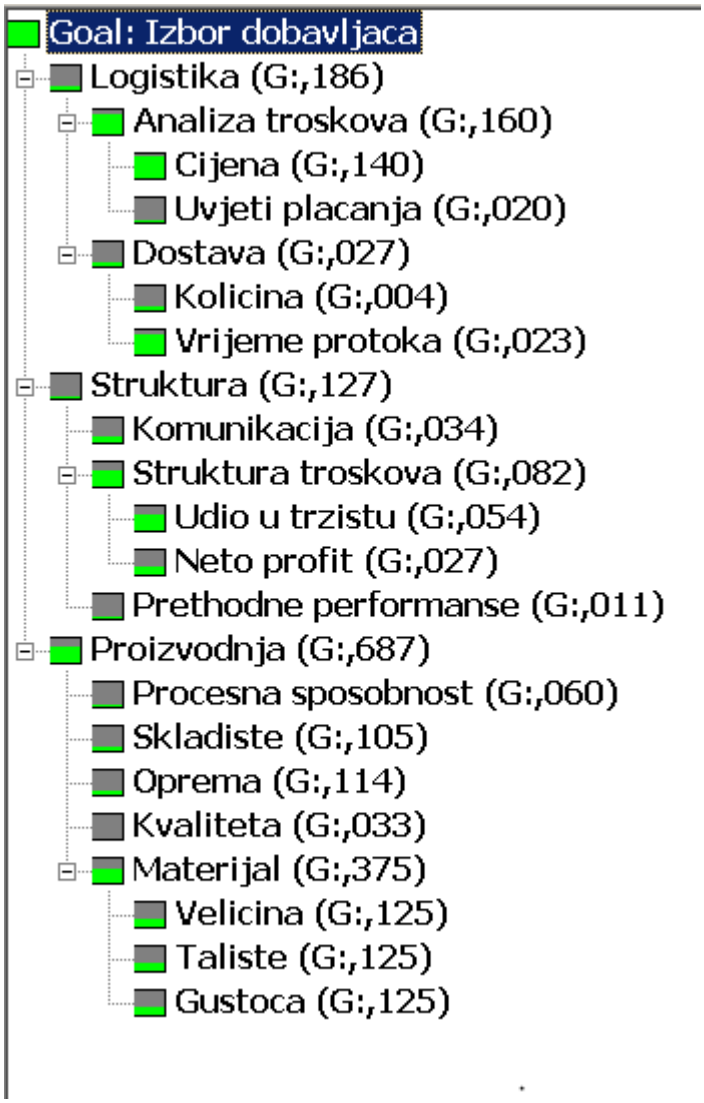
Odgovori iz ankete pretvoreni su u matrični oblik i lokalne težine izračunate su pomoću Expert Choice-a:

Sekundarni podkriteriji specifikacije materijala	Varijacija veličine	Talište	Varijacija gustoće	Vektor težina ***w***
Sistem komunikacije	1	1	1	0,3333
Struktura troškova	1	1	1	0,3333
Prethodne performanse	1	1	1	0,3333
			CR= 0	

Tablica 3.18 Matrica odluke, težine i omjer konzistentnosti pod sekundarnim podkriterijem „specifikacije materijala“

Lokalne težine sekundarnih podkriterija varijacija u veličini, talište i gustoća su *0,3333*, *0,3333* i *0,3333* u odnosu na kriterij komercijalna struktura.

U ovom trenutku sve su lokalne težine izračunate. Kako bi se dobio odgovor na pitanje koji dobavljač je najbolji za proizvođača potrebno je izračunati globalne težine koje su prikazane na sljedećoj slici:



Slika 3.7 Globalne težine

(Expert Choice)

Nakon izračuna globalnih težina svakog podkriterija i sekundarnog podkriterija na razini 3 i 4, rezultat se raspoređuje po padajućem redu prioriteta. Tablica 3.17 prikazuje da cijena, sve tri materijalne specifikacije i oprema imaju najvišu poziciju i, zaključno, najbitniji su kriteriji za izbor dobavljača.

Rang	Kategorija	Težina
1	Cijena	0,140
2	Varijacija veličine	0,125
2	Talište	0,125
2	Varijacija gustoće	0,125
5	Oprema	0,114
6	Politika skladišta	0,105
7	Procesna sposobnost	0,060
8	Udio u tržištu	0,054
9	Sistem komunikacije	0,034
10	Management kvalitete	0,033
11	Neto profit	0,027
12	Uvjeti plaćanja	0,020
13	Vrijeme protoka	0,023
14	Predhodne performanse	0,011
15	Količina	0,004

Tablica 3.19 Rangiranje kriterija po važnosti.

3.4 Primjena PROMETHEE metode za izbor dobavljača

Razlog za korištenje ove metode evaluacija je dobavljača za proizvođača auta. Evaluacija pomoću AHP metode zahtijeva usporedbu u parovima dobavljača po svakom kriteriju. U ovom slučaju postoji 15 kriterija i 10 dobavljača što bi rezultiralo vrlo opsežnim modelom s velikom vjerojatnošću grešaka. Da bi se došlo do evaluacije pomoću detaljnih podataka iz ove studije slučaja koristit će se PROMETHEE metoda i težine izračunate AHP metodom u prethodnom poglavlju.

Prije primjene PROMETHEE metode za rangiranje dobavljača HDPE spremnika, svakom se kriteriju mora dodijeliti funkcija preferencije i o njoj ovisno definirati točke indiferencije (q), preferencije (p), te parametar s koji se nalazi između praga indiferencije i preferencije. Funkcije preferencije i parametre definira voditelj nabave uzimajući u obzir karakteristike svakog kriterija.

Iduća tablica prikazuje matricu odluke proizvođača automobila, težine dobivene s AHP metodom, tip funkcije preferencije i potrebne parametre:

	Cijena (u EUR)	Uvjeti plaćanja (u danima)	Količina	Vrijeme protoka (min/10kom.)	Sistem komunikacije	Udio u tržištu (u %)	Net profit (u milj.)	Predhodne performanse	Procesna sposobnost	Politika skladišta	Oprema	Management kvalitete	Varijacija u veličini (u mm)	Talište (u °C)	Varijacija gustoće (x 100)
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
	min	max	max	min	max	max	max	max	max	max	max	max	min	max	Min
D1	114,30	30	3000	168	3	8,3	32,1	3	2	5	4	1	,1	132,25	3
D2	135,30	30	5000	240	4	12,7	123,2	2	2	2	4	1	,1	133,95	4
D3	109,10	15	2000	240	3	7,1	20,8	3	2	3	3	0	,2	140,1	2
D4	145,10	60	400	310	2	6	10,1	3	3	3	3	0	,1	139,2	3
D5	132,20	60	500	271	3	6,2	19,2	4	3	4	4	0	,7	131,95	2
D6	124,30	30	1000	403	3	7,6	42,1	3	2	2	4	1	,1	131,55	2
D7	135,40	30	300	168	4	1,1	19,2	3	3	2	3	1	,2	139,5	1
D8	145,30	30	400	242	5	1,2	9,9	5	2	5	5	1	,1	134,1	1
D9	123,10	60	2000	194	4	9,9	30,1	3	4	4	3	1	,2	129,2	2
D10	132,20	30	1000	210	4	9,1	4	2	2	4	3	0	,1	134,85	3
w_j	,14	,02	,004	,023	,034	,054	,027	,011	,06	,105	,114	,033	,125	,125	,125
Tip fun. Pref.	III	I	V	V	IV	V	V	IV	I	IV	IV	I	VI	V	VI
q			300	50	1,5	,01	10	1,5		1,5	1,5			2	
p	30		4000	200	2,5	,10	50	2,5		2,5	2,5			8	
s													,3		2

Tablica 3.20 Matrica odlučivanja

Za prvi kriterij, cijena, odabrana je linearna funkcija preferencije u kojoj svaka razlika u cijeni vodi do vrijednosti funkcije preferencije koja je veća od nule. Funkcija raste linearno sve dok razlika nije veća od 30 eura. U tom slučaju nastupa stroga preferencija, te je vrijednost funkcije preferencije jednaka 1.

Za drugi, deveti te dvanaesti kriterij odabrana je obična funkcija preferencije. Ako postoji neka razlika u uvjetima plaćanja, procesnoj sposobnosti ili managementu kvalitete među dobavljačima - vrijednost funkcije jednaka je 1.

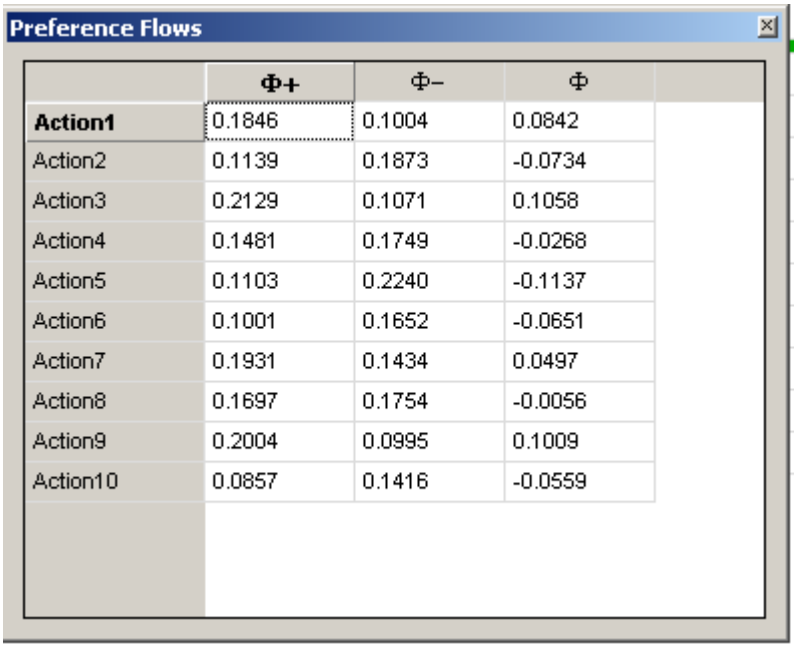
Za treći, četvrti šesti, sedmi i četrnaesti kriterij odabrana je funkcija preferencije petog tipa (linearna s područjem indiferencije). Kod trećeg kriterija definirani su parametri *q=300* i *p=4000*, što znači da upravitelj nabave smatra dobavljače s razlikom količine od ispod 300 komada indiferentnim dok razlike iznad 4000 komada vode do stroge preferencije. Dobavljači s 50 minuta razlike smatraju se indiferentnim, a kod 200 minuta razlike je vrijednost funkcije

jednaka 1. Slično je kod šestog kriterija gdje je prag indiferencije 1% razlike tržišnog udijela i prag preferencije 10% razlike. Kod sedmog kriterija, dobavljači s razlikom od 10 miljuna eura u neto profitu smatraju se indiferentnim, a kod razlike od 50 miljuna pojavi se stroga preferencija za dobavljača s većim profitom. Kod četrnaestog kriterija se 2℃ razlike smatra pragom indiferencije i 8℃ preferencije.

Peti, osmi, deveti i deseti kriterij koriste funkciju preferencije četvrtog tipa s pragom indiferencije *q=1,5* i pragom peferencije *p=2,5*. Sva četiri kriterija koriste istu skalu za ocjenjivanje (ocjene od 1 do 5) performansi dobavljača. Drugim riječima, ako je razlika ocjene između dva dobavljača od 1,5 - nema nikakve preferencije, a ako je razlika između 1,5 i 2,5 - vrijednost funkcija jednaka je ½. Ako je razlika veća od 2,5 vrijednost funkcije preferencije jednaka je 1.

Naadalje, trinaesti i petnaesti kriterij koriste funkciju preferencije šestog tipa, odnosno, što je razlika između dvije alternativa veća, vrijednost funkcije preferencije raste prema jedinici.

Nakon što su matrica odluke i odgovarajući tipovi funkcije preferencije, težište te parametri uneseni u program Decision Lab izračunale su se vrijednosti Φ_+ (pozitivni tok), Φ_- (negativni tok) i Φ (neto tok).

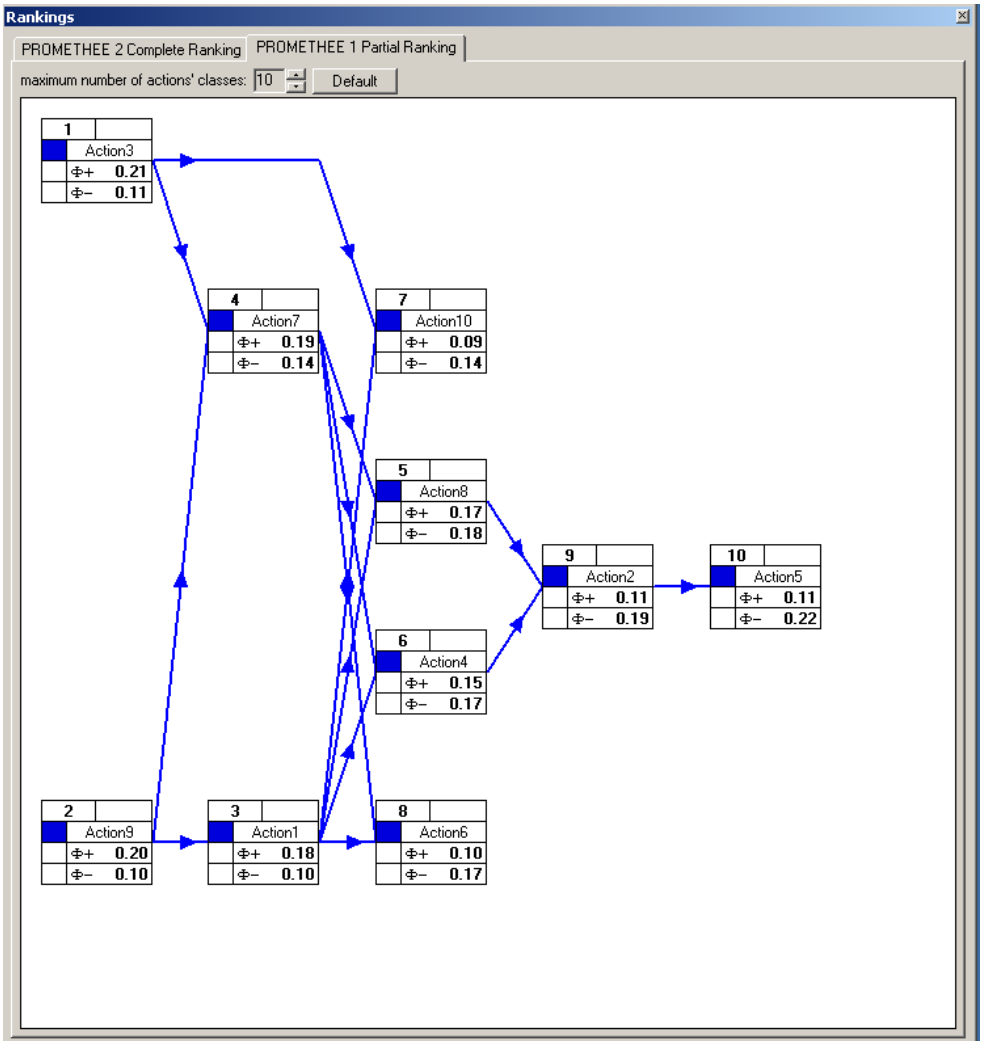


	Φ+	Φ−	Φ
Action1	0.1846	0.1004	0.0842
Action2	0.1139	0.1873	-0.0734
Action3	0.2129	0.1071	0.1058
Action4	0.1481	0.1749	-0.0268
Action5	0.1103	0.2240	-0.1137
Action6	0.1001	0.1652	-0.0651
Action7	0.1931	0.1434	0.0497
Action8	0.1697	0.1754	-0.0056
Action9	0.2004	0.0995	0.1009
Action10	0.0857	0.1416	-0.0559

Slika 3.8 Vrijednosti Φ, Φ_+ i Φ_-

(Decision Lab)

Koristeći sve pozitivne i negativne tokove dobavljača formirano je parcijalno rangiranje, tzv. PROMETHEE I prikazano na slici 3.8. lako je uočljivo da je treći dobavljač najjači po pozitivnom toku no ima lošiji negativni tok od prvog i devetog, što ih čini neusporedivim u parcijalnom uređaju. Slično tome, sedmi dobavljač ima bolji pozitivan tok od prvog i ponovno veći negativan tok od sedmog dobavljača što ih čini neusporedivim. Peti je dobavljač po rangiranju lošiji od drugog, osmog, četvrtog, sedmog, prvog, devetog i trećeg dobavljača ali ostaje neusporediv s desetim i šestim dobavljačem koji imaju niži pozitivan tok od petog dobavljača.



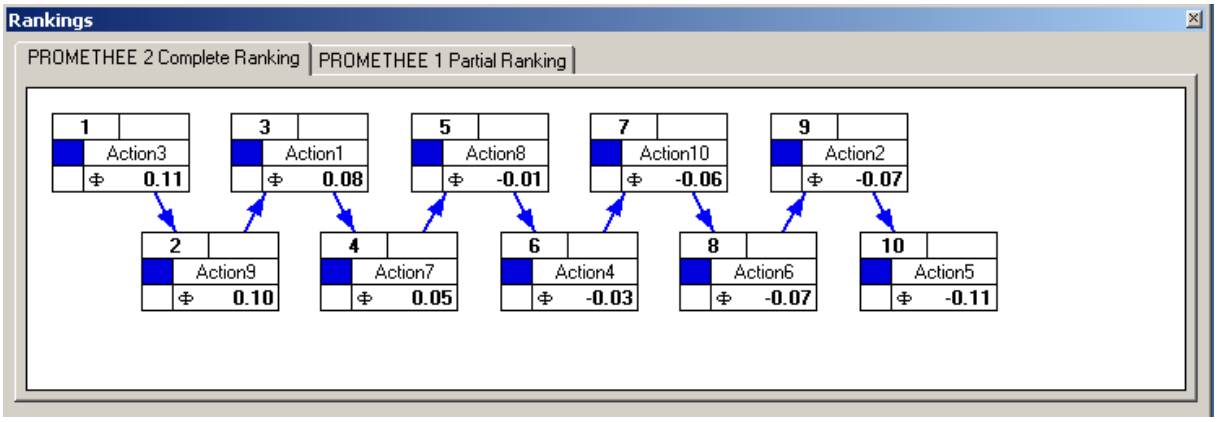
Slika 3.9 Rangiranje dobavjača - PROMETHEE I

(Decision Lab)

Zaključno se može reći da PROMETHEE I nije vodio do konačnog rangiranje dobavljača. Međutim, kako bi se dobio potpuni poredak koristit će se metoda PROMETHEE II u idućem poglavlju.

3.4.1 Konačno rangiranje dobavljača pomoću PROMETHEE II

PROMETHEE II omogućit će potpuno rangiranje dobavljača, što nije bilo moguće koristeći PROMETHEE I. Za rangiranje koriste se neto tokovi, što je razlika između pozitivnih i negativnih tokova. U slici 3.8 prikazane su vrijednosti neto tokova. Sljedeća grafika (3.9) prikazuje poredak po neto toku:



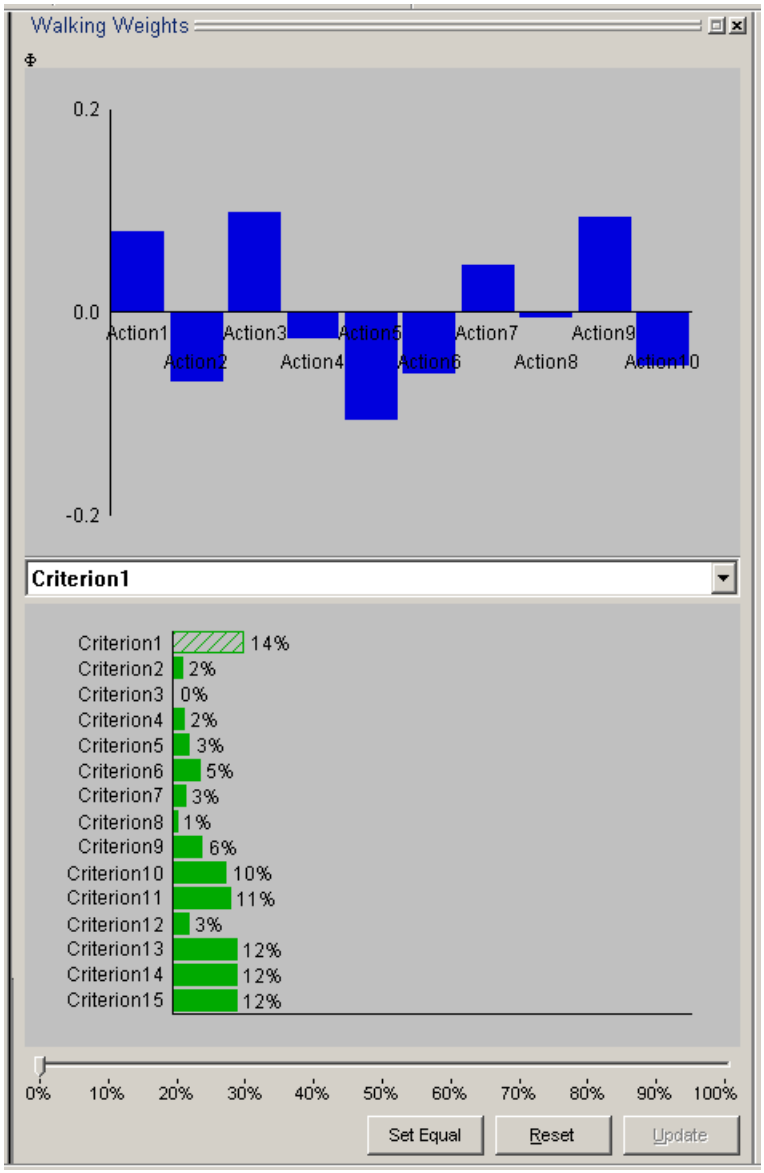
Slika 3.10 Rangiranje dobavjača - PROMETHEE II

(Decision Lab)

Može se primijetiti da između deset dobavljača dobavljač broj tri ima najviši rezultat. Kao što se vidi, dobavljač tri ima neto tok od $\Phi = 0{,}1058$ i najbolji je u usporedbi s dobavljačem šest ($\Phi = -0{,}0651$), dobavljačem dva ($\Phi = -0{,}0734$), ili dobavljačem pet ($\Phi = -0{,}1137$), koji imaju najniže neto tokove. S obzirom da se promatraju dobavljači bez količinskih organičenja, proizvođač automobila trebao bi kupovati sve spremnike kod trećeg dobavljača.

3.4.2 Analiza osjetljivosti

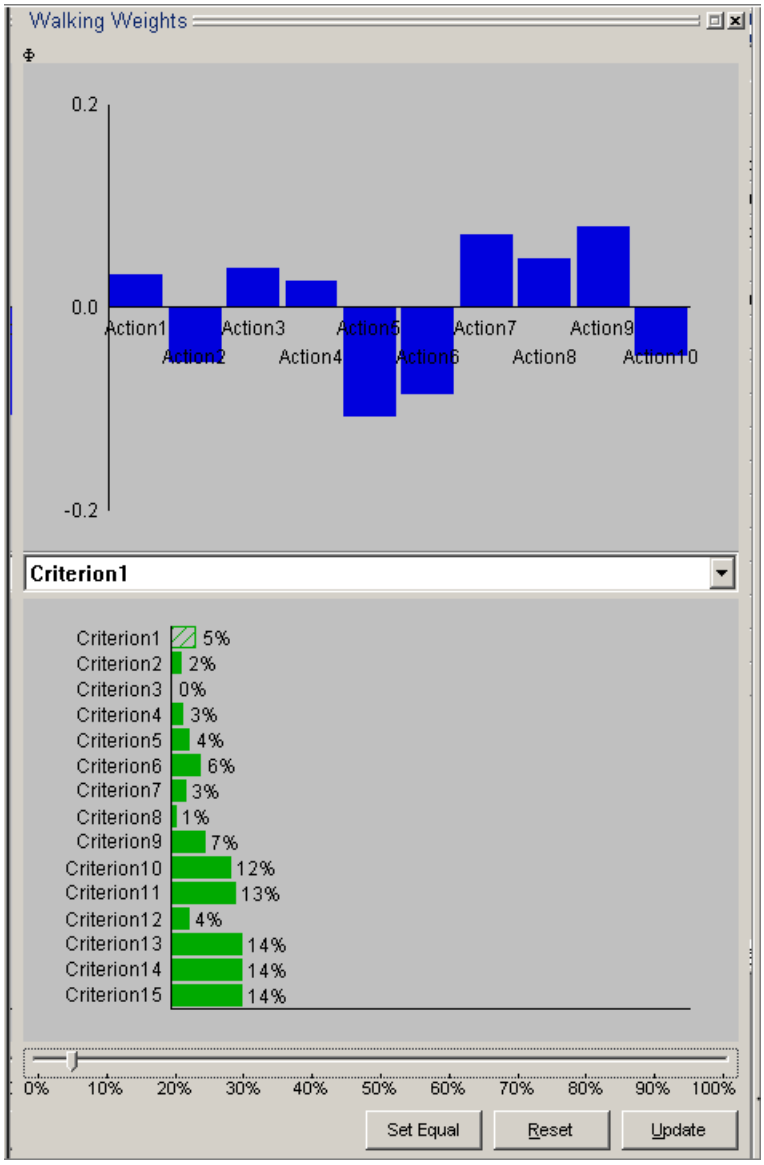
Program Decision Labs omogućava i analizu osjetljivosti na promjenu težina kriterija. Provedene su analize koristeći opciju „walking weights“. Na sljedećoj slici prikazan je poredak dobavljača uz početne vrijednosti težina kriterija:



Slika 3.11 Analiza osjetljivosti – početne vrijednosti

(Decision Lab)

Kao što se vidi, prvi kriterij (cijena) kriterij je s najvećom težinom od 14%. Cilj ovog poglavlja bit će promatranje promjene u poretku dobavljača ako se „važnost“ tog kriterija promijeni. U prvom scenarij težina kriterija spustit će se na 5% uz proporcionalno podizanje ostalih kriterija. Na sljedećoj slici vide se promjene u poretku:

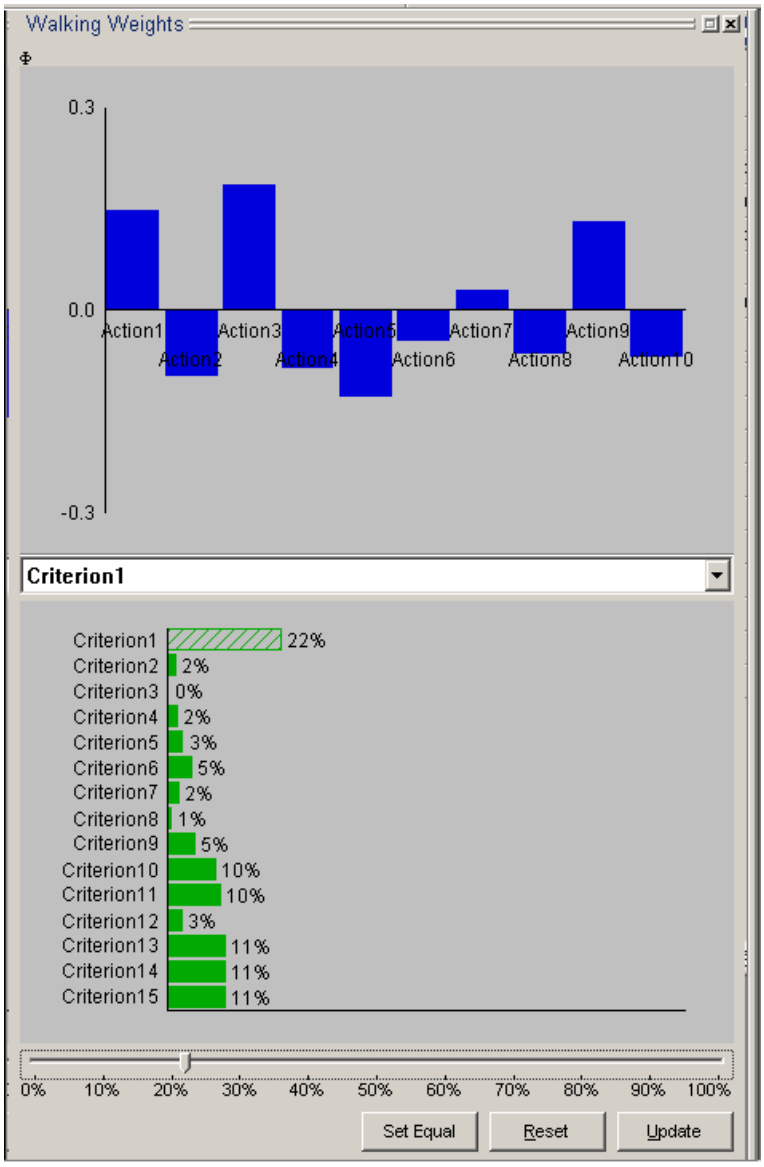


Slika 3.12 Analiza osjetljivosti – smanjena težina kriterija cijene

(Decision Lab)

Kao što se vidi, treći dobavljač više nije najbolja opcija za prizvođača automobila. Već su po neto toku dobavljači sedam, osam i devet bolji, a posebno dobavljač osam, koji je prije promjene cijene imao negativan neto tok i skočio s petog ranga na treći. Još jedan dobitnik manje težine kriterija cijene je četvrti dobavljač, koji je također imao negativan neto tok što se nakon primjene promjenilo. Treći i prvi dobavljač još uvijek imaju pozitivan neto tok, međutim, on im se znatno smanjio.

U drugom scenariju povećat će se važnost cijene na 22% uz proporcionalno smanjenje ostalih kriterija. Na sljedećoj slici se vidi promjene u poredku:



Slika 3.13 Analiza osjetljivosti – povišena težina kriterija cijene

(Decision Lab)

Težina prvog kriterija (cijena) povećava se na 22% te će doći do manje značajnih promjena u konačnom poretku nego kod spuštnja težine cijene. Treći dobavljač ostaje najbolji te prvi i deveti dobavljač mijenjaju se za drugo i treće mjesto. Peti dobavljač ostaje na zadnjem, te drugi na predzadnjem mjestu. Svi dobavljači koji su imali pozitivan neto tok ga imaju i nakon promjene težina, a svi dobavljači s negativim neto tokom imaju ga i dalje.

Konačno se može reći da konačni poredak osjetljivije reagira na smanjenje nego na dizanje težina cijene.

3.5 Izbor dobavljača pomoću linearnog programiranja

U prethodnim poglavljima utvrdilo se da treći dobavljač najbolje zadovoljava potrebe proizvođača. Problem koji će se promatrati u ovom poglavlju je sljedeći:

a) Dobavljači imaju količinska ograničenja i ne mogu proizvoditi ukupnu potražnju proizvođača
b) Ukupno vrijeme proizvodnje svih potraženih spremnika ne smije bit duže od 4 mjeseca.
c) Prosječna varijacija u veličini ne smije premašiti 0,175 mm.

Dobiveni neto tokovi za dobavljače iz poglavlja 3.4 bit će postavljeni kao koeficijenti u funkciji cilja. Ova funkcija maksimizira ukupnu vrijednost nabave (TVP). Za linarno programiranje će se koristiti vrijednost Φ koja se dobila pomoću PROMETHEE metode.

Rang	Dobavljač	Φ
1	Dobavljač 3	0,1058
2	Dobavljač 9	0,1009
3	Dobavljač 1	0,0842
4	Dobavljač 7	0,0497
5	Dobavljač 8	-0,0056
6	Dobavljač 4	-0,0268
7	Dobavljač 10	-0,0559
8	Dobavljač 6	-0,0651
9	Dobavljač 2	-0,0734
10	Dobavljač 5	-0,1137

Tablica 3.21 Konačno rangiranje dobavljača pomoću PROMETHEE II

Tablica 3.20 pokazuje ograničenja dobavljačeva kapaciteta, stoga je model linearnog programiranja napravljen kako bi se distribuirale količine na više od jednog dobavljača. Nadalje, vrijeme proizvodnje ne smije premašiti 4 mjeseca (pet osmosatnih radnih dana po tjednu) za svih 6000 proizvoda. Model linearno programiranje ima sljedeći oblik:

TVP

$$Max\ TVP = (\ 0{,}0842x_1 - 0{,}0734\ x_2 + 0{,}1058\ x_3 - 0{,}0268\ x_4 - 0{,}1137\ x_5 - 0{,}0651\ x_6 + 0{,}0497\ x_7 - 0{,}0056\ x_8 + 0{,}1009\ x_9 - 0{,}0559\ x_{10}) \qquad (3.5.1)$$

a) Količinskih ograničenja

$$x_1 \leq 3000 \quad (3.5.2)$$
$$x_2 \leq 5000 \quad (3.5.3)$$
$$x_3 \leq 2000 \quad (3.5.4)$$
$$x_4 \leq 400 \quad (3.5.5)$$
$$x_5 \leq 500 \quad (3.5.6)$$
$$x_6 \leq 1000 \quad (3.5.7)$$
$$x_7 \leq 300 \quad (3.5.8)$$
$$x_8 \leq 400 \quad (3.5.9)$$
$$x_9 \leq 2000 \quad (3.5.10)$$
$$x_{10} \leq 1000 \quad (3.5.11)$$

b) Ograničenja vremena protoka:

$$x_1 \leq 2285{,}714286 \quad (3.5.12)$$
$$x_2 \leq 1600 \quad (3.5.13)$$
$$x_3 \leq 1600 \quad (3.5.14)$$
$$x_4 \leq 1238{,}709677 \quad (3.5.15)$$
$$x_5 \leq 1416{,}97417 \quad (3.5.16)$$
$$x_6 \leq 952{,}853598 \quad (3.5.17)$$
$$x_7 \leq 2285{,}714286 \quad (3.5.18)$$
$$x_8 \leq 1586{,}77686 \quad (3.5.19)$$
$$x_9 \leq 1979{,}381443 \quad (3.5.20)$$
$$x_{10} \leq 1828{,}571429 \quad (3.5.21)$$

Prema tome nema potrebe duplo ograničavati varijable već je dovoljno uzeti samo manji broj od ograničenja pod a) i b), dakle:

$$x_1 \leq 2285{,}714286 \quad (3.5.22)$$
$$x_2 \leq 1600 \quad (3.5.23)$$
$$x_3 \leq 1600 \quad (3.5.24)$$
$$x_4 \leq 400 \quad (3.5.25)$$
$$x_5 \leq 500 \quad (3.5.26)$$
$$x_6 \leq 952{,}853598 \quad (3.5.27)$$
$$x_7 \leq 300 \quad (3.5.28)$$
$$x_8 \leq 400 \quad (3.5.29)$$
$$x_9 \leq 1979{,}381443 \quad (3.5.30)$$
$$x_{10} \leq 1000 \quad (3.5.31)$$

c) Ograničenj za varijaciju veličine

$$0{,}1x_1 + 0{,}1\,x_2 + 0{,}2\,x_3 + 0{,}1\,x_4 + 0{,}7\,x_5 + 0{,}1\,x_6 + 0{,}2\,x_7 + 0{,}1\,x_8 + 0{,}2\,x_9 + 0{,}1\,x_{10} \leq 0{,}125 * 6000 = 750 \qquad (3.5.22)$$

Zahtjevi tvrtke:

$$\sum_{i=1}^{10} x_i = 6000 \qquad (3.5.23)$$

Osim ovih ograničenja jos se definiralo uvjet nenegativnosti. Ovaj je problem riješen koristeći WINQSB na osobnom računalu:

Variable -->	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	Direction	R. H. S.
Maximize	0.0842	-0.0734	0.1058	-0.0268	-0.1137	-0.0651	0.0497	-0,0056	0.1009	-0,0559		
C1	0.1	0.1	0.2	0.1	0.7	0.1	0.2	0.1	0.2	0.1	<=	750
C2	1	1	1	1	1	1	1	1	1	1	=	6000
LowerBound	0	0	0	0	0	0	0	0	0	0		
UpperBound	2285	1600	1600	400	500	952	300	400	1979	1000		
VariableType	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous		

Slika 3.14 Unos u WINQSB za 6000 proizvoda

(WINQSB)

Dobavljač	Rješenje	Koeficijent funkcija cilja	Dobavljač	Rješenje	Koeficijent funkcija cilja
X1	2285	0,0842	X6	952	-0,0651
X2	863	-0,0734	X7	0	0,0497
X3	1500	0,1058	X8	0	-0,0056
X4	400	-0,0268	X9	0	0,1009
X5	0	-0,1137	X10	0	-0,0559
Maksimizirani TVP = 215,0576					

Tablica 3.22 Optimalan rezultat za 6000 proizvoda pod ograničenjenima.

Očito je da s ovakvom evaluacijom dobavljača i nametnutim ograničenjima proizvočač treba HDPE spremnike goriva od samo pet različita dobavljača, primarno od onih čiji su prioriteti najviši (koeficijenti funkcije cilja).

Ako su zahtjevi tvrtke viši, npr. 8000 proizvoda, onda će rezultat biti drugačiji i znatno veći broj dobavljača će biti odabran:

Variable -->	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	Direction	R. H. S.
Maximize	0.0842	-0.0734	0.1058	-0.0268	-0.1137	-0.0651	0.0497	-0,0056	0.1009	-0,0559		
C1	0.1	0.1	0.2	0.1	0.7	0.1	0.2	0.1	0.2	0.1	<=	1000
C2	1	1	1	1	1	1	1	1	1	1	=	8000
LowerBound	0	0	0	0	0	0	0	0	0	0		
UpperBound	2285	1600	1600	400	500	952	300	400	1979	1000		
VariableType	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous	Continuous		

Slika 3.15 Unos u WINQSB za 8000 proizvoda

(WINQSB)

U ovom slučaju, proizvođač treba napraviti narudžbu od osam različitih dobavljača. Rezultati su prikazani u tablici 3.23.

Dobavljač	Rješenje	Koeficijent funkcija cilja	Dobavljač	Rješenje	Koeficijent funkcija cilja
X1	2285	0,0842	X6	952	-0,0651
X2	1600	-0,0734	X7	0	0,0497
X3	1600	0,1058	X8	400	-0,0056
X4	400	-0,0268	X9	400	0,1009
X5	0	-0,1137	X10	363	-0,0559
Maksimizirani TVP = -225.105,2					

Tablica 3.23 Optimalan rezultat za 8000 proizvoda pod ograničenjenima.

4. ZAKLJUČAK

Svako poduzeće treba biti uz korak s današnjim turbulentnim tržištem koje se svakodnevno mijenja i donosi nove promjene. Kako bi opstali na tržištu i bili bolji od konkurencije, uprava svakog poduzeća mora se prilagođavati nastalim promjenama i pronalaziti rješenja koja vode prema efikasnijem poslovanju. Kako je već u uvodu navedeno, proizvođači automobila zadnjih se 20 godina usredotočuju na srž poslovanja i mnogo poslovnih procesa predaje se drugim tvrtkama u lancu vrijednosti. Taj tzv. «outsourcing» omogućava npr. smanjenje troškova, ubrzava inovaciju i povećava konkurentnost tvrtki na jednoj strani, ali i povećava ovisnost proizvođača o dobavljačima. To pokazuje kako je bitno naći najbolje dobavljače. Budući da su proizvodni procesi kompleksni i mnogobrojni, tako su i zahtjevi proizvođača prema dobavljačima jednako složeni. Broj kriterija (zahtjeva) konstantno raste i dovodi donositelja odluke u situaciju gdje više ne može usporediti sve veći broj dobavljača pomoću sve većeg broja kriterija. Zato je na početku ovog rada postavljena sljedeća hipoteza:

H1: Pomoću metoda višekriterijalnog odlučivanja može se postići optimalan izbor jednog ili više dobavljača. U konkretnom slučaju, radi se o izboru dobavljača spremnika goriva od HDPE-a za proizvođača automobila.

Kako bi se utvrdila ili odbacila hipoteza, tri metode višekriterijalong odlučivanja se koristilo za izbor najboljeg dobavljača i najbolje kombinacije više dobavljača ako postoje ograničenja za proizvođača automobila.

Nakon uvoda, u sljedećem poglavlju utvrdile su se teorijske predpostavke rada, a navedeno poglavlje sadrži detaljno objašnjenje izračuna težina u AHP modelu, rangiranje pomoću PROMETHEE metode i osnovne pojmove linearnom programiranju.

Praktički dio rada temeljio se na podacima dobivenima od voditelja nabave kod jednog proizvođača automobila. Prvo su se utvrdili bitni kriteriji za izbor dobavljača te je izrađena hijerarhija s pet nivoa. U odnosu na cilj (izbor najboljeg dobavljača) definirani su tri kriterija: performansa logistike, komercijalna struktura i proizvodnja. Svaki kriterij se nadalje razgradio u detaljnije podkriterije na trećem nivou hijerarhije. Za racionalan izbor dobavljača neki podkriteriji morali su se razložiti na sekundarne podkriterije na četvrtom nivou hijerarhije. Nadalje se definirao broj potencijalnih dobavljača koji su dodani na peti nivo hijerarhije.

Nakon stvaranja hijerarhije proveo se intervju s upraviteljem nabave gdje je on, kao donositelj odluke, ocjenjivao važnosti kriterija pomoću usporedbe u parovima. U konačnici se koristeći AHP metodu došlo do težina svakog kriterija.

Sljedeći korak je korištenje metode PROMETHEE za konačan rang odabranih dobavljača. Izračunom PROMETHEE II utvrdio se sljedeći poredak alternativa: dobavljač 3, dobavljač 9, dobavljač 1, dobavljač 7, dobavljač 8, dobavljač 4, dobavljač 10, dobavljač 6, dobavljač 2 i dobavljač 5.

Ovaj poredak potvrdio je prvi dio hipoteze: pomoću višekriterijalnog odlučivanja donosiocu odluke moguće je odabrati najboljeg dobavljača.

Za istraženje drugog dijela hipoteze koristilo se linearno programiranje. To je značilo maksimiziranje TVP za određenu količinu spremnika. Neto tokovi dobiveni iz PROMETHEE-a II služili su kao koeficijenti ciljne funkcije TVP-a koja se maksimizirala. Maksimizacija je provedena pod tri ograničenja: količinska ograničenja, ograničenja vremena protoka i ograničenja vezana uz maksimalnu prosječnu varijaciju veličine. Izračun dokazuja da pomoću linearnog programiranje proizvođač automobila može odrediti najbolju kombinaciju dobavljača te se stoga potvrđuje i drugi dio hipoteze.

Sažetak

U ovom je radu prikazan kvantitativni model izbora dobavljača. Model koristi tri metode operacijske pretrage: hijerarhijski proces analize, PROMETHEE metodu i linearno programiranje. Prva metoda, AHP, koristi se za izračun težina svakog kriterija pomoću usporedbe u parovima. Koristeći PROMETHEE metodu alternative (dobavljači) rangiraju se te se izračunavaju koeficijenti preferencije za svakog dobavljača. LP model, koji se temelji na prethodno prikupljenim koeficijentima, distribuira količine narudžbi svakom dobavljaču u svrhu maksimiziranja TVP-a.

Summary

This thesis presents a supplier selection quantitative model. The model deals with three methods of operation research: Analytic Hierarchy Process, PROMETHEE method and linear programming. The first of them – AHP – is used to calculate the weights of each criteria by pairwise comprehension. By using the PROMETHEE method the alternatives (suppliers) are ranked and preference coefitions for each supplier are calculated. The LP model, which is based on the previous gathered coefitions, distributes order quantities to each supplier in order to maximise the Total Value of Purchasing (TVP).

Literatura

1. Arbel, A., Seidmann, A. (1984): Selecting a microcomputer for process control and data acquisition. IIE transactions, 16(1), 73-80.
2. Babić, Z. (2011): Modeli i metode poslovnog odlučivanja. Sveučilište u Splitu, Ekonomski fakultet, Split, 2011.
3. Bard, J. F. (1986): Evaluating space station applications of automation and robotics. IEEE Transactions on Engineering Management, (2), 102-111.
4. Bayazit, O., Karpak, B. (2005): An AHP application in vendor selection. ISHAP 2005, Honolulu, Hawaii.
5. Beck, M. P., Lin, B. W. (1981): Selection of automated office systems: a case study. Omega, 9(2), 169-176.
6. Boer, L., Labro E., Morlacchi P. (2001): A review of methods supporting supplier selection. European Journal of Purchasing & Supply Management, 7, 2001, 75-89.
7. Brans, J. P., Vincke, P., Mareschal, B. (1986): How to select and how to rank projects: The PROMETHEE method. European journal of operational research, 24(2), 228-238.
8. Figueira, J., Greco, S., Ehrgott, M. (2005): Multiple criteria decision analysis: state of the art surveys. Springer Science & Business Media.
9. Cardozo, Richard N., James W. Cagley: Experimental study of industrial buyer behavior. Journal of Marketing Research (1971): 329-334.
10. Cakravastia, A., Takahashi, K. (2004): Integrated model for supplier selection and negotiation in a make-to-order environment. International Journal of Production Research, 42(21), 4457-4474.
11. Chapman, S. N., Carter, P. L. (1990): Supplier/customer inventory relationships under just in time. Decision Sciences, 21(1), 35-51.
12. Chaudhry,S.S., F.G.Forst, J.L.Zydiak (1993): Vendor selection with price breaks. EJOR, 52-66.

13. Choi, J., Bai, S. X., Geunes, J., Romeijn, H. E. (2007): Manufacturing delivery performance for supply chain management. Mathematical and Computer Modelling, 45(1), 11-20.

14. Chopra S., Meindl P. (2006): Supply chain management. Strategy, planning & operation. Das Summa Summarum des Management, 265-275.

15. Díaz-Madroñero, M., Peidro, D., Vasant, P. (2010): Vendor selection problem by using an interactive fuzzy multi-objective approach with modified S-curve membership functions. Computers & Mathematics with Applications, 60(4), 1038-1048.

16. Dickson, G.W. (1966): An analysis of vendor selection systems and decisions. Journal of Purchasing, 2(1), 5-17.

17. Gereffi, G., Humphrey, J., Sturgeon, T. (2005): The governance of global value chains. Review of international political economy, 12(1), 78-104.

18. Ghodsypour, S. H., O'Brien, C. (1998): A decision support system for supplier selection using an integrated analytic hierarchy process and linear programming. International journal of production economics, 56, 199-212.

19. Imeri, S. (2013): Key Performance Criteria for Vendor Selection – a Literature Review. Management Research and Practice, 5(2), 63-75.

20. ISO/TS 16949:2009: Quality management systems -- Particular requirements for the application of ISO 9001:2008 for automotive production and relevant service part organizations.

21. Jurun E., Plazibat N.T., Babić Z. (1999): Supplier Selection Problem in City of Split Kindergartens. Proceedings of the 5th International Symposium on Operational Research, Preddvor , Slovenia, October 1999, 99-104.

22. Kahraman, C., Cebeci, U., Ulukan, Z. (2003): Multi-criteria supplier selection using fuzzy AHP. Logistics information management, 16(6), 382-394.

23. Koplin, J., Seuring, S., Mesterharm, M. (2007): Incorporating sustainability into supply management in the automotive industry–the case of the Volkswagen AG. Journal of Cleaner Production, 15(11), 1053-1062.

24. Kumar, M., Vrat, P., & Shankar, R. (2006): A fuzzy programming approach for vendor selection problem in a supply chain. International Journal of Production Economics, 101(2), 273-285.

25. Mandal, A., Deshmukh, S. G. (1994): Vendor selection using interpretive structural modelling (ISM). International Journal of Operations & Production Management, 14(6), 52-59.

26. Neidik, B., Gereffi, G. (2006): Explaining Turkey's emergence and sustained competitiveness as a full-package supplier of apparel. Environment and Planning A, 38(12), 2285-2303.

27. Patton, W. E. (1997): Individual and joint decision-making in industrial vendor selection. Journal of Business Research, 38(2), 115-122.

28. Perić T., Babić Z. (2007): A Decision System for Vendor Selection Problem. Proceedings of the 9th International Symposium on Operational Research, Nova Gorica, Slovenija, 26-28 septembar 2007, 191-196.

29. Petroni, A., Braglia, M. (2000): Vendor selection using principal component analysis. Journal of supply chain management, 36(1), 63-69.

30. Porter, M. E., Millar, M. V. (1985): How Information Gives You Competitive Advantage. Harvard business review 63(4):149-74

31. Saaty, T. L. (2008): Decision making with the analytic hierarchy process. International journal of services sciences, 1(1), 83-98.

32. Saaty, T. L. (2005): Theory and applications of the analytic network process: decision making with benefits, opportunities, costs, and risks. RWS publications.

33. Saaty, T. L. (1990): Decision making for leaders: the analytic hierarchy process for decisions in a complex world. RWS publications.

34. Sturgeon, T., Lester, R. K. (2004): The new global supply-base: new challenges for local suppliers in East Asia. Global production networking and technological change in East Asia, 35-87.

35. Sturgeon, T. J., Memedovic, O., Van Biesebroeck, J., Gereffi, G. (2008): Globalisation of the automotive industry: main features and trends. International Journal of Technological Learning, Innovation and Development, 2(1-2), 7-24.

36. Syamsuddin, I. (2013): Multicriteria Evaluation and Sensitivity Analysis on Information Security. arXiv preprint arXiv:1310.3312.

37. Telgen, J. (1994): Inzicht en overzicht: de uitdagingen van Besliskunde en Inkoopmanagement. Academical address at the University of Twente, Enschede, The Netherlands.

38. Weber, C. A., Current, J., Desai, A. (2000): An optimization approach to determining the number of vendors to employ. Supply Chain management: An international journal, 5(2), 90-98.

39. Weber, C. A., Current, J. R. (1993): A multiobjective approach to vendor selection. European Journal of Operational Research, 68(2), 173-184.

40. Weber, C. A., Current, J. R., Benton, W. C. (1991): Vendor selection criteria and methods. European journal of operational research, 50(1), 2-18.

41. Wind, Y., Saaty, T. L. (1980): Marketing applications of the analytic hierarchy process. Management science, 26(7), 641-658.

42. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela. Ekonomski fakultet Sveučilišta u Rijeci, Rijeka, 2000.

Popis slika

Slika 2.1 Općenita struktura hijerarhije u AHP modelu 9
Slika 2.2 Funkcija preferencije 15
Slika 2.3 Obični kriterij 16
Slika 2.4 Kvazi kriterij 16
Slika 2.5 Kriterij s linearnom preferencijom 17
Slika 2.6 Nivo kriterij 17
Slika 2.7 Kriterij s linearnom preferencijom i područjem indiferencije 18
Slika 2.8 Gaussov kriterij 18
Slika 2.9 Lukovi $\Pi a, b$ i $\Pi b, a$ 19
Slika 3.1 Kriteriji u AHP modelu. 26
Slika 3.2 Podkriteriji i sekundarni podkriteriji performanse logistike. 27
Slika 3.3 Podkriteriji i sekundarni podkriteriji komercijalne strukture. 29
Slika 3.4 Podkriteriji i sekundarni podkriteriji komercijalne strukture 31
Slika 3.5 Potpuna hijerarhija 31
Slika 3.6 Težine kriterija 33
Slika 3.7 Globalne težine 41
Slika 3.8 Vrijednosti $\Phi, \Phi +$ i $\Phi -$ 44
Slika 3.8 Rangiranje dobavjača - PROMETHEE I 45
Slika 3.9 Rangiranje dobavjača - PROMETHEE II 46
Slika 3.11 Analiza osjetljivosti – početne vrijednosti 47
Slika 3.12 Analiza osjetljivosti – smanjena težina kriterija cijene 48
Slika 3.13 Analiza osjetljivosti – povišena težina kriterija cijene 49
Slika 3.14 Unos u WINQSB za 6000 proizvoda 52
Slika 3.15 Unos u WINQSB za 8000 proizvoda 53

Popis tablica

Tablica 2.1 Saatyeva skala važnosti i njezin opis te interpretacija 11
Tablica 2.2 Vrijednosti slučajnog indexa (RI). 13
Tablica 2.3 PROMETHEE – matrica odluke. 14
Tablica 2.4 PROMETHEE I – parcijalni uređaj 20
Tablica 3.1 Ljestvica performanse sa pet razina. 28
Tablica 3.2 Ljestvica za procjenu kapaciteta procesa. 30
Tablica 3.3 Odgovori u anketi voditelja nabave na drugoj razini hijerarhije. 32
Tablica 3.4 Usporedba u parovima na drugoj razini hijerarhije. 33
Tablica 3.5 Ocjene važnosti u anketi pod kriterijom „performansa logistike“ 34
Tablica 3.6 Matrica odluke i težine pod kriterijem „performanse logistike“ 34
Tablica 3.7 Ocjene važnosti u anketi pod kriterijem „komercijalna struktura“ 35
Tablica 3.8 Matrica odluke, težine i omjer konzistentnosti pod kriterijem „performanse logistike“ 35
Tablica 3.9 Ocjene važnosti u anketi pod kriterijem „proizvodnja“ 36
Tablica 3.10 Matrica odluke i težine pod kriterijem „proizvodnja“ 36
Tablica 3.10 Ocjene važnosti u anketi pod podkriterijem „analiza troškova“ 37
Tablica 3.11 Matrica odluke i težine pod podkriterijem „analiza troškova“ 37
Tablica 3.13 Ocjene važnosti u anketi pod podkriterijem „performansa dostave“ 38
Tablica 3.14 Matrica odluke i težine pod podkriterijem „performanse dostave“ 38
Tablica 3.15 Ocjene važnosti u anketi pod podkriterijem „struktura troškova“ 38
Tablica 3.16 Matrica odluke i težine pod sekundarnim podkriterijem „struktura troškova“ 39
Tablica 3.17 Ocjene važnosti u anketi pod podkriterijem „specifikacije materijala“ 39
Tablica 3.18 Matrica odluke, težine i omjer konzistentnosti pod sekundarnim podkriterijem „specifikacije materijala“ 40
Tablica 3.17 Rangiranje kriterija po važnosti. 42
Tablica 3.20 Matrica odlučivanja 43
Tablica 3.21 Konačno rangiranje dobavljača pomoću PROMETHEE II 50
Tablica 3.22 Optimalan rezultat za 6000 proizvoda pod ograničenjenima. 52
Tablica 3.23 Optimalan rezultat za 8000 proizvoda pod ograničenjenima. 53