Hijerarhijsko odlučivanje

Do sada smo se bavili odlučivanjem uz pomoć tablica odlučivanja, te kombiniranjem tablica odlučivanja pomoću stabla odlučivanja. Ipak, čak i kad odlučujemo o malom broju alternativa, tablice odlučivanja mogu biti nepraktične u situacijama kada treba dati subjektivne ocjene.

Tipičan primjer je razgovor s kandidatima za neko radno mjesto. Ako voditelj intervjua koristi tablicu odlučivanja, on mora ocijeniti sve kandidate nekom ocjenom (u nekoj skali, npr. 0-9). Kako odlučiti kojem kandidatu dati koju ocjenu? Psihologija pokazuje ljudski mozak funkcionira jednodimenzionalno, tj. na razini usporedbe dva objekta. Vrlo je teško dati definitivne (ali subjektivne!) ocjene većem broju objekata.

Problem se dodatno komplicira uvođenjem kriterija. Recimo, ako tražimo novog uposlenika za mjesto kontrolora u tramvaju, važni kriteriji mogu biti *odnos prema ljudima*, *pojava* (nekako, čisto psihologije radi, zdravo je da je "malo krupniji"), *stav prema ljudima koji se "švercaju"*,... Lako je kad je jedan kandidat nadmoćan ostalima po svim kriterijima, no to se u praksi jako rijetko događa. Kako riješiti taj problem?

Jedan način je, naravno, taj da za svaki kriterij damo ocjene svim kandidatima, no takvo rješenje multiplicira početni problem – ocjenjivanje većeg broja alternativa u odnosu na jedan kriterij.

Postoje mnoge metode koje se bave uspoređivanjem po parovima. Mi ćemo razmotriti dvije: Saatyjevu metodu svojstvenog vektora i Metodu potencijala.

AHP

AHP – analytic hierarchy process. Pristup koji je 1980. utemeljio Thomas L. Saaty. Ideja je naizgled slična stablu odlučivanja: problem raščlanjujemo na manje podprobleme koji su međusobno hijerarhijski ovisni. Ono što je ovdje bitno drugačije, ovisnost u hijerarhiji označava (jako pojednostavljeno) "tko o kome odlučuje", dok je stablo odlučivanja označavalo kronološku ovisnost odluka, novih spoznaja i stanja svijeta.

Prisjetimo se primjera "Minimizacija gubitka" s prvih vježbi. Tamo smo se bavili odlukom koju smo donosili isključivo po kriteriju dobiti (odnosno gubitka) financijskih sredstava. Ipak, procjenu profitabilnosti takve priredbe u praksi je gotovo nemoguće dati. Puno realističnije bi bilo uzeti u obzir *popularnost predloženih aktivnosti*, *prikladnost* (zbog očekivanih vremenskih prilika), *očekivanu uspješnost* (ako je slična manifestacija bila nedavno, možda nova neće biti tako zanimljiva),... Jasno je da će vjerojatno i natjecanje i zabava po nekim kriterijima biti značajni. Koga preferirati u takvoj situaciji?

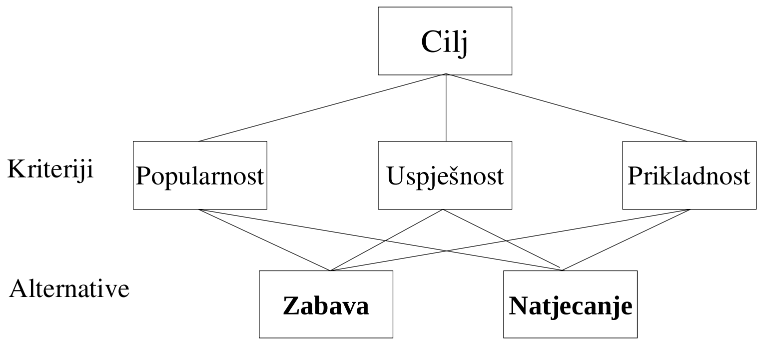

Postupak je, u biti, prirodan. Najprije treba odrediti "klase" objekata (zvat ćemo ih "nivoi"). U našem primjeru to su *nivo kriterija* i *nivo alter-nativa*. Kriteriji mogu biti razni i njih određuju stručnjaci za određeno područje. U našem primjeru, to mogu biti gore nabrojani. Skup alternativa je jednoznačno određen – to su objekti o čijim preferencama odlučujemo.

Grafički, hijerarhiju prikazujemo kao na slici.

U ovom trenutku, veze među čvorovima su manje-više ukras. U složenijim primjerima, te će veze dočaravati stvarnu podređenost, odnosno nadređenost, među objektima. Kako interpretiramo hijerarhiju?

“Cilj” je ono što želimo postići. Hijerarhija uvijek ima jedinstveni cilj.

Najprije je potrebno na neki način rangirati kriterije. “Rangirati”, u ovom kontekstu, ne znači samo “poredati”, nego “dodijeliti težine”. Pri tome sume težina obično normiramo 1-normom.

Nakon što smo rangirali kriterije, potrebno je rangirati alternative **u odnosu na svaki kriterij posebno**. Tek kad je to gotovo, računamo konsenzus – rangiranje koje će uzeti u obzir i težine kriterija i težine alternativa u odnosu na kriterije. Konsenzus će nam dati novo rangiranje alternativa.

Primijetimo da postupak možemo nastaviti rekurzivno koliko god je potrebno, što navodi na zaključak da hijerarhije mogu imati proizvoljnu (ili, bolje, bilo koju potrebnu) dubinu.

Na hijerarhiju se postavljaju sljedeća dva zahtjeva:

- **Nezavisnost**. Kriteriji ne ovise o alternativama
- **Očekivanje**. U hijerarhiju su uključeni svi relevantni kriteriji i sve alternative.

Naglasimo još da rangiranje alternativa po kriterijima ne mora biti *a priori* potpuno, tj. neke alternative možemo rangirati po jednom kriteriju, a neke po drugom. Stvar je konsenzusa (tj. primijenjene metode odlučivanja) kako tada dobiti odluku.

Uspoređivanje po parovima

Prije nego se osvrnemo na AHP metode odlučivanja, uvedimo pojam **uspoređivanja po parovima** – uz hijerarhiju ključan pojam za multikriterijalno odlučivanje pomoću hijerarhija.

Iako je intuitivno jasno o čemu je riječ, ipak je potrebna stanovita doza formalizma.

Neka su a_i i a_j alternative koje želimo usporediti u odnosu na kriterij c_k. Imamo sljedeće mogućnosti:

1. Donositelj odluke je indiferentan, tj. alternative a_i i a_j su jednako preferirane u odnosu na kriterij c_k
2. Donositelj odluke preferira alternativu a_i pred a_j u odnosu na kriterij c_k
3. Donositelj odluke preferira alternativu a_j pred a_i u odnosu na kriterij c_k

Dodatno, nije dovoljno reći koju alternativu preferiramo; potrebno je odrediti i težinu preference. Saaty je predložio: *slabu*, *jaku*, *vrlo jaku* i *apsolutnu* prednost.

Ovo su opisne preference. Njima pridružujemo odgovarajuću skalu (numeričku reprezentaciju). Iako ima mnogo skala koje su u upotrebi, generalno ih možemo podijeliti u nekoliko grupa: omjerne, intervalne i nominalne. Mi ćemo se baviti samo omjernim skalama.

Usporedbi alternativa a_i i a_j u odnosu na kriterij c_k pridružujemo broj $x_{ij}^{(c_k)}$ (obično je jasno iz konteksta o kojem kriteriju je riječ, pa ćemo pisati samo x_{ij}. Prva skala je bila linearna:

1. $x_{ij}=1$ ako su a_i i a_j jednako preferirane
2. $x_{ij}=3$ ako alternativa a_i ima slabu prednost pred a_j
3. $x_{ij}=5$ ako alternativa a_i ima jaku prednost pred a_j
4. $x_{ij}=7$ ako alternativa a_i ima vrlo jaku prednost pred a_j
5. $x_{ij}=9$ ako alternativa a_i ima apsolutnu prednost pred a_j

Primijetimo da nismo zadali skalu za slučajeve prednosti alternative a_j nad a_i. Taj dio skale je jednoznačno određen na temelju upravo danih vrijednosti.

Bez obzira na odabranu skalu, uspoređivanje po parovima mora zadovoljavati dva osnovna principa:

- **Recipročnost**. Donosilac odluke mora biti u stanju uspoređivati alternative i iskazati snagu svojih prioriteta. Jačina tih prioriteta mora zadovoljavati uvjet: $x_{ij}=1/x_{ji}$.
- **Homogenost**. Prioriteti su predstavljeni ograničenom skalom.

Ako je donositelju odluke potrebna dodatna preciznost u izražavanju, možemo uvesti i međuvrijednosti 2, 4, 6 i 8.

Navedimo još neke primjere skala:

- **Linearne**. Ovaj pojam ne treba uzeti "bukvalno"; neke od skala su, u stvari, afine. Primjeri linearnih skala: $[\alpha \cdot x]$, $\alpha > 0$, $\alpha + 0.x$, $\alpha \in \{1, 2, 3, 4\}$
- **Potencijalne**: $x^{\alpha}, \alpha \in \{1/2, 2, 3, 4, 5\}$
- **Eksponencijalne**: $2^{(x-1)/2}$, $9^{(x-1)/8}$

Varijabla x označava odgovarajuću vrijednost u prikazanoj skali 1-9.

Uz uspoređivanje po parovima prirodno se veže još jedan pojam:

Konzistentnost

Neka su dane tri alternative: a_1, a_2 i a_3. Ako donositelj odluke preferira alternativu a_1 nad alternativom a_2 i alternativu a_2 nad alternativom a_3, razumno bi bilo očekivati i da preferira alternativu a_1 nad alternativom a_3 i to intenzitetom koji je jednak ili veći od $max\{x_{12,} x_{23}\}$.

Definicija. Za matricu uspoređivanja $A=(x_{ij})$ kažemo da je konzistentna ako i samo ako vrijedi: $x_{ik}=x_{ij} \cdot x_{jk}$, za proizvoljne i, j, k

U praksi, konzistentnost se gotovo nikada ne postiže. Osnovni razlozi su ljudska psiha i nesavršenost mjernih skala. Većina metoda daje neki način mjerenja (in) konzistentnosti. Pritom se interpretacija te mjere ostavlja na slobodu samoj metodi, no mora vrijediti uvjet da je inkonzistentnost jednaka nuli ako i samo ako je matrica usporedbi konzistentna.

Važno je naglasiti da se konzistentnost ne smije forsirati. Mnogi donositelji odluka, suočeni s konceptom konzistentnosti, počnu računati procjene kako bi bili što konzistentniji. No, time se uvodi nepostojeća međuovisnost alternativa što lako može dovesti do ovisnosti konačne odluke o redoslijedu izvođenja usporedbi.

Donositelj odluke mora dati procjene onako kako on smatra da su ispravne. Faktor (in)konzistentnosti može poslužiti kao nekakva mjera ili korektivni faktor tek nakon što su dane sve usporedbe.

Metoda svojstvenog vektora

Saaty, pokretač AHP metode za dobijanje svojstvenog vektora, koristi tzv. metodu potencija koja se temelji na Perron - Frobeniusovom teoremu.

Teorem 1 (Perron - Frobenius)

Neka je A ≥ 0 zadana matrica. Tada vrijedi:

(1) A ima realnu pozitivnu jednostruku svojstvenu vrijednost $\lambda_{\max}$, za koju vrijedi $\lambda_{\max} \geq \lambda$, za svaku drugu svojstvenu vrijednost λ

(2) Svojstveni vektor koji pripada svojstvenoj vrijednosti $\lambda_{\max}$ ima sve nenegativne komponente i jedinstven je do na množenje pozitivnim brojem.

(3) $\lambda_{\max}$ ima mini-max karakterizaciju $\lambda_{\max} = \max\limits_{x \geq 0} \min\limits_{1 \leq i \leq n} \frac{(Ax)_i}{x_i} = \min\limits_{x \geq 0} \max\limits_{1 \leq i \leq n} \frac{(Ax)_i}{x_i}$

Teorem ovdje nećemo dokazivati, ali ćemo dati neke ključne pojmove i smjernice dokaza. Prvi takav pojam je funkcional Minkowskog.

Kažemo da je vektor x manji od vektora y i pišemo $x \leq y :\Leftrightarrow x_i \leq y_i \forall i$ .Uz pomoć ove definicije možemo definirati funkcional Minkowskog. Neka je $e > 0$ neki vektor. Funkcional Minkowskog je otvoren konveksan skup $B_e = \{x \in \mathbb{R}^n | -e < x < e\}$

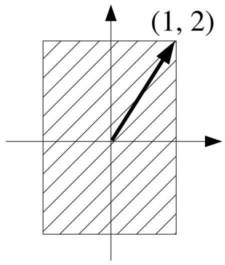

U dimenziji 2, za npr. $e = (1,2)$ prostor Minkowskog izgleda kao na slici desno.

U tom prostoru možemo definirati normu: $\|x\|_e = \inf\{t > 0 | x \in t\, B_e\}$. Lako je provjeriti da je to dobro definirana norma.

Ako je $A = (a_{ij})$ pozitivna matrica (tj. $a_{ij} > 0 \forall i, j$), tada matrica A čuva uređaj, tj. vrijedi: $x \leq y \Leftrightarrow Ax \leq Ay$. Odatle trivijalno slijedi: ako je $w \geq 0$ svojstveni vektor od A, tada je $w > 0$ i pripadna svojstvena vrijednost λ je pozitivna.

Ako je $A = (a_{ij}) > 0$ tada postoje jedinstveni pozitivni svojstveni vektor matrice A i pripadna svojstvena vrijednost λ koja je jednaka spektralnom radijusu $\rho(A) = \max\limits_{\lambda \in \sigma(A)} \{\|\lambda\|\}$.

Neka je $e = (1, 1, \ldots, 1)$ .Tada je $\lim\limits_{n \to \infty} \frac{A^n e}{e^T A^n e} = \alpha w,\ \alpha > 0$. Također, vrijedi i: $\|\cdot\|_e = \|\cdot\|_{max}$ i $e^T A^n e = \|A^n e\|_1$.

Definiramo niz: $z_n := \frac{A^n e}{\|A^n e\|_1} = \frac{A^n e}{\|A^n e\|_e} \cdot \frac{\|A^n e\|_e}{\|A^n e\|_1}$. Očito je da se niz z_n sastoji od umnožaka dva konvergentna niza, pa je onda i sam konvergentan. Koristeći opisane rezultate, možemo dati i samu metodu svojstvenog vektora.

Za početak, pretpostavimo da je dana konzistentna matrica usporedbi:

$$A=\begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \cdots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \cdots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \cdots & \frac{w_n}{w_n} \end{bmatrix}=\begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}\begin{bmatrix} \frac{1}{w_1} & \cdots & \frac{1}{w_n} \end{bmatrix}$$

Ako matricu A pomnožimo s desna vektorom $w=(w_1, w_2, \ldots, w_n)^T$, dobit ćemo:

$$Aw=\begin{bmatrix} & & \\ & \frac{w_i}{w_j} & \\ & & \end{bmatrix}\begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}=n\begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}$$

Dakle, n je svojstvena vrijednost, a $w=(w_1, w_2, \ldots, w_n)^T$ pripadni svojstveni vektor matrice A. Štoviše, matrica A ima rang 1 (jer se svaki redak može dobiti množenjem prvog retka odgovarajućim skalarom). Zato su sve njene svojstvene vrijednosti, osim jedne, jednake nuli. Suma svojstvenih vrijednosti matrice jednaka je njenom tragu, tj. sumi dijagonalnih elemenata. U našem slučaju, suma je očito n. Dakle, n je najveća ili vodeća svojstvena vrijednost matrice A.

Rješenje w jednadžbe $Aw=nw$, koje zovemo vodeći desni svojstveni vektor od A, ima pozitivne komponente i jedinstveno je do na multiplikativnu konstantu. Da bi w bilo u potpunosti jedinstveno rješenje, dodajemo jednadžbu $\|w\|_1=1$, tj. normiramo dobiveni vektor w. Jasno je da iz dane matrice A možemo rekonstruirati vektor w: on je normalizirana verzija proizvoljnog stupca od A.

Kao što smo već rekli, u praksi ne možemo očekivati da će donositelj odluke dati konzistentnu matricu usporedbi. Pokušajmo i u tom slučaju riješiti identičan problem:

$$Aw=\lambda_{\max} w, \quad A \text{ nije nužno konzistentna}$$

Rješenje ove jednadžbe je:

$$w=\lim_{k\to\infty} \frac{A^k e}{e^T A^k e}, \quad e=(1, 1, \ldots, 1)^T$$

Primijetimo da je matrica $\begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \cdots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \cdots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \cdots & \frac{w_n}{w_n} \end{bmatrix}$ konzistentna aproksimacija od A.

Prisjetimo se još: $e^\tau A^n e = \|A^n e\|_1$, tj. vrijedi: $w = \lim_{n \to \infty} \frac{A^n e}{\|A^n e\|_{max}}$. U praksi, niz $\frac{A^n e}{\|A^n e\|_{max}}$ brzo konvergira, pa je potrebno računati samo za nekoliko vrijednosti n.

Pripadna svojstvena vrijednost $\lambda_{\max}$ više nije jednaka n. Dapače, vrijedi: $\lambda_{\max} > n$, pa inkonzistentnost možemo mjeriti brojem $\lambda_{\max} - n$ (koji je jednak nuli ako i samo ako je matrica A konzistentna!).

Saaty je odabrao nešto drugačiju mjeru inkonzistentnosti:

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

CI zovemo indeks konzistentnosti (engl. *consistency index*). Tu vrijednost zatim uspoređuje s tzv. slučajnim indeksom (engl. *random index*), koji se dobije kao prosječan CI za velik broj slučajno generiranih recipročnih matrica istog reda. Ako je omjer $\frac{CI}{RI}$ – zvan omjer konzistentnosti – manji ili jednak 0.1, tada se prihvaća pripadna procjena w stvarnog vektora težina. U protivnom smatramo da procjene nisu bile dovoljno konzistentne da bi na njima bazirali odluku.

Metoda potencijala

Čaklović, tvorac Metode potencijala, krenuo je drugim smjerom. Što bi se desilo kad usporedbe ne bismo zapisali u matricu, nego u usmjereni graf? Preciznije, kreiramo graf kojem su vrhovi alternative, a lukovi predstavljaju usporedbe i to na slijedeći način:

$$F_{(a_i, a_j)} = \begin{cases} f > 0 & a_j \text{ preferirano u odnosu na } a_i \\ 0 & a_i \text{ i } a_j \text{ podjednako preferirani} \\ f < 0 & a_i \text{ preferirano u odnosu na } a_j \\ \perp\text{đ} & a_i \text{ i } a_j \end{cases}$$

F zovemo tok. Luk između vrhova a_i i a_j postoji ako i samo ako je $F_{(a_i, a_j)}$ definiran i nenegativan. Lukovi očito pokazuju u smjeru "jače" alternative.

Primjetimo odmah u startu važnu osobinu Metode potencijala: **nije nužno usporediti sve alternative**! Dapače, nastali graf ne mora ni biti povezan. Uvjet na povezanost je, čak i u najjednostavnijoj varijanti metode, bitno slabiji.

Tokove kreiramo za sve kriterije i zatim radimo kompromis – prije nego izvedemo rangiranje! Prisjetimo se, kod Metode svojstvenog vektora, trebalo je prvo rangirati alternative po svim kriterijima, pa tek onda napraviti konsenzus. Rangiranje je kod Metode svojstvenog vektora prilično složena operacija (višestruko množenje matrica), pa metoda postaje prilično spora na velikim primjerima.

Tek kad smo dobili kompromisni tok, vršimo rangiranje rješavanjem sustava jednadžbi.

Kako kreiramo kompromisni tok? Slično funkciji vrijednosti. Neka su dani tokovi $(F_k)_{k=1}^m$ (za svaki kriterij jedan tok). Tada kompromisni tok definiramo na slijedeći način:

$$F(a_i, a_j) = \begin{cases} \sum_{k=1}^{m} F_k(A_i, a_j) & \text{ako postoji tok } F_k \text{ u kojem su } a_i \text{ i } a_j \text{ povezani} \\ \perp & \text{i} \end{cases}$$
e

Kao što vidimo, kompromis može jako povećati povezanost toka. Ako ni kompromisni tok nije povezan, metoda djeluje na komponentama povezanosti. Ipak, u takvom slučaju, ukupna odluka može biti problematična. To nas dovodi i do konačnog uvjeta na povezanost toka: kompromisni tok treba biti povezan.

Za kompromisni graf definiramo matricu incidencije po bridovima:

$$b_{\alpha,i} = \begin{cases} 1, & \alpha = (k, i) \\ -1, & \alpha = (i, k) \end{cases} \text{ za neki } k \in V$$

V je skup vrhova u usmjerenom grafu (tj. skup alternativa). Također, definiramo vektor toka: $F_\alpha = F(\alpha)$.

Potencijal X dobijemo rješavanjem matrične jednadžbe $B^T B X = B^T F$. Odakle baš ta jednadžba? Pretpostavimo na trenutak da je dani tok F potpun (tj. da je svaki par alternativa uspoređen po najmanje jednom kriteriju). Tada vrijedi:

$$(BX)_\alpha = x_j - x_i, \quad \text{za } \alpha = (a_i, a_j)$$

Ako uzmemo $(BX)_\alpha = F_\alpha$, tj. $BX = F$, onda se dobiveni potencijal slaže s viđenjem potencijala u, na primjer, električnim mrežama.

No, ako tok nije potpun, onda je potrebno naći odgovarajući tok na drugi način. Prva ideja bi mogla biti nadopunjavanje početnog toka do potpuno lukovima težine nula, no to bi dovelo do remećenja ulaznih podataka. Prisjetimo se: luk težine nula označava indiferentnost između dvije alternative.

Drugi način bi bio nadopunjavanje tako da se održi konzistentnost, tj. nadopunjavanje sumom s nekog drugog puta. No, čak ni neke konzistentne tokove tako ne bismo mogli tako nadopuniti (npr. slika desno, na skali 0-4, između A_1 i A_3 bi trebalo povući luk težine 8).

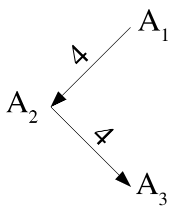

No, nema nikakvog posebnog razloga zašto i u ovom slučaju ne bismo rješavali jednadžbu od maloprije: $BX = F$. Pitanje je ima li sada ta jednadžba rješenje?

Odgovor na ovo pitanje je ujedno i karakterizacija konzistentnosti kod Metode potencijala: tok je konzistentan ako i samo ako jednadžba $BX = F$ ima rješenje.

U slučaju da rješenja nema, tj. ako je tok inkonzistentan, rješavamo jednadžbu $B^T B X = B^T F$. Pogledajmo geometrijsku interpretaciju.

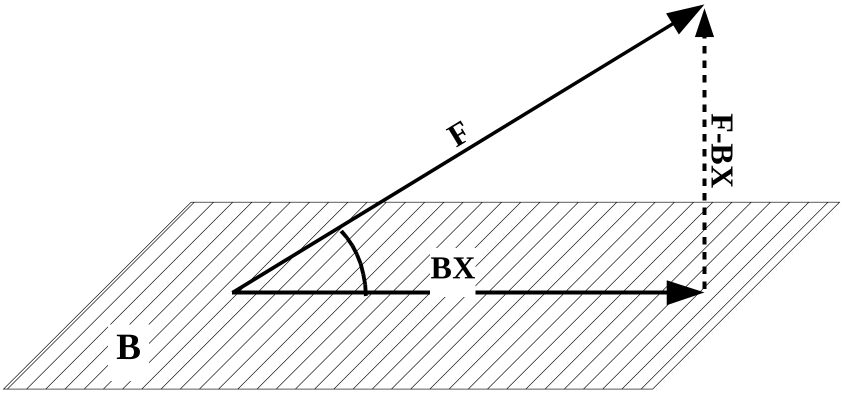

Mjera inkonzistentnosti kod Metode potencijala je $i(F)=\frac{\|F-BX\|}{\|BX\|}$, gdje je $\|\cdot\|$ euklidska norma na prostoru $\mathbb{R}^m$, a X konzistentni potencijal pridružen toku F. Primijetimo da je geometrijska interpretacija ovako definirane mjere inkonzistentnosti tangens kuta pod kojim se vektor F odmiče od prostora razapetog stupcima matrice B. Zato za mjeru inkonzistentnosti nije potrebno računati potencijal, nego ju je moguće dobiti direktno iz toka.

Parametri jednadže $B^\tau B X = B^\tau F$ su izuzetno laki za očitati s grafa:

$$\left(B^\tau B\right)_{ii} = \text{broj lukova incidentnih s vrhom } a_i$$

$$\left(B^\tau B\right)_{ij} = \begin{cases} -1, & \text{vrhovi } a_i \text{ i } a_j \text{ su povezani} \\ 0, & \text{vrhovi } a_i \text{ i } a_j \text{ nisu povezani} \end{cases}$$

$$\left(B^\tau F\right)_i = \sum_{\alpha \text{ incidentan s vrhom } a_i} F_\alpha$$

Nakon rješavanja matrične jednadžbe (tj. sustava linearnih jednadžbi), imamo potencijal X. Njega obično "pretvaramo" u vektor težina preko eksponencijalne funkcije: $w=\frac{2^X}{\|2^X\|}$, gdje je $2^X=\left(2^{X_1}, 2^{X_2}, \ldots, 2^{X_n}\right)$. Eksponencijalna funkcija je odabrana zbog prije navedenih otkrića u psihologiji.

Inače, rješenje normalne jednadžbe $B^\tau B X = B^\tau F$ je jedinstveno do na konstantu, pa uzimamo dodatni uvjet $\sum_{i=1}^n X_i = 0$.

Pogledajmo primjer izbora lokacije za izgradnju rafinerije (priložen, nastao u travnju 2000 kao dio rada za Rektorovu nagradu, autori R. Piskač i V. Šego).

Još malo o konzistentnosti

Uzmimo kao primjer raspravu u Parlamentu. Kad bi nekim čudom dotična "gospoda" dolazili do konsenzusa koristeći neku od metoda odlučivanja, gotovo uvijek bi imali veliku inkonzistentnost. Postavljaju se pitanja: Zašto? i Da li to znači da Parlament nije u stanju donijeti ispravnu odluku?

Odgovor na prvo pitanje je prilično jednostavan. Ako nije riječ o Kini, Kubi, Iraku i sl. državama, onda u Parlamentu postoje interesne grupacije. One u svojim odlukama mogu biti konzistentne (čak i monolitne!) iznutra. No, izvana, odnosno među pojedinim grupama, odluke mogu biti potpuno suprotne. To je prirodno (barem u terminima zapadne "demokracije").

Naravno, to ne znači da Parlament nije u stanju donijeti ispravnu odluku (iako on to u praksi stvarno i nije u stanju). Metoda potencijala daje dodatne mogućnosti u analizi ulaznih podataka. Tako možemo izvršiti *clusteriranje* – podjelu po interesnim grupama. Tada nam broj interesnih grupa i njihove unutarnje inkonzistentnosti daju puno više informacija o ulaznom toku od obične konzistentnosti.

Također, *clusteriranje* nam može ukazati na pojedinca (ili njih nekoliko) koji odstupa od ostatka grupe. Taj pojedinac može biti tendenciozan, nestručan ili nešto treće. Kako se nositi s tom pojavom, ostaje na donositeljima odluke. Metoda samo daje informaciju o takvoj pojavi.

Zaključak

Kao i uvijek kad je riječ o subjektivnim dojmovima (odlukama, procjenama i sl.), i AHP ima svoje razloge "za" i "protiv". Također, prikazane metode se međusobno razlikuju po primjenjivosti, složenosti i mnogim drugim faktorima. Na kraju priče, odabir metode koja će se primjenjivati može postati zasebni problem odlučivanja.☺

Ipak, utješno je da u praksi većina metoda daje slične, a često i identične poretke alternativa. Razlike obično nastaju ili kod nekonzistentnih odluka ili kod sličnih alternativa.

Za kraj, recimo još da je hijerarhija – koliko god izgledala prirodno – donekle ograničavajuća u primjenama. Jedan od težih problema odlučivanja, samorangiranje, ne može se prikazati hijerarhijom (jer kriteriji ne smiju ovisiti o alternativama). U tu svrhu se koriste **sistemi**, no to se uglavnom spominje kao mogućnost; teorija i primjene još nisu istraženi. Također, hijerarhija je ključ odluke i njeno kreiranje je najbolje prepustiti stručnjacima, ili ih barem konzultirati.