

## MODELIRANJE DEBLJINE KORE STABALA OBIČNE JELE (*Abies alba* Mill.)

MODELING BARK THICKNESS OF SILVER FIR TREES (*Abies alba* Mill.)

Mario BOŽIĆ\*, Juro ČAVLOVIĆ\*, Mislav VEDRIŠ\*, Mario JAZBEC\*\*

**SAŽETAK:** *Temeljni cilj istraživanja bio je načiniti modele koji objašnjavaju debljinu kore obične jele u dinarskim bukovo-jelovim šumama Hrvatske, kao funkciju stanišnih (ekoloških) čimbenika i značajki pojedinih stabala. Od stanišnih čimbenika pri modeliranju korištena je nadmorska visina, nagib te orijentacija terena, a od značajki pojedinih stabala korišteni su prsni promjer, visina te starost stabla. Uzorkom je obuhvaćeno 531 stablo obične jele, kojemu je osim navedenih parametara izmjerena debljina kore na izvrtku dobivenom Presslerovim svrdlom u prsnoj visini. Istraživanje je provedeno u dinarskom dijelu areala obične jele u Republici Hrvatskoj (Uprave šuma Podružnice: Delnice, Gospić, Ogulin i Senj). Pri modeliranju debljine kore obične jele, u provedenoj parcijalnoj linearnoj korelaciji statistički značajnim varijablama pokazali su se: prsni promjer, visina stabla, starost stabla, i nadmorska visina. Bonitet sastojine u radu uzet je kao kategorijska varijabla. U statističkoj obradi korištene su varijable u izvornom i logaritamskom (ln) obliku. Koeficijenti determinacije dobiveni modeliranjem nalaze se u rasponu od 62,5 % do 70,4 %. Modeli s varijablama u logaritamskom obliku daju oko 4 % veće koeficijente determinacije u odnosu na modele s izvornim varijablama. Složeniji modeli sa svim značajnim varijablama ukupno povećavaju objašnjenu varijabilnost sa svega 3–4 %, pa se preporučuje uporaba jednostavnijeg modela s prsnim promjerom kao jedinom nezavisnom varijablom te korištenje logaritamske funkcije. Pokazalo se da bonitet sastojine značajno utječe na debljinu kore, te je kora deblja što je bonitet lošiji. U radu je istražen i utjecaj gospodarenja ovim sastojinama u prošlosti na debljinu kore. Rezultati ovih istraživanja ukazuju na manju debljinu kore u sastojinama kojima se intenzivno gospodarilo u odnosu na ekstenzivno gospodarene ili negospodarene sastojine, iako se iz rezultata ne može razlučiti koji dio te razlike je posljedica intenziteta gospodarenja, a koji nešto boljeg srednjeg boniteta intenzivno gospodarenih sastojina.*

*Ključne riječi:* debljina kore, obična jela, modeliranje, linearna korelacija.

### UVOD – Introduction

Pod rastom stabla podrazumijeva se biološki fenomen povećanja dimenzija stabla tijekom vremena, a pod prirastom povećanje dimenzija stabla u odrede-

nom vremenskom intervalu (Pranjić i Lukić 1997). Na prirast pojedinih stabala utječu razni ekološki čimbenici (opskrba hranivima, svjetlom i vodom), genetske predispozicije stabala, starost, stanje krošnje, razna oštećenja te uzgojni postupci (Becker 1991), odnosno pod utjecajem su stanišnih (ekoloških) i sastojinskih (strukturnih) datosti u kojima rastu (Božić 2003).

\* Doc. dr. sc. Mario Božić, izv. prof. dr. sc. Juro Čavlović, Mislav Vedriš, dipl. ing. šum., Zavod za izmjeru i uređivanje šuma, Šumarski fakultet Sveučilišta u Zagrebu

\*\* Mario Jazbec, dipl. ing. šum., Gornji Popovac 6a, 47240 Slunj

Ako promatramo prirast stabla, možemo ga razlučiti na prirast drva i prirast kore. Određivanje učešća kore dubećih stabala u ukupnoj masi stabla, obavlja se za potrebe uređivanja šuma i kod prethodnih radova u iskorišćivanju šuma (planiranje sječive bruto i neto mase drva). Tako su se istraživanjem debljine ili postotnog udjela kore obične jele kod nas bavili Klepac (1972) i Bojanin (1966a, 1966b). Osim kore jele,

istraživana je i kora drugih vrsta drveća (vidi npr. Klepac, 1957, 1958, Bojanin 1972, Krpan 1986, Johnson i Wood 1987, Prka 2004, Laasasenhoidr. 2005). Debljina kore jedna je od varijabli koja se mjeri u Nacionalnim inventurama šuma nekih europskih zemalja (Francuska, Grčka, Nizozemska, Portugal, Španjolska; vidi: Rondeux 1997), te u Hrvatskoj (Čavlović i Božić 2005).

### CILJ ISTRAŽIVANJA – Aim of research

Kako je temeljna zadaća uređivanja šuma optimalno planiranje i organizacija šumske proizvodnje (prostorno i vremenski), tako je poznavanje rasta i prirasta individualnih stabala i sastojina od primarnog značenja za njeno provođenje.

Prirast se u Hrvatskoj najčešće procjenjuje metodom izvrtaka na temelju prethodnog prirasta drva uzorkovanih stabala, pri čemu se prirast kore zanemaruje. Metodom izvrtaka trajno oštećujemo uzorkovana stabla. Zbog toga bi bilo dobro prirast određivati na temelju opetovanih, preciznih (na mm točno) izmjera, istih, obilježenih stabla (kao što je to npr. predviđeno metodologijom Nacionalne inventure, vidi Čavlović i Božić 2005), na dijelu ukupnih ploha na kojima se izmjera sastojina provodi. Tako dobiveni debljinski prirast predstavljat će bruto prirast stabla, a debljina i prirast kore ostaju nepoznati. Debljinu kore važno je znati bilo da nas zanima izračun bruto prirasta iz neto prirasta ili obrnuto. Debljinu kore važno je poznavati i kod

metode izvrtaka, jer se analiza provodi na 2,5 cm drva, pri čemu uzeti izvrtak treba biti duži za debljinu kore.

Temeljni je cilj ovog istraživanja načiniti modele koji objašnjavaju debljinu kore obične jele u dinarskim bukovo-jelovim šumama, na vapnenačko-dolomitnim podlogama (na kršu Hrvatske), kao funkciju pojedinih stanišnih (ekoloških) čimbenika i značajki pojedinih stabala. Od stanišnih će se čimbenika pri modeliranju koristiti nadmorska visina, nagib te orijentacija terena koji su se u nekim istraživanjima modeliranja prirasta stabala pokazali značajnima (vidi npr. Antonić 1996, Božić 2003). Od značajki pojedinih stabala pri modeliranju koristit će se prsni promjer, visina te starost stabla koji su se značajnim pokazali u sličnim istraživanjima (vidi npr. Johnson i Wood 1987).

Kako se tim šumama u prošlosti gospodarilo različitim intenzitetom, uzorkom će se obuhvatiti različiti intenziteti gospodarenja (uključujući prašume), s ciljem procjene utjecaja gospodarenja na debljinu kore.

### MATERIJAL I METODE – Material and methods

Područje istraživanja je dinarski dio areala obične jele u Republici Hrvatskoj, kojim su obuhvaćene četiri Uprave šuma Podružnice: Delnice, Gospić, Ogulin i Senj. Uzorkom je prekriveno cijelo navedeno područje (detaljnije vidi u: Božić 2003).

Varijable koje su se mjerile, registrirale, odnosno procjenjivale podijeljene su u dvije skupine. Prva skupina varijabli definira položaj i karakteristike plohe: zemljopisni položaj (prostorne koordinate), nadmorska visina, nagib te orijentacija terena. Prostorne su koordinate snimljene GPS uređajem. Nadmorska je visina određena na temelju snimljenih x i y koordinata i digitalnog elevacijskog modela terena (DEM). Nagib terena izmjeren je Vertexom, a orijentacija u stupnjevima busolom (obje u smjeru dominantnog pada terena).

Druga skupina varijabli definira karakteristike pojedinačnih jelovih stabala: prsni promjer, visina stabla, debljina kore. Prsni je promjer mjeran promjerkama s mm preciznosti, a visina stabla Vertexom. Debljina kore mjerena je na dugim (do središta stabla) izvrcima, uzetim na prsnoj visini, za potrebe drugih istraživanja. Nezavisno od toga kora je mjerena i pomičnim mjeri-

lom u otvorima koji su nastali uzimanjem izvrtaka. Na ova dva načina izmjerene debljine kore nisu pokazivale statistički značajnu razliku. Dugi su izvrci za potrebe ovoga rada poslužili za određivanje starosti stabala iznad prsne visine.

Ukupno je uzorkovano 531 jelovo stablo. Uzorkovana stabla nalazila su se na raznim nadmorskim visinama (510–1380 m), nagibima (0–32,7°) te orijentacijama terena.

Svakoj je plohi na temelju visina dominantnih stabala (jela) određen bonitet. Bonitet je određen kao kategorijska varijabla.

Podaci o nadmorskoj visini izračunati su iz DEM-a, na osnovi očitanih x i y koordinata. Radi izbjegavanja problema s orijentacijom terena kao cirkularnom varijablom, ona je prikazana kao kosinus izvorne orijentacije terena (Guisan i dr., 1998, 1999).

Izmjerene i izračunate varijable prebačene su u formiranu bazu podataka. Izračuni varijabli načinjeni su u programskom paketu Excel, a statističke obrade i izgradnja modela u programskom paketu Statistica 7.1. Pri modeliranju je korištena metoda općeg linearnog

modeliranja, pri čemu su varijable u dijelu modela korištene u izvornom, a u dijelu u logaritamskom obliku. Kao metoda optimizacije modela, odnosno odabira podskupa linearnih prediktora koji ulaze u konačni model, korištena je “Backward Stepwise” metoda (Ott

1993). Za pojedine logičke skupine varijabli stabala provedena je parcijalna linearna korelacija u svrhu preliminarnog odabira varijabli za višestruke regresijske analize. U svim je statističkim obradama zadana razina značajnosti od  $p = 0,05$ .

## REZULTATI S RASPRAVOM – Results and discussion

Provedenom parcijalnom linearnom korelacijom dobiveni su korelacijski koeficijenti prikazani u tablici 1.

Za izgradnju modela ovisnosti dvostruke debljine kore dalje su korištene samo statistički značajne varijable

Tablica 1. Koeficijenti parcijalne linearne korelacije ( $d_{kore}$  – dvostruka debljina kore,  $d$  – prsni promjer,  $h$  – visina stabla,  $starost$  – starost stabla iznad prsne visine,  $n.v.$  – nadmorska visina,  $nagib$  – nagib terena,  $orijentacija$  – orijentacija terena).

Table 1. Partial linear correlation coefficients ( $d_{kore}$  – double bark thickness,  $d$  – diameter at breast height,  $h$  – tree height,  $starost$  – tree age above breast height,  $n.v.$  – altitude,  $nagib$  – terrain slope,  $orijentacija$  – terrain orientation).

Varijabla <i>Variable</i>	$d$ <i>diameter</i>	$h$ <i>height</i>	$starost$ <i>age</i>	$n.v.$ <i>altitude</i>	$nagib$ <i>terrain slope</i>	$orijentacija$ <i>terrain orient.</i>
$d_{kore}$	0,79	0,64	0,33	0,29	0,06*	-0,08*

\* koeficijenti nisu statistički značajni

\* *coefficients are not statistically significant*

ble. Modeliranje je započeto s varijablom koja u provedenoj parcijalnoj linearnoj korelaciji najbolje korelira s debljinom kore, te su sukcesivno dodavane varijable prema njihovoj značajnosti u provedenoj parcijalnoj linearnoj korelaciji (visina stabla, starost i nadmorska visina). U novijim se istraživanjima (vidi npr. L a s a s e n a h o i dr. 2005) pri modeliranju debljine kore koriste varijable u logaritamskom obliku, stoga ćemo i mi uz modeliranje varijablama u izvornom obliku (kao što su to radili K l e p a c (1972) i B o j a n i n (1966b)) koristiti i varijable u logaritamskom obliku. U tablici 2. prikazani su prilagođeni koeficijenti determinacije za sve izgrađene modele.

Kao što je iz tablice vidljivo, već sam prsni promjer stabla objašnjava gotovo 63 % (ako se koriste izvorne

varijable) odnosno 67 % ukupne varijabilnosti debljine kore (varijable u ln obliku). Uvođenje dodatnih varijabli povećava stupanj objašnjene varijabilnosti do ukupno 65,82 odnosno 70,37 %. Kao što se vidi iz tablice, funkcija u logaritamskom obliku daje nam bolja izjednačenja u odnosu na izvorne funkcije (veći koeficijent determinacije). Na slici 1 prikazan je odnos između modeliranih dvostrukih debljina kore prema modelu 1, gdje se prsni promjer kao nezavisna varijabla koristi u izvornom (1.1) i ln obliku (1.2).

Na slici 2 prikazane su promjene debljine kore prema modelu 4.2, u kombinaciji po dvije nezavisne varijable, gdje su vrijednosti ostalih nezavisnih varijabli uprosječene.

Tablica 2. Koeficijenti determinacije pojedinih modela ( $d$  – prsni promjer,  $h$  – visina stabla,  $starost$  – starost stabla iznad prsne visine,  $n.v.$  – nadmorska visina).

Table 2. Determination coefficients of each model ( $d$  – diameter at breast height,  $h$  – tree height,  $starost$  – tree age above breast height,  $n.v.$  – altitude).

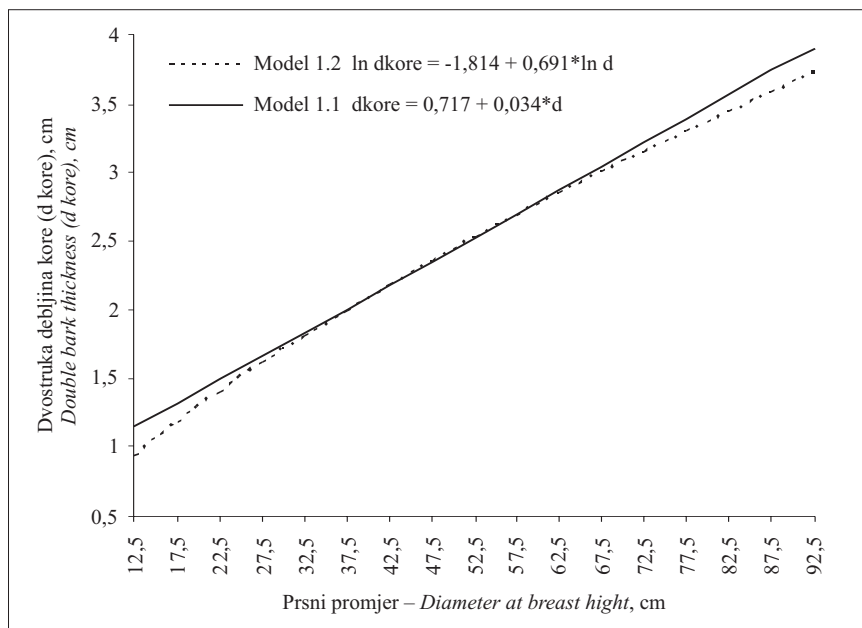
Model – Model	Varijable – Variables	Prilagođeni $R^2$ – Adjusted $R^2$
1.1	$d$	62,53 %
1.2	$\ln d$	66,58 %
2.1	$d, h$	63,12 %
2.2	$\ln d, \ln h$	68,22 %
3.1	$d, h, starost$	64,34 %
3.2	$\ln d, \ln h, \ln starost$	69,02 %
4.1	$d, h^*, starost, n.v.$	65,82 %
4.2	$\ln d, \ln h, \ln starost, \ln n.v.$	70,37 %

\* Varijabla je optimizacijom (Backward Stepwise) izbačena iz modela

\* *Variable excluded from model by optimization (Backward Stepwise)*

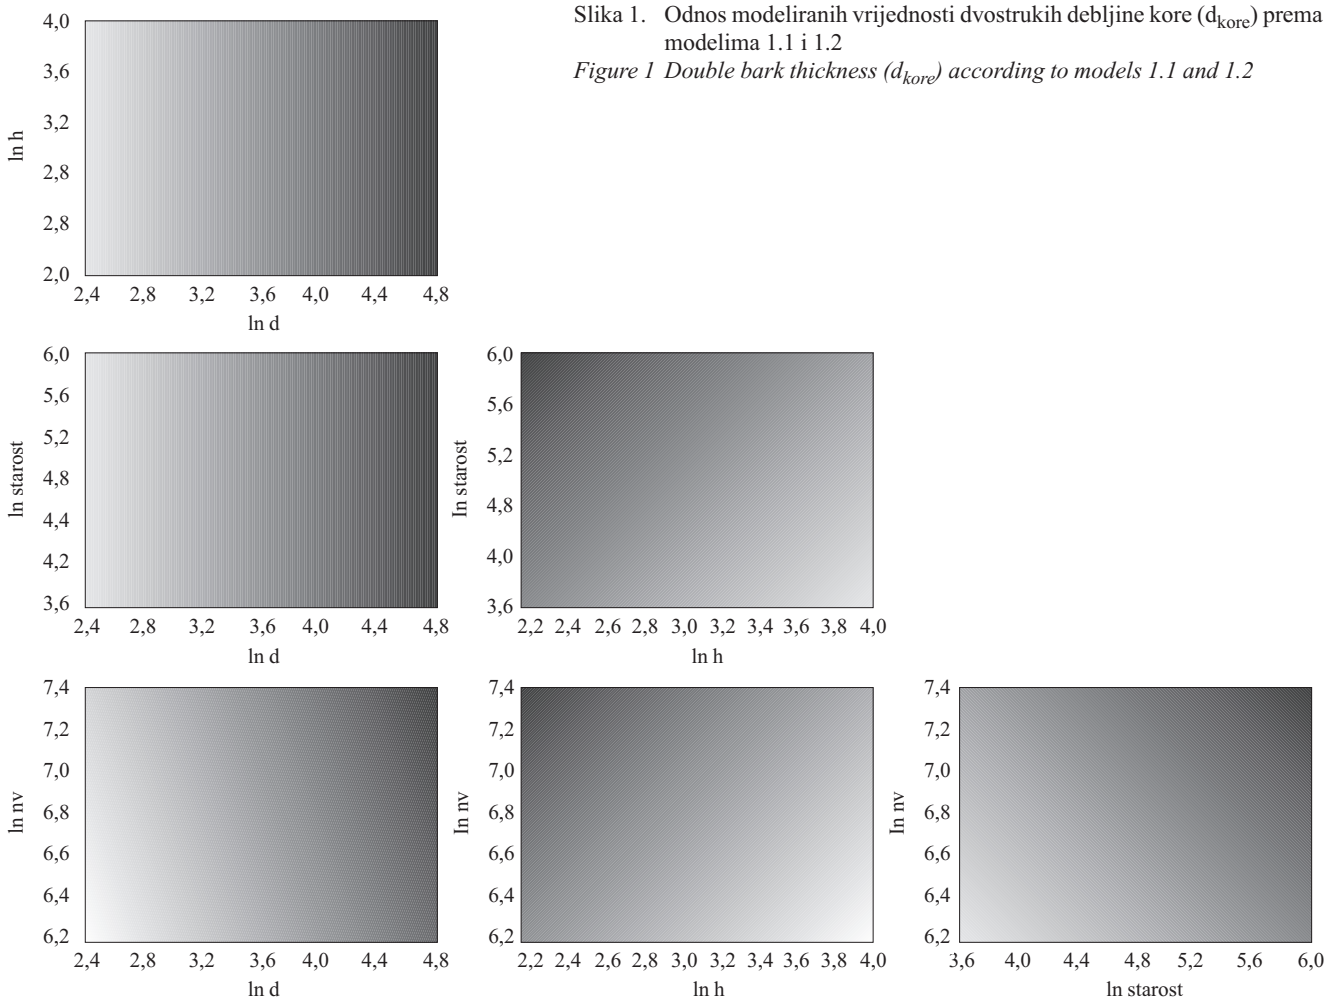
Iz slike je vidljivo da do povećanja debljine kore dolazi: uz isti promjer, što je stablo starije i nalazi se na većoj nadmorskoj visini; uz istu visinu, što je stablo starije i nalazi se na većoj nadmorskoj visini; uz istu starost, što se stablo nalazi na većoj nadmorskoj visini, a do smanjenja uz isti promjer, što je stablo više.

Na slikama 3 i 4 prikazan je odnos izmjerenih i modeliranih vrijednosti dvostruke debljine kore prema početnom i završnom modelu u kojima su korištene varijable u logaritamskom obliku, kao i razdioba učestalosti odstupanja.



Slika 1. Odnos modeliranih vrijednosti dvostrukih debljine kore ( $d_{kore}$ ) prema modelima 1.1 i 1.2

Figure 1 Double bark thickness ( $d_{kore}$ ) according to models 1.1 and 1.2



Slika 2. Promjene debljine kore prema modelu 4.2, u kombinaciji po dvije nezavisne varijable, gdje su vrijednosti ostalih nezavisnih varijabli uprosječene. Tamnija boja predstavlja deblju koru. U modelu su korištene logaritamske vrijednosti izvornih varijabli ( $d$  – prsni promjer,  $h$  – visina stabla, starost – starost stabla iznad prsne visine,  $n.v.$  – nadmorska visina).

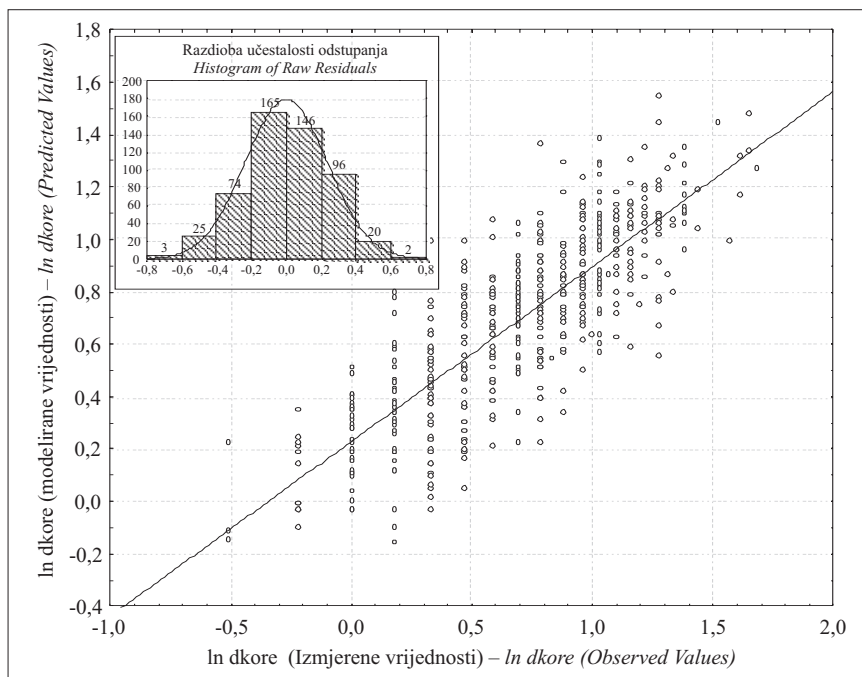
Figure 2 Bark thickness change according to model 4.2, two independent variables combined, other variables values are set to average. Darker areas stand for thicker bark. Logarithmic values of authentic variables are used ( $d$  – diameter at breast height,  $h$  – tree height, starost – tree age above breast height,  $n.v.$  – altitude).



Kod ovih kao i kod svih ostalih modela vidljiva je veća vrijednost modeliranih vrijednosti debljine kore kod stabala s tanjom korom, odnosno manja vrijednost debljine kore prema modelu u odnosu na izmjerene vrijednosti kod stabala s debljom korom. Te su razlike nešto veće kod jednostavnijih modela. Kako razlike između početnog i

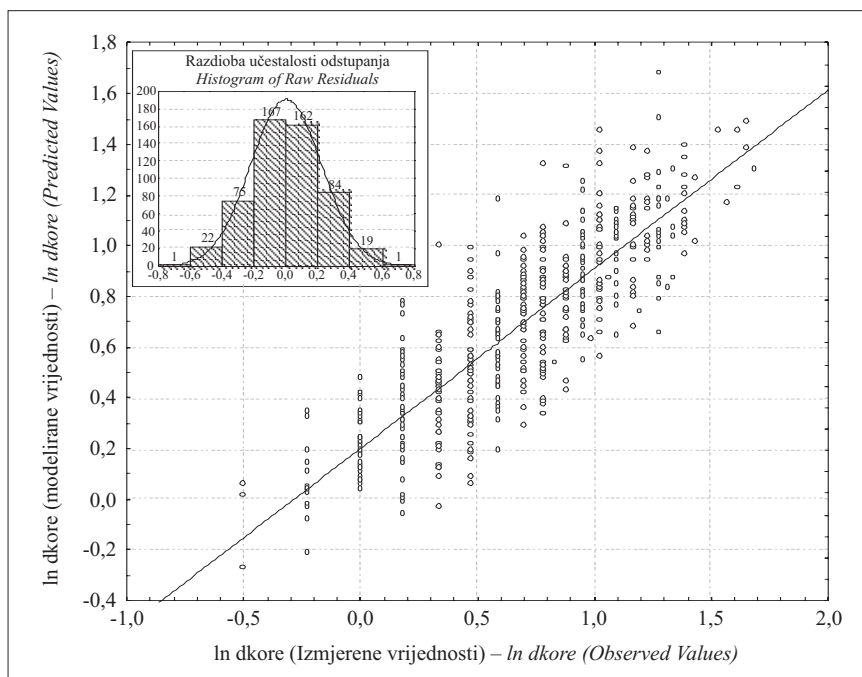
Slika 3. Odnos izmjerenih i modeliranih vrijednosti dvostruke debljine kore (u logaritamskom obliku), uz razdiobu učestalosti odstupanja, prema modelu 1.2.

Figure 3 Relationship between measured and modeled values of double bark thickness (in logarithmic form), according to model 1.2, with frequency distribution of residuals



Slika 4. Odnos izmjerenih i modeliranih vrijednosti dvostruke debljine kore (u logaritamskom obliku), uz razdiobu učestalosti odstupanja, prema modelu 4.2.

Figure 4 Relationship between measured and modeled values of double bark thickness (in logarithmic form), according to model 4.2, with frequency distribution of residuals



završnog modela nisu izrazite ni po spomenutim razlikama između izmjerenih i modeliranih vrijednosti, niti između učestalosti razdiobe njihovih odstupanja. Predlaže se uporaba jednostavnijeg logaritamskog modela, s prsnim promjerom (logaritamske vrijednosti) kao jedinom nezavisnom varijablom. Ovo posebno stoga, jer uključivanje

Tablica 3. Rezultati modeliranja dvostruke debljine kore jelovih stabala, korištenjem prsnog promjera u logaritamskom obliku kao nezavisne varijable ( $\ln d_{kore} = a + b * \ln d$ ). Modeliranje je provedeno za cijeli uzorak i po bonitetima.

Table 3 Results of modeling double bark thickness of fir trees, by using diameter at breast height in logarithmic form as an independent variable ( $\ln d_{kore} = a + b * \ln d$ ). Modeling is performed for the total sample and according to site class.

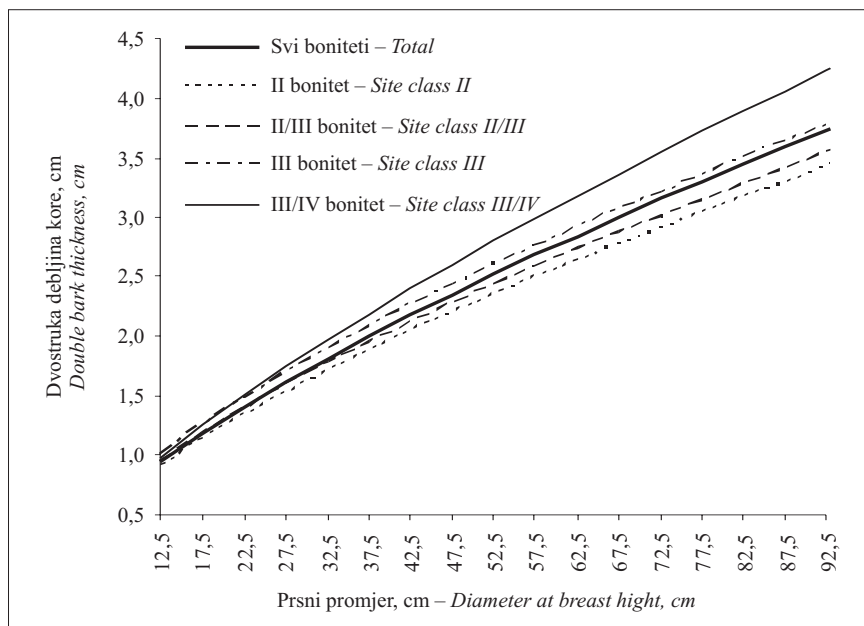
	Bonitet – Site class				
	Ukupno Total	II	II/III	III	III/IV
Broj stabala – Number of trees	531	95	165	117	64
Parametar a – Parameter a	-1,814	-1,767	-1,735	-1,670	-1,874
St. pogreška a – Stand. Error of a	0,078	0,167	0,136	0,169	0,231
Parametar b – Parameter b	0,691	0,662	0,662	0,662	0,733
St. pogreška b – Stand. Error of b	0,021	0,044	0,037	0,047	0,064
Koeficijent korelacije (R) – Correlation coefficient (R)	0,82	0,84	0,81	0,80	0,82
Prilagođeni R <sup>2</sup> - Adjusted R <sup>2</sup>	66,58 %	70,21 %	65,96 %	63,17 %	67,14 %

ostalim varijabli znatno poskupljuje posao pridobivanja podataka, uz neznatne promjene modeliranih vrijednosti.

Klepac (1972) napominje da postotak kore osim o fitocenozi u kojoj vrsta dolazi ovisi i o bonitetu, što je u suprotnosti s istraživanjima Krstanova i Wiedemanna (prema Bojaninu 1966a). Stoga smo u ovom radu proveli modeliranje po

Slika 5. Ovisnost dvostruke debljine kore o prsnom promjeru, za različite bonitete, prema modelu 1.2.

Figure 5 Double bark thickness depending on diameter at breast height, for different site classes, according to model 1.2.



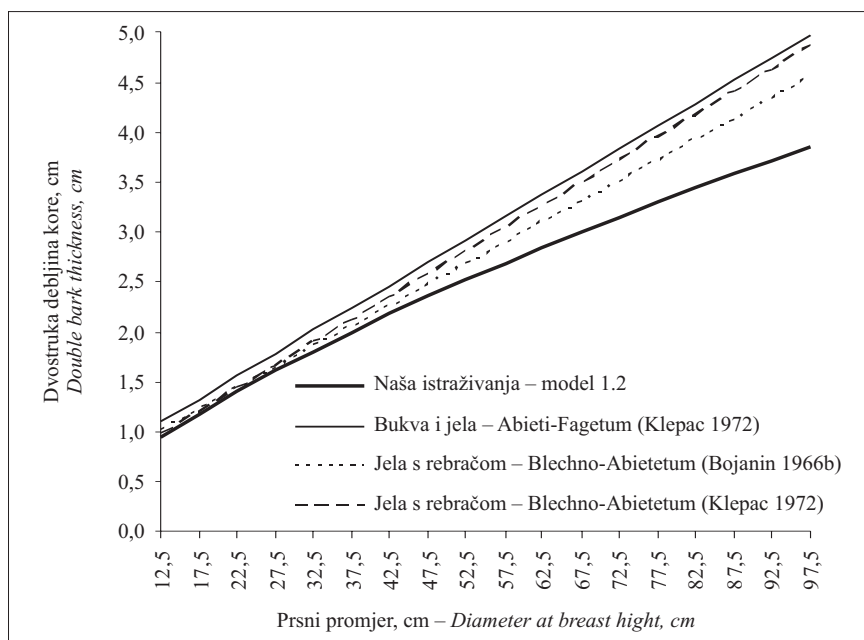
Slika 6. Usporedba debljine kore prema modelu 1.2 s Klepčevim i Bojaninovim rezultatima

Figure 6 Comparison of bark thickness according to model 1.2 with results of Klepac (1972) and Bojanin (1966)

bonitetnim razredima, za bonitete za koje smo imali uzorak s više od 60 stabala, pri čemu smo od nezavisnih varijabli koristili samo prsni promjer stabla u logaritamskom obliku (model 1.2). Rezultati ovog dijela modeliranja nalaze se u tablici 3.

Na temelju rezultata modeliranja načinjen je grafički prikaz odnosa dvostruke debljine kore u ovisnosti o prsnom promjeru, za različite bonitete, koji se nalazi na slici 5.

Kao što se iz slike vidi, pogoršanje boniteta značajno utječe na povećanje debljine kore. Do sličnih zaključaka dolaze Klepac (1972) za jelu te Johnson i Wood (1987) za kalifornijski bor. Klepac kakvoću staništa promatra kroz zajednicu koja na njemu raste. Tako napominje da je kora jelovih stabala najdeblja u fitocenozi jele s milavom, koja pridolazi na najlošijim staništima, odnosno najtanja u fitocenozi jele i rebrače koja pridolazi na najboljim staništima. Na slici je vidljivo da debljina kore unutar istog debljinskog stupnja ne raste linearno. Tako se razlika između debljine kore susjedna dva bonitetna razreda povećava smanjenjem dobrote staništa. To povećanje između II i II/III boniteta iznosi u prosjeku 3,5 %, II/III i III boniteta u prosjeku 6,8 %, a između III i III/IV boniteta 10,1 %.

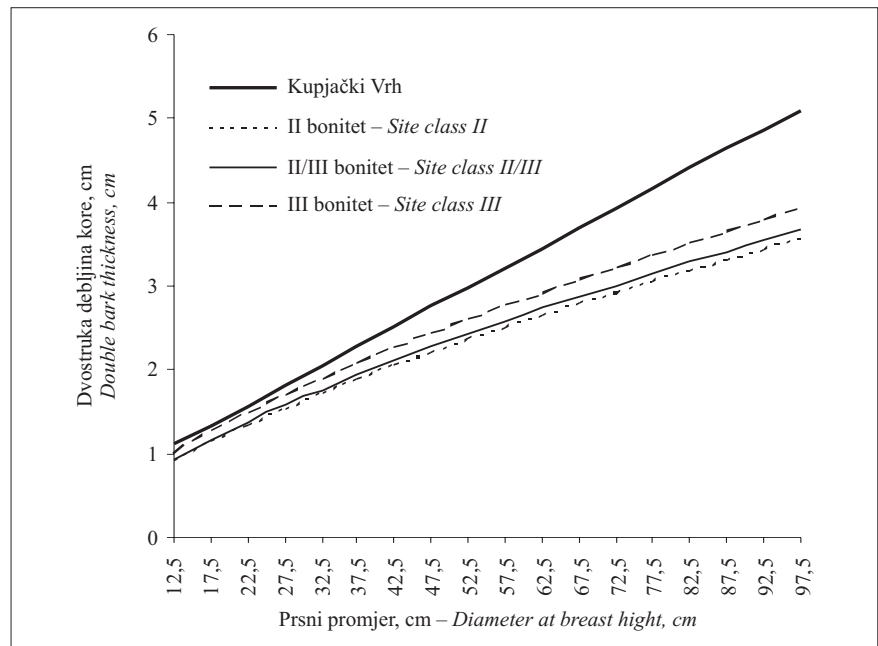


Koeficijenti determinacije prema modelu 1.1 nešto je niži (oko 1,5 %) u odnosu na istraživanja Bojanina (Bojanin 1996b), a vjerojatno je posljedica kompaktnosti njegovog uzorka, uzetog unutar jedne gospodarske jedinice. Drugi razlog mogao bi biti taj da se u njegovim istraživanjima ne radi o fitocenozi bukve i jele kao kod nas, nego o fitocenozi jele s rebračom. Modelirajući debljinu kore obične bukve Prka (2004) dobiva koeficijent determinacije od 66,59 %. Njegov je rezultat u usporedbi s našim (modelom 1.1) nešto bolji, ali tu se radi o drugoj vrsti drveća i što je još bitnije o drukčijem načinu gospodarenja (jednodobne šume). Debljinu kore u jednodobnim smrekovim sastojinama istraživali su Laasena i dr. (2005) te dobili koeficijent determinacije (66 %) istovjetan

našemu (s istim modelom – 1.2), dok im je koeficijent determinacije u kojemu se osim promjera pri modeliranju koriste i visina i starost stabla (u logaritamskom obliku – model 3.2) koeficijent determinacije znatno veći od našega (77 % u odnosu na 69 %). Uspoređujući njihov model:

Slika 7. Usporedba debljine kore Klepčevog uzorka za gospodarsku jedinicu “Kupjački vrh” s rezultatima modela 1.2 za II, II/III i III bonitet.

Figure 7 Comparison of bark thickness according to Klepac's sample for “Kupjački vrh” management unit with results of model 1.2 for site classes II, II/III and III.



In  $d_{kore} = -1,99 + 1,00 \ln d - 0,57 \ln h + 0,20 \ln starost$ , s našim modelom 3.2:  $\ln d_{kore} = -1,94 + 0,86 \ln d - 0,28 \ln h + 0,08 \ln starost$ , vidljiva je veća značajnost starosti i visine u njihovom (jednodobne sastojine), u odnosu na naš model (preborne sastojine).

Na slici 6. uspoređeni su rezultati naših (modela 1.2), s ranije provedenim Klepčevim i Bojaninovim istraživanjima.

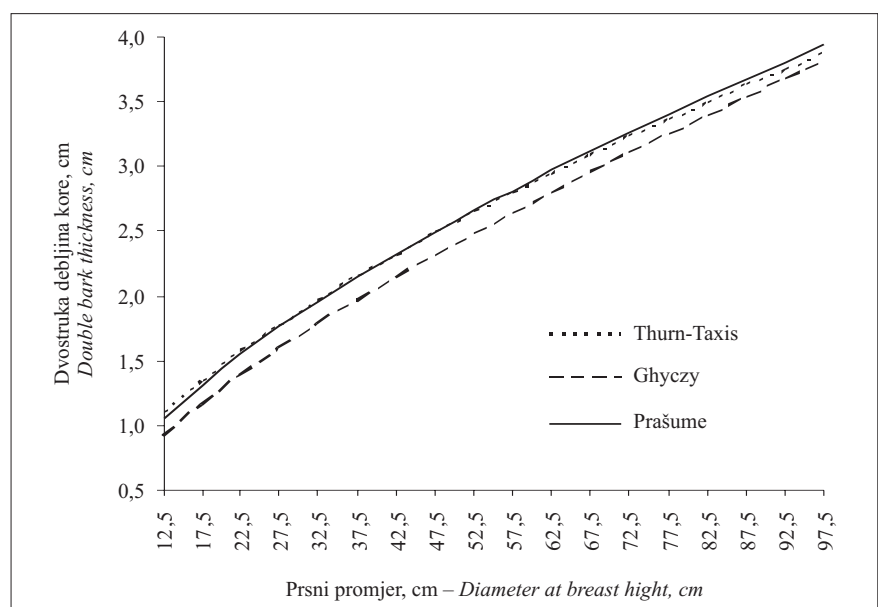
Iz slike je vidljivo da je debljina kore u cijelom rasponu promjera manja u našim nego u Klepčevim i Bojaninovim istraživanjima. Ta se odstupanja kreću do 0,68 cm kod Bojanina, odnosno 0,99 cm kod Klepca, u zajednici jele s rebračom, odnosno 1,11 cm u zajednici bukve i jele.

Postotni udio kore u ukupnom promjeru po našem modelu kreće se od 4,1 % kod najdebljih (97,5 cm) do 8,1 % kod najtanjih (12,5 cm) stabala, što je 0,2–0,3 % niže u odnosu na istraživanja Bojanina (Bojanin 1966b), odnosno 2,3 % niže do 1,7 % više u odnosu na istraživanja Klepca u zajednici bukve i jele (Klepac 1972).

S obzirom da nam bonitet sastojina u njihovim istraživanjima nije poznat, a kao što smo vidjeli on značajno utječe na debljinu kore, usporedit ćemo Klepčevu debljinu kore u parcijalnom uzorku iz gospodarske jedinice (g.j.) “Kupjački vrh”, s našim rezultatima za II, II/III i III bonitet, jer se jela u spomenutoj g.j. nalazi u dijelu sastojina na II, odnosno III bonitetu (slika 7.)

Slika 8. Usporedba debljine kore (model 1.2) različitih intenziteta gospodarenja promatranim sastojinama. Prašume – predstavljaju sastojine kojima se nije gospodarilo; Thurn-Taxis – sastojine kojima su vlasnici nekada bili njemački knezovi Thurn-Taxis i kojima se u to vrijeme ekstenzivno gospodarilo; Ghyczy – sastojine kojima su vlasnici nekada bili mađarski baruni Ghyczy i kojima se u to vrijeme intenzivno gospodarilo.

Figure 8 Comparison of bark thickness (model 1.2) in various management intensity conditions of analyzed stands. Prašume – stands with no management interventions; Thurn-Taxis – stands, formerly owned by German family Thurn-Taxis, that were extensively managed; Ghyczy – stands, formerly owned by Hungarian barons Ghyczy, that were intensively managed.



Kao i na prethodnoj slici, vidljivo je da su vrijednosti kore prema našem modelu znatno niže. Klepac je debljinu kore mjerio Švedskim instrumentom, te je bio svjestan činjenice da se njime mogu dobiti nešto veći rezultati uslijed zadiranja instrumenta u novi god. Kao što smo vidjeli (tablica 1 i 2) starost stabala također ima utjecaja na debljinu kore. Debljina kore je veća uz isti promjer stabla što je starost stabla veća. Tako je vrlo vjerojatno veća debljina kore kod Klepca i Bojanina posljedica ekstenzivnijeg gospodarenja tim sastojinama u prošlosti, gdje su stabla u prosjeku uz isti promjer bila starija od današnjih.

Kako su dosadašnji intenziteti gospodarenja utjecali na debljinu kore promotrit ćemo na slici 8.

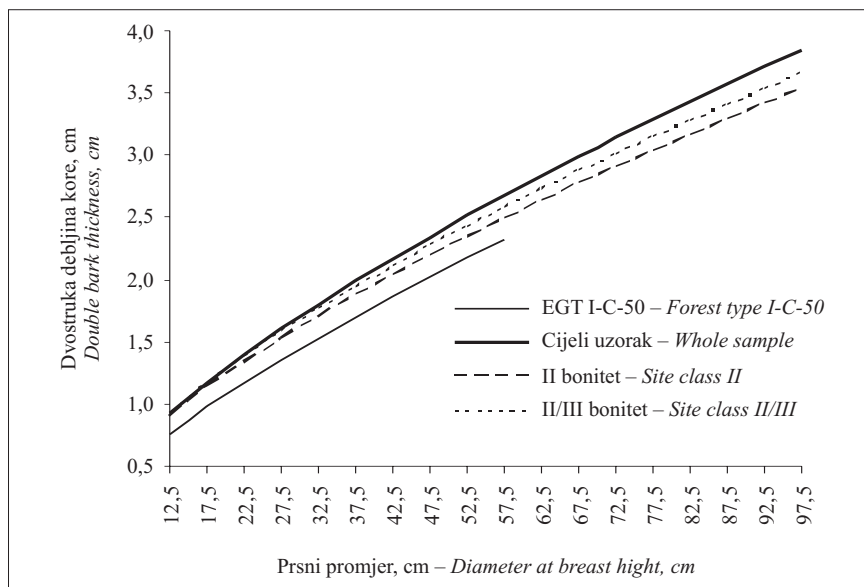
Iz slike je vidljivo da gotovo jednako debelu koru imaju negospodarene (Prašume) i ekstenzivno gospodarene sastojine (Thurn-Taxis), u odnosu na intenzivno gospodarene sastojine (Ghyczy). Ova je činjenica najvjerojatnije djelomično posljedica manje starosti stabala istih promjera u intenzivno gospodarenim sastojinama,

o čemu je već bilo riječi, ali i nešto lošijeg srednjeg boniteta sastojina prašumskog karaktera i sastojina kojima je gospodario Thurn-Taxis (između II/III i III), u odnosu na sastojine kojima je gospodario Ghyczy (između II i II/III boniteta).

Prilikom terenskih istraživanja uočeno je da je kora u dijelu sastojina (oko Otočca i Brinja, na nižim nadmorskim visinama) i kod debljih stabala glatka. Naknadnim uvidom u osnove gospodarenja uočeno je da su to sastojine koje pripadaju ekološko gospodarskom tipu (EGT) I-C-50, za koji u uputama za izradu karte EGT-ova gorskog područja Hrvatske (Cestar i dr. 1986) stoji da je karakteristična zajednica jele s mahovinom. S obzirom da sastojine ostalog dijela uzorka najvećim dijelom pripadaju zajednici bukve i jele, EGT-u I-C-10, provjerili smo postoji li osim razlike u teksturi i razlika u debljini kore stabala jele koja rastu u EGT-u I-C-50, prema ostalom uzorku. Rezultati te usporedbe prikazani su na slici 9.

Slika 9. Usporedba debljine kore (model 1.2) EGT-a I-C-50 u odnosu na cijeli uzorak, te poduzorke na II i II/III bonitetu. Srednji bonitet cijelog uzorka je II/III, a sastojina EGT-a I-C-50 između II i II/III.

Figure 9 Comparison of bark thickness (model 1.2) of Forest type (EGT) I-C-50 in relation to whole sample and subsamples on site classes II and II/III. Average site class of whole sample is II/III, whereas stands of Forest type (EGT) I-C-50 are between II and II/III site class.



Iz slike je vidljivo da stabla iz sastojina koje pripadaju EGT-u I-C-50 imaju znatno tanju koru u odnosu na ukupni uzorak, i to u cijelom rasponu prsnih promjera. To objašnjavamo specifičnim prilikama u kojima ona rastu – tlo prekriveno mahovinom koja dugo zadržava vlagu, kao i niske dimenzije sječive zrelosti, u odnosu na dominantni EGT I-C-10.

Na temelju modela dobivenih našim istraživanjima, može se procijeniti prirast kore. Prema modelu 1.2 za

cijeli uzorak, u povećanju prsnog promjera za 5 cm, kora sudjeluje (prirast kore u odnosu na ukupni prirast od 5 cm) s 0,14 cm odnosno 2,8 % kod stabala debljinskog stupnja 92,5 cm, te se njen udio povećava do 0,28 cm ili 5,6 % u debljinskom stupnju 12,5 cm. U odnosu na prirast drva te se vrijednosti kreću u rasponu 2,8 do 5,9 %.

## ZAKLJUČCI – Conclusions

Pri modeliranju debljine kore obične jele, u provedenoj parcijalnoj linearnoj korelaciji kao značajne varijable pokazale su se (prema redoslijedu značajnosti):

prсни promjer, visina stabla, starost stabla, i nadmorska visina. Nagib i orijentacija terena nisu se pokazale statistički značajnima.



Ukupno dobiveni koeficijenti determinacije nalaze se u rasponu od 62,5–70,4 %. Modeli s varijablama u logaritamskom obliku daju veće koeficijente determinacije u odnosu na modele s izvornim varijablama. Ta povećanja iznose oko 4 %.

S obzirom da znatno složeniji modeli sa svim značajnim varijablama ukupno povećavaju objašnjenu varijabilnost sa svega 3–4 % preporuča se uporaba jednostavnijeg modela s prsnim promjerom kao jedinom nezavisnom varijablom, te korištenje logaritamske funkcije.

Bonitet sastojine značajno utječe na debljinu kore, pri čemu taj rast unutar debljinskog stupnja ima oblik eksponencijalne krivulje te je kora deblja što je bonitet lošiji.

Rezultati ovih istraživanja dali su niže rezultate od ranije provedenih Klepčevih i Bojaninovih istraživanja.

Udio kore u ukupnom promjeru iznosi 4,1 % kod najdebljih (97,5 cm) do 8,1 % kod najtanjih (12,5 cm) stabala.

Rezultati ovih istraživanja ukazuju na manju debljinu kore u sastojinama kojima se intenzivno gospodari u odnosu na ekstenzivno gospodarene ili negospodarene sastojine. Iz rezultata ovih istraživanja ne možemo razlučiti koji dio te razlike je posljedica intenziteta gospodarenja, a koji nešto boljeg srednjeg boniteta intenzivno gospodarenih sastojina.

Kora jelovih stabala EGT-a I-C-50 (šuma jele s mahovinom) znatno je tanja od kore stabala ostalog dijela uzorka (većinom EGT I-C-10, šuma bukve i jele).

Udio kore u ukupnom debljinskom prirastu stabla iznosi od 2,8 % kod debelih do 5,6 % kod tankih stabala.

#### LITERATURA – References

- Antonić, O., 1996: Modeli utjecaja topoklime na vegetaciju krša. Disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, 156 str.
- Becker, M., 1991: Impact of climate, soil and silviculture on forest growth and yield. U: Landmann, G. (ur.), French research into forest decline. Ecole nationale du Génie rural, des Eaux et des Forêts, pp. 23–38, Nancy.
- Bojanin, S., 1966a: Debljina kore na raznim visinama od tla kod jelovih stabala. Drvna industrija 17 (4–5), str. 76–85, Zagreb
- Bojanin, S., 1966b: Debljina kore kod jelove oblovi- ne raznih debljina i njen odnos prema debljini stabala od kojih oblovina potječe. Drvna industrija 17 (11–12), str. 187–195, Zagreb
- Bojanin, S., 1972: Debljina i postotak kore oblovi- ne poljskog jasena (*Fraxinus angustifolia* Wahl). Šumarski list 96 (7–8), str. 267–277, Zagreb
- Božić, M., 2003: Utjecaj stanišnih i sastojinskih eleme- nata na prirast obične jele (*Abies alba* Mill.) u jelovim sastojinama na kršu u Hrvatskoj. Diser- tacija, Sveučilište u Zagrebu, Šumarski fakultet, 190 str., Zagreb
- Čavlović, J., M. Božić, 2005: Priručnik za nacio- nalnu inventuru šuma Republike Hrvatske, Za- greb.
- Guisan, A., J.-P. Theurillat, F., Kienast, 1998: Predicting the potential distribution of plant spe- cies in an alpine environment. J. Veg. Sci. 9, pp. 65–74.
- Guisan, A., S. B. Weiss, A.D. Weiss, 1999: GLM versus CCA spatial modeling of plant species distribution. Plant Ecol. 143, pp.107–122.
- Johnson, T. S., G. B. Wood, 1987: Simple linear model reliably predicts bark thickness of radiata pine in the Australian capital territory. Forest Ecology and Management, Volume 22, Issues 3–4, pp. 173–183.
- Klepac, D., 1957: Istraživanja o debljini kore u šum- ama hrasta lužnjaka i kitnjaka. Šumarski list br. 3–4/1957, str. 90–106, Zagreb.
- Klepac, D., 1958: Funkcionalni odnos između de- bljine kore i prsnog promjera za naše važnije listopadno drveće. Šumarski list br. 7–9/1958, str. 251–267, Zagreb.
- Klepac, D., 1972: Istraživanja o debljini i volumenu jelove kore u različitim fitocenoza- ma. Glasnik za šumske pokuse 16, Sveučilište u Zagrebu, Šu- marski fakultet, str. 105–122, Zagreb.
- Krpan, A. P. B., 1986: Kora bukve sa stanovišta eks- ploatacije šuma. Zbornik savjetovanja “Kolok- vij o bukvi”, Velika, Požega, 22. – 24. XI. 1984., str. 77–88, Zagreb.
- Laasasenaho, J., T. Melkas, S. Aldén, 2005: Modelling bark thickness of *Picea abies* with taper curves. Forest Ecology and Management 206, pp. 35–47.
- Ott, R. L., 1993: Introduction to Statistical Methods and Data Analysis. Duxbury Press, Belmont, 1152 str.
- Pranjić, A., N. Lukić, 1997: Izmjera šuma, 405 str. Zagreb.
- Prka, M., 2004: Debljina kore obične bukve (*Fagus sylvatica* L.) u sječinama Bjelovarske Bilogore. Šumarski list br. 7–8/2004., str. 391–403, Za- greb.

Rondeux, J., 1997: Überblick über nationale Waldinventuren in Europa. In: Testlauf zur Landeswaldinventur – Konzeption, Verfahrenstest, Ergebnisse. Heft 5 Schriftenreihe der Landesfor-

stverwaltung Nordrhein-Westfalen. Landesforstverwaltung Nordrhein-Westfalen, pp. 8–15. Düsseldorf.

*SUMMARY: Basic aim of research was to make correlation models that explain bark thickness of silver fir in dinaric beech – fir forests as a function of ecological and stand factors. Modeling was made by using spatial variables (altitude, terrain slope and orientation) and individual tree characteristics (diameter at breast height, tree height and age). Sample was taken by measuring given parameters of 531 fir trees in dinaric region of Republic of Croatia (Forest Administrations: Delnice, Gospić, Ogulin i Senj). Bark thickness was measured on increment cores taken at breast height by using Pressler's increment bore. Calculating was made by MS Excel application, and modeling bark thickness by Statistica 7.1 software. Diameter at breast height (DBH), tree height, tree age and altitude were variables with highest correlation coefficients to bark thickness that proved to be statistically significant, and were therefore used in model building. Models were made using partial linear correlation method, with variables calculated both in original and logarithmic form, considering  $p = 0,05$  as a limit of statistical significance. Determination coefficients of 8 models ranged from 62,5 % to 70,4 %, with logarithmic form variables showing on average 4 % higher values. Diameter at breast height proved to be basic variable for models, with determination coefficient of 63 %, while additional variables increased it at most to 70 %. Therefore it is suggested to use simple model for predicting bark thickness, with DBH in logarithmic form as the only independent variable. Impact of site quality on bark thickness was also studied, emphasizing that trees in lower quality stands have thicker bark. Models obtained by this research give lower values of bark thickness compared to former studies of Bojanin (1966a, 1966b) and Klepac (1972). Calculating percentage in tree dimensions, according to our model 1.2, bark make 4,1 % (diameter class 97,5 cm) to 8,1 % (diameter class 12,5 cm) of tree diameter, which is about 2,3 % lower to 1,7 % higher compared to their research. According to this study silviculture and management proved to influence bark thickness: trees in intensively managed stands have thinner bark. However this may be the result of difference in site quality of intensively managed and non-managed stands. Bark increment can also be predicted based on obtained models. According to model 1.2, bark contributes from 2,8 % (diameter class 92,5 cm). to 5,6 % (diameter class 12,5 cm) in tree diameter increment.*

*Key words: bark thickness, silver fir, modeling, linear correlation*