UDK 519.8
Pregledni članak
Primljeno: 05. 09. 1990.

Dr. DRAŽEN BARKOVIĆ,
Ekonomski fakultet Osijek

PRIMJENA ANALITIČKOG HIJERARHIJSKOG PROCESA NA JEDNOM MODELU DODJELE*

Ovaj članak je pokazao jedan prioritetni model koji koristi tranzitivnost procjene kao mjeru kvalitete izražene procjene i koji pruža priliku da se matematičkim putem kvalitet prilagođene informacije razvije u prioritetnu težinu. Ispitani su različiti operacionalni aspekti modela i moguće primjene.

* Rad predstavlja dio istraživačkih rezultata potprojekta "Zakon vrijednosti u funkciji upravljanja razvojem", kojeg kao dio projekta "fundamentalna istraživanja u ekonomiji" financira SIZ znanosti Hrvatske u razdoblju 1987-1990. godine.

1. UVOD

Jedna od interesantnih i korisnih teorija na polju odlučivanja je analitički hijerarhijski proces koji je razvio Saaty[1] Njezina primjena bila je dosta usporena uglavnom radi krivog shvaćanja teorijske osnove kao i slabe sklonosti teoretičara i praktičara da se udalje od tradicionalnih metoda analize kao što su npr. delphi metoda, multiatributivna teorija korisnosti. Analitički hijerarhijski proces[2] je opsežna okosnica namijenjena savladavanju poteškoća na intuitivan, racionalan i iracionalan način u situacijama kada se donose odluke koje se odnose na više ciljeva ili više kriterija, a kada se ne poznaju izvjesnosti pojedinih alternativa. U ovom procesu, problem se rastavlja na manje konstitutivne dijelove da bi se izvršila jednostavna procjena parova koji se uspoređuju. Zatim se postave prioriteti po svakoj hijerarhiji. Cilj ovog članka nije da se bavi aksiomatskom podlogom na kojoj se temelji analitički hijerarhijski proces već da pomoću jednog modelskog pristupa prikaže sastavne elemente te teorije i njihovu praktičnu primjenu u rješavanju problema odlučivanja. U tu svrhu dobro može poslužiti model prioritetne dodjele u kojemu Lusk[3] provodi sistematsku analizu jednog problema investicijskog odlučivanja u kojemu se investicijske alternative trebaju prosuditi na temelju više kriterija. Od te analize se zahtjeva: (1) da se identificira skup alternativa koje se mogu uspoređivati, (2) da se specificira opsežan skup kriterija tako, da se o svakoj alternativi može prosuditi u odnosu na neku drugu po svakom kriteriju, (3) da se procijeni svaki kriterij, (4) da se svakoj alternativi dodijeli "težina" koja odražava poželjnost te alternative, uzimajući u obzir sve dostupne informacije.

2. MODEL PRIORITETNE DODJELE NA TEMELJU SVOJSTVENE VRIJEDNOSTI

U namjeri da osigura relevantne informacije za donosioca odluke Saaty[4] je razvio model koji uzima u obzir alternativne izbore u kompleksnim situacijama

1) Saaty, T. L., the Analytic Hierarchy Process, Mc Graw-Hill, New York, 1981.

2) Harker, P. T., Vargas, L. G., The Theory of Ratio Scale Estimatio: Saaty's Analytic Hierarchy Process, Managment Science, br. 11, 1987,

3) Lusk, E., Analysis of Hospital Capital Decision Alternatives: A Priority Assigment Model, The Journal of Operational Research Society, br. 5,1979, str 439

4) Saaty, T.L.,A Scaling Method for Priorities in Hierarchiel Structures, Journal of Mathematical Psihology, br.15,1977, str.234-281.

odlučivanja i koji zahtjeva: (1) procjenu alternativa za svaki kriterij, (2) procjenu relativne važnosti kriterija u procesu odlučivanja. Nakon toga što su utvrđene alternative i kriteriji, svakom paru elemenata bilo alternativa odlučivanja, bilo kriterija dodjeljuje se broj koji daje procjenu para u vidu točke na ordinalnoj skali. Taj ordinalni broj koji odražava intenzitet diferencije između dva elementa zabilježen je u matrici koja se zove matrica procjene. Informacije koje su sadržane u pojedinoj matrici temelje se na izračunavanju svojstvene vrijednosti vektora pridruženog maksimalnoj svojstvenoj vrijednosti matrice. Relativna veličina vrijednosti elemenata svojstvenog vektora najbolje će predstavljati intenzitet procjene kako je zabilježeno u matrici procjene.

Ako na raspolaganju stoji n alternativa i m kriterija, za koje se moraju izvršiti procjene, onda će biti m matrica procjene alternativa odlučivanja, svaka tipa n x n i jedna matrica procjene kriterija tipa m x m. m svojstvenih vektora koji se dobivaju iz m matrica procjene alternativa odlučivanja skaliraju se tako da odražavaju netransitivnost procjene i zajedno sa svojstvenim vektorom koji se dobije iz matrice procjene kriterija koriste se za izračunavanje prioritetnih težina koje se dodjeljuju alternativama.

Problem svojstvene vrijednosti i svojstvenog vektora s kojim se operira u daljnjem prikazu problematike sastoji su u slijedećem:[5] Neka kvadratna matrica može se opisati tzv. karakterističnom jednadžbom. Do te jednadžbe se dolazi ako se od svakog elementa glavne dijagonale odbije neka vrijednost na taj način da vrijednost determinante postane nula:

$$\left| A - E \right| = \begin{vmatrix} a_{11} - \lambda & a_{12} \ldots\ldots a_{1p} & \\ a_{21} & a_{22} - \lambda & a_{2p} \\ \bullet & \bullet & \bullet \\ a_{p1} & a_{p2} & a_{pp} - \lambda \end{vmatrix} = 0 \qquad (1)$$

Ovdje se radi o primjeni tehnike Lagrangeovih multiplikatora; za rješenje se dobije toliko vrijednosti λ_i kolika je dimenzija odnosne matrice. Te vrijednosti se zovu svojstvene vrijednosti (svojstveni korijeni). Svakoj takvoj svojstvenoj vrijednosti pridružen je svojstveni vektor v na taj način da zadovoljava jednadžbu

$$A\,v = \lambda\,v \qquad (2)$$

Ovoj definiciji svojstvene strukture matrice dodajemo i ovo:[6]

Ako je λ_i svojstvena vrijednost matrice A, onda homogeni sistem linearnih jednadžbi

$$(A - \lambda E)\,\upsilon = 0 \qquad (3)$$

ima bar jedno netrivijalno rješenje v, a svako takvo rješenje je svojstveni vektor matrice koji odgovara svojstvenoj vrijednosti λ_i. S obzirom da realna matrica može imati kompleksne svojstvene vrijednosti, slijedi da i svojstveni vektori realne matrice mogu biti kompleksni.

3. RAZVOJ MATRICA PROCJENA

Da bi se razvile matrice procjena potrebna su tri elementa:[7]

I . Skup alternativa:

$a_i = i: \{1,\ldots,n\}$

II . Skup kriterija koji se odnose na alternative:

$C_j,\quad j: \{1,\ldots,m\}$

III . Mjerna skala koja u tipičnoj analitičkoj hijerarhijskoj studiji izgleda ovako:[8]

Intenzitet relativne važnosti	Definicija	Objašnjenje
1	Jednaka važnost	Aktivnosti doprinose jednako cilju
3	Umjerena važnost jedne nad drugom	Iskustvo i procjena lako favoriziraju jednu aktivnost nad drugom
5	Bitna važnost	Jako se favorizira jedna aktivnost nad drugom
7	Demonstrirajuća važnost	Jedna aktivnost se jako favorizira a njezina dominacija je uočena u praksi.
9	Ekstremna važnost	Evidentno favoriziranje jedne aktivnosti nad drugom
2,4,6,8	Srednja vrijednost između dvije susjedne procjene	Potreban je kompromis

Međuvrijednosti 2,4,6, i 8 se praktički koriste, ako primarni deskriptori nisu dovoljno reprezentativni za individualnu procjenu. Proces procjene zahtjeva od pojedinca da procijeni pojedine alternative u odnosu na odgovarajući kriterij. Ako su kriteriji dobro zamišljeni u odnosu na alternative odlučivanja, onda se očekuje da postoji mogućnost diferenciranja elemenata i prosudbe o intenzitetu te diferencije. Postoje mnogi sistemi skaliranja[9] koji se koriste u računanju veličine diferencije. U samom analitičkom hijerarhijskom procesu koristi se skala 1 do 9 koju je predložio Saaty na temelju eksperimentalne evidencije.[10]

5) Huttner, M.: Multivariante Methoden im Marketing, Verlag Moderne Industrie, Munchen 1978, str. 30-31.

6) Stojaković, Z., Herceg, D., Numeričke metode linearne algebre, Građevinska knjiga, Beograd 1982, str.198. .

7) Lusk, E., isti str. 440.

8) Saaty,T.,S.,Axiomatic Foundation of the Analytic Hierarchy Process, Management Science, br.7,1986, str. 843.

9) Green,P.,Tull,D., Research for Marketing Decisions, Prentice, Englwood Clifs, New Jersey, 1975, str. 175-191,

10) Harker,P.,Vargas,L., The Theory of Ratio Scale Estimation: Saaty's Analytic Hierarchy Process, Management Science, br.11,1987, str. 1390-1391.

3. l. Matrica procjene alternativa odlučivanja

Ako su poznati skup alternativa odlučivanja, skup kriterija i mjerna skala, onda bi se matrica procjene mogla postaviti na temelju procijenjenih relacija para alternativa po svakom kriteriju. Rezultati te procjene bilježe se na osnovi specifikacije jednog od deskriptora skale: 1,3,5,7, ili 9 ili nekom međuvrijednošću, te se unose u odgovarajući red i stupac matrice procjene kako slijedi

$$A_j = a_j^{kh} \qquad \begin{aligned} j &= 1,\dots,m \\ k &= 1,\dots,n \\ h &= 1,\dots,n \end{aligned}$$

gdje indeksi k i h indiciraju da je k-ta alternativa uspoređena s h-tom alternativom, a rezultat te komparacije zabilježen je pomoću kvantificirajućeg sistema skale u k-ti red i h-ti stupac od matrice A; j označava pojedinačni kriterij, $1 \le j \le m$; za bilo koji a_j^{kh}, ako je k = h vrijednost $a_j^{kh} = 1$; za bilo koju drugu alternativu pretpostavlja se slijedeća relacija $a_j^{kh} = (a_j^{hk})^{-1}$. Npr., ako se alternativa k malo preferira u odnosu na alternativu h po j-tom kriteriju, tada je $a^{kh}_j = 3$, zbog toga se pretpostavlja da će alternativa h u usporedbi s alternativom k biti procijenjena kao $a^{hk}_j = 1/3$. Za svaki kriterij se postavlja matrica procjene A_j.

3.2 Matrica omjera alternativa odlučivanja

Procjene koje su izračunate i iznijete u A_j predstavljaju uočene relacije između n alternativa. U analizi alternativa odlučivanja vrlo često se primjećuje da su mnogi kriteriji subjektivni i zahtjevaju da se razvije tzv. matrica procjene. Ponekad postoji objektivna baza mjerenja, npr. povrat investicije. Ako postoji objektivna mjera, nije potrebno procjenjivati, budući da se pretpostavlja, da mjerna vrijednost svake alternative odlučivanja odražava adekvatno relativni intenzitet. Te mjerne vrijednosti mogle bi se koristiti za razvoj matrice omjera tipa n x n . Matrica omjera R je komponirana od elemenata koji su omjer vrijednosti pridružene svakoj alternativi. Elementi matrice omjera r^{kh}_j predstavljaju omjer vrijednosti k-te alternative u odnosu na vrijednost h-te alternative po j-tom kriteriju. Treba uočiti: ulazi u matricu omjera r^{kh}_j imaju svojstva koja su pretpostavljena i za matricu procjene A_j, t.j. $r^{kh}_j = 1$ kada je k = h i $r^{kh}_j = (r^{kh}_j)^{-1}$.

3.3 Matrica procjene kriterija

Da bi se zadovoljili zahtjevi sistematske analize, svaki kriterij mora biti procijenjen u pogledu njegove važnosti u postizanju cilja institucije. Svakom paru opraka dat će se ordinalni deskriptor iz skale 1...9 i ubilježit će se u matricu C kako slijedi:

$$C = c^{kh} \qquad \begin{aligned} k &= 1,\dots,m \\ h &= 1,\dots,n \end{aligned}$$

gdje se primjenjuje ista konvencija matričnih ulaza kao i kod A_j. Matrica procjene kriterija predstavlja eksplicitnu vezu između kriterija onako kako su zapaženi da utječu na postizanje ciljeva investicije (npr.). Kada su jednom poznate informacije, procjene i omjeri u matricama A_j, R_j, i C, može se pojmovno zamisliti kompletna postava eksplicitno zabilježenih internih relacija u pojedinoj matrici računanjem svojstvenog vektora koji se pojmovno dovodi u vezu s maksimalnom svojstvenom vrijednošću matrice. Da bi se olakšala usporedba između elemenata, svojstveni vektor se normalizira na taj način da suma ulaza u vektor n x 1 bude jednak jedan. Ulazi u taj normalizirani svojstveni vektor imat će vrijednosti koje su konzistentne s relativnim intenzitetom kako je to zabilježeno u matrici iz koje je izračunat svojstveni vektor.

4. PRILAGODAVANJE SVOJSTVENOG VEKTORA

Oblik matrice procjene i matrice omjera pogodan su okvir u kojem se procjenjuju dostupne informacije za pojedini kriterij i skaliraju alternative odlučivanja na taj način da interalternativna tranzitivnost ostane očuvana.

Može se pokazati da je najveća svojstvena vrijednost (bilježimo je λ_{max}) matrice koja ima tranzitivne elemente jednaka veličini matrice. Zbog toga je $\lambda_{max} = n$ za matricu procjene kod koje su sve vrijednosti dodijeljene alternativama tranzitivne. Ako se pojavi greška procjene i ako je neki skup alternativa skaliran na taj način da elementi matrice procjene nisu više trazitivni, svojstvena vrijednost λ_{max}, bit će veća od n. Što je veća greška procjene, to je veća netranzitivnost i veće postaje λ_{max}. Za matricu procjene neke određene veličine postoji neki limit λ_{max}. Maksimalno moguća vrijednost koju može postići λ_{max} označit ćemo s λ_{sup} pojavit će se kada je matrica procjene ovog oblika:

$$B = \begin{vmatrix} 1 & 9 & 1/9 & \cdot\cdot \\ 1/9 & 1 & 9 & \cdot\cdot \\ 9 & 1/9 & 1 & \cdot\cdot \\ \cdot & \cdot & \cdot & \cdot\cdot \\ \cdot & \cdot & \cdot & \cdot\cdot \end{vmatrix}$$

Matrica B je matrica procjene u kojoj su elementi na dijagonalama paralelnim s glavnom dijagonalom jednaki svojim recipročnim vrijednostima koje se nalaze na paralelnim dijagonalama s druge strane glavne dijagonale. Elementi u B su apsolutno netranzitivni. Budući da greška procjene uzrokuje pomak λ_{max} koji od n stiže do granice na kojoj je λ_{max} najveći, relativna netranzitivnost pojedine matrice procjene može se izračunati iz slijedećeg omjera:

$$\theta_j = \frac{\lambda_{max - n}}{\lambda_{sup - n}} \tag{4}$$

gdje θ_j predstavlja relativnu netranzitivnost elemenata matrice koja je razvijena po j-tom kriteriju.

Vrijednost θ_j za matricu koja ima samo tranzitivne elemente je nula budući da je $\lambda_{max} = n$. Kako greška procjene uzrokuje netranzitivnost, postaje λ_{max} veći od n i dostiže λ_{sup}. Kvalitet procjena zavisi o tranzitivnosti procjene. Svojstveni vektori koji su izračunati iz matrica koje posjeduju neki srednji stupanj netranzitivnosti preračunavaju se u vektore u kojima je naglašena relativna tranzitivnost. To se postiže na taj način da se svojstveni vektor koji je dobiven iz j-te matrice množi s $1 - \theta_j$ kako slijedi:

$$\bar{w}_j = \bar{a}_j (1 - \theta_j) \tag{5}$$

gdje $\bar{a}_j$ predstavlja svojstveni vektor pridružen maksimalnoj svojstvenoj vrijednosti matrice A_j.

Treba uzeti u obzir da je relativna tranzitivnost samo jedna mjera kvaliteta informacija koje se uzimaju u obzir prilikom procjene. Bolje bi bilo kada bi postojali statistički indikatori koji bi pokazivali kakva je stvarna veza podataka iz procjene sa stvarnošću. Nažalost, u mnogim slučajevima kada se procjenjuju alternative odlučivanja takva statistika ne postoji.

Prilagođeni svojstveni vektori kojih ima m koriste se kao stupci u matrici tipa n x m:

$W = (\bar{w}_1\ \bar{w}_2 ... \bar{w}_m)$

Matrica W predstavlja relativni intenzitet n alternativa odlučivanja za svaki od m kriterija. Radi toga, informacije koje su zabilježene u mn x m matricama sada su prikazane kompaktno u jednoj matrici tipa n x m. Slijedeći korak se sastoji u razvoju prioritetnih težina i zahtjeva da matrica procjene mora biti razvijena po m kriterija. Zato će se svaki od m kriterija procijeniti po njegovoj relativnoj važnosti u postizanju cilja institucije. Kada se jednom odredi C, njegov će se svojstveni vektor pridružen maksimalnoj svojstvenoj vrijednosti izračunati i zapisati kao $\bar{v}$. Elementi u $\bar{v}$ predstavljaju relativnu važnost m kriterija koji su sadržani u C. Važno je uočiti da nije jednostavno sistematski uzimati u obzir netranzitivnost matrica kriterija u razvoju finalnog skupa prioritetnih težina.

Budući da se konačni prioritetni vektor normalizira, skaliranje $\bar{v}$ s $1 - \theta_c$ neće utjecati na relativnu vrijednost konačnog prioritetnog vektora. Problem nastaje u slučaju kad je rang C paran broj, jer ako je m paran broj a elementi od C su potpuno netranzitivni, vektor $\bar{v}$ neće biti neutralan, sve vrijednosti u vektoru neće biti identične. Poželjno je da se dobiju elementi $\bar{v}$ koji su jednaki 1/m kad su elementi C apsolutno netranzitivni budući da neutralni vektor važe jednako sve kriterije. Ako je poznata matrica alternativnih odluka, W, i normalizirani svojstveni vektor $\bar{v}$ koji predstavlja relativnu važnost od m kriterija, onda se prioritetne težine za n alternativa računaju ovako:

$$\frac{W\bar{v}}{e^T W \bar{v}} = \bar{r}^* \tag{6}$$

gdje je e^T vektor koji se sastoji od samih jedinica. Elementi od $\bar{r}^*$ predstavljaju prioritetne težine pridružene alternativama odlučivanja. Prioritetna težina reflektira relativnu važnost svake od n alternativa odlučivanja uzimajući u obzir relativnu važnost svake alternative odlučivanja prema svakom kriteriju i važnost kriterija. Radi toga one alternative odlučivanja koje su zabilježene u W a koje su relativno preferirane prema kriterijima koji su relativno važni bit će zastupljene u finalnom prioritetnom vektoru.

5. MOGUĆNOSTI PRIMJENE

Prije nego se navedu moguće primjene analitičkog hijerarhijskog procesa ilustrirat će se Luskov model prioritetne dodjele[11] koji se temelji na konceptu analitičkog hijerarhijskog procesa.

U okviru nekog investicijskog procesa od rukovodstva neke veće bolnice se zahtijeva da ustanove kriterije po kojima bi se vrednovale tri moguće investicijske alternative. Posebno se zahtijeva od rukovodstva, da uoči kriterij koji je najvažniji za ekonomski rast institucije. Te informacije daju se timu koji je zadužen za projekt, u kojemu se treba odlučiti o alternativi koju treba konačno izabrati.

U ovom slučaju je interesantno da se ispita kako se koristi model prioritetne dodjele u razvoju informacija koje su dostupne timu koji radi na projektu.

Kriteriji po kojima treba vrednovati alternative odlučivanja su:

C_1 = interna kamatna stopa: izračunata na temelju računovodstvenih podataka i izražena u postotku;

C_2 =poboljšani status bolnice, izveden iz procjene

C_3 = porast kapaciteta prihvata pacijenata, izveden iz procjene

Tri moguće alternative koje se mogu vrednovati po navedenim kriterijima su:

a_1 = obnova i adaptacija postojećeg prostora koji se može preurediti tako da se dobije novi ambulantni prostor;

11) Lusk,E.,idem str. 443-444.

a_2 = nova struktura: jednokatna zgrada, ambulante na katu, administracija u prizemlju;

a_3 = nova struktura: dvokatna zgrada, ambulante na prvom katu, pomoćne prostorije na drugom katu.

Prvi kriterij predstavlja objektivnu mjeru za sve tri alternative. Naime, interna kamatna stopa za moguće alternative iznosi $a_1 = 0,137$, $a_2 = 0,421$, $a_3 = 0,097$. Radi toga nije potrebno procijeniti parove za taj kriterij već odmah prijeći na određivanje matrice omjera:

$$R_1 = \begin{vmatrix} \frac{0,137}{0,137} & \frac{0,137}{0,421} & \frac{0,137}{0,097} \\ \frac{0,421}{0,137} & \frac{0,421}{0,421} & \frac{0,421}{0,097} \\ \frac{0,097}{0,137} & \frac{0,097}{0,421} & \frac{0,097}{0,097} \end{vmatrix} = \begin{vmatrix} 1 & 0,325 & 1,412 \\ 3,08 & 1 & 4,34 \\ 0,708 & 0,23 & 1 \end{vmatrix}$$

Za zadnja dva kriterija nema objektivnih mjerila, zbog toga je potrebno razviti matricu procjene. Za drugi kriterij (status bolnice) su pretpostavljeni slijedeći odnosi preferencija u odnosu na tri investicijske alternative: a_3 je slabo preferirana (umjereno) a_1; a_1 je slabo preferirana a_2; a_3 je apsolutno preferirana (ekstremno) a_2. Te vrijednosti su ubilježene u matricu:

$$A_2 = \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix} = \begin{vmatrix} 1 & 3 & 1/3 \\ 1/3 & 1 & 1/9 \\ 3 & 9 & 1 \end{vmatrix}$$

Rezultat procjene tri alternativne investicije po trećem kriteriju (porast kapaciteta) ubilježen je u slijedeću matricu:

$$A_3 = \begin{vmatrix} 1 & 1/7 & 3 \\ 7 & 1 & 1/7 \\ 1/3 & 7 & 1 \end{vmatrix}$$

Svojstveni vektori pridruženi maksimalnoj svojstvenoj vrijednosti su:

$R_1{:}r_1 = (o,21 \;\; 0,64 \;\; 0,15\,)^T$

$A_2{:}a_2 = (0,23 \;\; 0,08 \;\; 0,69)^T$ i

$A_3{:}a_3 = (0,24 \;\; 0,33 \;\; 0,43\,)^T$

Svojstveni vektor R_1 sugerira da je druga alternativa najpoželjnija. Analogno tome, svojstveni vektor A_2 pokazuje da je prema procjeni po drugom kriteriju, alternativa dva najmanje poželjna.

Vrijednost λ_{max} za matricu omjera i dvije matrice procjene iznose:

R_1: $\lambda_{max} = 3$; A_2: $\lambda_{max} = 3$; A_3: $\lambda_{max} = 6,5$

Na temelju jednadžbe (4) računa se $_j$ za R_1, A_2 i A_3 kako slijedi:

$$\theta_1 = \frac{\lambda_{max} - n}{\lambda_{sup} - n} = \frac{3 - 3}{1o,1-3} \quad \theta_2 = \frac{3 - 3}{10,1-3} \quad \theta_3 = \frac{3,5}{7,1}$$

gdje je λ_{sup} maksimalna svojstvena vrijednost slijedeće matrice:

$$B = \begin{vmatrix} 1 & 9 & 1/9 \\ 1/9 & 1 & 9 \\ 9 & 1/9 & 1 \end{vmatrix}$$

Prema jednadžbi (5) prilagođavaju se $\bar{r}_1$, $\bar{a}_2$, i $\bar{a}_3$ relativnoj tranzitivnosti. U tom smislu se obrazuje matrica:

$$W = \begin{array}{c} \begin{array}{ccc} \bar{w}1 & \bar{w}2 & \bar{w}3 \end{array} \\ \begin{vmatrix} 0,21 & 0,23 & 0,122 \\ 0,64 & 0,08 & 0,168 \\ 0,15 & 0,69 & 0,220 \end{vmatrix} \end{array}$$

Slijedeći element koji se mora formulirati u analizi je matrica procjene kriterija:

$$C = \begin{array}{c|ccc|} & C_1 & C_2 & C_3 \\ C_1 & 1 & 3 & 3 \\ C_2 & 1/3 & 1 & 1 \\ C_3 & 1/3 & 1 & 1 \end{array}$$

U ovom slučaju rukovodstvo bolnice je bilo mišljenja da kriterij 1 treba umjereno preferirati u odnosu na kriterije C_2 i C_3 dok se kriteriji 2 i 3 jednako preferiraju. Normalizirani svojstveni vektor pridružen maksimalnoj svojstvenoj vrijednosti od C je $\bar{v} = (0,6 \;\; 0,2 \;\; 0,2)^T$ Za poznato W i $\bar{v}$ računaju se prioriteti dodijeljeni alternativama odlučivanja:

$$\bar{i}^* = \left\| \begin{matrix} 0,21 & 0,23 & 0,122 \\ 0,64 & 0,08 & 0,168 \\ 0,15 & 0,69 & 0,220 \end{matrix} \right| \bullet \left| \begin{matrix} 0,6 \\ 0,2 \\ 0,2 \end{matrix} \right\| : 0,902 = \begin{vmatrix} 0,218 \\ 0,491 \\ 0,301 \end{vmatrix}$$

Budući da je interna kamatna stopa procijenjena kao najvažniji kriterij, a ona je kod druge alternative najveća, to se ta alternativa preferira ostalim. Ovaj jednostavni primjer pokazuje kako se konačni vektor prioriteta, $\bar{i}^*$ sistematski razvija iz eksplicitnih informacija.

O primjeni analitičkog hijerarhijskog procesa kao rutinskoj osnovi u kompleksnim analizama politike planiranja izvještavaju mnogi stručni članci[12] Ta nova teorija[13] bila je uspješno primjenjena na različitim područjima. Posebno treba istaknuti rješavanje problema alokacije energije u industriji; konstrukcije transportnog sistema u Sudanu; planiranje budućnosti velikih firmi i mjerenje utjecaja faktora okruženja njihovu budućnost; postavljanje budućeg scenarija visokog obrazovanja u SAD; kandidacijskih i izbornih procesa; određivanje prioriteta za vrhunske znanstvene institute u zemljama u razvoju. Interesantna primjena analitičkog hijerarhijskog procesa moguća je na području marketinga, odnosno marketinškog odlučivanja.[14] Između ostalih, ovom metodologijom se mogu rješavati problemi ciljnog proizvoda, tržišta, distribucije, gene-

12) Harker, P.T., Vargas,L.G., idem, str.1383.

13) Saaty,T.L., idem 8) str.855,

14) Wind,Y., Saaty,T.L., Marketing applications of the analytic hierarchy process, Managment Science, br.7, 1980, str.656-657.

riranja i procjene koncepta novog proizvoda, određivanje marketing-mixa. Analitički hijerarhijski proces koji se primjenjuje na spomenutim problemima pruža specifičan vodič za alokaciju resursa između postojećih i potencijalnih proizvoda neke firme, za izbor jedne između više ideja o novom proizvodu, za izbor različitih marketing-mix strategija u situacijama alternativnih uvjeta okruženja i različitih ciljeva.

Konceptualno unapređenje analitičkog hijerarhijskog procesa i iskustva koja bi se tim u vezi prikupila moglo bi dovesti do važnog proširenja arsenala modela odlučivanja i dostignuća u pogledu mjerenja.

Dražen Barković, Ph.D.

Summary

ANALYTIC HIERARCHY PROCESS: A PRIORITY ASSIGNMENT MODEL

This paper presents a priority assigment model which uses judgmental transitivity as a measure of the quality of the judgments rendered, and provides for mathematical integration of the quality adjusted judgmental information into development of priority weights. Various operational aspects of the model and possible applications are examined.