



## BRANKO VUČIJAK

UNIVERZITET U SARAJEVU  
ARHITEKTONSKI FAKULTET  
BiH – 71000 SARAJEVO, PATRIOTSKE LIGE 30

PREGLEDNI ZNANSTVENI ČLANAK

UDK 711-1

TEHNIČKE ZNANOSTI / ARHITEKTURA I URBANIZAM

2.01.02 – URBANIZAM I PROSTORNO PLANIRANJE

PRIRODNE ZNANOSTI / MATEMATIKA

1.05.07 – PRIMIJENJENA MATEMATIKA I MATEMATIČKO MODELIRANJE

ČLANAK PRIMLJEN / PRIHVACEN: 28. 03. 2006. / 31. 05. 2007.

UNIVERSITY OF SARAJEVO  
FACULTY OF ARCHITECTURE  
B&H – 71000 SARAJEVO, PATRIOTSKE LIGE 30

SUBJECT REVIEW

UDC 711-1

TECHNICAL SCIENCES / ARCHITECTURE AND URBAN PLANNING

2.01.02 – URBAN AND PHYSICAL PLANNING

???

1.05.07 – APPLIED MATHEMATICS AND MATHEMATICAL MODELING

ARTICLE RECEIVED / ACCEPTED: 28. 03. 2006. / 31. 05. 2007.

# VIŠEKRITERIJALNA OPTIMIZACIJA U UPRAVLJANJU PROSTOROM

## MULTI-CRITERIA OPTIMIZATION IN SPACE MANAGEMENT

UPRAVLJANJE PROSTOROM  
VIŠEKRITERIJALNA OPTIMIZACIJA  
VIŠEKRITERIJALNO ODLUČIVANJE

SPACE MANAGEMENT  
MULTI-CRITERIA OPTIMIZATION  
MULTI-CRITERIA DECISION-MAKING

Rad predstavlja osnovne elemente uporabe višekriterijalne optimizacije (VKO) u prostornom planiranju. Kao i u svim drugim procesima u kojima je jedna sastavnica i donošenje odluka, te u kojima se pojavljuju konfliktni interesi ili ciljevi, pomoć za donošenje najbolje odluke je dobrodošla i u prostornom planiranju. Prikazana je uloga višekriterijalne optimizacije u upravljanju prostorom, njezini osnovni pojmovi, kao i izvori neizvjesnosti i mogućih grešaka modeliranja sustava.

This paper presents the basic elements in the use of multi-criteria optimization (MCO) in physical planning. As in any other process in which decision-making is its constituent element and in which conflicting interests or objectives appear, an assistance in achieving an optimal solution in physical planning is certainly welcome. The paper also presents the role of MCO in space management, the basic terms in MCO as well as the sources of uncertainty and possible mistakes in systems modeling.

## UVOD

### INTRODUCTION

Pri svakoj raspravi ili pripremi novoga prostornog plana pojavljuju se konfliktni ciljevi uporabe prostora. Takvi su npr. gospodarsveni razvoj, zaštita prirode, uporaba prirodnih resursa, minimizacija negativnih društvenih posljedica, a sve se to rijetko postiže jednovremeno, pa planeri često zapravo „trguju“ između različitih ciljeva kako bi postigli zadovoljavajuće rezultate. Odlučivanje o prostornom planu nekoga područja podrazumijeva razmatranje alternativa i donošenje optimalne strategije razvoja i zadovoljenja ponajprije čovjekovih potreba. No, što zapravo znači 'optimalno', kada se alternative sučele po raznim kriterijima i kada je svaka od njih po jednom od kriterija možda bolja od ostalih, ili barem nije lošija od ostalih ni po jednom kriteriju? Kako uopće i vrednovati opisne kriterije koji se teško kvantificiraju? I kako sažeti nemjerljive i raznorodne vrijednosti kriterija različitih alternativa u jednu i usporedivu, po mogućnosti brojčanu vrijednost? Kakav se pristup prije primjenjivao?

Koncept optimalnog upravljanja prostorom donedavno se u praksi zasnivao najčešće na financijskoj osnovi, često zanemarujući pritom sve ostale posljedice takvog rješenja. Naime, smatralo se da povećanje financijske dobiti u svakom slučaju vodi napretku i općem blagostanju u društvu, te time i zadovoljenju svih čovjekovih potreba. Posve pogrešnu utemeljenost takvoga modela dobro prikazuje tzv. godišnji model poznatog astronoma H.

Siedentorpa<sup>1</sup> – tim se modelom cjelokupna povijest Zemljine kugle u trajanju od oko 170 milijuna godina promatra kao da je u pitanju samo jedna kalendarska godina. Razmjerno takvom umanjenju, po ovom je modelu čovjek to i postao (uspravljajući se u hod na dvije noge) tek 30. prosinca iste godine. Trideset minuta prije isteka takve godine čovjek počinje obrađivati zemljište i time mijenja izgled Zemlje. Industrijska revolucija počinje samo 36 sekunda prije ponoći i u posljednjih 30 sekunda čovjek gotovo sagorijeva sva tekuća i plinovita goriva, dovodeći u opasnost i bilancu kisika na Zemlji.

Poprtni efekti takvog koncepta – kao što su pogoršanje kvalitete zraka i vode te zagađenje čovjekove okoline uopće, loši socijalni utjecaji i slično – neosporno ukazuju na pogrešnu utemeljenost takvoga modela. Stoga je stvoren novi i danas vladajući koncept tzv. održivoga razvoja, to jest takvog razvoja koji je u skladu s okolišem, odgovarajući po suvremenim tehničkim standardima, ekonomski životan, ali i društveno prihvatljiv sa stajališta socijalnih poremećaja koje može proizvesti. Dakle, takav pristup omogućava ispunjenje potreba današnje generacije, bez istodobnoga narušavanja mogućnosti sljedećim generacijama da i one zadovolje svoje potrebe. Stvorena je potreba za traženjem optimalnog rješenja po više kriterija, inicirajući na taj način pojavu jedne nove grane u oblasti optimizacije odnosno optimalnog odlučivanja – višekriterijalne optimizacije (VKO), kao alata za pomoć u procesu višekriterijalnog odlučivanja.

Višekriterijalna je optimizacija dakle samo jedan dio procesa koji se zove višekriterijalno odlučivanje, te koji u sebi objedinjuje i sociološke, psihološke ili fizičke elemente. Osnovni su koraci u ovoj optimizaciji prije svega:

1. Definiranje/izbor ciljeva i određivanje načina njihovih postizanja – primjeri takvih ciljeva jesu gospodarski razvoj, uporaba prirodnih resursa, izgradnja ili ocuvanje okoliša;
2. Formalizacija problema i određivanje te vrednovanje kriterijalnih funkcija – ovaj korak podrazumijeva izbor izmjerljivih vrijednosti uspješnosti postizanja prethodno odabranih ciljeva, kao što su broj radnih mjesta, postotak zemljišta u području koje je posumljeno i sl.;
3. Izbor i upotreba odgovarajuće metode višekriterijalne optimizacije odnosno optimizacija u užem smislu;
4. Usvajanje konačnog rješenja, ili ponavljanje cijelog postupka, počevši od drugoga (nekada čak i prvoga) koraka.

Šezdesetih godina 20. stoljeća javlja se povećana svijest o neophodnosti identifikacije i promatranja istodobno više ciljeva (kriterija) u analizi i rješavanju pojavnih problema. Po-

1 OPRICOVIC, 1986: 1

vecana svijest o značenju okoliša i čovjekovu razornom djelovanju na nj svakako je pritom bio važan element. U SAD-u, npr. višekriterijalna je analiza svoj razvoj uglavnom dugovala radu programa Harvard Water ili inženjeriji vojske SAD-a, te Nacionalnoj okolišnoj politici. I u Europi često potrebe za rezultatima ove vrste optimizacije dolaze iz sektora okoliša, danas nezaobilazno integriranoga u planiranje prostora. U SAD-u višekriterijalna analiza često se naziva i višekriterijalno odlučivanje (MCDM – *Multicriteria Decision Making*), a u Europi pomoć u višekriterijalnom odlučivanju (MCDA – *Multicriteria Decision Aid*).

Matematičkim jezikom govoreći, cilj višekriterijalne optimizacije jest odrediti maksimum vektorske funkcije zadane na odgovarajućoj oblasti u  $n$ -dimenzionalnom vektorskom prostoru promjenljive –  $n$  odabranih kriterija optimizacije odgovaraju komponentama vektorske funkcije, a postojeća ograničenja definiraju navedenu oblast. Ukoliko jedna točka dopustive oblasti istodobno maksimizira sve komponente vektorske funkcije, ona će biti i rješenje navedenoga problema. Međutim, u praksi se takav slučaj događa izuzetno rijetko – jasan je primjer da obično veće iskorištenje prirodnih resursa vodi maksimiziranju gospodarstvenoga razvoja, ali i većoj degradaciji okoliša, pa dakle u ovom slučaju nema rješenja koje je najbolje za oba cilja jednovremeno. Posljedica samo djelomičnog uređenja prostora kriterijalnih funkcija jest pojava pojma tzv. neinferiornog (dominantnog, Pareto-optimalnog) rješenja kao osnovne mjere mogućnosti rješavanja takvoga problema.

Do danas je razvijen čitav niz raznovrsnih metoda koje pokušavaju riješiti ovaj problem. Kao razvijene metode za rješavanje zadataka višekriterijalne optimizacije najčešće se navode metode za određivanje neinferiornih rješenja, metode s unaprijed izraženom preferencijom, interaktivne metode, tj. metode u kojima se preferencija postupno određuje, stohastičke metode, kompromisno programiranje i sl. Naravno, ovisno o izboru metode odnosno odgovarajućem konceptu optimalnosti, dobit će se i različita rješenja. S obzirom da  $n$ -dimenzionalni prostor nije kompletno ureden relacijom 'manje', to znači da ove metode uglavnom nastoje ili na neki način taj prostor kompletno urediti, ili eventualno proširiti parcijalno uređenje.

Važno je napomenuti da termini 'višekriterijalna optimizacija' i 'rješenje problema višekriterijalne optimizacije' ne opisuju dosljedno strukturu kojoj su namijenjeni. Sam pojam optimizacije podrazumijeva pronalaženje optimuma (dakle maksimuma ili minimuma, ovisno o samoj prirodi funkcije i zahtjeva) neke funkcije, dok se u slučaju višekriterijalne optimizacije pod tim podrazumijeva određivanje dodatnih uvjeta koji će omogućiti da se iz skupa tzv. neinferiornih rješenja (ili čak nekad i iz

skupa svih rješenja, odnosno vrijednosti) izdvoji ono ili ona koja su 'prihvatljiva' ili koja su s neke točke gledišta 'najbolja'.

Očito treba donijeti odluku o načinu (metodi) kako će se doći do tražene optimalne vrijednosti, odluku o vrijednostima neophodnih parametara u primjeni te metode, odluku o potvrđivanju izbora konačno predloženoga rješenja odabranom metodom ili o izboru jedne alternative iz suženoga skupa ponuđenih. Stoga se cijeli proces definiranja problema, određivanja alternativa ili scenarija, kriterijalnih funkcija, konturnih ograničenja, optimizacije te donošenja konačnog izbora naziva i – višekriterijalno odlučivanje. Sam izraz 'odlučivanje' vjerojatno preciznije određuje cijeli proces jer se jedino odlukom može odabrati rješenje (ili suziti skup rješenja) koje je neusporedivo s drugim (i koje, naravno, također zadovoljava granicne uvjete) jer je po nekim svojim komponentama bolje, a po drugima lošije od onoga s kojim se uspoređuje.

## UPRAVLJANJE PROSTOROM I VKO

### SPACE MANAGEMENT AND MCO

Otkuda, dakle, potreba za višekriterijalnom optimizacijom u upravljanju prostorom? VKO je dio složenije strukture višekriterijalnog odlučivanja i kao takva predstavlja koristan alat svugdje gdje je potrebno donijeti neku odluku. Upravljanje prostorom i prirodnim resursima jest veoma složena procedura odlučivanja, gdje svaka odluka sažima u sebi značajne elemente tehničkih, prirodnih i društvenih znanosti, jednako kao i elemente ekonomskoga razvoja, zahtjeve društva, naravno u postojećem političkom i administrativnom okolišu. Aktivnosti u urbanističkom planiranju i upravljanju prostorom mogu se grubo podijeliti u dvije grupe: pripremne aktivnosti koje podrazumijevaju pregled postojećega stanja i planiranje te izvedbene aktivnosti koje opet podrazumijevaju projektiranje i izvođenje.

Ovakva gruba podjela dalje zahtijeva da procjena postojećega stanja obuhvaća opseg prirodnih resursa, njihovu upotrebu, potrebe i procjenu budućih zahtjeva, mogućnosti nepogoda, kvalitetnu procjenu financijskih kapaciteta i ograničenja, različitih tehnički izvodljivih rješenja i sl. Planiranje treba odgovoriti na pitanje izbora lokacija izvođenja, vremenskog rasporeda, veličine pojedinih zahvata i dr. S druge strane, projektiranje će predvidjeti preciznije nove strukture i njihovu cijenu. Izvođenje pokriva konstrukcijske radove i nadzor, uz dosljednu primjenu prihvaćenih zakona.

Ako već upravljanje prostorom ima ovako detaljno određenje, odakle potreba da se naziv ponekad proširi riječju 'integralno' ili 'održivo'? Ovime se želi naglasiti povišen stupanj želja, uvođenje novih postupaka i procedura,

te u svakom slučaju očekivanje boljih, svrhovitijih i kvalitetnijih odluka o pažljivijem upravljanju prostorom i njegovu iskorisćenju, te čuvanju njegovih vrijednosti i za iduće generacije. Integracija podrazumijeva i sveobuhvatnost pregleda, uzimanje u obzir svih relevantnih čimbenika koji mogu utjecati na izbor odluke u ovom procesu. Pritom u razmatranju opcija često ni administrativne granice ne smiju biti zapreka jer npr. riječni slijev ili zrak ne poznaju općinske, kantonalne / županijske, regionalne, entitetske ili državne granice.

Integralno upravljanje prostorom ne može nikako biti izdvojeno od svoga političkoga i ukupnoga društvenog i ekonomskog okruženja. Okvir djelovanja mora se prilagoditi uvjetima u kojima se može pregovarati o ciljevima različitih interesnih grupa, njihovim razinama težnje, mogućim tehničkim opcijama i, naravno, centrima odlučivanja, koji opet u sebi sadrže ili u cijelosti uzimaju u obzir postojeće društvene sile. Ono mora biti naglašeno interaktivno, uz neprekidan monitoring različitih interesnih grupa.

Očito je da ovakav pristup zahtijeva široka znanja iz različitih oblasti (metodike planiranja, sociologije, ekologije, hidrologije itd.), kao i visoku sposobnost za upravljanje onih koji donose odluke, što sve 'prividno' umanjuje mogućnost potpune učinkovitosti modela koji treba u sebi uključiti sve važne ciljeve, kriterije kojima će se vrednovati dosezanje istih.

U procesu odlučivanja relevantni su čimbenici različite grupe koje predstavljaju i javne i pojedinačne interese, a neophodno je primijetiti da u najvećem broju slučajeva procesi odlučivanja uključuju više sudionika.<sup>2</sup> Oni često predlažu raznovrsne ciljeve i kriterije, uz uporabu brojčanih ili deskriptivnih kvantifikatora, kojih preklapanje ili neusuglašenost vodi sve težem problemu donosenja 'ispravne' odluke odnosno izgradnji konsenzusa sudionika.

Posebna je značajka toga problema nepreciznost iznesenih ciljeva i kriterija, nepouzdanost ili neizvjesnost kvantifikatora ili procedura za njihovo određivanje, pa sve to često zahtijeva iterativan i interaktivan pristup njegovu rješavanju. Pri modeliranju takvoga sustava ciljeva i kriterija izvori se pogrešaka mogu kategorizirati u nekoliko osnovnih grupa:

1. Topologija modela – odnosi se na red, stupanj i formu sustava jednadžbi kojima se predstavlja realni sustav;
2. Parametri matematičkoga modela – izborom topologije modela otvara se pitanje izbora njegovih parametara – oni određuju točnost reprezentacije realnoga sustava;
3. Obuhvat modela – odnosi se na tip i razinu rezolucije modela, a podrazumijeva vremenski opis, fizički opis, političko-geografski opis te opis ciljeva i funkcija (dakle, ne odnosi se samo na prostorni obuhvat);

4. Podatci – veoma su važan element pri analizi sustava, njegovoj konstrukciji, kalibraciji i validaciji, pa nedostatak odgovarajućih podataka može dovesti do ozbiljnih pogrešaka;

5. Tehnika optimizacije – izbor i primjena odgovarajuće optimizacione tehnike uvodi još jednu mogućnost pogreške ili neizvjesnosti; izbor optimizacijske tehnike treba biti u uskoj vezi s konstrukcijom modela;

6. Subjektivnost ljudskoga čimbenika – uključuje trening i iskustvo analitičara, osobnu preferenciju i interes, ili umješnost.

Sve to upućuje na to da bi tehnike, procedure, modeli koje obuhvaća integralno upravljanje prostorom morale postajati sve složenije kako bi udovoljile zahtjevu integralnosti i sve boljoj preciznosti i kvaliteti, dok istodobno ostaje i zahtjev za njihovom jednostavnošću radi šire i lakše primjene u jednostavnom izboru alternative, kraćeg intervala procesiranja, nižih troškova i transparentnosti, mogućnosti izgradnje konsenzusa sudionika u procesu odlučivanja, što je već samo po sebi zaseban problem odlučivanja, tj. ulaz za posebnu višekriterijalnu optimizaciju (kako odabrati najbolju proceduru koja nastoji zadovoljiti međusobno konfliktne zahtjeve za integralnošću i jednostavnošću).

Višekriterijalno se odlučivanje u 20. stoljeću razvilo ponajprije iz potreba upravljanja (menadžmenta) u jednom širem smislu i obuhvatu – upravljanje prostorom svakako ima svojih posebnosti koje se moraju uzimati u obzir, gdje se tek kao primjer mogu izdvojiti:

- Prostor podrazumijeva i postojeće prirodne resurse, za koje je potrebno osigurati održivo korištenje;
- Prostor je dio ukupne nacionalne infrastrukture kao mogući izvor energije, kao putna komunikacija, izvor hrane i sl.;
- Prostor može nad sobom imati privatno, državno ili javno vlasništvo, koje se može prodavati ili ustupati putem dozvola za uporabu od strane nadležnih tijela itd.

Integralni pristup neizostavno razmatra sve ove i druge pojavne aspekte sa ciljem eliminacije ili, ako to nije moguće, minimiziranja razlika između željenih pravaca različitih interesnih grupa.

## PROSTOR ODLUČIVANJA U VKO

### DECISION-MAKING IN MCO

Kako, dakle, matematski formulirati ovakav pristup višekriterijalnog odlučivanja? U svakom sustavu kojim se upravlja postoje ulazne i izlazne sastavnice. Ulazne mogu biti potpuno ili djelomično kontrolirane postupcima, tj.

odlukama, ali i posve izvan mogućnosti kontrole. Izlazne komponente mogu imati željeno, kao i posve suprotno djelovanje, ali i biti neutralnoga statusa s trenutne točke gledišta postizanja odabranih ciljeva. Između svih ovih komponenti postoji i određena, jača ili slabija, interakcija kojom se u okruženju uobličuje cijeli sustav – naravno, u svojoj vremenskoj strukturi koja ga čini dinamičkim.

S obzirom na to da ulazne komponente koje su sasvim ili djelomično kontrolirane predstavljaju predmet odlučivanja, one se opisuju varijablama odlučivanja. Skup svih odluka koje se mogu donijeti nad ovim skupom varijabli odlučivanja stoga se naziva prostor odlučivanja. Posljedice su odluke naravno generirane i parametrima sustava, koje karakteriziraju nekontrolirane ulazne komponente, ali i odgovore samog sustava.

S druge strane, poseban interes postoji za željene, ali i neželjene posljedice odlučivanja. Cilj je svakako ove prve maksimizirati, a druge istodobno minimizirati, što ne mora obvezatno biti i brojčano kvantificirano (zadovoljenje ovih zahtjeva može biti prikazano i opisno). Odluke koje se donose vode promjenama u sustavu i ove se promjene opisuju varijablama stanja (čija je priroda ponajprije dinamička).

Svaki skup varijabli odlučivanja, dakle, proizvodi određene posljedice i stoga se postavlja odgovarajući ciljevi. Stanje postaje jednostavnije za ispitivanje ako je ipak moguće brojno kvantificiranje kriterija zadovoljenja postavljenih ciljeva, čak i ako dobivene vrijednosti ne pripadaju istom obuhvatu ili se ne mogu izraziti istim mjernim jedinicama. Matematski uobičajeno moglo bi se reći da je cilj maksimiziranje (ili eventualno minimiziranje) odabrane ciljne funkcije  $f(x,s,p)$ , gdje je:

- $f = (f_1, f_2, \dots, f_N)$  Vektorska funkcija kao kompozicija odabranih  $N$  kriterija  $f_1 \dots f_N$ ;
- $x = (x_1, x_2, \dots, x_K)$  Vektorska varijabla odlučivanja –  $K$  varijabli  $x_1 \dots x_K$ , kojih se izborom žele dobiti najbolje vrijednosti funkcije  $f$ ;
- $s = (s_1, s_2, \dots, s_J)$  Vektorska varijabla stanja –  $J$  varijabli  $s_1 \dots s_J$ , kojih vrijednosti opisuju postojeće stanje promatranoga sustava;
- $p = (p_1, p_2, \dots, p_I)$  Vektor parametara sustava –  $I$  odabranih nepromjenljivih vrijednosti  $p_1 \dots p_I$  koje opisuju sustav;

pri čemu je izbor varijabli odlučivanja podložan i dodatnim ograničenjima (npr. resursa, putnih komunikacija, te geološkim ograniče-

njima i sl.). Razlika između ciljeva i ograničenja jest često neprecizna ili i nejasna, te se može dogoditi da neki cilj postane ograničenje, ali i obratno. Maksimiziranje (ili minimiziranje) ciljnih vektorske funkcije  $f$  podrazumijeva nalaženje odgovarajućih varijabli odlučivanja koje to osiguravaju u matematskom modelu. Treba još jednom naglasiti da je ipak riječ o modelu koji pokušava opisati stvarno stanje i da optimalno rješenje odgovara tome modelu, što na žalost ne mora značiti i stvarnoj situaciji jer je priroda često složenija od postavljenih jednadžbi. Stoga se cjelokupan proces naziva – osim višekriterijalna optimizacija – i pomoć u višekriterijalnom odlučivanju, ili čak samo višekriterijalno odlučivanje.

## OSNOVNI POJMOVI U VIŠEKRITERIJALNOM ODLUČIVANJU

### BASIC TERMS IN MCO

Pojmovi koji su nezaobilazni u procesu višekriterijalnog odlučivanja jesu ciljevi ili kriteriji, ograničenja i atributi i njihove definicije često se razlikuju od autora do autora.<sup>3</sup> Ipak, neke zajedničke naznake za svaki od pojmova mogu se predstaviti.

**Kriteriji ili ciljevi** predstavljaju željeni pravac promjena stanja od strane onoga ili onih koji o njemu odlučuju. Pravac promjena može biti već spomenuto maksimiziranje ili minimiziranje, ali i održavanje stanja na određenom stupnju koji se može kvantificirati (naravno, odgovarajućim transformacijama sva se ova tri pravca mogu svesti na problem maksimiziranja, te se kao takvi najčešće i promatraju). Izbor kriterija ovisi prije svega o dobrom razumijevanju problema, tj. njegovu modeliranju. Pristup modeliranju može biti putem detaljnoga pregleda prikaza sličnih problema i stanja u svijetu, analitičke studije problema ili čak i uporabe iskustava. Proces definiranja kriterija prati uglavnom njihova konfliktnost, tj. nemogućnost istodobnog potpunog zadovoljenja, do čega uglavnom dolazi zbog konturnih ograničenja u uporabi resursa (da ih je moguće istovremeno sve zadovoljiti, ne bi se ni govorilo o višekriterijalnom odlučivanju). Primjeri ciljeva u upravljanju prostorom jesu ostvarenje što veće dobiti (donedavno, na žalost, dominantan, pa često i jedini cilj), očuvanje i unaprjeđenje kvalitete okoliša, zadovoljavajuće putne komunikacije, bitno smanjenje mogućnosti prirodnih katastrofa, održiva uporaba prirodnih resursa itd.

**Atributi** opisuju karakteristike i kvalitetu parametara postupaka u procesima odlučivanja. Zadatak atributa jest da omogućiti procjenu zadovoljenja postavljenih ciljeva, tj. da odredi mjeru kojom se mogu karakterizirati posljedice različitih odlučivanja. Za svaki po-

3 Npr.: \*\*\* 1994: 33-39 (TECLE i sur.); GOICOECHEA i sur., 1982: 17-26



stavljene atribut (npr. očuvanje prirode, zadovoljavajuće komunikacije i kvalitete komunalne infrastrukture i sl.) veže se određeni indikator (koncentracija zagađenja, dužina cesta, pokrivenost vodoopskrbom i odvodnjom te precišćavanjem otpadnih voda itd.) i formiraju odgovarajući rasponi kojima pripadaju referentne vrijednosti.

**Promjenljive (varijable) odlučivanja** jesu nepoznate veličine koje treba odrediti u zadanom problemu optimalnog odlučivanja. Uglavnom su predstavljene ne-negativnim veličinama, a često su neprekidne, pa i ograničene (npr. količina vode potrebne za navodnjavanje ili za vodoopskrbu: ova vrijednost nije diskretna već neprekidna, ograničena je ukupnom dostupnošću vode – npr. zapreminom akumulacije – i naravno ne-negativna). Neke od promjenljivih nisu neprekidne, nego mogu primiti ograničen broj vrijednosti. Previše mogućnosti vodilo bi otežanom procesiranju i odlučivanju, pa se u takvom slučaju često najprije provodi određeno filtriranje.

Određeni broj veličina u procesu odlučivanja jesu konstantne vrijednosti, ili ih se može takvima smatrati (npr. ako je poznato koja vrijednost neke veličine, koja sama nije konstantna, sigurno vodi optimalnom rješenju i njen izbor nije povezan s izborom promjenljivih). Ovakve vrijednosti zovu se **parametri procesa**.

**Konturna ograničenja** jesu restrikcije koje postoje nad atributima ili parametrima odlučivanja – poželjno ih je kvantificirati, ali to nije uvijek moguće. Mogu biti uvjetovana različitim čimbenicima, kao što su dostupni ekonomski resursi, kulturno naslijeđe, pravni okviri djelovanja, stanje okoliša ili samih resursa. Ograničenja izražavaju međusobnu ovisnost između varijabli odlučivanja i parametara, te naravno stanja sustava. Mogu biti izražena kako jednakostima koje opisuju zahtijevano stanje ravnoteže, tako i nejednakostima (koje najčešće opisuju ograničenja resursa), pa čak i mjerama vjerojatnosti. Može se dogoditi da neki cilj postane ograničenje, ali i obratno, jer crta razgraničenja ciljeva i ograničenja nije uvijek jasno povučena.

U matematskom obliku zapisa problem više-kriterijalne optimizacije glasio bi:

Odrediti optimum (u praksi je to najčešće maksimum, i kao takav uglavnom se i uzima) vektorske funkcije kriterija

$$f(x) = [f_1(x), f_2(x), \dots, f_N(x)], \quad /1/$$

gdje je

$$x = (x_1, x_2, \dots, x_K)$$

vektorska varijabla odlučivanja koja zadovoljava odgovarajuće uvjete – ograničenja:

$$G_j(x) \leq 0, \quad j = 1, 2, \dots, M \quad /2/$$

$$x_k \geq 0, \quad k = 1, 2, \dots, K \quad /3/$$

K je broj pojedinačnih varijabli odlučivanja, N broj odabranih kriterija i M broj prepoznatih ograničenja koja moraju biti zadovoljena

(gdje drugi uvjet nije neophodan, jer se može preformulirati u:

$$G_j(x) = -x_k \leq 0, \quad j = M + 1, \dots, M + K \quad /4/$$

ali se iz praktičnih razloga često izdvaja).

S obzirom na to da su komponentne funkcije kriterija  $f_i(x)$ ,  $i = 1, \dots, N$  obično međusobno konfliktne, što znači da željeno minimiziranje ili maksimiziranje jedne od njih često vodi neželjenom – suprotnom reagiranju neke druge kriterijalne funkcije, to se pod optimumom vektorske funkcije ovdje podrazumijeva takva vrijednost  $f(x)$  koja nije inferiorna u odnosu na bilo koju drugu  $f(y)$ , a koja u odgovarajućem smislu (koji treba posebno definirati) zadovoljava donositelja odluke. Dakle, osim u rijetkim slučajevima, takvo rješenje ne predstavlja jednovremeni pretpostavljeni maksimum svih pojedinačnih kriterijalnih funkcija  $f_i(x)$ ,  $i = 1, \dots, N$ .

Vektorska varijabla odlučivanja  $x$  i vektorska kriterijalna funkcija  $f(x)$  pripadaju K-dimenzionalnom prostoru odlučivanja X, odnosno N-dimenzionalnom prostoru cilja F, između kojih je upravo vektorskom funkcijom  $f(x)$  definirano preslikavanje. Naravno da cijeli prostor X ne mora biti dopustiv, tj. ne mora svaka točka  $x \in X$  biti moguća varijabla odlučivanja, što je pak ograničeno dodatnim konturnim uvjetima. Dopustivi skup odlučivanja je podskup  $\underline{X}$  skupa X i on može biti konačan, prebrojiv ili neprebrojiv, ovisno o karakteru problema, pa tako i razlikujemo probleme diskretnoga ili kontinualnoga tipa. Preslikavanjem  $f$  ovaj se skup preslikava u skup  $\underline{F}$  koji je također konačan, prebrojiv ili neprebrojiv podskup N-dimenzionalnog prostora cilja F (dakle N-dimenzionalnoga prostora koji je razapet koordinatnim osima jednakim odabranim kriterijima).

Ukoliko se zahtijeva da se neka komponentna kriterijalna funkcija  $f_i(x)$  minimizira (npr. gotovo je redovito jedan od kriterija trošak koji treba minimizirati), taj se problem uvijek može zamijeniti problemom maksimiziranja funkcije  $-f_i(x)$  (u prethodnom primjeru negativna vrijednost troška treba, naravno, biti maksimizirana), jednako kao što se dodatni spomenuti uvjet  $x_k \geq 0$  može zapisati u obliku:

$$G_k(x) = -x_k \leq 0$$

što vodi k pojednostavljenom zapisu problema visekriterijalne optimizacije:

$$\text{maksimizirati } f_i(x), \quad i = 1, \dots, N \quad /5/$$

$$\text{uz uvjete } G_j(x) \leq 0, \quad j = 1, \dots, M' \quad /6/$$

Posebno su interesantne vrijednosti  $f_1^*, f_2^*, \dots, f_N^*$  koje predstavljaju rješenja  $N$  zadataka skalarnih optimizacija:

maksimizirati  $f_i(x)$ ,  $i = 1, \dots, N$ ,

uz uvjete  $G_j(x) \leq 0$ ,  $j = 1, \dots, M'$ . /7/

$f^* = (f_1^*, f_2^*, \dots, f_N^*)$  naziva se **idealnom točkom** polaznoga problema – ako vrijedi  $f^* \in F$  (gdje je  $F$  skup mogućih, izvodivih rješenja koja zadovoljavaju sve granične uvjete opisane sa /6/), onda će ona naravno biti i rješenje zadanoga problema. Kako se takav slučaj rijetko događa u praksi (najjeftinije rješenje teško da će optimizirati druge odabrane kriterije), ova se vrijednost iz prostora kriterija uglavnom upotrebljava kao odgovarajuća referentna točka u različitim metodama višekriterijalne optimizacije.

Treba primijetiti da su koordinate ove točke iz prostora  $F$  egzaktno određene, ali moguće je sličnu točku  $f^* \in F$  i zadati kao željenu razinu zadovoljenja postavljenih kriterijalnih funkcija. Analogna logika i ovdje postoji: ako vrijedi  $f^* \in F$ , onda je ova, tzv. ciljna točka i rješenja problema, a to ipak najčešće nije slučaj.

Kako idealna točka problema višekriterijalne optimizacije uglavnom ne pripada skupu  $F$ , najčešća je situacija u kojoj se drukčijim izborom varijable odlučivanja dobije poboljšanje jedne komponentne kriterijalne funkcije  $f_i(x)$ , ali istodobno vrijednost druge funkcije  $f_j(x)$  opada. To je posljedica nekompletnog uređenja vektorskoga prostora  $F$ , u kojem nije moguće za bilo koje dvije točke  $f$  i  $g$  reci da je zadovoljena jedna i samo jedna od tri relacije:  $f \leq g$ ,  $f = g$  ili  $f \geq g$  (to je slučaj npr. u prostoru  $R^3$ ). Stoga se i uvodi pojam **Pareto-optimalnih, neinferiornih ili dominantnih**<sup>4</sup> rješenja na sljedeći način:

Rješenje  $f^* = (f_1^*, f_2^*, \dots, f_N^*)$  je Pareto-optimalno (dominantno, neinferiorno) ako ne postoji drugo dopustivo rješenje  $f = (f_1, f_2, \dots, f_N) \in F$  takvo da je  $f_i \geq f_i^*$ ,  $i = 1, \dots, N$  i  $f_j > f_j^*$  za bar jedno  $j \in \{1, \dots, N\}$ .

Pareto-optimalna rješenja jesu elementi skupa  $F$  – skupa dopustivih kriterijalnih vrijednosti. Ovakvoj definiciji odgovara definicija efikasne točke ili efikasnog rješenja, odnosno efikasne varijable odlučivanja u prostoru odlučivanja  $X$ , tj. njegovu podskupu dopustivih varijabli odlučivanja  $X$ . Tako se kaže da je točka  $x^* = (x_1^*, x_2^*, \dots, x_K^*)$  efikasna varijabla odlučivanja ako ne postoji druga varijabla odlučivanja  $x = (x_1, x_2, \dots, x_K) \in X$  takvo da je  $f_i(x) \geq f_i(x^*)$ ,  $i = 1, \dots, K$  i  $f_j(x) > f_j(x^*)$  za bar jedno  $j = 1, \dots, K$ . S obzirom na prethodnu definiciju, može se reci da je varijabla odlučivanja efikasna ako se

može dobiti inverznim preslikavanjem preslikavanja  $f$  Pareto-optimalnog rješenja. Varijable odlučivanja koja nije efikasna naziva se neefikasnom varijablom odlučivanja.

Vrijedi naglasiti da skup efikasnih rješenja  $E$ , kao podskup skupa  $X$ , također može biti konačan, prebrojiv i neprebrojiv (ali ne i prazan, ako skup  $X$  nije prazan). Ako on ima samo jedan element, zadan problem višekriterijalne analize je riješen i dani element predstavlja vektor optimalnog odlučivanja. Ako to nije slučaj, tek predstoji odabir postupka izbora jednoga od elemenata skupa  $E$  kao zadovoljavajućeg, tj. optimalnog rješenja postavljeno-ga zadatka.

## ZAKLJUČAK

### CONCLUSION

Postoji niz različitih pristupa problemu konačnog odabira samo jedne alternative iz skupa ponuđenih rješenja, ili problemu njihova rangiranja, tj. utvrđivanja međusobnog poretka – dakle i izboru jedne alternative mogućega prostornog plana. Najčešće se, zasnovano na nekom principu preferencije, kreira dodatna skalarna funkcija nad postojećim vektorskim varijablama, ili čak i funkcijama. To može biti funkcija udaljenosti u višedimenzionalnim prostorima, određena funkcija utiliteta, funkcija konačnog skupa preodređenih vrijednosti itd. Ovisno o tome koji je princip odabran, različite metode višekriterijalne optimizacije (odlučivanja) mogu se podijeliti u nekoliko grupa, kao što su metode za generiranje neinferiornoga skupa rješenja, metode s unaprijed izraženom preferencijom, metode postupno određene preferencije, a u sklopu ovih grupacija mogu se prepoznati npr. i metode zasnovane na konceptu odstojanja, metode koje uvode funkciju utiliteta, metode međusobne usporedbe.

Brojni su izvori neizvjesnosti vrijednosti s kojima se ulazi u problem višekriterijalne optimizacije uopće, pa i u prostornom planiranju. Odlučivanje u prostornom planiranju ili upravljanju prostorom uvijek nosi sa sobom i poseban stupanj neizvjesnosti. Ove se pak neizvjesnosti mogu kategorizirati u dvije grupe: neizvjesnost uzrokovana inherentnom prirodnom promjenljivošću (npr. hidrološka ili klimatološka) i neizvjesnost uzrokovana nedostatkom dostupnoga znanja. Također treba uzeti u obzir da se većina odluka u sektoru prostornog i urbanističkog planiranja donosi u situacijama kada ciljevi, ograničenja i posljedice nisu posve precizno određene.

<sup>4</sup> HAIMES i sur., 1975: 8-9; \*\*\* 1994: 42 (TECLE i sur.); GOICOECHEA i sur., 1982: 20; OPRICOVIC, 1986: 5



## LITERATURA

### BIBLIOGRAPHY

1. FEICK, R. D.; HALL, G. B. (1999.), *Consensus-building in a Multi-Participant Spatial Decision Support System*, URISA Journal, 11(2): 17-23, Park Ridge, IL, USA
2. GOICOECHEA, A.; HANSEN, D. R.; DUCKSTEIN, L. (1982.), *Multiobjective Decision Analysis With Engineering and Business Applications*, John Wiley and Sons, New York
3. HAIMES, Y. Y.; HALL, W. A.; FREEDMAN, H. T. (1975.), *Multiobjective Optimization in Water Resource Systems*, Elsevier, Nizozemska
4. OPRICOVIC, S. (1986.), *Višekriterijumska optimizacija*, Naučna knjiga, Beograd
5. VUČIJAK, B. (2003.), *Analiza stabilnosti rjesenja u višekriterijumskoj optimizaciji sa primjenom u sektoru voda*, disertacija, Arhitektonsko-Gradevinski fakultet, Banja Luka
6. \*\*\* (1994.), *Multicriteria decision analysis in water resources management* (BOGARDI, J. J.; NACHTNEBEL, H. P. – eds.), UNESCO, Pariz

## SAŽETAK

## SUMMARY

## MULTI-CRITERIA OPTIMIZATION IN SPACE MANAGEMENT

Every discussion or a preliminary phase of physical planning is accompanied by conflicting objectives regarding space use. The illustrative examples are economic development, protection of nature, the use of natural resources, minimalization of the negative social effects etc. They are rarely satisfied simultaneously. Therefore planners often keep a balance among various objectives with the intention to obtain positive results. Until recently the concept of optimal space management has been based on finances often failing to observe all other consequences of such a solution. It was considered that the increase in financial profit necessarily results in progress and general well-being thus meeting human needs. The undesirable side-effects of such a concept (environmental pollution, negative social influences etc.) undeniably prove that the concept is fundamentally based on erroneous premises. Hence a prevailing concept today is the so-called sustainable development concept, i.e. an environment-friendly development in line with modern technical standards, economically cost-effective, and socially acceptable from the point of view of social disturbances it might produce. This approach meets the needs of the existing generation without at the same time destroying the possibility for future generations to satisfy their own needs. A need has been created to search for optimal solution following different and often contradictory criteria such as: the least possible cost and the minimal effect on the environment with the parallel creation of optimal economic conditions thus initiating the emergence of a new branch in the field of optimization and optimal decision-making – a multi-criteria optimization (MCO) as a helping tool in the multi-criteria decision-making process. MCO is then just one segment of the process termed multi-criteria decision-making which integrates social, psychological and physical elements. The essential steps in this optimization are primarily:

1. Defining the objectives and determining ways to accomplish them;

2. Formalizing the problems and determining and assessing criteria functions;
3. Selection and use of appropriate methods of multi-criteria optimization, i.e. optimization in narrow sense;
4. Adopting the final solution, or repeating the same procedure starting from step 2.

Managing space and natural resources is a very complex procedure of decision-making in which every decision sums up in itself the significant elements of technical, natural and social sciences as well as the elements of economic development, social requirements in the present political and administrative environment. In decision-making process the relevant factors are various groups representing both public and individual interests. They all suggest diverse objectives and criteria using numerical or descriptive quantifiers whose overlapping or noncoordination leads to an ever-increasing problem of making the "right" decision. A special feature of this issue is an imprecise identification of the objectives and criteria, unreliable quantifiers or procedures for their establishment. All this requires repeated attempts and often an interactive approach to solving the problem.

All this indicates that the techniques, procedures and models encompassed by an integral space management should become ever more complex in order to be able to meet the requirements regarding integrity as well as an improved level of accuracy and quality whereas at the same time they should remain simple for the purpose of their wider application, a shorter processing span, lower costs and transparency which in itself is a separate problem of decision-making, i.e. a specific multi-criteria optimization.

Multi-criteria optimization developed in the 20<sup>th</sup> century from the management needs in a wider sense and scope. Space management is characterized by a range of special features which should be taken into account, in particular:

- Space implies also the existing natural resources for which it is necessary to ensure sustainable use,
- Space is a part of an entire national infrastructure as a possible source of energy, travel communications, source of food etc.
- Space implies private or public / state ownership which may be sold or ceded through operating licence issued by the relevant authorities.

An integral approach therefore takes into consideration all these and other aspects with the aim to eliminate or at least to minimize the difference between the desired directions of various interested groups.

There is a range of different approaches to the problem of a final selection of just one solution from the group of Pareto-optimal solutions (a group of all solutions for which there is no other solution that would be better according to at least one criterion, all other criteria being the same), or to the problem of their hierarchy, i.e. determining their sequence or selecting one solution of a physical plan. Most commonly, an additional scalar function is created (following the principle of preferences) over the existing vector variables or even functions – it may be a distance function in multi-dimensional spaces, a utility function etc. Depending on the selected principle, various methods of multi-criteria optimization (decision-making) may be divided into several categories such as the methods for generating noninferior group of solutions, methods with an expressed preference in advance, methods of a gradual determination of preference. Within these groups one can identify also methods based on distance concept, methods introducing utility function, methods of mutual comparison. Of course, depending on the choice of method, i.e. an appropriate optimization concept, different solutions are to be expected. Considering the fact that n-dimensional space is not entirely defined by the relation „less“, it follows that all these methods mainly attempt either to plan entirely the space or possibly to extend partial planning.

**BRANKO VUČIJAK**

## BIOGRAFIJA

## BIOGRAPHY

Dr.sc. **BRANKO VUČIJAK** rođen je 1960. godine u Sarajevu. Diplomirao je 1983. godine na Prirodno-matematičkom fakultetu Univerziteta u Sarajevu, odsjek matematika, a magistrirao na Elektrotehničkom fakultetu Univerziteta u Beogradu, odsjek primijenjena matematika, 1989. godine. Doktorirao je na Arhitektonsko-Gradevinskom fakultetu u Banjoj Luci 2003. godine s tezom u oblasti višekriterijalne optimizacije. Od 1995. godine angažiran je na Arhitektonskom fakultetu u Sarajevu, gdje danas sudjeluje u nastavi grupe kolegija „Računari“. Zaposlen je u Institutu za hidrotehniku Građevinskoga fakulteta u Sarajevu d.d., gdje je izvršni direktor. Objavio je više znanstvenih i stručnih radova iz područja primjene računala, optimizacije i upravljanja, među kojima i knjigu o primjeni računala.

**BRANKO VUČIJAK**, Ph.D., born in 1960 in Sarajevo. In 1983 he graduated from the Faculty of Science (Department of Mathematics) and in 1989 he got his master's degree at the Faculty of Electrical Engineering of the University of Belgrade (Department of Applied Mathematics). In 2003 he got his PH.D. degree at the Faculty of Architecture and Civil Engineering in Banja Luka with a dissertation on multi-criteria optimization. Since 1995 he has been working at the Faculty of Architecture in Sarajevo teaching a course in "Computers". He is also executive manager of the Institute of Hydraulic Engineering, Faculty of Civil Engineering in Sarajevo. He has published a number of scientific papers on computer application, optimization and management as well as a book on computer application.