

## VIŠEKRITERIJSKO ODLUČIVANJE KAO PODRŠKA U GOSPODARENJU ŠUMAMA – MODELI I ISKUSTVA

### MULTIPLE CRITERIA DECISION MAKING IN FORESTRY – METHODS AND EXPERIENCES

Mario ŠPORČIĆ, Matija LANDEKIĆ, Marko LOVRIĆ,  
Saša BOGDAN, Ksenija ŠEGOTIĆ<sup>1</sup>

*SAŽETAK:* U radu su prikazani višekriterijski modeli koji u šumarstvu mogu poslužiti kao podrška u planiranju i odlučivanju. Ukratko je opisano i uspoređeno više metoda među kojima su: analiza omeđivanja podataka, analitički hijerarhijski proces, jednostavno višeatributno rangiranje, metode višeg ranga i dr. Cilj je bio pojasniti za koje se vrste zadataka i problema takve metode mogu primijeniti u šumarstvu. Time je omogućen uvid u karakteristike pojedinih metoda i pomoć u odabiru potencijalnih metoda kod eventualne primjene. Uloga i značaj višekriterijskih modela u šumarstvu opisani su brojnim primjerima i izvorima u kojima su primijenjeni različiti modeli. U radu se također kroz prikaz istraživanja provedenih na primjeru “Hrvatskih šuma” d.o.o. Zagreb daje uvid u mogućnosti te svrsishodnost i opravdanost primjene višekriterijskih matematičkih modela. Zaključuje se da razvoj i primjena modela višekriterijskog odlučivanja može pridonijeti lakšem analiziranju, planiranju i predviđanju pri gospodarenju šumama.

*Ključne riječi:* višekriterijsko odlučivanje, planiranje, šumarstvo, AOMP, AHP

#### 1. UVOD – Introduction

U posljednjih se dvadesetak godina opći okvir šumskog gospodarenja dramatično promijenio. Višestruki ciljevi danas su tipični u šumarstvu. Gospodarenjem šumama mora se proizvesti određeni prihod dok se u isto vrijeme trebaju promovirati zaštita i očuvanje šuma, rekreacijske usluge i sl. Uz proizvodnju i pridobivanje drva drugim se kriterijima, u odabiru načina upravljanja šumama, pridaje sve veća težina. Drugim riječima, šume se istovremeno koriste u mnogostruke svrhe. Višestruke koristi i brojne dobrobiti koje pružaju šume kao i netržišna priroda dijela takvih proizvoda, pritom čine planiranje i odlučivanje u šumarstvu posebno zahtjevnim. To je dovelo do potrebe za modelima koji se mogu primijeniti u višefunkcionalnom gospodarenju šumama. Posebice je takva podrška, kroz različite me-

tode i modele, potrebna u planiranju i predviđanju, ali i analizi rezultata poslovanja u šumarstvu.

Planiranje i odlučivanje se u hrvatskom šumarstvu u prošlosti učestalo obavljalo na temelju zdravog razuma i/ili prošlih iskustava. Dok u nekim slučajevima ovakav pristup može biti dovoljan, s pozicije složenosti današnjeg poslovnog okruženja i imperativa stalnog povećanja uspješnosti poslovanja, nužno je korištenje novih modela i preciznijih metoda. Isto tako, istraživanja su pokazala da je šumarski sektor u Hrvatskoj prilično trom u pogledu usvajanja novih podloga i alata za donošenje odluka u gospodarenju šumama (Šporčić 2007).

U zemljama razvijenoga šumarstva, jednostavne numeričke simulacije i optimizacije već se duže vrijeme smatraju nedovoljnim u pouzdanom planiranju šumskoga gospodarenja. Današnje šumarstvo, s brojnim ciljevima i zadaćama te više uključenih i zainteresiranih strana često s različitim interesima, traži fleksibilniju i svestraniju podršku u donošenju odluka od one koju

<sup>1</sup> Doc. dr. sc. Mario Šporčić, Matija Landekić, dipl. ing. šum., Marko Lovrić, dipl. ing., doc. dr. sc. Saša Bogdan, prof. dr. sc. Ksenija Šegotić; Šumarski fakultet Sveučilišta u Zagrebu, [sporcic@sumfak.hr](mailto:sporcic@sumfak.hr)

mogu pružiti ‘tradicionalni’ alati i pokazatelji. Općenito, pod donošenjem odluke podrazumijeva se izbor neke od alternativa kojima se rješava dani problem. U problemu odlučivanja postoje ciljevi koji se žele postići odlukom, kriteriji kojima se mjeri postizanje tih ciljeva, težine tih kriterija koje odražavaju njihovu važnost i alternativna rješenja problema. U procesu odlučivanja, oni koji donose odluke rangiraju set alternativnih rješenja i odabiru one koje po vlastitim preferencijama smatraju najboljim.

### 1.1. Planiranje i odlučivanje u šumarstvu

#### *Planning and decision making in forestry*

Planiranje šumskoga gospodarenja je instrument od središnje važnosti, jednako za usmjeravanje šumskih uprava i poduzeća u gospodarenju šumama, kao i za osiguranje javnoga interesa u donošenju odluka vezanih uz šumarstvo. Cilj planiranja u šumarstvu je pružanje potpore za donošenje odluka na način da se postigne najbolji omjer inputa i outputa u gospodarenju šumama, a kojim će se istovremeno najpovoljnije ispunjavati kriteriji i zahtjevi postavljeni pred određeno šumsko-gospodarsko područje. Planiranje u šumarstvu može se promatrati na više razina. Osnovne razine mogu predstavljati strateško, taktičko i operativno planiranje. Strateški planovi najčešće se pripremaju ne samo za duže razdoblje, već i za veća područja nego taktički. Štoviše, iz praktičnih razloga, planske kalkulacije nisu toliko detaljne kao pri taktičkom planiranju. Taktičko planiranje u šumarstvu obično obuhvaća razdoblje od 5–20 godina, a pri strateškome planiranju ono se odnosi na razdoblje do 50 i 100 godina. U taktičkome planiranju broj alternativnih planova gospodarenja, svaki s određenom kombinacijom mjera i zahvata te rasporeda njihova izvođenja u šumskim sastojinama, može biti značajan, praktički beskonačan. Uobičajeno, krajnji rezultat šumarskoga planiranja je plan upravljanja koji predstavlja preporučeni akcijski plan za određeno šumsko područje, s predviđenim rezultatima i posljedicama njegova pro-

Da bi se rangiranje moglo obaviti, moraju se postaviti kriteriji koji su relevantni i po mišljenju donositelja odluke značajni za određeni problem. U rangiranju različitih alternativa, svaka od alternativa treba se ocijeniti s obzirom na svaki od postavljenih kriterija. Modeli i metode višekriterijskog odlučivanja pritom mogu poslužiti za analizu situacije odlučivanja i pomoći u donošenju najbolje moguće ili barem zadovoljavajuće odluke.

vođenja. Šumarski postupci pritom imaju dugoročne ekonomske, ekološke i socio-kulturne učinke.

Također, potrebno je naglasiti da rukovođenje bilo kojom organizacijom zahtijeva sposobnost učinkovite procjene i analize informacija generiranih u poslovnome procesu. Kod organizacija, kakve su šumarske tvrtke, koje gospodare prirodnim resursima i donošenjem poslovnih odluka utječu na okoliš, isto je s gledišta ekološke obazrivosti i okolišnog menadžmenta još kritičnije. Razvoj i primjena metoda koje do sada nisu tradicionalno korištene u rukovođenju takvih organizacija i djelatnosti, menadžmentu pruža novi alat koji može biti vrijedna pomoć na strateškoj i operativnoj razini odlučivanja. Naglasak je pritom na nužnosti da se prijedlog odluke utemelji na racionalnim argumentima. Jedna od metoda koja je u tom smislu posljednjih godina doživjela široku primjenu je npr. analiza omeđivanja podataka (AOMP), *engl. Data Envelopment Analysis (DEA)*. U nastavku rada prikazat će se osnovne postavke i značajke analize omeđivanja podataka ali i drugih višekriterijskih metoda koje se mogu primijeniti u šumarstvu. Također će se kroz kratki prikaz istraživanja provedenih na primjeru ‘Hrvatskih šuma’ d.o.o. Zagreb pružiti uvid u mogućnosti te svrsishodnost i opravdanost primjene višekriterijskih matematičkih modela kao snažne podrške planiranju i odlučivanju u šumarstvu.

## 2. MODELI VIŠEKRITERIJSKOG ODLUČIVANJA

### *Multiple criteria decision making models*

Kao što sugerira njihov naziv, modeli višekriterijskog odlučivanja<sup>2</sup> su razvijeni da bi omogućili analize u višekriterijskim situacijama odlučivanja. Obično se primjenjuju u takvim slučajevima gdje je potrebno holistički razmotriti i ocijeniti različite alternative u odlukama, pri čemu je sveobuhvatna analiza posebice otežana mnogobrojnošću teško usporedivih kriterija i suprotstavljenih interesa koji utječu na proces odlučivanja. Na taj je način, primjenom višekriterijskih modela odlučivanja, izazove u današnjem zahtjevnom i složenom planiranju šumskoga gospodarenja moguće ola-

kšati i umanjiti. O istome pišu mnogi autori, npr. Tarp i Helle 1995, Krč 1999, Kangas i Kangas 2005, Herath i Prato 2006. i dr.

Višekriterijsko odlučivanje spada u široki spektar metoda operacijskih istraživanja. Razvijene su mnogobrojne metode, pri čemu svaka od njih ima svoje specifične karakteristike i različite tehnike koje su primjenjive u odgovarajućim situacijama i slučajevima. Na primjer, neke su metode posebno namijenjene za upravljanje rizikom i nesigurnošću, ili za ne-linearne procjene, dok su druge usmjerene na primjenu u upravljanju konfliktnim zadacima i ciljevima ili u korištenju nepotpunih ili nekvalitetnih informacija. Mnoge metode također dolaze s različitim postavkama i u različitim verzijama (npr.

<sup>2</sup> *engl. Multiple Criteria Decision Making (MCDM) ili MCD Support (MCDS) ili MCD Aid (MCDA)*

'fuzzy' ili stohastičke verzije i sl.). Neke su isto tako donekle modificirane kako bi što bolje odgovorile na zadatke i probleme u određenim područjima, pa tako i šumarstvu. Svakako da operacijska istraživanja pritom ne mogu riješiti sva pitanja i probleme u šumarstvu, ali višekriterijske metode odlučivanja mogu poslužiti kao platforma na kojoj se rezultati različitih znanstvenih područja mogu sveobuhvatno iskoristiti u procesu odlučivanja. Za detaljniji prikaz operacijskih istraživanja i metoda višekriterijskog odlučivanja upućujemo na neke od mnogobrojnih izvora (Vincke 1992, Triantaphyllou 2000, Koksalan i Zionts 2001, Kahraman 2008. i dr.).

Postupak višekriterijskog odlučivanja uključuje, prvo, razradu nekoliko alternativa koje se ne mogu više poboljšati po nekom kriteriju, a da se istovremeno ne pokvare po nekom drugom kriteriju (tzv. pareto optimal-

nost ili efikasnost). Usporedba odabranih alternativa provodi se obzirom na sve prethodno postavljene kriterije i karakteristike koje imaju utjecaja na odabir određenoga rješenja. Kao rezultat sveobuhvatne usporedbe utvrđuje se prioritet i rang promatranih alternativa. Kod grupnog planiranja i odlučivanja, pojedinci mogu ovisno o osobnim kriterijima različito rangirati određene alternative. Cjelovite usporedbe pritom se mogu obaviti pridavanjem različitih težina pojedinim kriterijima, ali i mišljenjima pojedinih sudionika. Time se obuhvaća utjecaj različitih kriterija i individualnih stajališta koji se u analizama skupa uzimaju u razmatranje.

Članak se nastavlja kratkim pregledom i usporedbom nekih metoda višekriterijskog odlučivanja. Sve prikazane metode ispitane su i primijenjene u šumarstvu, a za detaljnije proučavanje određenih metoda i njihove primjene u šumarstvu, navodimo relevantne izvore.

## 2.1. Analiza omeđivanja podataka – Data envelopment analysis (DEA)

Analiza omeđivanja podataka (AOMP) posljednjih je godina postala jedna od središnjih tehnika u analizama produktivnosti i učinkovitosti. Korištena je pri uspoređivanju organizacija (Sheldon 2003), tvrtki (Galanopoulos i dr. 2006) te regija i zemalja (Vennessland 2005). U određivanju učinkovitosti poslovanja primijenjena je u bankarstvu (Davosir 2006), poljoprivredi (Bahovec, Neralić 2001), školstvu (Glass i dr. 1999), drvnoj industriji (Diaz-Balteiro i dr. 2006), šumarstvu (LeBel 1996, Kao 1998, Bogetoft i dr. 2003, Šporčić i dr. 2007, 2008, 2009) i dr. O njenom razvoju i značaju govori bibliografija analize omeđivanja podataka koja bilježi preko 3200 radova objavljenih do 2001. godine (Tavares 2002).

AOMP je metodologija određivanja relativne učinkovitosti proizvodnih i neproizvodnih jedinica kao donositelja odluke (od engl. *Decision Making Unit, DMU*) koje imaju iste inpute i outpute, a razlikuju se prema razini resursa kojima raspolazu i razinama aktivnosti unutar procesa transformacije. Na temelju podataka o korištenim inputima i ostvarenim outputima svih promatranih jedinica AOMP konstruira empirijsku granicu učinkovitosti i računa relativnu učinkovitost svake jedinice. Najuspješnije jedinice su one koje određuju granicu učinkovitosti, a stupanj neučinkovitosti ostalih jedinica mjeri se na temelju udaljenosti njihovog input-output omjera u odnosu na granicu učinkovitosti.

## 2.2. Analitički hijerarhijski proces – Analytical hierarchy process (AHP)

Analitički hijerarhijski proces (AHP) je često primjenjivana i vrlo popularna metoda u mnogim područjima, uključujući i gospodarenje prirodnim resursima. Mendoza i Sprouse (1989), Murray i Gadow (1991), Kangas (1992) neki su od autora koji su AHP primijenili u šumarstvu, a broj aplikacija se kontinuirano povećava (Pykalainen i dr. 1999, Ananda i

Dok su tipični statistički pristupi karakterizirani kao pristupi središnje tendencije koji procjenu izvode u odnosu na prosječnu proizvodnu jedinicu, AOMP se temelji na ekstremnim vrijednostima i svaku proizvodnu jedinicu uspoređuje samo s onom najboljom. Osnovna je pretpostavka pritom da ako određena jedinica može s X ulaznih resursa (inputa) proizvesti Y izlaznih proizvoda (outputa), isto bi trebale moći učiniti i ostale jedinice ukoliko rade učinkovito. Središte analize leži u pronalaženju 'najbolje' virtualne proizvodne jedinice za svaku realnu jedinicu. Ako je virtualna jedinica bolja od originalne, bilo da postiže više outputa s istim inputima ili da ostvaruje iste outpute s manje inputa, tada je ova neučinkovita.

Šumarskim stručnjacima, menadžerima i istraživačima AOMP rješenja relativne učinkovitosti mogu biti interesantna zbog tri svojstva metode:

- izravna usporedba jedinica s višestrukim inputima i outputima, pri čemu ne treba znati eksplicitni oblik veze između inputa i outputa koji mogu biti iskazani u različitim jedinicama mjere,
- karakterizacija svake organizacijske jedinice jednim rezultatom relativne učinkovitosti,
- poboljšanja koja model predlaže neučinkovitim jedinicama bazirana su na ostvarenim rezultatima organizacijskih jedinica koje posluju učinkovito.

Herath 2003, Wolfslehner i dr. 2005, Šegotić i dr. 2003, 2007).

AHP ima nekoliko prednosti sa stajališta višekriterijskog i grupnog planiranja. Objektivne informacije, stručno znanje i subjektivne preferencije se pomoću AHP metode mogu razmatrati skupno i istovremeno. Također se u obzir mogu uzeti i kvalitativni kriteriji,



dok ostale metode obično traže kvantitativne kriterije za izbor neke od alternativa.

Rješavanje složenih problema odlučivanja pomoću ove metode temelji se na njihovom rastavljanju na komponente: cilj, kriterije (podkriterije) i alternative. Ti elementi se potom povežu u model s više razina (*hijerarhijsku strukturu*) pri čemu je na vrhu cilj, a na prvoj nižoj razini su glavni kriteriji. Kriteriji se mogu rastaviti na podkriterije, a na najnižoj razini nalaze se alternative. Druga važna komponenta je matematički model pomoću kojeg se računaju prioriteti (težine) elemenata koji su na istoj razini hijerarhijske strukture. Metoda je zasnovana na usporedbama parova alternativa, svaka sa svakom, pri čemu se izražava intenzitet, težina preferencije jedne alternative u odnosu na drugu. Na isti način uspoređuju se i kriteriji pri čemu se preferencije izražavaju uz pomoć Saaty-jeve skale (S a a t y 1977, 1980).

Nedostatak metode je u tome što ne dozvoljava oklijevanje i iskazivanje nesigurnosti u usporedbama. U

upravljanju prirodnim resursima velik dio informacija i podataka na kojima se temelji planiranje i odlučivanje karakterizira određena razina nesigurnosti i neizvjesnosti. Nadalje, broj usporedbi se značajno povećava s brojem alternativa i kriterija, što može biti vrlo skupo i zahtjevno. AHP pritom ne omogućava dubinske analize usporebi. Da bi se prevladala ova ograničenja, razvijeni su različiti AHP modeli kakvi su npr. A'WOT koji predstavlja kombinaciju AHP metode i poznate SWOT analize (Kurttila i dr. 2000), analitički mrežni proces (*Analytical network process, ANP*) koji je svojevrsna nadogradnja osnovne verzije AHP (Saty 2001) i dr. Takvi hibridni modeli pritom polaze od iste ideje usporedbe parova kao praktičnoga, pedagoškog i intuitivnog pristupa. Popularnost metode temelji se u prvom redu na činjenici da je vrlo bliska načinu na koji pojedinac intuitivno rješava složene probleme rastavljajući ih na jednostavnije.

### 2.3. Jednostavno višeatributno rangiranje

#### *Simple multi-attribute rating technique (SMART)*

Metoda jednostavnog višeatributnog rangiranja (SMART) razvijena je početkom 1970-ih u okviru višeatributne teorije korisnosti (MAUT, *multiattribute utility theory*). SMART tehnika ima mnoge sličnosti sa osnovnom idejom AHP metode, no glavna razlika je u tome što SMART ne koristi usporedbu u parovima, već rangiranje alternativa obavlja izravno. Izravno rangiranje znači da se kriterijima izravno dodjeljuju numeričke vrijednosti razmjerno njihovoj važnosti. U skladu s tim izbor alternativa isto se provodi jednostavnim pridavanjem relativnih numeričkih vrijednosti koje opisuju njihov prioritet, s obzirom na svaki kriterij odlučivanja. Najčešće se nakon odabira kriterija prvo određuje glavni

kriterij kojemu se dodjeljuje vrijednost 100. Svim ostalim kriterijima dodjeljuju se vrijednosti između 0 i 100 ovisno o njihovoj važnosti prema glavnom kriteriju. Prema istom načelu pojedinim alternativama se po svakom od kriterija pridaju određene vrijednosti. Najboljoj alternativu se daje vrijednosti 100, a svim ostalima vrijednosti između 0 i 100.

Kada su utvrđene važnosti pojedinih kriterija i prioriteta u alternativama, u SMART tehnici se primijenjuju isti računski postupci kao u AHP metodi. Primjeri primjene SMART metode u upravljanju prirodnim resursima su V e n t e r i dr (1998), K a j a n u s i dr (2004).

### 2.4. Metode 'višeg ranga' – *Outranking methods*

Metode 'višeg ranga' predstavljaju europsku, odnosno Francusku školu u višekriterijskom odlučivanju. Razvijeno je više različitih metoda, a u šumarstvu se primijenjene PROMETHEE i ELECTRE (K a n g a s i dr. 2001). Ove metode uspoređuju alternative u parovima, na osnovi tzv. pseudo-kriterija. Pseudokriterije čine dvije granične vrijednosti, *prag indiferencije* i *prag preferencije* koje opisuju razliku u težini preferencija između dvije alternative. Ako je razlika, s obzirom na određeni kriterij, manja od praga indiferencije, alternative se drže indiferentima po tom kriteriju. Ako je raz-

lika veća od praga preferencije, bolja alternativa se bez sumnje smatra boljom. Ako je razlika veća od praga indiferencije, ali manja od praga preferencije, prioritet između alternativa nije siguran.

Proračuni se provode na različite načine u PROMETHEE i ELECTRE, a obje metode imaju više verzija koje odgovaraju različitim situacijama. Glavna prednost ovih metoda je u tome što ne zahtijevaju kompletne podatke o preferencijama kao npr. AHP metoda. Međutim, nedostatak je što su to prilično nejasne metode koje je dosta teško shvatiti i interpretirati.

### 2.5. Glasачke tehnike – *Voting methods*

Glasanje je poznati način iskazivanja mišljenja i utjecanja u važnim pitanjima. Glasачke tehnike se u višekriterijskom odlučivanju mogu primijeniti pri utvrđivanju kriterija, npr. kriterij koji dobije najviše glasova smatra se najvažnijim. Drugi primjer može biti glasanje o pri-

kladnosti alternativa s obzirom na određeni kriterij. Glasanje može biti provedeno po principu "jedan čovjek, jedan glas" ili se jednome glasaču daje više glasova. U slučaju glasačke tehnike 'odobrenja' (engl. *Approval Voting*) daje se glas za svaku opciju koja se smatra prihva-

tljivom. Kod tzv. ‘borda glasanja’ (engl. *Borda Count*) svaki glasač daje  $n$  glasova za, po njemu, najbolju opciju,  $n - 1$  glasova za sljedeću i tako dalje dok ne preostane jedan glas za onu najlošiju. Navedene tehnike tek su primjeri velikog broja načina glasanja.

Glasačke tehnike razvijene su za obradu situacija s niskom kvalitetom podataka o preferencijama. Jednostavnost i obuhvatnost glasačkih tehnika njihova je glavna prednost, posebice pri grupnom planiranju i odlučivanju. Uključivanjem većeg broja informacija one

sve više sliče SMART metodi. Općeniti je stav pritom da glasačke tehnike ne treba modificirati i dodatno komplicirati za primjene za koje već postoje posebne višekriterijske aplikacije. ‘Metoda višekriterijskog odobrenja’ (engl. *Multicriteria Approval method*) je metoda koja je zasnovana na glasačkoj tehnici odobrenja i primijenjena je u šumarstvu (Laukkanen i dr. 2002, Kangas i Kangas 2004). Glasačke tehnike još su primijenili npr. Shields i dr. (1999) i Hiltunen i dr. (2008).

## 2.6. Analiza stohastičke višekriterijske prihvatljivosti

### *Stochastic multicriteria acceptability analysis (SMAA)*

Slično kao i SMART, analiza stohastičke višekriterijske prihvatljivosti (SMAA) zapravo predstavlja skup metoda. Prvotno su razvijene za diskretne višekriterijske probleme s nepotpunim i/ili nepouzdanim kriterijima gdje, zbog nekih razloga, od donositelja odluka nije bilo moguće dobiti podatke o težinama i preferencijama. SMAA metode su zasnovane na određivanju onih vrijednosti težina koje će svaku od alterantiva učiniti najboljom ili joj dati određeni rang. Glavni pokazatelji SMAA proračuna uključuju tzv. indekse prihvatljivosti, koji opisuju vjerojatnost rangiranja određene alternative. Naime, ako težine ili važnosti kriterija nisu unaprijed određene, indeksi prihvatljivosti prikazuju dominantnost alternativa u svim mogućim težinskim kombinacijama

kriterija. Indeks ukupne prihvatljivosti može se izračunati npr. kao težinski prosjek vjerojatnih rangova različitih alternativa, s najvećom težinom za prvo mjesto, zatim drugo i tako dalje. Ovakav način blizak je šumarstvu, gdje se može reći da se uslijed snažne nesigurnosti u planiranju, najčešće niti jedna od razmatranih alternativa ne može sa sigurnošću proglasiti najboljom.

Prve primjene SMAA metoda u šumarstvu provedene su u kontekstu planiranja upravljanja šumskim ekosustavom (Kangas i dr. 2003, Kangas i Kangas 2004). Budući su mnoge karakteristike SMAA metode korisne u današnjem upravljanju prirodnim resursima, sve je veći interes za njih i u šumarstvu (Kangas i dr. 2006, Diaz-Balteiro i Romero 2008).

## 2.7. AOMP i druge metode višekriterijskog odlučivanja

### *DEA and other multi-criteria decision models*

Kratki opis nekih metoda višekriterijskog odlučivanja i njihove primjene pokazuje da se one znatno razlikuju. Očito je pritom da različitim situacijama i problemima najbolje odgovaraju različite metode. Niti jedna metoda nije univerzalna i najbolja, čak ni primjenjiva, u svim slučajevima. Izbor najbolje ili jednostavno

odgovarajuće metode za potporu u odlučivanju zahtjeva poznavanje više modela, njihovih postavki, prednosti i ograničenja, kao i karakteristika te zahtjeva specifičnih situacija i problema u planiranju i odlučivanju. U tablici 1 prikazane su karakteristike nekih metoda višekriterijskog odlučivanja i njihova usporedba.

Tablica 1. Karakteristike metoda višekriterijskog odlučivanja (prema Sarkis i Weinrach 2001)

Table 1 Multiple criteria evaluation technique characteristics (Sarkis i Weinrach 2001)

Metoda <i>Evaluation technique</i>	Troškovi <i>Cost of implementation</i>	Zahtjev za podacima <i>Data requirement</i>	Osjetljivost <i>Ease of sensitivity</i>	Razumljivost <i>Management understanding</i>	Matematička složenost <i>Mathematical complexity</i>	Fleksibilnost <i>Parameter mixing-flexibility</i>
AOMP - DEA	S	S	N	N	V	S
AHP	S	S	N	S	N	V
Ekspertni sustavi <i>Expert systems</i>	V	V	N	S	V	V
Ciljno programiranje <i>Goal program</i>	S	S	S	N	V	N
MAUT	V	V	S	S	S	V
Metode višeg ranga <i>Outranking</i>	S	S	N	N	S	S
Simulacije <i>Simulation</i>	V	V	V	V	V	S
Scoring modeli <i>Scoring models</i>	N	N	N	V	N	V

V – visoko - *high*; S – srednje - *medium*; N – nisko - *low*

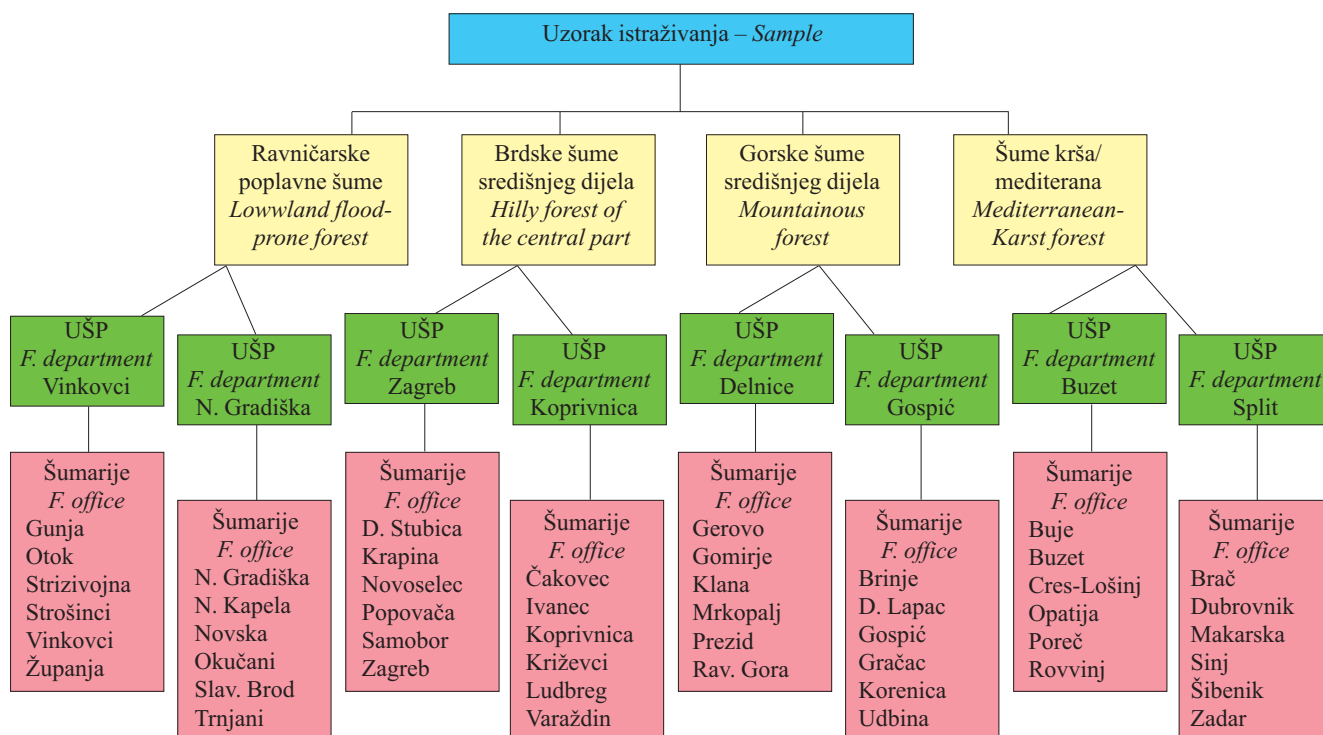
Iz tablice 1 vidljivo je da npr. AOMP u više karakteristika nije dominantna nad ostalim metodama. Njena primjena je umjereno skupa s obzirom na troškove osposobljavanja i prikupljanja podataka. Osjetljivost metode na promjene u podacima je mala, a razumijevanje od strane menadžmenta je relativno nisko, uglavnom zbog njene matematičke složenosti. Rezultate je lako shvatiti, jer uspoređivane jedinice rangira prema učinkovitosti, a fleksibilnost omogućava uključivanje više parametara i čimbenika u analize.

### 3. PRIMJER HRVATSKIH ŠUMA – Example of Croatian forests

Putem analize omeđivanja podataka ocijenjena je učinkovitost organizacijskih jedinica “Hrvatskih šuma” d.o.o. Zagreb. U istraživanja su uključene odabrane šumarije kao predstavnici četiri glavnih regija u hrvatskom šumarstvu: 1) ravničarskih poplavnih šuma, 2) brdskih šuma središnjeg dijela, 3) gorskih šuma i 4) šuma krša/mediterana. Svaka je regija zastupljena u analizama

Općenito je teško izravno usporediti različite modele. Svaki ima svoje prednosti i nedostatke. Primjena često ovisi o situaciji odlučivanja, pri čemu dostupnost podatka, vrijeme i troškovi utječu na odabir određene metode. U svakom slučaju, prilikom primjene u analiza istraživači, stručnjaci i menadžeri trebaju biti svjesni njihovih ograničenja.

s dvije Uprave šuma Podružnice (UŠP), odnosno sa šest šumarija iz svake Uprave (slika 1). U istraživanju su primijenjeni osnovni CCR i BCC<sup>3</sup> modeli orijentirani outputima, tj. usmjereni su na određivanje maksimalnih outputa koje je moguće postići uz korištenje zadane količine inputa.



Slika 1. Shema uzorka organizacijskih jedinica obuhvaćenih istraživanjima  
Figure 1. Sample of the forestry organizational units involved in the research

Utvrđivanje inputa i outputa, uz izbor osnovnog modela, smatra se jedinim elementom unošenja subjektivnosti u AOMP. Oni su u primjeru izabrani tako da odražavaju poslovanje šumarija kao temeljnih organizacijskih jedinica hrvatskog šumarstva u kojima se ostvaruju stručno-tehničke zadaće i većina prihoda i izravnih troškova gospodarenja šumama.

Kao inputi u model su uključeni:

Površina – ukupna površina šuma i šumskih zemljišta određene šumarije,

Drvena zaliha – bruto obujam svih stabala koja su prekoračila taksacijsku granicu,

Troškovi – ukupno ostvareni troškovi poslovanja šumarija,

Zaposlenici – ukupan broj zaposlenih radnika u pojedinim šumarijama.

<sup>3</sup> CCR – po autorima Charnes-Cooper-Rhodes  
BCC – po autorima Banker-Charnes-Cooper

Kao outputi u model su uključeni:  
 Prihodi – ukupno ostvareni prihodi poslovanja šumarija,  
 Etat – ostvareni neto obujam etata,  
 Investicije u infrastrukturu – duljina novoizgrađenih  
 šumskih cesta,

Biološka obnova šuma – površina na kojoj su provedeni radovi uzgoja i zaštite.

U tablici 2 dana je deskriptivna statistika inputa i outputa uključenih u analizu.

Tablica 2. Statistika inputa i outputa uključenih u AOMP model

Table 2 Descriptive statistics of the variables used in the DEA model

Varijabla - Variable	Srednja vrijednost - Mean	St. Devijacija - St. deviation	Min - Min	Max - Max	Ukupno - Total
<b>Inputi - Inputs</b>					
Površina, 10 <sup>3</sup> ha <i>Area, 10<sup>3</sup> ha</i>	11,42	10,36	2,60	49,87	547,96
D. zaliha, m <sup>3</sup> /ha <i>G. stock, m<sup>3</sup>/ha</i>	214,98	91,94	51,85	418,00	-
Troškovi, 10 <sup>5</sup> kn <i>Costs, 10<sup>5</sup> kn</i>	152,35	93,61	23,24	470,31	7312,99
Zaposleni, N <i>Employees, N</i>	42	21	8	100	2007
<b>Outputi - Outputs</b>					
Prihod, 10 <sup>5</sup> kn <i>Income, 10<sup>5</sup> kn</i>	157,20	106,40	21,12	538,41	7545,68
Etat, m <sup>3</sup> /ha <i>Harvest, m<sup>3</sup>/ha</i>	3,06	2,19	0,00	8,78	-
Investicije, km <i>Investments, km</i>	2,24	4,29	0,00	22,59	107,48
B. obnova, ha <i>B. renewal, ha</i>	422,26	606,34	30,21	3846,34	20268,47

Za rješavanje CCR i BCC modela korišten je programski paket DEA Excel Solver, pri čemu je relativna tehnička učinkovitost utvrđena posebno za svaku šumariju. Prosječna CCR učinkovitost promatranih šumarija iznosi 0,829, što znači da prosječna (pretpostavljena) šumarija, ako želi poslovati na granici učinkovitosti treba koristiti samo 82,9 % količine inputa koju trenutno koristi i proizvoditi istu količinu outputa koju trenutno proizvodi. Odnosno, trebala bi, ako želi poslovati učin-

kovito, uz korištenu razinu inputa proizvoditi 20,6 %<sup>4</sup> više outputa. Prema BCC modelu, učinkovitost prosječno iznosi 0,904. To znači da prosječna šumarija, ako želi biti učinkovita treba koristiti samo 90,4% postojećih inputa i proizvoditi istu količinu outputa. Odnosno, trebala bi proizvoditi 10,6%<sup>5</sup> više outputa uz jednake inpute. Učinkovitost s obzirom na opseg djelovanja (*scale efficiency*, SE – omjer rezultata CCR i BCC učinkovitosti) pokazuje koliko je veličina promatrane jedinice

Tablica 3. Rezultati osnovnih AOMP modela

Table 3 Results obtained with the base case DEA models

	CCR model	BCC model	SE - scale efficiency
Broj šumarija, N <i>Number of forest offices, N</i>	48	48	48
Relativno učinkovite šumarije, N <i>Relatively efficient forest offices, N</i>	15	24	16
Relativno učinkovite šumarije, % <i>Relatively efficient forest offices, %</i>	31 %	50 %	33 %
Prosječna relativna učinkovitost, E <i>Average relative efficiency, E</i>	0,829	0,904	0,919
Maximum – maksimum	1,000	1,000	1,000
Minimum – minimum	0,407	0,524	0,501
Standardna devijacija – St. deviation	1,170	0,129	0,138
Šumarije s učinkovitosti manjom od E, N <i>F. offices with efficiency lower than E, N</i>	23	18	12

<sup>4</sup> Lako se dobije da je  $20,6\% = (1 - 0,829)/0,829$

<sup>5</sup> Lako se dobije da je  $10,6\% = (1 - 0,904)/0,904$



blizu ili daleko od njezine optimalne veličine. SE iznosi 0,919, što znači da bi analizirane šumarije svoju relativnu učinkovitost povećale prosječno za 8 % kada bi svoju veličinu, odnosno opseg djelovanja prilagodile optimalnoj veličini. Prikaz glavnih rezultata AOMP analize nalazi se u tablici 3.

Uspoređivanjem relativne učinkovitosti šumarija po veličini, regiji, strukturi etata i drugim čimbenicima utvrđeno je da prosječno najvišu razinu učinkovitosti imaju šumarije s površinom od 10 do 15000 hektara, odnosno šumarije koje gospodare s 200 – 300 m<sup>3</sup>/ha drvne zalihe. Također je utvrđeno da je najveća prosječna učinkovitost postignuta u upravama šuma Vinkovci, Zagreb i Gospić,

#### 4. RASPRAVA I ZAKLJUČCI – Discussion and conclusions

Planiranje i odlučivanje u šumarstvu je naglašeno kompleksno uslijed višestrukih ciljeva gospodarenja šumama. Načelo održivog razvoja pretpostavlja upravljanje i uporabu šuma i šumskog zemljišta na način da se održava njihova biološka raznolikost, produktivnost, sposobnost obnavljanja, vitalnost i potencijal da bi šume ispunile sada i u budućnosti bitne gospodarske, ekološke i socijalne funkcije. Sve nabrojeno svakodnevno zaostava uvjete poslovanja u šumarstvu, a menadžmentu nalaže stalne analize svih relevantnih pokazatelja gospodarenja. Pritom su naglasci najčešće na standardiziranim naturalnim i financijskim pokazateljima proizvodnje i poslovanja. U ovom izrazito dinamičnom razdoblju gospodarenja prirodnim resursima šumarskim stručnjacima su pak potrebni modeli kojima se različiti računovodstveni i financijski podaci pretvaraju u upotrebljive informacije. U takvim su okolnostima od velike važnosti metode i tehnike koje mogu doprinijeti pouzdanijem planiranju i objektivnijem odlučivanju s jedne strane, te modeli objektivne analize i ocjenjivanja rezultata gospodarenja šumama s druge strane.

U radu su prikazani modeli koji u razmatranje istodobno uzimaju više kriterija tako da mogu dati obuhvatniju mjeru poslovanja i poslužiti kao podrška u planiranju i odlučivanju. Cilj je bio pojasniti za koje se vrste zadataka i problema takve metode mogu primijeniti u šumarstvu. Time je omogućen uvid u karakteristike pojedinih metoda i pomoć u odabiru potencijalnih metoda kod eventualne primjene. Vrijedna informacija o ulozi i značaju višekriterijskih modela u šumarstvu dana je citiranim radovima i posebno konkretnim primjerom primjene takvih modela kroz istraživanja provedena u Hrvatskim šumama.

U primjeni višekriterijskog odlučivanja posebnu pozornost treba posvetiti kvaliteti i dostupnosti informacija koje su prema postavljenim kriterijima potrebne za analizu i ocjenu alternativnih odluka. Odgovarajuća metoda treba biti odabrana na način da se svi podaci koji su dostupni uz razuman napor i zalaganje mogu što bolje iskoristiti. Također je dobro primijeniti modele koje do-

odnosno na području ravničarskih poplavnih šuma. Za detaljniji prikaz provedenih istraživanja upućujemo na radove Šporčić 2007 i Šporčić i dr. 2009.

Primjena AOMP metode omogućava menadžmentu da na osnovi analize i usporedbe rezultata relativne učinkovitosti rangira organizacijske jedinice. Za neučinkovite jedinice utvrđuju se projekcije na granicu učinkovitosti kao i izvori i iznosi neučinkovitosti. Na taj se način utvrđuju potencijalne promjene inputa i/ili outputa potrebne za postizanje relativne tehničke učinkovitosti i određuju ciljevi koje bi neučinkovite jedinice trebale ostvariti kako bi postale učinkovite.

nositelji odluka i drugi sudionici mogu razumijeti i shvatiti te čije je rezultate i proračunske postupke lako interpretirati i ilustrirati. Nažalost, višekriterijske aplikacije su često isuviše tehničke, pa ili previše pojednostavljaju stvarne slučajeve ili su presložene za primjenu, razumijevanje i tumačenje. U takvim uvjetima njihova primjena često zahtijeva posebna znanja i/ili pomoć osposobljenih stručnjaka. Isto tako, pojedinci su različito opremljeni za sudjelovanje u analizama i odlukama te se razlikuju u znanjima i vještinama. Novije studije ukazuju na hibridne pristupe ili korištenje više modela i tehnika istovremeno. Interaktivna primjena više metoda pridonosi učinkovitosti analiza, odnosno objektivnosti i pouzdanosti procjena, ali i učenju i osposobljavanju.

U šumarstvu se vrlo često pri planiranju i odlučivanju moramo osloniti na više ili manje nepotpune podatke, nedostatne informacije ili ponekad na čisto deskriptivne podatke. Na taj način u gospodarenju šumama baratamo s mnogo nesigurnosti, neizvjesnosti i rizika koji ne dozvoljavaju precizne procjene i planove. Upravo se u tom smislu smatra da metode ‘višekriterijskog odobrenja’, AHP, SMAA i dr. imaju potencijala za šire prihvaćanje u šumarstvu i da će njihova primjena u budućnosti još rasti. Višekriterijski modeli pritom ne mogu zamijeniti tradicionalne alate i postupke u planiranju šumskog gospodarenja. Umjesto toga, oni se trebaju nadopunjavati. Tako su, numeričke simulacije i optimizacije važne za procjene budućih proizvodnih mogućnosti i donošenje proizvodnih planova, iako možda ne uspijevaju pokriti sve probleme multifunkcionalnog gospodarenja šumama. U takvim slučajevima njihove procjene i rezultati, kao i drugi informacijski izvori kakvi su GIS, stručne prosudbe, subjektivne preferencije ili deskriptivni podaci, mogu se koristiti u zajedničkom okviru s metodama višekriterijskog odlučivanja.

Istraživanja i primjena višekriterijskih modela posljednjih su godina znatno zastupljeni u mnogim područjima, a posebice u upravljanju prirodnim resursima. Dodatno, pridobili su zanimanje ne samo znanstvenika i istraživača, već i stručnjaka i praktičara. U šumarstvu su primi-



jenjeni s namjerom boljšega odgovora današnjim izazovima u gospodarstvu šumama. Složenost poslovnog okruženja, imperativ ekološke prihvatljivosti i poslovne uspješnosti, uz istovremeno održivo gospodarstvo šumama, nalaže potrebu za novim i preciznijim modelima i tehnikama. Razvojem i primjenom analize omeđivanja podataka i drugih modela višekriterijskog odlučivanja

moguće je obogatiti šumarsku znanost i praksu pristupom, koji bi trebao pridonijeti lakšem analiziranju, planiranju i predviđanju pri gospodarstvu šumama. Općenito se smatra da višekriterijski modeli u šumarstvu, jednako kao u mnogim drugim poslovnim sustavima, mogu biti vrlo snažna podrška planiranju i odlučivanju.

#### LITERATURA – References

- Ananda, J., G. Herath, 2003: The use of Analytic Hierarchy Process to incorporate stakeholder preferences into regional forest planning. *Forest Policy and Economics*, 5, (1): 13–26.
- Bahovec, V., L. Neralić, 2001: Relative efficiency of agricultural production in county districts of Croatia. *Mathematical Communications – Supplement 1* (2001), 1: 111–119.
- Bogetoft, P., B. J. Thorsen, N. Strange, 2003: Efficiency and merger gains in the Danish Forestry Extension Service. *Forest Science*, 49 (4): 585–595.
- Davosir Pongrac, D., 2006: Efikasnost osiguravajućih društava u Republici Hrvatskoj. Magistarski rad, Ekonomski fakultet, Zagreb, str. 1–139 + III.
- Diaz-Balteiro, L., A. C. Herruzo, M. Martinez, J. González-Pachón, 2006: An analysis of productive efficiency and innovation activity using DEA: An application to Spain's wood-based industry. *Forest Policy and Economics*, vol. 8 (7): 762–773.
- Diaz-Balteiro, L., C. Romero, 2008: Making forestry decisions with multiple criteria: A review and an assessment. *Forest Ecology and Management*, 255 (8–9): 3222–3241.
- Galanopoulos, K., S. Aggelopoulos, I. Kamenidou, K. Mattas, 2006: Assessing the effects of managerial and production practices on the efficiency of commercial pig farming. *Agricultural Systems* 88 (2–3): 125–141.
- Glass, J. C., D. G. McKillop, G. O'Rourke, 1999: A cost indirect evaluation of productivity change in UK universities. *J Prod Anal* 10 (2): 153–75.
- Herath, G., T. Prato, 2006: Using multi-criteria decision analysis in natural resource management. Ashgate publishing, 239 p., Hampshire, England
- Hiltunen, V., J. Kangas, J. Pykäläinen, 2008: Voting methods in strategic forest planning – Experiences from Metsähallitus. *Forest Policy and Economics*, 10 (3): 117–127.
- Kahrman, C., 2008: Fuzzy multi-criteria decision making: theory and applications with recent developments. 591 p., Berlin/Heidelberg.
- Kajanus, M., J. Kangas, M. Kurttila, 2004: The use of value focused thinking and the A'WOT hybrid method in tourism management. *Tourism Management*, 25 (4): 499–506.
- Kangas, J., 1992: Multiple-use planning of forest resources by using analytic hierarchy process. *Scan. J. For. Res.*, 7: 259–268.
- Kangas, A., J. Kangas, J. Pykalainen, 2001: Outranking methods as tools in strategic natural resources planning. *Silva fenn.* 35: 215–227.
- Kangas, J., J. Hokkanen, A. Kangas, R. Lahdelma, P. Salminen, 2003: Applying stochastic multicriteria acceptability analysis to forest ecosystem management with both cardinal and ordinal criteria. *For. sci.* 49: 928–937.
- Kangas, J., A. Kangas, 2004: Multicriteria approval and SMAA-O in natural resource decision analysis with both cardinal and ordinal criteria. *J. multi-criteria decision anal.*, 12: 3–15.
- Kangas, J., A. Kangas, 2005: Multiple criteria decision support in forest management – the approach, methods applied, and experiences gained. *Forest ecology and management*, (207): 133–143.
- Kangas, A., J. Kangas, R. Lahdelma, P. Salminen, 2006: Using SMAA-2 method with dependent uncertainties for strategic forest planning. *Forest Policy and Economics*, 9, (2): 113–125.
- Kao, C., 1998: Measuring the efficiency of forest districts with multiple working circles. *Journal of the Operational Research Society*, 49: 583–590.
- Koksalan, M. M., S. Zionts, 2001: Multiple criteria decision making in the new millennium. Springer, 478 p., Berlin/Heidelberg.
- Krč, J., 1999: Večkriterijalno dinamično vrednotenje tehnoloških, ekonomskih, socialnih in ekoloških vplivov na gospodarjenje z gozdovi. Disertacija, Biotehniška fakulteta, Univerza v Ljubljani, 174 str. Ljubljana.
- Kurttila, M., M. Pesonen, J. Kangas, M. Kajanus, 2000: Utilizing the analytical hierarchy process (AHP) in SWOT analysis – a hybrid method and its application to a forest certification case. *For. policy econ.*, 1: 41–52.

- Laukkanen, S., A. Kangas, J. Kangas, 2002: Applying voting theory in natural resource management: a case of multiple-criteria group decision support. *J. environ. manage.*, 64: 127–137.
- LeBel, L. G., 1996: Performance and efficiency evaluation of logging contractors using Data envelopment analysis. Dissertation, Virginia Polytechnic Institute and State University. Blacksburg, 201 p.
- Mendoza, G. A., Sprouse, W., 1989: Forest planning and decision making under fuzzy environments: an overview and illustrations. *For. sci.*, 35: 481–502.
- Murray, D. M., K. Gadow, 1991: Prioritizing mountain catchment areas. *J. environ. manage.*, 32: 357–366.
- Pykalainen, J., J. Kangas, T. Loikkanen, 1999: Interactive decision analysis in participatory strategic forest planning: experiences from state owned boreal forests. *J. for. econ.*, 5: 341–364.
- Sarkis, J., J. Weinrach, 2001: Using data envelopment analysis to evaluate environmentally conscious waste treatment technology. *Journal of Cleaner Production*, 9 (5): 417–427.
- Saty, T. L., 1977: A scaling method for priorities in hierarhical structures. *J.mathemat.psych.* 15: 234–281.
- Saty, T. L., 1980: The analytical hierarchy process. McGraw-Hill, New York.
- Saty, T. L., 2001: Decision making with dependance and feedback – the analytic network process. RWS Publications, Pittsburgh.
- Sheldon, G. M., 2003: The efficiency of public employment services. A nonparametric matching function analysis for Switzerland. *Journal of Productivity Analysis*, 20: 49–70.
- Shields, D. J., B. Tolwinski, B. M. Keny, 1999: Models for conflict resolution in ecosystem management. *Socio-Econ. Plann. sci.*, 33: 61–84.
- Šegotić, K., M. Šporčić, I. Martinić, 2003: The choice of a working method in forest stand thinning. *SOR '03 Proceedings – The 7th International Symposium on Operational Research in Slovenia, Podčetrtek, Slovenia, September 24–26, 2003.*, p. 153–159.
- Šegotić, K., Šporčić, M., Martinić, I., 2007: Ranking of the mechanisation working units in the forestry of Croatia. *SOR '07, Proceedings of the 9th International Symposium on Operational Research, Nova Gorica, Slovenia, September 26–28, 2007.*, p. 247–251.
- Šporčić, M., 2007: Ocjena uspješnosti poslovanja organizacijskih cjelina u šumarstvu neparametarskim modelom. Disertacija, Šumarski fakultet Sveučilišta u Zagrebu, str. 1–112 + VIII.
- Šporčić, M., I. Martinić, K. Šegotić, 2007: Ocjena efikasnosti radnih jedinica u šumarstvu analizom omeđivanja podataka. *Nova mehanizacija šumarstva*, vol. 28: 3–15.
- Šporčić, M., I. Martinić, M. Landekić, M. Lovrić, 2008: Analiza omeđivanja podataka kao metoda efikasnosti – mogućnosti primjene u šumarstvu. *Nova mehanizacija šumarstva*, vol. 29: 51–59.
- Šporčić, M., I. Martinić, M. Landekić, M. Lovrić, 2009: Measuring efficiency of organisational units in Forestry by nonparametric model. *Croatian Journal of Forest Engineering*, vol. 30 (1): 1–13.
- Tarp, P., F. Helles, 1995: Multi-criteria decision making in forest management planing. *J. For. Econ.* 53, 53–70.
- Tavares, R., 2002: A bibliography of Data envelopment analysis (1978–2001). Ructor Research Report.
- Triantaphyllou, E., 2000: Multi-criteria decision making methods: a comparative study. Kluwer, 288 p., Dordrecht, Netherlands.
- Vennesland, B., 2005: Measuring rural economic development in Norway using data envelopment analysis. *Forest Policy and Economics* 7 (2005): 109–119
- Venter, S. N., A. L. Kühn, J. Harris, 1998: A method for the prioritization of areas experiencing microbial pollution of surface water. *Water Science and Technology*, 38, (12): 23–27.
- Vincke, Ph., 1992: Multi-criteria decision aid. Wiley, New York.
- Wolfslehner, B., H. Vacik, M. J. Lexer, 2005: Application of the analytic network process in multi-criteria analysis of sustainable forest management. *Forest Ecology and Management*, 207 (1–2): 157–170.

*SUMMARY: Planning and decision making in forestry is characterized with a high degree of complexity due to multiple goals of forest management. The principle of the sustainable development is incorporated in management and utilization of forests and forest land in a way that adheres to biological diversity, productivity, regeneration capacity, vitality and potential of the forest to fulfill, now and in the future, its important economical, ecological and social functions. All of the above complicates the performing of daily forestry operations, while managers are conditioned to perform constant analyzes of all relevant management indicators. The emphasis in these analyzes is put on standardized natural and financial indicators of production and management. In this highly dynamical period for the management of natural resources forestry experts need models in which different accounting and financial data is transformed into easily usable information. In such circumstances methods and techniques that can contribute to more reliable planning and to more objective decision making are of great importance, as are the models of objective analysis and management result-scoring methods.*

*This paper provides an overview of models which take into consideration simultaneously several criteria, so that they can provide more comprehensive measures of management, and to serve as a background for planning and decision making. Several methods of multiple-criteria decision making has been described and compared. Brief description and comparison presented in the paper includes following multi-criteria methods: data envelopment analysis (DEA), analytic hierarchy process (AHP), simple multi-attribute rating technique (SMART), outranking methods, voting methods and stochastic multicriteria analysis (SMAA). The goal is to explain for which types of tasks and problems these methods can be applied in the field of forestry. That provides an insight into characteristics of the respective methods and a guideline to eventual choice of which method to apply. A valuable contribution on the role and significance of the multiple-criteria decision making models in forestry is provided through cited papers, and specially through concrete example of the application of such models through the research performed within "Hrvatske šume" Ltd. Zagreb. In this research the efficiency of organizational units in the Croatian forestry is evaluated by applying DEA. The results of relative efficiency are based on calculation of output oriented CCR and BCC models. Frequency of efficient units in reference set of inefficient units is given. The sources and values of inefficiencies are established and the impact of structural characteristics on relative efficiency of forest offices is shown. Forest offices are also grouped by Forest Administrations and regions they belong to.*

*In the selection and application of multiple-criteria decision making methods a special attention must be paid to the quality and availability of information which are needed for the analysis and grading of alternatives, according to the set criteria. An appropriate method must be chosen in a way in which all the data available with the reasonable amount of effort and dedication could be utilised as fully as possible. It is also good to apply models which decision makers and other stakeholders can understand, and whose results and calculations they can easily illustrate and interpret. However, practical multiple-criteria decision making applications are usually too "technical", so real cases and situations are either over-simplified, or they are too complex for application, comprehension and interpretation. In such conditions their application in decision making and management often needs special knowledge and/or help of trained experts. At the same time, the differences in the types of individuals involved in the process of planning and decision making has to be also taken into consideration. People differ between each other in knowledge and skills, and they are differently prepared do participate in analyzes and decision making. Recent studies demonstrate to the*

*usage of hybrid methods, or to the usage of several models and techniques simultaneously. Interactive application of several methods contributes to the efficiency of the analyzes, that is to the objectivity and to the reliability of estimates, but also to learning and raising capacities.*

*In forestry, planning and decision making is often based on more or less incomplete information, missing information, or sometimes on purely descriptive information. In that way the process of forest management is tackled with much of insecurity, incertitude and risk, which does not allow precise estimates and planning. In that context the methods of multiple-criteria decision making, such as AHP and SMAA, have potential for the wider acceptance in forestry and natural resource management. Multiple-criteria models cannot replace traditional tools and procedures in forest planning; on the contrary, they should be complementary. In that sense, the numerical simulations and optimizations are important for the estimation of future production abilities and decision making related to production planning, although they may not be able to enlist all the relative problems of multi-functional forest management. In that cases their estimations and results, as any other information sources (such as GIS, expert judgments, subjective preferences of descriptive data) can be used within a common framework with the methods of multiple-criteria decision making.*

*In the last few years, the research and the application of multiple-criteria decision making models has been widely represented in many areas, and especially in the management of natural resources. Additionally, besides scientists and researchers these methods have gained interest of experts and practitioners. In forestry they are applied with an intention of better responding to current challenges in forest management. The complexity of business environment, the imperative of ecological acceptability and business success with simultaneous sustainable management of forests creates a demand for new and more precise models and techniques in forestry. Through development and application of analysis which encompasses different models of multiple-criteria decision making it is possible to contribute to more simplified analysis, planning and foreseeing in forest management. Generally, it is considered that multiple-criteria decision making models in forestry, as in other business systems, can be very strong support to planning and decision making.*

*Key words: Multiple criteria decision making, forestry, forest management, DEA, AHP*