UDK / *UDC*: 582.632.2:[520.874:621.375.82]
DOI: https://dx.doi.org/10.21857/ygjwrc26zy
Izvorni znanstveni rad / *Original scientific paper*
Prispjelo / *Received*: 10. 4. 2024.
Prihvaćeno / *Accepted*: 10. 1. 2025.

Procjena prsnog promjera u mješovitoj srednjodobnoj sastojini hrasta lužnjaka korištenjem ručnoga laserskog skenera

Diameter at breast height estimation in a mixed middle-aged pedunculate oak stand using had-held personal laser scanner

Andro Kokeza, Luka Jurjević, Krunoslav Indir, Danko Kuric, Ivan Balenović*

Sažetak

U posljednjih nekoliko godina tehnologija ručnoga laserskog skeniranja budi sve veći interes šumarske znanosti i prakse, poglavito u istraživanjima o mogućnostima njezine primjene u izmjeri šuma. Cilj ovog istraživanja bio je testirati točnost ručnoga laserskog skeniranja za detekciju broja stabala i procjenu prsnog promjera u mješovitoj srednjodobnoj sastojini hrasta lužnjaka. Istraživanje je provedeno na šest primjernih ploha polumjera 15 m. Jedna primjerna ploha odabrana je za testiranje različitih shema skeniranja, a radi odabira najpouzdanije sheme skeniranja kojom je potom skenirano svih šest ploha. Skeniranje je provedeno korištenjem uređaja Geoslam ZEB-HORIZON. Na svim primjernim plohama mjernom vrpcom izmjeren je opseg svih stabala

* Andro Kokeza, mag. ing. geod. et geoinf., Hrvatski šumarski institut, Zavod za uređivanje šuma i šumarsku ekonomiku, Cvjetno naselje 41, 10450 Jastrebarsko
* Dr. sc. Luka Jurjević, GeoUnit d. o. o., Ulica Grgura Budislavića 99, Zadar
* Dr. sc. Krunoslav Indir, viši znanstveni suradnik, Hrvatski šumarski institut, Zavod za uređivanje šuma i šumarsku ekonomiku, Cvjetno naselje 41, 10450 Jastrebarsko
* Mr. sc. Danko Kuric, Hrvatske šume d. o. o., Direkcija, Ulica kneza Branimira 1, 10000 Zagreb
* Dr. sc. Ivan Balenović, viši znanstveni suradnik, Hrvatski šumarski institut, Zavod za uređivanje šuma i šumarsku ekonomiku, Cvjetno naselje 41, 10450 Jastrebarsko, ivanb@sumins.hr

s prsnim promjerom većim od 10 cm. Podaci prikupljeni na temelju ručnoga laserskog skeniranja obrađeni su u softveru *LiDAR360*. Pri tome su korištene potpuno automatizirane procedure bez naknadnih manualnih korekcija radi što boljeg testiranja i uvida u mogućnosti tehnologije. Uspješnost segmentacije i detekcije stabala iznosila je 93 % na svih šest ploha. Pri tome je uspješnost detekcije na tri plohe iznosila 100 %, dok se na preostale tri plohe kretala u rasponu 81 – 92 %. Daljnjom analizom utvrđeno je da je niži postotak detekcije na tri plohe uzrokovan nesegmentacijom tankih stabala lipe i graba iz panja. U usporedbi s prsnim promjerom dobivenim mjerenjem opsega mjernom vrpcom, srednja apsolutna pogreška procijenjenoga prsnog promjera iz podataka dobivenih na temelju ručnoga laserskog skeniranja iznosila je -1,52 cm, dok je srednja apsolutna pogreška iznosila 1,67 cm. Na dobiveni rezultat utjecala je automatska segmentacija koja nije manualno korigirana. U usporedbi s terenskim mjerenjima ručno lasersko skeniranje pokazalo je višu vremensku učinkovitost. S obzirom na veliki potencijal tehnologije ručnoga laserskog skeniranja, potrebno je provoditi daljnja detaljna istraživanja u sastojinama različitih tipova šuma i strukturnih karakteristika.

Ključne riječi: LiDAR; mobilno ručno lasersko skeniranje; detekcija stabala; broj stabala; prsni promjer; izmjera šuma

Abstract

Mobile hand-held laser scanning technology has attracted increasing interest in forestry science and practice over the last few years, especially in research on the possibilities of its application in forest measurement. The objective of this research was to test the accuracy of hand-held laser scanning for the detection of the number of trees and the estimation of breast diameter in a mixed medium-aged stand of the pedunculate oak. The research was conducted on six circular sample plots with a radius of 15 meters. The scanning of the surfaces was carried out according to a predefined scanning scheme (walking path) using the Geoslam ZEB-HORIZON device. On all plots, the diameter of all trees with a diameter at breast height above 10 cm was measured with a measurement tape. Collected hand-held laser scanning data were processed in LiDAR360 software. In doing so, fully automated procedures were used without subsequent manual corrections for the best possible testing and insight into the possibilities of the technology. The success rate of tree segmentation and detection was 93 % on all six plots. At

the same time, the success rate of detection on three plots was 100 %, while on the remaining three plots, it was in the range of 81-92 %. Further analysis revealed that the lower percentage of detection on the three plots was caused by the non-segmentation of thin linden and hornbeam trees from the stump. Compared with diameter at breast height obtained by measurement tape, the mean deviation of estimated diameter at breast height from hand-held laser scanning data was -1.52 cm, while the root mean square error was 1.82 cm. The obtained result was affected by the automatic segmentation, which was not additionally manually corrected. Compared to field measurements, hand-held laser scanning showed higher time efficiency. Considering the great potential of manual laser scanning technology, it is necessary to carry out further detailed research on forest stands of different forest types and structural characteristics.

Keywords: *LiDAR; mobile hand-held personal laser scanning; tree detection; tree number; diamaeter at breast height; forest inventory*

Uvod
Introduction

Potencijal primjene daljinskih istraživanja u inventuri šuma već je dugo prepoznat kako u znanstvenoj zajednici, tako i u praktičnoj primjeni u šumarstvu (White i dr. 2016). U proteklim desetljećima ključan napredak u istraživanjima inventure šuma temeljenima na daljinskim istraživanjima postignut je razvojem tehnologije laserskog skeniranja (LS), poznate i kao *LiDAR* (engl. *Light Detection And Ranging*) tehnologije (Wang i dr. 2019). LS predstavlja aktivnu tehnologiju daljinskog istraživanja koja omogućuje prikupljanje visokopreciznih trodimenzionalnih (3D) prostornih podataka (oblak točaka) temeljenih na laserskom skeniranju, mjerenju udaljenosti, pozicioniranju i tehnikama mjerenja orijentacije (Petrie i Toth 2009). Prema Wang i dr. (2019), glavne su prednosti LS tehnologije u inventuri šuma: (1) neposredna procjena 3D atributa objekata (npr. stabala); (2) sposobnost prodiranja (penetracije) kroz krošnje stabala, što omogućuje detekciju vrhova stabala, vertikalne strukture šumske sastojine i samog terena u jednom skeniranju; i (3) visoka razina automatizacije u obradi podataka, što olakšava učinkovitost mjerenja na velikim područjima.

S obzirom na platformu na kojoj je LiDAR sustav postavljen, LS tehnologija može se grupirati u svemirske, zračne (avioni, helikopteri, bespilotne letjelice) i terestričke sustave (mobilni, statički). Svaki od navedenih sustava pruža

podatke određenih karakteristika koji mogu biti korisni za specifične potrebe inventure šuma, tj. na razini pojedinačnih stabala, ploha i sastojina ili čak na državnoj i globalnoj razini. LS tehnologija ima potencijal promijeniti i unaprijediti dosadašnje, klasične načine prikupljanja podataka u okviru inventure (izmjera) šuma. Primjerice istraživanja o mogućnosti primjene terestričkih (statičkih i mobilnih) LS sustava privukla su znatnu pozornost, i to poglavito zbog smanjenja radno intenzivnih i dugotrajnih terenskih aktivnosti tijekom klasičnih terenskih izmjera u okviru uređajnih inventura šuma. Prva istraživanja o mogućnostima primjene statičkoga terestričkog laserskog skeniranja (TLS) u inventuri šuma započela su oko 2000. godine. Tijekom posljednjeg desetljeća ta je tema intenzivno proučavana (Liang i dr. 2012, 2014, Bauwens i dr. 2016, Cabo i dr. 2018, Liang i dr. 2018a), a posebno kada je hardver TLS-a doživio bitna poboljšanja u smislu smanjenja veličine, težine i cijene te povećanja prostorne razlučivosti i brzine mjerenja (Liang i dr., 2018a). Provedena istraživanja ukazala su da se primjenom TLS-a pojedinačna stabla mogu detaljno digitalizirati na razini milimetara, što omogućuje preciznu procjenu ključnih atributa stabala, poput položaja, prsnog promjera, visine stabla, volumena, biomase iznad tla itd. (Bauwens i dr. 2016, Cabo i dr. 2018, Liang i dr. 2018a). Međutim glavno ograničenje TLS-a u njegovoj operativnoj primjeni u inventuri šuma jest brzina prikupljanja podataka. Naime, kako bi se smanjio učinak zaklonjenosti (okluzije) uzrokovan okolnim stablima, svaka ploha mora biti skenirana s više pozicija korištenjem tzv. pristupa višestrukog skeniranja, što u konačnici znatno produljuje vrijeme prikupljanja podataka te samim time i troškove prikupljanja podataka.

Mobilni laserski skeneri (MLS) vremenski su učinkovita alternativa TLS-u, i to u pogledu smanjenja vremena potrebnog za prikupljanje podataka te zbog smanjenja ili potpunog izbjegavanja već spomenutog utjecaja zaklonjenosti stabala. Osim platforme (vozilo ili čovjek), MLS sustavi obično se sastoje od tri ključne komponente: 1) laserskoga skenera (LiDAR senzor), 2) inercijalnoga mjernog uređaja (IMU) i 3) prijamnika globalnoga navigacijskog satelitskog sustava (GNSS). Kvaliteta i točnost podataka MLS-a ovise o preciznosti i točnosti svih triju komponenti i njihovoj sinkronizaciji (Bauwens i dr. 2016). Zbog lošijeg GNSS signala u šumskom okruženju i dinamike kretanja platforme koju opaža IMU, podaci MLS-a obično su manje točni od podataka TLS-a (Liang i dr. 2018b). Nadalje, vozila imaju ograničen pristup određenim, terenski kompleksnijim šumskim područjima, što sprječava kontinuirano kretanje

i prikupljanje podataka. To ograničenje kretanja u šumi potaknulo je upotrebu operatera kao platforme, gdje sve senzore nosi čovjek, što se naziva ručno lasersko skeniranje (RLS, engl. *personal laser scanning*). Prvi RLS sustavi bili su velikih dimenzija i težine oko ili iznad 30 kg (Kukko i dr. 2012, Hyyppä i dr. 2013, Liang i dr. 2014). Tijekom posljednjih desetak godina brz napredak u minijaturizaciji senzora rezultirao je razvojem laganih i visoko mobilnih RLS sustava. Daljnji napredak u RLS sustavima postignut je zamjenom GNSS-a algoritmom simultanog lociranja i mapiranja (SLAM). Algoritam SLAM obrađuje IMU i laserske podatke kako bi locirao skener u nepoznatom okruženju i registrirao cijeli skup točaka, čime su RLS sustavi pogodni za upotrebu u šumi gdje je GNSS signal često oslabljen. Pojava i dostupnost sve naprednijih RLS sustava posljednjih godina rezultirala je povećanim istraživanjem mogućnosti njihove primjene u inventuri šuma, prvenstveno za procjenu ključnih atributa stabala (npr. položaj stabla, prsni promjer, visina stabla, volumen stabla itd.) (Chen i dr. 2019, Gollob i dr. 2020, Balenović i dr. 2021). Budući da RLS sustavi neprestano i brzo napreduju u pogledu tehničkih karakteristika, potrebno je kontinuirano provoditi istraživanja o njihovoj primjeni u šumarstvu. Cilj ovog istraživanja jest testirati točnost ručnoga laserskog skeniranja za detekciju broja stabala i procjenu prsnog promjera u mješovitoj srednjodobnoj sastojini hrasta lužnjaka.

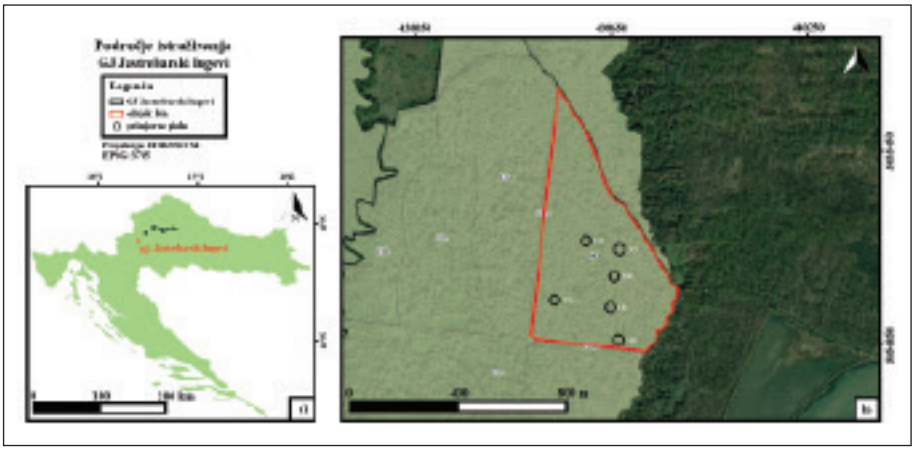
Materijal i metode

Materials and methods

Područje istraživanja

Research area

Istraživanje je provedeno na šest kružnih primjernih ploha polumjera 15 m u mješovitoj srednjodobnoj sastojini (77 godina starosti) uređajnog razreda hrasta lužnjaka (odsjek 14a) u Gospodarskoj jedinici Jastrebarski lugovi. Područje istraživanja (45° 38' N, 15° 43' E) nalazi se unutar kompleksa nizinskih lužnjakovih šuma Pokupskog bazena u blizini grada Jastrebarskog te 35 km jugoistočno od Zagreba (slika 1). Osim hrasta lužnjaka (*Quercus robur* L.) kao glavne vrste drveća, u sastojini u znatnoj mjeri pridolaze obični grab (*Carpinus betulus* L.), a u manjoj crna joha (*Alnus glutinosa* (L.) Gaertn.), klen (*Acer campestre* L.) te malolisna lipa (*Tilia cordata* Mill.). Prosječan broj stabala s prsnim promjerom većim od 10 cm na šest primjernih ploha iznosi 305 stabala/ha. U



Slika 1. Područje istraživanja: a) lokacija gospodarske jedinice Jastrebarski lugovi u Hrvatskoj, b) prostorni raspored primjernih ploha u odsjeku 14a.

sloju grmlja u umjerenoj mjeri pridolaze obična lijeska (*Corylus avellana* L.) i glog (*Crataegus monogyna* Jacq.). Teren je ravničarski sa zanemarivim, minimalnim varijacijama, a nadmorska visina terena kreće se oko 110 m.

Terenska izmjera

Field masurements

Terenska izmjera na šest primjernih ploha (slika 1b) provedena je u stanju mirovanja vegetacije u siječnju 2021. godine. Prvotno je označen centar plohe kojem je lokacija određena totalnom stanicom Topcon es65 (Topcon Positioning Systems Inc., Tokio, Japan). Potom su svim stablima s prsnim promjerom većim od 10 cm izmjereni prsni promjeri te pozicije stabala. Prsni promjeri stabala izmjereni su na dva načina: promjerkom s podjelom na debljinske stupnjeve od 5 cm te mjernom vrpcom s preciznošću od 1 cm. Prilikom izmjere promjerkom svakom su stablu izmjerena dva međusobno okomita prsna promjera. Prvi prsni promjer izmjeren je u smjeru sjever – jug, a drugi u smjeru zapad – istok. Na taj način prikupljeni su podaci o prsnim promjerima kao i u klasičnoj operativnoj inventuri šuma. Nadalje, svakom stablu detektirana je vrsta drveća, dok je pozicija svakog stabla određena totalnom stanicom Topcon es65.

Ručno lasersko skeniranje

Hand-held personal laser scanning

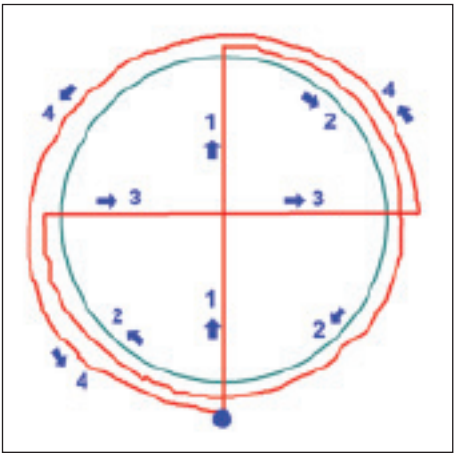
Ručno lasersko skeniranje provedeno je uređajem GeoSLAM Zeb Horizon (Geoslam Ltd, Nottinghamshire, UK) u siječnju 2021., tj. gotovo istovremeno kao i terenska izmjera. Zeb Horizon ima kapacitet snimanja od 300.000 točaka u sekundi u vidnom polju od 360° horizontalno i 270° vertikalno na udaljenostima do 100 metara i s relativnom točnošću 1 – 3 cm. Sastavljen je od glave skenera spojene s ručkom koja je povezana s *data loggerom* i baterijom, te ukupno teži oko tri kilograma. Baterija skenera može izdržati do tri sata neprekidnog korištenja u radnim uvjetima od 0 °C do +40 °C (GeoSLAM 2020a).

Prije samog skeniranja postavljene su referentne točke na području skeniranja kako bi se omogućilo georeferenciranje oblaka točaka. Na svakoj plohi postavljene su najmanje četiri referentne točke zabijanjem drvenih kolaca (5 × 5 × 40 cm) u zemlju, čiji su položaji određeni totalnom stanicom Topcon es65 (Jurjević i dr. 2021). Lokacije referentnih točaka nisu bile strogo definirane, ali su ravnomjerno i optimalno raspoređene na površini plohe. Na drvene su kolce prije skeniranja postavljene sfere radijusa 14,5 cm za georeferenciranje.

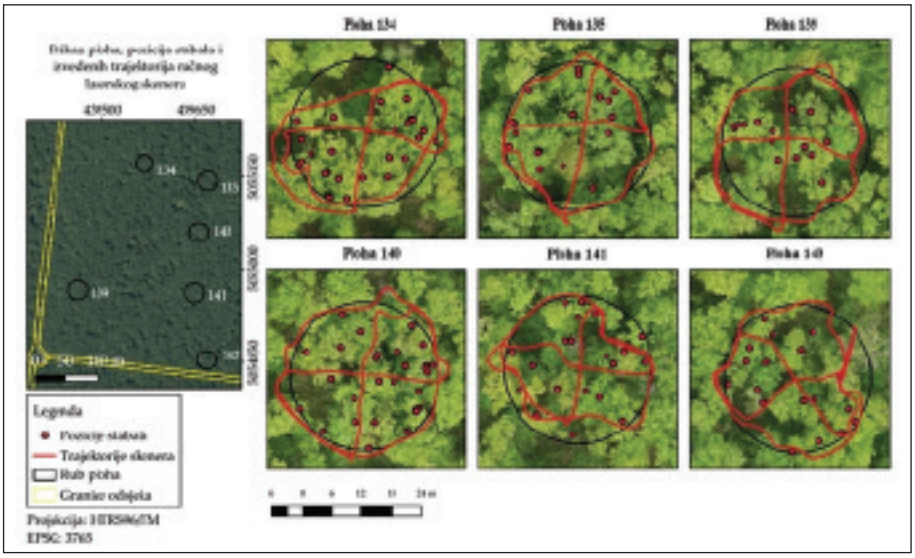
Za skeniranje na primjernim plohama korištena je unaprijed planirana shema skeniranja (slika 3) koja je osmišljena radi postizanja potpune pokrivenosti plohe, odnosno pokrivenosti svakog stabla na plohi iz više smjerova. Pri



Slika 2. Ručni laserski skener GeoSLAM Zeb Horizon (Geoslam Ltd, Nottinghamshire, UK) korišten u istraživanju. Lijevo: glava skenera s ručkom, desno: *data logger* s baterijom, dolje: kutija uređaja.



Slika 3. Planirana shema skeniranja.



Slika 4. Provedene sheme skeniranja i položaji stabala po plohama.

tome je početak i završetak skeniranja bio na istome mjestu, tj. primijenjena je tzv. metoda zatvorene petlje (engl. *closed loop*).

Položaji (koordinate) terenski izmjerenih stabala na plohama te provedene sheme skeniranja prikazani su na slici 4. Za skeniranje svih šest ploha uključujući pripremu (inicijalizacija skenera) te kretanje između ploha utrošeno je ukupno 65 minuta, dok je samo skeniranje ploha u prosjeku trajalo oko 5 minuta.

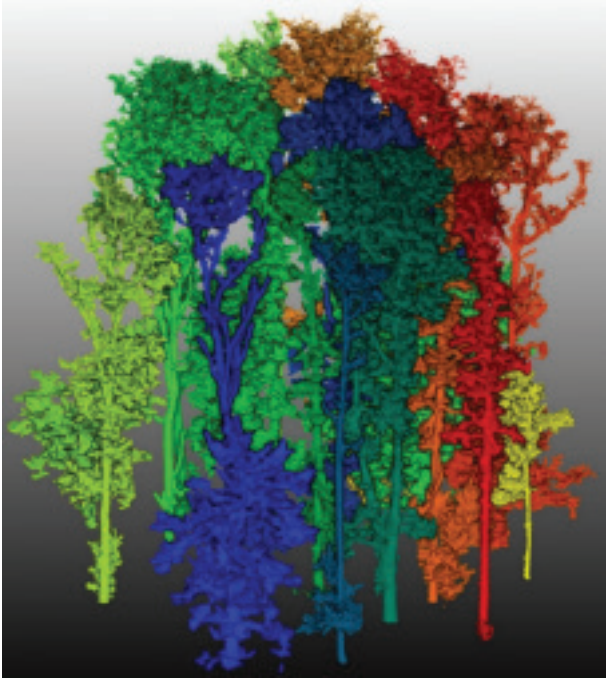
Obrada podataka dobivenih na temelju ručnoga laserskog skeniranja

Hand-held personal laser scanning data processing

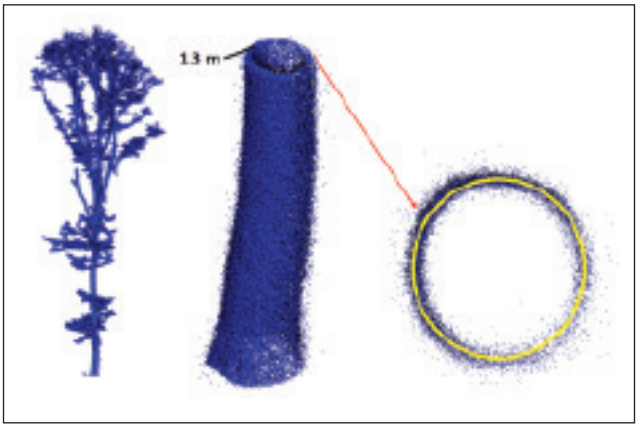
Predobrada prikupljenih podataka provedena je u programu *GeoSLAM HUB* (GeoSLAM 2020b), koji je generirao oblak točaka. Georeferenciranje oblaka točaka iz lokalnoga koordinatnog sustava u HTRS96/TM koordinatni sustav provedeno je pomoću referentnih točaka, odnosno sfera postavljenih na drvene kolce. Nakon toga oblak točaka eksportiran je u formatu .las (LASer) kako bi se mogao dalje obraditi u programu *LiDAR360 v5* (GreenValley Intl, Kalifornija, SAD).

Oblak točaka učitan u program *LiDAR360* procesiran je u nekoliko koraka. Korištenjem alata *Remove Outliers* uklonjeni su šumovi iz oblaka točaka uzrokovani povratom visokoletećih objekata (npr. ptice) ili ekstremno niskih

položaja uzrokovani višestaznim efektom laserskog pulsa, dok su točke tla klasificirane pomoću alata *Classify Ground Points*. Nakon toga provedena je normalizacija oblaka točaka korištenjem alata *Normalize by Ground Points* kako bi se nadmorske visine oblaka točaka pretvorile u visine iznad tla. Proces normalizacije izveden je oduzimanjem nadmorske visine terena od vrijednosti nadmorskih visina svake točke. Zatim je provedena automatska segmentacija oblaka točaka korištenjem alata *Point Cloud Segmentation* i tzv. pristupa odozdo prema gore (engl. *bottom-up approach*, Tao i dr. 2015) radi identifikacije, odnosno segmentacije pojedinačnih stabala na plohama. Navedeni pristup pogodan je za TLS i RLS, koji prikupljaju podatke ispod razine krošanja, gdje su debla stabala izražena i lako uočljiva u oblaku točaka, te se mogu koristiti za informiranje algoritma segmentacije. Pri tome je, a u ovisnosti o strukturi same šumske sastojine, potrebno podesiti niz parametara za uspješnu segmentaciju (GreenValley International 2021). Vrlo pojednostavnjeno rečeno, algoritam segmentacije radi na temelju postavljenih parametara te detektira deblo na određenoj visini (npr. 1,6 m) i zatim mu pridodaje pripadajući oblak točaka sve do samog vrha stabla (slika 5).



Slika 5. Prikaz automatski segmentiranih stabala na plohi 139.



Slika 6. Prikaz procjene prsnog promjera na primjeru jednoga segmentiranog stabla (ploha 139).

Nakon provedene segmentacije pojedinačni atributi stabala (npr. lokacija stabla, prsni promjer, visina stabla, dimenzije krošnje itd.) procijenjeni su za svako stablo segmentirano iz ulaznog oblaka točaka. Prilikom automatske segmentacije stabala prsni promjeri stabala procjenjuju se milimetarskom preciznošću na visini od 1,30 m od središnje osi stabla korištenjem metode uklapanja po krugu. Drugim riječima, oblak točaka na visini od 1,30 m od tla aproksimiran je kružnicom korištenjem metode najmanjih kvadrata (slika 6).

Analiza podataka

Data analysis

Prije same evaluacije dobivenih rezultata kreirane su prostorne baze podataka za terenske metode izmjere i ručno lasersko skeniranje. Uspješnost segmentacije, odnosno detekcije pojedinačnih stabala ($D_{\%}$) iz podataka ručnoga laserskog skeniranja evaluirana je na razini svake plohe te ukupno na svih šest primjernih ploha. Izračunata je kao odnos broja stabala segmentiranih iz podataka ručnoga laserskog skeniranja (n_{RLS}) te terenski izmjerenog broja stabala (n_T). Za ocjenu točnosti procjene prsnih promjera iz podataka ručnoga laserskog skeniranja (d_{RLS}) i klasične terenske izmjere promjerkom (d_{pr}) u odnosu na prsni promjer izmjeren mjernom vrpcom ($d_{1,3}$) izračunato je srednje odstupanje (MD, prema engl. *mean difference*) te korijen srednje kvadratne pogreške (RMSE, prema engl. *root mean square error*). MD ukazuje na predznak odstupanja procijenjenih vrijednosti, odnosno podcjenjuju li one ili precjenjuju referentne vrijednosti. Za MD se često koristi i termin pristranost (engl. *bias*)

jer ukazuje na sistemsku pogrešku procijenjenih vrijednosti. RMSE ukazuje na točnost procijenjenih vrijednosti u odnosu na referentne terenske vrijednosti. MD i RMSE izračunate su u mjernim jedinicama (cm) te u postotnom iznosu od referentne vrijednosti prema jednadžbama 2 – 5.

$$D_{\%} = \frac{n_{RLS}}{n_T} \times 100 \quad (1)$$

$$MD = \frac{\sum_{i=1}^{n}(d'_i - d_{1,3-i})}{n} \quad (2)$$

$$MD_{\%} = \frac{MD}{\overline{d_{1,3}}} \cdot 100 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(d'_i - d_{1,3-i})^2}{n}} \quad (4)$$

$$RMSE_{\%} = \frac{RMSE}{\overline{d_{1,3}}} \cdot 100 \quad (5)$$

gdje je d'_i prsni promjer procijenjen iz podataka ručnoga laserskog skeniranja (d_{RLS}) ili klasične terenske izmjere korištenjem promjerke (d_{pr}) za stablo i, $d_{1,3-i}$ je referentni prsni promjer izmjeren mjernom vrpcom za stablo i, n je broj stabala na svih šest primjernih ploha, $\overline{d_{1,3}}$ je aritmetička srednja vrijednost referentnoga prsnog promjera.

Rezultati i rasprava

Results and discussion

Segmentacija i detekcija stabala

Tree segmentation and detection

Broj i postotak segmentiranih stabala, odnosno postotak detekcije stabala ($D_{\%}$) iz RLS podataka za svaku plohu te ukupno za svih šest ploha prikazani su u tablici 1. Postotak automatske detekcije kreće se u rasponu 81 – 100 %, a gledajući svih šest ploha zajedno, prosječno iznosi 93 %. Iako do sada ne postoje istraživanja provedena u nizinskim lužnjakovim sastojinama sličnih strukturnih karakteristika, vidljivo je da su rezultati ovog istraživanja u skladu s dosadašnjim spoznajama dobivenim korištenjem istog RLS-a (Gollob i dr. 2020, Hyyppä i dr. 2020, Tupinambá-Simões i dr. 2023). Naime Gollob i dr. (2020) postigli su prosječan postotak detekcije od 96 % u istraživanju provedenom u Austriji na 20 ploha u sastojinama različitih tipova šuma (listače, četinjače,

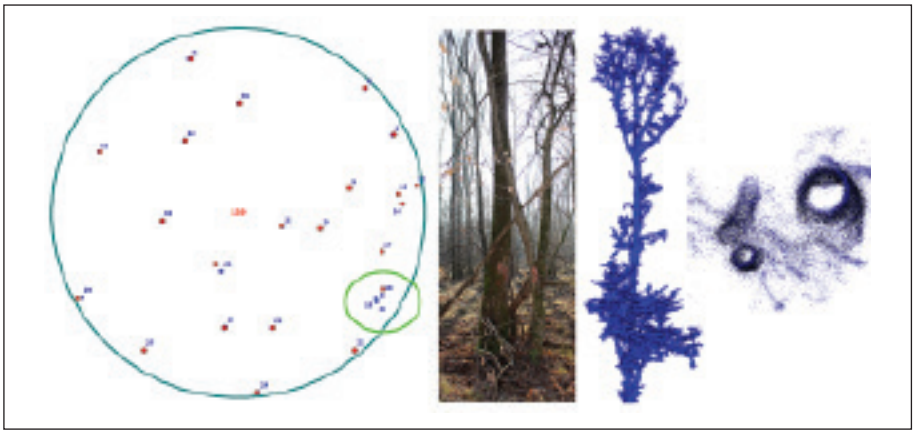
mješovite) te različitih strukturnih i terenskih karakteristika. U borealnom tipu finskih šuma, gdje su dominirale četinjače, Hyyppä i dr. (2020) na plohi (32 x 32 m) jednostavnijih strukturnih karakteristika postigli su postotak detekcije od 93 %, a na plohi složenijih strukturnih karakteristika postotak detekcije od 77 %. Tupinambá-Simões i dr. (2023) u mješovitim su sastojinama listača i četinjača zapadne Španjolske na kvadratnoj plohi veličine 1 ha testirali dvije sheme skeniranja te postigli postotak detekcije od 69 % i 92 %. Za razliku od ovog istraživanja, gdje su promatrana stabla s prsnim promjerom jednakim ili većim od 10 cm, u sva tri navedena istraživanja taksacijski prag bio je niži, tj. promatrana su stabla s prsnim promjerom jednakim ili većim od 5 cm.

Tablica 1. Broj segmentiranih i postotak detektiranih stabala na temelju podataka ručnoga laserskog skeniranja na plohama

Ploha	Gustoća sastojine	Broj terenski izmjerenih stabala	Broj stabala segmentiranih iz RLS podataka	Postotak segmentacije / detekcije
	(n_T/ha)	(n_T)	(n_{RLS})	($D_{\%}$)
134	368	26	21	81
135	255	18	15	88
139	368	26	24	92
140	212	15	15	100
141	283	20	20	100
143	255	18	18	100
Ukupno	290	123	113	93

Promatrano po plohama (tablica 1), na tri primjerne plohe (140, 141, 143) dobivena je 100-postotna automatska detekcija stabala, dok je na preostale tri plohe (134, 135 i 139) dobiven smanjeni postotak detekcije (81 %, 88 %, 92 %). Ako se usporede gustoća sastojine (broj stabala po ha) pojedinih ploha i dobiveni rezultati, vidljivo je da povećanje gustoće sastojine utječe na smanjenje uspješnosti detekcije stabala. Navedeno je dokazano prijašnjim istraživanjima (Cabo i dr. 2018, Chen i dr. 2019, Balenović i dr. 2021). Međutim, detaljnom analizom uočeno je da, osim broja stabala (gustoće sastojine), na niži postotak detekcije stabala utječe i strukturni te prostorni razmještaj stabala na plohi. Konkretnije, pogrešku u automatskoj segmentaciji stabala uzrokovala su tanka stabla (npr. lipe ili graba) koja su se nalazila u neposrednoj blizini debljih stabala (lužnjaka) te su u procesu automatske segmentacije segmentirana kao

jedno stablo (slika 7). U ovom slučaju dva tanka stabla lipe koja se nalaze u neposrednoj blizini debljega lužnjakova stabla nisu segmentirana kao pojedinačna stabla, tj. segmentirana su zajedno sa stablom lužnjaka kao jedno stablo. Pogreške u automatskoj segmentaciji uočene su i kod tankih stabala graba i lipe iz panja, gdje su sva stabla ili većina stabala iz panja segmentirana kao jedno stablo. Automatizirani proces segmentacije softvera *LiDAR360*, tj. algoritam segmentacije, ne može prepoznati da se u tom slučaju radi o više stabala na istome mjestu; umjesto toga grupira ih u jedan oblak točaka, tj. jedno stablo. Stoga je nakon svake automatske segmentacije, a osobito ako se provodi u sastojinama kompleksnijih strukturnih karakteristika, uputno provesti vizualnu kontrolu dobivenih rezultata. Ako se vizualnom kontrolom uoče propusti u automatskoj segmentaciji pojedinačnih stabala, najjednostavnije i najpouzdanije rješenje jest manualna korekcija segmentiranog oblaka točaka, gdje se oblak točaka debljeg stabla ručno razdvaja od oblaka točaka tankih stabala.



Slika 7. Prikaz više stabala segmentiranih u jedan oblak točaka.

Procjena prsnog promjera

Diameter at breast height estimation

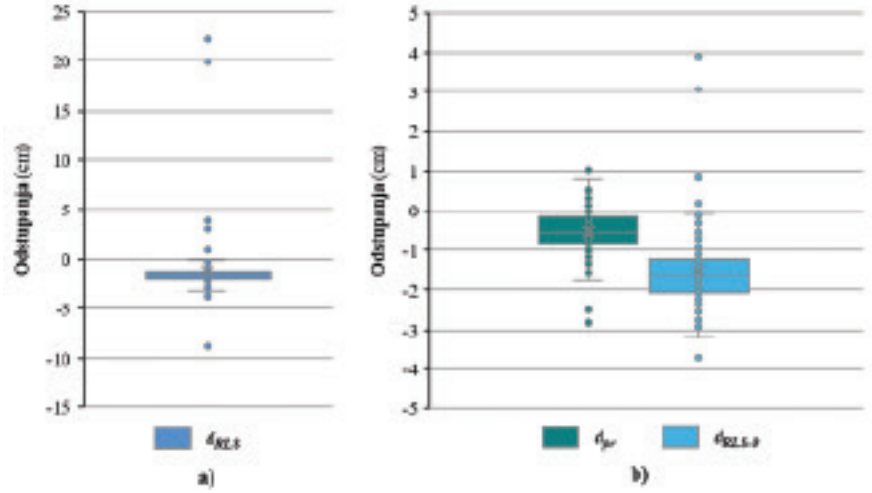
Odstupanja procijenjenih prsnih promjera iz podataka klasične terenske izmjere korištenjem promjerke (d_{pr}) te podataka dobivenih na temelju ručnoga laserskog skeniranja (d_{RLS}) u odnosu na referentni prsni promjer izmjeren mjernom vrpcom ($d_{1,3}$) prikazana su u tablici 3 kroz srednje odstupanje (MD) i korijen srednje kvadratne pogreške (RMSE) iskazane u mjernim jedinicama (cm) te u postotnom iznosu od referentne vrijednosti. U tablici 3 prikazana su

i odstupanja procijenjenih prsnih promjera iz podataka dobivenih na temelju ručnoga laserskog skeniranja ($d_{RLS\text{-}O}$) bez grubih grešaka (tzv. *outliers*). Naime tijekom analize dobivenih rezultata uočeno je nekoliko većih odstupanja d_{RLS} u odnosu na $d_{1,3}$, te su kao grube greške definirana odstupanja veća od ±5 cm. Na taj način uočene su i eliminirane tri grube greške, s odstupanjima d_{pr} u odnosu na $d_{1,3}$ u iznosima od -8,82 cm, 19,91cm i 22,21 cm (slika 8a). Pregledom oblaka točaka utvrđeno je da su navedene grube greške nastale kao posljedica pogrešnoga automatskog određivanja prsnog promjera (uklapanja kruga). U slučaju pozitivnih grubih grešaka algoritam je samom deblu pridružio deblo susjednih tankih stabala (pogrešna automatska segmentacija, slika 7). Negativna gruba greška nastala je kod stabla graba iznimno nepravilnog oblika debla gdje je oblak točaka bio nešto lošije kvalitete te algoritam nije uspio uspješno uklopiti krug.

Ako se promatraju $d_{RLS\text{-}O}$ rezultati, tj. nakon uklanjanja grubih grešaka, vidljivo je da se automatskom segmentacijom i procjenom prsnih promjera iz RLS podataka dobivaju rezultati nešto slabije točnosti nego klasičnom terenskom izmjerom (tablica 2, slika 8b). Razlika između dobivenih MD vrijednosti dviju metoda (d_{pr}, $d_{RLS\text{-}O}$) iznosi 0,34 cm, a za RMSE razlika iznosi 2,64 cm. Obje metode (klasična terenska izmjera, RLS) podcjenjuju referentni prsni promjer izmjeren mjernom vrpcom, pri čemu RLS rezultate podcjenjuje u nešto većim iznosima ($MD_{\%}$ = -3,46 %) u odnosu na klasičnu terensku izmjeru promjerkom (MD = -0,53 %).

Tablica 2. Usporedba točnosti prsnog promjera RLS-a i promjerke s prsnim promjerom izmjerenim pomoću vrpce

Metoda	Broj stabala	MD	MD	RMSE	RMSE
	(kom.)	(cm)	(%)	(cm)	(%)
d_{pr} vs $d_{1,3}$	122	-0,53	-1,61	0,79	2,39
d_{RLS} vs $d_{1,3}$	113	-1,19	-3,46	3,43	9,99
$d_{RLS\text{-}O}$ vs $d_{1,3}$	110	-1,52	-4,41	1,82	5,27



Slika 8. *Box-plot* odstupanja procijenjenih prsnih promjera u odnosu na referentni prsni promjer izmjeren mjernom vrpcom ($d_{1,3}$): a) odstupanja podataka dobivenih na temelju ručnoga laserskog skeniranja (d_{RLS}), b) odstupanja na temelju klasične terenske izmjere korištenjem promjerke (d_{pr}) te podataka dobivenih na temelju ručnoga laserskog skeniranja (d_{RLS-O}) nakon uklanjanja grubih grešaka.

Rezultati procjene prsnog promjera iz RLS podataka u skladu su s dosadašnjim istraživanjima (Gollob i dr. 2020, Hyyppä i dr. 2020, Sofia i dr. 2021, Tupinambá-Simões i dr. 2023) koja su se koristila istim RLS uređajem, ali su provedena u šumskim sastojinama različitih tipova i strukturnih karakteristika. U navedenim dosadašnjim istraživanjima dobiveni $RMSE_{\%}$ kreće se u rasponu 3,5 – 12,01 %. Pri tome je potrebno napomenuti da se provedena istraživanja, osim u strukturnim karakteristikama šumskih sastojina, veličini i obliku ploha te taksacijskoj granici promatranih stabala (5 cm ili 10 cm), razlikuju i po tipu referentnih podataka (terestrički laserski skener, terenska izmjera mjernom vrpcom), korištenom softveru za obradu podataka i algoritmu za procjenu prsnog promjera.

Potrebno je napomenuti i da su u ovom radu podaci ručnoga laserskog skeniranja potpuno automatski obrađeni, od segmentacije pojedinačnih stabala do procjene prsnog promjera, te da u prethodnom poglavlju opisane pogreške segmentacije utječu na točnost procjene prsnog promjera. Ako se nakon automatske segmentacije provede vizualna kontrola te manualna korekcija segmentacije stabala, smanjit će se i broj grubih pogrešaka te samim time povećati točnost procjene prsnih promjera. Nadalje, uputno je provesti i vizualnu korekciju automatske procjene prsnih promjera te, ako se uoče određeni propusti

algoritma kod pojedinih stabala, manualnim uklapanjem kruga moguće je dodatno povećati točnost procjene prsnih promjera. U ovom istraživanju korišteni softver (*LiDAR360*), osim na temelju aproksimacije kruga, pruža mogućnost procjene prsnog promjera i na temelju aproksimacije prsnog promjera elipsom ili cilindrom. Stoga je u daljnjim istraživanjima potrebno ispitati sve mogućnosti aproksimacije prema pojedinim vrstama drveća korištenjem u uređaj integrirane panoramske kamere, jer se može pretpostaviti da određene metode aproksimacije bolje odgovaraju pojedinim oblicima debla, odnosno vrstama drveća. Iako manualna procjena prsnog promjera zahtijeva veći utrošak vremena, potrebno je istražiti u kojoj mjeri povećava točnost dobivenih rezultata te utvrditi u kojoj ju je primjeni uputno koristiti.

Zaključci

Conclusions

Glavni cilj ovog istraživanja bio je ispitati mogućnost primjene tehnologije ručnoga laserskog skeniranja u izmjeri šuma, točnije u detekciji broja stabala i procjeni prsnog promjera u mješovitoj, srednjodobnoj, nizinskoj šumi hrasta lužnjaka. U ovom istraživanju korišten je najnapredniji sustav ručnoga laserskog skenera te je prvi put za navedene ciljeve testiran u nizinskim sastojinama hrasta lužnjaka. Pri tome je naglasak bio na potpuno automatiziranoj obradi podataka, uz neizbježno podešavanje nužnih parametara prilikom pojedinih postupaka. Rezultati ručnoga laserskog skeniranja, kao i klasična terenska izmjera promjerkom s podjelom na debljinske stupnjeve od 5 cm, uspoređeni su s referentnim terenskim podacima (prsni promjeri izmjereni mjernom vrpcom). Dobiveni rezultati ukazali su na velik potencijal primjene tehnologije ručnoga laserskog skeniranja. Automatiziranom segmentacijom stabala na šest primjernih ploha dobiven je postotak detekcije od 93 %, pri čemu su jasno detektirani propusti automatske segmentacije i načini kako ih se može otkloniti. Nadalje, utvrđeno je da pogreške automatske segmentacije imaju utjecaj i na procjenu prsnog promjera, čija se točnost znatno poboljšava nakon eliminacije grubih pogrešaka uzrokovanih automatskom segmentacijom. Potrebno je napomenuti da je broj takvih pogrešaka zadovoljavajući (tri) u odnosu na ukupni broj stabala (113). U usporedbi s klasičnom terenskom izmjerom s promjerkom ($RMSE_{\%}$ = 2,39 %), automatska procjena prsnih promjera na temelju podataka ručnoga laserskog skeniranja pruža podatak tek nešto slabije točnosti ($RMSE_{\%}$ = 5,27 %). S druge strane, prikupljeni podaci mogu se višestruko provjeravati i

obrađivati različitim alatima. Nadalje, točnost prikupljenih podataka može se pospješiti jednostavnom vizualnom kontrolom dobivenih rezultata te eventualnom manualnom obradom podataka. S obzirom na pozitivne preliminarne rezultate dobivene ovim istraživanjem, daljnja istraživanja trebaju biti usmjerena na sastojine različitih strukturnih i stanišnih karakteristika te na definiranje optimalnih shema skeniranja i metoda obrade prikupljenih podataka (npr. automatizirane, poluautomatizirane, manualne), a sve radi definiranja optimalne metodologije primjene ručnoga laserskog skeniranja u izmjeri šuma.

Zahvala

Acknowledgments

Ovaj rad sufinanciran je sredstvima Programa znanstveno-istraživačkog rada (ZIR) Hrvatskih šuma d. o. o. u sklopu projekta *Primjena terestričkog laserskog skeniranja u preciznoj operativnoj izmjeri šuma (LASSCAN-2)* te na temelju programskog ugovora s Ministarstvom znanosti i obrazovanja u sklopu projekta *Uspostava i razvoj laboratorija za daljinska istraživanja i geoinformacije u šumarstvu i okolišu (LABDIG)* koji financira Europska unija – *NextGenerationEU*.

Literatura

Literature

Balenović, I., X. Liang, L. Jurjević, J. Hyyppä, A. Seletković, A. Kukko, 2021: Hand-held personal laser scanning – current status and perspectives for forest inventory application. Croatian journal of forest engineering, 42 (1): 19. https://doi.org/10.5552/crojfe.2021.858.

Bauwens, S., H. Bartholomeus, K. Calders, P. Lejeune, 2016: Forest inventory with terrestrial LiDAR: a comparison of static and hand-held mobile laser scanning. Forests, 7 (6): 127. https://doi.org/10.3390/f7060127.

Cabo, C., C. Ordóñez, C. A. López-Sánchez, J. Armesto, 2018: Automatic dendrometry: tree detection, tree height and diameter estimation using terrestrial laser scanning. International journal of applied earth observation and geoinformation, 69: 164 – 174. https://doi.org/10.1016/j.jag.2018.01.011.

Chen, S., H. Liu, Z. Feng, C. Shen, P. Chen, 2019: Applicability of personal laser scanning in forestry inventory. PLOS ONE, 14 (2): e0211392. https://doi.org/10.1371/journal.pone.0211392.

GeoSLAM, 2020a: ZEB-HORIZON User Manual v1.3. https://geoslam.com/wp-content/uploads/2021/02/ZEB-Horizon-User-Manual-v1.3.pdf.

GeoSLAM, 2020b: GeoSLAM Hub 6 User Manual. https://downloads.faro.com/index.php/s/JWrxDgT3YjNLScR.

Gollob, C., T. Ritter, A. Nothdurft, 2020: Forest inventory with long range and high-speed personal laser scanning (PLS) and simultaneous localization and mapping (SLAM) technology. Remote sensing, 12 (9): 1509. https://doi.org/10.3390/rs12091509.

GreenValley International, 2021: LiDAR360 user guide V5.0. https://www.greenvalleyintl.com//static/upload/file/20210817/1629190611196646.pdf.

Hyyppä, E., X. Yu, H. Kaartinen, T. Hakala, A. Kukko, M. Vastaranta, J. Hyyppä, 2020: Comparison of backpack, handheld, under-canopy UAV, and above-canopy UAV laser scanning for field reference data collection in boreal forests. Remote sensing, 12 (20): 3327. https://doi.org/10.3390/rs12203327.

Hyyppä, J., A. Jaakkola, Y. Chen, A. Kukko, 2013: Unconventional LIDAR mapping from air, terrestrial and mobile. Photogrammetric week, 205 – 214.

Jurjević, L., M. Gašparović, X. Liang, I. Balenović, 2021: Assessment of close-range remote sensing methods for DTM estimation in a lowland deciduous forest. Remote sensing, 13 (11): 2063. https://doi.org/10.3390/rs13112063.

Kukko, A., H. Kaartinen, J. Hyyppä, Y. Chen, 2012: Multiplatform mobile laser scanning: usability and performance. Sensors, 12 (9): 11712 – 11733. https://doi.org/10.3390/s120911712.

Liang, X., J. Hyyppä, H. Kaartinen, M. Lehtomäki, J. Pyörälä, N. Pfeifer, M. Holopainen, G. Brolly, P. Francesco, J. Hackenberg, H. Huang, H. Jo, M. Katoh, L. Liu, M. Mokroš, J. Morel, K. Olofsson, J. Poveda-Lopez, J. Trochta, D. Wang, J. Wang, Z. Xi, B. Yang, G. Zheng, V. Kankare, V. Louma, X. Yu, L. Chen, M. Vastaranta, N. Saarinen, Y. Wang, 2018a: International benchmarking of terrestrial laser scanning approaches for forest inventories. ISPRS Journal of photogrammetry and remote sensing, 144: 137 – 179. https://doi.org/10.1016/j.isprsjprs.2018.06.021.

Liang, X., A. Kukko, J. Hyyppä, M. Lehtomäki, J. Pyörälä, X. Yu, H. Kaartinen, A. Jaakkola, Y. Wang, 2018b: In-situ measurements from mobile platforms: An emerging approach to address the old challenges associated with forest inventories. ISPRS Journal of photogrammetry and remote sensing, 143: 37 – 107. https://doi.org/10.1016/j.isprsjprs.2018.04.019.

Liang, X., J. Hyyppä, A. Kukko, H. Kaartinen, A. Jaakkola, X. Yu, 2014: The use of a mobile laser scanning system for mapping large forest plots. IEEE Geoscience and remote sensing letters, 11 (9): 1504 – 1508. https://doi.org/10.1109/LGRS.2013.2297418.

Liang, X., J. Hyyppä, H. Kaartinen, M. Holopainen, T. Melkas, 2012: Detecting changes in forest structure over time with bi-temporal terrestrial laser scanning data. ISPRS International journal of geo-information, 1 (3): 242 – 255. https://doi.org/10.3390/ijgi1030242.

Petrie, G., C. K. Toth, 2009: Terrestrial laser scanners. Topographic laser ranging and scanning principles and processing, 1: 87 – 128.

Sofia, S., S. Sferlazza, A. Mariottini, M. Niccolini, T. Coppi, M. Miozzo, T. La Mantia, F. Maetzke, 2021: A case study of the application of hand-held mobile laser scanning in the planning of an Italian forest (Alpe di Catenaia, Tuscany), Int. Arch. Photogramm. Remote sens. spatial inf. sci., XLIII-B2-2021: 763 – 770. https://doi.org/10.5194/isprs-archives-XLIII-B2-2021-763-202.

Tao, S., F. Wu, Q. Guo, Y. Wang, W. Li, B. Xue, X. Hu, P. Li, D. Tian, C. Li, H. Yao, Y. Li, G. Xu, J. Fang, 2015: Segmenting tree crowns from terrestrial and mobile LiDAR data by exploring ecological theories. ISPRS Journal of photogrammetry and remote sensing, 110: 66 – 76. https://doi.org/10.1016/j.isprsjprs.2015.10.007.

TupinambáSimões, F., A. Pascual, J. GuerraHernández, C. Ordóñez, T. de Conto, F. Bravo, 2023: Assessing the performance of a handheld laser scanning system for individual tree mapping – a mixed forests showcase in Spain. Remote sensing, 15 (5): 1169. https://doi.org/10.3390/rs15051169.

Wang, Y., M. Lehtomäki, X. Liang, J. Pyörälä, A. Kukko, A. Jaakkola, J. Liu, Z. Feng, R. Chen, J. Hyyppä, 2019: Is field-measured tree height as reliable as believed – a comparison study of tree height estimates from field measurement, airborne laser scanning and terrestrial laser scanning in a boreal forest. ISPRS Journal of photogrammetry and remote sensing, 147: 132 – 145. https://doi.org/10.1016/j.isprsjprs.2018.11.008.

White, J. C., N. C. Coops, M. A. Wulder, M. Vastaranta, T. Hilker, P. Tompalski, 2016: Remote sensing technologies for enhancing forest inventories: a review. Canadian journal of remote sensing, 42 (5): 619 – 641. https://doi.org/10.1080/07038992.2016.1207484.