UDK 634.0:519.8
Prethodno priopćenje
Primljeno: 03.06.1993.

Dr. LIDIJA ZADNIK STIRN,
Biotehnički fakultet Ljubljana

UPRAVLJANJE ŠUMOM PO EKONOMSKOM KRITERIJU S DINAMIČKIM PROGRAMIRANJEM

Šuma je vrlo sofisticirani prirodni resurs s mogućnošću neprestanog obnavljanja s kojim se treba upravljati preko određenih ekonomskih ciljeva i ciljeva iz okruženja. Proces koji usmjerava razvoj šume od početnog do konačnog stanja je dugoročan. Sastoji se od nekoliko faza i obuhvaća sekvencije relativno sličnih odluka. Zato se na politiku optimalnog upravljanja šumom može gldati kao na veliki kombinatorni problem. U modelu je problem opisan kao višefazni otimalizacijski problem u kojem se traži maksimum diskontirane vrijednosti proizvodnje drveća za vrijeme tih faza. Optimalni niz odluka koji se donosi za vrijeme rasta šume određen je korištenjem diskretne dinamičke procedure koju je razvio Bellman(1975).

1. UVOD

Prihvatljiva stabilnost okruženja je vrlo važna za životni standard. Od prirode se zahtijeva da nas opskrbljava hranom i drugim sirovinama. Općenito priželjkivani cilj šumarstva je da učini šumu sposobnom da ostvari neprekidni tok drveća i drugih šumskih pogodnosti. Zbog toga se problem upravljanja šumom sastoji u pretvaranju trenutnog stanja šume u takvo završno stanje da se aproksimirani jednaki godišnji prihodi mogu vječno ostvarivati. Ciljno stanje šume ne omogućava samo konstantni tok drveća, već također i stabilan prihod, zaposlenost i druge beneficije za društvo. Dok vrše pretvaranje postojećeg stanja šume i ciljno stanje, poslovoditelji moraju donositi niz relativno jednakih odluka (npr. odluke o vremenu i količini žetve) koje nalaze maksimum pri ostvarivanju određenog cilja. Pošto je šuma vrlo sofisticirani prirodni resurs koji se obnavlja i s kojim se treba upravljati pomoću određenih ekonomskih i ciljeva okruženja, predviđanje posljedica posebnih odluka o šumi nije jednostavan zadatak. Modeli pomažu poslovoditelju šume da predvidi posljedice svoje akcije pošto je model sredstvo koje dovodi realni svijet u laboratorij ili ured. Poslovoditelj može provoditi eksperimente s modelom, a koji se ne bi mogli izvršiti u šumi. Matematički modeli rade sa svim mogućim rješenjima problema, a izabiru optimalna. Dakle, poslovoditelji dobijaju bolje informacije o odlukama koristeći se matematičkim modelima od onih dobivenih pomoću neformalnih, većinom intuitivnih modela.

Jedan od najranijih primjera modela upravljanja šumom je Cotta metoda (1820) ili ideja normalne šume (Heyer, 1826, Hundeshagen, 1841) (Klepac, 1965). Brzi razvoj algoritma na polju operacijskih istraživanja i doprinosa ekonomike pri uspostavljanju matematičkih modela koristi se u upravljanju šumom (Bare i drugi, 1984). Tako se za vrijeme 60-tih i 80-tih godina razvijala metodologija planiranja, u kojoj se najviše primjenjivalo linearno programiranje (Atkinson, 1974). U modelima upravljanja šumom koristio je Kao (1982) stohastičke metode, dok su O'Hara i drugi (1989) navodi heurističke procedure. Međutim, šuma je komplicirani biološki i ekonomski sustav, nije razumljivo očekivati da bilo koji matematički model može pružiti sve odgovore na sadržajno i višestruko korištenje šume. Ali nada, da optimazicijski modeli mogu dati skup politika koje rezultiraju poboljšanjem odluči-

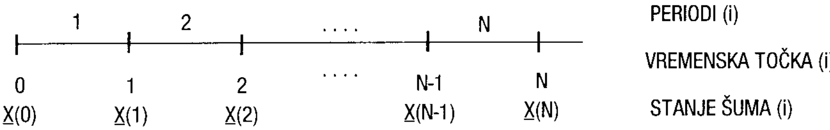

Slika 1. Proces upravljanja šumom

vanja pri upravljanju šumom potiče nas da razvijemo matematički model. U takvom se modelu stvarnost ne obuhvaća simboličkim varijablama i formalnim algebarskim vezama. Model se temelji na ideji diskretnog dinamičkog programiranja i koristi Bellmanov princip optimalnosti kao svoju optimizacijsku tehniku. Kao takav može biti relevantan za optimizaciju više drugih dugoročnih optimizacijskih procesa.

2. OPĆI MODEL UPRAVLJANJA ŠUMOM

Proces rasta, njegovanja i eksploatacije šume u bilo kojem vremenu t prikazuje se:

$$\underline{x}'(t+\delta) = f(\underline{x}(t), \underline{d}(\underline{x}(t)), \quad t \in (0,T) \qquad (1)$$

gdje je:

- $\underline{x}(t)=(x_1,x_2,...)$ vektor koji opisuje aktualno stanje šume u vremenu t. Njegove komponente predstavljaju varijable stanja kao što su stabla u neposječenoj šumi, parametri funkcije rasta, maksimalni kapaciteti rasta, kakvoća postojeće vrste drveća, faze razvoja klasa šuma.. $\underline{x}(t) \in X(t)$, gdje je X(t) konačni skup svih mogućih stanja šume u vremenu t.
- $\underline{d}(\underline{x}(t)) = (d_1,d_2,...)$ je vektor odlučivanja i prikazuje sve moguće odluke. Njegove komponente pokazuju varijable odlučivanja kao što su prorjeđivanje, čista sječa, zamjena postojećih vrsta drveća s novim itd. u stanju šume $\underline{x}(t)\cdot\underline{d}(\underline{x}(t) \;\; D \in t)$, gdje je D(t) konačni skup svih mogućih odluka. U upravljanju šumom se pretpostavlja da su odluke na istom mjestu i u istom vremenu zajedničke. Proces iskorištavanja šume se provodi izborom sekvenci odluka koje se odnose na proces rasta i njegovanja šume. Posljedica odluke je da se pokrene stanje $\underline{x}(i)$ u stanje $\underline{x}'(t+\delta)$. Sekvenca odlučivanja predstavlja upravljačku strategiju za vrijeme čitavog upravljačkog horizonta šume.

f(...) je funkcija koja opisuje promjenu stanja šume $\underline{x}(t)$ u novo stanje $\underline{x}'(t+\delta)$ u zavisnosti od izabrane odluke $\underline{d}(\underline{x}(t))$. Funkciju f(...) treba odrediti uzimajući u obzir biološku i ekonomsku kompleksnost šume. Jedan pristup takvoj funkciji je opisan kod Zadnika 1990.

$\underline{x}'(t+\delta)$ je vektor koji opisuje stanje šume nakon provođenja odluke $\underline{d}(\underline{x}(t))$ u šumi koja je u stanju $\underline{x}(t)$.

Varijabla t se odnosi na vrijeme kada se donosi odluka. Budući da se odluke u šumarstvu provode samo u diskretnim vremenskim točkama t=i, (i=0,1,...,N) proces (1) se dijeli u periode i, (i=1,2,...,N), slika 1. Postoji N perioda koji se razlikuju kao konačno upravljačko vrijeme procesa (1). Svi periodi su iste dužine. Oni se broje postepeno i slijede jedan za drugim. Da bi se postigao razuman broj varijabli, model radi često s periodima duljim od godine dana. Budući da su varijable $\underline{x}(i) \in X(i)$ a $\underline{dx}(i) \in D(i)$ su aproksimirane na diskretnu vremensku točku i, one su isto diskretne. Skupovi X(i) i D(i) su konačni i diskretni. U upravljanju šumom se pretpostavlja da se radi s istim skupom X(i) i D(i) za svaki i,i=0,1,...,N) uz respektiranje x(i). Uzimajući u obzir diskretne varijable, proces (1) ima svojstvo diskretnog dinamičkog procesa:

$$\underline{x}(i+1) = f(\underline{x}(i), \underline{d}(\underline{x}(i))) \quad \text{za } i = 0,1,...,N-1 \qquad (2)$$

gdje je $\underline{x}(N)$ ciljno stanje šume s početnim stanjem $\underline{x}(0)$.

Ukupna količina drveta koja se proizvodi u šumi za vrijeme upravljačkog procesa, to je od vremenske točke t=i=0 do točke vremena t=i=N se često maksimizira (Buongiorno, 1987). Ali poslovoditelj koji prodaje drvo da bi ostvario profit više voli investirati u ostvarivanje dobiti preko stope povrata. Radi toga, funkcija cilja mora izraziti sadašnju vrijednost šume u terminima varijabli odlučivanja $\underline{d}(\underline{x}(i))$, (i=0,1,2,...,N-1). Sadašnja vrijednost šume ovisi o stanju šume i odluci koja se donosi u tom stanju. Označimo sadašnju

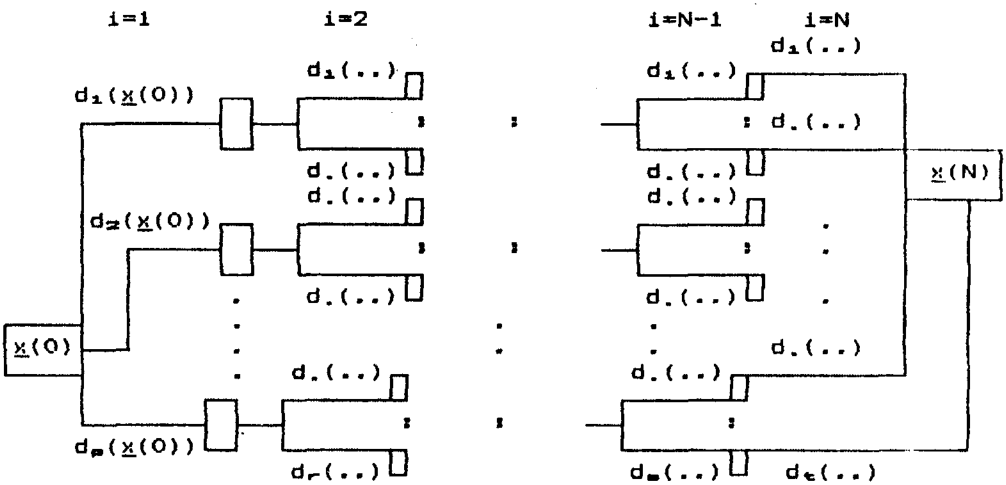

Slika 2. Stablo odlučivanja za diskretni dinamički problem (3)

vrijednost šume stanjem $\underline{x}(i)$ u kojem se donosi odluka $\underline{d}(\underline{x}(i))$ kao $V(\underline{x}(i),\underline{d}(\underline{x}(i)))$. Pomoću cost-benefit analize koja omogućava procjenu troškova koji se mogu kvantitativno obuhvatiti, a i onih koji se ne mogu, uspjeva se ta vrijednost procijeniti kako je to predloženo u članku (Kavčić, Zadnik, 1992).

Zahtijevom za određivanjem maksimuma sadašnje vrijednosti šume kroz sve periode, diskretni dinamički proces (2) se transformira u diskretni dinamički optimalizacijski proces opisan kao:

$$\sum_{0}^{\infty} V(\underline{x}(i), \underline{d}(\underline{x}(i)))$$

$$d(...)$$

uz

$$\underline{x}(i+1) = f(\underline{x}(i), \underline{d}(\underline{x}(i))),\ i = 0,1,...,N-1 \qquad (3)$$

Problem (3) se odnosi na strukturu grane s varijablama $\underline{d}(\underline{x}(i)) \in D(i)$ u svakom periodu i. Nakon što se odrede sva stanja x(i) (korištenjem funkcije f(...)), sve moguće odluke $\underline{d}(\underline{x}(i))$ s korespodentnim vrijednostima $V(\underline{x}(i),\underline{d}(\underline{x}(i)))$ za svaki i=0,...N-1, problem (3) može se vizualno modelirati u obliku stabla odlučivanja (slika 2). Njegovi čvorovi predstavljaju stanje šume (početni čvor je stanje $\underline{x}(0)$, a konačni čvor je ciljno stanje $\underline{x}(N)$. Grane predstavljaju odluke koje se donose u korespondirajućem stanju, a vode do ciljnog stanja.

Budući da je broj mogućih stanja iz skupa X(i) i mogućih odluka iz skupa D(i) velik, takvo stablo odlučivanja se u stvarnosti može konstruirati samo pomoću kompjutora. U skladu s maksimalnom sumom sadašnjih vrijednosti, optimalna sekvenca odluka može se uspješno odrediti unatrag, od ciljnog stanja prema početnom stanju šume na temelju Bellmanovog principa optimalnosti, koji je Bellman opisao (1957), a primjenjen je npr. kod Zadnik (1992).

3. POJEDNOSTAVLJENA VERZIJA PREDLOŽENOG MODELA

Da bi iznijeli numerički primjer predstavimo vrlo pojednostavljnu verziju predloženog modela. Pretpostavlja se da postoji šuma koja se sastoji od neposječenih stabala, parne starosti, različite dobi i veličine. U slučaju da neposječena stabla nisu parne starosti u jedinicu se grupiraju stabla slične starosti. Na taj se način modelira šuma u svakom periodu i uz pomoć proporcije različitih starosnih klasa šume. Kada smo grupirali šumska stabla (koja spadaju zajedno) u starosne klase dužine npr. 10 godina, prva starosna klasa se sastoji od površine šume sa stablima starim (0,10) godina, sljedeća površina šume bi bila ona sa stablima starima (10,20) godina, itd. Neka se tako razlikuje n starosnih klasa. U svakom periodu i jedna ima stanje:

$$\underline{x}(i) = (a_{i1}, ..., a_{ij}, ... a_{in})$$

gdje je a_{ij} površina koja je pokrivena stablima j-te starosne klase u periodu i.

$x(i) \in X(i)$, gdje je X(i)skup svih mogućih distribucija šumske površine u starosne klase u vremenu i. Pretpostavimo da ukupna površina šume iznosi P površinskih jedinica, a_{ij} su cijeli brojevi, skup X(i) je konačan. U skupu X(i) za svaki i=0,...,N može biti najviše (P+n-1)!/P!(n-1)!) elemenata (dokaz kod Zadnika, 11982). Na kraju planskog perioda, zalihe koje rastu i sječa trebaju ostati konstantne u vječnosti tako da starosne klase koje se sastoje od jednakih šumskih površina predstavljaju ciljno stanje x(N):

$$\underline{x}(N) = (P/n, P/n, ..., P/n).$$

Iako smo svjesni svih šumskih pogodnosti, pretpostavljamo da se u okviru zahtjeva koji se postavljaju pred upravljanje šumom poželjnim smatra onaj koji vodi računa o organizaciji proizvodnje drveća na najbolji mogući način. Problem upravljanja šumom je povezan s odlučivanjem kada, gdje i koliko drveća se treba sjeći na način da se postigne optimalna vrijednost šume kroz sve periode.

Varijabla odlučivanja $\underline{d}(\underline{x}(i))=(d_{i1},...,d_{ij},...,d_{in})$ za i=0,...,N-1; $\underline{d}(\underline{x}(i)) \in D(i)$. d_{ij} mjeri površinu sječe šume i odmah nakon sječe umjetno regenerirano područje a_{ij} u periodu i. Da bi se broj varijabli $\underline{d}(\underline{x}(i)) = (d_{i1},...,d_{ij},...,d_{in}) \in D(i)$ zadržao u razumnoj količini d_{ij} se može učiniti diskretnim uključivanjem više površinskih jedinica.

Ako je dužina perioda 10 godina (isto što i dužina svake starosne klase) funkcija f(...) koja opisuje promjenu stanja šume $\underline{x}(i)$ u stanje $\underline{x}(i+1)$ kod odluke $\underline{d}(\underline{x}(i))$ jednostavno smješta površinu a_{ij} u sljedeću starosnu klasu, a površinu sječe u prvu starosnu klasu:

$$(a_{i1},...,a_{ij},...,a_{in}) \to (d_{i1}+...d_{ij}+...+$$
$$+d_{in},a_{i1}-d_{i1},...,a_{ij}-d_{ij-1},...,a_{i,n-1}-d_{i,n-1}+a_{in}-d_{in})$$

Da bi se procijenila sadašnja vrijednost $V(\underline{x}(i))$, $\underline{d}(\underline{x}(i))$ za svaki $\underline{x}(i)$ i $\underline{d}(\underline{x}(i))$, potrebni su podaci o kvantitetu drveta koji stoji na raspolaganju po jedinici površine kroz godine upravljanja. Očekivani prinos drveća u tonama, ft^3 ili m^3 po jedinici površine u svakom vremenskom periodu jedan funkcijom rasta (slika 3). O pogodnom analitičkom obliku krivulje rasta se raspravlja, Vadnal i drugi (1983). Budući da pretpostavljamo da je drvo potpuno homogeno, cijena će svagdje biti ista. Prema tome, ignoriraju se moguće promjene cijene. Dosljedno tome, drvetu se arbitrira pridružena vrijednost od jedne novčane jedinice po jedinici volumena. Kalkulacija će se raditi po diskontnoj stopi od 5 % godišnje. Sadašnja vrijednost prosječnog drveta se uračunava u sredinu 10-godišnjeg perioda za vrijeme kojeg je donesena odluka. Neka je v_n volumen po površinskoj jedinici posječenih stabala starosti n, a c troškovi pošumljavanja i drugi minorni troškovi. Za vrijeme perioda i sadašnja vrijednost povrata po površinskoj jedinici je:

$$(v_n-c)/(1+0{,}05)^{10i-5}$$

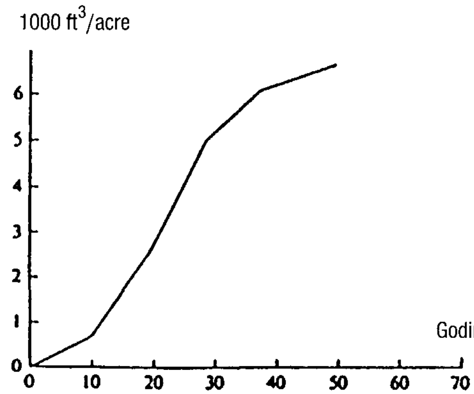

Slika 3. Prinos borovine po položaju zemlje index 60 (Smalley i dr. 1979.)

4. RAČUNSKI ASPEKTI

Numerička aplikacija pojednostavljene verzije modela daje se na površini šume na 4 akra pokrivenih borovima na 60 mjesta tako da se koristi funkcija rasta sa slike 3. Budući da se razlikuje period dug 10 godina neka se uzmu 4 starosne klase, šest perioda (i=1...6) i početno stanje $\underline{x}(0) = (2,0,0)$. To stanje treba dovesti do ciljnog stanja $\underline{x}(6)=(1,1,1,1)$ uz pomoć odluka $\underline{d}(\underline{x}(i))=(0,0,x,y)=(x,y)$ kao što smo u daljnjoj simplifikaciji pretpostavili da će se drvo rezati samo u trećoj i četvrtoj starosnoj klasi. x je površina sječe u trećoj starosnoj kalsi, a y površina sječe u četvrtoj starosnoj klasi u šumi koja se nalazi u stanju x(i). Iz slike 3. razabiremo da v_n u trećoj starosnoj klasi iznosi 5(1000 ft^3/akra). Sadašnja vrijednost šume u svakom periodu i trebala bi se izračunati prema: $((5-0.5)x + (6-0.5)y)/(1.05)^{10i-5}$, kada uzimamo c=0.5 novčanih jedinica za sječu po akru.

Stablo odlučivanja svih 6 perioda je prezentirano na slici 4. Optimalna strategija je definirana upotebom Bellmanovog principa optimalnosti i istaknuta na slici 4.

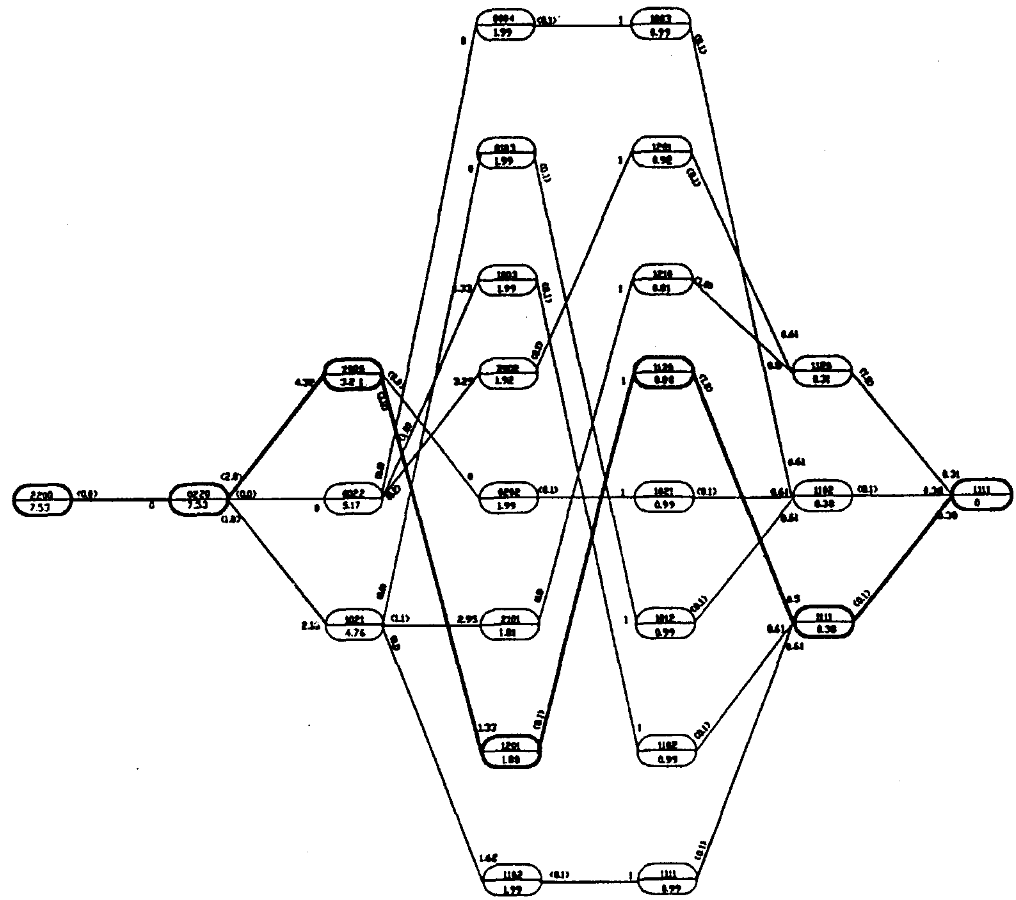

Slika 4. Stablo odlučivanja za optimalnu strategiju u numeričkom primjeru

5. ZAKLJUČAK

Donošenje optimalnih odluka pri upravljanju šumom predstavlja se kao dugoročni kombinatorni problem koji vodi računa o maksimumu ekonomske vrijednosti šume za čitavo vrijeme planiranja i ispunjavanju principa sadržajnog i višestrukog korištenja šume. Premda je tijek vremena rasta i korištenja šume u modelu kontinuiran, izabrana je diskretna verzija vremena budući da se odluke provode na diskretnim vremenskim točkama. Odluke usmjeravaju razvoj postojećeg stanja šume prema ciljnom stanju, tradicionalno su određene korištenjem linearnog programiranja. Koristili smo diskretno dinamičko programiranje jer mislimo da ova metoda nudi puno prednosti. Dopustite nam da spomenemo neke od njih:

- funkcija cilja u obliku varijabli odlučivanja maksimizira čistu sadašnju vrijednost posječenih stabala tijekom čitavog perioda. Drugi outputi šume mogu se uključiti čim se mogu kvantificirati.
- model je deterministički, ali uzimajući u obzir činjenicu da šumski procesi ne mogu biti jasno definirani zbog svoje stohastičke prirode, može se koristiti algoritam stohastčkog dinamičkog programiranja umjesto algoritma determinističko dinamičkog programiranja.
- na kraju i na početku svake faze stanja šume dano je modelom koji je na raspolaganju. Ako ovo stanje ne korespondira na zadovoljavajući način s pravim stanjem šume, mi ga možemo adaptirati i nastaviti proceduru na isti način novim stanjem.

- problem upravljanja šumom je numerički ekstenzivan. U dinamičkoj proceduri programiranja, sve odluke koje donose negativan povrat mogu biti eliminirane. Na takav logičan način vrijeme traženja optimalne strategije može se reducirati.

preko drveta odlučivanja koje je adaptirano za problem dinamičkog programiranja može se dokazati intuicija ako se dostigne ciljno stanje, koje će biti zadržano u svim daljnjim periodima optimalnog upravljanja.

LITERATURA

1. *Atkinson,W.A.*, 1974. Simulation and mathematical programming in the control of forest tree nusery operations. University of California, Barkley.

2. *Bare, B.B.,D.G.Briggs, J.P.Roise, G.F.Schreuder*, 1984. A survey of system analysis models in forestry and the forest products industries. Eu.J.Oper. Res.18:1_18.

3. *Bellman, R.E.*, 1957. Dynamic programing. Princeton Univ. Press, Princeton, NJ.

4. *Buongiorno,J.*, 1987. Forest management and economics. Macmillan Pub. Company, New York.

5. *Smalley, G.W., Bailey, R.L.*, 1979. Yield tables and stand structure for pine plantation in Tennessee. U.S.Forest Service, Resarch paper SQ-97.

6. *Kavčić, S., Zadnik Stirn, L.*, 1992. Cost benefit analysis as a criteria for investment decisins in forestry. Schriften zur Forstoekonomie, Band 1, editor Bergen, V. et al., Sauerlaenders Verlag, Frankfurt, str. 95-106.

7. *Klepac, D.*, 1965. Uređivanje šuma. Nakladni zavod Znanje. Zagreb.

8. *Kao,C.*, 1982. Optimal stocking levels and rotation under risk. For. Sci., 28:711-719.

9. *O'Hara A.J., Faaland,B.H., Bare,B.B.*, 1989. Spatially constrained timber barvest scheduling. Can.J.of For.Res.19:715-724.

10. *Vadnal,A., Kotar,M., Gašperšić,F., Zadnik Stirn,L.*, 1983. Uporaba rastnih funkcij v gozdarstvu. Zbornik gozdarstva in lesarstva, Ljubljana, 23:149-178.

11. *Zadnik Stirn,L.*, 1982. Uporaba diskretnega dinamičnega programiranja v gozdnogospodarskem načrtovanju. Ekonomska fakulteta, Ljubljana, magistrsko delo.

12. *Zadnik Stirn,L.*,1990. Adaptive dynamic model for optimal forest management. For.Ecol.Manage.,31:167-188.

13. *Zadnik Stirn,L.*, 1992. A dynamic model appliedto forest sustined use. Forsteinrichtung und Betriebswirtschaftsgarantender Nachhaltigkeit, editor Kurth,H., Technishe Universitaet Dresden, Tharandt, str.23-31.

Lidija Zadnik Stirn

FOREST MANAGEMENT ACCORDING TO ECONOMIC CRITERION AND DYNAMIC PROGRAMMING

Summary

Forest is a very sophisticated natural resource with the possibility of permanent reforestation which ought to be managed through certain economic targets and environmental ones. The process which is directing forest development from the initial to final circumstances is a long-term one. Therefore the policy of the optimal forest management can be looked upon as a large combinatory problem. The problem is discussed in the model as a multiphase optimal one in which the maximum of discount production value of trees during these phases is being searched. The optimal series of decisions relating to the forest growing time is determined thorough the dynamic procedure utilization developed by Bellman(1975).