

Izvorni znanstveni članak
Original scientific paper

Prispjelo - *Received*: 15. 11. 2005.
Prihvaćeno - *Accepted*: 16. 05. 2006.

UDK: 630*52(497.13)

Hrvoje Marjanović^{1*}, Juro Čavlović²,
Vladimir Novotny¹, Tomislav Dubravac¹

PARAMETRIZIRANJE SIMULATORA BWINPRO: KOEFIČIJENTI MODELA ZA VISINU BAZE KROŠNJE (DULJINU DEBLA) I ŠIRINU KROŠNJE HRASTA LUŽNJAKA I OBIČNOG GRABA ZA PODRUČJE SREDIŠNJE HRVATSKE

*PARAMETRIZATION OF BWINPro SIMULATOR: COEFFICIENTS
FOR MODELS FOR CROWN BASE HEIGHT (STEM LENGTH)
AND CROWN WIDTH OF COMMON OAK AND EUROPEAN
HORNBEAM FOR STANDS IN CENTRAL CROATIA*

SAŽETAK

Kako bi se poboljšala kvaliteta simulacija rasta i razvoja sastojina, treba, prema vrstama i području, prilagoditi parametre modela koji se koriste. U ovom je radu obavljena parametrizacija modela širine krošnje (KB) i visine baze krošnje (KA) koji se koriste u simulatoru BWINPro (NAGEL i dr. 2002). Koeficijenti modela za KB i KA za hrast lužnjak i obični grab dobiveni su nelinearnom regresijom (NR), koristeći podatke izmjera na pokusnim plohama u sastojina hrasta lužnjaka i običnog graba (*Carpino betuli* – *Quercetum roboris* /Anić 1959/Rauš 1969) s područja središnje Hrvatske. Uspoređeni su rezultati dobiveni korištenjem originalnog skupa koeficijenata i skupa koeficijenata dobivenog NR. Pokazalo se kako se uporabom novih koeficijenata smanjila pristranost modela za KB, posebice za tanja stabla običnog graba. Korištenjem novih koeficijenata u modelu za KA hrasta, odnosno graba, smanjuje se i ukupna pristranost procjene. Međutim, te rezultate treba uzeti s rezervom jer vrijednosti nekih od koeficijenata imaju nisku razinu statističke značajnosti. Praksa poistovjećivanja visine baze krošnje s duljinom debla prouzrokuje stanovito umanjenje prediktivne vrijednosti te varijable, ali to nije od presudnog značaja te bi trebalo razmotriti i eventualno modificirati sam model za KA.

Ključne riječi: BWINPro, parametrizacija, duljine debla, visina baze krošnje

¹ Šumarski institut, Jastrebarsko, Cvjetno naselje 41, 10450 Jastrebarsko

² Šumarski fakultet, Sveučilište u Zagrebu, Svetošimunska c. 25, 10000 Zagreb

* Dopisni autor, tel.: +385 1 6273 015, fax: +385 1 6273 035, E-mail adresa: hrvojem@sumins.hr

UVOD

INTRODUCTION

Simulacijsko modeliranje rasta i razvoja sastojina, za to razvijenim simulatorima rasta, intenzivno se razvija od kraja osamdesetih godina prošlog stoljeća. U nas su matematički modeli i simulacije korišteni za simuliranje rasta i razvoja sastojina hrasta lužnjaka i običnog graba (PRANJIC i dr. 1988); procjenu volumena sastojina hrasta lužnjaka aerosnimkama (KUŠAN i KREJČI 1993); određivanje ovisnosti promjera horizontalne projekcije krošanja hrasta lužnjaka o totalnim visinama stabala (DUBRAVAC i KREJČI 1993); pri planiranju gospodarenja regularnim šumama sustavnom dinamikom (ČAVLOVIĆ 1996); za praćenje pomaka osnovnih sastojinskih elemenata u vremenu (NOVOTNY 1998); pri modeliranju prirasta stabala obične jele na temelju stanišnih i sastojinskih čimbenika (BOŽIĆ 2003).

Šire u europskim okvirima, primjer primjene simulatora rasta sastojina je projekt Europske unije završen 2004. godine, naslovljen "Implementing Tree Growth Models as Forest Management Tools" (QRLT 1999-31349, koordinator projekta bio je prof. dr. Hubert Hasenauer - WAFO, BOKU). U projekt je bilo uključeno sedam zemalja, a za svoj glavni cilj imao je komparaciju i primjenu postojećih simulatora rasta šumskih sastojina. U sklopu projekta su, između ostalog, analizirana četiri simulatora rasta: BWINPro (NAGEL 1997; NAGEL i GADOW 2003), Moses (HASENAUER 1994), Prognaus (MONSERUD i STERBA 1996; STERBA i MONSERUD 1997), i Silva (PRETZSCH 2002; PRETZSCH i dr. 2002).

Simulatori rasta - pri čemu se misli na računalne programe koji sadrže niz matematičkih modela s mogućnošću unosa, obrade podataka te prezentacije rezultata - imaju za cilj omogućiti šumskim stručnjacima i inženjerima jednostavan i pouzdan alat za analizu stanja i prognozu razvoja promatrane sastojine. Analiza stanja sastojine obuhvaća klasični prikaz pokazatelja dendrometrijskih i drugih varijabli kojima opisujemo određenu sastojinu (distribucija prsnih promjera, visinske krivulje, volumeni, očekivani prirast, sortimentna struktura, bioraznolikost i razni parametri sastojinske strukture). Druga važna komponenta simulatora je procjena, odnosno računanje stanja sastojine u zadanom trenutku u budućnosti. Rezultati analiza i simulacija najčešće su dani u obliku tablica, grafikona i 3D prikaza sastojine. U tom obliku rezultate može koristiti krajnji korisnik (npr. šumarski inženjer) ili ih se može povezati s drugim programskim paketima poput baze podataka, programa za inventuru i slično (DÖBBELER i dr. 2003).

Poznato je kako prirasno-prihodne tablice njemačkih autora, posebice za hrast lužnjak, nisu najprikkladnije za uporabu u našim sastojinama (ŠPIRANEC 1975a i b). S druge strane, kad je riječ o volumnim tablicama, često se u nedostatku originalnih koriste zamjenske, tj. volumne tablice slične vrste. Pri simulaciji, slično kao i kod upotrebe tablica, često se koriste parametri koji nisu optimizirani za danu vrstu ili područje. Pritom se može očekivati određeno smanjenje točnosti procjene. Sukladno tome, pri uporabi određenog modela ili simulatora rasta korisno je, kad god je to moguće, obaviti parametrizaciju matematičkih jednadžbi koje se koriste u proračunima. U idealnom slučaju, što je rijetkost, na raspolaganju je potpun skup ulaznih podataka te su svi parametri točno specificirani po vrsti i području.

Ranije spomenuti simulatori obavljaju simulacije na razini pojedinačnih stabala (eng. *single tree simulators*) te pri tome rabe niz podataka za svako pojedinačno stablo. Za odabrani simulator, u našem slučaju to je BWINPro, potpun skup ulaznih podataka o jednom stablu sadržavao bi vrstu, prsni promjer, visinu stabla, visinu baze krošnje, širinu krošnje i starost. Kako je postojanje potpunog skupa podataka u praksi rijetkost, simulatori rasta u pravilu imaju ugrađene rutine kojima, na temelju postojećih podataka i modela, za svako stablo generiraju one podatke koji nisu izmjereni.

Prilikom klasičnih izmjera na pokusnim ploham duljine debla mjere se najčešće samo na dijelu stabala, a širine krošanja mjere se rijetko. Kod operativne izmjere za potrebe uređivanja šuma širine krošanja uopće se ne mjere, što je razumljivo obzirom na opseg posla. Za simulaciju rasta i razvoja stabala u sastojini te određivanje sortimentne strukture potrebni su, između ostalog, podaci o visini, duljini debla i širini krošnje. Ako za pojedino stablo neke varijable nisu izmjereni, simulator BWINPro ih aproksimira odgovarajućim modelima (DÖBBELER i dr. 2003).

Ranije spomenuta neprikladnost njemačkih prirasno-prihodnih tablica za hrast implicitno ukazuje na različitu strukturu sličnih sastojina hrasta lužnjaka koje rastu u Njemačkoj i kod nas. Različita struktura, npr. broj stabala po ha povezana je u većoj ili manjoj mjeri s oblikom stabla. Tako će, uz pretpostavku kako sklop nije prekinut, broj stabala po ha biti obrnuto proporcionalan volumenu krošnje. Volumen krošnje je pri simulaciji prirasta ključan, ali treba istaknuti kako se, u pravilu, rijetko mjere varijable kojima se računa volumen krošnje. To stavlja veliku težinu na modele prema kojima se varijable krošnje procjenjuju, odnosno na koeficijente koji se koriste u tim modelima.

Sve navedeno ponukalo nas je da na temelju vlastitih podataka izračunamo koeficijente jednadžbi koje simulator BWINPro koristi za procjenu širine te visinu baze krošnje za hrast lužnjak i obični grab.

CILJ

AIM

Cilj ovog rada je, na temelju postojećih podataka u bazi EGTRH Šumarskog instituta, izračunati nove koeficijente jednadžbi koje se koriste za procjenu širine i visine baze krošnje za hrast lužnjak i obični grab te procijeniti kvalitetu procjene korištenjem starih i novih koeficijenata.

MATERIJALI I METODE

MATERIALS AND METHODS

Baza podataka i statistička obrada

Database and statistical analysis

Mreža pokusnih ploha Šumarskog instituta, Jastrebarsko razvija se i proširuje od samog osnutka Šumarskog instituta. Podaci prikupljeni tokom godina upisuju

se i čuvaju u bazi podataka EGTRH. Od različitih vrsta zajednica, za potrebe ovog rada odabrana je zajednica hrasta lužnjaka i običnog graba (*Carpino betuli* – *Quercetum roboris* /Anić 1959/Rauš 1969). Razlozi su manja kompleksnost regularnih sastojina u odnosu na preborne, važnost hrasta lužnjaka kao vrste te kvaliteta podataka s pokusnih ploha. U ovom radu korišteni su podaci izmjera na 17 pokusnih ploha lociranih u središnjoj Hrvatskoj (UŠP Karlovac, Bjelovar, Koprivnica), obavljenih u razdoblju 1991. – 1993. godine (DUBRAVAC 2002; MARJANOVIĆ 2005). Od podataka koji su tom prilikom mjereni, korišteni su prsni promjer, visina, dužina debla te prosječna širina krošnje. Mjerenja su ponovljena 2004./2005. godine, s ciljem testiranja kvalitete rezultata simulacija na temelju koeficijenata dobivenih u ovom radu.

Računanje koeficijenata nelinearne regresije i statistička obrada obavljeno je programskim paketom STATISTICA 6.1 (STATSOFT, INC. 2004). Računanje koeficijenata nelinearne regresije radi se iterativnom metodom, uz unaprijed određene početne vrijednosti koeficijenata (STATISTICA u startu sve koeficijente postavlja u 0,1). Međutim, ponekad se dogodi da neki od koeficijenata divergira, što upućuje na slabu prediktivnu vrijednost tog segmenta modela, npr. korekcijskog člana. U tom slučaju najčešće treba korigirati model.

Simulator rasta šumskih sastojina

Forest growth simulator

Za potrebe ovog rada, odabran je simulator BWINPro koji je razvijan na Zavodu za šumarska istraživanja Donje Saske od 1994. godine (NAGEL 1997; NAGEL i dr. 2002). Glavni razlozi za odabir spomenutog simulatora bili su njegova konstrukcija koja omogućava interaktivnu promjenu parametara, ulazni podaci sukladni su podacima koji se u nas uobičajeno mjere i dostupnost jer je program za istraživačke svrhe dostupan besplatno (NFV 2005). Ne manje važna bila je i činjenica kako postoji izvorni skup parametara za vrste hrast lužnjak i obični grab, dobivenih temeljem izmjera u njemačkim šumama, što omogućuje usporedbu s parametrima dobivenim izmjerama u domaćim sastojinama.

Model širine krošnje

Crown width model

U programu BWINPro širina krošnje, ako nije izmjerena, procjenjuje se prema modelu:

$$KB = (p_0 + p_1 \cdot d_{1,3}) \cdot \left[1 - e^{-\left(\frac{d_{1,3}}{p_3}\right)^{p_4}} \right] \quad (1)$$

gdje je KB širina krošnje, $d_{1,3}$ prsni promjer stabla, a p_0 , p_1 , p_3 , p_4 su koeficijenti. To je u osnovi linearni model s korekcijom (uglata zagrada). Vrijednosti koeficijenata u relaciji (1) dobivene su nelinearnom regresijom na temelju izmjerenih vri-

jednosti podataka za prsni promjer i prosječnu širinu krošnje. Računanje koeficijenta obavljeno je posebno za hrast lužnjak, odnosno obični grab. Za komparaciju su korištene izvorne vrijednosti koeficijenta, dobivene na temelju podataka njemačkog NFV-a (NAGEL i dr. 2002; SCHMIDT 2001; DÖBBELER i dr. 2003). Zbog malog broja podataka o širini krošnje za grab (svega 75 stabala), širinu krošnje graba Nagel izjednačava s linearnom funkcijom (DÖBBELER i dr. 2003). To se postiže kad se vrijednost korekcijskog člana postavi u 1, na način da se koeficijenti p_3 , odnosno p_4 postave u 0, odnosno 1, respektivno.

Model visine baze krošnje (duljine debla)

Height of crown base (stem length) model

U Hrvatskoj se pri izmjeri u sastojinama uz visinu stabla često mjeri i duljina debla koja se u nas poistovjećuje s visinom na kojoj počinje krošnja (DUBRAVAC 2002). To poistovjećivanje kod modeliranja rasta nekog stabla može biti problematično. Na primjer, kod pravilno razvijenih stabala bez rašlji duljina debla s vremenom uglavnom raste. S druge strane, ako stablo ima rašlje, duljina debla tokom vremena praktički ostaje konstantna. Za modeliranje rasta stabla korisnija je varijabla visine baze krošnje. Prema NFV-u, visina baze krošnje kod listača definirana je kao početak prve primarne zelene grane (DÖBBELER i dr. 2003, str. 75 prema *Niedersächsische Forstliche Versuchsanstalt* 1996). Živići i sekundarna krošnja ne uzimaju se u obzir. Rašlje i strme grane uzimaju se kao visina početka krošnje samo ako imaju karakter primarnih grana. Kako se kod nas u praksi na radi takva distinkcija, u ovom je radu za visinu baze krošnje korištena odgovarajuća vrijednost duljina debla.

BWINPro za procjenu visine početka krošnje koristi model (SCHMIDT 2001):

$$KB = h \cdot \left(1 - e^{-abs \left[p_0 + p_1 \frac{h}{d} + p_2 \cdot d + p_3 \cdot \ln(H100) \right]} \right) \quad (2)$$

gdje je KA visina početka krošnje, h visina stabla, d prsni promjer stabla, $H100$ dominantna visina (prosječna visina 100 najdebljih stabala po ha), a p_0, p_1, p_2, p_3 su koeficijenti.

REZULTATI I RASPRAVA

RESULTS AND DISCUSSION

Parametriziranje modela širine krošnje

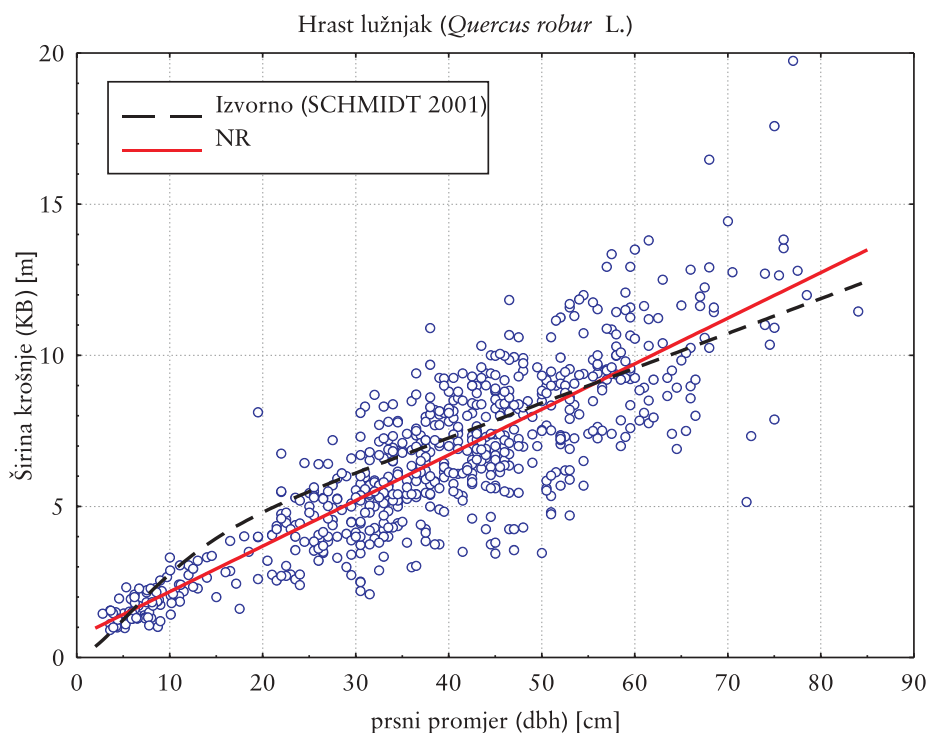
Parameterizations of crown width model

Izvorni koeficijenti modela (1) određeni su na temelju podataka o širinama krošanja od 1225 stabala hrasta i samo 75 stabala graba (DÖBBELER i dr. 2003). Mi smo na raspolaganju imali podatke o prsnim promjerima i širinama krošnji za

Tablica 1. Koeficijenti modela za širinu krošnje danog relacijom (1) za hrast lužnjak i običnog graba dobiveni nelinearnom regresijom (NR)

Table 1. Coefficients of crown width model (1) for Common oak and European hornbeam obtained through nonlinear regression

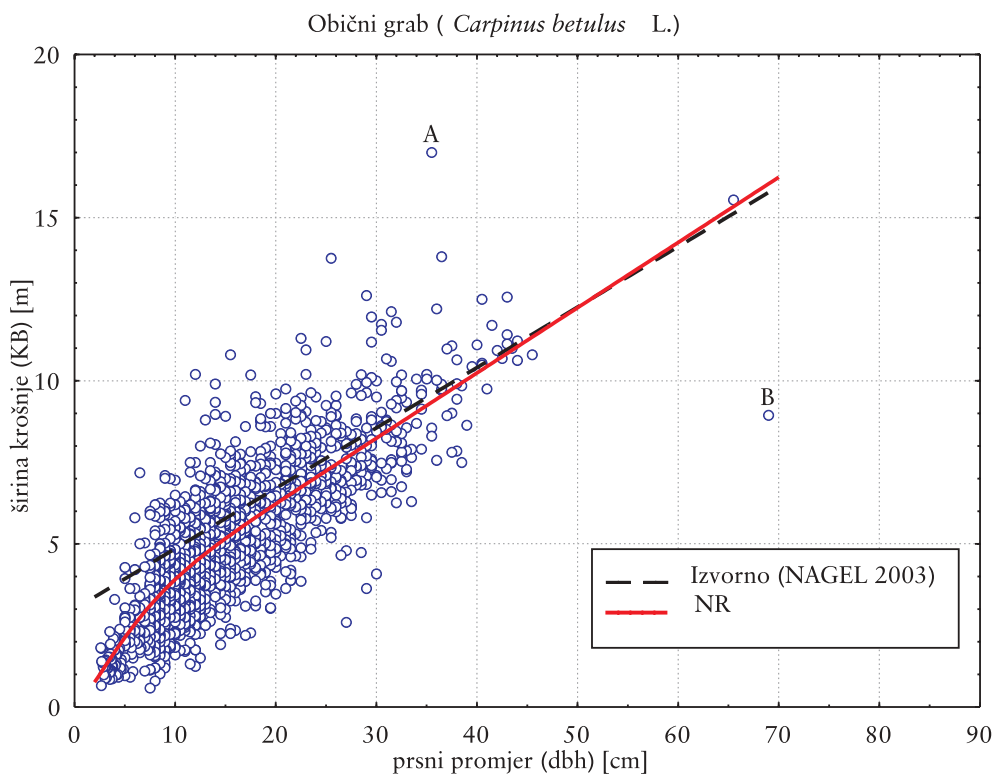
Koeficijent Coefficient	Hrast - oak (N=693, $r^2=0,72$)				Grab - hornbeam (N=1842, $r^2=0,67$)			
	Vrijednost Value	Std. pogr. Std. err.	t-vrijednost t-value	p-nivo p-level	Vrijednost Value	Std. pogr. Std. err.	t-vrijednost t-value	p-nivo p-level
p_0	0,6718	0,1483	4,5230	<0,0001	2,2392	0,2287	9,7910	<0,0001
p_1	0,1508	0,0035	42,5752	<0,0001	0,2000	0,0089	22,5733	<0,0001
p_3	0,000001	-	-	-	4,7354	0,4515	10,4877	<0,0001
p_4	1,0	-	-	-	1,2505	0,1842	6,7884	<0,0001



Slika 1. Ovisnost širine krošnje (KB) hrasta lužnjaka o prsnom promjeru (dbh), s krivuljama izjednačenja. Isprekidana crna linija – izvorni koeficijenti; puna crvena – koeficijenti dobiveni nelinearnom regresijom (NR)

Figure 1. Dependence of crown width (KB) on diameter at breast height (dbh) for Common oak. Dashed black line is fitting curve using original coefficients; full red line is fitting curve using coefficients obtained by nonlinear regression

693 stabla hrasta lužnjaka i 1842 stabla običnog graba. Koeficijenti relacije (1) dobiveni nelinearnom regresijom (NR) na spomenutom skupu podataka, dani su za hrast i grab u Tablici 1. Iz Tablice 1 vidljivo je kako je za koeficijente postignut vi-



Slika 2. Ovisnost širine krošnje graba o prsnom promjeru. Isprekidana crna linija prikazuje krivulju izjednačenja uz korištene izvorne koeficijente Nagela, a puna crvena uz korištene koeficijente dobivene NR-om. Točke A i B izuzete su iz računanja koeficijenta jer predstavljaju tzv. "outliers"

Figure 2. Dependence of crown width on diameter at breast height (dbh) for European hornbeam. Dashed black line is fitting curve using original coefficients; full red line is fitting curve using coefficients obtained with nonlinear regression. Points marked A and B are outliers and were not used in calculations

soki nivo značajnosti (p -nivo $< 10^{-4}$). Ovisnost širine krošnje hrasta lužnjaka o prsnom promjeru, prikazana je na Slici 1, zajedno s krivuljama izjednačenja s izvornim koeficijentima i koeficijentima dobivenim NR-om. Na spomenutoj Slici 1, može se pretpostaviti kako je ovisnost širine krošnje o prsnom promjeru za hrast linearnog oblika. Pretpostavku je potvrdio račun jer su pri računanju koeficijenata NR-om, koeficijenti p_3 i p_4 divergirali. Stoga je korekcijski član u modelu za KB trebalo ukloniti. To je učinjeno na način da se za početnu vrijednost koeficijenta p_3 postavi 0,000001, a koeficijenta p_4 vrijednost 1. U tom slučaju tokom izračuna spomenuti koeficijenti praktički ne mijenjaju vrijednost, što je zapravo posredan način lineariziranja modela (1).

Na Slici 1. može se usporediti kvaliteta izjednačenja krivuljom prema izvornim koeficijentima te krivuljom (tj. pravcem) s koeficijentima iz Tablice 1. za hrast. Evidentno je kako u ovom slučaju pravac bolje opisuje podatke, posebice u području manjih prsnih promjera, kad funkcija s izvornim koeficijentima precjen-

Tablica 2. Deskriptivna statistika reziduala: model (1) procjene širine krošnje hrasta lužnjaka i običnog graba s izvornim i koeficijentima dobivenim NR-om.

Table 2. Descriptive statistics of residuals: model (1) for crown width using original coefficients and NR's coefficients for Common oak and European hornbeam

Statističko obilježje – <i>Statistic</i>	Hrast lužnjak (<i>Quercus robur</i> L.) <i>Common oak</i>		Obični grab, (<i>Carpinus betulus</i> L.) <i>European hornbeam</i>	
	izvorno (<i>Original</i>)	NR	izvorno (<i>Original</i>)	NR
N – N	693	693	1842	1842
Aritm. sredina reziduala – <i>Residual mean</i>	-0,4322	0,0000	-0,7906	0,0000
Median – <i>Median</i>	-0,4790	-0,0238	-0,9175	-0,0498
Std.dev. – <i>Std. dev.</i>	1,6029	1,5430	1,3556	1,2877
Std. pogr. – <i>Std. err.</i>	0,0609	0,0586	0,0316	0,0300
Skošenost – <i>Skewness</i>	0,4110	0,1083	0,6165	0,5135
Std.pogr. skošenosti – <i>Std.err. skewness</i>	0,0928	0,0928	0,0570	0,0570
Spljoštenost – <i>Kurtosis</i>	1,8233	1,5469	1,0415	1,3353
Std.pogr. spljoštenosti – <i>Std. err. kurtosis</i>	0,1854	0,1854	0,1140	0,1140


juje širinu krošnje te u slučaju velikih prsnih promjera, kad podcjenjuje širinu krošnje.

U slučaju običnog graba pokazalo se kako je situacija obrnuta. Nagel je za parametrizaciju modela (1) na raspolaganju imao podatke od samo 75 stabala graba te je stoga ovisnost širine krošnje o prsnom promjeru linearizirao. U našem slučaju postojao je puno veći skup podataka za grab pa nije trebala linearizacija *a priori*.

Na temelju podataka za 1842 stabla graba, nelinearnom su regresijom izračunati koeficijenti p_0, p_1, p_3, p_4 u relaciji (1). Kao što se može primijetiti na Slici 2, i u slučaju graba primjetno je kako dobivena krivulja izjednačenja bolje naliježe od originalne izvorne. Ovdje treba napomenuti kako su točke označene slovima A i B na Slici 2. izuzete iz računanja koeficijenata nelinearne regresije. Razlog je njihovo veliko odstupanje od osnovnog "oblaka" podataka. Opravdanje za to nalazimo u činjenici kako čak i ako su podaci točni, s velikom vjerojatnošću može se reći kako točke A i B ne oslikavaju zakonitost koja se pokušava opisati krivuljom izjednačenja, već su vjerojatno posljedica nekih ekstremnih slučajeva ili neutvrđene pogreške. Pritom ipak treba naglasiti kako te točke ne smijemo olako odbaciti jer nam baš one kazuju kolika su moguća odstupanja od krivulje izjednačenja.

Ako analiziramo rezultate iz Tablice 2, možemo zaključiti kako je kvaliteta predikcije poboljšana korištenjem koeficijenata dobivenih NR-om. Smanjena je pristranost u procjeni širine krošnje kod tanjih stabala hrasta i graba, vidljiva u smanjenju skošenosti distribucije reziduala (za hrast i grab) i povećanju koeficijenta spljoštenosti za grab (ušiljena distribucija znači kako se reziduali grupiraju oko nule, više no što je očekivano prema normalnoj razdiobi). S druge strane uzrok smanjenja koeficijenta spljoštenosti u slučaju hrasta posljedica je smanjenja skošenosti te pravilnije distribucije reziduala.

Na Slici 3 prikazana je usporedba rezultata predikcije širine krošnje temeljem izvornih i koeficijenata dobivenih NR, s izmjerenim rezultatima plohe P14 u sa-



Slika 3. Tlocrt plohe P14 u sastojini staroj 18 godina. Svijetlozeleni krugovi predstavljaju krošnje hrasta, a tamnozeleni graba. Vrh: prosječne izmjerene širine krošanja s njihovim rasporedom u sastojini; sredina: širine krošanja procijenjene po modelu (1) s izvornim koeficijentima; dno: isto s koeficijentima dobivenima nelinearnom regresijom

Figure 3. Plan of the plot P14 in the 18 years old stand. Light green circles represent oak crowns and dark green hornbeam crowns. Top: averaged measured crown widths and their position in the stand; middle: crown widths estimated with the model (1) using original coefficients; bottom: using coefficients obtained through nonlinear estimation

stojini staroj 18 godina. Prikaz je načinjen programom BWINPro koji omogućuje 3D prikazivanje sastojine iz bilo kojeg kuta, u ovom slučaju ptičje perspektive.

Parametriziranje modela visine baze krošnje (duljine debla)

Parameterizations of crown base model (stem length)

Visina baze krošnje danog stabla u modelu (2) ovisi o njegovoj visini h , prsnom promjeru d i visini dominantnoj visini $H100$. Usporedbom vrijednosti visina dobivenih iz prve i druge izmjere utvrđeno je kako se kod nekih ploha možda dogodila sistematska pogreška pri izmjeri visina. Stoga je obavljena selekcija ploha prema kvaliteti podataka, što je detaljno opisano u magistarskom radu Marjanovića (2005). Od 17 ploha, za potrebe računanja koeficijenata odabrano je njih 8 te je za računanje koeficijenata modela (2) poslužilo ukupno 635 stabala.

Kako bi računanje koeficijenata bilo moguće, treba izračunati dominantnu visinu $H100$ hrasta, odnosno graba za svaku plohu. Dominantne visine izračunali smo programom BWINPro. To je dopušteno stoga što se pri računanju njihove vrijednosti ne koriste aproksimacije, već se dominantne visine računaju na temelju izmjerenih podataka o visinama stabala. Vrijednosti dominantnih visina hrasta i graba dane su u Tablici 3.

Nakon što su izračunate dominantne visine $H100$, nelinearnom su regresijom izračunati i koeficijenti p_0, p_1, p_2, p_3 . Vrijednosti dobivenih koeficijenata, za hrast lužnjak i obični grab, nalaze se u Tablici 4. Iz tablice je razvidno kako kod hrasta nivo značajnosti od 95% (p-nivo manji od 0,05) nije postignut niti za jedan koeficijent. S druge strane, kod graba je za sve koeficijente, osim za p_2 , nivo značajnosti visok (p-nivo $< 0,05$). Takav rezultat navodi na zaključak kako treba biti oprezan u prihvaćanju rezultata procjene dužine debla za hrast te bi trebalo razmisliti o modifikaciji modela. S druge strane, za grab se pokazalo da je model razmjerno dobar jer su svi koeficijenti, osim p_2 , statistički značajni.

Usporedba izmjerene i duljine debla predviđene po modelu (2), uz uporabu izvornih i koeficijenata dobivenih NR-om, prikazana je na Slici 4 za hrast lužnjak,

Tablica 3. Dominantne visine (H100) za hrast i grab dobivene na temelju podataka izmjere iz 1991.-1993., dobivene simulatorom BWINPro

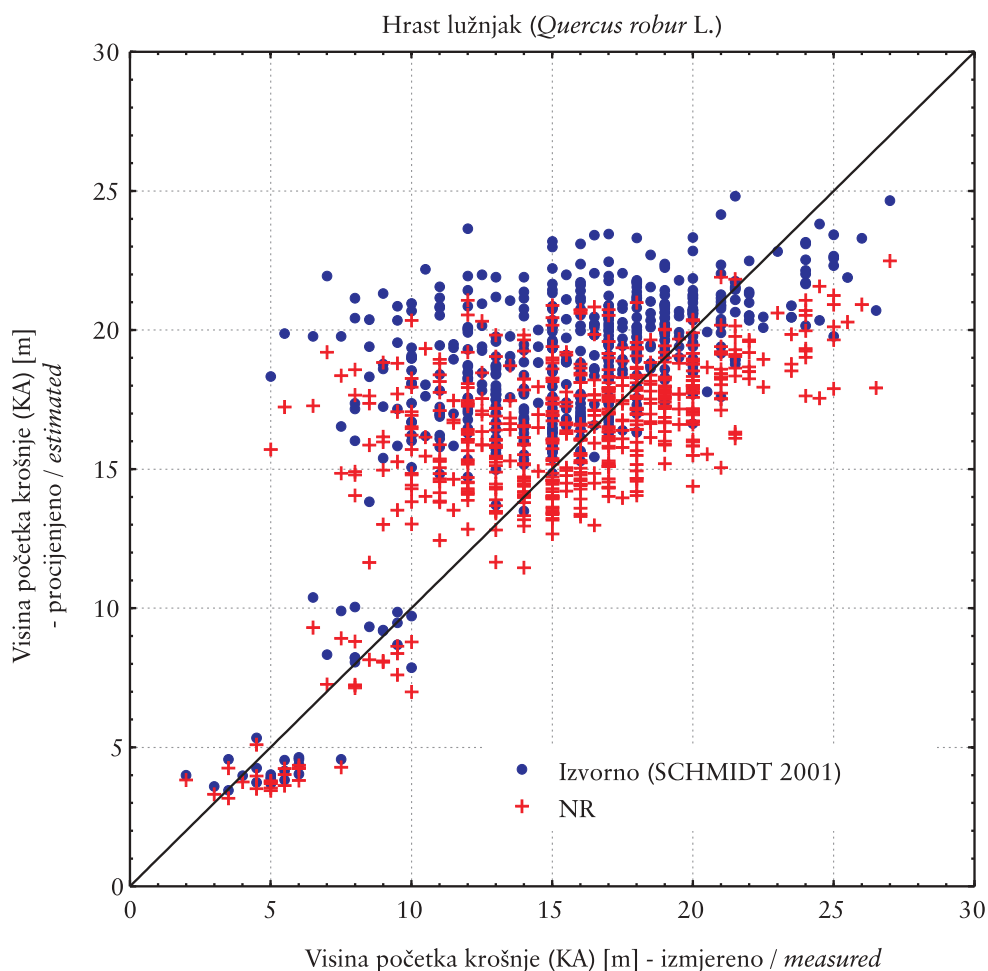
Table 3. Dominant heights (H100) of oak and hornbeam, based on the measurements took in 1991-1993 calculated with simulator BWINPro.

Ploha – Plot	Starost sastojine [god] Stand age – [yrs]	H100 [m]	
		hrast lužnjak Common oak	obični grab European hornbeam
P14	18	9,0	8,2
P11	56	27,5	18,4
P35	66	26,1	17,4
P21	77	28,2	26,9
P25	87	29,1	22,1
P28	102	32,1	19,1
P26	117	33,2	17,1
P27	118	31,9	20,7

Tablica 4. Koeficijenti modela visine početka krošnje (duljine debla) za stabla hrasta lužnjaka i običnog graba, dobiveni nelinearnom regresijom

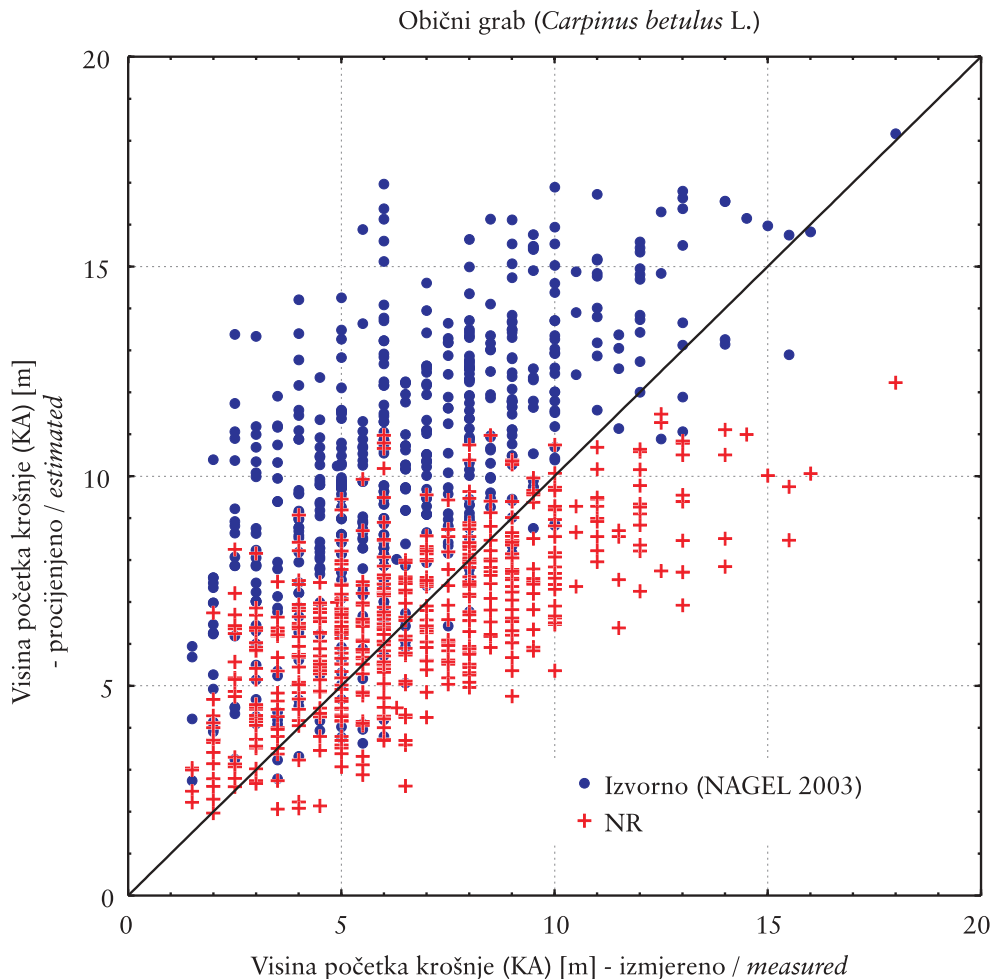
Table 4. Coefficients of crown base (stem length) model for Common oak and European hornbeam obtained by nonlinear regression

Koeficijent Coefficient	Hrast - oak (N=314, $r^2=0,62$)				Grab - hornbeam (N=321, $r^2=0,51$)			
	Vrijednost Value	Std. pogr. Std. err.	t-vrijednost t-value	p-nivo p-level	Vrijednost Value	Std. pogr. Std. err.	t-vrijednost t-value	p-nivo p-level
p0	-0,1204	0,4009	-0,3004	0,7641	-0,5108	0,1990	-2,5663	0,0107
p1	0,2867	0,1688	1,6985	0,0904	0,3577	0,0625	5,7269	0,0000
p2	0,0010	0,0023	0,4198	0,6749	0,0005	0,0017	0,2609	0,7943
p3	0,2093	0,1215	1,7230	0,0859	0,2014	0,0617	3,2625	0,0012



Slika 4. Odnos procijenjene i izmjerene visine baze krošnje za hrast lužnjak, koristeći koeficijente Nagela (plave točke) i koeficijente dobivene NR (crveni križići)

Figure 4. Relation between measured and estimated height of crown base for Common oak using coefficients by Nagel (blue dots) and coefficients obtained by nonlinear regression (red crosses)



Slika 5. Odnos procijenjene i izmjerene visine baze krošnje za obični grab, koristeći izvorne (plave točke) i koeficijente dobivene NR-om (crveni križići)
Figure 5. Estimated vs measured heights of crown base for European hornbeam using original (blue dots) and coefficients obtained by nonlinear regression (red crosses)

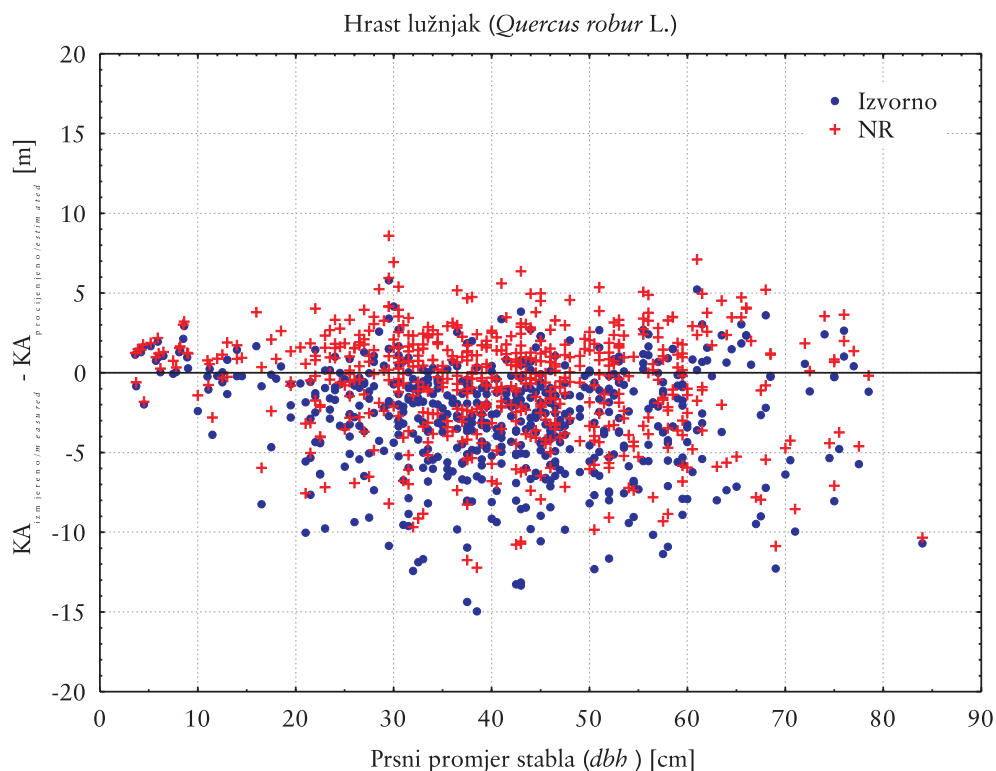
odnosno Slici 5. za obični grab. Plavim točkama označene su vrijednosti duljine debla predviđene koristeći izvorne koeficijente, a crvenim križićima vrijednosti dobivene korištenjem koeficijenata dobivenih NR-om.

U Tablici 5 dana je deskriptivna statistika reziduala model (2) procjene visine baze krošnje hrasta lužnjaka i običnog graba s izvornim koeficijentima i koeficijentima dobivenim NR-om.

Ostaje još provjeriti postoji li ovisnost reziduala o prsnom promjeru. Rezultati su prikazani na Slikama 6 i 7 iz kojih je razvidno kako su reziduali koristeći koeficijente dobivene NR-om ravnomjerno raspoređeni oko nule. To je i očekivano jer

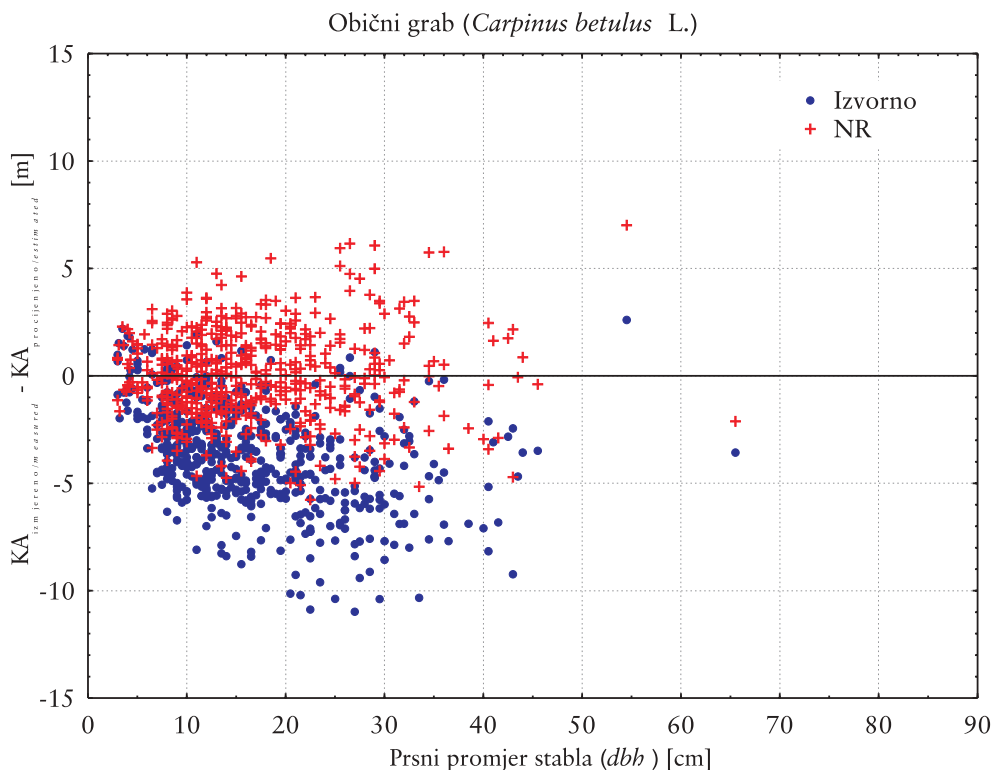
Tablica 5. Deskriptivna statistika reziduala za model (2) visine baze krošnje hrasta lužnjaka i običnog graba s izvornim i koeficijentima dobivenim nelinearnom regresijom (NR)
Table 5. Descriptive statistics of residuals for height of crown base model (2) using Nagel's and nonlinear regression (NR) coeff. for Common oak and European hornbeam

Statističko obilježje – <i>Statistic</i>	Hrast lužnjak (<i>Quercus robur</i> L.) <i>Common oak</i>		Obični grab, (<i>Carpinus betulus</i> L.) <i>European hornbeam</i>	
	Izvorno <i>(Original)</i>	NR	Izvorno <i>(Original)</i>	NR
N – N	314	314	321	321
Aritm. sredina reziduala – <i>Residual mean</i>	-2,0462	0,0464	-3,4117	-0,0162
Median – <i>Median</i>	-1,5700	0,6900	-3,3800	-0,1600
Std.dev. – <i>Std. dev.</i>	2,7348	2,6327	2,2925	1,9479
Std. pogr. – <i>Std. err.</i>	0,1543	0,1486	0,1280	0,1087
Skošenost – <i>Skewness</i>	-0,6748	-0,7886	-0,1556	0,2220
Std.pogr. skošenosti – <i>Std.err. skewness</i>	0,1376	0,1376	0,1361	0,1361
Spljoštenost – <i>Kurtosis</i>	0,4167	0,7268	0,3881	0,4337
Std.pogr. spljoštenosti – <i>Std. err. kurtosis</i>	0,2743	0,2743	0,2713	0,2713



Slika 6. Ovisnost reziduala kod KA o prsnom promjeru za stabla hrasta lužnjaka. Plave točke predstavljaju vrijednosti dobivene korištenjem izvornih koeficijenata, a crveni križići korištenjem koeficijenata dobivenih NR-om.

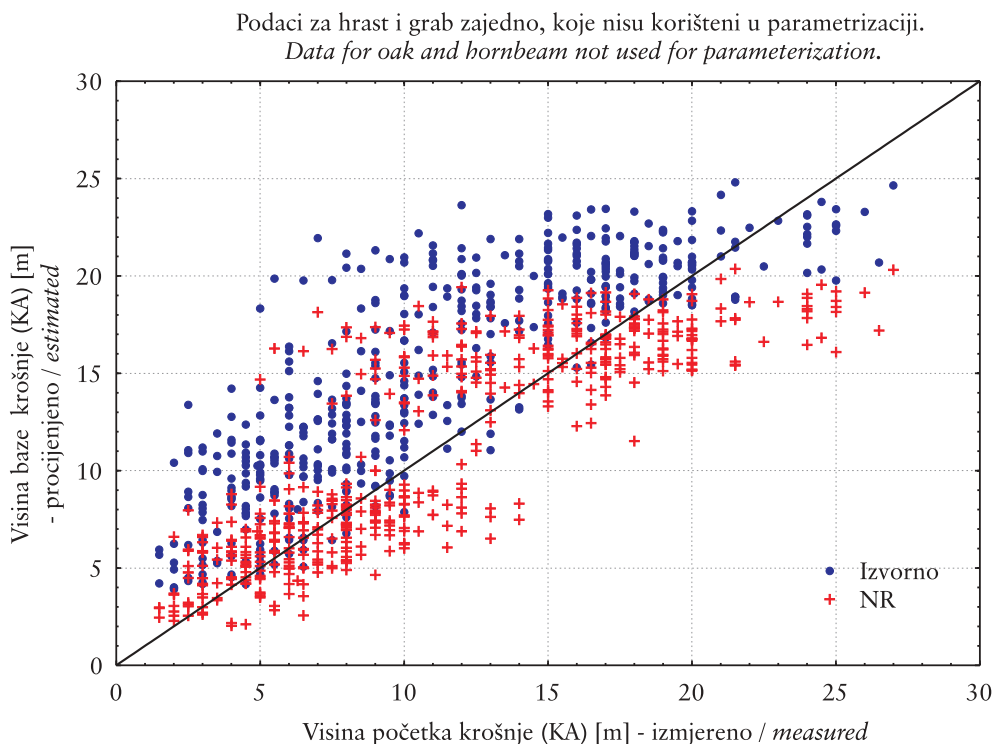
Figure 6. Dependence of residuals of KA on dbh for Common oak using original coefficients (blue dots) and using coefficients obtained by nonlinear regression (red crosses).



Slika 7. Ovisnost reziduala o prsnom promjeru za stabla običnog graba, koristeći izvorne koeficijente (plave točke) i koeficijente dobivene NR-om (crveni križići)
Figure 7. Dependence of residuals on dbh for European hornbeam using Nagel's coefficients (blue dots) and using coefficients obtained by nonlinear regression (red crosses)

je upravo na tom skupu obavljano parametriziranje. Koristeći izvorne koeficijente, dobivaju se reziduali uglavnom negativnog predznaka (ispod osi x), što ukazuje na sustavno precjenjivanje duljine debla. Osim toga, kod hrasta su reziduali najveći kad je riječ o stablima prsnog promjera oko 40cm (Slika 6). Kod graba je situacija nešto drukčija te je primjetno kako korištenjem izvornih koeficijenata pogreška raste s porastom prsnog promjera (Slika 7). Promotrimo li distribuciju reziduala za hrast, vidljivo je kako su iznosi podbacivanja (točke iznad osi x) u prosjeku bliže osi x nego iznosi prebacivanja, što je u skladu s negativnom vrijednosti koeficijenta skošenosti (Tablica 5). To je i očekivano i posljedica je činjenice kako je veća vjerojatnost postojanja stabla velikog prsnog promjera i visine s kratkim deblom (rašlje), no što je vjerojatnost da tanko i nisko stablo ima vrlo dugačko deblo.

Distribucija reziduala za grab je, koristeći izvorne koeficijente, skošena slično hrastu, dok uporabom koeficijenata dobivenih NR skošenost distribucije reziduala mijenja predznak i postaje pozitivna (Tablica 5). To znači kako je podbacivanje u procjeni visine baze krošnje postalo vjerojatnije od prebacivanje. Analiziramo li



Slika 8. Odnos procijenjene i izmjerene visine baze krošnje za hrast lužnjak i obični grab zajedno, koristeći izvorne koeficijente (plave točke) i koeficijente dobivene nelinearnom regresijom (crveni križići)
Figure 8. Estimated vs measured heights of crown base for both Common oak and European hornbeam using Nagel's coefficients (blue dots) and coefficients obtained by nonlinear regression (red crosses)

koeficijente spljoštenosti, vidljivo je i kako su vrijednosti dobivene uporabom koeficijenata dobivenih NR-om nešto veće od vrijednosti za izvorne koeficijente. To djelomično uvećava kvalitetu procjene korištenjem koeficijenata NR jer ukazuje na činjenicu kako pogreška, za razliku od procjene korištenjem izvornih koeficijenata, raste nešto sporije kako se udaljavamo od središta, odnosno prosječne duljine debla dane vrste u sastojini. Sumiranjem svega opaženog, možemo zaključiti kako koeficijenti dobiveni nelinearnom regresijom koji su korišteni u modelu (2) za procjenu visine početka krošnje, daju bolje predviđanje na skupu postojećih podataka nego izvorni koeficijenti.

Pravo testiranje kvalitete modela moguće je tek na nezavisnom skupu podataka koji nisu korišteni u postupku parametrizacije. Kako je u našem slučaju za parametriziranje modela poslužio samo dio podataka s odabranih ploha, bilo je moguće provjeriti kakva je kvaliteta predikcije duljine debla za podatke s ploha koje nisu korištene u parametrizaciji. Odnos predviđenih i izmjerenih vrijednosti visine baze krošnje za skup podataka koji nije korišten u parametriziranju modela dan je, radi sažetosti, zajedno za hrast i grab na Slici 8.

Tablica 6. Deskriptivna statistika reziduala za model (2) visine baze krošnje hrasta lužnjaka i običnog graba, s izvornim koeficijentima i koeficijentima dobivenim NR-om, na podacima koji nisu korišteni za parametrizaciju modela.

Table 6. Descriptive statistics of residuals for height of crown base model (2) using original coefficients and coefficients from nonlinear regression for Common oak and European hornbeam on data not used for parameterization of the model.

Statističko obilježje – <i>Statistic</i>	Hrast lužnjak (<i>Quercus robur</i> L.) <i>Common oak</i>		Obični grab, (<i>Carpinus betulus</i> L.) <i>European hornbeam</i>	
	Izvorno (<i>Original</i>)	NR	Izvorno (<i>Original</i>)	NR
N – N	265	265	257	257
Aritm. sredina reziduala – <i>Residual mean</i>	-3.7398	-0.2725	-3.8261	0.2073
Median – <i>Median</i>	-3.32	0.1732	-3.78	0.0095
Std.dev. – <i>Std. dev.</i>	3.8731	3.8079	2.528	2.2171
lin0Std. pogr. – <i>Std. err.</i>	0.2379	0.2339	0.1577	0.1383
Skošenost – <i>Skewness</i>	-0.3799	-0.3054	-0.1788	0.2261
Std.pogr. skošenosti – <i>Std.err. skewness</i>	0.1496	0.1496	0.1519	0.1519
Spljoštenost – <i>Kurtosis</i>	-0.0941	0.0181	-0.2283	0.0911
Std.pogr. spljoštenosti – <i>Std. err. kurtosis</i>	0.2982	0.2982	0.3027	0.3027

Iz Slike 8. i Tablice 6, vidi se kako je predikcija duljine debla uistinu bolja ako se u modelu (2) koriste koeficijenti dobiveni nelinearnom regresijom. Štoviše, uviđom u podatke o skošenosti i spljoštenosti razdiobe reziduala može se primijetiti kako su njihove vrijednosti skošenosti bliže nuli (skošenost je smanjena), a spljoštenost je približno jednaka normalnoj. To ukazuje kako u ovom slučaju, na granicama, model daje bolju predikciju od očekivane. Srednja vrijednost odstupanja uz korištenje izvornih koeficijenata i dalje je velika (-3,74 za hrast i -3,83 za grab). Srednje odstupanje uz korištenje koeficijenata dobivenih nelinearnom regresijom nešto je veće od prijašnjeg, što je i očekivano, ali je i dalje vrlo blizu nuli (-0,27 za hrast i 0,21 za grab) te se nalazi unutar dopuštene pogreške ($\pm 1,96 \cdot \text{Std. dev.}$).

ZAKLJUČCI

CONCLUSION

Na temelju postojećih podataka iz domaćih sastojina obavljena je parametrizacija modela za širinu krošnje i visinu baze krošnje koji se koriste u simulatoru BWINPro. Korištenjem novih koeficijenata, umjesto izvornih, u modelu širine krošnje poboljšana je kvaliteta procjene jer se smanjila pristranost. Smanjenje pristranosti značajnije je kod mladih sastojina graba. Iako je time povećana ukupna točnost, sama preciznost nije se značajnije poboljšala i posljedica je ograničenosti modela.

Vrijednosti koeficijenata dobivene nelinearnom regresijom za model visine baze krošnje nisu za sve koeficijente statistički značajne, što ukazuje na slabu prediktivnu vrijednost ulaznih varijabli, odnosno na činjenicu kako model nije dovol-

jno dobar. Poistovjećivanje visine baze krošnje s dužinom debla u našem slučaju, doprinijelo je smanjenju prediktivne vrijednosti te varijable i stoga bi ga trebalo izbjevati. Smanjenje pristranosti, dokazano testiranjem na nezavisnom skupu podataka, govori u prilog korištenja novih koeficijenata modela visine baze krošnje. Generalno, procjene temeljene korištenjem izvornih koeficijenata imaju sklonost precjenjivanju, dok se korištenjem novih koeficijenata takva sklonost smanjuje s tendencijom prema podcjenjivanju visine baze krošnje. Ta činjenica značajna je ako bi se spomenuti model (2) koristio u procjeni sortimentne strukture.

LITERATURA

REFERENCES

- BOŽIĆ, M., 2003: Utjecaj stanišnih i sastojinskih elemenata na prirast obične jele (*Abies alba* Mill.) u jelovim sastojinama na kršu u Hrvatskoj. Disertacija, Šumarski fakultet, Zagreb.
- ČAVLOVIĆ, J., 1996: Sustavna dinamika u planiranju gospodarenja regularnim šumama na području Uprave šuma Zagreb. Glas. šum. pokuse, Vol. 3, 109-152, Zagreb.
- DÖBBELER, H., M. Albert, M. Schmidt, J. Nagel, 2003: BWINPro Handbuch zur Version 6.2, Abteilung Waldwachstum, Niedersächsische Forstliche Versuchsanstalt. Göttingen.
- DUBRAVAC, T., 2002: Zakonitosti razvoja strukture krošanja hrasta lužnjaka i običnoga graba ovisno o prsnom promjeru i dobi u zajednici *Carpino betuli* - *Quercetum roboris* Anić ex Rauš 1969. Disertacija, Šumarski fakultet Sveučilišta u Zagrebu.
- DUBRAVAC, T., V. Krejči, 1993: Ovisnost promjera horizontalne projekcije krošanja hrasta lužnjaka o totalnim visinama stabala pojedinih dobnih razreda ekološko-gospodarskog tipa II-G-10 (*Carpino betuli* – *Quercetum roboris* /Anić/emend Rauš 1969). Rad. Šumar. inst. 28: 79-91, Zagreb.
- HASENAUER, H., 1994. Ein Einzelbaumwachstumssimulator für ungleichaltrige Fichten-Kiefern- und Buchen-Fichtenmischbestände. Forstl. Schriftenreihe, Univ. f. Bodenkultur, Wien. Österr. Ges. f. Waldökosystemforschung und experimentelle Baumforschung. 152 pp.
- KUŠAN, V., V. Krejči, 1993: Regresijski model za procjenu volumena sastojina hrasta lužnjaka (*Q. robur* L.) na aerosnimkama. Rad. Šumar. inst. Jastrebarsko 18(1-2): 69-77, Zagreb.
- MARJANOVIĆ, H., 2005. Primjenjivost simulatora rasta sastojina kao dodatnih alata u planiranju i gospodarenju šumama u Hrvatskoj. Magistarski rad, Šumarski fakultet Sveučilišta u Zagrebu.
- MONSERUD, R.A., H. Sterba, 1996. A basal area increment model for individual trees growing in even- and uneven- aged forest stands in Austria. For. Ecol. and Manage. 80, 57-80.
- NAGEL, J., 1997: BWIN Program for Standanalysis and Prognosis. User's Manual for Version 3.0, Niedersächsische Forstliche Versuchsanstalt, Göttingen.
- NAGEL, J., K. v. Gadow, 2003: Forstliche Software Sammlung. Institut für Waldinventur und Waldwachstum der Universität Göttingen.
- NAGEL, J., M. Albert, M. Schmidt, 2002: Das waldbauliche Prognose- und Entscheidungsmodell BWINPro 6.1. Forst u. Holz 57, (15/16) 486-493.
- NFV (Niedersächsische Forstliche Versuchsanstalt), 1996: Arbeitsanweisung, Niedersächsische Forstliche Versuchsanstalt, Göttingen.
- NFV (Niedersächsische Forstliche Versuchsanstalt), 2005: službene internet stranice programa BWINPro, <http://www.nfv.gwdg.de/A/BwinPro/bwinpro.php>
- NOVOTNY, V., 1998: Pomak osnovnih sastojinskih elemenata u vremenu između dviju izmjera u zajednici *Carpino betuli* – *Quercetum roboris* /Anić 1959/ Rauš 1969. Rad. Šumar. inst. 33(1): 1-46, Jastrebarsko.

- PRANJIĆ, A., V. Hitrec, N. Lukić, 1988: Praćenje razvoja sastojina hrasta lužnjaka tehnikom simuliranja. Glas. šum. pokuse 24:133-149, Zagreb.
- PRETZSCH, H., 2002: Application and evaluation of the growth simulator SILVA 2.2 for forest stands, forest estates and large regions. Forstw. Cbl. 121(Suppl.1): 28-51.
- PRETZSCH, H., P. Biber, J. Dursky, 2002: The single tree-based stand simulator SILVA: construction, application and evaluation. For. Ecol. Manage. 162: 3-21.
- SCHMIDT, M. 2001: Prognosemodelle für ausgewählte Holzqualitätsmerkmale wichtiger Baumarten, Disertacije, Univ. Göttingen. S.302
(<http://webdoc.sub.gwdg.de/diss/2002/schmidt/index.html>)
- STATSOFT, INC., 2004: STATISTICA (data analysis software system), version 6.1 www.statsoft.com.
- STERBA, H., R.A. Monserud, 1997: Applicability of the forest stand growth simulator PROGNAUS for the Austrian part of the Bohemian Massif, Ecological Modelling, Volume 98: p. 23-34.
- ŠPIRANEC, M., 1975a: Drvnogromadne tablice za hrast, bukvu, obični grab i pitomi kesten. Rad. Šumar. inst. 22:1-262, Zagreb.
- ŠPIRANEC, M., 1975b: Prirasno-prihodne tablice za hrastove, bukvu, obični grab i pitomi kesten. Rad. Šumar. inst. 25:1-103, Zagreb.

PARAMETERIZATION OF BWINPro SIMULATOR: COEFFICIENTS
FOR MODELS FOR CROWN BASE HEIGHT (STEM LENGTH)
AND CROWN WIDTH OF COMMON OAK AND EUROPEAN
HORNBEAM FOR STANDS IN CENTRAL CROATIA

Summary

In order to improve the quality of simulations of growth and development of stands, parameters of the models used should be adjusted in accordance with species and regions. In this study parameterization was performed of the models of crown width (KB) and height of crown base (KA), which are used in the BWINPro simulator (NAGEL et al, 2002). Coefficients of models for KB and KA for Common oak and European hornbeam were obtained by non-linear regression (NR), using measurement data on experimental plots in the stands of Common oak and European hornbeam (Carpino betuli - Quercetum roboris / Anić 1959/ Rauš 1969) from the region of central Croatia. Comparison was made of the results obtained by the use of the original sum of coefficients and the sum of coefficients obtained by NR. It was shown that with the use of new coefficients the bias of the model for KB decreased, particularly for European hornbeam trees of smaller diameter. With the use of new coefficients in the model for KA oak, or hornbeam, the overall assessment bias becomes decreased. However, these results should be cautiously taken, because the values of some coefficients have a low level of statistical significance. The practice of identification of the crown base height with the stem length causes a certain reduction in the predictive value of this variable, although it is not of crucial significance. Thus, the model for KA should be analysed and possibly modified.

Key words: BWINPro, parameterization, crown base height, crown width

