Sustavna dinamika u planiranju gospodarenja regularnim šumama na području Uprave šuma Zagreb

Čavlović, Juro

Source / Izvornik: **Glasnik za šumske pokuse: Annales Experimentis Silvarum Culturae Provehendis, 1996, 33, 109 - 152**

Journal article, Published version
Rad u časopisu, Objavljena verzija rada (izdavačev PDF)

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:108:542331

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-07-17**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

J. Čavlović: Sustavna dinamika u planiranju gospodarenja regularnim šumama na području Uprave šuma Zagreb. Glas. šum. pokuse 33: 109–152, Zagreb, 1996.

UDK 630*624--015.5:630*903 Izvorni znanstveni članak

JURO ČAVLOVIĆ

SUSTAVNA DINAMIKA U PLANIRANJU GOSPODARENJA REGULARNIM ŠUMAMA NA PODRUČJU UPRAVE ŠUMA ZAGREB

USING SYSTEM DINAMICS IN EVEN-AGED FORESTS MANAGEMENT IN THE AREA OF THE ZAGREB FOREST DISTRICT

Prispjelo: 12. 6. 1996. **Prihvaćeno:** 2. 9. 1996.

Osnovni je zahtjev koji se danas postavlja pred gospodarenje šumskim resursima trajna proizvodnja svih koristi šuma uz očuvanje stabilnosti šumskih ekosustava. Kada je riječ o gospodarenju regularnom šumom, to će biti osigurano postizanjem kompozicije normalne i stabilne šume, što se zasniva na normalnom nizu dobnih razreda.

Kako se radi o prirodnim sustavima u kojima vladaju vrlo složeni uzročno-posljedični odnosi u vremenu i prostoru, za metodu rada izabrano je sustavno dinamičko modeliranje. Projektiran je simulacijski model procesa gospodarenja regularnom šumom po metodi razmjera dobnih razreda.

Simuliranjem odgovarajućih scenarija u radu je istraživan budući razvoj razmjera dobnih razreda po površini i drvnoj zalihi na području Uprave šuma Zagreb na različitim razinama gospodarenja unutar uređajnog razreda hrasta lužnjaka.

Simulacijsko je istraživanje pokazalo da je gospodarenje regularnom šumom definirano dinamikom oplodne sječe (načinom računanja površinskog etata glavnog prihoda) i duljinom ophodnje i da je vrlo snažan čimbenik koji utječe na buduće ponašanje (kretanje razmjera dobnih razreda, etata i drvne zalihe) zatvorenog sustava regularne šume.

Ključne riječi: potrajno gospodarenje, regularna šuma, sustavna dinamika, kretanje razmjera dobnih razreda, oplodna sječa, ophodnja

UVOD – INTRODUCTION

Gospodarenje šumama u današnjim je uvjetima vrlo složen i odgovoran posao. U jednom složenom dinamičkom sustavu nalazi se niz resursa (šumsko zemljište, šumsko drveće, životinjski svijet, ljudi, vrijeme, novac) koji su u stalnim uzajamnim i ograničavajućim odnosima (B u o n g i o r n o & G i l l e s 1987).

Upravljanje šumama i upotreba šuma i šumskih zemljišta na način i u takvoj mjeri da se očuva njihova biološka raznolikost, produktivnost, mogućnost obnove,

vitalnost i njihov potencijal za sadašnjost i za budućnost pretpostavlja ispravno donošenje odluka o vremenu, mjestu, količini i načinu korištenja šumskih resursa.

Ljudska se aktivnost može opisati kao metodično stremljenje prema ostvarenju sigurnih ciljeva. Tako je i gospodarenje šumskim resursima dosada bilo često usmjereno prema najvećoj ekonomskoj dobiti u najkraćem mogućem ophodnom razdoblju (što veći kamatnjak). To se odnosilo na smanjenje površina prirodnih i mješovitih šuma na račun podizanja monokultura brzorastućih četinjača i mekih listača. Takav način gospodarenja kratkoročno postiže uspjeh, ali ne vodi prema nužnoj potrajnoj proizvodnji svih šumskih dobara, što jamči stabilnost svih čimbenika u ekosustavu, uključujući i čovjeka. Evans i Hibberd (1990) navode da je gospodarenje prirodnim, mješovitim i raznolikim šumama ključ za ostvarenje proizvodnje svih šumskih vrijednosti.

Prema Faesheru (1989) određivanje ekonomskih procesa u ekološkom kompleksu može uključiti ove sastavnice: ekonomsku djelotvornost (uspješnost), ekološke učinke, socijalnu i kulturnu pomirljivost (snošljivost).

Ekonomska se djelotvornost ogleda u maksimiziranju čiste sadašnje vrijednosti sječive drvne zalihe i određivanju ekonomske politike (Haight 1985, Kaya & Buongiorno 1987, Medema & Lyon 1985).

Danas je sve aktualnije vrednovanje socioekološke funkcije šume. U tom je kontekstu značajno spomenuti istraživanja utjecaja borovih kultura na čistoću zraka u Sredozemlju (Meštrović 1980). Djelatnosti koje uzrokuju emisiju CO_2 i sve veću njegovu akumulaciju u atmosferi trebaju biti oporezivane tako da se alimentira asimilacija CO_2 kao jedna od važnih općekorisnih funkcija šume. Primjerice, u Norveškoj je na temelju računanja optimalnog razdoblja ophodnje u smrekovoj sastojini (Hoen 1994), u koju je uključena cijena od 250 NOK za tonu asimiliranog CO_2, ophodnja produžena s 80 na 155 godina.

Estetske kvalitete šuma već se dugo vremena vrednuju kao vrlo važan proizvod šume. Studije u sjeveroistočnom dijelu SAD-a (Birch 1983) pokazuju da privatni šumovlasnici kao osnovne razloge posjedovanja šume navode njihovo korištenje za rekreaciju i uživanje u njihovoj estetskoj vrijednosti. Istraživanja u borovim i hrastovo-borovim sastojinama u istočnom Teksasu pokazuju da s povećanjem vremena ophodnje i čišćenjem tla ispod krošanja raste estetska vrijednost, odnosno predodžba šumske ljepote (Rudis, Gramann, Ruddel & Westphal 1988).

Nova teorija gospodarenja šumom nastoji spojiti ekološke, ekonomske, sociološke i kulturalne zahtjeve. U stvarnosti, još uvijek smo daleko od ostvarenja tih ciljeva. Klasična ekonomska teorija daje prednost spajanja proizvodnih čimbenika (priroda, ljudski rad i kapital) da bi se postigla što veća dobit u kapitalu. Ta načela, koja su još u praksi, razaraju prirodu u cijelom svijetu, u kojemu vlada nestabilna ravnoteža, uzrokovana pogrešnim odnosom proizvodnih čimbenika. Nužno je vratiti se stabilnoj ravnoteži, gdje priroda i ljudski rad dominiraju nad čimbenikom koji se zove "kapital".

Tradicionalni stavovi, koji se ogledaju u samom znanju, uskom gledanju na stvari, gospodarenju prirodom i proizvodnji što većega kapitala, ne odgovaraju više

zahtjevima za rješavanje ozbiljnih lokalnih, regionalnih i globalnih problema. Šumarska politika i gospodarenje šumama stalno su pod utjecajem aktualnih političkih i ekonomskih stavova, koji su uzrokovali gubitak kvalitete prirode, a s tim u svezi i gubitak kvalitete življenja u cijelom svijetu.

Prirodi podređeno gospodarenje šumama, koje se odlikuje novim načinom kreativnoga i interaktivnog razmišljanja, suradnjom s prirodom, potrajnom i uravnoteženom proizvodnjom svih šumskih dobara radi kvalitetnijeg življenja, danas je sve aktualnije. Glavni ciljevi tako usmjerenoga šumarstva po prednostima su zaštita okoliša, ostvarivanje osnovnih ljudskih potreba u prirodnim ekosustavima te ostvarivanje osnovnih potreba nacionalnoga gospodarstva zasnovanoga na drvnoj sirovini.

U srednjoj Europi (Švicarska, Njemačka) šumari se sve više vraćaju gospodarenju šumama podređenom prirodi. To je obilježeno prebornim stablimičnim sječama, prirodnom obnovom autohtonim vrstama drveća bez teške mehanizacije i pesticida, što sve skupa rezultira miješanim, raznodobnim i raznoliko struktuiranim i stabilnim šumama (F e a s h e r 1989).

Gospodarenje šumama moći će zadovoljiti opća temeljna načela samo uz uvjet istodobnoga ostvarenja osnovnih sastavnica uređenja: prostor kao tehnička, vrijeme kao ekonomska te materija kao biološka sastavnica uređivanja (K r i ž a n e c 1992).

PREDMET I SVRHA ISTRAŽIVANJA – THE PROBLEM AND AIM OF INVESTIGATION

Kako se u ljudi počela javljati spoznaja da drvne zalihe nisu neiscrpne, šume su se počele uređivati na načelima potrajnoga šumskog gospodarenja. Pitanje potrajnosti imalo je velik utjecaj na razvoj šumarske znanosti, a posebice na razvoj znanstvene discipline uređivanje šuma. Metoda dijeljenja šume na godišnje sječine seže još u 14. stoljeće. Potrajnost je ostvarivana različitim metodama (rašestarenje po drvnoj zalihi, rašestarenje po površini, kombinirane metode i druge) i prolazila je različite faze od stroge potrajnosti preko intenzivnoga sastojinskog gospodarenja pa do metode razmjera dobnih razreda (M i l e t i ć 1922).

Pojam proizvodne i prihodne potrajnosti zapravo je širi pojam potrajnoga šumskoga gospodarenja (U g r e n o v i ć 1922). Ostvarivanje je potrajanog prihoda ugrađeno u tradicionalnu šumarsku teoriju i praksu i radno je načelo pri gospodarenju i upravljanju šumama. To je osnova na kojoj je šumsko gospodarstvo organizirano tako da se iz šume dobivaju svake godine (trajno) podjednaki prihodi uz osiguranje i očuvanje proizvodne sposobnosti šume (K l e p a c 1965).

Potrajno gospodarenje šumskim bogatstvom danas ima mnogo širi koncept od neprekinute proizvodnje podjednakih prihoda drvne tvari. U tom je kontekstu očuvanje šuma radi njihovih općekorisnih funkcija i genetskog potencijala mnogo važnije od neprekinute proizvodnje drvne tvari.

Kontinuirana proizvodnja podjednakih prihoda ne znači istodobno u određenim slučajevima i potrajno gospodarenje šumskim resursima (G a n e 1992). Razvoj u tom smjeru ide prema traženju puta ekonomskog progresa koji neće naškoditi blagostanju budućih generacija (P e a r c e i dr. 1989).

Šumarstvo ima dva aspekta (G a n e 1991), a može biti promatrano sa stanovišta šumskih resursa i sa stanovišta upotrebe dobara. Unutar potrajnoga šumskog gospodarenja postoji s jedne strane *ponuda* resursa (različite šumske površine ili izvori dobara, različite vrste dobara i stopa korištenja dobara), a s druge strane *potražnja* za različitim vrstama proizvoda za zadovoljenje potreba industrije, trgovine i različitih socijalnih grupa s različitom stopom potrošnje.

Resursi se mogu promatrati na različitim razinama (država, područje, gospodarska jedinica), gdje su izvori ponude velikog broja vrsta dobara različiti, pa je i potrajno šumsko gospodarenje specifično za svaku od nabrojenih razina.

U istoj je vezi i potražnja za dobrima, gdje je još uključena i sigurnost za stalnom zaposlenošću, prihodima, investicijskim aktivnostima generiranima neprekinutim pritjecanjem dobara. I na svakoj pojedinoj razini gospodarenja prema različitim okolnostima postoje specifičnosti potrajnoga šumskog gospodarenja od mjesta do mjesta. Potrajno šumsko gospodarenje ovisi o pronalaženju zadovoljavajuće kombinacije svih elemenata zasnovanoj na svakoj posebnoj situaciji ili problemu.

Potrajno šumsko gospodarenje mora uzeti u obzir sve moguće interakcije u traženju zadovoljavajuće ravnoteže između šumskih resursa i korištenja dobara, uzevši pri tome u obzir prostorne i vremenske razlike.

Prema M e š t r o v i ć u (1978) osnovno načelo potrajnosti prihoda, koje se provlači kroz sve zakonske uredbe i pravilnike za uređivanje šuma, treba poprimiti dinamičan i progresivan smisao. To će biti osigurano postizanjem kompozicije normalne i stabilne šume koja se zasniva na normalnom nizu dobnih razreda.

Potreban je novi pristup integralnoga i dugoročnog planiranja jedinstvenim prostorom. Načelo potrajnosti prihoda treba proširiti na pojam potrajnoga šumskog gospodarenje. Ono bi postalo vodeće načelo po kojemu bi se gospodarilo šumskim resursima na razini određenoga šireg prostora. U tom je smjeru sustavna dinamika znanstvena disciplina koja može pružiti snažnu podršku pri upravljanju najsloženijim sustavima u kojima vladaju interaktivna međusobna djelovanja svih elemenata proučavanog sustava jednodobne šume.

Na osnovi navedene problematike istraživanja te najnovijih spoznaja iz područja sustavne dinamike postavljen je skup ciljeva:

- projektirati kontinuirani simulacijski model gospodarenja regularnom šumom po metodi razmjera dobnih razreda
- istražiti budući razvoj razmjera dobnih razreda na temelju konkretnoga gospodarenja i stanja resursa unutar više razina i kategorija gospodarenja na području Uprave šuma Zagreb
- utvrditi značajne razlike među pojedinim kategorijama gospodarenja
- na temelju različitih scenarija definiranih politika gospodarenja simulirati ponašanje resursa unutar uređajnog razreda hrasta lužnjaka na četiri razine gospodarenja

- odrediti najpovoljnije gospodarenje s obzirom na dobivene rezultate simulacije
- utvrditi značajne razlike među različitim razinama gospodarenja u istoj kategoriji gospodarenja (uređajni razred hrasta lužnjaka)
- ispitati valjanost kontinuiranoga simulacijskog modela na temelju ponašanja stvarne jednodobne šume (realnog sustava) u prošlosti
- odrediti važnost primjene sustavne dinamike kao snažne podrške u planiranju gospodarenja regularnim šumama.

Ispunjenje tih ciljeva omogućilo bi stvaranje znanstvene podloge za predviđanje i planiranje gospodarenja regularnim šumama.

PRIMJENA METODA SIMULIRANJA I MODELIRANJA U ŠUMARSTVU – MODELLING AND SIMULATION IN FORESTRY

Važnost metode simulacije u praksi i primjeni tek u novije doba postaje sve veća. Sve do kraja pedesetih godina dvadesetog stoljeća troškovi opsežnih računskih operacija bili su toliko veliki da se znanost usmjerila na nalaženje analitičkih rješenja za sve jednostavnije sustave, a složeni su se sustavi potpuno prepuštali ljudskoj intuiciji i improvizaciji. Budući da su cijene računala znatno smanjene i da su tako pojeftinile i opsežne računske operacije, važnost simulacije kao metode iznimno je porasla.

Metode simulacije počele su se razvijati 1950. godine, ponajprije pri izradi i konstrukciji balističkih raketa i svemirskih letjelica, a potom za civilnu i inženjersku primjenu.

Pod pojmom simulacija razumijeva se imitiranje ponašanja stvarnosti različite prirode. Postoji cijeli niz definicija, ali je važno da se pod tim pojmom razumijeva niz aktivnosti, od eksperimentiranja na realnom sustavu pa do analize eksperimentalnih rezultata, što znači: modeliranje promatrane zbilje, računalno programiranje i eksperimentiranje modelom (M u n i t i ć 1989).

Prema M u n i t i ć u (1990) postoje najmanje tri opća razloga uporabe simulacijskih modela:

1. Rješavanje najsloženijih upravljačkih sustava, u kojima je matematička ili statistička analiza previše složena.
2. Omogućavanje istraživaču da stekne nova znanja i razumijevanja mehanizama događanja, odnosno zakonitosti u složenim realnim sustavima.
3. Omogućavanje predviđanja ponašanja sustava eksperimentiranjem na simulacijskom modelu, a ne na realnom sustavu, koje bi moglo izazvati neželjene posljedice za promatrani sustav, ugrožavajući mu katkad i samu egzistenciju. To znači da simulacijsko modeliranje omogućava eksperimentiranje na najsloženijim sustavima bez opasnosti za njihovu egzistenciju, rast i razvoj.

Šumski se ekosustav može ubrojiti u najsloženije ekosustave u biosferi. Njega sačinjava šumska zajednica ili asocijacija, njezino stanište te svi organski i anorganski ciklički procesi u sustavu. Iz tog su razloga nastali vrlo složeni simulacijski modeli šumskih ekosustava ili dijelova šumskih ekosustava. Tako prema Kolstromu (1991) postoje sljedeće različite i moguće razine pri konstruiranju simulacijskih modela u šumarstvu: stanica, tkivo, dio stabla, stablo, sastojina i šuma.

Druga osnovna podjela računalnih modela nastala je prema pristupu modeliranju. Tako prema Bosselu (Bossel i dr. 1991) postoje dva tipa računalnih modela. To su deskriptivni modeli ("matematički" ili "statistički" modeli) i eksplanatorni, mehanicistički, strukturni modeli ili modeli temeljeni na procesima (process-based).

Najveći dio simulacijskih modela u šumarstvu, koji su zapravo deskriptivni, rađeni su na temelju za računalo prilagođenih različitih prirasno-prihodnih tablica. Prema Bosselu & Kriegeru (1991) to su *growth table models*, gdje se razvoj sastojina opisuje brojčano, odnosno gdje je predstavljen rast i razvoj sastojine na plohi u funkciji vrste drveta, kvalitete staništa i vremena.

U svijetu je razvijeno mnogo determinističkih simulacijskih modela u području rasta, razvoja i prirasta pojedinačnih stabala (Lee & Chan 1988) i sastojina različitih vrsta drveća na različitim lokalitetima: bukove sastojine (Riebeling & Weimann 1984), duglazijeve (Mohren 1987, Mohren i dr. 1984, Mitchell i dr. 1983), smrekove (Kisilev & Atroshchenko 1985), srebrnolisno javorove (Carpentier 1987), tulipančeve (Burkhardt i dr. 1983), eukaliptusove (Oliveira & Conto 1986), mješovitih sastojina tvrdih listača (Solomon & Leah 1986). Ovdje je značajno spomenuti simulacijski model dugoročnog planiranja FOBSI (Jobst 1 1984), koji je razvijen na temelju srednjoročnog planiranja i gospodarenja po načelu potrajnosti prihoda.

U nas je (Pranjić 1985, Pranjić i dr. 1988) predstavljen simulacijski model razvoja čistih jednodobnih sastojina hrasta lužnjaka. Primjenom tog modela praćene su promjene sastojinskih parametara te distribucije stabala i njihovih dimenzija u prostoru i vremenu. Pri tome odabir stabala koja ostaju na plohi ovisi o indeksu konkurencije, tj. o broju stabala po jedinici površine, te o njihovim međusobnim udaljenostima, a prirast je u funkciji vremena.

Ovdje je značajno spomenuti i rad koji opisuje način simuliranja sadašnje i buduće distribucije prsnih promjera na temelju sastojinskih parametara i jednogodišnjega radijalnog prirasta (Kružić 1991).

Kako se u zadnjih dvadeset godina događaju brze i nepredvidive promjene ekoloških uvjeta koje se odražavaju na šumske ekosustave, razvijen je velik broj procesnih ili strukturnih modela s različitim pristupom rješavanja određenih problema. Istodobno dolazi do izražaja sve manja upotrebljivost deskriptivnih simulacijskih modela, zasnovanih na prirasno-prihodnim tablicama pri srednjoročnom i dugoročnom planiranju (Bossel 1991). Strukturni ili eksplanatorni modeli predstavljaju stvarne sustave sastavljene od veličina stanja (biomasa, količina hraniva i dr.) povezanih procesima (veličina promjena varijabli stanja: asimilacija, respiracija i

dr.) u dinamički sustav u kojemu postoje povratne sprege. Strukturni simulacijski modeli temeljeni su na biološkim procesima, a njihova je prednost u tome što se mogu upotrebljavati za ekstrapolaciju izvan područja eksperimentalnih podataka, odnosno za predviđanje ponašanja sustava u posve novim uvjetima (B o s s e l 1991).

B o s s e l (1991) procesne ili eksplanatorne modele dijeli na dvije osnovne kategorije prema razini koju model predstavlja:

- modeli koji simuliraju fiziološke procese na razini stabla (tzv. real-structure modeli ili fiziološki modeli)
- modeli koji simuliraju procese na razini plohe ili sastojine (tzv. gap-modeli).

Osnova je svih fizioloških modela čvrsta fizikalna veza između apsorbirane radijacije i proizvodnje suhe tvari (T r o s t 1990). Fiziološki modeli simuliraju fiziološke procese na razini stabla ili čiste sastojine: fotoprodukcija lišća, fotoprodukcija krošnje, respiracija (lišća, parenhima, drva, korijena i drugo), obnova lišća i finoga korijenja, distribucija asimilata i prirašćivanje, opadanje lišća, opskrba i potreba za dušikom, mineralizacija i humifikacija te ostali procesi na razini stabla. U tom su području razvijeni modeli koji simuliraju razvoj čistih sastojina ili kultura jedne vrste drveća: BIOMASS (Mc M u r t r i e i dr. 1990, Mc M u r t r i e 1991, Mc M u r t r i e & L a n d s b e r g 1991), BEECH (S c h a f e r i dr. 1990), SPRUCE (B o s s e l 1986, K r i e g e r i dr. 1990). Poslije je razvijen općeniti model TREEDYN, koji simulira rast te dinamiku ugljika i hraniva u jednodobnim čistim sastojinama, bez obzira na vrstu drveća.

Najveći je nedostatak i teškoća kod tih modela nepoznavanje pravih fizioloških ili fizikalnih objašnjenja za brojne parametre fizioloških procesa, na primjer pitanje stvarnog objašnjenja mehanizama koji upravljaju redistribucijom asimilata (S i e v a n e n i dr. 1988).

Gap-modelima se simulira razvoj vegetacije kroz dugo razdoblje (nekoliko stotina godina). Ti modeli najčešće imaju vremenski korak od jedne godine. Procesi koji su zajednički za sve šumske ekosustave i na temelju kojih se mogu graditi općeniti modeli razvoja cenoze su klijanje, rast, smrtnost i kompeticija stabala. Ti su procesi dovoljni da bi model imao realnu strukturu, da bi ispravno funkcionirao i da bi mogao poslužiti za predviđanje nekakva budućeg razvoja šume (L e e m a n s & P r e n t i c e 1987). Osim tih osnovnih procesa u model se mogu uključiti brojni drugi procesi koji se odvijaju u šumskim zajednicama, kao što su neposredni antropogeni utjecaji (sječa, selekcija, sadnja biljaka; npr. K i e n a s t & K r a u c h i 1991), posredni antropogeni utjecaji, npr. onečišćenje i globalni poremećaji klime (P r e n t i c e i dr. 1991), utjecaji hidrološkog režima u nizinskim šumama (I v k o v 1994) i drugo.

Iako postoje teškoće zbog različitoga vremenskog koraka simuliranja, koji je kod gap-modela jedna godina, a kod fizioloških je modela potrebna dnevna ili čak kraća rezolucija (proces fotosinteze), radi se na stvaranju hibridnih modela u kojima su spojena dva pristupa modeliranju. Takav je na primjer model FORMIX (B o s s e l 1991, B o s s e l & K r i e g e r 1991).

Uz opisane tipove modela na razini stabla i sastojine razvijen je i veći broj modela koji simuliraju razvoj vegetacije na razini krajolika ili regije. Takav je i model FORSKA, koji je u osnovi sličan gap-modelima, ali simulira razvoj vegetacije na nizu ploha koje su izvrgnute raznim tipovima poremećaja, tako da se kao rezultat dobije struktura krajolika po tipovima vegetacije (Prentice i dr. 1991).

Sva su istraživanja simulacijskih modela u šumarstvu usmjerena prema daljem razvoju sveobuhvatnih računalnih sustava putem integracije s klasičnim metodama rješavanja problema (linearno programiranje, npr. Buongiorno & Gilles 1986, Hoen 1992, Šegotić 1993, Čavlović 1994) radi razvoja takozvanog sustava podrške pri odlučivanju (Decision Support Systems). Tako Loh i dr. (1991) opisuju metodu izrade integralnog sustava za podršku u šumskom gospodarenju, koji u sebi objedinjuje baze podataka, geografski informacijski sustav, modele za simulaciju i ekspertni sustav. Taj se sustav (IRMA – Integrated Resource Management Automation) sastoji od četiri računalna podsustava. To su korisnički međusklop (interface), zatim sustav gospodarskih informacija, sustav upravljanja bazama podataka i geografski informacijski sustav. Sustav gospodarskih informacija sastoji se od dva osnovna dijela, a to su ekspertni sustav (rule-based programiranje – kvalitativno znanje) i modeli za simuliranje (kvantitativna znanja). Sve se sastavnice sustava mogu mijenjati i modificirati kada se god za to ukaže potreba.

Zato se s pravom može očekivati da će takvi inteligentni i sveobuhvatni računalni sustavi imati neobično veliku važnost primjene u redovitom gospodarenju šumama.

RAZVOJ I PRIMJENA SUSTAVNE DINAMIKE

Sustavna je dinamika relativno nova znanstvena disciplina koja ima vlastitu metodologiju istraživanja, modeliranja, simuliranja i optimiranja složenih dinamičkih sustava. Ona obuhvaća i konkretnu primjenu "sustavnog mišljenja" i kibernetike na probleme upravljanja složenim dinamičkim sustavima, tj. organizacijskim sustavima, npr. poduzećem, općinom, županijom, gospodarskim granama, cjelokupnim gospodarstvom, svjetskim gospodarskim i društvenim sustavom itd.

Ekonomist Jay Forrester (1961) prvi je primijenio opća načela kibernetike pri istraživanju funkcioniranja industrijskih sustava te je svojim djelom *Industrial Dynamics* pokrenuo rađanje nove znanstvene discipline, koja se u početku zvala industrijska dinamika, no poslije je zbog proširivanja područja primjene dobila naziv sustavna dinamika (System Dynamics), odnosno dinamika sustava (prema nekim našim autorima).

U nas se prof. dr. Ante Munitić (1990, 1992) bavi sustavnom dinamičkom računalnom simulacijom modela različitih realiteta.

U šumarstvu se izvode modeliranja na načelima sustavne dinamike, koja služe kao podrška pri planiranju potrajnoga gospodarenju šumskim resursima na različitim razinama gospodarenja (Gane 1992). Razvijena su tri modela, i to VOLPLAN

za planiranje proizvodnje drvne tvari, TIMPLAN za financijsko i ekonomsko planiranje rasta, sječe, izrade i prodaje te GROPLAN za financijsko planiranje i gospodarenje šumom (G a n e 1986, G a n e 1991). U nas su u području drvnoindustrijske proizvodnje provedena istraživanja uz pomoć sustavne dinamike (G r l a d i n o v i ć 1992).

Osnovne vrijednosti sustavne dinamike zasada možda još nisu toliko sukladne tipu odgovora o ponašanju dinamičkih sustava, koji se dobivaju primjenom jezika DYNAMO, koliko izmijenjenom pristupu postavljanju pitanja. Naime, sustavna dinamika omogućuje da se svi sustavi (bili oni živi, neživi, ljudski ili tehnički) obuhvate jedinstvenom metodologijom simulacije. Drugim riječima, ta disciplina pruža sveobuhvatan način sustavnog pristupa i sustavnog mišljenja, koji nije samo teorijske, nego i konkretne, aplikacijske naravi.

PODRUČJE ISTRAŽIVANJA – THE AREA OF THE RESEARCH

Uprava šuma Zagreb gospodari šumama i šumskim zemljištem u državnom vlasništvu na prostoru koji se sastoji od bivšega Prigorsko-zagorskog i Srednjoposavskoga šumskogospodarskog područja. To su dvije cjeline koje se međusobno razlikuju po svojim posebnostima.

Bivše Prigorsko-zagorsko šumskogospodarsko područje smješteno je u sjeverozapadnom dijelu Hrvatske i gravitira gradu Zagrebu. Područje je heterogeno i ističe se složenim geomorfološkim, litološkim i biljnogeografskim odnosima. Tu su izražena tri krupna biotopa: posavska ravnica, prigorsko pobrđe i osamljene gore, koje strše izolirane iznad nižih terena (Medvednica, Ivančica, Strahinjčica, Macelj i Samoborsko gorje). Sve gore i prigorja dobro su pokriveni šumom. Kvartarna je ravnica većinom iskrčena od šume, osim u južnom dijelu posavske ravnice, gdje su se održale veće površine lužnjakovih šuma.

To je relativno gusto naseljen prostor u kojemu živi preko 1 000 000 stanovnika, odnosno 307 stanovnika po kvadratnom kilometru (prema popisu stanovništva iz 1981. god.). Šumske površine zauzimaju 1160 km^2, što je ukupna šumovitost od 34 %. Jedna je od najvažnijih značajki ovog područja vrlo snažan industrijski razvoj i urbanizacija s jedne strane, te stalna tendencija smanjivanja šumskih površina, s druge strane. U tom je smjeru potrebno staviti poseban naglasak na općekorisnu funkciju šuma tog prostora.

Prostor bivšega Srednjoposavskoga šumskogospodarskog područja nalazi se uz lijevu obalu rijeke Save s manjim otklonom na zapadnom dijelu. Prostor je podijeljen cestovnom i željezničkom komunikacijom Zagreb – Vinkovci. Sjeverno od navedenih komunikacija nalaze se blago uzdignuti, brdski i gorski predjeli, a južno se nalaze šume i šumska zemljišta koja pripadaju srednjoposavskoj ravnici.

Ukupna je površina tog prostora 2530 km^2, a naseljen je s oko 150 000 stanovnika (59 stanovnika po 1 km^2). Šumske površine zauzimaju 885,5 km^2, što je uku-

pna šumovitost od 35 %. Velik dio nizinskih šuma nalazi se u poplavnoj zoni rijeke Save, a izgradnjom vodoprivrednih objekata radi obrane od poplava veći je dio šuma iskrčen. Međutim, zahvaljujući osvajanju novih šumskih površina podizanjem plantaža i pošumljavanjem čistina, ukupne se šumske površine tog područja povećavaju. Na tom su prostoru podignuti veliki drvnoindustrijski kapaciteti. U tom se smislu osim općekorisnih funkcija šume ističe veliko šumskogospodarsko značenje šuma tog područja.

Cjelovito područje Uprave šuma Zagreb vrlo je heterogeno i u njemu vladaju složeni odnosi između šumskih resursa i okruženja. Gospodarenje tim šumama organizirano je u 14 šumarija, i to 8 šumarija iz bivšega Prigorsko-zagorskoga šumskogospodarskog područja (dio Uprave šuma Zagreb I) i 6 šumarija iz bivšega Srednjoposavskog šumskogospodarskog područja (dio Uprave šuma Zagreb II).

Podaci o šumskim resursima snimljeni su u Odjelu za uređivanje šuma – Uprava šuma Zagreb. Iz osnova gospodarenja za 41 gospodarsku jedinicu, koje se nalaze na području Uprave šuma Zagreb u državnom vlasništvu, prikupljeni su podaci o površinama dobnih razreda, o drvnim zalihama i prirastu po uređajnim razredima. Nakon prikupljanja ti su osnovni podaci svrstani prema pojedinim uređajnim razredima na svim razinama gospodarenja (gospodarska jedinica, šumarija, dio uprave šuma i cjelokupna uprava šuma).

Tako snimljeni i svrstani podaci početna su stanja pojedinih sustava pri simulacijskom istraživanju ponašanja danog sustava.

Ukupna šumom obrasla površina državnih šuma kojima gospodari Uprava šuma Zagreb iznosi 89 152 ha. Drvna zaliha od 20 029 710 m^3 godišnje prirašćuje oko 2,83 % od ukupne drvne zalihe (566 650 m^3). Kada se promatra dobna struktura, uočava se prezastupljenost srednjih dobnih razreda i nedostatak zrelih sastojina. Za ilustraciju kvalitativne strukture šumskih resursa ovog područja važno je razmotriti strukturu po uređajnim razredima. Svakako je najznačajniji uređajni razred hrasta lužnjaka na 31 150 ha (35 % ukupne površine), čija drvna zaliha od 8394 767 m^3 (42 %) godišnje prirašćuje oko 2,4 % (204 406 m^3). Nadalje, prema značenju i prema zastupljenosti slijede bukove šume (20 131 ha), šume hrasta kitnjaka (12 513 ha), jasena (7816 h), jele (3734 ha), ostalo (7214 ha), panjače (5024 ha), grabove šume (1185 ha). Šume posebne namjene čine zaseban uređajni razred (2281 ha).

Šumom obrasle površine kojima gospodare šumarije kreću se od 2610 ha (Šumarija D. Stubica) pa do 10 770 ha (Šumarija Velika Gorica).

Niža razina gospodarenja sastoji se u podjeli prostora na 41 gospodarsku jedinicu. Struktura je gospodarskih jedinica po kvalitativnom sastavu, dobnoj strukturi i površini raznolika. Primjerice, površina gospodarskih jedinica kreće se od 154 ha (GJ Savski vrbaci) pa do 6860 ha (GJ Grede – Kamare).

J. Čavlović: Sustavna dinamika u planiranju gospodarenja regularnim šumama na području Uprave šuma Zagreb. Glas. šum. pokuse 33: 109–152, Zagreb, 1996.

METODA RADA – WORKING METHOD

PROJEKTIRANJE MODELA PROCESA GOSPODARENJA REGULARNOM ŠUMOM (MODEL PGRS)
MODELLING MANAGEMENT OF EVEN AGED FOREST (PGRS MODEL)

Za istraživanje gospodarenja šumskim resursima u regularnim šumama prihvaćena je metoda računalne simulacije pomoću sustavne dinamike. To je metoda koja se zasniva na sustavnom pristupu istraživanja tokova materijala, informacija i energije te uzročno-posljedičnih veza koje postoje u složenim sustavima.

Objektivni aspekt polazi od toga da se regularna šuma može promatrati kao složeni biološki sustav u kojemu vladaju uzročno-posljedični odnosi među brojnim elementima navedenog sustava. Zbog sve većeg problema nedostatka informacija potrebnih za uspješno odlučivanje pri pretpostavljenom gospodarenju šumom javlja se potreba razvoja i primjene simulacijskih modela i u šumarstvu. Na temelju informacija o prošlom i trenutnom stanju i načinu ponašanja simulacijom se nastoje dobiti spoznaje o danom sustavu u kraćem ili dužem razdoblju.

Izrađen je simulacijski model procesa gospodarenja regularnom šumom (model PGRS) te prihvaćen kompajler DYNAMO prema M u n i t i ć u (1990). Na temelju iznesenoga polazi se od toga da model računalne simulacije, uz pomoć sustavne dinamike, predstavlja konkretnu regularnu šumu kao zatvoreni sustav koji teži uspostavljanju ravnoteže. Modelom se nastoje obuhvatiti i opisati svi utjecajni čimbenici koji postoje u samom sustavu i izvan njega (biološki poremećaji, gospodarski postupci) i koji mogu utjecati na brže ili sporije uspostavljanje stanja ravnoteže (postizanje normalnog razmjera dobnih razreda).

Pojednostavljeno, regularna se šuma može prikazati kao sustav koji se sastoji od dva osnovna dijela. Jedan, po površini manji dio čine zrele sastojine u kojima se izvode oplodne sječe i pomlađivanje sastojina, te ostvaruje etat glavnog prihoda. Drugi dio šume čine sastojine u kojima se one njeguju proredom, te ostvaruje etat prethodnog prihoda. Između tih dvaju dijelova postoji neprekinuto kretanje sastojina. Izvođenjem oplodnih sječa smanjuje se površina zrelih sastojina, a povećava se površina sastojina koje se proređuju. S druge strane, s vremenom one sastojine koje su po svojoj starosti najbliže zrelima prelaze u dio šume koji čine zrele sastojine, povećavajući njegovu površinu.

Takav se dinamički sustav može prikazati sljedećim verbalnim modelom:

Veća brzina izvođenja oplodne sječe (ha/god.) uzrokovat će povećanje površine nezrelih sastojina, što znači pozitivnu (+) uzročno-posljedičnu vezu. Što je površina nezrelih sastojina veća, bit će veća i brzina prelaženja sastojina (ha/god.) u dio šume koji čine zrele sastojine, što znači opet pozitivnu (+) uzročno-posljedičnu vezu. Površina će nezrelih sastojina biti manja što je brzina prelaženja sastojina veća, pa imamo negativnu (-) uzročno-posljedičnu vezu. Globalni je predznak povratne sprege negativan (-), pa je prvi krug povratnog djelovanja negativan (-KPD1). Veća brzina prelaženja sastojina iz dijela šume nezrelih sastojina uzrokovat će povećanje

površine zrelih sastojina. Što je veća površina zrelih sastojina, bit će i veća brzina izvođenja oplodnih sječa, dakle pozitivna (+) uzročno-posljedična veza. Površina sastojina zrelih za oplodnu sječu bit će manja što je veća brzina izvođenja oplodnih sječa, što znači negativnu (-) uzročno-posljedičnu vezu. Globalni je predznak povratne sprege ponovno negativan (-), pa je i drugi krug povratnog djelovanja negativan (-KPD2).

Ako se želi promatrati regularna šuma kao dinamički sustav koji se sastoji od dobnih razreda bez obzira na njihov broj i širinu, tada ona može biti predstavljena sljedećim verbalnim modelom:

Brzina izvođenja oplodne sječe (ha/god.) ovisit će o politici izvođenja sječe kao mehanizma upravljanja. Ona može biti konstantna ako je vezana uz ukupnu površinu šume koja se tijekom vremena ne mijenja, ili promjenjiva, ako je vezana uz određeni dio površine šume koji je s vremenom promjenljiv do trenutka izjednačenja površina dobnih razreda.

Što je veća brzina izvođenja oplodne sječe, bit će veća površina prvoga dobnog razreda, što znači pozitivnu (+) uzročno-posljedičnu vezu među promatranim elementima sustava. Po toj logici brzina prelaženja sastojina iz prvoga u drugi dobni razred bit će veća što je veća površina prvoga dobnog razreda, a to znači pozitivnu (+) uzročno-posljedičnu vezu. Istodobno će stanje, odnosno površina prvoga dobnog razreda biti manja što je brzina prelaženja sastojina iz prvoga u drugi dobni razred veća, a to pak znači negativnu (-) uzročno-posljedičnu vezu. Veća brzina prelaženja sastojina iz prvoga u drugi dobni razred uzrokovat će povećanje površine drugoga dobnog razreda, što znači pozitivnu (+) uzročno-posljedičnu vezu. Ako je veća površina drugoga dobnog razreda, bit će brže prelaženje sastojina iz drugoga u treći dobni razred, što upućuje na pozitivnu (+) uzročno-posljedičnu vezu. Istodobno će površina drugoga dobnog razreda biti manja što je brzina prelaženja sastojina u treći dobni razred veća, pa imamo negativnu (-) uzročno-posljedičnu vezu. Niz uzročno-posljedičnih veza dalje se nastavlja na isti način i njegova je duljina ovisna o broju dobnih razreda koji čine konkretnu regularnu šumu, odnosno o duljini ophodnje kojom se gospodari konkretnom regularnom šumom. Površina posljednjega dobnog razreda u kojemu se izvode oplodne sječe bit će veća što je brzina prelaženja sastojina iz pretposljednjega dobnog razreda veća, pa postoji pozitivna (+) uzročno-posljedična veza. Brzina izvođenja oplodne sječe ovisi o upravljačkoj politici izvođenja oplodne sječe. Ako prema politici izvođenja oplodne sječe brzina sječe ovisi o površini posljednjega dobnog razreda, onda će ona biti veća što je veća površina posljednjega dobnog razreda, što upućuje na pozitivnu (+) uzročno-posljedičnu vezu. Što je brzina izvođenja oplodne sječe veća, bit će manja površina posljednjega dobnog razreda, a to znači negativnu uzročno-posljedičnu vezu, odnosno negativan (-) krug povratnog djelovanja.

Na osnovi tako danoga verbalnog modela dinamičkog sustava regularne šume moguće je predočiti njegov strukturni model te elementarni dijagram tokova u simbolici DYNAMO (slika 1).

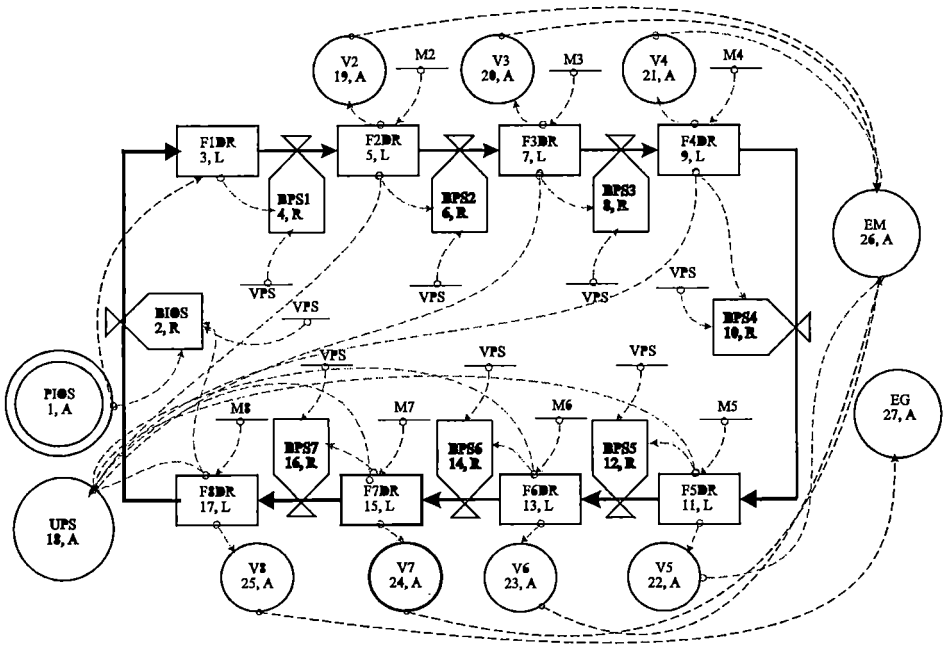

BIOS - brzina izvođenja oplodnih sječa (ha/god.), BPS1, BPS2,..., BPS7 - brzina prelaženja sastojina iz jednoga u drugi dobni razred (ha/god.), F1DR, F2DR,..., F8DR - površina prvoga, drugoga,..., osmoga dobnog razreda (ha), EG - etat glavnog prihoda (m^3/god.), EM - etat međuprihoda (m^3/god.), M2, M3,..., M8 - prosj. drvna zaliha pojed. dob. razr. (m^3/god.), PIOS - politika izvođenja oplodne sječe (ha/god.), UPS - ukupna površina šume (ha), V2, V3,..., V8 - ukupna drvna zaliha pojed. dobn. razr. (m^3), VPS - prosječno vrijeme prelaženja sastojina iz jednoga u drugi dobni razred (godina)

Slika 1. Elementarni dijagram tokova modela PGRS
Figure 1. Elementary diagram flows of PGRS model

VREDNOVANJE MODELA – VALLUATION OF THE MODEL

Kakvoća i valjanost modela PGRS ispitane su na temelju stvarnih podataka dinamike ponašanja realnog sustava u prošlosti. Kao primjer dinamike ponašanja realnog sustava uzeta je za razmatranje gospodarska jedinica Južna Ivančica u prošlom razdoblju od 1960. do 1990. godine. Na temelju podataka iz Osnova gospodarenja za navedeno prošlo razdoblje prikazano je kretanje dobnih razreda po površini po uređajnim razdobljima od po 10 godina (slika 2a). Na slici se može uočiti tendencija kretanja površina dobnih razreda i međuovisnost pojedinih dobnih razreda.

Pomoću modela PGRS za ophodnju od 120 godina simulirana je dinamika ponašanja navedenoga realnog sustava regularne šume za prošlih 30 godina. Na

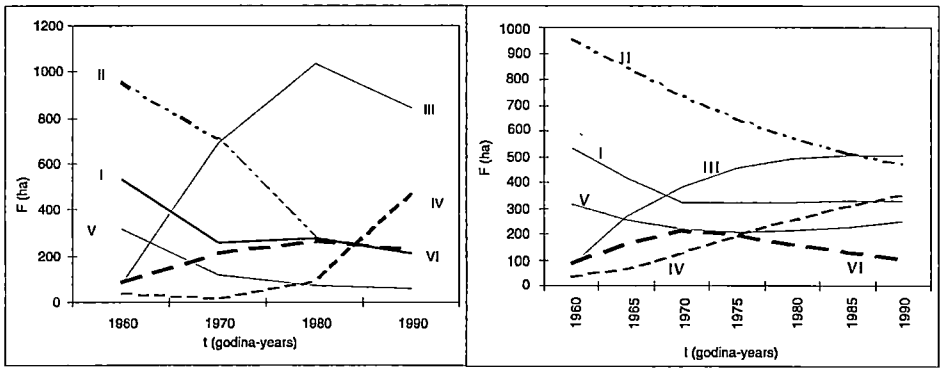

Slika 2. *a)* stvarno kretanje površina dobnih razreda
b) simulirano kretanje dobnih razreda – GJ Južna Ivančica
Figure 2. *a)* real tendency of age clases area
b) simulate tendency of age clases area – Working cirkle Južna Ivančica

temelju stanja površina dobnih razreda iz 1960. godine te pretpostavljene politike gospodarenja za razdoblje 1960 – 1990. godine dobivena je dinamika kretanja površina dobnih razreda (slika 2b).

Uspoređivanjem i analiziranjem prikazanih dviju slika može se donijeti ocjena kvalitete i valjanosti simulacijskog modela. Uočljiva finija slika kretanja površina dobnih razreda u simulacijskom modelu objašnjava se korakom računanja stanja pri simulaciji. Taj korak iznosi 0,5 godine, a podaci su prikazani u razdobljima od po 5 godina. Općenito se može reći da su osnovne tendencije kretanja površina dobnih razreda slične. Najveće se razlike očituju u kretanju drugoga i trećeg dobnog razreda. Izrazito povećanje površine trećega dobnog razreda povezano s jednakim smanjenjem površine drugoga dobnog razreda, te stagniranje površine četvrtoga dobnog razreda u prvih 20 godina posljedica je neravnomjerne starosne strukture sastojina u drugom dobnom razredu u stvarnoj šumi. To znači da je najveći dio sastojina bio zastupljen u posljednjem dijelu drugoga dobnog razreda. Ujednačenije kretanje dobnih razreda po površini, u simulacijskom modelu, događa se zbog pretpostavljene jednolike starosne strukture sastojina u dobnim razredima te jednolikog prelaženja sastojina. Razlike u ponašanju realnoga i simuliranog sustava mogle su nastupiti i zbog promjenljivoga gospodarenja u promatranom razdoblju, za koje nije bilo mogućnosti da se ugradi u program simulacijskog modela. U prilog objašnjenja nastalih razlika može se dodati i činjenica da modeli uvijek sadrže određeni stupanj apstrakcije stvarnosti.

Na osnovi ponašanja simulacijskog modela, te usporedbe sa stvarnim ponašanjem realnog sustava može se zaključiti da je model valjan i da se može primijeniti za simuliranje budućeg ponašanja. Homogene regularne šume (uređajni razredi) na velikim površinama (uprava šuma), gdje je starosna struktura sastojina u dobnim razredima jednolika, jesu realni sustavi koji se mogu uspješno predočiti takvim si-

mulacijskim modelom. Drugim riječima, može se reći da je ovaj model pogodan za dugoročno planiranje pri gospodarenju regularnim šumama s precizno određenim gospodarenjem.

SUSTAV SIMULACIJSKOG ISTRAŽIVANJA – THE SYSTEM OF THE SIMULATION RESEARCH

U Upravi šuma Zagreb istraživano je na više razina i kategorija gospodarenja uz pomoć izrađenih simulacijskih modela gospodarenja regularnom šumom. Modeli se razlikuju po scenariju politike izvođenja oplodne sječe te variranoj duljini ophodnje za regularnu šumu.

Prema politici izvođenja oplodne sječe izrađeno je nekoliko scenarija:

Prvi se scenarij zasniva na načelu da se oplodna sječa izvodi u zrelim sastojinama na površini koja predstavlja *u*-ti dio ukupne površine šume. U tijeku simulacijskog razdoblja nisu predviđene promjene ukupne površine šume, bilo povećanje površine pošumljavanjem, bilo smanjenje površine, pa je brzina izvođenja oplodne sječe konstantna za cijelo razdoblje simulacije (slika 3).

Drugi se scenarij zasniva na načelu da se oplodna sječa izvodi u zrelim sastojinama na površini koja predstavlja kvocjent između površine sastojina koje su starije od jedne polovine ophodnje i vrijednosti jedne polovine ophodnje. Na slici 4 vidi se kako brzina izvođenja oplodne sječe nije konstantna. Ona je ovisna o površini sastojina starijih od jedne polovine ophodnje i koja je varijabilna u razdoblju izjednačavanja površina dobnih razreda.

Nakon vremenske točke u kojoj je izjednačena površina dobnih razreda brzina je izvođenja oplodne sječe konstantna.

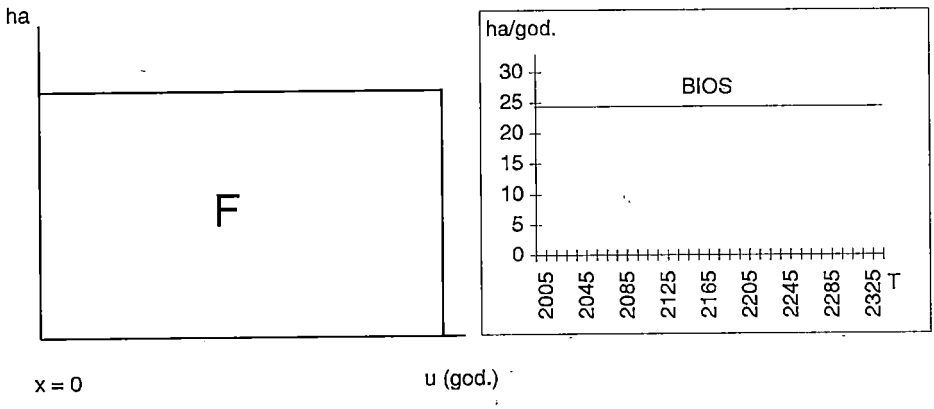

Slika 3. Politika izvođenja oplodne sječe prema ukupnoj površini šume
Figure 3. Policy of felling according total forest area

$$PIOS = \frac{F}{u} = BIOS$$

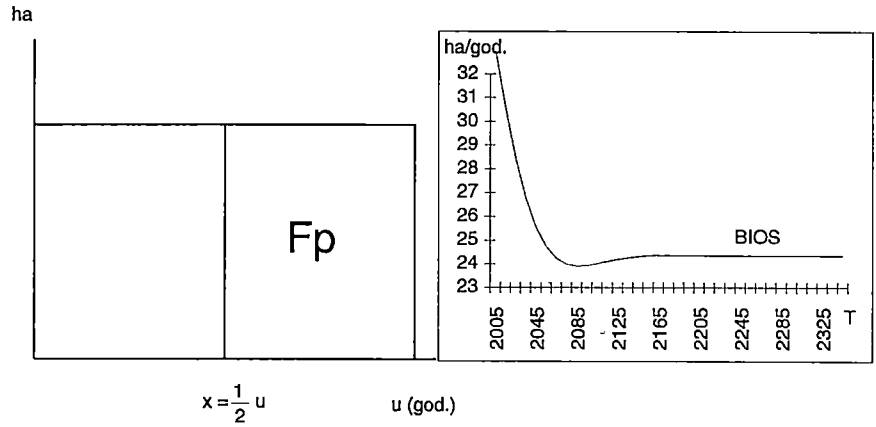

Slika 4. Politika izvođenja oplodne sječe prema površini sastojina starijih od polovine ophodnje
Figure 4. Policy of felling according area stands oldest of half rotation age

$$PIOS = \frac{F_p}{u - \frac{u}{2}} = BIOS$$

Treći se scenarij zasniva na načelu da se oplodna sječa izvodi u sastojinama posljednjega dobnog razreda, na površini koja je jednaka jednoj dvadesetini površine posljednjega dobnog razreda u danom vremenskom trenutku. Iz slike 5 vidi se da je brzina izvođenja oplodne sječe varijabilna tijekom cijelog razdoblja simulacije i da pokazuje oscilacijski karakter.

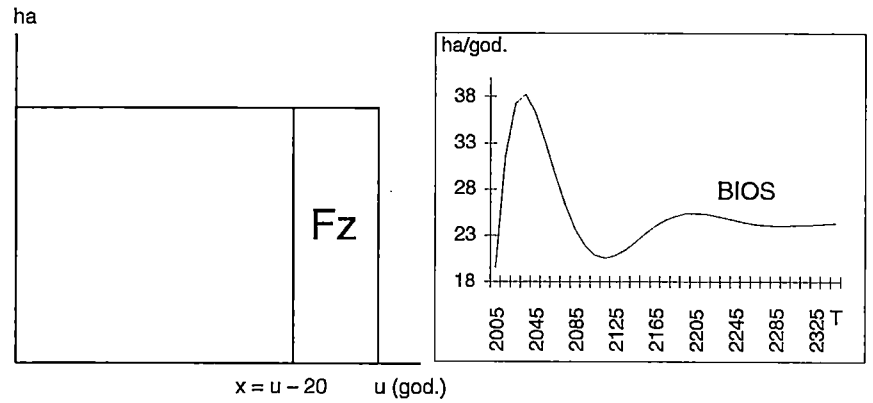

Slika 5. Politika izvođenja oplodne sječe prema površini posljednjega dobnog razreda
Figure 5. Policy of felling according area of last age class

$$PIOS = \frac{F_z}{u - (u - 20)} = \frac{F_z}{20} = BIOS$$

Uz podršku simulacijskog modela prvog scenarija, s duljinom ophodnje od 140 godina, istraživano je ponašanja površina dobnih razreda, drvne zalihe i etata na svim razinama gospodarenja (Uprava šuma Zagreb, dio Uprave šuma Zagreb I, dio Uprave šuma Zagreb II, šumarija i gospodarska jedinica) te u najzastupljenijim kategorijama gospodarenja (uređajni razredi hrasta lužnjaka, hrasta kitnjaka, bukve i jasena).

Nadalje, drugi i opsežniji dio istraživanja obavljen je samo u uređajnom razredu hrasta lužnjaka, ali na četiri razine gospodarenja, i to u Upravi šuma Zagreb, u dijelu Uprave šuma Zagreb II, Šumariji Novoselec i u gospodarskoj jedinici Josip Kozarac. U svakom od spomenutih scenarija izrađeni su simulacijski modeli prema duljini ophodnje, pa se u svakom scenariju nalaze po četiri modela za duljine ophodnje od 100, 160, 180 i 200 godina.

Na kraju je, na temelju varijabilne i nepravilne politike izvođenja oplodne sječe te nedefinirane duljine ophodnje, istraženo ponašanje sustava šume hrasta lužnjaka na razini Uprave šuma Zagreb.

DISKUSIJA S REZULTATIMA ISTRAŽIVANJA – RESULTS AND DISCUSION

Modelom 1 istraženo je kretanje šumskih resursa (površine dobnih razreda, drvna zaliha i etat) na razini gospodarenja cjelokupne Uprave šuma Zagreb, gdje se gospodari s ophodnjom od 140 godina, a oplodna se sječa izvodi na *u*-tom dijelu ukupne šumske površine. Velike i brze promjene površina dobnih razreda događaju se u prvih 90 godina. Posebno je zabilježeno veliko povećanje površine slabo zastupljenoga posljednjega dobnog razreda. Ako se zanemare mala odstupanja površina dobnih razreda od normalne površine, može se reći da je normalan razmjer dobnih razreda postignut za 90 godina. Zabilježena je niska drvna zaliha po hektaru u posljednja dva dobna razreda. U razdoblju izjednačavanja površina dobnih razreda, kada je smanjena površina prezastupljenih srednjih dobnih razreda, ukupna se drvna zaliha smanjila za 316 000 m^3, s početnih 18 826 000 m^3 na 18 510 000 m^3. Uz stalan etat glavnog prihoda (180 710 m^3) zabilježeno je smanjenje etata prethodnog prihoda sa 130 000 m^3 na 119 000 m^3 godišnje.

Na dijelu Uprave šuma Zagreb I koji gravitira gradu Zagrebu kretanje šumskih resursa istraženo je modelom 2. Površina posljednjega dobnog razreda sporije je rasla i izjednačila se s normalnom za 130 godina ne prelazeći njezinu vrijednost (40 godina poslije u odnosu na cjelokupnu Upravu šuma Zagreb). Početna ukupna drvna zaliha od 8 957 000 m^3 približno je jednaka stalnoj zalihi nakon 130 godina (8 954 000 m^3). U razdoblju izjednačavanja površina dobnih razreda u početku je brzo rasla ukupna drvna zaliha prema najvećoj vrijednosti (9 020 000 m^3 u 30. godini), a nakon te vremenske točke vrijednost ukupne drvne zalihe polaganije opada prema konstantnoj vrijednosti u 130. godini. Uz stalanan etat glavnog prihoda od

89 422 m^3 godišnje vrijednost etata prethodnog prihoda u razdoblju prvih 130 godina polagano se smanjivala s početne maksimalne (67 000 m^3) prema konstantnoj vrijednosti (57 000 m^3).

Modelom 3 istraženo je kretanje površina dobnih razreda, drvne zalihe i etata na razini gospodarenja dijelom Uprave šuma Zagreb II koji gravitira rijeci Savi. Kretanje površine posljednjega dobnog razreda znatno se razlikuje od kretanja iz prethodnoga modela. Proporcionalno jače zastupljeni srednji dobni razredi (IV. i V) uzrokovali su brži rast površine posljednjega dobnog razreda, koji je vrijednost normalne površine dostigao već nakon 60 godina. Početni utjecaj brzih promjena stanja posljednjega dobnog razreda izazvao je poslije sporije izjednačenje površina dobnih razreda. Zbog toga se krivulja površine posljednjega dobnog razreda vrlo dugo zadržala iznad vrijednosti normalne površine (razdoblje od 60. do 230. godine). Potpuno izjednačenje površina dobnih razreda zato se događa gotovo pred kraj promatranog razdoblja simulacije, mnogo poslije nego što je to na razini gospodarenja dijelom Uprave šuma Zagreb I. Zabilježena je niska drvna zaliha posljednjega dobnog razreda. Ukupna je drvna zaliha sa početnih 7 905 000 m^3 narasla na 8 211 000 m^3 u 40. godini, a pri kraju razdoblja simulacije postignuta je konstantna vrijednost od 8 018 000 m^3. Ponavlja se sličnost kretanja etata prethodnog prihoda s prethodna dva modela. Početna se vrijednost etata prethodnog prihoda (70 860 m^3) polagano smanjivala prema konstantnoj vrijednosti pri kraju simulacijskog razdoblja (62 700m^3). Prema scenariju i zadanoj politici gospodarenja etat je glavnog prihoda konstantan tijekom cijelog razdoblja i iznosi 90 000 m^3 godišnje.

Sve tri razine gospodarenja obilježava vrlo slična početna struktura dobnih razreda, odnosno dijelovi Uprave šuma Zagreb imaju više-manje sličnu strukturu dobnih razreda. S jedne strane postoje jako zastupljeni srednji dobni razredi nasuprot slabo zastupljenomu posljednjem dobnom razredu, dok je površina prvoga dobnog razreda približno normalna. Takva početna struktura dobnih razreda i scenarijem zadana politika gospodarenja odredile su specifičan razvoj razmjera dobnih razreda te kretanje drvne zalihe i etata. Značajno je posebno stabilno ponašanje površine prvoga dobnog razreda. Početna približno normalna površina prvoga dobnog razreda postigla je vrlo brzo konstantnu vrijednost normalne površine na sve tri razine gospodarenja. Iako je početna površina šestoga dobnog razreda jednaka onoj prvoga, razvoj šestoga dobnog razreda je drugačiji. U početku je površina šestoga dobnog razreda rasla do svoje maksimalne vrijednosti, kada je prelaženje sastojina iz prezastupljenih srednjih dobnih razreda bilo brže od prelaženja sastojina iz šestoga u sedmi dobni razred. Potpuno izjednačenje površina dobnih razreda postignuto je najprije na razini gospodarenja dijelom Uprave šuma Zagreb I (u 140. god.), dok je na ostale dvije razine gospodarenja to postignuto na kraju razdoblja simulacije. To upućuje na zaključak da površina šume nije u korelaciji s potrebnim vremenom izjednačenja površina dobnih razreda (ukupna površina Uprave šuma Zagreb je 88 734 ha, a površina šuma dijela Uprave šuma Zagreb I je 41 560 ha). Ako se promatra površina triju prezastupljenih srednjih dobnih razreda (III, IV. i

V), vidi se da ona iznosi 400 % normalne površine za sve tri razine gospodarenja. Za ponašanje sustava bitna je, međutim, međusobna struktura površine tih triju dobnih razreda. Na razini gospodarenja dijelom Uprave šuma Zagreb I površina IV. i V. dobnog razreda u odnosu na površinu svih triju dobnih razreda manje je relativno zastupljena nego što je to na razini gospodarenja dijelom Uprave šuma Zagreb II. Četvrti i peti dobni razredi "bliži" su posljednjemu dobnom razredu kojega su promjene stanja odraz stanja spomenutih dobnih razreda. Polaganiji rast površine posljednjega dobnog razreda u modelu 2 posljedica je veće površine trećega i manje površine četvrtoga i petoga dobnog razreda. Suprotno je u modelu 3, u kojemu brže raste površina posljednjega dobnog razreda s tendencijom oscilacijskog ponašanja. To je poslije izazvalo kasnije izjednačenje površina dobnih razreda. Na temelju toga može se reći da vrijeme izjednačenja površina dobnih razreda (uspostavljanje ravnoteže sustava) ovisi o strukturi i odnosu početnih stanja elemenata promatranog sustava. Taj početni odnos stanja elemenata sustava može biti manje ili više u stanju neravnoteže. Prema tomu, to će izazvati ranije uspostavljanje ravnoteže uz polaganije promjene stanja elemenata sustava, odnosno kasnije uspostavljanje ravnoteže uz brže promjene stanja elemenata sustava. Povezano s razvojem razmjera dobnih razreda, odvija se kretanje drvne zalihe i etata. Etat je glavnog prihoda konstantan zbog dane politike gospodarenja, a etat prethodnog prihoda opada u razdoblju izjednačavanja površina dobnih razreda zbog prezastupljenosti srednjih dobnih razreda.

Modelom 4 istraženo je kretanje šumskih resursa u četiri najzastupljenija uređajna razreda (hrasta lužnjaka, hrasta kitnjaka, bukve i jasena). Razvoj razmjera dobnih razreda određen je danom politikom gospodarenja te početnom strukturom dobnih razreda svakoga pojedinog uređajnog razreda. Tako se u uređajnom razredu hrasta lužnjaka u prvih 60 godina može planirati s vrlo brzim i velikim rastom površine zrelih sastojina, dok je površina sastojina prvoga dobnog razreda u kojima se njeguju pomladak i mladik te čiste koljik i letvik konstantna tijekom cijelog razdoblja simulacije (250 godina). Jače početno neuravnoteženo stanje sustava (UR hrast lužnjak) izazvalo je kasno izjednačenje površina dobnih razreda (kraj razdoblja simulacije) preko brzih i intenzivnih promjena stanja posljednjega dobnog razreda. Zabilježen je gotovo jednak razvoj razmjera dobnih razreda između uređajnih razreda hrasta kitnjaka i bukve zbog slične početne strukture dobnih razreda. Polaganiji je rast površine slabo zastupljenoga posljednjega dobnog razreda uzrok brzoga nepotpunog izjednačenja površina dobnih razreda. To se događa u trenutku kada posljednji dobni razred dostiže vrijednost normalne površine, već nakon 100 godina. U uređajnom jasenovu razredu zabilježen je vrlo polagan rast površine posljednjega dobnog razreda te kasno dostizanje vrijednosti normalne površine. Ni u ovom modelu nije uočen utjecaj ukupne površine šume na brzinu izjednačenja površina dobnih razreda (hrast lužnjak 31 150 ha, hrast kitnjak 12 513 ha, bukva 20 130 ha, jasen 7816 ha). Uz danu politiku gospodarenja najveći utjecaj na brzinu izjednačenja površina ima početna struktura površina dobnih razreda. Kretanje

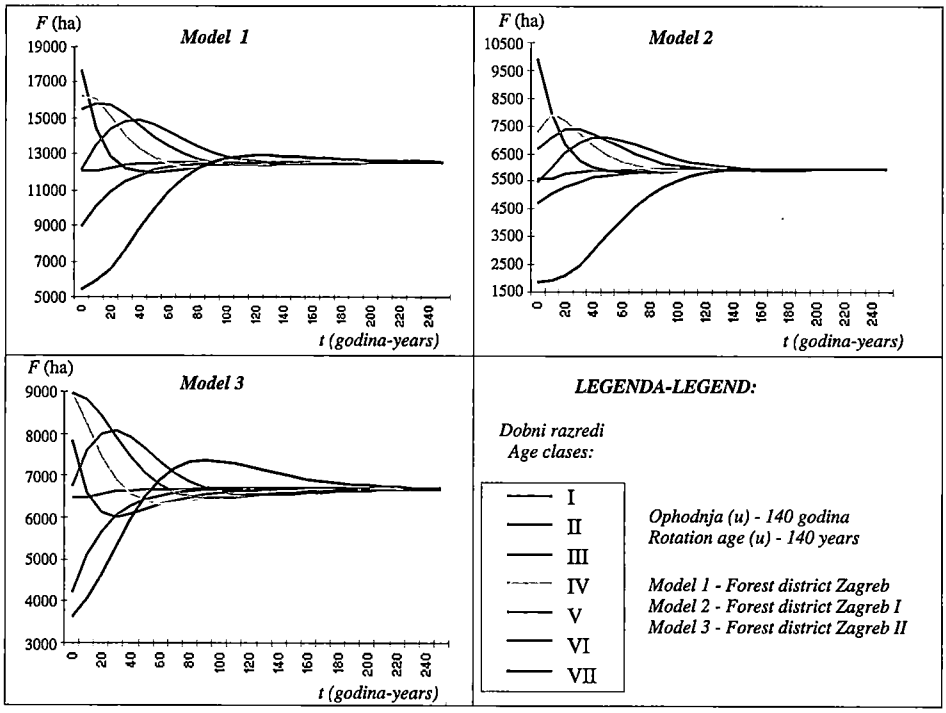

Slika 6. Kretanje površina dobnih razreda
Figure 6. Trends of age classes area

drvne zalihe i etata prethodnog prihoda odraz je specifičnosti kretanja površina dobnih razreda svakoga pojedinog uređajnog razreda u razdoblju izjednačavanja površina dobnih razreda. U uređajnim razredima hrasta lužnjaka, hrasta kitnjaka i bukve uočljiva je preniska drvna zaliha u posljednja dva dobna razreda.

Kretanje promatranih resursa u 14 šumarija Uprave šuma Zagreb prikazano je modelom 5. Na slici 8 opaža se da je razvoj razmjera dobnih razreda karakterističan za svaku pojedinu šumariju. Površina šuma kojima gospodare šumarije kreće se od 2661 ha (Šumarija Donja Stubica), pa do 12 714 ha (Šumarija Novska). Prema potrebnom vremenu izjednačenja površina dobnih razreda postoje tri skupine šumarija. U prvoj su skupini šumarije u kojima je izjednačenje površina dobnih razreda postignuto za 100 – 140 godina. To su šumarije Donja Stubica (2661 ha), Jasenovac (7383 ha), Popovača (6899 ha) i Samobor (6316 ha). Drugu skupinu čine šumarije u kojima je izjednačenje površina dobnih razreda postignuto za 140 – 180 godina. To su šumarije Kutina (8084 ha), Velika Gorica (11 544 ha) i Zlatar (2712 ha). Najveću skupinu čini ostalih sedam šumarija, u kojima je izjednačenje površina dobnih razreda postignuto nakon 200 i više godina. U svakoj šumariji postoji razli-

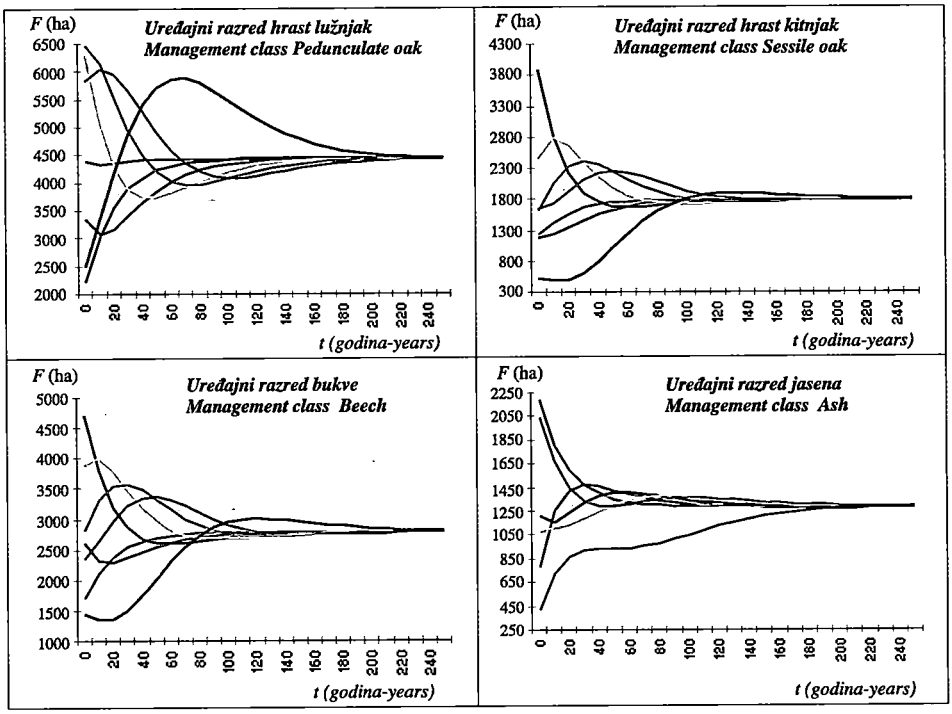

Slika 7. Kretanje površina dobnih razreda – Model 4
Figure 7. Trends of age classes area – Model 4

čita početna struktura dobnih razreda. Najpovoljniji je odnos površina dobnih razreda u prvoj skupini šumarija, gdje je razdoblje uspostavljanja normalnog razmjera dobnih razreda najkraće. Što se tiče kretanja drvne zalihe i etata prethodnog prihoda, može se reći da je ono odraz specifičnosti kretanja površina dobnih razreda u razdoblju njihova izjednačavanja, za svaku pojedinu šumariju.

Modelom 6 istraženo je kretanje površina dobnih razreda, drvne zalihe i etata u 4 slučajno izabrane gospodarske jedinice: GJ Josip Kozarac (5728 ha), GJ Kutinske prigorske šume (2781 ha), GJ Šiljakovačka Dubrava I (661 ha) i GJ Žumberak-Novoselska gora (4590 ha). Slično kao i na razini gospodarenja u šumariji, razvoj je razmjera dobnih razreda u korelaciji s početnom strukturom površina dobnih razreda pojedine gospodarske jedinice. Posebno se ističe gospodarska jedinica Žumberak-Novoselska gora, gdje su već za 50 godina djelomično izjednačene površine dobnih razreda. To se može objasniti pravilnom ravnotežom, s jedne strane, slabo zastupljenih trećega i sedmoga dobnog razreda i nešto jače zastupljenih ostalih dobnih razreda, s druge strane. Kretanje etata prethodnog prihoda karakteristično je za

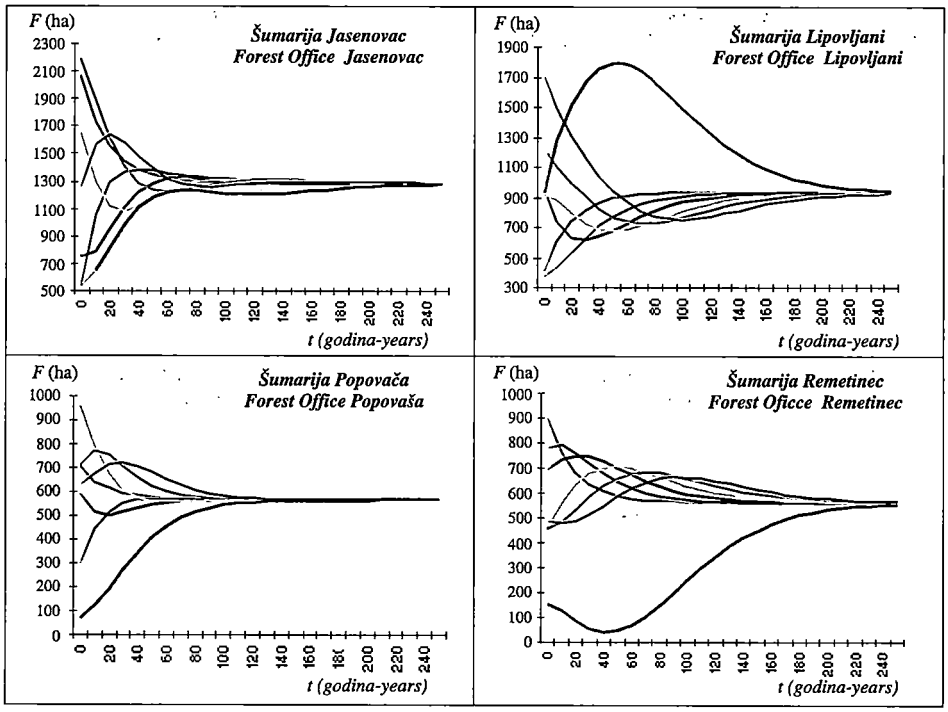

Slika 8. Kretanje površina dobnih razreda – Model 5
Figure 8. Trends of age classes area – Model 5

svaku pojedinu gospodarsku jedinicu, a GJ Žumberak-Novoselska gora ističe se s vrlo postojanim etatom prethodnog prihoda.

Slikama 6 – 9 prikazan je razvoj razmjera dobnih razreda u modelima od 1 do 6.

U modelima 7 – 18 istraženo je ponašanje šumskih resursa u uređajnom razredu hrasta lužnjaka, i to na četiri razine gospodarenja: Uprava šuma Zagreb, dio Uprave šuma Zagreb II, Šumarija Novoselec i gospodarska jedinica Josip Kozarac. Na temelju različitih politika upravljanja i gospodarenja, predstavljenih s 3 scenarija i 12 modela, istraživano je kretanje površina dobnih razreda, etata i drvne zalihe na navedenim četirima razinama gospodarenja. Osnovna je namjera da se na temelju dobivenih rezultata istraživanja odabere i definira najpovoljnija politika gospodarenja jednodobnom šumom za određene okolnosti i postavljene ciljeve. Istraživanje na četirima razinama gospodarenja hrastom lužnjakom, gdje se površina šume kreće od 3900 ha na najnižoj razini, pa do 31 500 ha na najvišoj razini, provedeno je usporedno radi utvrđivanja mogućeg utjecaja površine šume na ponašanje danog sustava.

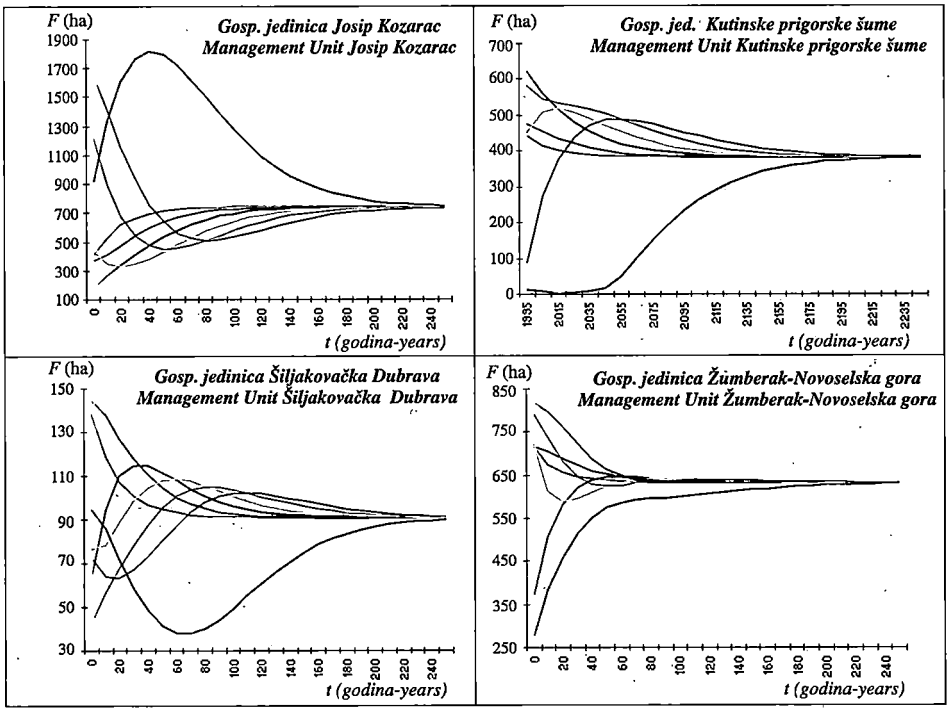

Slika 9. Kretanje površina dobnih razreda – Model 6
Figure 9. Trends of age classes area – Model 6

Na temelju 1. scenarija istraživano je kretanje dobnih razreda po površini, drvne zalihe i etata u uređajnom razredu hrasta lužnjaka na četirima spomenutim razinama gospodarenja. Šumom se gospodari tako da se svake godine posiječe i obnovi *u*-ti dio ukupne površine šume. Po scenariju postoje četiri modela za četiri različite duljine ophodnje.

Modelom 7 predstavljena je šuma kojom se gospodari uz ophodnju od 100 godina i na način definiran scenarijem. Skraćivanjem ophodnje povećala se površina posljednjega dobnog razreda (V), odnosno površina sastojina starijih od 80 godina. Tako se ona kreće između 45 % (Šumarija Novoselec) i 73 % (GJ Josip Kozarac) ukupne šumske površine. Oplodna sječa izvodi se u najzrelijim sastojinama posljednjega dobnog razreda, na stotom dijelu ukupne šumske površine. Na temelju početnog stanja i scenarijem definirane politike gospodarenja određen je razvoj razmjera dobnih razreda te kretanje drvne zalihe i etata. Razvoj razmjera dobnih razreda određen je početnom strukturom dobnih razreda, brzinom izvođenja oplodnih sječa, koja je u ovom modelu konstantna, te normalnom površnom kao ciljem kojemu

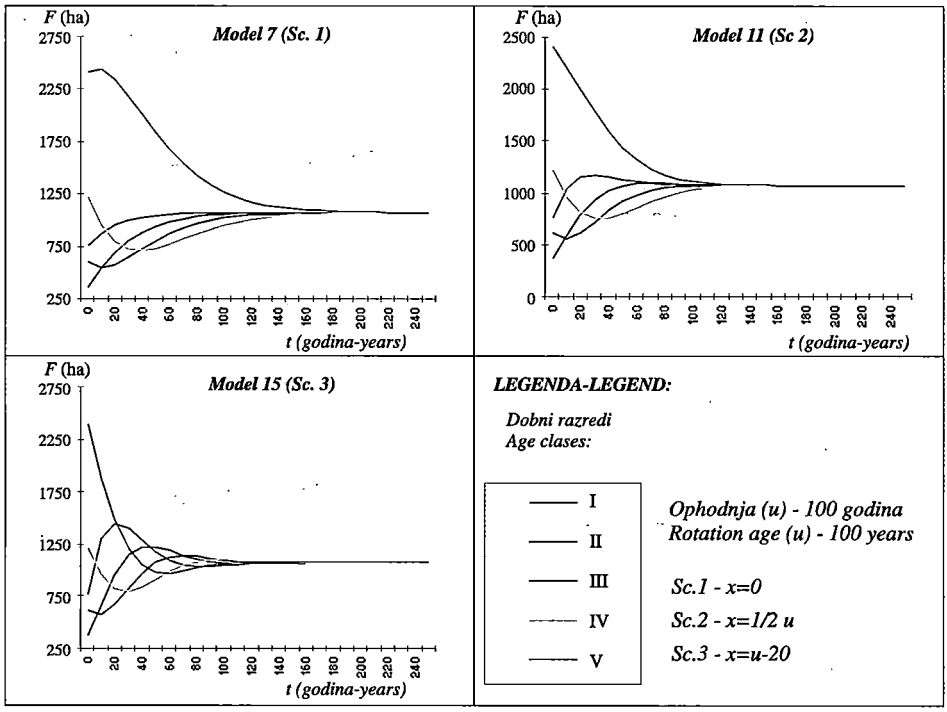

Slika 10. Kretanje površina dobnih razreda po scenarijima, Šumarija Novoselec, UR h. lužnjak
Figure 10. Trends area of age clases per scenarios, FO Novoselec, MC of Pedunculate oak

ovaj zatvoreni dinamički sustav teži radi postizanja stanja ravnoteže. S jedne su se strane dogodile manje promjene (povećanje) površina prvih četiriju dobnih razreda, a s druge su strane veće promjene (smanjenje) površine posljednjega dobnog razreda u jednakom razdoblju. Karakteristična je potpuno jednaka početna struktura te jednak razvoj razmjera dobnih razreda na prvim trima razinama gospodarenja, dok je u GJ Josip Kozarac početna struktura dobnih razreda nešto drugačija. Međutim, bez obzira na površinu šume (razina gospodarenja) i na početnu strukturu dobnih razreda u ovom su modelu istodobno izjednačene površine dobnih razreda (u 170. godini). U razdoblju izjednačavanja površina dobnih razreda, kada se smanjuju površine zrelih sastojina i povećavaju površine sastojina u dobi do 80 godina, vrijednost etata prethodnog prihoda progresivno se povećavala. Ukupna drvna zaliha u tom se razdoblju progresivno smanjivala. To se objašnjava smanjivanjem površine posljednjega dobnog razreda s relativno visokom prosječnom drvnom zalihom po hektaru te povećanjem površine prvoga dobnog razreda.

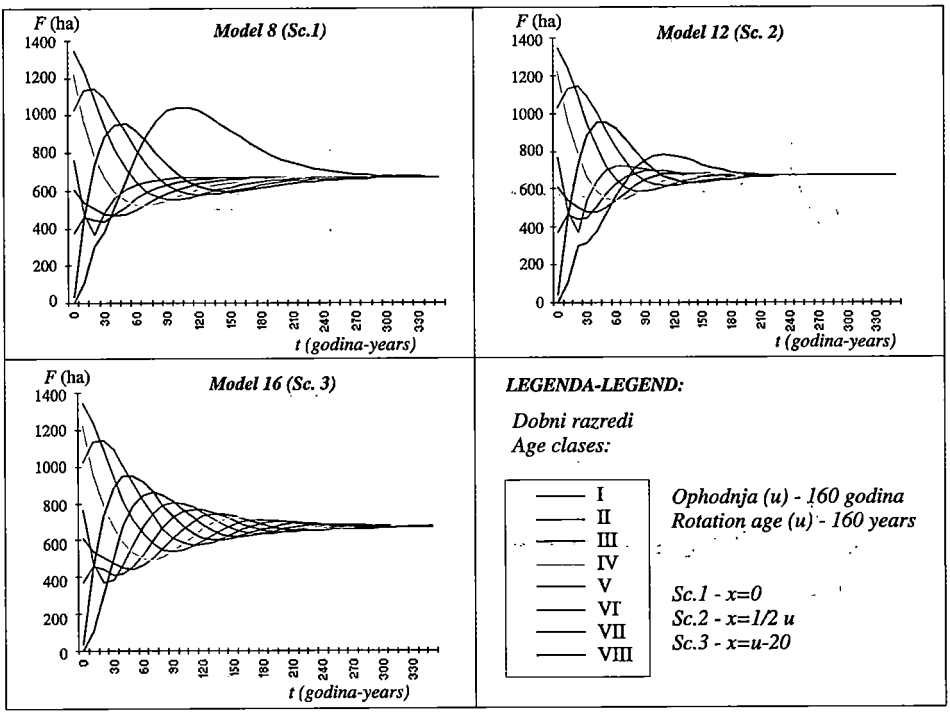

Slika 11. Kretanje površina dobnih razreda po scenarijima, Šumarija Novoselec, UR h. lužnjak
Figure 11. Trends area of age clases per scenarios, FO Novoselec, MC of Pedunculate oak

Model 8 predstavlja šume u kojima je ophodnja produžena za 20 godina. U prvih 20 godina nije se izvodila oplodna sječa radi formiranja posljednjega dobnog razreda. Upravo zbog toga posebno se ističe vrlo brzi rast površine posljednjega dobnog razreda, čija maksimalna vrijednost iznosi 155 % (Šumarija Novoselec) pa do 240 % (GJ Josip Kozarac) normalne površine. Potpuno izjednačenje površina dobnih razreda postignuto je između 280. i 300. godine. Brzo prelaženje sastojina u posljednji dobni razred prouzročilo je brže ili sporije smanjivanje etata prethodnog prihoda. Njegova najmanja vrijednost događa se u vremenskoj točki najveće vrijednosti površine posljednjega dobnog razreda. Nakon toga polagano raste i postiže konstantnu vrijednost u trenutku izjednačenja površina dobnih razreda. Zbog jednakog intenziteta izvođenja oplodnih sječa, što je svojstveno 1. scenariju, etat je glavnog prihoda stalan, pa je krivulja etata ukupnog prihoda usporedna s krivuljom etata prethodnog prihoda. Ukupna je drvna zaliha u prvih 20 godina rasla zbog smanjenja površine prvoga dobnog razreda.

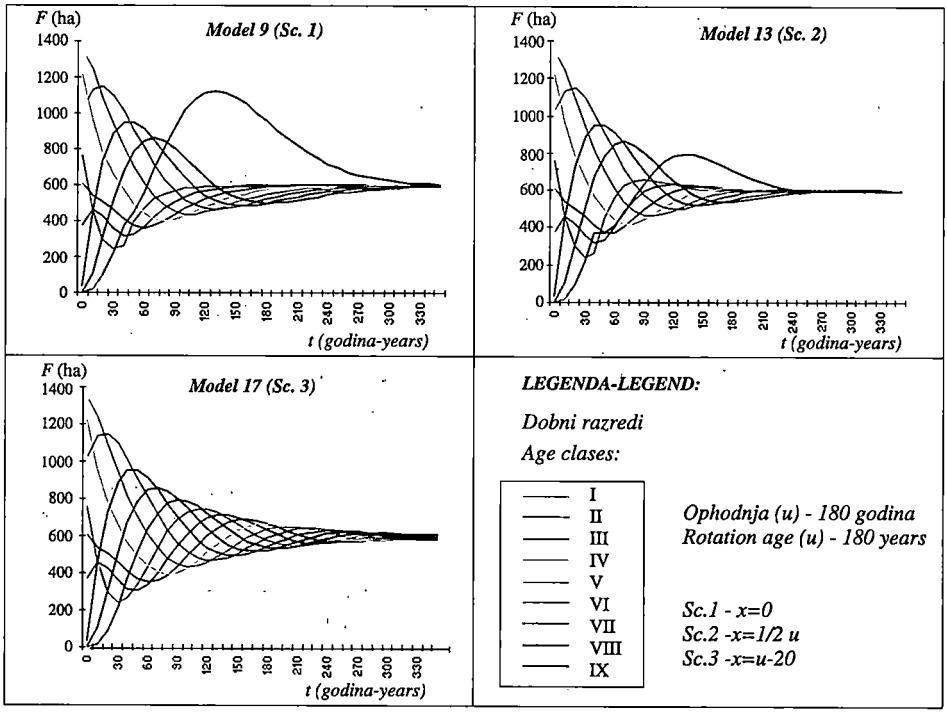

Slika 12. Kretanje površina dobnih razreda po scenarijima, Šumarija Novoselec, UR h. lužnjak
Figure 12. Trends area of age clases per scenarios, FO Novoselec, MC of Pedunculate oak

Model 9 dobiven je produžavanjem ophodnje za 40 godina u promatranim šumama. Kako se oplodna sječa izvodi u posljednjem, devetom dobnom razredu i kako je ona ovisna o njihovoj površini, brzina izvođenja oplodne sječe na početku ima vrijednost nula. Za to su vrijeme formirana posljednja dva dobna razreda. Što se tiče razvoja razmjera dobnih razreda po površini, u modelu je uočeno pravilno nizanje krivulja površina pretposljednjih dobnih razreda, gdje svaka iduća ima manju vrijednost maksimuma te izdvajanje krivulje površine posljednjega dobnog razreda s najvećim maksimumom. Odnos najveće vrijednosti površine posljednjega dobnog razreda i normalne površine povećao se, ako se uspoređuje s modelom 8. Potpuno izjednačenje površina dobnih razreda pomaknuto je pred kraj razdoblja simulacije oko 340. godine. Kretanje etata prethodnog prihoda slično je onomu iz prethodnog modela, osim što se njegova najmanja vrijednost događa kasnije, u vremenskoj točki kulminacije površine posljednjega dobnog razreda. Kretanje ukupne drvne zalihe ima sličnu tendenciju iz prethodnog modela. Ono je određeno površinom prvoga i jače zastupljenih pretposljednjih dobnih razreda. Na početku

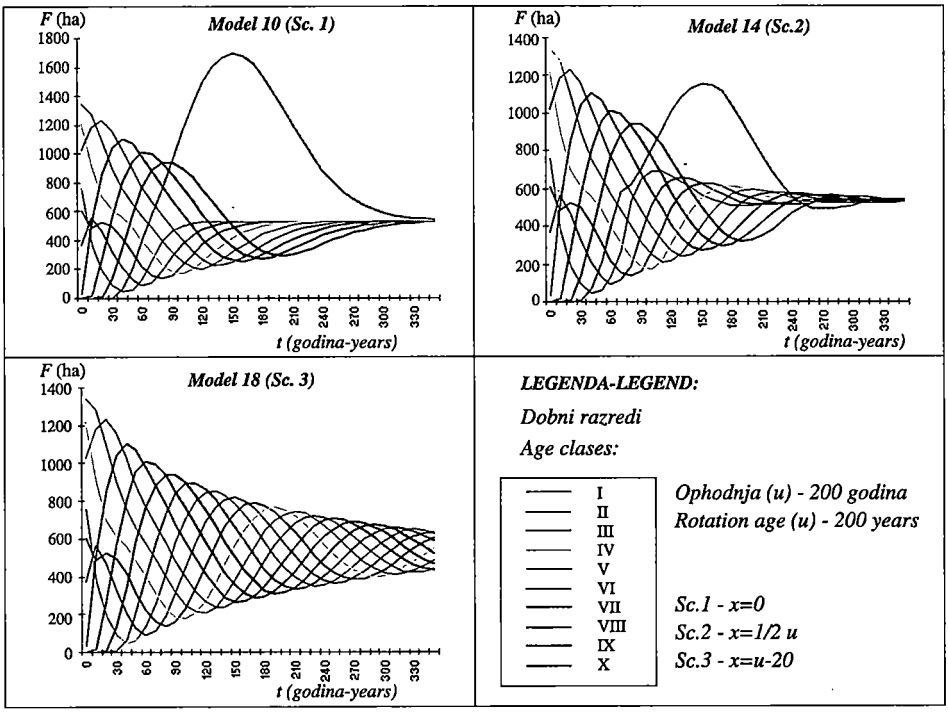

Slika 13. Kretanje površina dobnih razreda po scenarijima, Šumarija Novoselec, UR h. lužnjak
Figure 13. Trends area of age clases per scenarios, FO Novoselec, MC of Pedunculate oak

drvna zaliha raste kako se smanjuje površina prvoga dobnog razreda, a potom opada smanjivanjem površina pretposljednjih dobnih razreda.

Produžavanjem ophodnje za 60 godina dobiven je model 10. Sustav je povećan za jednu krivulju u odnosu na model 9. Još je izraženije pravilno nizanje krivulja površina dobnih razreda, a osobito je izraženo izdvajanje krivulje posljednjega dobnog razreda po svojoj najvećoj vrijednosti. Zakonitost koja je uočena u modelima 7, 8 i 9 da se produžavanjem ophodnje povećava vrijeme potrebno za izjednačenje površina dobnih razreda, nije se pojavila u modelu 10. Potpuno izjednačenje površina dobnih razreda događa se pred kraj razdoblja simulacije, kao u modelu 9, gdje je ophodnja 180 godina. Kretanje etata i drvne zalihe nastavljeno je s istom tendencijom, ali različite jačine.

Politika gospodarenja u 2. scenariju zasniva se na načelu da se svake godine oplodna sječa i obnova sastojina izvodi na površini koja je jednaka kvocjentu površine sastojina starijih od polovine ophodnje i vrijednosti polovine ophodnje. Znači, intenzitet izvođenja oplodne sječe ovisi o površini sastojina starijih od polovine op-

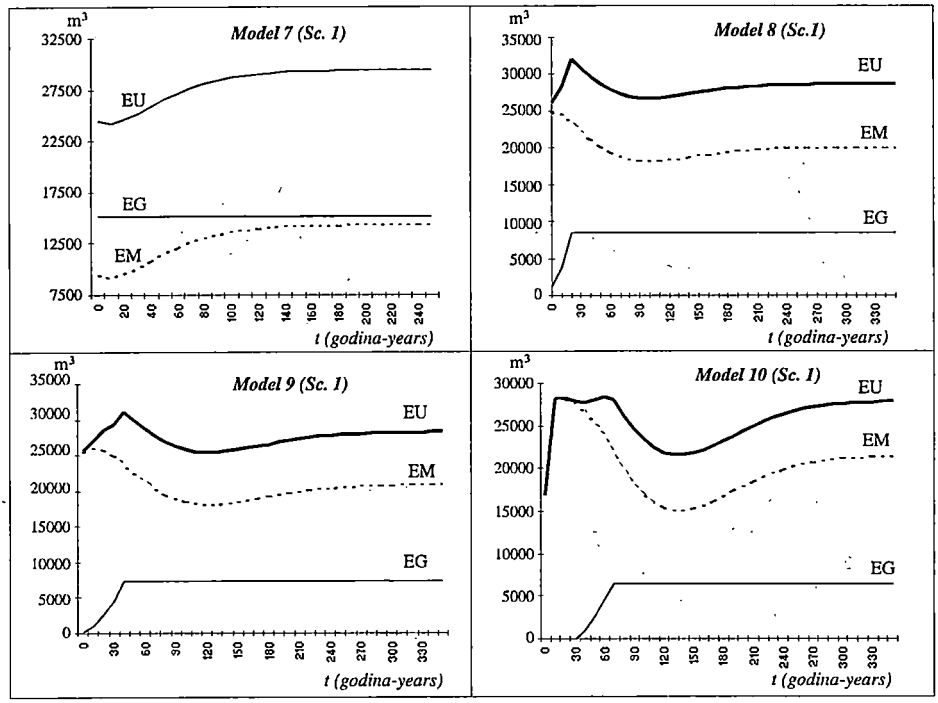

Slika 14. Kretanje godišnjeg etata prethodnoga, glavnoga i ukupnog prihoda, Šumarija Novoselec, UR hrast lužnjak
Figure 14. Trends of felling-plan per years, FO Novoselec, MC of Pedunculate oak

hodnje. Kako površina sastojina starijih od polovine ophodnje nije konstantna u prvom dijelu razdoblja, tako ni brzina izvođenja oplodne sječe nije konstantna u danom razdoblju. Postoje 4 modela za 4 duljine ophodnje (100, 160, 180 i 200 godina).

U modelu 11 intenzitet izvođenja oplodne sječe na početku je bio izrazito velik (površina sastojina starijih od 50 godina iznosi 73 % do 82 % ukupne površine), te se smanjivao kako se smanjivala površina posljednjega dobnog razreda. To je izazvalo brže promjene stanja površina dobnih razreda, pa je normalan razmjer dobnih razreda postignut 60 godina prije nego u modelu 7. Etat glavnog prihoda nije konstantan kao u modelima 1. scenarija. On je u svezi s brzinom izvođenja oplodne sječe, koja je na početku razdoblja najveća, a potom opada prema konstantnoj vrijednosti u trenutku izjednačenja površina dobnih razreda. Ponašanje etata prethodnog prihoda, kao i ukupne drvne zalihe, ima tendenciju modela 7, samo su promjene brže zbog kraćeg razdoblja u kojemu je postignuto izjednačenje površina dobnih razreda

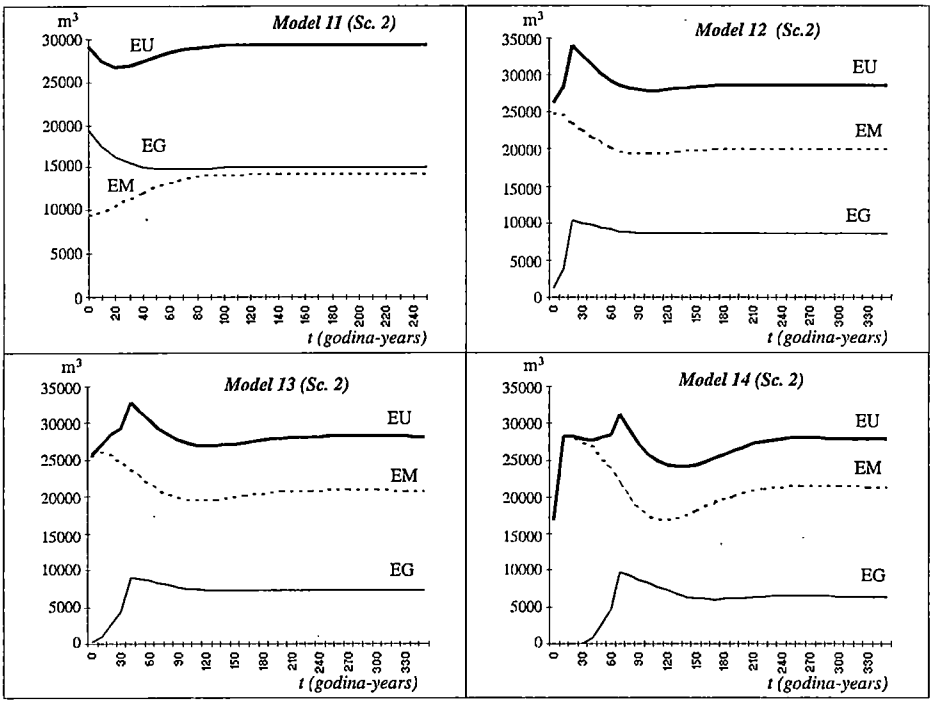

Slika 15. Kretanje godišnjeg etata prethodnoga, glavnoga i ukupnog prihoda, Šumarija Novoselec, UR hrast lužnjak
Figure 15. Trends of felling-plan per years, FO Novoselec, MC of Pedunculate oak

Kada se uspoređuje slika kretanja dobnih razreda po površini modela 12 sa slikom modela 8, uočava se značajna razlika u ponašanju prvoga i posljednjega dobnog razreda. Sporiji rast površine i slabije izražena najveća vrijednost krivulje posljednjega dobnog razreda te dinamičnije kretanje površine prvoga dobnog razreda uzrok su bržega potpunog izjednačenja površina dobnih razreda. To se dogodilo za 70 do 100 godina prije nego u modelu 8. Razlika u kretanju površina dobnih razreda odraz je promjenjive brzine izvođenja oplodne sječe. Ona je u prvih 20 godina vrlo brzo rasla i postigla maksimalnu vrijednost u trenutku kada je površina sastojina starijih od 80 godina bila najveća. Od te vremenske točke BIOS polagano opada i postiže konstantnu vrijednost u vremenskoj točki izjednačenja površina dobnih razreda. To je čimbenik koji je u tom razdoblju smanjio rast površine posljednjega dobnog razreda u odnosu na model 8. Krivulja etata glavnog prihoda ima isti tijek kao opisana dinamika izvođenja oplodnih sječa. Kretanje etata prethodnog prihoda i ukupne drvne zalihe ima izraženiju dinamiku u odnosu na model 8 zbog opisanog ponašanja sustava.

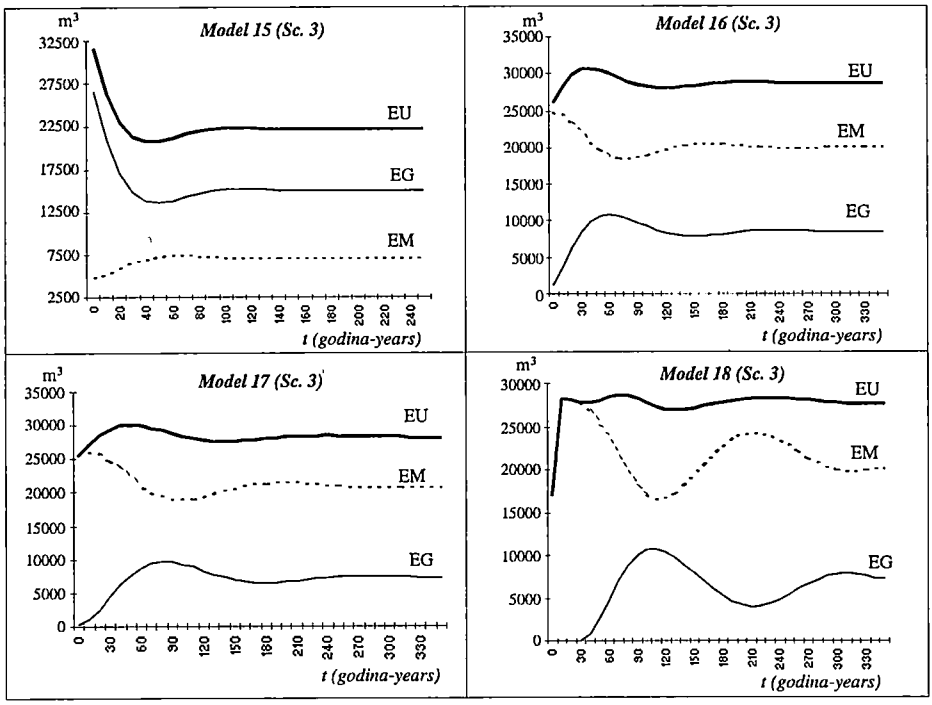

Slika 16. Kretanje godišnjeg etata prethodnoga, glavnoga i ukupnog prihoda, Šumarija Novoselec, UR hrast lužnjak
Figure 16. Trends of felling-plan per years, FO Novoselec, MC of Pedunculate oak

Kretanje dobnih razreda po površini u modelu 13 razlikuje se na isti način od modela 9 kao što je to slučaj prethodnog modela i njemu sukladnog modela iz prethodnog scenarija. Nastavljeno je pravilno nizanje krivulja pretposljednjih dobnih razreda, gdje se posljednji dobni razred izdvaja samo po dužem razdoblju između maksimalnih vrijednosti susjednih krivulja (60 godina). Produženjem ophodnje vremenska točka izjednačenja površina dobnih razreda pomaknula se udesno na vremenskoj osi za 40 godina u odnosu na model 12. Kada se uspoređuje razdoblje izjednačavanja površina dobnih razreda sa sukladnim modelom prethodnog scenarija, vidi se da je ono kraće za 60 do 90 godina, ovisno o razini gospodarenja. Prednost ovog modela očituje se i u manje ekstremnom ponašanju krivulje posljednjega dobnog razreda. Kretanje etata i ukupne drvne zalihe nastavljeno je s istom tendencijom i s pomakom udesno u odnosu na prethodni model.

Za model 14 karakteristično je da nije nastavljeno slično nizanje krivulja površina dobnih razreda. Izdvajanje krivulje posljednjega dobnog razreda ne samo po dužem razdoblju između najvećih vrijednosti sa susjednim dobnim razredom već i

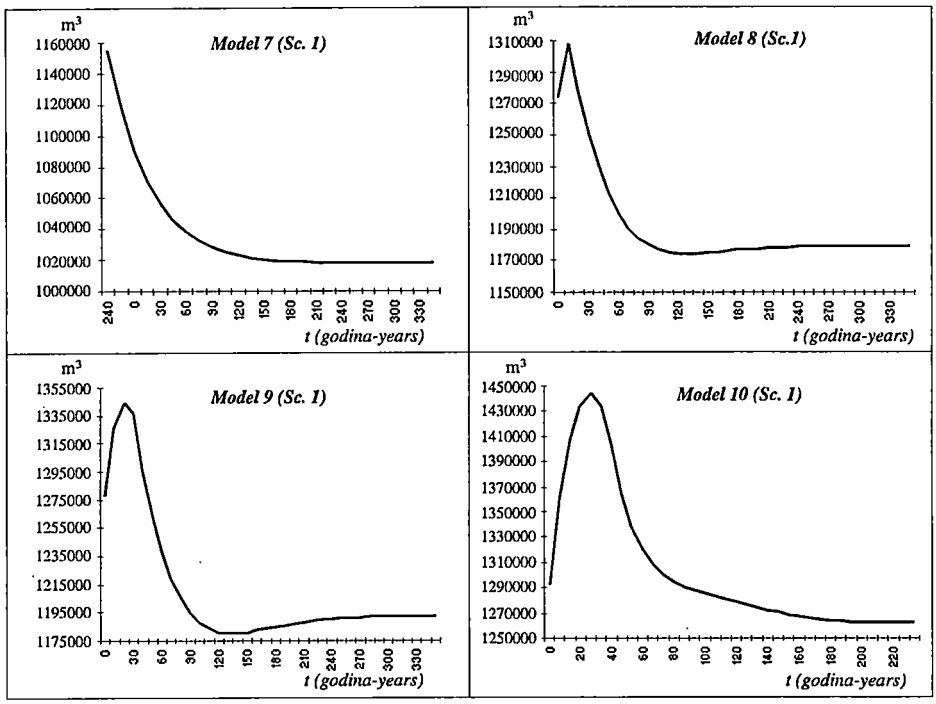

Slika 17. Kretanje ukupne drvne zalihe, Šumarija Novoselec, UR hrast lužnjak
Figure 17. Trends of total growing stock, FO Novoselec, MC of Pedunculate oak

po izraženijem maksimumu, upućuje na sličnost s modelima 1. scenarija. Potpuno izjednačenje površina dobnih razreda nastupilo je na kraju razdoblja simulacije, kao u modelu 10. U modelu je zabilježeno višestruko osciliranje krivulje prvoga dobnog razreda oko osi normalne površine, a to se odrazilo i na pojačano oscilirajuće ponašanje ostalih elemenata sustava. Posljednjih 100 godina obilježeno je smirivanjem oscilacija, gdje su odstupanja oko normalne površine unutar granice + 5 %. Ako se uzme da je takav razmjer dobnih razreda zadovoljavajući, onda je izjednačenje površina dobnih razreda nastupilo 100 godina prije nego u modelu 10. Iz sličnosti kretanja dobnih razreda po površini s modelom 10 nastala je sličnost kretanja etata. Neznatna razlika u kretanju etata glavnog prihoda u razdoblju izjednačavanja površina sastojina starijih od 100 godina s površinom sastojina mlađih od 100 godina posljedica je politike gospodarenja. I nakon 105. godine uočljivo je oscilirajuće ponašanje ukupne drvne zalihe.

Scenarijem definirana politika gospodarenja sastoji se u tome da brzina izvođenja oplodne sječe ovisi o površni posljednjega dobnog razreda. Ponašanje

istraživanih elemenata za 4 različite duljine ophodnje (100, 160, 180 i 200 godina) prikazano je s 4 modela.

U modelu 15 uočene brže promjene stanja površina dobnih razreda u odnosu na model 11 upućuju na sustav s izraženijom dinamikom i naznakom oscilirajućeg ponašanja. Brže promjene površina posljednjega i prvoga dobnog razreda, a preko njih i ostalih, posljedica su bržeg izvođenja oplodnih sječa na početku razdoblja. Do toga je došlo zato što je 1/20 površine na opisani način nastaloga posljednjega dobnog razreda bila veća od 1/50 površine sastojina starijih od 50 godina na početku simulacije. Razdoblje izjednačavanja površina dobnih razreda može se podijeliti na dva dijela. U prvom dijelu brzo se mijenja stanje površina, a u drugom dijelu smiruju se oscilacije izazvane tim brzim promjenama. Iako drukčije dinamike, vremenska točka izjednačenja površina dobnih razreda odgovara onoj iz modela 11. Brže i izraženije promjene etata i ukupne drvne zalihe isto tako upućuju na dinamičniji model u odnosu na model 11.

Model 16 upućuje na posebno dinamično ponašanje, koje se značajno razlikuje od modela prethodnih dvaju scenarija. Već nakon prvih 30 godina formiran je snop isprepletenih krivulja površina dobnih razreda, koje osciliraju oko uzdužne osi snopa (pravca normalne površine). Za razliku od prethodnih modela, krivulja se posljednjega dobnog razreda ne izdvaja iz snopa, već se snop krivulja jednakomjerno sužava i prelazi u svoju os na kraju razdoblja simulacije. U odnosu na model 12, u modelu 16 dugotrajnije se, ali ujednačenije izjednačuju površine dobnih razreda. Kao odraz spomenutoga kretanja površina dobnih razreda oscilira i kretanje etata i ukupne drvne zalihe. U vremenskoj točki najmanje vrijednosti etata glavnog prihoda nalazi se najveća vrijednost etata prethodnog prihoda, i obrnuto. Etat cjelokupnog prihoda nije stalan zbog različite jačine promjena spomenutih etata.

Produžavanjem ophodnje za još 20 godina, odnosno dodavanjem još jednoga dobnog razreda, dobiven je model 17. Nastavljena je slična tendencija razvoja razmjera dobnih razreda. Os normalne površine pomaknuta je naniže, a osciliranje krivulja oko te osi izraženije je u odnosu na model 16. Zbog toga se snop krivulja sporije sužava pa je potpuno izjednačenje površina dobnih razreda pomaknuto više udesno na vremenskoj osi u odnosu na model 16. Potpuno izjednačenje površina nije postignuto ni na kraju razdoblja. Kretanje etata i ukupne drvne zalihe pokazuje tendenciju prethodnog modela, ali s izraženijim i dugotrajnijim osciliranjem vrijednosti.

Model 18 pokazuje još izraženiju dinamiku u odnosu na prethodna dva. Izraženim i pravilnim osciliranjem oko osi normalne površine, koja je produženjem ophodnje pomaknuta naniže, krivulje površina dobnih razreda čine gust i simetričan snop koji ima tendenciju vrlo sporog sužavanja. To upućuje na činjenicu da se produžavanjem ophodnje po 3. scenariju vrlo progresivno povećava vrijeme potrebno za izjednačenje površina dobnih razreda. Povezano s kretanjem dobnih razreda po površini, nastalo je posebno izraženo osciliranje vrijednosti etata i ukupne drvne zalihe s tendencijom dugotrajnog smirivanja.

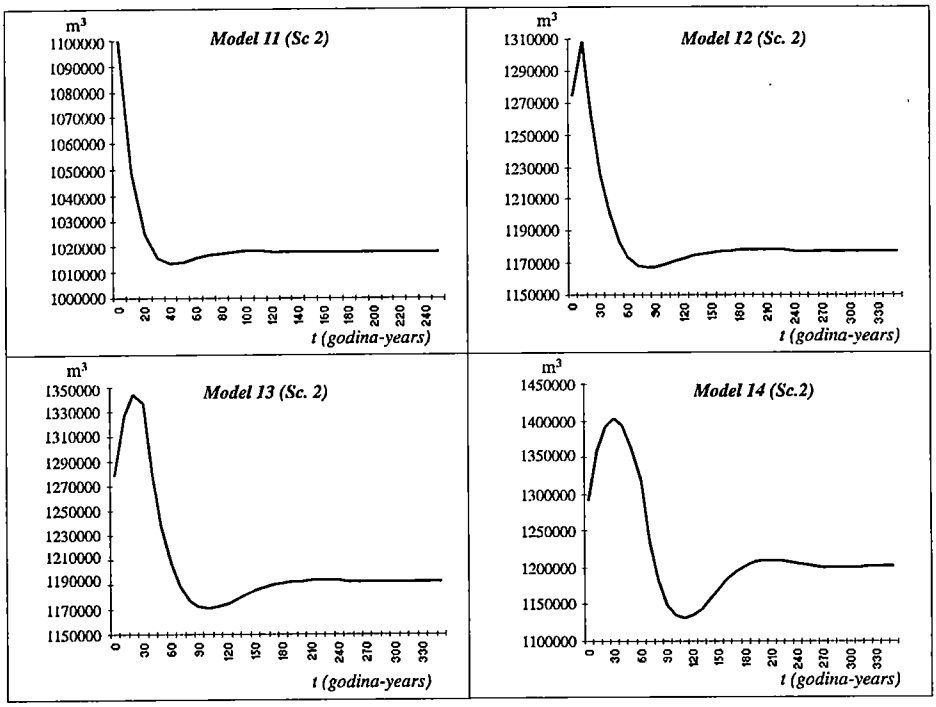

Slika 18. Kretanje ukupne drvne zalihe, Šumarija Novoselec, UR hrast lužnjak
Figure 18. Trends of total growing stock, FO Novoselec, MC of Pedunculate oak

Na slikama 10 do 19 zbog prostora, samo na razini gospodarenja u Šumariji Novoselec, prikazano je kretanje površine dobnih razreda, etata te drvne zalihe u modelima od 7 do 18.

Modelom 19 prikazano je ponašanje sustava šume hrasta lužnjaka na području Uprave šuma Zagreb kao posljedica varijabilne i nepravilne politike izvođenja oplodne sječe te nedifinirane duljine ophodnje. Takvo gospodarenje može biti uvjetovano različitim čimbenicima, kao što je izostanak uroda sjemena, masovna pojava sušenja srednjodobnih i starih sastojina, povećana potražnja za ekološkom funkcijom starih sastojina i drugo. Kako se to može odraziti na kretanje dobnih razreda i etata prikazano je na slici 20.

Tablica 1 prikazuje odnos vremenskih točaka izjednačenja površina dobnih razreda, etata i ukupne drvne zalihe prema scenariju i između scenarija, na razini gospodarenja hrastom lužnjakom u Upravi šuma Zagreb.

Prikazani podaci o etatu i drvnoj zalihi odnose se na razdoblje nakon izjednačenja površina dobnih razreda, ili na kraj razdoblja simulacije, u slučaju kada još

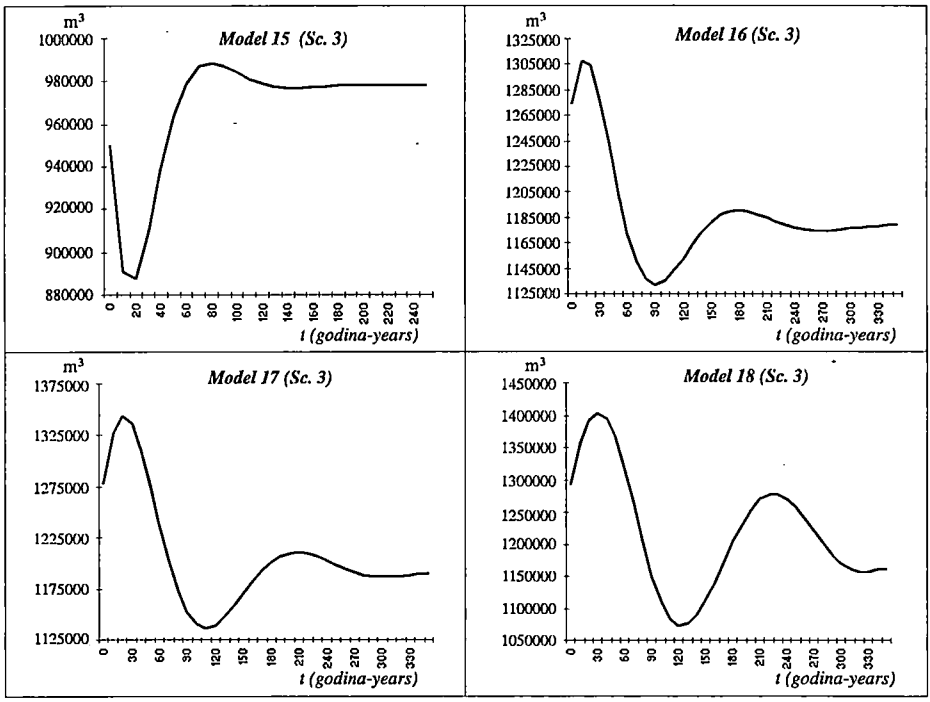

Slika 19. Kretanje ukupne drvne zalihe, Šumarija Novoselec, UR hrast lužnjak
Figure 19. Trends of total growing stock, FO Novoselec, MC of Pedunculate oak

nisu izjednačene površine dobnih razreda (modeli 17 i 18). Dakle, podaci se odnose na uravnoteženo stanje proučavanih jednodobnih šuma. Uspoređivanjem podataka u navedenim tablicama uočava se sličnost odnosa promatranih elemenata među četirima navedenim razinama gospodarenja hrastom lužnjakom. To upućuje na zaključak da na kretanje površina dobnih razreda, etata i drvne zalihe ne postoji utjecaj površine šume. Prema tomu, razmatranje rezultata iz tablica odnosi se na sve četiri istraživane razine gospodarenja hrastom lužnjakom.

Za sva tri scenarija može se općenito reći da se produžavanjem ophodnje povećava potrebno vrijeme za izjednačavanje površina dobnih razreda. Slika 20, na kojoj je dan prikaz odnosa vremena potrebnoga za izjednačenje površina dobnih razreda i ophodnje, pokazuje velike razlike među scenarijima.

Po 1. scenariju produžavanjem ophodnje linearno se povećava vrijeme potrebno za izjednačenje površina dobnih razreda do duljine ophodnje od 180 godina. Zanimljivo je da je to vrijeme isto za ophodnje od 180 i 200 godina.

Sporo progresivno povećanje vremena izjednačenja površina dobnih razreda obilježje je 2. scenarija, a cijela krivulja nalazi se ispod krivulje 1. scenarija.

Tablica 1. Prikaz odnosa T_{idr}, etata i drvne zalihe prema scenariju i između scenarija
Table 1. Relationship T_{idr}, allowable cut and growing stock under and between scenarios

Scenario		Ophodnja (godina) – Rotation age (years)			
		100	160	180	200
1	T_{idr}	170	300	340	340
	EM	33 856	55 117	58 594	61 207
	EG	112 591	68 010	59 231	52 207
	EU	146 447	123 127	117 825	113 414
	V	6 485 309	8 251 584	8 519 017	8 708 067
2	T_{idr}	130	200	250	330
	EM	33 865	55 131	58 675	61 267
	EG	112 591	68 010	59 229	52 114
	EU	146 456	123 141	117 904	113 381
	V	6 484 981	8 251 664	8 519 202	8 710 282
3	T_{idr}	130	350	>350	>350
	EM	33 866	55 209	58 514	57 916
	EG	112 606	67 757	59 014	58 278
	EU	146 472	122 966	117 528	116 194
	V	6 485 310	8 256 231	8 494 191	8 375 185

EM – etat prethodnog prihoda (m^3/god.) EU – etat cjelokupnog prihoda (m^3/god.)
EG – etat glavnog prihoda (m^3/.) V – ukupna drvna zaliha (m^3)
T_{idr} – vremenska točka izjednačenja površina dobnih razreda

Dinamičnost modela 3. scenarija uočava se i u vrlo brzom i progresivnom rastu vremena potrebnoga za izjednačenje površina dobnih razreda produžavanjem ophodnje.

Kada je cilj gospodarenja postići normalan razmjer dobnih razreda uz produžavanje ophodnje, temeljem slike 21, izabrat će se najpovoljnija politika gospodarenja i upravljanja jednodobnom šumom koja je definirana 2. scenarijem. Prednost modela 2. scenarija (modeli 12 i 13) prema modelima 1. scenarija očituje se u većoj ravnomjernosti zrelih prema ostalim sastojinama u razdoblju izjednačavanja površina dobnih razreda. Ekstremno prezastupljene zrele sastojine u sredini spomenutog razdoblja, pri gospodarenju definiranome 1. scenarijem, nedostatak su u odno-

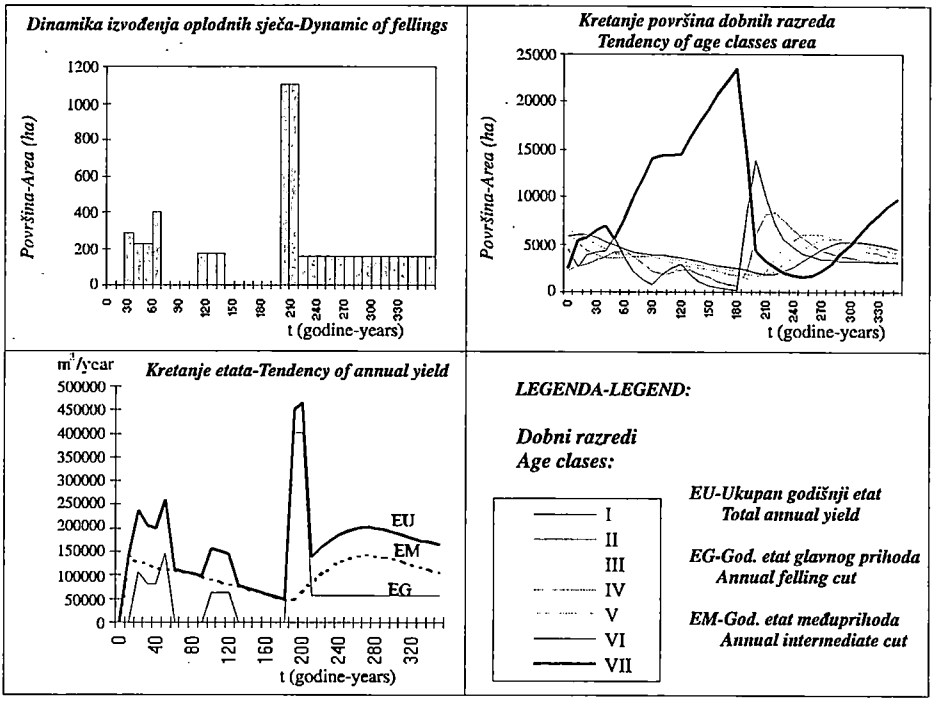

Slika 20. Kretanje oplodne sječe, površina dobnih razreda i godišnjeg etata; scenarij 4
Figure 20. Tendency of fellings, age classes area and annual yield; Scenario 4

su na modele 2. scenarija i ne odgovaraju zahtjevima kvalitetnoga gospodarenja s potrajnom proizvodnjom.

Za gospodarenje definirano 3. scenarijem može se reći da je najbliže prirodnomu, odnosno da ono prati i oponaša procese u prirodi. Ono je karakterizirano vrlo polaganim i jednolikim uspostavljanjem stanja ravnoteže sustava. Takvo gospodarenje primjereno je u šumama u kojima su primarno izražene općekorisne funkcije (park-šume, nacionalni parkovi, parkovi prirode).

Gospodarenjem definiranim 2. scenarijem nastoji se ubrzati proces postizanja stanja ravnoteže i potrajnosti prihoda u drvnoj tvari. Ono je primjereno u šumama koje imaju jače izražen gospodarski karakter.

Više statično i manje intenzivno gospodarenje u odnosu na 2. scenarij definirano je 1. scenarijem.

Promjena politike gospodarenja nije utjecala na promjenu veličine etata cjelokupnog prihoda, kako se to vidi iz tablica. Mijenjao se odnos između etata glavnoga i etata prethodnog prihoda kako se mijenjala duljina ophodnje. Produžavanjem

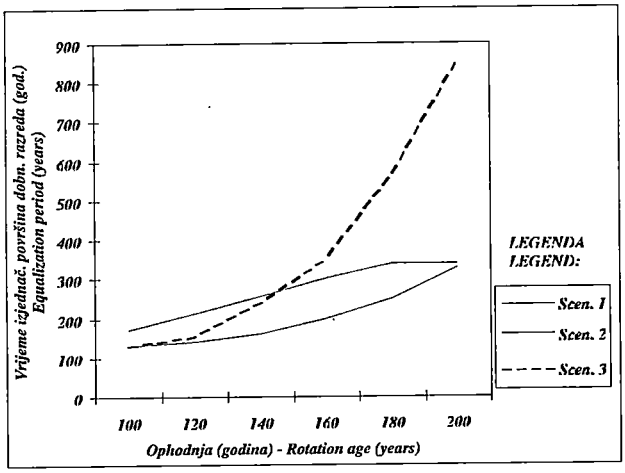

Slika 21. Odnos vremena potrebnoga za izjednačenje površina dobnih razreda i duljine ophodnje prema scenarijima
Figure 21. Relationship between equalization period of age clases area and rotation age under scenarios

ophodnje rasla je površina sastojina koje se njeguju proredom, a smanjivala površina zrelih sastojina u kojima se izvodi oplodna sječa. Jedino se model 3. scenarija s ophodnjom od 200 godina razlikuje od prethodna dva po etatu glavnoga i prethodnog prihoda zato što u tom modelu ni na kraju razdoblja nisu izjednačene površine dobnih razreda, odnosno vrijednosti etata nisu kostantne. Promjene ukupne drvne zalihe nisu izazvane različitim politikama gospodarenja. Produžavanjem ophodnje povećava se ukupna drvna zaliha.

ZAKLJUČAK – CONCLUSION

Na temelju opisane metodologije znanstvenog istraživanja, projektiranoga simulacijskog modela, provedenih simulacija te ispitivanja valjanosti simulacijskog modela moguće je donijeti sljedeće zaključke:

1. Modeliranjem se uz pomoć sustavne dinamike mogu predstaviti različiti složeni sustavi u šumarstvu, pa tako i sustav regularne šume kojom se gospodari metodom razmjera dobnih razreda. Računalnim simulacijskim modelom mogu se simulirati ponašanja stvarnih sustava regularne šume u definiranom vremenu, te na taj način odrediti njihov budući razvoj. Takva tehnika pruža velike mogućnosti pri planiranju u šumarstvu, kako na lokalnoj, tako i na višim razinama gospodarenja.

2. Na temelju razmatranja dobivenih podataka kretanja dobnih razreda po površini u istraživanim šumama (Uprava šuma Zagreb, dijelovi Uprave šuma Zagreb I i II, šumarije, gospodarske jedinice te uređajni razredi) može se zaključiti da vrijeme koje je potrebno za izjednačenje površina dobnih razreda u najvećoj mjeri ovisi o početnoj strukturi i odnosu površina dobnih razreda u promatranoj stvarnoj šumi. Utjecaj ukupne šumske površine nije uočen. Taj utjecaj posredno postoji, uz pretpostavku da na većoj šumskoj površini postoji povoljnija struktura dobnih razreda.

3. U svim istraživanim šumama u Upravi šuma Zagreb najveće se promjene u kretanju površina dobnih razreda, etata i drvne zalihe događaju u prvih 100 godina. Ovisno o stvarnom stanju i odnosu dobnih razreda unutar pojedine razine i kategorije gospodarenja, vrijeme potrebno za izjednačenje površina dobnih razreda kreće se od 90 godina (cjelokupna Uprava šuma Zagreb, šumarija Jasenovac) do preko 200 godina (Šumarija Lipovljani, GJ Šiljakovačka Dubrava).

4. Kretanje etata i ukupne drvne zalihe odraz je specifičnosti kretanja površina dobnih razreda konkretne šume. Promjene etata i ukupne drvne zalihe najveće su prvih 100 godina, kada se događaju i najveće promjene površina dobnih razreda kao posljedica početne nepravilne dobne strukture istraživanih šuma.

5. Na temelju pretpostavljenoga gospodarenja, početnog stanja površina dobnih razreda te stanja prirasta i drvne zalihe bilo koje stvarne jednodobne šume predstavljenim kontinuiranim simulacijskim modelom moguće je odrediti budući razvoj razmjera dobnih razreda te kretanje etata i drvne zalihe.

6. Uočena sličnost dinamike ponašanja između istraživanih stvarnih šumskih sustava hrasta lužnjaka na četiri različite razine gospodarenja nepravilnih početnih dobnih struktura upućuje na zaključak da se, teoretski, normalan razmjer dobnih razreda koji osigurava potrajnost prihoda, može postići jednako brzo i na razini gospodarske jedinice i na razini šumarije, dijela uprave šuma i cjelokupne uprave šuma.

7. Zakonitost da normalnu površinu najprije postigne prvi dobni razred, a potom redom drugi, treći i tako dalje uočena je u svim šumama nepravilne početne dobne strukture.

8. Kada se pri gospodarenju površinski etat glavnog prihoda računa na temelju ukupne površine šume, produžavanjem ophodnje izrazito se povećava površina posljednjega dobnog razreda u sredini simulacijskog razdoblja. To je u manjoj mjeri izraženo pri gospodarenju u kojemu se površinski etat glavnog prihoda računa na temelju površine sastojina starijih od polovine ophodnje, dok u gospodarenju definiranomu 3. scenarijem polaganije se i ujednačenije izjednačuju površine svih dobnih razreda.

9. Promjena duljine ophodnje prema simuliranim scenarijima u istraživanim jednodobnim šumama hrasta lužnjaka utječe na duljinu vremena potrebnoga za postizanje normalnog razmjera dobnih razreda. Skraćivanjem ophodnje smanjuje se vrijeme potrebno za izjednačenje površina dobnih razreda i obrnuto, produžavanjem ophodnje povećava se to vrijeme. Svakako da u zdravim i stabilnim šumamama hrasta lužnjaka nepravilne dobne strukture skraćivanje ophodnje radi smanjenja razdoblja izjednačavanja površina dobnih razreda nije dovoljno jako opravdano.

10. Promjene gospodarenja definirane simuliranim scenarijima nemaju utjecaja na veličinu ukupne drvne zalihe i etata. Prema simuliranim scenarijima produžavanjem ophodnje ukupna se drvna zaliha povećava. Na etat cjelokupnog prihoda ne utječe duljina ophodnje. Mijenja se samo odnos između etata prethodnog prihoda i etata glavnog prihoda. Produžavanjem ophodnje povećava se etat prethodnog prihoda, a smanjuje etat glavnog prihoda.

11. Politika gospodarenja jednodobnom šumom definirana brzinom izvođenja oplodne sječe (načinom računanja površinskog etata glavnog prihoda) i duljinom ophodnje vrlo je snažan vanjski čimbenik koji utječe na buduće ponašanje (kretanje razmjera dobnih razreda, etata i drvne zalihe) zatvorenoga sustava regularne šume.

12. U gospodarenju definiranomu 2. scenarijem u razdoblju izjednačavanja površina dobnih razreda postoji ravnomjerniji odnos zrelih i mladih sastojina te povoljniji odnos potrebnoga vremena izjednačenja površina dobnih razreda i duljine ophodnje. Zato se za buduće gospodarenje ovim šumama hrasta lužnjaka, koje imaju nepravilnu dobnu strukturu, radi postizanja stabilnog sustava s potrajnom proizvodnjom svih koristi od šume ocjenjuje najpovoljnije gospodarenje pri kojemu oplodne sječe ovise o površini sastojina starijih od polovine ophodnje, a šumom se gospodari ophodnjom od 140 do 180 godina.

13. Gospodarenjem regularnom šumom nepravilne dobne strukture uz maksimalnu ophodnju, gdje je izvođenje oplodne sječe ovisno samo o površini najzrelijih sastojina, polagano se i ujednačeno uspostavljava normalni razmjer dobnih razreda. Takav je model primjeren u šumama u kojima su izražene više općekorisne, a manje gospodarske funkcije šume.

14. Sustavnim dinamičkim modeliranjem moguće je u simulacijski model ugraditi buduće predvidive neželjene promjene koje će se odraziti na gospodarenje šumskim resursima na određenom području. Na temelju takve dinamike ponašanja sustava kao odziva na simulirani scenarij može se izvoditi dugoročno planiranje fizičkih, ekonomskih i financijskih elemenata.

15. Na osnovi ispitivanja valjanosti simulacijskog modela može se zaključiti da je model valjan i da se može primijeniti za simuliranje budućeg ponašanja, osobito u regularnim šumama na većim površinama gdje je starosna struktura sastojina unutar dobnih razreda jednolika. Izrađeni je simulacijski model pogodna osnova za dugoročno planiranje pri gospodarenju regularnim šumama.

Ovo je istraživanje provedeno da bi se prikazao novi pristup koji bi omogućio lakše planiranje i predviđanje pri gospodarenju regularnim šumama, a u kontekstu šireg smisla potrajne proizvodnje. Ono upućuje na potrebu daljnjeg istraživanja jer je otvorilo brojna nova pitanja koja nisu mogla biti obuhvaćena ovim radom. Određene pretpostavke izvedene na temelju dobivenih rezultata i donesenih zaključaka trebaju poslužiti kao osnova za daljnje istraživanje radi unapređenja toga vrlo važnoga šumarskog područja.

LITERATURA – REFERENCES

Birch, T. W., 1983: The forest land owners of New York. USDA For. Serv. Resour. Bull. NE-78. 80 p.

Bossel, H., 1986: Dinamics of forest dieback: systems analysis and simulation. Ecol. Modelling 3: 259 – 288.

Bossel, H., 1991: Modelling forest dynamics: Moving from description to explanation. For. Ecol. Management 42: 129 – 142.

Bossel, H., & H. Krieger, 1991: Simulation model of natural tropical forest dynamics. Ecol. Modelling 59: 37 – 71.

Bossel, H., H. Krieger, H. Schafer & N. Trost, 1991: Simulation of forest stand dynamics, using real-structure process models. For. Ecol. Manage. 42: 3 – 21.

Buongiorno, J., & K. J. Gilless, 1986: Forest management and economics. Macmillan, New York, 285 pp.

Burkhardt, H. E., B. R. Knoebel & D. E. Beck, 1983: A Growth and Yield Model for Thined Stands of Yellow-poplar (Liriodendron tulipifera). Forest Growth Modelling and Simulation: 41 – 53, Wien.

Carpentier, J. P., 1987: Modelling the growth and yield of sugar maplestands. Memoire, Direction de la Recherce et du Developpement, Ministere de l'Energie et des Ressources, Quebec (1987) No. 91, 160 pp.

Čavlović, J., 1994: Linearno programiranje u planiranju i gospodarenju jednodobnim šumama. Glas. šum. pokuse 31: 435 – 442, Zagreb.

Evans, J., & B. G. Hibberd, 1990: Managing to diversify forests. Arboricultural Journal 14: 373 – 378.

Fahser, L., 1988: The ecological orientation of the forest economy. Natural Resources and Development. 28: 71 – 99.

Fahser, L., 1989: Forest management-an ecological, social, cultural and economic commitment. Forests as living space and economic factor, Proceedings of the Workshop on Forests at Max Mueller Bhavan, Bombay, December 4 – 9,1989, 7 pp

Forrester, J. W., 1961: Industrial dynamics, Massachusetts Institute of Technology Press Cambridge, Massachusetts, Students Edition, Tenth Printing, 1980, Copyright 1961 by Massachusetts Institute of Technology.

Forrester, J. W., 1968: Principles of systems. Massachusetts Institute of Technology Press Cambridge, Massachusetts and London, England, Second Preliminary Edition, Ninth Printing, 1980, Copyright 1968. by Jay W. Forrester.

Forrester, J. W., 1971: World dynamics. Wright-Allen Press, Inc. Cambridge, Massachusetts, Second Edition, Copyright 1971, 1973, Wright-Allen Press, Inc Ninth Printing, 1980, Copyright 1968. by Jay W. Forrester.

Gane, M., 1986: TIMPLAN: A planning system for industrial timber-based development. Cmmonwealth Forestry Review. 65 (1): 41 – 49.

Gane, M., 1992: Sustainable Forestry. Cmmonwealth Forestry Review. 71 (2): 83 – 90.

Gane, M., 1992: Country experience with modelling systems for forest sector planning. Special Paper for 10th World Forestry Congress, Paris.

Grladinović, T., 1993: Istraživanje optimalnog režima poslovanja u proizvodnji namještaja. Disertacija, Zagreb.

Haight, R. G., 1985: A Comparison of Dynamic and Static Economic Models of Uneven-Aged Stand Management. Forest Sci. 4: 957 – 974.

H o e n, H. F., 1987: Optimal timber management scheduling for a region. Scandinavian Forest Economics. 29: 89 – 99..

H o e n, H. F., 1992: GAYA-LP: A PC-based long range forest management model. Paper prepared for the EURO XII/TIMS XXXI Joint International Conference in Helsinki, Finland, June 28th – July 1st 1992.

H o e n, H. F., 1994: The Faustmann rotation in the presence of a Positive CO_2-price. Scandinavian Forest Economics. 35: 278 – 287.

I v k o v, M., 1994: Simuliranje razvoja sastojina uz pomoć modela ovisnosti debljinskog prirasta o razini podzemnih voda. Glas. šum. pokuse 30: 95 – 142, Zagreb.

J o b s t l, H. A., 1984: Simulation of long-term develoment as a basis sustained yield management and medium-term planning. Forst-und Holzwirt 39 (14 – 15): 349 – 354.

K a y a, I., & J. B u n g i o r n o, 1987: Economic Harvesting of Uneven-Aged Northern Hardwood Sands Under Risk: A Markovian Decision Model. Forest Sci. 4: 889 – 907.

K i e n a s t, F., & N. K r a u c h i, 1991: Simulated successional characteristics of managed and unmanaged low-elevation forests in central Europe. For. Ecol. Manage. 42: 49 – 61.

K i s i l e v, A. F., & O. A. A t r o s h c h e n k o, 1985: Modelling the growth and productivity of Belorussian Norway spruce stands. Lesovedenie i Lesnoe kozjajstvo 20: 70 – 75.

K l e p a c, D., 1965: Uređivanje šuma. Znanje, Zagreb, 340 str.

K l s t r o m, T., 1991: Modelling early development of a planted pine stand: an aplication of object-oriented programming. For. Ecol. Manage. 42: 67 – 77.

K r i e g e r, H., H. S c h a f e r & H. B o s s e l, 1990: SPRUCOM – a simulation model of spruce stand dynamics under varying immision exposure. Syst. Anal. Model. Simul. 7 (2): 117 – 129.

Križanec, R., 1992: Uređivanje šuma – Razvoj metoda. U Šume u Hrvatskoj: 131 – 152, Zagreb.

K r u ž i ć, T., 1991: Simuliranje sadašnje i buduće distribucije prsnih promjera. Šumarski list 65 (1 – 2): 55 – 62, Zagreb.

L e e, J. S., & C. T. C h a n, 1988: Studies on the simulation model for the growth of individual trees of a young Taiwan red cypress plantation in the Ta-Hsueh-Shan area. Quarterly Journal of Chinese Forestry 21 (2): 25 – 44.

L e e m a n s, R., 1992: Simulation and future projection of succession in a Swedish broadleaved forest. For. Ecol. Manage. 48: 305-319.

L e e m a n s, R., & I. C. P r e n t i c e, 1987: Description and simulation of tree layer composit. and size distribution in primaeval Picea-Pinus forst. Vegetatio 69:147 – 156.

L o h, D. K. Y. -T. C h u, H. H o l t f r e r i c h & Y. K. C h o o, 1991: Integrated resource management automation. U: Current advances in the use of computers in forest research; Workshop of the IUFRO Working Party S4. 11 – 03, Joensuu, Finland, February 14, 1991, Saarenmaa H. (Ed.): 69 – 77.

M c M u r t r i e, R. E., 1991: Relationship of forest productivity to nutrient and carbon supplay – a modelling analysis. Tree Physiology 9: 89 – 99.

M c M u r t r i e, R. E., & J. Landsberg, 1991: BIOMASS – a mechanistic model of the growth of tree stands. ASIT Newsletter 3 (3): 33 – 35.

M c M u r t r i e, R. E., D. A. R o o k & F. M. K e l l i h e r, 1990: Modelling the yield of Pinus radiata on a site limited by water and nitrogen. For. Ecol. Manage. 30: 381 – 413.

M e d e m a, E. L., & G. W. L y o n, 1985: The Determination of Fancial Rotation Ages for Coppicing Tree Species. Forest Sci. 2: 398 – 404.

M e š t r o v i ć, Š., 1978: Pravilnik o izradi šumsko-privrednih osnova, osnova gospodarenja i programa za unapređenje šuma u svijetlu šumarske znanosti. Šumarski list 102 (8 – 10): 352 – 364.

Meštrović, Š., 1980: Utjecaj borovih kultura na čistoću zraka u kliško-solinskom bazenu. Glas. šum. pokuse 20: 231 – 293.

Mitchell, K. J., H. Oswald & J. -M. Ottorini, 1983: Modelling the Growth of Douglas Fir in France. Forest Growth Modelling and Simulation: 25 – 40, Wien.

Miletić, Ž., 1922: Ideja potrajnosti u nauci o uređivanju šuma. Šumarski list 46 (1 – 12): 84 – 392.

Mohren, G. M. J., 1987: Simulation of forest growth, applied to Douglas fir stands in the Netherlands. Thesis, Agricult. Univers., Wageningen, Netherlands (1987), 184 pp.

Mohren, G. M. J., C. P. van Gerwen & C. J. T. Spiters, 1984: Simulation of primary production in even-aged stands of Douglas fir. For. Ecol. Manage. 9: 27 – 49.

Munitić, A., 1990: Kompjuterska simulacija uz pomoć sistemske dinamike. Brodosplit, Kultura, Split.

Munitić, A., & N. Račić, 1992: Sustav dinamičko kompjutersko simulacijsko modeliranje brdskih elektroenergetskih sustava. Zbornik radova 37. međunarodnog godišnjeg skupa KoREMA 92, Hrvatsko društvo za komunikacije, računarstvo, elektroniku, mjerenje i automatizaciju, Zagreb.

Munitić, A., 1992: Sustav dinamička kontinuirana kompjuterska simulacija. Zbornik radova 37. međunarodnog godišnjeg skupa KoREMA 92, Hrvatsko društvo za komunikacije, računarstvo, elektroniku, mjerenje i automatizaciju, Zagreb.

Oliveira, A. J., & L. Conto, 1986: Simulation and economic comparison of regeneration, density increase and interplanting in eucalypt stands, using the MANFLOR System-a case study. Instituto de Pasquisas e Estudos Florestais 34: 63 – 67.

Pearce, D., A. Markandya & E. B. Barbier, 1989: Blueprint for a green economy. Earthscan Publications, London.

Pranjić, A., V. Hitrec & N. Lukić, 1988: Praćenje razvoja sastojina hrasta lužnjaka tehnikom simuliranja. Glas. šum. pokuse 24: 133 – 149, Zagreb.

Prentice, I. C., M. T. Sykes, & W. Cramer, 1991: The possbile dynamic response of northern forests to global warming. Global Ecology and Biogeography Letters 1: 129 – 135.

Riebeling, R., & H. J. Weimann, 1984: Simulation of long-term development and yield performance of beech in the Scheleder Wald. Forst-und Holzwirt 39 (14 – 15): 354 – 361.

Rudis, V. A., J. H. Gramann, E. J. Ruddel & J. M. Westphall, 1988: Forest Inventory and Management-Based Visual Preference Models of Southern Pine Stands. Forest Science. 4: 846 – 863.

Schafer, H., H. Krieger & H. Bossel, 1990: The modelling of air pollution effects on plants, particulary on forest growth. U: Acid deposition in Europe: environmental effects, control strategies and policy options, Chadowich, M.J., & M. Hutton (Eds.). Stocholm Environmental Institute: 31 – 79.

Sievanen, R., P. Hari, P. J. Orava & P. Pelkonen, 1988: A model for the effect of photosynthate allocation and soil nitrogen on plant growth. Ecol. Modelling 41: 55 – 65.

Solomon, D. S., & W. B. Leah, 1986: Simulated yields for managed northern hardwood stands. USDA Forest Service, NE-578: 24.

Šegotić, K., 1993: Matematički model za upravljanje šumama. Glas. šum. pokuse, posebno izdanje 4: 315 – 320, Zagreb.

Trost, N., 1990: An approximate formula for the daily photoproduction of forest tree canopies. Ecol. Modelling 49: 297 – 309.

Ugrenović, A., 1922: Potrajnost šumskog gospodarenja. Šumarski list 46 (1 – 12): 149 159; 73 – 285.

J. Čavlović: Sustavna dinamika u planiranju gospodarenja regularnim šumama na području Uprave šuma Zagreb. Glas. šum. pokuse 33: 109–152, Zagreb, 1996.

JURO ČAVLOVIĆ

Original scientific paper

USING SYSTEM DYNAMICS IN EVEN-AGED FORESTS MANAGEMENT IN THE AREA OF THE ZAGREB FOREST DISTRICT

Summary

As time is one of the most important components in planning and managing forests, the goal of this research is to establish the best method of managing of even-aged forest with a view of achieving a sustainable production. This goal can be fulfilled by studying trends in forest resources within a longer period of time. A scientific research on the dynamics of even-aged forest system was conducted using system dynamics. The research was based on concrete data on the state of forest resources in the area of the Zagreb Forest District. In designing a continuous simulation model of a sustainable even-aged forest management, the latest insights into the field of system dynamics were used. Manifold simulations of four scenarios were conducted with an electronic computer. By applying the basic simulation model, the dynamics of forest resource trends were studied at all management levels (management unit, forest office, a part of forest district, the entire district) and management categories (management class). Defined management policies were used to design four scenarios, the aim being to select the most favourable policy. The research was done within the Pedunculate oak management class at four management levels. The results obtained from the established methodology of scientific research, the simulation model, the conducted simulations, and the evaluation of the simulation model validity, can be described as follows:

System dynamics in modelling can be used to represent different complex systems in the field of forestry, including the system of even-aged forest managed with the age class distribution method. The time needed to achieve equalization of age class areas depends mostly on the initial structure and relation of age class areas within the observed real forest. The time needed to achieve equalization of age class areas ranges between 90 years (the entire Zagreb Forest District, the Jasenovac Forest Office) and over 200 years (the Lipovljani Forest Office, Management Unit Šiljakovačka Dubrava). A regular age-class distribution ensuring yield sustainability can be obtained equally fast both at the levels of management unit, forest office, partial forest district, and the entire forest district. A change in rotation age within the simulated scenarios in the observed of even-aged Pedunculate oak forest influences the length of time needed to achieve a regular age class distribution. The policy of even-aged forest management, defined by the intensity at which seed fellings are done (a method of computing the surface allowable cut of the principal yield) and the rotation age, provides a very important external factor affecting fu-

ture trends (trends in age class distribution, allowable cuts and growing stock) of a closed even-aged forest management system. The best future method of managing the studied Pedunculate oak forests of irregular age structure is the one in which seed fellings depend on the area of stands older than one half of rotation age, and the forests are managed with a rotation lasting between 140 and 180 years. In this way a stable system with a sustainable production of all forest benefits will be achieved. By using the system of dynamic modelling, it is possible to build into the simulation model the future predictable undesirable changes affecting the management of forest resources in a certain area. This kind of trend in the system dynamics resulting from a simulated scenario offers a possibility for long-term planning of physical, economic and financial elements. The natural systems in question are governed by highly complex cause-consequence relations in time and space; therefore, the dynamic system modelling provides a strong support to planning and deciding in forest management. Consequently, the applied methodology, coupled with the use of the GIS technology, is recommended in concrete practice. In this way, a sound basis will be made for drawing up of both short-term and long-term management plans of a certain area at several management levels. Spatial and time planning in managing forest resources will be raised to a more qualitative level.

Author's address:
Juro Čavlović
Faculty of Forestry
HR – 10 000 Zagreb
P. O. Box 178