

PRECIZNOST PROCJENE STRUKTURNIH ELEMENATA BUKOVO-JELOVE SASTOJINE OVISNO O VELIČINI KRUŽNIH PRIMJERNIH PLOHA

PRECISION OF STRUCTURE ELEMENTS' ESTIMATION IN A BEECH – FIR STAND DEPENDING ON CIRCULAR SAMPLE PLOT SIZE

Mislav VEDRIŠ*, Anamarija JAZBEC*, Marko FRNTIĆ**,
Mario BOŽIĆ*, Ernest GORŠIĆ*

SAŽETAK: Osnovni elementi strukture sastojine (broj stabala, temeljnica i volumen) procjenjuju se na temelju uzorka primjernih ploha. Cilj ovog istraživanja je usporediti rezultate procjene strukturnih elemenata sastojine dobivene na primjernim plohama različite veličine, te posredno ocijeniti učinkovitost izmjere glede veličine ploha. Mjerenja su provedena u bukovo-jelovoj sastojini Nastavno-pokusnoga šumskog objekta "Zalesina" na području prebornih šuma Gorskoga kotara u Hrvatskoj. Na sistematskom uzorku 17 koncentričnih kružnih primjernih ploha izmjereni su prsni promjeri stabala te njihov položaj (azimut i udaljenost) u odnosu na središte plohe. Pri tome su stabla iznad 10 cm promjera mjerena na krugovima radijusa 13 m, stabla iznad 30 cm promjera na krugovima radijusa 19 m, te samo stabla deblja od 50 cm na krugovima radijusa 26 m. Načinjen je računalni program za izračun strukturnih elemenata sastojine te njihovu simulaciju i obračun po plohama radijusa različitih od onih izmjerenih. Uspoređeno je osam veličina kružnih ploha – osim mjerenih ploha (radijusi 13, 19 i 26 m) uzete su plohe radijusa korištenih u uređajnoj inventuri (7,98 m; 12,62 m; 5 i 12 m), nacionalnoj inventuri (7, 13 i 20 m) i nekoliko pokusnih veličina krugova (9,77 m; 11,28 m te 7 i 13 m). Na svim stajalištima su za svaku veličinu plohe izračunate prosječne vrijednosti broja stabala, temeljnica i volumena po hektaru. Razlike u procjeni strukturnih elemenata na razini sastojine između ploha različitih veličina nisu statistički značajne, uz razinu značajnosti 0,05. Za rezultate procjene izračunata je preciznost procjene uz 95 % pouzdanosti koja izravno ovisi o odabranoj veličini ploha. Bolja preciznost procjene strukturnih elemenata dobivena je na većim plohama, gdje je zbog većeg broja uključenih stabala dobivena manja prostorna varijabilnost. Primjenom koncentričnih krugova posebice je kod procjene broja stabala zbog manje mjerenih stabala povećana varijabilnost i pogreška uzorka. Preciznost procjene temeljnica i volumena na koncentričnim krugovima nije znatno pogoršana, što upućuje na opravdanost njihove primjene zbog moguće uštede pri izmjeri. Dobiveni rezultati omogućuju odabir željene veličine ploha uzorka na temelju omjera broja mjerenih stabala na plohama i kakvoće (preciznosti) procjene strukturnih elemenata. Prije praktične primjene potrebno je

* Mislav Vedriš, dipl. ing. šum., mvedris@sumfak.hr;
izv. prof. dr. sc. Anamarija Jazbec, jazbec@sumfak.hr;
doc. dr. sc. Mario Božić, bozic@sumfak.hr;
Ernest Goršić, dipl. ing. šum., egorsic@sumfak.hr;
Šumarski fakultet Sveučilišta u Zagrebu, Svetošimunska 25,
Zagreb

** Marko Frntić, dipl. ing. šum., marko.frntic@hrsume.hr;
"Hrvatske šume" d.o.o., Lj. F. Vukotinovića 2, Zagreb

istraživanje provesti na većem uzorku ploha u više sastojina različitog prostornog rasporeda stabala te analizirati razdiobe broja stabala, temeljnica i volumena po debljinskim razredima. Mjerenje vremena potrebnog za izmjeru ploha omogućilo bi točniji izračun učinkovitost izmjere na plohama različite veličine.

Ključne riječi: izmjera šuma, kružne primjerne plohe, broj stabala, temeljnica, volumen, procjena, preciznost, računalni model CirCon

UVOD – Introduction

Izmjera ili inventura šuma temeljna je pretpostavka za planiranje potrajnoga gospodarenja šumama (Pranjčić i Lukić 1997). Budući da najčešće nije moguće izmjeriti sva stabla, redoviti način dobivanja podataka o stanju sastojine je pomoću uzorka primjernih ploha. Vrlo je važno odabrati dobar (reprezentativan) uzorak, što osim prostornog rasporeda uključuje odabir oblika i veličine primjernih ploha. Tako dobiveni podaci na temelju uzorka procjena su stvarnih veličina. Bliskost procijenjene i stvarne veličine (točnost) gotovo je nemoguće odrediti, jer su u nju uključeni mnogi izvori pogrešaka. Kvaliteta uzorka procjenjuje se na temelju pogreške uzorka, odnosno preciznosti. Osim pogreške uzorka na kvalitetu procjene utječu i pogreške mjerenja, pogreške izračuna površina sastojina, metodske pogreške obračuna volumena (korištene volumne tablice) i druge. Osnovni strukturni elementi sastojine su broj stabala, temeljnica i volumen (drvena zaliha). Na preciznost procjene ovih elemenata izravno utječu njihova varijabilnost u sastojini te veličina uzorka (broj ploha). Pritom je procjena srednjih vrijednosti i varijabilnosti ovisna o veličini i obliku ploha (Schreuder i dr. 1993, Koprivica 2006), te njihovom rasporedu. Budući da je sastojina osnovna jedinica gospodarenja, vrlo je korisno

znati koja je preciznost i pouzdanost procjene osnovnih elemenata strukture sastojine dobivena izmjerom na terenu. Ovaj rad dio je istraživanja preciznosti procjene strukturnih elemenata i potrebne veličine uzorka u području prebornih šuma. Cilj rada je usporediti procijenjene vrijednosti strukture sastojine (po hektaru) dobivene na plohama različite veličine, a također i pritom postignutu preciznost. U Hrvatskoj je do sada napravljeno nekoliko istraživanja i usporedbi različitih metoda terenske izmjere na području jednodobnih regularnih šuma (Lukić 1984, Galić 2002, Indir 2004). Zbog veće prostorne i strukturne varijabilnosti te mogućih posebnosti ovo istraživanje napravljeno je u području bukovo-jelovih prebornih šuma kao uvod u opsežniji projekt iznalaženja optimalnog uzorka za inventuru na tom području. Istraživanje se odvija usporedno s promjenama sustava uređajne izmjere državnih šuma u Hrvatskoj (Pravilnik o uređivanju šuma, NN 111/06, 141/08), te započetim projektom Nacionalne inventure šuma (Čavlović i Božić 2008). Budući da je planiranje uzorka posao koji može poskupiti ili pojeftiniti postupak terenske izmjere, ispitivanje potrebne veličine uzorka za postizanje željenog cilja s obzirom na željenu kvalitetu rezultata uvijek je aktualno i korisno.

MATERIJAL I METODE – Material and methods

Za istraživanje je odabrano dinarsko područje prebornih šuma u Gorskome kotaru u sjeverozapadnoj Hrvatskoj. Terenska izmjera provedena je u raznodobnoj mješovitoj bukovo-jelovoj sastojini visokog uzgojnog oblika, površine 20,63 ha u Gospodarskoj jedinici "Belevine" Nastavno pokusno šumskoga objekta "Zalesina". Sastojina se proteže na nadmorskoj visini od 790 do 850 m, južne do istočne ekspozicije, nagiba terena 5 – 10°, pripada uređajnom razredu raznodobne sjemenjače jele na drugome bonitetu.

Zbog jednostavnosti i praktičnosti, te raširene upotrebe u inventuri šuma (Johnson 2000, Iles 2003), odabran je sistematski uzorak primjernih ploha. Na zemljovidu je položena kvadratna mreža s duljinama stranica 100 m. Na sjecištima mreže u sastojini postavljeno je 17 kružnih ploha, kao praktičan i često korišten oblik ploha u inventuri šuma (Schreuder i dr. 2004). Usporedbom s primjenjivanim veličinama ploha u inventuri šuma u Hrvatskoj (uređajna izmjera, Nacionalna inventura šuma) odabrana su tri koncentrična kruga

radijusa 13, 19 i 26 metara. Položaj središta ploha na terenu određen je busolom i daljinomjerom. Na svakoj plohi mjereni su prsni promjeri stabala (1,30 m iznad tla) na milimetar precizno, njihova udaljenost od središta, nagib i azimut. Pri izmjeri pokusnih ploha primijenjena je taksacijska granica od 10 cm, uobičajena u hrvatskoj šumarskoj praksi (članak 19. Pravilnika o uređivanju šuma, NN 111/06). Promjeri stabala mjereni su na koncentričnim krugovima različitih radijusa, ovisno o dimenzijama stabala: na krugu radijusa 13 m mjerena su sva stabla iznad taksacijske granice, na krugu radijusa 19 m mjerena su stabala od 30 cm i deblja, a na krugu radijusa 26 m stabla promjera od 50 cm na više (K13-19-26). Odabrane veličine krugova za izmjeru veće su od pretpostavljeno potrebnih, sa svrhom simulacije krugova različitih radijusa te mogućnosti simulacije pomaka položaja krugova.

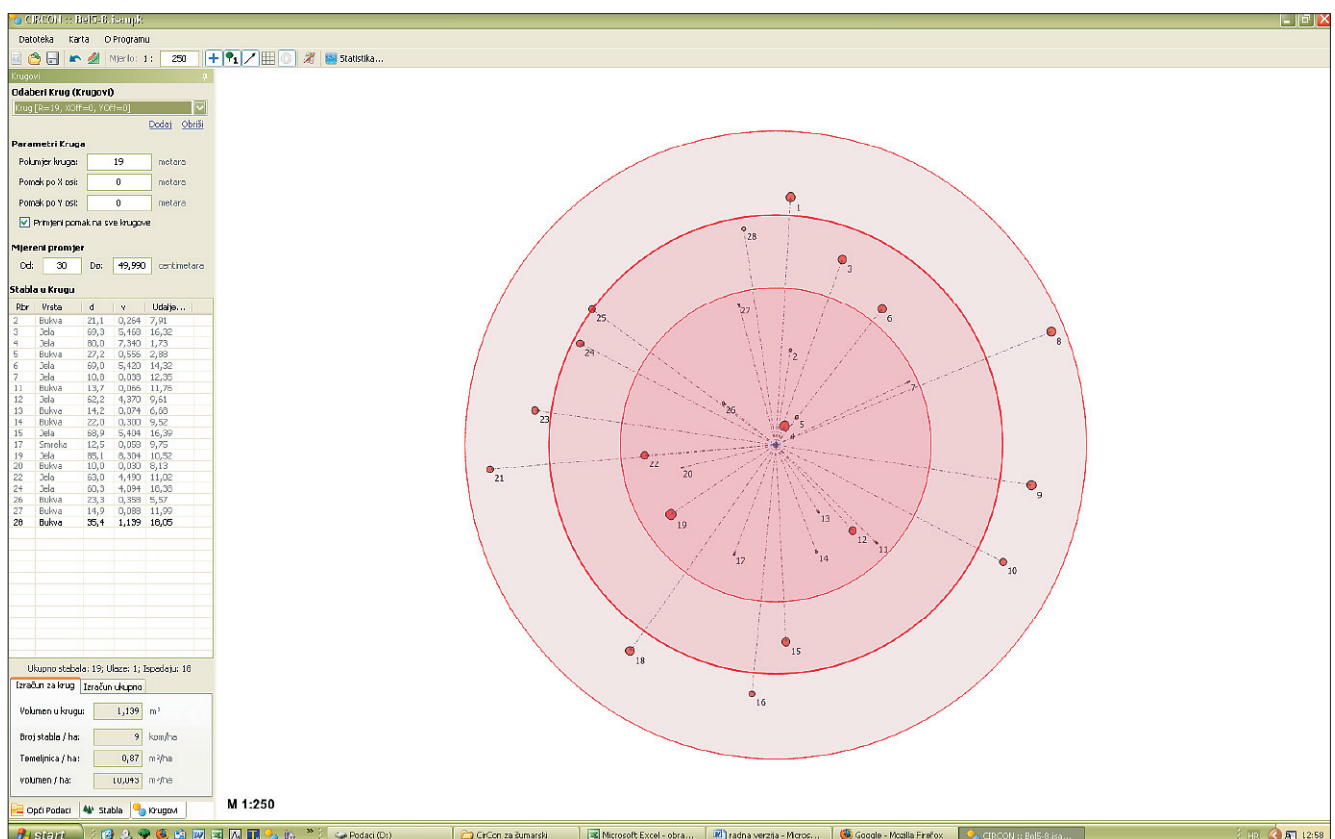
Za izmjeru su korišteni instrumenti: promjerka Haglof s milimetarskom podjelom, busola Suunto sa stalnikom, ultrazvučni daljinomjer Vertex III i mjerna vrpca

(za mjerenje opsega stablima prsnog promjera većeg od 80 cm). Rad na terenu izvodila su dva do tri radnika, od kojih je jedan mjerio prsne promjere, drugi sa središta određivao azimut i udaljenost stabala, te (treći) bilježio podatke.

Budući da je cilj usporediti procjene strukturnih elemenata za različite veličine ploha, u tu svrhu su zanezamani postojeći izvori pogrešaka, tj. pogreške pri izmjeri, pogreške određivanja površine sastojina, pogreške odabira tarife i obračuna volumena. Volumen je obračunavan po interpoliranim Šurićevim jednoulaznim volumnim tablicama za jelu i bukvu (Pranjić 1966) koje su propisane po važećem programu gospodarenja za Gospodarsku jedinicu "Belevine" (Čavlović i Božić 1999). Pritom je napravljena linearna interpolacija volumena za promjere izmjerene milimetarskom preciznošću.

Za obradu podataka osmišljen je i izrađen program *CirCon* koji služi za obračun podataka na razini plohe i sastojine, te se njime mogu simulirati željeni položaji i veličine ploha u odnosu na stvarno izmjereno stanje. Osnovna jedinica obračuna je stablo na pojedinoj plo-

hi. Iz baze su prebačeni podaci svih mjerenih stabala na plohi (prsni promjer, azimut i horizontalna udaljenost od središta). Za tako unesena stabla izračunata je temeljnica i volumen iz volumne tablice, ovisno o vrsti i bonitetu. Iz podataka o stablima i površine plohe izračunati su broj stabala, temeljnica i volumen po hektaru za svaku plohu, ovisno o veličini plohe koja je definirana promjerom stabla. Nakon unesenih i obračunatih stvarno mjerenih ploha pomoću *CirCon*-a izvedeni su broj stabala, temeljnica i volumen za plohe različitog (manjeg) radijusa od stvarno izmjerenih, na temelju udaljenosti pojedinog stabla i odabranog radijusa ploha. Budući da program obračunava automatski je li neko stablo unutar plohe ili nije, moguće je simulirati bilo koju veličinu plohe (manju od mjerene). Pritom je moguće zadati veći broj koncentričnih krugova različitih radijusa i graničnih vrijednosti promjera stabala koja se obračunavaju na plohi. Vizualno sučelje *CirCon*-a daje tlocrt ploha s položajem stabala u željenom mjerilu (slika 1), što ga čini preglednim i pogodnim za proučavanje prostornog rasporeda stabala.



Slika 1. Raspored stabala na plohi u sučelju programa *CirCon*

Figure 1. Tree distribution on a plot displayed in *CirCon* interface

Za usporedbu je simulirano više različitih veličina kružnih ploha. To su ponajprije često korištene kružne plohe radijusa 12,62 m s površinom 500 m² (K12,62), te dvostruki krug radijusa 5 m (površine 78,54 m²) za stabla 10 do 29,9 cm i radijusa 12 m (površine 452,39 m²)

za stabla od 30,0 cm na više (K5-12), koji su u vrijeme istraživanja (i donedavno) bili službeno u uporabi. Obračunati su i manji krugovi radijusa 7,98 m, površine 200 m² (K7,98), zatim radijusa 9,77 m, površine 300 m² (K9,77), te radijusa 11,28 m, površine 400 m² (K11,28).

Za usporedbu su odabrani i dvostruki koncentrični krugovi radijusa 7 i 13 m (K7-13) s jednakim rasponima izmjere promjera (manji krug za promjere 10-29,9 cm, a veći krug za promjere 30,0 i više centimetara) te koncentrični krugovi radijusa 7, 13 i 20 metara (K7-13-20), kakvi se koriste u Nacionalnoj inventuri šuma (Čavlović i Božić 2008). Za svaku od metoda (veličina ploha) izračunati su statistički parametri strukturalnih ele-

menata (N, G, V): prosječna vrijednost po hektaru za svaku plohu i ukupno za cijelu sastojinu (\bar{X}), standardna devijacija (s) i 95 %-tni pouzdani interval. Množenjem standardne pogreške s pripadajućom vrijednosti varijable t -distribucije za željenu pouzdanost dobivena je pogreška uzorka u apsolutnom iznosu. Dijeljenjem pogreške uzorka s aritmetičkom sredinom dobivena je preciznost iskazana kao relativna pogreška uzorka (P).

$95\%PI \dots\dots \bar{X} \pm t \cdot \frac{s}{\sqrt{n}}$	95 % PI	95 % pouzdani interval 95 % confidence interval;
\bar{X}	\bar{X}	prosječni iznos elementa strukture sastojine (N,G,V) po hektaru Average stand structure element (N, G, V) per hectare;
$P \dots\dots\dots \frac{t \cdot \frac{s}{\sqrt{n}}}{\bar{X}}$	t	granična vrijednost za rubnih 2,5 % površine ispod t distribucije uz $n-1$ stupnjeva slobode critical value for upper 2,5 % of area under t distribution with $n-1$ degrees of freedom;
	s	standardna devijacija dobivena iz uzorka standard deviation based on sample;
	n	veličina uzorka (broj ploha) sample size (number of plots);
	P	preciznost iskazana kao relativna pogreška uzorka precision (relative sample error).

Za postupak obračuna statističkih parametara iz uzorka (aritmetička sredina, standardna devijacija, standardna pogreška, pogreška uzorka) korištene su pretpostavke i jednadžbe za slučajni uzorak koje se smatraju prihvatljivim i kod sistematskog uzorka (Pranjić i Lukić 1997). Budući da su simulacijom dobiveni rezultati povezani, jer se radi o istim središtima (djelomično i o istim stablima), ne mogu se smatrati nezavisnim uzorcima. Zbog toga smo za uspoređivanje prosječnih vrijednosti strukturalnih elemenata sastojine po hektaru između različitih metoda (veličina krugova) koristili analizu varijance ponovljenih mjerenja uz razinu značajnosti 0,05 (Sokal i Rohlf 1995). Statistička analiza i grafički prikazi napravljeni su u statističkom paketu Statistica 7.1. (Statsoft 2006) i Microsoft Excel 2003.

Rezultati procjena po različitim veličinama ploha uspoređivani su međusobno, bez da su poznate stvarne vri-

jednosti broja stabala, temeljnice i volumena. To bi bilo moguće samo u slučaju da su izmjerena sva stabla. No, ni takva izmjera ne može se uzeti kao apsolutno mjerilo, jer uključuje moguće pogreške pri izmjeri (Lukić 1984, Pranjić 1987). Kao referentna vrijednost uzeta je procjena na temelju najvećih ploha (K13-19-26) koje zbog površine predstavljaju veći dio sastojine, a time vjerojatno i procjenu bližu stvarnim vrijednostima.

Osim procjene strukturalnih elemenata, a radi uvida u učinkovitost izmjere na plohama odabranih veličina, izračunat je prosječan broj mjerljivih stabala po jednoj plohi tako da su za svaku metodu zbrojena sva stabla koja su obračunata na svim plohama i zbroj podijeljen s brojem ploha. Za usporedbu broja stabala po plohi između metoda također je zbog gore navedenih razloga primijenjena analiza varijance ponovljenih mjerenja (Sokal i Rohlf 1995).

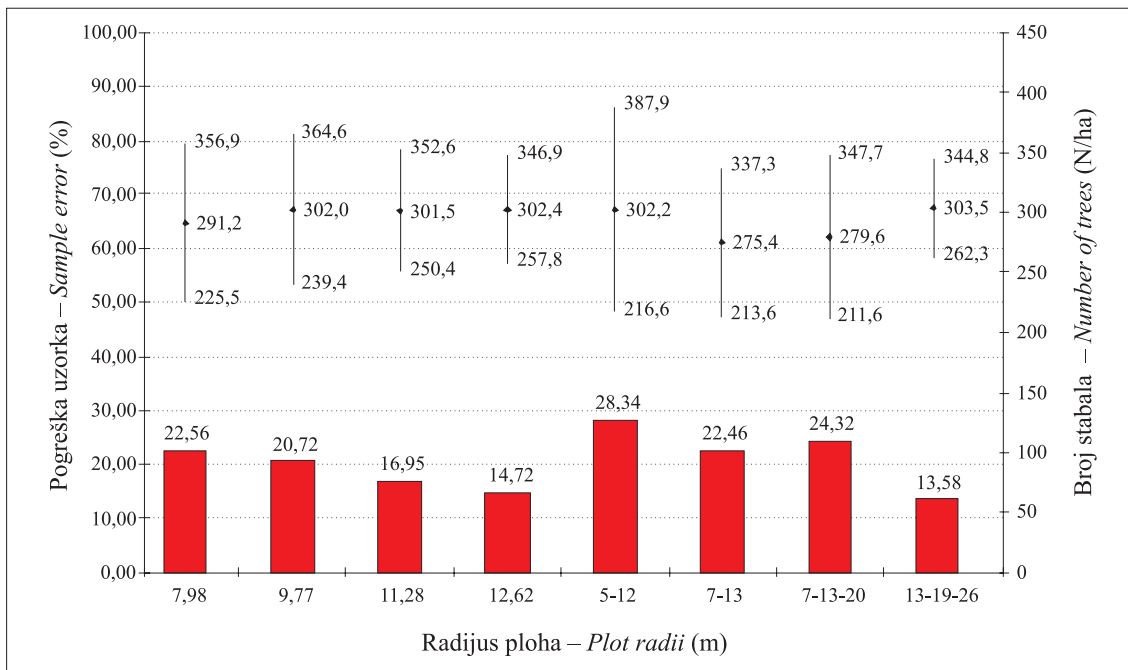
REZULTATI – Results

Broj stabala – Number of trees (N)

Rezultati procjene broja stabala sastojine na temelju mjerenih ploha te simuliranih jednostrukih i koncentričnih kružnih ploha prikazani su na slici 2, gdje je osim prosjeka prikazan interval za 95 % pouzdanosti te relativna pogreška uzorka (preciznost) za sve navedene metode.

Procjena broja stabala u sastojini kreće se ovisno o veličini ploha u rasponu od 275,4 do 303,5 komada po hektaru, s time da razlike nisu statistički značajne (ANOVA s ponovljenim mjerenjima: $F = 0,6027$, $df = 7$, $p = 0,7526$). Vidljivo je poboljšanje preciznosti (sma-

njenje pogreške uzorka) povećanjem ploha. Primjenom koncentričnih krugova preciznost je lošija – najlošija preciznost (28,34 %) dobivena je na plohama K5-12. Na većim koncentričnim krugovima (K7-13) preciznost je bolja, a uvođenjem trećega koncentričnog kruga (K7-13-20) opet je pogoršana zbog povećane varijabilnosti. Najveće plohe (K13-19-26) polučile su najprecizniju procjenu broja stabala (13,58 %), što je ipak zanemarivo poboljšanje u usporedbi sa 14,72 % dobivenim jednostrukim krugovima radijusa 12,62 m.




Slika 2. Prosjezni broj stabala po hektaru i pogreška uzorka ovisno o veličini ploha. Točke su procjene broja stabala, a okomite linije predstavljaju 95 % pouzdane intervale procjene. Stupci prikazuju relativnu pogrešku uzorka u postocima

Figure 2 Average number of trees per hectare and sample error by different plot sizes. Dots are average number of trees and vertical lines stand for 95 % confidence intervals. Bars denote relative sample error in percent

Temeljnica – Basal area (G)

Rezultati procjene temeljnice sastojine za različite veličine ploha prikazani su na slici 3. Prosječne vrijednosti kreću se od 34,80 do 37,76 m² po hektaru. Anali-

zom varijance ponovljenih mjerenja razlike se nisu pokazale statistički značajnima ($F = 0,2948$, $df = 7$, $p = 0,9547$). Preciznost procjene poboljšava se povećava-



Slika 3. Prosječna temeljnica sastojine po hektaru i pogreška uzorka ovisno o veličini ploha. Točke su procjene temeljnice sastojine, a okomite linije predstavljaju 95 % pouzdane intervale procjene. Stupci prikazuju relativnu pogrešku uzorka u postocima

Figure 3 Average stand basal area per hectare and sample error by different plot sizes. Dots are average basal area estimates and vertical lines stand for 95 % confidence intervals. Bars denote relative sample error in percent

njem ploha (K7,98 do K12,62). Primjenom koncentričnih krugova (K5-12) preciznost temeljnica je neznatno lošija (17,69 %), a povećanje radijusa (K7-13) nije znatno doprinijelo poboljšanju procjene (17,14 %). Uvo-

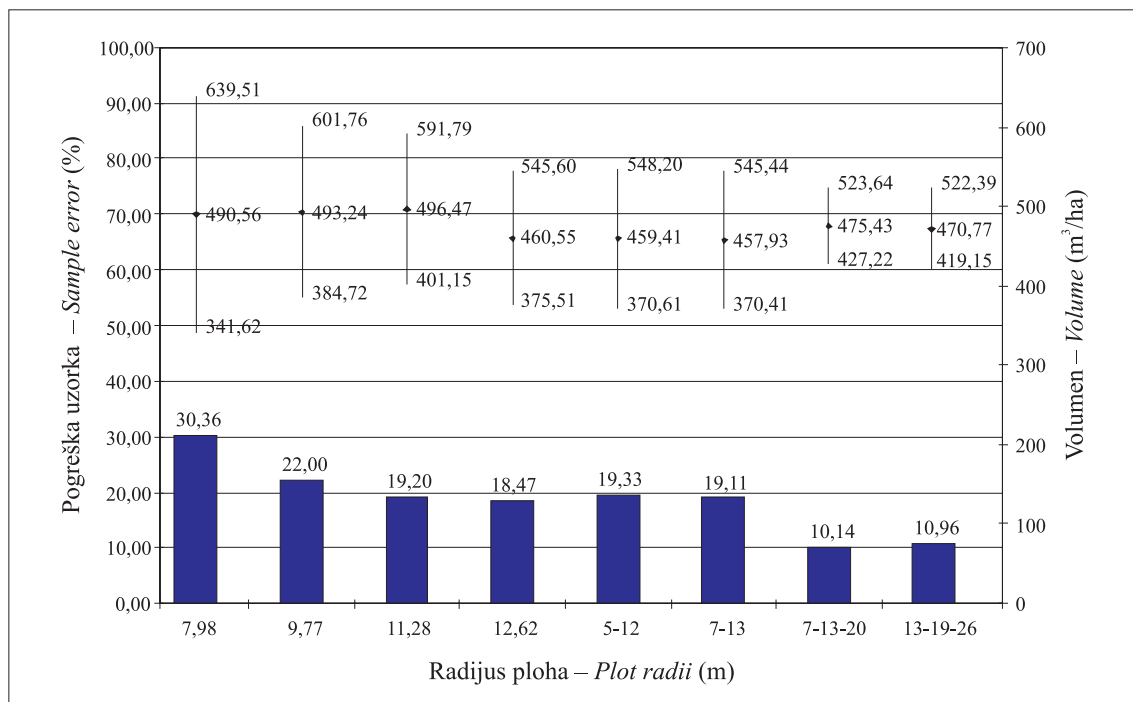
Drvena zaliha – Stand volume (V)

Rezultati procjene volumena sastojine (m^3/ha) za uspoređivane veličine ploha prikazani su na slici 4.

Različitim veličinama ploha dobiveni su različiti iznosi volumena na pojedinim plohama i ukupno za sa-

đenje trećega koncentričnog kruga (K7-13-20) bitno je smanjilo pogrešku uzorka (10,56 %), dok je povećanje trostrukoga kruga (K13-19-26) tek neznatno smanjilo pogrešku uzorka (10,13 %).

stojinu. Procjene volumena sastojine kreću se u rasponu od 457,93 do 496,47 m^3 po hektaru. Na temelju analize varijance ponovljenih mjerenja razlika prosječnih vrijednosti nije statistički značajna ($F = 0,2650$,



Slika 4. Prosječni volumen sastojine po hektaru i pogreška uzorka ovisno o veličini ploha. Točke su procjene volumena sastojine, a okomite linije predstavljaju 95 % pouzdane intervale procjene. Stupci prikazuju relativnu pogrešku uzorka u postocima

Figure 4 Average stand volume per hectare and sample error by different plot sizes. Dots are average volume estimates and vertical lines stand for 95 % confidence intervals. Bars denote relative sample error in percent

$df = 7, p = 0,9661$). Iz slike 2 vidljive su razlike u intervalima pouzdanosti procjene i preciznosti. Tako je metoda najmanjih ploha (K7,98) polučila najlošiju preciznost (30,36 %), a najbolja je postignuta na koncentričnim

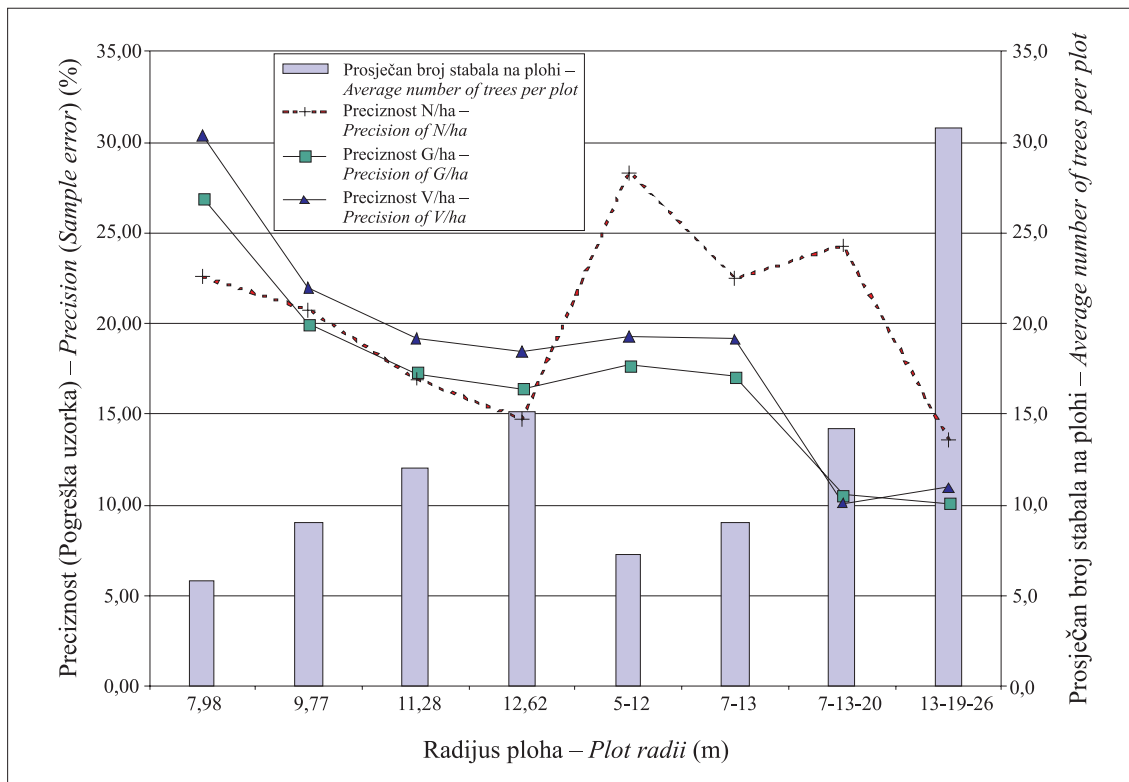
krugovima radijusa 7, 13 i 20 m (K7-13-20). Zanimljivo da na najvećim (mjeranim) plohama (K13-19-26) nije poboljšana preciznost procjene u odnosu na K7-13-20.

Broj stabala po plohi – Number of trees per plot

Za usporedbu učinkovitosti izmjere na plohama različitih veličina potrebno je znati vrijeme izmjere na plohi. Budući da za simulirane veličine ploha nije moguće odrediti vrijeme izmjere, izračunali smo prosječan broj stabala po jednoj primjernoj plohi, koji na neki način određuje utrošak vremena za izmjeru ploha pojedine veličine. Razlike prosječnih vrijednosti pokazale su se statistički značajnima na razini 0,05 (ANOVA s ponovljenim mjerenjima: $F = 187,621, df = 7, p = 0,0000$) za gotovo sve metode, osim između K7,98 i K5-12; K7-13 i K9,77 te K7-13-20 i K12,62 (Fisherov LSD *post-hoc* test). Na slici 5 prikazan je prosječan

broj stabala po jednoj plohi za svaku metodu, te pripadajuće preciznosti procjene strukturnih elemenata u svrhu usporedbe polučene preciznosti procjene obzirom na broj stabala po plohi.

Povećanjem površine povećava se broj stabala i smanjuje pogreška uzorka za sve tri promatrane varijable. Uočljivo je smanjenje broja stabala po plohi uvođenjem koncentričnih krugova i pritom povećanje pogreške uzorka.



Slika 5. Prosječan broj stabala po plohi i preciznost procjene (pogreška uzorka) broja stabala, temeljnica i volumena sastojine po hektaru ovisno o veličini ploha.

Figure 5 Average number of trees per plot and precision of estimate (sample error) for number of trees, basal area and volume per hectare by different plot sizes

RASPRAVA – Discussion

U istraživanju smo usporedili utjecaj veličine ploha na preciznost procjene sastojinskih varijabli, pri čemu veličina uzorka nije obračunavana na temelju poznate varijabilnosti i željene preciznosti.

Valja napomenuti da je veličina uzorka (n) jednaka za sve uspoređene veličine ploha i strukturne elemente, što ima za posljedicu da su razlike u preciznosti (pogreška uzorka) ovisne isključivo o standardnoj devijaciji (prostornoj varijabilnosti između ploha), jer su n i t u obračunu jednaki za sve veličine ploha. Također raspored ploha je jednak za sve metode, što je povoljno za usporedbu samih veličina ploha jer nema razlika u položaju i broju ploha.

Rezultati analize varijance su kao i kod sličnih istraživanja u jednodobnim sastojinama (Lukić 1984, Galić 2002) pokazali da dobivene razlike procjene strukturnih elemenata po veličinama ploha nisu statistički značajne na 95 % razini pouzdanosti. Dakle procjena niti po jednoj od metoda ne odstupa mnogo od ostalih, što je razumljivo jer se radi o istoj sastojini, gdje su prosječne vrijednosti dobivene iz svakog dobrog uzorka više ili manje blizu stvarnoj srednjoj vrijednosti. Iako se ne može tvrditi koja od veličina ploha daje “točne” rezultate, usporedba je učinjena ponajprije sa stajališta preciznosti. Osim toga u praksi se rijetko radi totalna klupaža većih

površina, te se uvijek radi o boljoj ili lošijoj procjeni stvarnih vrijednosti, koje ostaju teoretski nepoznate.

Razlike u preciznosti općenito ovise o varijabilnosti pojedine varijable (broj stabala, temeljnica, volumen). Pri tome se na većim plohama redovito dobivaju preciznije procjene, jer one obuhvaćaju više stabala te imaju ukupnu manju varijabilnost (Schreuder et al. 1993, Iles 2003), što je potvrđeno i ovim istraživanjem.

Kod manjih jednostrukih krugova (K7,98, K9,77 i K11,28) primjetne su veće prosječne vrijednosti temeljnica i volumena, što može upućivati da u ovakvim sastojinskim prilikama te veličine ploha daju nešto veće procjene, ali za takvu tvrdnju trebalo bi provjeriti veći uzorak ploha i sastojina.

Kod koncentričnih krugova odabranim rasponom izmjere prsnih promjera na određenom radijusu kruga smanjuje se broj mjerenih stabala na plohi. Time se redovito povećava varijabilnost između ploha pa se povećava i pogreška uzorka, što se najbolje vidi na slici 5 (metode K12,62 i K5-12). Dakako, svrha koncentričnih kružnih ploha upravo jest smanjiti broj mjerenih stabala na plohi, kako bi se smanjilo vrijeme izmjere. S druge strane, broj stabala redovito nije ciljani varijabla za koju je uzorak postavljen. Najčešće je to volumen kao mjera drvene zalihe na kojoj se temelji gospodare-

nje, pa je najzanimljivija usporedba metoda upravo po preciznosti procjene volumena.

Osim toga volumen je veličina čija je preciznost procjene bila zakonski propisana za uređajni razred (Pravilnik o uređivanju šuma, NN 111/06), pa smo stoga i pokušali ispitati razlike u procjeni volumena sastojine na temelju različitih veličina ploha. Međutim rezultati procjene volumena u sebi osim pogreške uzorka uključuju niz drugih pogrešaka (pogreške odabira tablica i obračuna volumena). Prema Pranjić (1987) temeljnica je bolji pokazatelj preciznosti inventure, jer u sebi ne sadrži pogrešku obračuna volumena. Na temelju ovih rezultata preciznost procjene temeljnice je nešto bolja od preciznosti volumena (prosječno oko 2 %), ali pokazuje jednaki trend promjene po metodama (slika 5). Nešto veća pogreška procjene volumena je posljedica povećane varijabilnosti zbog različitog volumena za iste promjere stabala ovisno o vrsti drveća.

Preciznost procjene temeljnice i volumena na koncentričnim krugovima nije toliko pod utjecajem manjeg broja mjerenih stabala. Zbog povećanog udjela debljih stabala na plohi kod koncentričnih krugova ne dolazi do znatnog povećanja varijabilnosti temeljnice i volumena smanjenjem broja stabala na plohi, pa se pogreška uzorka neznatno povećava. Upravo je ta činjenica, uz razvoj mjernih instrumenata, i potaknula primjenu koncentričnih krugova u izmjeri šuma.

Za usporedbu navodimo da su Čavlović i dr. (2001) u sličnim sastojinskim uvjetima iste gospodarske jedinice dobili koeficijent varijacije volumena 27,75 % i relativnu pogrešku uzorka (preciznost) 10,87 %. U tom slučaju uzorak je bio veći (25 ploha površine po 900 m²), a oblik ploha je bio kvadratičan. Za usporedbu mogu se uzeti rezultati iz naših mjerenih triju koncentričnih krugova (K13-19-26). Izmjeren je podjednak prosječan broj stabala na plohi: 31 u našem slučaju i 33 kod Čavlovića i dr. (2001). Postignuta preciznost procjene volumena je podjednaka za obje sastojine (relativna pogreška uzorka 10,87 % i 10,96 %) s time da je u našem slučaju dobiven manji koeficijent varijacije (21,33 %). Uzrok tomu je u samoj varijabilnosti volumena u sastojini, a djelomično se vjerojatno radi i o utjecaju vrste i oblika odabranih ploha za izmjeru.

Pravilnikom propisani intenzitet izmjere od najmanje 5 % za preborne sastojine u pravilnom rasporedu ploha s razmacima 100x100 m upućuje na korištenje ploha radijusa 12,62 m. Na takvim ploham postignuta je podjednaka preciznost (18,5 %) kao i koncentričnim krugovima radijusa 5 i 12 metara (19,3 %). Ako usporedimo te dvije veličine ploha, možemo reći da bi trebalo detaljno ispitati troškove vremena izmjere za postizanje jednake preciznosti.

Utrošak vremena za izmjeru ploha pojedine veličine aproksimirali smo brojem mjerenih stabala na ploha-

ma, što je prikazano na slici 5. Točna usporedba učinkovitosti – štedljivosti izmjere moguća je samo stvarnim mjerenjem vremena na ploham pojedine veličine, jer vrijeme izmjere ovisi još o veličini i vrsti plohe (jednostruki ili koncentrični krug) te rasporedu stabala. Plohe radijusa 5 i 12 prema omjeru broja mjerenih stabala i preciznosti procjene volumena predstavljaju najbolji odabir (slika 5). Kod koncentričnih krugova mjeri se manje stabala, ali je s druge strane zbog više rubnih stabala koja se moraju provjeravati, veća mogućnost pogreške i produljeno vrijeme izmjere. Upravo zato uporaba laserskih ili ultrazvučnih daljinomjera znatno ubrzava izmjeru na koncentričnim krugovima.

Gubitak preciznosti na manjim ploham (K11,28) je zanemariv u odnosu na K12,62 (oko 1 %) uz prosječno tri mjerena stabla manje po plohi. To upućuje na mogućnost smanjenja ploha bez znatnog gubitka preciznosti. No, budući da je promjenama Pravilnika o uređivanju šuma (NN 141/08) zadan isključivo intenzitet uzorka bez obzira na kakvoću procjene (preciznost), uz manje plohe bilo bi potrebno povećati broj ploha, što bi povećalo vrijeme izmjere.

Ako promatramo ukupne vrijednosti broja stabala, temeljnice i volumena, plohe radijusa 7 i 13 m nisu preporučljive jer povećavaju trošak izmjere (prosječno 9 stabala na plohi), a preciznost nije poboljšana u odnosu na K5-12. Ako bi promatrali distribucije po debljinskim razredima, vjerojatno bi postigli bolje rezultate nego K5-12 zbog većeg broja mjerenih stabala.

Plohe K7-13-20 ostvaruju veliko poboljšanje preciznosti (skoro 10 % u odnosu K7-13), ali uz bitno veći broj mjerenih stabala (14). Koncentrični krugovi s tri radijusa zasigurno povećavaju broj rubnih stabala, što pak produljuje izmjeru. Takvo poboljšanje preciznosti na razini sastojine nije opravdano s obzirom na utrošak vremena, tim više što preciznost na razini sastojine nije propisana. Naprotiv to poboljšanje preciznosti svakako dolazi do izražaja u inventuri malog intenziteta uzorka na velikome prostoru kao što je Nacionalna inventura šuma (Čavlović i Božić 2008).

Zanimljivo je primijetiti da plohe K7-13-20 prosječno sadrže podjednak broj stabala kao jednostruki krugovi K12,62 uz znatno precizniju procjenu temeljnice i volumena.

Mjerene plohe (K13-19-26) nisu poboljšale preciznost procjene volumena u odnosu na metodu K7-13-20, nego čak dale neznatno lošiju preciznost.

Na temelju “dovoljne” (ili propisane) preciznosti može se odabrati optimalnu veličinu ploha na kojoj su troškovi najmanji. Računanje preciznosti procjene sastojinskih elemenata daje mogućnost uštede u planu inventure, što je zanemareno promjenama Pravilnika o uređivanju šuma (NN 141/08). S druge strane propisani intenzitet uzorka (5 % površine sastojine) ne ograni-

čava primjenu ploha različite veličine, ali bi zahtijevao prilagodbu rasporeda (razmaka) ploha.

Dobiveni rezultati procjene strukturnih elemenata vrijede za ovu sastojinu i sastojine slične strukture, te su jedan prilog širem istraživanju optimalnog uzorka za

raznodobne sastojine. Za detaljniju usporedbu potrebno je uključiti i vrijeme izmjere.

Kao dodatni čimbenici pri odabiru veličine ploha mogli bi se koristiti omjer smjese i razdioba broja stabala po debljinskim stupnjevima/razredima.

ZAKLJUČCI – Conclusions

Poznata činjenica poboljšanja preciznosti procjene povećanjem primjernih ploha, potvrđena ovim istraživanjem, daje mogućnost prilagodbe veličine ploha za konkretne sastojinske uvjete ovisno o željenoj kakvoći rezultata (preciznosti) procjene.

Za procjenu broja stabala koncentrični krugovi nisu preporučljivi jer se njihovom primjenom pogreška uzorka povećava.

Za temeljnicu i volumen rezultati su upravo suprotni. Primjenjivane plohe radijusa 12,62 m u ovoj sastojini daju sličan rezultat kao koncentrični krugovi radijusa 5 i 12 m. Stoga koncentrične kružne plohe radijusa 5 i 12 metara koje su korištene u hrvatskoj uređajnoj inventuri, predstavljaju dobar odabir, jer manji prosječni broj mjerenih stabala na plohi skraćuje vrijeme izmjere. S druge strane dvostruki krug zahtijeva više provjera rubnih stabala, a time se povećava mogućnost pogrešnog bilježenja stabala. Zato je potrebno stručno i dobro uvježbano osoblje za izmjeru, jer u suprotnom pri provjeri rubnih stabala osim gubitka vremena može doći do velikih pogrešaka.

S obzirom na podjednak broj mjerenih stabala na plohi te na bolju preciznost procjene temeljnica i volumena u odnosu na plohe K12,62, čak bi i trostruki koncentrični krugovi K7-13-20 bili prihvatljivi odabir, ako je ukupni volumen ciljane varijabla.

Primjena koncentričnih ploha radijusa 13-19-26 m u praksi bi bila ekonomski neopravdana, jer povećanje vremena izmjere (veći broj stabala) na plohi ne rezultira boljom procjenom, a pritom je veća vjerojatnost

pogrešaka pri izmjeri (Indir 2004). Njihova svrha je bila ponajprije mogućnost simulacije manjih ploha te njihovo izmicanje u prostoru (što nije tema ovog rada).

Potvrđeni općeniti trend poboljšanja preciznosti povećanjem ploha valja matematički izraziti konkretnim podacima za određene sastojinske prilike. Konkretni brojevi odnosi povećanja troška izmjere na većim plohami i pritom postignuto poboljšanje preciznosti mogu poslužiti u razboritom odabiru veličina ploha.

U slučaju približno jednake postignute preciznosti uz jednak broj ploha ekonomičnije su manje plohe (zbog manje mjerenih stabala). Uzevši u obzir da će u manjim sastojinama s manjim brojem ploha pogreška uzorka biti i veća, za takve slučajeve treba ispitati druge mogućnosti za poboljšanje preciznosti (gušća mreža, specifični radijusi, metode daljinskih istraživanja). Cjeloviti plan uzorka treba uskladiti prema postojećim propisima koji uvjetuju intenzitet površine uzorka (Pravilnik o uređivanju šuma NN 141/08). Dakle u planiranju uzorka veličinu ploha treba uskladiti rasporedom, razmakom i brojem ploha u sastojini, što nije obuhvaćeno ovim istraživanjem.

Odabir veličine ploha koji ovisi o svrsi inventure morao bi se temeljiti na ocjeni troškova (vremena) izmjere i željene preciznosti procjene. Ovakvo istraživanje pruža uporište za takav odabir veličine ploha, a uključivanjem vremena izmjere moglo bi se izračunati konkretan omjer troškova i učinkovitost izmjere ploha različite veličine.

ZAHVALA – Acknowledgements

Ovo istraživanje potpomogle su “Hrvatske šume” d.o.o. preko projekta “Utjecaj različitih metoda uzorkovanja na izmjeru i procjenu elemenata strukture

prebornih sastojina” te Ministarstvo znanosti obrazovanja i športa Republike Hrvatske u sklopu projekta 068-0681966-1969.

LITERATURA – References

- Čavlović, J., M. Božić, 1999: Program gospodarenja za G.J. šume posebne namjene “Belevine” (2000.–2009.). Šumarski fakultet, Sveučilište u Zagrebu.
- Čavlović, J., M. Božić, 2008: Nacionalna inventura šuma u Hrvatskoj – metode terenskog prikupljanja podataka, Šumarski fakultet Sveučilišta u Zagrebu, 146 str., Zagreb.
- Čavlović, J., M. Božić, Ž. Galić, 2001: Varijabilnost i prostorna raspodjela elemenata strukture i

etata na razini sastojine pri gospodarenju prebornim šumama uz pomoć GIS-a. U: Matić, S., Krpan, A., P. B., Gračan, J. (Ur.), Znanost u potrajnom gospodarenju hrvatskim šumama. Šumarski fakultet Sveučilišta u Zagrebu, Šumarski institut Jastrebarsko, str.413–422, Zagreb.

Galić, Ž., 2002: Pouzdanost procjene strukturnih elemenata izmjere šuma primjenom kombiniranih metoda. Magisterij. Šumarski fakultet, Sveučilište u Zagrebu.

- Iles, K., 2003: A Sampler of Inventory Topics. A textbook on forest inventory. Second edition. Kim Iles and Associates, 869 str., Nanaimo, B.C. Canada.
- Indir, K., 2004: Optimalni načini prikupljanja i obrade podataka kontrolnom metodom u inventuri šuma. Magisterij. Šumarski fakultet, Sveučilište u Zagrebu.
- Johnson, E. W., 2000: Forest sampling desk reference. CRC Press, 1008 str., Boca Raton, Florida.
- Koprivica, M., 2006: Varijabilitet i preciznost procjene taksacionih elemenata visokih sastojina bukve u Jablaničkom šumskom području. Glasnik Šumarskog fakulteta Univerziteta u Banjoj Luci 6, 49–60.
- Lukić, N., 1984: Izmjera jednodobnih sastojina primjenom uzoraka promjenljive vjerojatnosti selekcije. Glasnik za šumske pokuse 22, 333–377, Zagreb.
- Pranjić, A., 1966: Interpolirane Šurićeve jednoulazne tablice za jelu – smreku i bukvu. Šumarski list 90 (3–4), 185–212, Zagreb.
- Pranjić, A., 1987: Pouzdanost rezultata izmjere šuma. Glasnik za šumske pokuse, Posebno izdanje 3, 161–176, Zagreb.
- Pranjić, A., N. Lukić, 1997: Izmjera šuma. Šumarski fakultet, 210 str., Zagreb.
- Schreuder, H. T., T. G. Gregoire, G. B. Wood, 1993: Sampling methods for multiresource forest inventory. John Wiley & Sons, 446 str., New York.
- Schreuder, H. T., R. Ernst, H. Ramirez-Maldonado, 2004: Statistical techniques for sampling and monitoring natural resources. General Technical Report RMRS-GTR-126, U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, 111 str., Fort Collins.
- Sokal, R. R., F. J. Rohlf, 1995: Biometry, (Third edition). Freeman and Company, 880 str., New York.
- StatSoft, Inc., 2006: STATISTICA (data analysis software system), version 7.1. www.statsoft.com.
- *** Pravilnik o uređivanju šuma, Narodne novine, 111/06 i 141/08.

SUMMARY: Stand structure estimate is based on data from sample plots. The aim of this research was to compare the stand structure estimates based on sample of circular plots with different radii. Through this influence of plot size on structure estimate and efficiency of stand measurement was also indirectly assessed. Measurements were made in beech-fir selection stand in the Educational and experimental forest site "Zalesina" in Gorski kotar region, Croatia. Stand size is 20,63 ha, it is situated from 790 to 850 m above sea level, and belongs to site class II. Stand exposition is south to east, terrain slope is 5–10°. Tree breast height diameters (DBH) were measured on systematic sample of 17 concentric circular sample plots. Tree location from plot centre was recorded by azimuth and distance. All trees of DBH 10 cm or more were measured on 13 meter radius plot, trees of DBH 30 cm and more were measured on 19 m radius plot and trees of DBH 50 cm and more on 26 m radius plot. Computer programme CirCon for calculation of stand parameters based on measured plots and simulated plots, with radii different from measured ones, has been developed. Plots based on real measurements were simulated according to ones used in forest management practice (singular and concentric circle plots). We simulated 8 methods: K7,98 (7.98 m radius plots), K9,77 (9.77 m radius plots), K11,28 (11.28 m radius plots), K12,62 (12.62 m radius plots); K5-12 (concentric circle plots with radii 5 and 12 m), K7-13 (concentric plots with radii 7 and 13 m), K7-13-20 (concentric plots with radii 7, 13 and 20 m) and K13-19-26 (three concentric circles of 13, 19 and 26 m radius). Calculated estimates for number of trees, basal area and volume on the same standing points differed between methods depending on spatial tree distribution and size of plots. Descriptive statistics (arithmetic mean, standard deviation, standard error) was made for each variable (number of trees, basal area and volume) on stand level. Sample error with 95 % confidence ($SE/mean \cdot t_{0.05}$) was also calculated to express the precision of estimates. Different estimates by methods depending on plot size were compared by re-

peated measures ANOVA, due to lack of independence between methods (plot sizes) on the same standpoints.

Estimates of number of trees by methods (Figure 2) ranged between 275.4 and 303.5 per hectare, although differences were not statistically significant at 0.05 confidence level (Repeated measures ANOVA: $F = 0.6027$, $df = 7$, $p = 0.7526$). Precision expressed by relative sample error varied from 13.58 % (K13-19-26) to 28.34 % (K5-12). Better results (lesser sample error) were obtained on bigger plots, though concentric circles (K5-12, K7-13 and K7-13-20) have considerably greater sample error due to fewer trees per plot.

Basal area estimates by methods ranged from 34.80 to 37.76 m² per hectare (Figure 3), making no statistically significant differences (Repeated measures ANOVA: $F = 0.2948$, $df = 7$, $p = 0.9547$). Relative precision ranged from 10.13 % (K13-19-26) to 26.96 % on smallest plots (K7,98). Sample error of basal area estimate on concentric circles was just slightly bigger in spite of fewer trees per plot. Reason for that is stability of basal area on plots regardless to fewer trees: concentric circles include fewer trees but have great share of bigger ones that contribute to basal area more than smaller ones.

Estimate of stand volume by methods ranged from 457.93 to 496.47 m³ per hectare (Figure 4). There was no statistical difference in volume estimates between analysed methods (Repeated measures ANOVA: $F = 0.2650$, $df = 7$, $p = 0.9661$). Relative precision ranged between 10.14 % (K7-13-20) and 30.36 % (K7,98). Better precision was obtained with bigger plots, due to more trees per plot. Concentric circles produce just slight increase in sample error while lowering the cost of measurement by reducing the number of trees per plot.

Number of measured trees per plot was computed as an indicator of plot efficiency. Differences in number of trees per plot between plot sizes were statistically significant at 0.05 level (Repeated measures ANOVA: $F = 187.621$, $df = 7$, $p = 0.0000$), except for: K7,98 and K5-12; K7-13 and K9,77; K7-13-20 and K12,62 (Fisher LSD Post-hoc test).

Evident increasing trend of number of trees per plot by increasing of plot size is the main cause of better precision. Although concentric circles reduce number of trees per plot, loss of precision for basal area and volume are minimal (Figure 5). Therefore plots K5-12 are acceptable for use in this kind of stands, with remark that they require well trained staff and modern instruments. Plots K7-13 do not improve precision while increasing number of trees per plot (9), therefore are not recommended. Triple concentric circles K7-13-20 reduce sample error almost by 10 %, although by significant increase of measured trees per plot.

Plots K11,28 reduce number of trees per plot with minimal increase in sample error compared to K12,62 plots. That fact makes them acceptable choice for gain in efficiency. However, K11,28 sample should be adjusted with more plots to satisfy required sampling intensity (5 % of stand), which would increase costs. In order to simplify the sampling plan, legislation does not require precision rather sampling intensity (5 % of stand area), which restricts opportunity to optimize sample size.

The choice of plot size is based on inventory goals and should depend on cost of measurements and expected precision. This kind of research can provide useful base for determining plot size by costs and precision of data. Exact ratio of cost and precision could be computed by including time measurement per plots of different sizes.

Key words: forest inventory, circular sample plots, number of trees, basal area, volume, estimation, precision, CirCon computer model