

Učinkovitost izmjere prebornih šuma na primjernim plohama različitih radijusa

Anamarija Jazbec, Mislav Vedriš, Mario Božić, Ernest Goršić

Nacrtač – Abstract

Učinkovitost izmjere šuma na jednostrukim kružnim plohama različite veličine u prebornim jelovo-bukovim sastojinama u Gorskom kotaru ocijenjena je na temelju preciznosti procjene i utrošenoga vremena za izmjere. Na 103 primjerne plohe radijusa 20 m izmjereni su prsni promjer, visina i položaj stabala. Računalnim programom CirCon napravljen je obračun strukturnih elemenata (broja stabala, temeljnice i volumena) za plohe u rasponu radijusa od 4 do 20 m s pripadajućom preciznosti procjene.

Prosječne vrijednosti strukturnih elemenata na plohama različitih veličina uspoređene su analizom varijance ponovljenih mjerenja te Fisherovim post hoc testom.

Na poduzorku 24 stajališta izmjereno je vrijeme potrebno za terensko mjerenje na plohama različite veličine te je za sve veličine ploha procijenjeno vrijeme izmjere u ovisnosti o površini plohe. Postignuta učinkovitost ocijenjena je kao umnožak kvadrata pogreške uzorka i utrošenoga vremena. Učinkovitost uz zadani intenzitet izmjere od 5 % površine za različite veličine i broj ploha procijenjena je pomoću očekivane preciznosti i potrebnoga vremena.

Procjena broja stabala na plohama manjim od 7 m radijusa statistički je značajno podcijenjena u odnosu na plohe radijusa 20 m, što nije potvrđeno za temeljnicu i volumen.

Preciznost procjene bitno je poboljšana povećanjem ploha do radijusa 13 m, a prosječne vrijednosti ustaljuju se na približno 10 m radijusa.

Uz isti broj ploha učinkovitost je znatno poboljšana povećanjem površine ploha do radijusa 10 m te podjednaka za plohe radijusa iznad 13 m. Za broj ploha prilagođen zadanoj ukupnoj površini uzorka utrošak vremena jednoznačno se smanjuje primjenom manjega broja većih ploha u odnosu na veći broj manjih ploha, uz male razlike u preciznosti procjene.

Plohe površine 500 m² potvrdile su se prihvatljivima, s tim da bi uz istu veličinu uzorka veće plohe poboljšale preciznost procjene i učinkovitost. Prilagodбом veličine i broja ploha propisanom intenzitetu ove plohe također su se pokazale prikladnima uz moguću uštedu vremena na plohama većega radijusa.

Ključne riječi: izmjera šuma, primjerne plohe, sastojinska struktura, preciznost, vrijeme izmjere, učinkovitost, jelovo-bukove sastojine

1. Uvod – Introduction

Izmjera šuma prijeko je potreban temelj razboritoga i potrajnoga gospodarenja šumama, pri čemu točnost i pouzdanost podataka o stanju šuma imaju presudnu ulogu. Općenito se cijena izmjere šume povećava većom ciljanom kakvoćom (točnošću i pouzdanošću) podataka, pa se u praksi uspostavlja ravnoteža između cijene koju je moguće platiti i željene pouzdanosti podatka inventure. Za takvu ravnotežu potrebno je poznavati troškove i kakvoću podataka izmjere, jer izbor metode inventure bez poznatih troškova i(li) kakvoće podataka postaje vrlo

subjektivan. Praktična je posljedica takva odabira ili preskupa ili nedovoljno pouzdana izmjera. Najgori je mogući ishod da ni nakon same izmjere odabranom metodom nije poznata pouzdanost procjene, uz nepotrebno velike troškove.

Pouzdanost (preciznost) procjene sastavni je dio rezultata svakoga uzorkovanja i statističkoga zaključivanja, pa tako i inventure šuma. Može se reći da je uzaludno određivati trošak inventure ako je nepoznata kakvoća procjene jednako kao što je »besmislena cijena bez poznavanja kakvoće«, te je određivanje pouzdanosti procjene iz uzorka sastavni dio čitavoga postupka izmjere (Deming 1950). Pouzdanost pro-

cjene također je neizostavni dio ocjenjivanja učinkovitosti odnosno prihvatljivosti metoda inventure šuma.

Primjerne plohe određene površine osnovna su vrsta uzorka za prikupljanje podataka o strukturi šumskih sastojina, a oblik, veličina i raspored u prostoru ovisi o strukturi sastojine, svrsi izmjere te o iskustvu i tradiciji rada. Istraživanje optimalne veličine i oblika primjernih ploha za terensku izmjeru je »vječna potraga« potaknuta željom da se smanji trošak i vrijeme uzorkovanja, a da se pritom postigne cilj izmjere ili pokusa (Gregoire i Valentine 2008). Općeniti je cilj da ploha sadrži »dovoljan« broj stabala uz što manje vrijeme izmjere (Schreuder i dr. 1993: 293). Budući da se prikladan broj i veličina ploha prilagođavaju prirodnim svojstvima (strukturi šuma) i namjeni inventure (Curtis i Marshall 2005), nije moguće postići općevažeci zaključak, nego je u svakom području potrebno utvrditi najbolji način uzorkovanja za praktičnu primjenu (Mesavage i Grosenbaugh 1956, Freese 1961, Gregoire i Valentine 2008). Tako je Kulow (1966) zaključio da su veće plohe učinkovitije od malih, dok Husch i dr. (2003: 262) smatraju da općenito vrijedi suprotno. Na temelju teorije uzoraka i dosadašnjih istraživanja postoji zakonitost postizanja manje varijabilnosti procijenjenih parametara (broja stabala, temeljnica, volumena) povećanjem površine primjernih ploha (Freese 1961, Sukwong i dr. 1971, Reich i Arvanitis 1992, Brooks i McGill 2004, Lindemuth 2007, Vedriš i dr. 2009). S druge strane za plohe manje površine potrebno manje vremena, pa se učinkovitost ploha neke veličine ocjenjuje iz odnosa postignute preciznosti i utroška vremena za izmjeru. Najveća učinkovitost općenito je postignuta kad se dodatnim povećanjem vremena više (bitno) ne poboljšava preciznost (Lindemuth 2007). Takva su istraživanja više puta provedena u svijetu (Mesavage i Grosenbaugh 1956, Nyssönen i dr. 1971, Zeide 1980, Wiant i Yandle 1980, Reich i dr. 1992, Čuković 2005, Lindemuth 2007), dok su u Hrvatskoj do sada objavljeni rezultati nekoliko istraživanja ocjene pouzdanosti procjene kojima nije izravno mjeren utrošak vremena (Šurić 1929, Lukić 1984, Galić 2002, Indir 2004, Vedriš i dr. 2009). Subotić je (1981) utvrdio da je prilagodbom veličine uzorka uz zadanu preciznost procjene moguće smanjiti troškove izmjere do 50 %, bez prilagodbe veličine ploha.

Danas su plohe kružnoga oblika najčešće korišten oblik ploha zbog najmanje rubnih stabala (manje pogreški pri izmjeri) i jednostavnosti postavljanja (Schreuder i dr. 1993, Shiver i Borders 1996). U prilog kružnim plohama ide činjenica da je danas provjera rubnih stabala znatno ubrzana uporabom ultrazvučnih i laserskih daljinomjera. Prema istraživanjima Nyssöna i dr. (1971) u finskim šumama pokazalo se da su kružne plohe znatno učinkovitije od kva-

drata iste površine, s tim da se taj omjer smanjuje povećanjem površine ploha. Potankom usporedbom više veličina i oblika ploha Kulow je (1966) zaključio da oblik plohe ne utječe na preciznost niti točnost procjene temeljnica, nego samo na njezinu praktičnost, a time i na učinkovitost.

2. Problematika istraživanja – *Research issues*

Za izradu osnova gospodarenja (uređajnu inventuru) u Hrvatskoj podaci se od sredine 20. stoljeća prikupljaju terenskom izmjerom na primjernim plohama postavljenima kao sistematski uzorak (Pravilnik o uređivanju šuma, 2008). U hrvatskoj praksi izmjere šuma pouzdanost procjene do sada nije bila kvantitativno vrednovana, a pokušaj unaprjeđivanja postupka uređajne inventure koji je uključivao i pouzdanost (preciznost) procjene drvne zalihe zbog praktičnih teškoća i neprihvaćenosti za sada nije zaživio (Pravilnik o uređivanju šuma, 2006, 2008). Prema Pravilniku o uređivanju šuma (2008) način uzorkovanja određen je površinskim intenzitetom od 5 %, što razumijeva primjenu jednostrukih ploha, koje su prema dosadašnjoj praksi u prostoru raspoređene kao sistematski uzorak po kvadratnoj mreži. Budući da plan uzorka ipak nije zakonski propisan, prilagodbom veličine i broja ploha za postizanje zadanoga intenziteta moguće je poboljšati pouzdanost procjene i učinkovitost izmjere.

Budući da u novije vrijeme nije bilo sustavnoga istraživanja učinkovitosti metoda terenske izmjere, ovim se istraživanjem pokušava ocijeniti utjecaj veličine primjernih ploha na procjenu strukturnih elemenata i potrebno vrijeme izmjere, a iz toga i na učinkovitost inventure koja ovisi o varijabilnosti sastojina (Husch i dr. 2007). Smatramo da je takvim pristupom moguće pridonijeti poboljšanju i racionalizaciji plana uzorkovanja u izmjeri šuma.

3. Materijal i metode istraživanja *Material and methods of research*

3.1 Terenska izmjera – *Field measurements*

Zbog jednostavnosti i praktičnosti te raširene upotrebe u inventuri šuma (Johnson 2000, Iles 2003) odabran je sistematski uzorak primjernih ploha. Sistematskim uzorkom sa slučajnim početkom postavljene su 103 primjerne plohe u četiri preborne sastojine. Na kružnim plohama radijusa 20 m, postavljenima po kvadratnoj mreži razmaka 100 × 100 m u svakoj sastojini, izmjereni su prsni promjer i visina stablima iznad taksacijske granice 10 cm te je snimljen njihov položaj u prostoru (azimut i udaljenost od središta).

Plohe su na terenu položene uporabom busole i ultrazvučnoga daljinomjera Vertex IV, na temelju azimuta i udaljenosti određenih sa zemljovida. Vrijeme hoda između ploha izmjereno je prilikom obilaska ploha te je uz poznatu udaljenost izračunata brzina hoda po terenu. Na poduzorku 24 stajališta naknadno je na plohama različite veličine izmjereno vrijeme potrebno za terensko mjerenje radi ocjene učinkovitosti ploha različite veličine. Ekipa za izmjeru vremena imala je dva mjeritelja te su mjereni samo prsni promjer stablima iznad navedene taksacijske granice.

3.2 Obračun i analiza podataka – Data processing and analysis

Iz snimljenih podataka o stablima, a uz pomoć posebno izrađenoga računalnoga programa *CirCon* (Vedriš i dr. 2009), izračunati su iznosi strukturnih elemenata (broja stabala, temeljnice i volumena) po jedinici površine za sve izmjerene plohe. Drvna je zaliha obračunata lokalnim tarifama dobivenima pomoću visinske krivulje i parametara Schumacher-Hallove jednadžbe (Špiranec 1975, 1976). Budući da su za sva stabla uneseni prostorni podaci, u računalu je napravljen obračun strukture za primjerne plohe u rasponu radijusa od 4 do 20 m s korakom povećanja 0,5 m. Za svaku je veličinu ploha izračunata preciznost procjene strukturnih elemenata izražena kao pogreška uzorka uz 95 % pouzdanosti, a radi međusobne usporedbe iskazana u relativnom iznosu (*KP*):

$$KP = t \cdot \frac{s}{\sqrt{n}} \cdot \frac{1}{\bar{X}}$$

Uspoređivanje prosječnih vrijednosti strukturnih elemenata između različitih veličina krugova na istim stajalištima učinjeno je analizom varijance ponovljenih mjerenja (ANOVA PM) uz razinu značajnosti 0,05 (Sokal i Rohlf 1995) pomoću statističkoga paketa Statistica 7.1. (Statsoft 2006). Naknadno je testiranje rezultata ploha različite veličine provedeno Fisherovim LSD *post hoc* testom.

Iz zabilježenih vremena izmjere za različite veličine ploha procijenjeno je vrijeme izmjere (t_{IZM}) u ovisnosti o površini plohe (P) po jednadžbi $t_{IZM} = a \cdot P^b$ (Zeide 1980, Reich i dr. 1992).

Učinkovitost izmjere za plohe pojedine veličine na temelju preciznosti procjene i vremena potrebnoga za izmjeru ocijenjena je na dva načina – za stvarno postavljani broj ploha te za broj ploha prilagođen površinskomu intenzitetu 5 %.

a) Indeks dobivene učinkovitosti – Index of obtained efficiency

Jednostavni indeks učinkovitosti (*IU*) predstavlja mjeru dobivene pouzdanosti za utrošeno vrijeme

(Avery i Burkhart 2002, prema Lindemuthu 2007), a izračunat je kao umnožak kvadrata standardne pogreške procjene željene varijable (s_x^2) i ukupno utrošenoga vremena (t_{UK}) koje uključuje izmjeru i hod po sastojini:

$$IU = s_x^2 \cdot t_{UK}$$

Tim je indeksom ocijenjena ostvarena učinkovitost izvršenoga uzorka jer uključuje stvarno utrošeno vrijeme za izmjeru i hod između ploha te dobivenu preciznost za taj trošak. Radi praktičnosti i usporedbe za različite varijable iskazan je kao omjer indeksa učinkovitosti kružnih ploha radijusa 20 m i svake druge veličine krugova za sve tri varijable. Tako izračunat relativni indeks veći od 1 znači bolju, a manji od 1 lošiju učinkovitost u odnosu na plohe radijusa 20 m (Husch i dr. 2003).

b) Očekivana učinkovitost uz zadani intenzitet uzorka 5 % – Expected efficiency of 5% cruise

Učinkovitost ploha različitih veličina također je procijenjena pomoću očekivane preciznosti uz zadani površinski intenzitet izmjere od 5 % propisan Pravilnikom o uređivanju šuma (2008) iz kojega je izračunat potreban broj ploha svake veličine. Potrebno vrijeme hoda (t_{HOD}) za pravilan raspored ploha dobiveno je prema Zeideu (1980) iz poznate površine (A), broja ploha (n) i brzine hoda (v_{HOD}) jednadžbom:

$$t_{HOD} = \frac{\sqrt{A \cdot n}}{v_{HOD}}$$

Množenjem broja ploha s vremenom izmjere na plohi izračunato je ukupno vrijeme izmjere za svaku veličinu ploha. Zbrajanjem vremena hoda između ploha i vremena izmjere na svim plohama dobiveno je ukupno vrijeme. Iz procjene varijabilnosti (koeficijenta varijacije) strukturnih elemenata (N , G , V) dobivene obračunom na izvornom broju ploha, te potrebnoga broja ploha za zadani intenzitet (n) izračunata je očekivana preciznost procjene (*KP*) broja stabala, temeljnice i volumena za svaku veličinu ploha po jednadžbi:

$$KP = t \cdot \frac{KV}{\sqrt{n}}$$

Obračuni preciznosti i učinkovitosti te grafički prikazi napravljeni su u programu Microsoft Excel 2003.

4. Područje istraživanja – Area of research

Istraživanje je provedeno u dinarskim jelovo-bukovim sastojinama u Gorskom kotaru. Bitno je obilježje toga područja istaknuti gorski reljef na nadmorskim

visinama od 700 do 900 m, koji uvjetuje umjereno toplu kišnu klimu, bez sušnoga razdoblja. Prosječna godišnja količina oborine iznosi oko 2000 mm, s jednoličnim rasporedom oborine tijekom godine. Prosječna godišnja temperatura nešto je iznad 7 °C, s vrlo izraženim temperaturnim ekstremima i čestim mrazom, te uz vrlo visoku zračnu vlagu. Prema Köppenovoj podjeli područje pripada tipu klime cfsbx" (Seletković 2001).

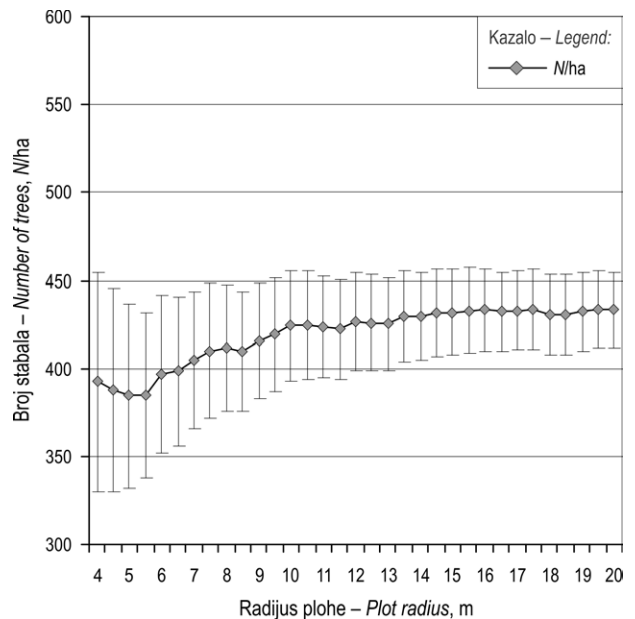
Sastojine za izmjeru odabrane su u šumskoj zajednici bukve i jele na vapnenačkoj podlozi (*As. Omphalodo-Fagetum* /Tregubov 1957/ Marinček i dr. 1993) na području Uprave šuma podružnice Delnice koja sadrži najveću površinu jelovih šuma u Hrvatskoj. Iz podataka *Osnova gospodarenja* odabrane su sastojine kojima gospodare Hrvatske šume d.o.o. i u kojima znatnije pridolazi obična jela, propisanoga prebornoga načina gospodarenja i približno prosječne površine 28 ha. Između tih sastojina, prema različitim udjelima vrsta drveća i strukturi, za istraživanje su odabrani odjeli 10a i 24a u gospodarskoj jedinici »Delnice« te odjeli 100a i 146a u gospodarskoj jedinici »Ravna Gora«, na nadmorskim visinama od 740 do 1 064 m, ukupne površine 113,64 ha.

5. Rezultati istraživanja – Research results

5.1 Procjena broja stabala, temeljnica i volumena – Estimate of number of trees, basal area and volume

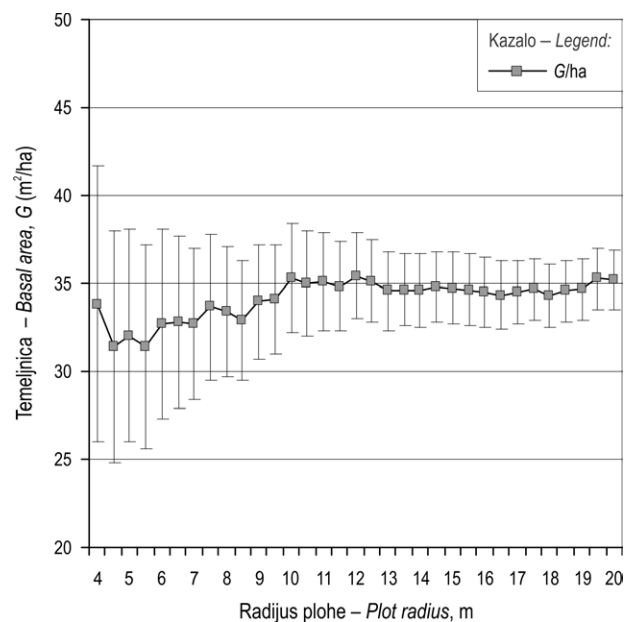
Procjena broja stabala (slika 1) kreće se od 384 stabla na plohama radijusa 5 m do 434 stabla na plohama radijusa 17,5 m, s koeficijentom varijacije između veličina ploha 3,8 %. Vidljiv je trend povećanja procijenjenoga broja stabala povećanjem ploha do radijusa 13,5 m, a također i veća odstupanja prosječnih vrijednosti kod manjih ploha. Razlike procjene broja stabala između pojedinih veličina ploha pokazale su se statistički značajnima (ANOVA PM: $F = 2,31$, $df = 102$, $p < 0,0001$) te je naknadnim testiranjem Fisherovim testom na plohama radijusa manjega od 7 m utvrđena statistički značajno manja procjena broja stabala nego na najvećim plohama.

Procjena temeljnica (slika 2) kreće se od 31,4 m²/ha na plohama radijusa 4,5 m do 35,4 m²/ha na plohama radijusa 12 m, s koeficijentom varijacije između veličina ploha 3,2 %. Procijenjena se temeljnica povećava povećanjem radijusa ploha do radijusa 10 m. Međutim, razlike procjene temeljnica između pojedinih veličina ploha nisu se pokazale statistički značajnima (ANOVA PM: $F = 0,72$, $df = 102$, $p = 0,8772$) te se ne može tvrditi da postoji pristranost procjene temeljnica na manjim plohama, odnosno da su manje plohe neprikladne za procjenu temeljnica.



Slika 1. Procijenjeni broj stabala po hektaru ovisno o radijusu ploha. Okomite crte predstavljaju 95 % pouzdani interval procjene

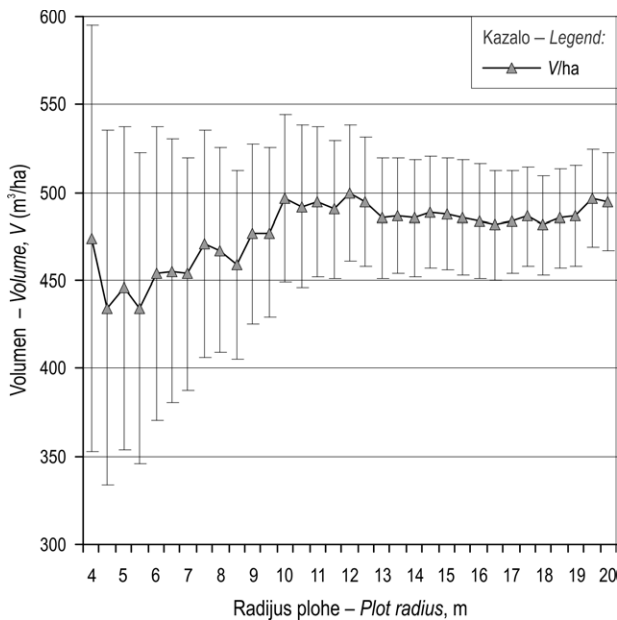
Fig. 1 Estimated number of trees per hectare by plot radii. Vertical lines indicate the 95% confidence intervals



Slika 2. Procijenjena temeljnica po hektaru ovisno o radijusu ploha. Okomite crte predstavljaju 95 % pouzdani interval procjene

Fig. 2 Estimated basal area per hectare by plot radii. Vertical lines indicate the 95% confidence intervals

Procjena volumena (slika 3) kreće se od 434,0 m³/ha na plohama radijusa 5,5 m do 499,8 m³/ha na plohama radijusa 12 m, s koeficijentom varijacije između veli-



Slika 3. Procijenjeni volumen po hektaru ovisno o radijusu ploha. Okomite crte predstavljaju 95 % pouzdani interval procjene

Fig. 3 Estimated volume per hectare by plot radii. Vertical lines indicate the 95% confidence intervals

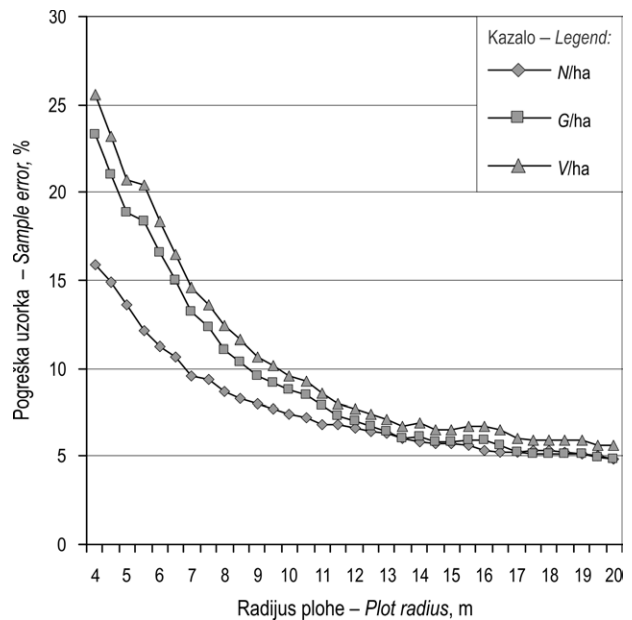
čina ploha 3,7 %. Procijenjeni volumen povećava se kao temeljnica povećanjem radijusa ploha približno do radijusa 10 m. Razlike procjene volumena između pojedinih veličina ploha nisu se pokazale statistički značajnima (ANOVA PM: $F = 0,78$ $df = 102$, $p = 0,8124$) te se manje plohe ne mogu općenito odbaciti kao neprikladne za procjenu volumena.

5.2 Preciznost procjene – Precision of estimates

Sukladno očekivanju i rezultatima sličnih istraživanja (Sukwong i dr. 1971, Vedriš i dr. 2009) uz isti broj ploha preciznost procjene poboljšana je povećanjem površine ploha kao posljedica smanjenja varijabilnosti (varijance) između ploha.

Relativna pogreška uzorka za broj stabala kreće se od 15,9 % na najmanjim plohama do 4,9 % na plohama radijusa 20 m, a za temeljnicu 23,3 % do 4,8 %. Preciznost procjene volumena najlošija je od sve tri varijable, a kreće se od 25,65 % na plohama radijusa 4 m do 5,6 % na plohama radijusa 20 m. Pri tome je uočljivo da je preciznost procjene bitno poboljšana povećanjem ploha do radijusa 13 m, a daljnjim povećanjem površine ploha preciznost se znatno ne mijenja.

Trend poboljšanja preciznosti sličan je za sve tri varijable (slika 4), osobito za temeljnicu i volumen. Preciznost procjene broja stabala na najmanjim plohama bolja je za 10 % od preciznosti temeljnice, ali se ta razlika smanjuje povećanjem ploha te se preciznost



Slika 4. Preciznost procjene strukturnih elemenata ovisno o radijusu ploha iskazana kao relativna pogreška uzorka od aritmetičke sredine uz 95 % pouzdanosti

Fig. 4 Precision of estimate depending on plot radii expressed by a relative sample error in relation to arithmetic mean with 95% confidence level

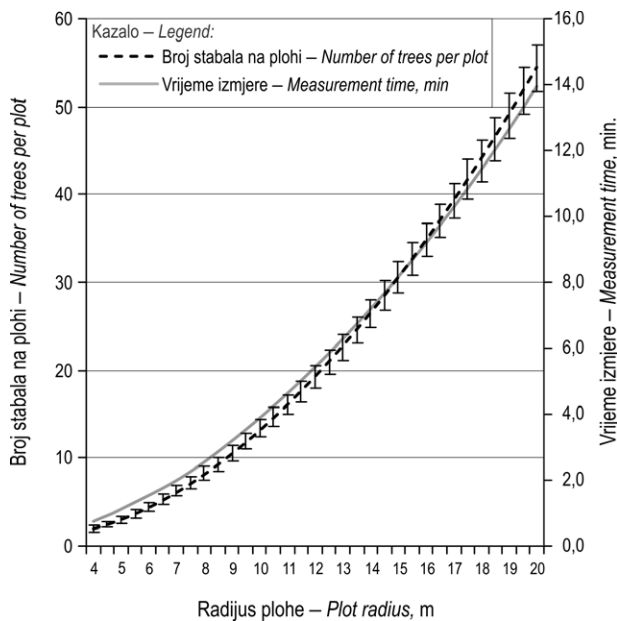
izjednačava kod ploha radijusa oko 12 m. Razlika preciznosti procjene temeljnice i volumena kreće se od 2 % kod najmanjih ploha do manje od 1 % kod najvećih ploha radijusa 20 m.

**5.3 Utrošak vremena i broj stabala po plohi
Time consumption and number of trees per plot**

Vrijeme hoda između ploha zabilježeno je pri obilasku svih ploha te je iznosilo ukupno 19,58 sati, iz čega ja za prijedeni put izračunata prosječna brzina 9,07 m/min.

Vrijeme izmjere na plohama (t_{IZM}), ovisno o površini plohe (P), procijenjeno je za sve veličine ploha jednadžbom ($t_{IZM} = a \cdot P^b$) s parametrima $a = 0,019$ i $b = 0,9245$ dobivenima izjednačenjem iz prosječnih vrijednosti vremena izmjere po mjerenim plohama različite površine ($R^2 = 0,82$). Iz tako dobivenih vremena za površine ploha preračunato je prosječno vrijeme izmjere po radijusima ploha i prikazano na slici 5.

Procijenjeno prosječno vrijeme izmjere kreće se od 0,7 minuta na plohama radijusa 4 m do 13,9 min na plohama radijusa 20 m, odnosno povećava se približno linearno s površinom ili kvadratom promjera plohe.



Slika 5. Izjednačeno prosječno vrijeme izmjere i prosječan broj stabala na plohi ovisno o radijusu ploha. Okomite crte predstavljaju 95 % pozdani interval broja stabala

Fig. 5 Average measurement time and average number of trees per plot depending on plot radius. Vertical lines indicate the 95% confidence intervals for number of trees

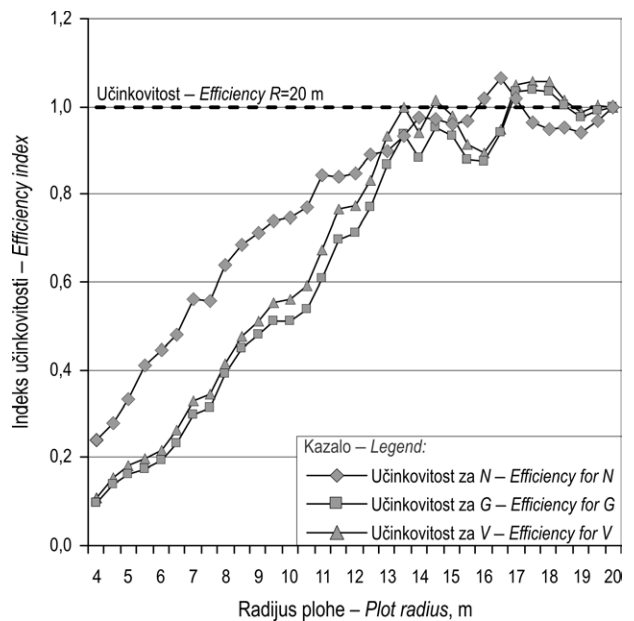
Prosječan broj stabala po plohi kreće se od 2 na plohi radijusa 4 m do 54 na plohi radijusa 20 m. Trend povećanja gotovo je jednak kao kod povećanja vremena pa je zbog toga broj stabala dobar pokazatelj vremena izmjere kod jednostrukih ploha.

5.4 Učinkovitost – Efficiency

a) Indeks dobivene učinkovitosti – Index of obtained efficiency

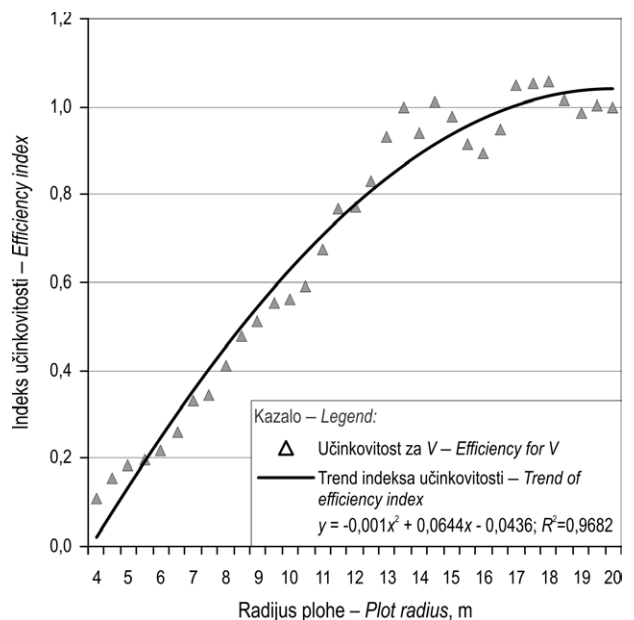
Iz stvarno izmjerena vremena hoda između ploha, izračunate preciznosti (pogreške uzorka) i procijenjena vremena izmjere dobiven je indeks učinkovitosti prikazan u odnosu na učinkovitost najvećih ploha (slika 6).

Indeks učinkovitosti poboljšava se povećanjem površine ploha podjednako za sve tri varijable, s tim da je znatno poboljšanje do radijusa ploha oko 13 metara za temeljnicu i volumen, a do radijusa 14 m za broj stabala. Najučinkovitije su za broj stabala plohe radijusa 16,5 m, a za temeljnicu i volumen plohe radijusa između 17 i 18 m. Ako iz konkretnoga uzorka pokušamo ocijeniti općeniti trend učinkovitosti bez pojedinačnih odstupanja (»skokova«), pretpostavljamo da se trend učinkovitosti poboljšava povećanjem površine ploha te da se za volumen



Slika 6. Učinkovitost ploha za strukturne elemente ovisno o radijusu ploha iskazana u odnosu prema učinkovitosti ploha radijusa 20 m

Fig. 6 Plot efficiency depending on plot radius in relation to efficiency of 20 m radius plots



Slika 7. Trend relativnoga indeksa učinkovitosti za volumen iskazanoga u odnosu prema učinkovitosti ploha radijusa 20 m ovisno o radijusu ploha

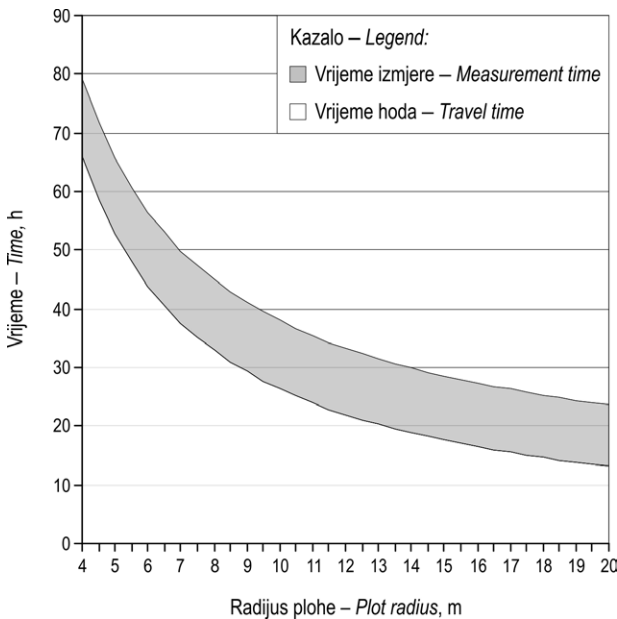
Fig. 7 Trend of efficiency index in relation to efficiency of 20 m radius plots depending on plot radius

može približno opisati kvadratnom jednadžbom kao na slici 7.

b) Očekivana učinkovitost uz zadani intenzitet uzorka 5 % – Expected efficiency of 5 % cruise

Iz odabranoga površinskoga intenziteta za svaku veličinu plohe dobiven je potreban broj ploha za koji su procijenjena potrebna vremena izmjere i hoda između ploha.

U konkretnim sastojinama uz takav način izmjere i kretanja po terenu utrošak vremena za zadani površinski intenzitet trajno se smanjuje u korist većih ploha (slika 8). Glavni je uzrok toga trenda vrijeme hoda između ploha koje se kreće od 65,9 h na plohama radijusa 4 m do 13,2 h na plohama radijusa 20 m. Vrijeme izmjere nešto se sporije smanjuje povećanjem površine ploha (od 13,4 h na plohama radijusa 4 m do 10,5 h na plohama radijusa 20 m) pa je između najmanjih i najvećih ploha razlika 2,9 h.

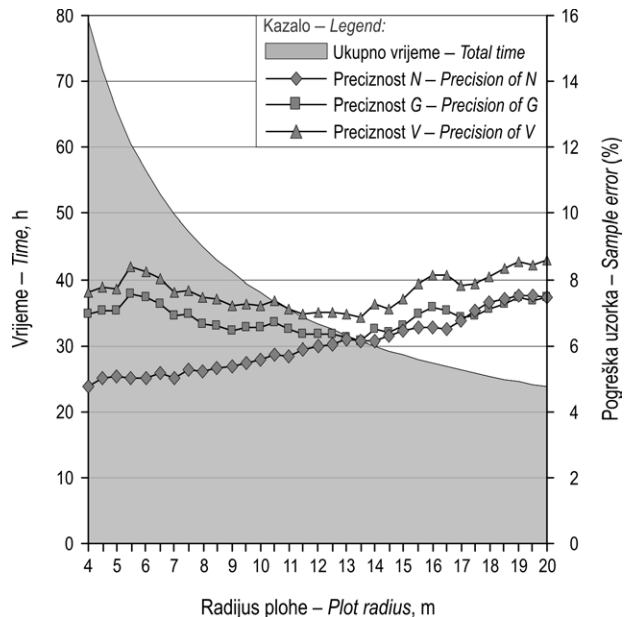


Slika 8. Ukupno potrebno vrijeme ovisno o radijusu ploha uz zadani površinski intenzitet uzorka 5 %

Fig. 8 Total time depending on plot radius with sampling intensity set on 5% area

Pogreška uzorka smanjuje se povećanjem površine ploha zbog veće varijabilnosti unutar ploha i manje varijabilnosti između ploha (Schreuder i dr. 2004). S druge se strane pogreška »računski« smanjuje povećanjem broja ploha, iz čega slijedi da uz zadani površinski intenzitet uzorka nije moguće unaprijed ocijeniti preciznost ovisno o veličini ploha.

Iz slike 9 vidljivo je pogoršanje preciznosti povećanjem radijusa ploha za broj stabala, dok je za temeljnicu i volumen trend manje izražen: preciznost se poboljšava do radijusa ploha 14 m, a zatim se pogreška uzorka povećava.



Slika 9. Preciznost procjene strukturalnih elemenata i ukupno potrebno vrijeme ovisno o radijusu ploha uz zadani površinski intenzitet uzorka 5 %

Fig. 9 Precision of estimate and total required time depending on plot radius with sampling intensity set on 5% area

6. Rasprava – Discussion

Iako se ne može tvrditi koja od veličina ploha daje »točne« rezultate, jer stvarne vrijednosti populacije ostaju nepoznate (Lindemuth 2007), ipak su rezultati s većih ploha »uvjerljiviji« iz nekoliko razloga. Budući da su sve veličine ploha odabrane kao sistematski uzorak sa slučajnim početkom, veći broj mjerenih stabala na većim plohama očekivano poboljšava reprezentativnost samoga uzorka. S tim je povezana pojava da se prosječne vrijednosti svih triju varijabli ustaljuju povećanjem površine (kao što se vidi na slikama 1, 2 i 3). Osim toga »uvjerljivost« većih ploha slijedi iz manje varijabilnosti odnosno bolje preciznosti procjene (slika 4), pa se prema tomu kao mjerilo »točnosti« mogu uzeti rezultati s najvećih ploha (Brooks i McGill 2004). Prema takvu kriteriju »točnosti« prihvatljive bi bile plohe radijusa iznad kojega se prosječna vrijednost ustaljuje, a ujedno se varijabilnost (preciznost) dalje bitno ne smanjuje. Iz rezultata bi to približno bile plohe radijusa većega od 13 m za sve tri varijable.

Rezultati su analize varijance, kao i kod sličnih istraživanja (Vedriš i dr. 2009), pokazali da dobivene razlike procjene temeljnice i volumena po veličinama ploha nisu statistički značajne na 95 % razini pouzdanosti. Dakle, iako su razlike po veličinama ploha iz ovoga uzorka vidljive, ne možemo potvrditi da općenito procjena iz neke veličine ploha odstupa od

ostalih, što se teoretski objašnjava time da prosječne vrijednosti dobivene iz svakoga nepristranoga uzorka teže stvarnoj srednjoj vrijednosti (Pranjić 1986, Johnson 2000). Jedino je pri procjeni broja stabala utvrđeno značajno podcjenjivanje na manjim plohama (do radijusa 7 m), što znači da za procjenu broja stabala u ovim sastojinama tako male plohe nisu pouzdane jer je na njima moguće očekivati značajno podcjenjivanje broja stabala. Slične su rezultate dobili Brooks i McGill (2004) u jednodobnim sastojinama, s tim da je kod njih broj stabala na malim plohama precijenjen.

Osim što je kod ploha radijusa do 13 m uočeno znatnije poboljšanje preciznosti procjene, zanimljivo je primijetiti da se kod toga radijusa ploha ujednačuje preciznost procjene svih triju strukturnih elemenata, pa bi i po zajedničkomu kriteriju preciznosti to mogla biti donja granica površine ploha.

Postavljanje željene preciznosti procjene uobičajeno je u inventuri šuma (Hamilton 1979) te bismo uz tako zadani uvjet izbor veličine ploha dodatno mogli prilagoditi. Primjerice, uz zadanu preciznost 10 % za procjenu volumena iz slike 4 vidljivo je da bi prihvatljive plohe bile radijusa 10 m i veće, iz čega bi po vremenu izmjere uz zadani raspored i broj ploha najprihvatljivije bile plohe upravo minimalnoga radijusa (10 m). Prema učinkovitosti uz zadani intenzitet 5 % površine, sve veličine ploha zadovoljile bi uvjet preciznosti procjene 10 % (slika 9), pa bi kriterij izbora bilo isključivo vrijeme, po čemu bi najveće plohe bile najprihvatljivije.

Budući da nema velike razlike u indeksu učinkovitosti ploha radijusa od 13 m naviše, uobičajene (propisane) plohe radijusa 12,62 m (površine 500 m²) u ovim sastojinama prihvatljive su po indeksu učinkovitosti, s tim da bi sve veće plohe bile podjednako dobre ili neznatno bolje.

Iako za plohe veće od 20 m nemamo podataka, iz trenda preciznosti i učinkovitosti (slika 4 i 7) pretpostavljamo da se ne bi (bitno) poboljšavale na plohama radijusa većega od 20 m. U svakom slučaju veće plohe teško bi bile praktično prihvatljive za izmjeru zbog velikoga broja stabala na plohi, poteškoće vidljivosti, a time i veće mogućnosti pogrešaka (izostavljanja stabala). Osim zbog većega opsega plohe, povećanjem radijusa povećava se broj provjera rubnih stabala zbog teže ocjene udaljenosti.

Uz isti intenzitet uzorka na većim plohama je lošija preciznost broja stabala, dok je vrijeme izmjere manje (slika 9), pa željena veličina ploha ovisi o važnosti tih dvaju kriterija. S druge strane, razlike preciznosti procjene volumena između ploha različite veličine gotovo su zanemarive – pogreška uzorka kreće se od 6,9 % kod ploha radijusa 13,5 m do 8,6 % kod najvećih ploha radijusa 20 m – osobito ako pre-

ciznost procjene nije unaprijed zadana. Stoga bi prema ovom načinu određivanja učinkovitosti za procjenu volumena povoljnije bilo odabrati što veće plohe kojima se znatno smanjuje ukupan utrošak vremena, što se vidi iz slike 9. Ukupno vrijeme na plohama radijusa 20 m procijenjeno je na približno 24 sata, što je značajna ušteda u odnosu na 31 sat za »najprecizniju« veličinu krugova radijusa 13,5 m ili na 79 sati kod najmanjih ploha. U slučaju da je preciznost procjene zadana ili propisana, ovaj bi vremenski kriterij izbora trebalo s njome uskladiti.

Ovi su rezultati u skladu sa Zeideovim zaključcima (1980) da je po učinkovitosti optimalna veličina ploha kod kojih je vrijeme izmjere jednako vremenu hoda između ploha, što su u ovom slučaju plohe radijusa 20 m (slika 8).

Nedostatak većih ploha jest teže određivanje rubnih stabala (Husch i dr. 2003: 262), što bi u praksi mogao biti važan uzrok pogreški pri izmjeri. Taj se odnos djelomično ispravlja činjenicom da za istu ukupnu površinu (zadani intenzitet) više malih ploha ima mnogo veći ukupni rub nego manje većih ploha (Gregoire i Valentine 2008: 236), što povećava vjerojatnost pogreške.

Iako je izračunata učinkovitost za sve tri varijable (broj stabala, temeljnica i volumen), za ocjenu prihvatljivosti moglo bi se koristiti bilo koja od njih, s tim da je procjena volumena u uređajnoj izmjeri najčešće najvažnija. Iz rezultata se (slike 6 i 9) vidi da učinkovitost i preciznost po temeljnici i po volumenu imaju jednak trend povećanjem površine ploha, s tim da volumen ima nešto veću pogrešku uzorka. Stoga bi procjena preciznosti i učinkovitosti pomoću temeljnice u ovim sastojinama mogla dobro poslužiti i za volumen.

Po oba načina ocjene učinkovitosti veće plohe pokazale su se učinkovitijima od malih, što je suprotno nekim općenitim postavkama, ali je očekivano u heterogenim sastojinama (Husch i dr. 2003). Uzroci su tomu prostorna heterogenost koja uvjetuje poboljšanje preciznosti na većim plohama (indeks dobivene učinkovitosti) te brzina kretanja između ploha (učinkovitost kod zadanoga prostornoga intenziteta). Kod prvoga je indeksa učinkovitosti vrijeme hoda jednako za sve veličine ploha pa je veća učinkovitost na većim plohama posljedica mnogo bolje preciznosti. Budući da se učinkovitost poboljšava povećanjem ploha, može se zaključiti da vrijeme izmjere ima manji utjecaj na učinkovitost nego preciznost procjene, odnosno da je povećanje vremena izmjere na većim plohama »nadačano« njihovom boljom preciznošću procjene koja u konačnici daje i bolju učinkovitost.

Ključan utjecaj koji uvjetuje neučinkovitost manjih ploha kod zadanoga površinskoga intenziteta jest vrijeme hoda između ploha, jer čak i ako zane-

marimo smanjenje vremena izmjere, vrijeme hoda kod velikoga broja malih ploha neusporedivo je veće nego kod manjega broja velikih ploha (slika 8). Iako je razlika u broju ploha jasan uzrok toga odnosa (teoretski 1130 ploha radijusa 4 m u odnosu na 45 ploha radijusa 20 m), mala brzina kretanja bitno doprinosi takvu omjeru (Van Laar i Akça 2007). Slično su Wiant i Yandle (1980) utvrdili da se optimalna veličina ploha povećava smanjenjem brzine hoda. Naizgled neočekivano velika razlika vremena hoda uzrokovana različitim brojem ploha (n) na istoj površini (A) proizlazi iz jednadžbe:

$$t_{HOD} = \frac{\sqrt{A \cdot n}}{v_{HOD}}$$

Dakle, na istoj površini sastojine uz gušću mrežu ploha vrijeme hoda po sastojini znatno se povećava, a prema dobivenim rezultatima u ovom slučaju neopravdano.

Dodatni praktični kriterij pri izmjeri jest prosječan broj stabala na plohi jer je kod većega broja stabala na plohi očekivano veća vjerojatnost pogreške pri izmjeri zbog izostavljanja udaljenih ili skrivenih stabala. Iznos ovakvih pogrešaka nije poznat, odnosno u ovom radu nije istraživao. S druge strane iskustveno pokazalo da (pre)mali broj stabala na plohi ne daje reprezentativan uzorak populacije, što je uostalom potvrđeno rezultatima procjene broja stabala (slika 1). Plohe radijusa manjega od 7 m nisu preporučljive zbog podcjenjivanja broja stabala, što po prosječnom broju stabala na plohi znači da u ovim sastojinama nije prihvatljivo manje od 6 stabala po plohi.

Prema nekim iskustvenim preporukama po plohi bi trebalo biti barem 20 stabala (Spurr 1952) odnosno 25 do 30 stabala (Meštrović i Fabijanić 1995), što bi u ovim sastojinama odgovaralo ploham radijusa od 12 do 15 m (slika 5). Iako taj kriterij nije egzaktan niti statistički iskazan, u ovom se slučaju dobro poklapa s računskim pokazateljima učinkovitosti te može poslužiti kao pomoć u odabiru veličine plohe.

Vrijeme kao bitan čimbenik učinkovitosti sigurno bi se moglo smanjiti drukčijom organizacijom i načinom rada te se ovi rezultati ne mogu smatrati općevažecima. Dvojica su mjeritelja realna i racionalna pretpostavka, no vrijeme izmjere ovisi i o uvježbanosti mjeritelja, motivaciji te načinu rada. Uvježbanost mjeritelja smanjuje broj provjera i ubrzava izmjeru, dok oprez povećava broj provjera i time izmjeru usporava. Budući da je izmjera u ovom istraživanju izvedena vrlo pažljivo radi izbjegavanja pogrešaka, vjerojatno je procjena potrebnoga vremena veća nego što se očekuje u praksi (Lindemuth 2007). Osim toga vrijeme hoda sigurno bi se smanjilo dolaskom

na plohu pomoću unaprijed određenih koordinata i uređaja GPS.

Najpovoljnija veličina (i broj) ploha ovisi o ključnom mjerodavnom kriteriju izbora (preciznost, vrijeme) pa je, ovisno o cilju inventure ili propisima, veličinu ploha moguće prilagoditi primjerice zadanoj preciznosti, minimalnom utrošku vremena ili istodobno optimirati više kriterija kako je učinjeno pri procjeni učinkovitosti uz zadani površinski intenzitet.

Poboljšanje preciznosti procjene i učinkovitosti izmjere postiglo bi se uvođenjem višestrukih kružnih ploha prilagođenih sastojinskoj strukturi, što je nažalost sadašnjim propisima onemogućeno te nije bilo predmetom ovoga rada.

7. Zaključci – Conclusions

Jednoznačno i po preciznosti i učinkovitosti veće su se plohe pokazale boljima u ovim sastojinskim prilikama uz ovakav način (brzinu) izmjere. Stoga se može zaključiti da je dobit preciznosti veća nego povećanje troška vremena, odnosno da je dodatno vrijeme izmjere opravdano povećanjem preciznosti procjene. Zbog velike prostorne varijabilnosti sastojina male plohe pokazale su se neprikladnima i neučinkovitima.

Na temelju rezultata ovoga istraživanja uobičajene plohe radijusa 12,62 m (površine 500 m²) prihvatljive su za ove preborne sastojine po »uvjerljivosti«¹ procjene, preciznosti i učinkovitosti uz zadani broj ploha. Ako učinkovitost promatramo uz zadani površinski intenzitet uzorka propisan Pravilnikom o uređivanju šuma (2008), nešto veće plohe bile bi učinkovitije zbog uštede vremena uz neznatan gubitak preciznosti (koja uostalom nije propisana).

Važno je napomenuti da rezultati i zaključci o učinkovitosti vrijede u ovim (i sličnim) sastojinama te da svakako ovisi o načinu izmjere – vrsti mjerenja, broju mjeritelja, njihovoj brzini kretanja i mjerenja. Stoga se ovi odnosi učinkovitosti ploha različite veličine ne mogu generalizirati ni doslovno prenijeti na druga područja i razine promatranja (površine).

Ovaj se način procjene učinkovitosti pokazao uspješnim u konkretnim prebornim sastojinama te bi mogao pridonijeti poboljšanju pouzdanosti i(li) smanjenju troškova inventure šuma prilagodbom veličine i broja ploha. Radi šire primjene slična je istraživanja potrebno poduzeti u različitim sastojinskim prilikama i na većem uzorku.

8. Zahvala – Acknowledgements

Ovo istraživanje omogućile su Hrvatske šume d.o.o. preko projekta »Utjecaj različitih metoda uzor-

kovanja na izmjeru i procjenu elemenata strukture prebornih sastojina« te Ministarstvo znanosti obrazovanja i športa Republike Hrvatske u sklopu projekta 068-0681966-1969.

9. Literatura – References

- Brooks, J. R., D. McGill, 2004: Evaluation of Multiple Fixed-Area Plot Sizes and BAFs in Even-Aged Hardwood Stands. U: D. A. Yaussy, D. M. Hix, R. P. Long, P. C. Goebel (ur.), Proceedings of the 14th Central Hardwood Forest Conference, General Technical Report GTR-NE-316, U.S. Department of Agriculture, Forest Service, Northeastern Research Station, Newtown Square, str. 94–100.
- Curtis, R. O., D. D. Marshall, 2005: Permanent-plot procedures for silvicultural and yield research. General technical report PNW-GTR-634, U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, Portland, 86 str.
- Čuković, D., 2005: Izbor optimalnog metoda uređajne /sastojinske/ inventure u raznodobnim i prebimnim šumama u Republici Srpskoj (*Choice of optimal stand inventory method in uneven-aged and selection forests in Republika Srpska*). Magistarski rad, Šumarski fakultet, Univerzitet u Beogradu, Beograd, 146 str.
- Deming, W. E., 1950: Some theory of sampling. John Wiley and sons, London, 602 str.
- Freese, F., 1961: Relation of plot size to variability: an approximation. *Journal of Forestry*, 59(9): 679.
- Galić, Ž., 2002: Pouzdanost procjene strukturnih elemenata izmjere šuma primjenom kombiniranih metoda (*Confidence of structural elements estimation in forest inventory by combined methods*). Magistarski rad, Šumarski fakultet Sveučilišta u Zagrebu, Zagreb, 71 str.
- Gregoire, T. G., H. T. Valentine, 2008: Sampling strategies for natural resources and the environment. Chapman and Hall/CRC, Boca Raton, Florida, 474 str.
- Hamilton, D. A., 1979: Setting precision for resource inventories: The manager and the mensurationist. *Journal of Forestry*, 77(10): 667–670.
- Husch, B., T. W. Beers, J. A., Kershaw, Jr., 2003: Forest mensuration. 4th Edition. John Wiley and Sons, New Jersey, 443 str.
- Iles, K., 2003: A Sampler of Inventory Topics. A textbook on forest inventory. Second edition, Kim Iles and Associates, Nanaimo, B. C. Canada, 869 str.
- Indir, K., 2004: Optimalni načini prikupljanja i obrade podataka kontrolnom metodom u inventuri šuma (*Optimal ways of data collection and analysis by control method in forest inventory*). Magistarski rad, Šumarski fakultet Sveučilišta u Zagrebu, Zagreb, 118 str.
- Johnson, E. W., 2000: Forest sampling desk reference. CRC Press, Boca Raton, Florida, 1008 str.
- Kulow, D. L., 1966: Comparison of forest sampling designs. *Journal of Forestry*, 64(7): 469–474.
- Lindemuth, R. M., 2007: A field trial comparison of sampling methods for estimating basal area and volume in partially harvested stands in Maine. Magistarski rad, University of Maine, 100 str.
- Mesavage, C., L. R. Grosenbaugh, 1956: Efficiency of several cruising designs on small tracts in north Arkansas. *Journal of Forestry*, 54 (9): 569–576.
- Meštrović, Š., G. Fabijanić, 1995: Priručnik za uređivanje šuma (*Handbook for forest management*). Ministarstvo poljoprivrede i šumarstva Hrvatske i »Hrvatske šume« p.o., Zagreb, 416 str.
- Nyysönen, A., P. Roiko-Jokela, P. Kilkki, 1971: Studies on improvement of the efficiency of systematic sampling in forest inventory. *Acta forestalia fennica*, 116: 26, Helsinki.
- Pranjić, A., 1986: Šumarska biometrika (*Forestry biometrics*). Šumarski fakultet Sveučilišta u Zagrebu, Zagreb, 204 str.
- Pravilnik o uređivanju šuma (*Rulebook for forest management*), Narodne novine, 111/06.
- Pravilnik o uređivanju šuma (*Rulebook for forest management*), Narodne novine, 141/08.
- Reich, R. M., L. G. Arvanitis, 1992: Sampling unit, spatial distribution of trees, and precision. *Northern Journal of Applied Forestry*, 9 (1): 3–6.
- Reich, R. M., C. A. Bravo, M. Iqbal, 1992: Optimal plot size for sampling coniferous forests in El Salto, Durango, Mexico. *Agrociencia, Recursos Naturales Renovables*, 2 (2): 93–106.
- Schreuder, H. T., T. G. Gregoire, G. B. Wood, 1993: Sampling Methods for Multiresource Forest Inventory. John Wiley & Sons, New York, 446 str.
- 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, Fort Collins, 111 str.
- Seletković, Z., 2001: Klima i hidrološke prilike u dinarskim jelovim šumama u Hrvatskoj (*Climate and hydrological conditions in the fir forests of the Dinaric region of Croatia*). U: B. Prpić (ur.), Obična jela (*Abies alba* Mill.) u Hrvatskoj, Akademija šumarskih znanosti i »Hrvatske šume« p.o., Zagreb, str. 133–141.
- Sokal, R. R., F. J. Rohlf, 1995: Biometry, Third edition. Freeman and Company, New York, 880 str.
- Spurr, S. H., 1952: Forest inventory. Roland Press Co., New York, 476 str.
- StatSoft, Inc., 2006: STATISTICA (data analysis software system), version 7.1. Tulsa, OK, USA.
- Subotić, M., 1981: Planiranje veličine uzorka pri taksacijskoj procjeni šuma (*Planning the sample size in forest inventory*). Magistarski rad, Šumarski fakultet Sveučilišta u Zagrebu, Zagreb, 36 str.

Sukwong, S., W. E. Frayer, E. W. Mogren, 1971: Generalized comparisons of the precision of fixed-radius and variable-radius plots for basal-area estimates. *Forest Science*, 17(2): 263–271.

Špiranec, M., 1975: Drvnogromadne tablice za hrast, bukvu, obični grab i pitomi kesten (*Volume tables for oak, beech common hornbeam and European chestnut*). *Radovi Šumarskoga instituta, Jastrebarsko*, 22: 1–262.

Špiranec, M., 1976: Tablice drvnih masa jele i smreke (*Volume tables for fir and spruce*). *Radovi Šumarskoga instituta, Jastrebarsko*, 29: 1–119.

Šurić, S., 1929: Tačnost procjene sastojina pomoću primjernih ploha (*Accuracy of stand estimation by sample plots*). *Šumarski list*, 53: 16–28, 66–76, 114–126.

Van Laar, A., A. Akça, 2007: *Forest mensuration*. Springer, Dordrecht, 383 str.

Vedriš, M., A. Jazbec, M. Frntić, M. Božić, E. Goršić, 2009: 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*). *Šumarski list*, 133 (7–8): 369–379.

Wiant, H. V., Jr., D. O. Yandle, 1980: Optimum plot size for cruising sawtimber in eastern forests. *Journal of Forestry*, 78 (10): 642–643.

Zeide, B., 1980: Plot size optimization. *Forest Science*, 26 (2): 251–256.

Abstract

Efficiency of Inventory in Uneven-Aged Forests on Sample Plots with Different Radii

For the purpose of forest management planning in Croatia, forest inventory is performed on sample plots of permanent sizes, generally from 500 to 1,000 m². Such plots have been accepted in practice on the basis of experience. Thus, the plot size has only partially been adjusted to different forest types. Although methods of sample selection are regulated by Forest Management Regulations and are limited to plots of permanent sizes, the Regulations still allow plot sizes to be adjusted to specific stand conditions. This article compares the results of forest measurement on differently sized plots in order to estimate their efficiency in selection fir and beech stands. Research was carried out in Gorski Kotar, where the stand structure was recorded using a sample of experimental plots. Systematic sampling with a random start was used to establish 103 sample plots in the management units of »Delnice« and »Ravna Gora«. Breast height diameters over 10 cm and tree heights were measured on circular plots of 20 m radius, set up across a 100 x 100 m square grid, and their positions in the space (azimuth and distance from the centre) were recorded. The values of structural elements (number of trees, basal area and volume) were calculated from the obtained data by means of a specially constructed computer programme CirCon for the plots and stands. The precision of estimates was expressed as a relative sample error with 95% confidence. Thanks to spatial data for all the trees, a calculation was made of the structure for sample plots in the radius range from 4 to 20 m. The precision of structural elements estimate (sample error) was calculated for each plot size.

The average values in differently sized plots were compared with repeated measurement analysis of variance (RM ANOVA) with significance level of 0.05. The results of different plot sizes were subsequently tested by means of the Fisher's LSD 'post hoc' test.

On a sub-sample of 24 standpoints, the time needed for field measurements on differently sized plots was later measured in order to estimate the efficiency of differently sized plots. From these data measurement time (t) for all plot sizes was assessed in dependence on plot area (P) using the equation $t = a \cdot P^b$.

Walking time and distance between the plots were measured, from which the travel speed in the field was calculated. The efficiency of plots of a particular size was evaluated by the precision of estimate and the time needed for measurements. The achieved efficiency index was evaluated as the product of squared sample error and total time expressed in relation to the efficiency of 20 m radius plots. The efficiency for differently sized plots was also assessed by means of the expected accuracy at given sampling intensity of 5% area (5% cruise), as set down in the Forest Management Regulations.

The results show the differences in the estimate of structural elements in dependence on plot sizes, especially for tree number. The differences were confirmed as statistically significant (RM ANOVA: $F = 2.31$, $df = 102$, $p < 0.0001$). Subsequent testing revealed that on the plots with radii less than 7 m the estimate of tree number was statistically significantly lower than in the larger plots. A similar trend did not prove to be statistically significant either for the basal area (ANOVA PM: $F = 0.72$, $df = 102$, $p = 0.8772$) or for the volume (ANOVA PM: $F = 0.78$, $df = 102$, $p = 0.8124$).

Expectedly a more precise estimate was obtained with an increase in plot size. Considerable improvement in the precision was observed up to plot radii of about 13 m. The trend was slowed down with further increase: consequently, in terms of precision, plots with at least the above radii are recommended. The assessment accuracy of tree numbers in the smallest plots was better by 10% than that of the basal area; however, this difference decreases as the plot size increases, to become equal at plots with radii of about 12 m. The difference in the assessment accuracy of the basal area and volume ranges from about 2% in the smallest plots to less than 1% in the largest plots with 20 m radius.

In the case of smaller plots, apart from poorer precision of estimates, there were also bigger deviations from the average obtained on larger plots. With regard to the average assessment value of tree number, the basal area and volume, plots with radii greater than 10 m would be acceptable in the study area.

The average measurement time increases almost linearly with an increase in plot size. In terms of the achieved efficiency index at the same number of plots, the smallest plots proved to be the least efficient, while the efficiency increases considerably up to 9 m radius, and levels from radii larger than 13 m. Along with the number of plots adjusted to the given sample size intensity of 5%, plots with radii between 8 and 15 m proved to be more precise than smaller and bigger plots. Time expenditure uniformly decreases with the application of a smaller number of bigger plots in relation to a larger number of smaller plots with an equal total area. Hence, the use of bigger plots is more practical since differences in precision are negligible.

In terms of the number of measured trees per plot as a practical criterion that affects the quality of the results and of field work, plots with radii between 12 m and 15 m are recommended, which contain between 20 and 30 trees on average.

This research confirmed the assumption that the reliability of estimates depends on plot size. Specific numerical relationships were obtained for the investigated selection stands. Plots of 500 m², common in forest management practice, proved to be adequate for the investigated stands. Nevertheless, larger plots could significantly contribute to better precision of estimates at identical sample size. In terms of efficiency, these plots are definitely acceptable, taking into account the fact that even larger plots could also be efficient at identical sample size. By adjusting the size and number of plots to the prescribed intensity, standard plot sizes proved to be adequate. Still, plots of larger radii would possibly save the measurement time.

Additional research involving a larger sample and broader range of stand conditions would give a clearer insight into the effect of plot size on precision of estimates. It would also enable better adjustment of plot sizes to individual stands for the purpose of forest inventory rationalization. For similar beech-fir selection stands, a comparison of nested plots (concentric circles) that are adjusted to the diameter structure should definitely be made. By doing so, the efficiency of assessment reliability and measurement efficiency could be improved, which is neglected by the present regulations.

Keywords: Forest inventory, sample plots, stand structure, precision, measurement time, efficiency, fir-beech stands

Adresa autorâ – Authors' address:

Izv. prof. dr. sc. Anamarija Jazbec
e-pošta: jazbec@sumfak.hr
dr. sc. Mislav Vedriš
e-pošta: mvedris@sumfak.hr
Izv. prof. dr. sc. Mario Božić
e-pošta: bozic@sumfak.hr
Ernest Goršić, dipl. inž. šum.
e-pošta: egorsic@sumfak.hr
Zavod za izmjeru i uređivanje šuma
Šumarski fakultet Sveučilišta u Zagrebu
Svetošimunska 25
10 000 Zagreb
Hrvatska