https://doi.org/10.31298/sl.149.11-12.1

Izvorni znanstveni članci – Original scientific papers
Šumarski list, 11-12 (2025): 503-516

TOČNOST PROCJENE ATRIBUTA POJEDINAČNIH STABALA RUČNIM LASERSKIM SKENIRANJEM U STAROJ SASTOJINI HRASTA LUŽNJAKA

ACCURACY OF TREE ATTRIBUTE ESTIMATES BY PERSONAL LASER SCANNING IN AN OLD PEDUNCULATE OAK FOREST

Ante SELETKOVIĆ[1], Albert SEITZ[2], Andro KOKEZA[2], Matej MATOŠEVIĆ[3], Ivan BALENOVIĆ[2]*

SAŽETAK

U radu je testirana točnost trenutno najsuvremenijeg komercijalnog ručnog laserskog skenera (PLS) pri procjeni prsnog promjera i visine stabala u staroj sastojini hrasta lužnjaka (*Quercus robur* L.). Istraživanje je provedeno na tri primjerne plohe polumjera 20 m s ukupno 40 stabala. Kao referentne vrijednosti korišteni su prsni promjeri izmjereni mjernom vrpcom te visine stabala procijenjene statičkim terestričkim laserskim skeniranjem (TLS). Rezultati su pokazali vrlo visoku točnost PLS procjena za oba analizirana atributa: za prsni promjer srednje odstupanje (MD) iznosilo je 0,62 cm (1,28 %), a korijen srednje kvadratne pogreške (RMSE) 1,04 cm (2,13 %), dok su procjene visine stabala ostvarene s MD = 0,22 m (0,69 %) i RMSE = 0,30 m (0,95 %). U oba slučaja uočen je blagi trend precjenjivanja. Utvrđena visoka podudarnost s referentnim vrijednostima (r = 0,995) potvrđuje gotovo savršeno slaganje između PLS procjena i terenskih izmjera prsnih promjera te PLS i TLS procjena visina stabala. Dobiveni rezultati ukazuju da PLS tehnologija, pruža vrlo točne procjene prsnog promjera i visina stabala te predstavlja iznimno perspektivnu metodu za primjenu u operativnoj inventuri šuma.

KLJUČNE RIJEČI: ručno lasersko skeniranje (PLS), LiDAR, prsni promjer, visina stabala, inventura šuma

UVOD

INTRODUCTION

Za potrebe održivog gospodarenja šumama nužno je raspolagati detaljnim i sveobuhvatnim podacima o šumskim resursima, koji se u pravilu prikupljaju inventurom šuma. U većini zemalja u svijetu podaci inventure šuma prikupljaju se prvenstveno pomoću konvencionalnih terenskih mjerenja provedenih na primjernim površinama (Liang i dr. 2022). U Hrvatskoj je način i intenzitet izmjere propisan Pravilnikom o uređivanju šuma (NN 97/2018, 38/2024). Pojednostavljeno, prsni promjer stabala mjeri se uglavnom na sistematskom uzorku primjernih površina, a propisani intenzitet uzorkovanja ovisi o načinu gospodarenja, uzgojnom obliku te starosti sastojine. Iznimno, u jednodobnim sastojinama visokog uzgojnog oblika određenih dobnih razreda i boniteta u kojima se propisuje etat glavnog prihoda u narednom polurazdoblju provodi se tzv. totalna klupaža, tj. mjere se prsni promjeri svih stabala u sastojini. Za razliku od prsnih promjera, izmjera visina stabala zahtijeva znatno veći utrošak vremena, pa visine stabala predstavljaju najskuplji podatak koji se prikuplja u okviru inventura šuma (Durrieu i dr. 2015). Stoga se visine stabala mjere na značajno manjem uzroku stabala nego prsni promjeri. Na temelju izmjerenih visina, konstruira se visinska krivulja i određuje tarifni niz za određenu grupu sastojina (odsjeka). Pored navedenog, terenske izmjere visina

[1] Prof. dr. sc. Ante Seletković, Sveučilište u Zagrebu Fakultet šumarstva i drvne tehnologije, Zagreb
[2] Albert Seitz, univ. mag. ing. geod. et geoinf., Andro Kokeza, mag. ing. geod. et geoinf., dr. sc. Ivan Balenović, Hrvatski šumarski institut, Jastrebarsko
[3] Matej Matošević, mag. ing. silv., Zagreb
* Dopisni autor: Ivan Balenović, email: ivanb@sumins.hr

pojedinačnih stabala u pravilu imaju značajno nižu točnost u odnosu na mjerenja prsnih promjera (Luoma i dr. 2017). Kod uobičajeno korištenih ultrazvučnih visinomjera (Vertex hipsometara), pogreške u procjeni visine stabala mogu iznositi 1–5 m ili čak i više (Ganz i dr. 2019, Stereńczak i dr. 2019, Wang i dr. 2019), i to ponajprije zbog ograničene vidljivosti vrhova krošanja, osobito u šumskim sastojinama kompleksnije strukture (Liang i dr. 2022). Na točnost terenske procjene visina utječe i niz drugih faktora poput vrste drveća i oblika krošnje, visine i oblika stabla (npr. nagnutost), topografije terena, udaljenosti mjerenja te vještine (preciznost) i iskustva operatera (Larsen i dr. 1987, Korning i Thomsen 1994, Bragg i dr. 2014, Stereńczak i dr. 2019, Jurjević i dr. 2020). Nadalje, Tomplaski i dr. (2014) utvrdili su da pogreške u procjenama visine stabala imaju značajniji utjecaj na procjene volumena stabala nego pogrešna identifikacija vrsta stabala.

Iako su konvencionalne terenske metode inventure šuma provjerene i u određenoj mjeri pouzdane, one su prije svega radno intenzivne, dugotrajne, a samim time i iziskuju značajna novčana sredstva. Stoga su ograničene na malu uzorkovanu površinu i malu vremensku rezoluciju. Metode daljinskih istraživanja imaju potencijal unaprijediti klasične terenske metode, osobito smanjenjem radno intenzivnih i dugotrajnih mjerenja, što je odavno prepoznato u šumarskoj znanosti i praksi (White i dr. 2016). Najznačajniji napredak u istraživanjima primjene daljinskih istraživanja u inventuri šuma dogodio se tijekom proteklih dva-tri desetljeća pojavom i razvojem tehnologije laserskog skeniranja, poznate i kao LiDAR (engl. *Light Detection and Ranging*) (Wang i dr. 2019). Kao posljedica toga, zračno lasersko skeniranje (ALS – engl. *Airborne Laser Scanning*) implementirano je u operativnim inventurama šuma na razini ploha u određenom broju razvijenih zemalja s vremenski učestalijim nacionalnim skeniranjima (Rahlf i dr. 2014., Wang i dr. 2019). Glavno ograničenje ALS tehnologije je nemogućnost dobivanja informacija o pojedinačnim stablima, posebno u kompleksnijem šumskom okruženju. Međutim, konstantan i brz tehnološki napredak u pogledu senzora i razvoja algoritama doveli su do pojave raznih terestričkih sustava laserskog skeniranja. U usporedbi sa zračnim sustavima, terestrički sustavi mogu prikupiti sveobuhvatne i vrlo precizne podatke o pojedinačnim stablima na detaljnoj razini (npr. grane). Trenutačno, statičko terestričko lasersko skeniranje (TLS – engl. *Terrestrial Laser Scanning*) pruža najvišu geometrijsku kvalitetu među svim senzorima i platformama (Liang i dr. 2022), ali ima ograničenu praktičnu primjenu zbog brzine odnosno sporosti prikupljanja podataka. Naime, kako bi se smanjio učinak zaklonjenosti (okluzije) uzrokovan okolnim stablima i grmljem, odnosno kako bi se dobio oblak točaka koji detaljno opisuje svako stablo na plohi, skeniranje ploha potrebno je provesti s više pozicija koristeći tzv. pristup višestrukog skeniranja. Stoga su glavne primjene TLS-a još uvijek povezane s istraživačkim radovima u inventuri šuma, npr. za prikupljanje detaljnih informacija o svojstvima stabala koje nije jednostavno dobiti klasičnim terenskim metodama (Liang i dr. 2018) ili referentnih podataka za validaciju drugih sustava i izvora podataka (Liang i dr. 2016, Wilkes i dr. 2017, Disney i dr. 2019). Primjerice, TLS se najčešće koristi kao referentni podatak pri procjeni visina dubećih stabala budući da je dokazano kako točnije procjenjuje visinu od klasičnih, konvencionalnih terenskih metoda (Calders i dr. 2015, Disney i dr. 2019).

Suvremeni sustavi terestričkog mobilnog laserskog skeniranja predstavljaju učinkovitu alternativu TLS-u jer mogu potpuno ili značajno smanjiti problem okluzije te značajno ubrzati cjelokupni postupak prikupljanja podataka (Balenović i dr. 2021). Napredak u minijaturizaciji senzora tijekom posljednjih desetak godina rezultirao je razvojem laganih i mobilnih ručnih laserskih skenera (PLS – engl. *Personal Laser Scanning*) koje može nositi ili držati jedna osoba. Glavne prednosti komercijalnih ručnih PLS sustava postignute su zamjenom globalnog navigacijskog satelitskog sustava (GNSS-a – engl. *Global Navigation Satellite System*) s algoritmom za istovremenu lokalizaciju i kartiranje (SLAM – engl. *Simultaneous Localization And Mapping*), što čini PLS sustave prikladnim za korištenje u šumskim područjima gdje je GNSS signal često degradiran. Prva značajnija preliminarna PLS istraživanja u inventuri šuma započela su prije 10-ak godina (Ryding i dr. 2015, Bauwens i dr. 2016) pojavom prvih komercijalnih PLS instrumenata. Balenović i dr. (2021) dali su detaljan pregled PLS istraživanja u inventuri šuma provedenih u razdoblju od 2015. do 2020. godine te su istaknuli veliki potencijal PLS tehnologije, ali i određena ograničenja uzrokovana tadašnjim tehničkim mogućnostima instrumenata. Tijekom posljednjih pet godina, razvoj PLS instrumenata u pogledu tehničkih karakteristika (npr. domet, brzina i rezolucija skeniranja, integracija panoramske kamere, itd.) vrlo je intenzivan i dinamičan, što je rezultiralo brojnim istraživanjima o mogućnostima njihove primjene u inventuri šuma (Jurjević i dr. 2020, 2021; Mokroš i dr. 2021; Gollob i dr. 2023; Tupinambá-Simões i dr. 2023; Giannetti i dr. 2024; Guan i dr. 2024a; Henrich i dr. 2024; Kokeza i dr. 2024; Sofia i dr. 2024; Kükenbrink i dr. 2025, itd.). Iako su dosadašnja istraživanja ukazala na velik potencijal primjene PLS-a u inventuri šuma, još uvijek se mogu smatrati preliminarnima jer su uglavnom provedena na malom broju primjernih ploha, u sastojinama specifičnih strukturnih karakteristika i s fokusom na točno određeni atribut stabla.

U kontekstu Hrvatske i njenih glavnih šumskih

ekosustava provedeno je nekoliko relevantnih istraživanja. Jurjević i dr. (2020) proveli su istraživanje na šest primjernih ploha u nizinskoj, srednjodobnoj šumi hrasta lužnjaka (*Quercus robur* L.) gdje su usporedili različite tehnologije blizu-predmetnih daljinskih istraživanja, i to PLS, lasersko skeniranje iz bespilotne letjelice (ULS – engl. *Unmanned Aerial Scanning*) i aerofotogrametriju iz bespilotne letjelice (UAV_p – engl. *Unmanned Aerial Vehihle Photogrammetry*) te konvencionalne terenske metode za procjenu visine stabala. Istraživanje provedeno u vrijeme mirovanja vegetacije pokazalo je da PLS daje najtočnije procjene visina, osobito za stabla viša od 21 m (dominantna i kodominantna etaža). Na istom području, Jurjević i dr. (2021) evaluirali su točnost različitih blizu-predmetnih tehnologija daljinskih istraživanja (TLS, PLS, ULS, UAV_p) za izradu digitalnog modela reljefa i utvrdili da se korištenjem navedenih tehnologija postiže veća točnost od klasičnih metoda izrade digitalnih modela reljefa (zračno lasersko skeniranje i digitalna aerofotogrametrija iz zrakoplova). Nadalje, Kokeza i dr. (2024) proveli su preliminarno testiranje dva najsuvremenija komercijalna PLS instrumenta (GeoSlam ZEB Horizon, Faro Orbis) na jednoj primjernoj plohi u starijoj nizinskoj šumi hrasta lužnjaka za procjenu prsnog promjera stabala te utvrdili da noviji uređaj s poboljšanim karakteristikama (Faro Orbis) daje rezultate nešto veće točnosti. Također je utvrđeno kako složenije sheme skeniranja dodatno povećavaju preciznost rezultata. Na temelju dosadašnjih spoznaja može se zaključiti da PLS trenutno predstavlja najperspektivniju tehnologiju laserskog skeniranja za primjenu u operativnoj inventuri šuma. Ipak, zbog ograničenog broja provedenih istraživanja još uvijek nedostaju smjernice o najboljoj praksi za prikupljanje i obradu PLS podataka (Balenović i dr. 2021, Liang i dr. 2022). S obzirom na stalan i brz razvoj PLS uređaja i softverskih rješenja, nužno je provoditi kontinuirana i detaljna istraživanja kako bi se unaprijedila njihova primjena u preciznoj inventuri šuma. Glavni cilj ovog istraživanja je testirati točnost tehnologije ručnog laserskog skeniranja korištenjem trenutno najsuvremenijeg komercijalnog PLS instrumenta za procjenu prsnog promjera i visina stabala u staroj sastojini hrasta lužnjaka.

MATERIJAL I METODE

MATERIAL AND METHODS

Područje istraživanja – *Study area*

Istraživanjem su obuhvaćene tri kružne primjerne plohe polumjera 20 m u staroj sastojini (145 godina starosti) uređajnog razreda hrasta lužnjaka (odsjek 71b) u gospodarskoj jedinici Šiljakovačka Dubrava na području Uprave šuma podružnica Zagreb, šumarije Velika Gorica (Slika 1). Inače mješovita sastojina hrasta lužnjaka i običnoga graba (*Carpinus betulus* L.) II boniteta, u vrijeme prikupljanja podataka (ožujak 2025. godine) nalazila se u fazi prirodne obnove oplodnim sječama tijekom koje su već provedeni pripremni i naplodni sijek. Stoga su u sastojini tijekom prikupljanja podataka bila prisutna samo stabla hrasta lužnjaka ostavljena za dovršni sijek. Tri kružne primjerne plohe uključene u ovo istraživanje odabrane su iz većeg uzorka sistematski postavljenih primjernih ploha (100 × 100 m) na temelju broja stabala, s ciljem da predstavljaju strukturne karakteristike čitave sastojine. Odabrane su plohe s 11, 13 i 16 stabala hrasta lužnjaka. Teren na području istraživanja je ravničarski bez nagiba, a nadmorska visina terena kreće se oko 116 metara.

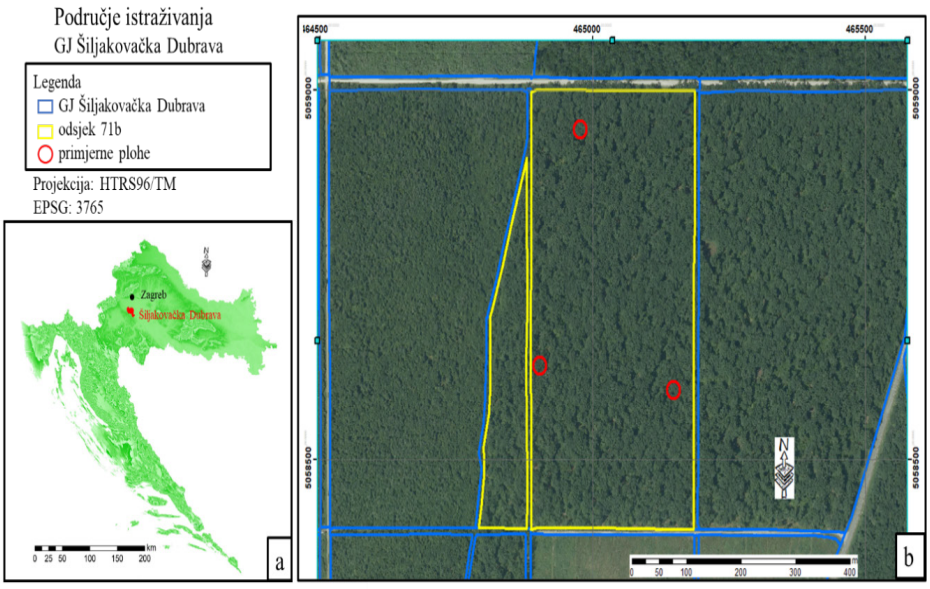

Slika 1. Područje istraživanja: a) lokacija gospodarske jedinice Šiljakovačka Dubrava u Hrvatskoj, b) prostorni raspored primjernih ploha u sastojini (odsjek 71b).
Figure 1 Study area: a) location of the Šiljakovačka Dubrava Management Unit in Croatia, b) spatial distribution of the sample plots in the stand (subcompartment 71b).

Detaljna terenska izmjera – *Detailed field measurements*

Detaljna terenska izmjera na primjernim plohama provedena je u stanju mirovanja vegetacije, početkom ožujka 2025. godine. Prvotno je centar plohe obilježen geodetskom oznakom te mu je pozicija precizno izmjerena GNSS instrumentom Trimble R12i (Trimble Inc., Westminster, Colorado, SAD) povezanim na hrvatski pozicijski sustav (CROPOS – engl. *CROatian POsitioning System*) koristeći visokoprecizni servis pozicioniranja u realnom vremenu (VPPS) s kojim se postiže deklarativna točnost mjerenja od ≈ 2 – 4 cm (Dragčević i dr. 2016). Osim centra plohe, na svakoj plohi su na isti način obilježene i izmjerene pozicije četiri orijentacijske točke pravilno raspoređene na sjevernom, zapadnom, južnom i istočnom rubu plohe. Orijentacijske točke su se naknadno koristile za georeferenciranje TLS i PLS podataka (oblaka točaka). Potom je svakom stablu na plohi izmjerena pozicija, provedena obilježba i numeracija stabala, te izmjeren opseg odnosno prsni promjer. Pozicija svakog stabla dobivena je mjerenjem udaljenosti i azimuta od centra plohe. Za mjerenje udaljenosti korišten je Vertex IV daljinomjer (Haglöf Sweden AB, Långsele, Sweden), a za mjerenje azimuta busola Suunto KB-14 (Suunto Oy, Vantaa, Finland). Stabla su numerirana s pozicije centra plohe gledano prema sjeveru pa u smjeru kazaljke na satu. Na svakom stablu na visini 1,3 m od tla drvomarker sprejom označeno je mjesto izmjere opsega odnosno prsnog promjera. Visina od 1,3 m iznad tla određena je prislanjanjem letve uz samo stablo. Izmjera opsega odnosno prsnog promjera provedena je mjernom vrpcom s milimetarskom podjelom i to na prethodno označenoj visini mjerenja.

Lasersko skeniranje – *Laser scanning*

Statičko terestričko lasersko skeniranje (TLS) i mobilno ručno lasersko skeniranje (PLS) provedeno je gotovo istovremeno kada i detaljna terenska izmjera, početkom ožujka 2025. godine. Za prikupljanje TLS podataka korišteni su laserski skener FARO Focus Premium 150 (FARO Technologies Inc., Lake Mary, Florida, USA), predstavljen na tržištu 2022. godine (Slika 2, Tablica 1), te pristup višestrukog skeniranja (Slika 3a). Skeniranje se izvodilo s pet stajališta na svakoj plohi, uključujući centar plohe i četiri stajališta raspoređenih u blizini orijentacijskih točaka udaljenih približno 1 m od granice plohe. Za potrebe naknadne registracije (povezivanja) stajališta odnosno TLS podataka, unutar svake plohe postavljene su četiri sfere raspoređene na način da su najmanje tri bile vidljive sa svakog stajališta skeniranja. Skeniranje je provedeno s postavkama rezolucije ¼ i kvalitete 4x. Rezolucija označava razinu detalja (razlomak ukupne moguće razlučivosti snimanja), dok kvaliteta određuje broj ponavljanja istog mjerenja po točki. Odabrani parametri rezultirali su trajanjem skeniranja od približno pet minuta po stajalištu. Uključujući promjene položaja i podešavanje stajališta, ukupno vrijeme skeniranja jedne plohe iznosilo je oko jedan sat.

Prikupljanje PLS podataka provedeno je laserskim skenerom FARO Orbis (FARO Technologies Inc., Lake Mary, Florida, USA), predstavljenim na tržištu krajem 2023. godine (Slika 2, Tablica 2). Skeniranje se provodilo prema unaprijed definiranom obrascu kretanja kroz plohu. Shema kretanja oblikovana je tako da omogući optimalnu pokrivenost plohe, odnosno da sva stabla budu skenirana iz više smjerova. Operator je skeniranje započeo u centru plohe te se kretao po zadanoj shemi, pritom se zaustavljajući na orijentacijskim točkama radi naknad-

Slika 2. Laserski skeneri korišteni u istraživanju: TLS instrument FARO Focus Premium 150 (lijevo) i PLS instrument FARO Orbis (desno).
Figure 2 Laser scanners used in the research: FARO Focus Premium 150 TLS instrument (left) and FARO Orbis PLS instrument (right).

Tablica 1. Osnovne specifikacije FARO Focus Premium 150 i FARO Orbis instrumenata.
Table 1 The main specifications of FARO Focus Premium 150 and FARO Orbis instruments.

	FARO Focus Premium 150	Faro Orbis
Domet (m) *Range (m)*	0,5 - 150	120
Brzina prikupljanja (točaka/sek) *Acquisition rate (points/sec)*	2.000.000	640.000
Preciznost (mm) *Precision (mm)*	± 1	5
Vidno polje (°) *Field of View (°)*	300/360	360/290

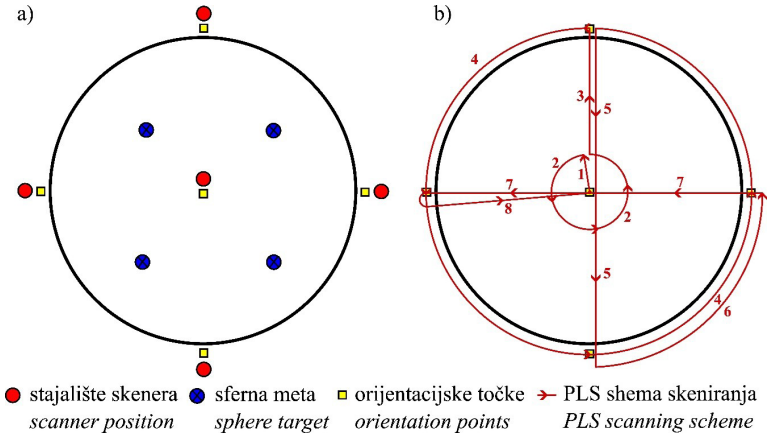

Slika 3. Planirane sheme skeniranja s: (a) FARO Focus Premium 150 i (b) FARO Orbis instrumentima.
Figure 3 Planning scanning schemes with: (a) FARO Focus Premium 150, and (b) FARO Orbis instruments.

nog georeferenciranja podataka. Vrijeme skeniranja svake plohe iznosilo je približno sedam minuta.

Obrada podataka laserskog skeniranja – *Processing of laser scanning data*

Prije same procjene pojedinačnih atributa stabala, provedena je predobrada prikupljenih TLS i PLS podataka. Predobrada TLS podataka provedena je u softveru FARO SCENE v2025.1.1 (FARO Technologies Inc., Lake Mary, Florida, USA). Prvo je na temelju skeniranih sfera provedena registracija odnosno povezivanje višestrukih skenova (oblaka točaka) jedne plohe u jedan oblak točaka, koji je potom pomoću orijentacijskih točaka georeoferenciran iz lokalnog koordinatnog sustav u HTRS96/TM koordinatni sustav. Georeferencirani oblaci točaka potom su izvezeni u .las format. Za predobradu PLS podataka korišten je softver FARO Connect v2025.1 (FARO Technologies Inc., Lake Mary, Florida, USA) tijekom čega je provedeno georeferenciranje korištenjem orijentacijskih točaka te izvoz oblaka točaka svake plohe u .las formatu (Slika 4).

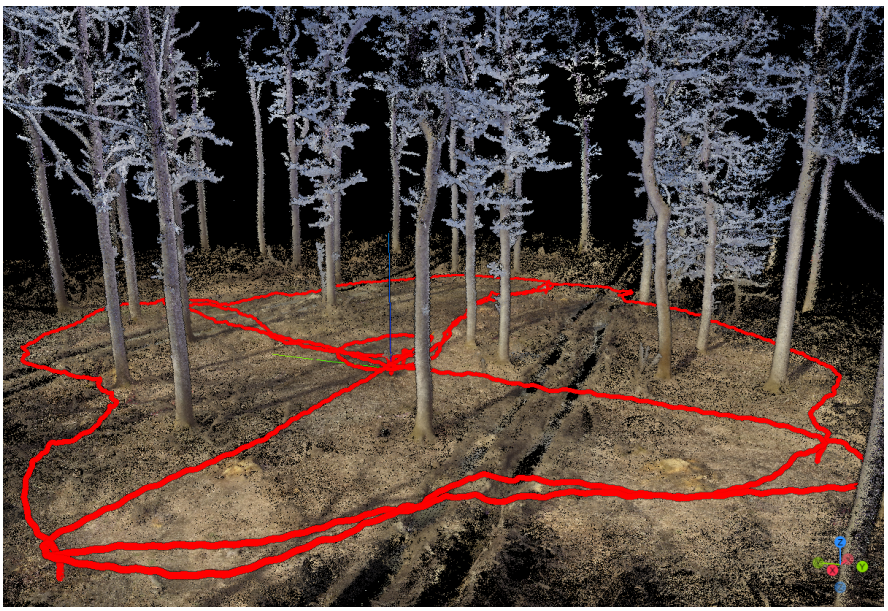

Slika 4. Prikaz georeferenciranog oblaka točaka i provedene sheme skeniranja (crvena linija) u FARO Connect softveru na primjeru jedne plohe.
Figure 4 Georeferenced point cloud with implemented scanning scheme (red line) in FARO Connect for one sample plot.

Obrada TLS i PLS podataka (oblaka točaka) provedena je na identičan način u softveru LiDAR360 v8.1. (GreenValley International, Berkeley, California, SAD). Pri tome je primijenjena polu-automatizirana obrada koja se sastojala od nekoliko koraka. Nakon učitavanja, svaki je oblak točaka obrezan u krug s radijusom od 25 m od centra plohe kako bi se sa sigurnošću zadržale krošnje stabala koja se nalaze uz rub plohe. Na taj je način smanjena veličina oblaka točaka i olakšana daljnja obrada. Potom su iz obrezanih oblaka točaka, korištenjem alata *Remove outliers*, uklonjeni eventualni odstupajući podaci (šumovi). Nakon toga su klasificirane točke tla korištenjem alata *Classify Ground Points*. Na temelju klasificiranih točaka tla, provedena je normalizacija oblaka točaka korištenjem alata *Normalize by Ground Points*. Normalizacijom su apsolutne (nadmorske) visine oblaka točaka transformirane u relativne visine čija nula predstavlja tlo sastojine.

Zatim je slijedila procjena prsnih promjera svih stabala na normaliziranom oblaku točka. U tu svrhu korišten je modul softvera *TLS Seed Point Editor* u kojem je na poprečnom presijeku oblaka točaka na visini od 1,30 m operator prvo manualno označio prsni promjer svakog stabla, a koje je potom precizno aproksimirano kružnicom korištenjem *Fit-by-Circle* algoritma. *Fit-by-Circle* algoritam koristi metodu najmanjih kvadrata za aproksimaciju prsnog promjera iz x, y vrijednosti oblaka točaka. Tako aproksimirani prsni promjeri poslužili su potom kao polazne točke (engl. *Seed Points*) za segmentaciju pojedinačnih stabala iz čitavog oblaka točaka korištenjem algoritma *Point Cloud Segmentation from Seed Points* (Slika 5). Time je osigurano da algoritam segmentira samo stabla povezana s unaprijed određenim polaznim točkama, a ujedno je smanjena mogućnost pogrešaka prilikom segmentacije. U procesu segmentacije, automatski je procijenjena i visina svakog segmentiranog stabla. Automatski procijenjene visine stabala manualno su provjerene i ukoliko je bilo potrebe ispravljene. Pojednostavljeni postupak procjene prsnog promjera i visine stabla iz oblaka točaka prikazan je na Slici 6.

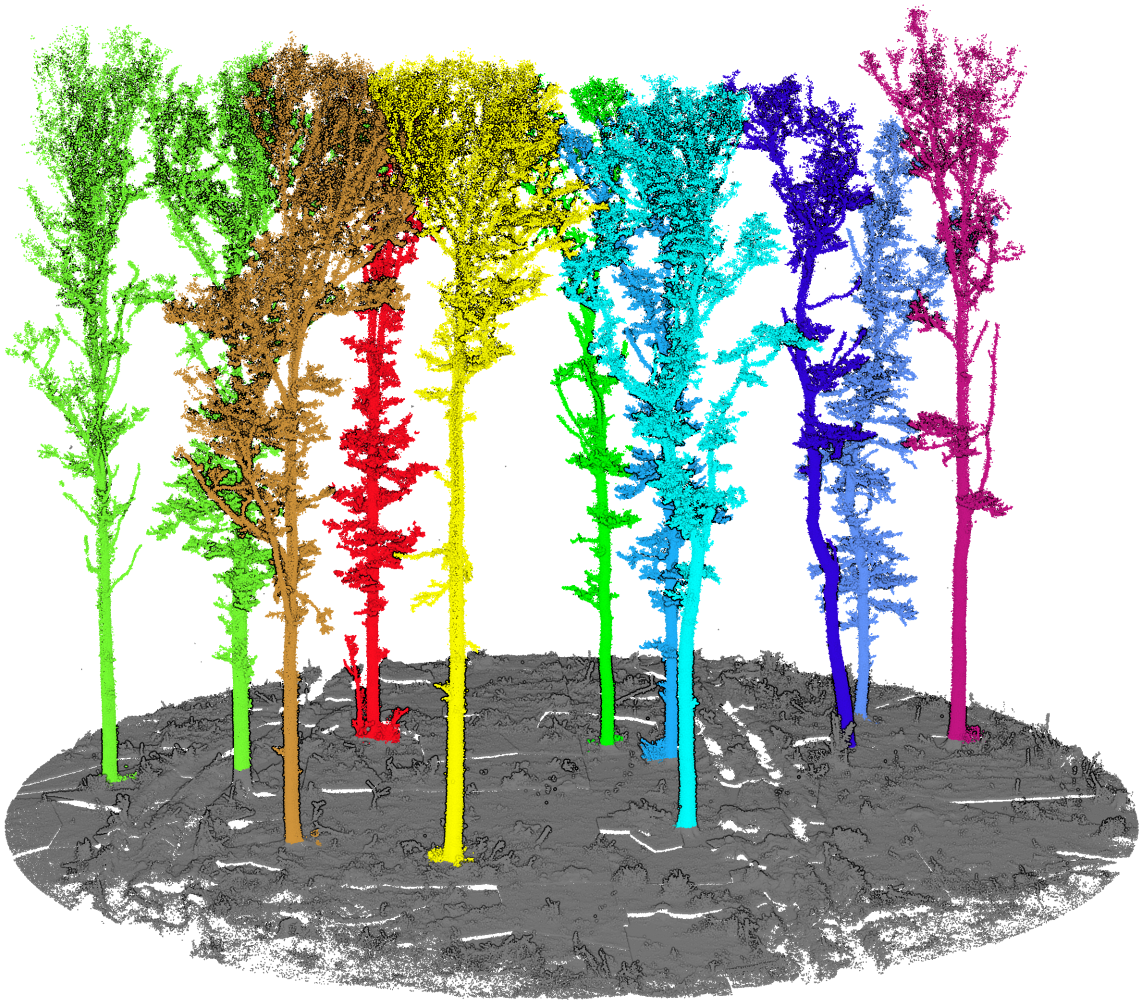

Slika 5. Segmentirani oblak točaka na primjeru jedne plohe.
Figure 5 Segmented point cloud for one sample plot.

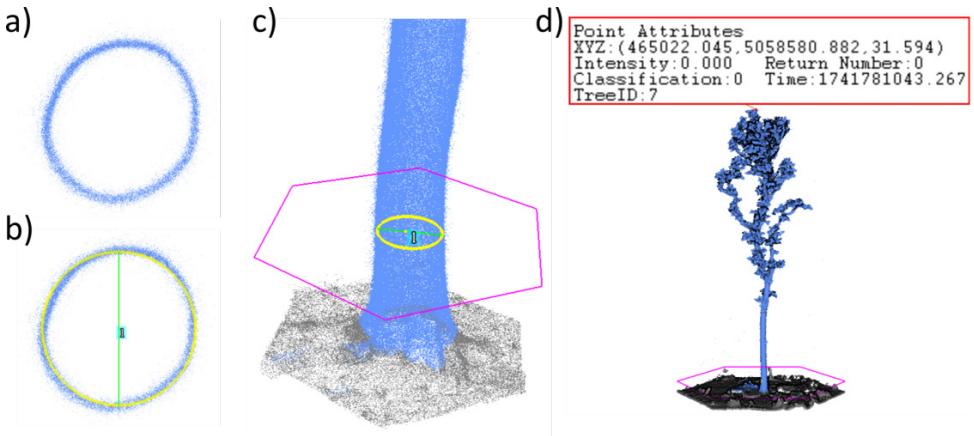

Slika 6. Pojednostavljeni postupak procjene atributa pojedinačnih stabala iz oblaka točaka: a) oblak točaka na površini presjeka debla na visini od 1,30 m, b) i c) prsni promjer aproksimiran kružnicom koji je ujedno poslužio kao polazna točka za segmentaciju stabala, d) segmentirano stablo i automatski ili manualno procijenjena visina.
Figure 6 Simplified workflow for estimating individual tree attributes from point clouds: a) point cloud of the stem cross-section at 1.30 m height, b) and c) diameter at breast height approximated by a fitted circle, used as a reference for tree segmentation, d) segmented tree with automatically or manually estimated height.

Ocjena točnosti – *Accuracy assessment*

Kako bi se ocijenila točnost procijenjenih vrijednosti prsnih promjera i visina stabala iz PLS izračunati su srednje odstupanje (MD, prema engl. *mean difference*) te korijen srednje kvadratne pogreške (RMSE, prema engl. *root mean square error*) prema jednadžbama 1 i 2. 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 te u postotnom iznosu od referentne vrijednosti prema jednadžbama 3 i 4. Kao referentne vrijednosti za ocjenu točnosti procijenjenih prsnih promjera i visina iz PLS podataka korišteni su prsni promjeri izmjereni mjernom vrpcom u okviru detaljne terenske izmjere, odnosno visine stabala procijenjene iz TLS podataka.

$$MD = \frac{\sum_{i=1}^{n}(\hat{y}_i - y_i)}{n} \quad (1)$$

$$MD_{\%} = \frac{MD}{\bar{y}} \cdot 100 \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(\hat{y}_i - y_i)^2}{n}} \quad (3)$$

$$RMSE_{\%} = \frac{RMSE}{\bar{y}} \cdot 100 \quad (4)$$

gdje je $\hat{y}_i$ procijenjena vrijednost prsnog promjera ili visine stabla iz PLS podataka za stablo i, y_i je referentna vrijednost prsnog promjera ili visine stabla za stablo i, n je broj stabala na sve tri primjerne plohe, $\bar{y}$ je aritmetička srednja vrijednost referentnog prsnog promjera ili visine stabla.

REZULTATI I RASPRAVA
RESULTS AND DISCUSION

Rezultati ocjene točnosti procijenjenih vrijednosti prsnih promjera i visina stabala iz PLS podataka u odnosu na referentne vrijednosti prikazani su u Tablici 2. Rezultati su objedinjeni za sve tri plohe, odnosno ukupno za 40 stabala hrasta lužnjaka. Prema referentnim podacima, mjernom vrpcom izmjereni su prsni promjeri u rasponu od 33,74 cm do 67,48 cm, sa srednjom vrijednošću od 48,57 cm, dok su iz TLS podataka procijenjene visine stabala u rasponu od 25,44 m do 35,07 m, sa srednjom visinom od 31,48 m. Vrijednosti izmjerenih i procijenjenih prsnih promjera i visina svakog stabla, dobivene terenskim mjerenjima te TLS i PLS podacima, nalaze se u dodatku (Tablica A1).

U odnosu na referentne vrijednosti, odstupanja procijenjenih prsnih promjera iz PLS podataka kretala su se od –0,99 cm do 3,02 cm. Vidljivo je da su minimalna i maksimalna odstupanja te ukupni raspon odstupanja manji od debljinskog stupnja (5 cm). Pri tumačenju rezultata treba uzeti u obzir i način određivanja visine prsnog promjera. U terenskoj izmjeri mjesto mjerenja (1,3 m od tla) određeno je prislanjanjem letve uz deblo, dok je kod PLS podataka promjer automatski procijenjen na visini od 1,3 m nakon klasifikacije i normalizacije oblaka točaka. Drugim riječima, razlike u određivanju visine izmjere mogle su pridonijeti odstupanjima između PLS i referentnih vrijednosti.

Vrlo visoka korelacija (r = 0,995) potvrđuje gotovo

Tablica 2. Točnost prsnih promjera (DBH) i visina stabala (H) procijenjenih iz PLS podataka u odnosu na referentne vrijednosti (prsni promjer izmjeren vrpcom te visina stabala procijenjena iz TLS podataka). Min, Max, SD, MD i RMSE za prsni promjer su iskazane u centimetrima, a za visine u metrima.
Table 2 Accuracy of diameter at breast height (DBH) and tree height (H) estimated from PLS data compared to reference values (DBH measured with a diameter tape and tree height estimated from TLS data). Min, Max, SD, MD and RMSE for DBH are expressed in centimeters, and for H in meters.

Atribut *Attribute*	R	Min	Max	SD	MD	MD%	RMSE	RMSE%
DBH	0,995	-0,99	3,02	0,84	0,62	1,28	1,04	2,13
H	0,995	-0,13	0,92	0,21	0,22	0,69	0,30	0,95

savršenu podudarnost između PLS procijenjenih i terenski izmjerenih prsnih promjera. Prema srednjoj pogrešci (MD = 0,62 cm; $MD_{\%}$ = 1,28 %) utvrđen je blagi trend precjenjivanja PLS procijenjenih prsnih promjera. To potvrđuje i grafički prikaz (Slika 7), na kojem je vidljivo gotovo konstantno blago precjenjivanje PLS procjena u odnosu na referentne vrijednosti, dok se tek manji broj slučajeva nalazi ispod 1:1 linije. Isti trend precjenjivanja zabilježen je i u drugim istraživanjima u lužnjakovim sastojinama korištenjem istog PLS instrumenta (FARO Orbis) (Kokeza i dr. 2024, 2025). Primjerice, Kokeza i dr. (2024) u starijoj lužnjakovoj sastojini (100 godina) testirali su dva najsuvremenija PLS instrumenta (GeoSlam ZEB Horizon i FARO Orbis) te različite sheme skeniranja. Najtočniji rezultati ($MD_{\%}$ = 0,58 %; $RMSE_{\%}$ = 1,42 %) postignuti su upravo FARO Orbisom uz istu shemu skeniranja kao u ovom istraživanju. Nadalje, u istom sastojinskom tipu, ali na drugoj plohi, Kokeza i dr. (2025) istražili su utjecaj razdoblja prikupljanja PLS podataka. Očekivano, nešto bolji rezultati postignuti su u razdoblju mirovanja vegetacije ($MD_{\%}$ = 1,23 %; $RMSE_{\%}$ = 1,76 %) nego u vegetacijskom razdoblju ($MD_{\%}$ = 1,43 %; $RMSE_{\%}$ = 2,04 %). Sveukupno, u ovom istraživanju utvrđen je isti trend precjenjivanja, uz nešto manju točnost u odnosu na prethodno navedena istraživanja. Glavni razlog vjerojatno leži u starosti i strukturi sastojine – manjoj gustoći stabala i većim dimenzijama prsnih promjera nego u starijim sastojinama. Kod stabala hrasta lužnjaka većih dimenzija moguće je precjenjivanje upravo zbog debele i hrapave kore. Na starijim stablima razvijaju se duboke brazde i zadebljanja, pa laserske zrake primarno registriraju „vrhove" kore umjesto prosječne linije debla, što rezultira većim procijenjenim promjerom. Takav je utjecaj potvrđen i u istraživanju Kokeze i dr. (2025), gdje je u bukovoj sastojini zabilježeno manje precjenjivanje ($MD_{\%}$ = 0,90 %) nego u lužnjakovoj ($MD_{\%}$ = 1,43 %). Ipak, zahvaljujući boljoj kvaliteti instrumenta i terenskim uvjetima, u lužnjakovoj je sastojini postignuta nešto veća točnost ($RMSE_{\%}$ = 2,04 %) nego u bukovoj ($RMSE_{\%}$ = 2,13 %).

Općenito, dobiveni rezultati u skladu su s nalazima drugih istraživanja (npr. Gollob i dr. 2020, Hyyppä i dr. 2020, Mokroš i dr. 2021, Guan i dr. 2024a, Kokeza i dr. 2024, Sofia i dr. 2024, Hrdina i dr. 2025, Kokeza i dr. 2025, Kükenbrink i dr. 2025). U njima su korišteni instrumenti poboljšanih karakteristika (npr. ZEB Horizon, FARO Orbis), a procjene prsnog promjera ostvarene su s pogreškama ($RMSE_{\%}$) u rasponu od 2,04 % do 25,92 %. Međutim, uz izuzetak domaćih istraživanja (Kokeza i dr. 2024, 2025), izravna usporedba nije moguća zbog razlika u strukturi sastojina, metodama prikupljanja podataka (npr. veličina i oblik plohe, shema skeniranja) te postupcima obrade (npr. softveri, algoritmi).

U odnosu na referentne vrijednosti visina stabala procijenjenih TLS-om, iz PLS podataka zabilježena su

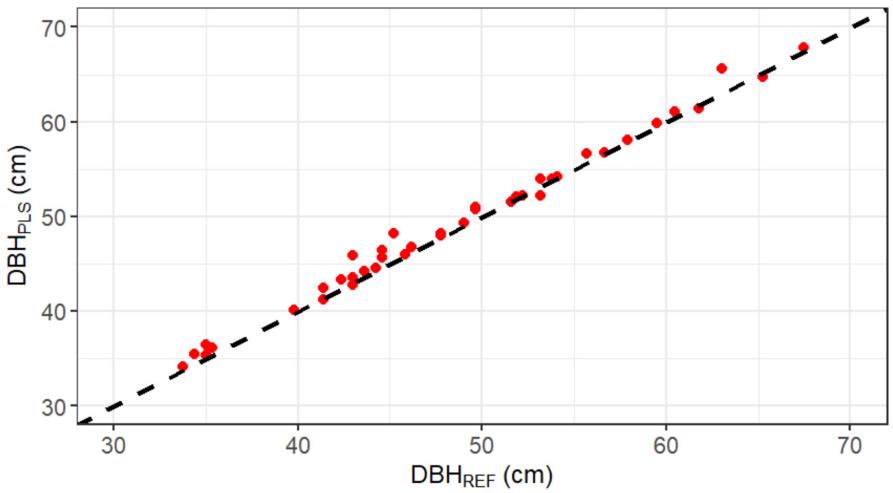

Slika 7. Usporedba prsnih promjera procijenjenih iz PLS podataka (DBH_{PLS}) i referentnih prsnih promjera izmjerenih mjernom vrpcom (DBH_{REF}).
Figure 7 Comparison of diameters at breast height estimated from PLS data (DBH_{PLS}) and reference diameters at breast height measured with a diameter tape (DBH_{REF})..

minimalna odstupanja u rasponu od –0,13 m do 0,92 m (Tablica 2). Vrlo visoka korelacija (r = 0,995) potvrđuje gotovo savršenu podudarnost između visina stabala procijenjenih TLS-om i PLS-om. Dobro slaganje između dvaju izvora podataka dodatno potvrđuju mjere točnosti. Prema srednjoj pogrešci (MD = 0,22 m; $MD_{\%}$ = 0,69 %), uočen je blagi trend precjenjivanja visina stabala procijenjenih iz PLS podataka u odnosu na TLS. Navedeni obrazac vidljiv je i na grafičkom prikazu (Slika 8), gdje su visine tek triju stabala neznatno podcijenjene, dok su kod preostalih 37 stabala uglavnom blago precijenjene, tj. smještene neposredno iznad linije 1:1 grafikona. Nadalje, dobivena vrijednost RMSE od 0,30 m (0,95 %) također potvrđuje minimalna odstupanja i visoku točnost PLS procjena visina stabala u odnosu na referentne TLS vrijednosti.

Ranija istraživanja (Cabo i dr. 2018, Giannetti i dr. 2018)

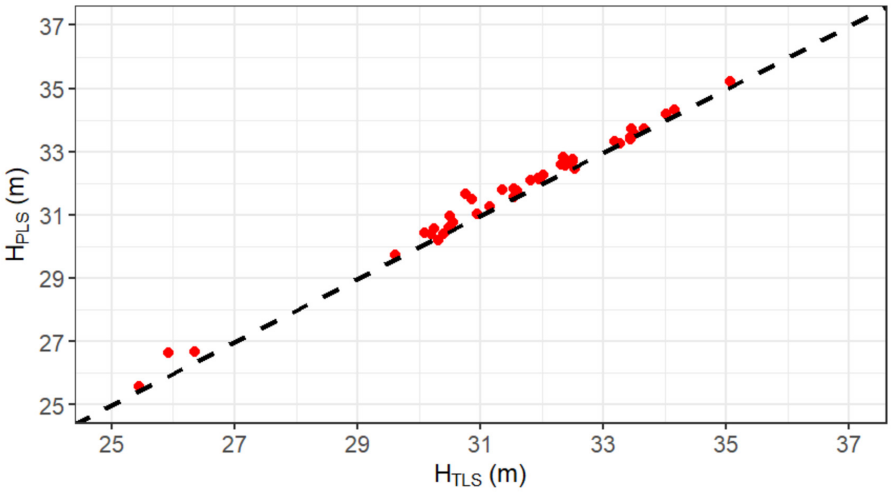

Slika 8. Usporedba visina stabala procijenjenih iz PLS podataka (H_{PLS}) i referentnih visina procijenjenih iz TLS podataka (H_{TLS}).
Figure 8 Comparison of tree heights estimated from PLS data (H_{PLS}) and reference tree heights estimated from TLS data (H_{TLS}).

pokazala su slabiju točnost procjene visina stabala, ponajprije zbog ograničenog dometa senzora. Primjerice, Cabo i dr. (2018) u urbanoj park-šumi (maksimalne visine stabala 18 m) procijenili su visine s RMSE od 1,34 m, dok su u planinskoj borovoj šumi (maksimalne visine 33 m) dobili RMSE od 9,44 m. Giannetti i dr. (2018) u mediteranskoj mješovitoj sastojini, unatoč nižim maksimalnim visinama (19 m), utvrdili su značajno podcjenjivanje i odstupanje procjena (MD = –4,61 m; RMSE = 2,15 m). U tim istraživanjima korišteni su PLS instrumenti (ZEB-REVO i ZEB1) čiji maksimalni domet skeniranja u šumama iznosi svega 15 – 20 m (Balenović i dr. 2021), što dovodi do izraženog podcjenjivanja stabala viših od 15 m.

Razvojem tehnologije značajno se povećao domet senzora. Od 2019. godine dostupni su instrumenti poput ZEB Horizona (100 m), a od 2023. i instrumenti poput FARO Orbisa (120 m). Istraživanja provedena novijom generacijom PLS instrumenata (Jurjević i dr. 2020, Hyypä i dr. 2020, Vandendaele i dr. 2022, Kokeza i dr. 2025) pokazala su znatno bolju točnost. Tako su Jurjević i dr. (2020) u srednjodobnim lužnjakovim sastojinama, usporedbom PLS (ZEB Horizon) i terenskih mjerenja, utvrdili MD od 0,45 m (1,82 %) i RMSE od 1,11 m (4,45 %). Hyypä i dr. (2020) u borealnim mješovitim sastojinama, koristeći ULS kao referencu, dobili su u rjeđim sastojinama MD od 1,3 m (6,0 %) i RMSE od 1,8 m (8,7 %), a u gušćim sastojinama MD od 0,68 m (3,0 %) i RMSE od 1,1 m (4,9 %). Vandendaele i dr. (2022) su u kanadskim mješovitim bjelogoričnim sastojinama, primjenom instrumenta Hovermap (100 m dometa) i usporedbom s TLS podacima, postigli RMSE od 0,42 m (1,78 %).

U ovom istraživanju postignuti su još točniji rezultati (Tablica 2; $MD_{\%}$ = 0,69 %; $RMSE_{\%}$ = 0,95 %). Razlozi mogu biti višestruki: poboljšane tehničke značajke FARO Orbisa u odnosu na ZEB Horizon i Hovermap, shema skeniranja i metode obrade podataka, struktura sastojine, kao i pouzdanost referentnih podataka. Direktna usporedba moguća je tek s istraživanjem Kokeze i dr. (2025), provedenim u starijoj lužnjakovoj sastojini korištenjem istog instrumenta, identične sheme skeniranja i obrade te evaluacije na temelju TLS podataka. U tom su istraživanju autori dobili vrlo slične rezultate, iako nešto niže točnosti (MD = 0,33 m; 1,23 %; RMSE = 0,47 m; 1,76 %), što se može pripisati razlikama u strukturi sastojina, odnosno većoj gustoći stabala na primjernim plohama koja otežava vidljivost vrhova krošnji. Zajedničko ovom i svim prethodno navedenim istraživanjima (Jurjević i dr. 2020, Hyypä i dr. 2020, Vandendaele i dr. 2022, Kokeza i dr. 2025) jest tendencija blagog precjenjivanja visina stabala procijenjenih PLS-om, neovisno o vrsti i tipu korištenih referentnih podataka. S obzirom na to, moguće je pretpostaviti da PLS daje možda i najtočnije procjene visina stabala u odnosu na metode

koje su u ranijim istraživanjima korištene kao referentne (TLS, ULS) ili za usporedbu (klasične terenske metode). Naime, već je u uvodnom poglavlju spomenuto da pogreška procjene visine stabala klasičnim terenskim metodama (ultrazvučni visinomjeri) može iznositi 1 – 5 m ili više (Ganz i dr. 2019, Stereńczak i dr. 2019, Wang i dr. 2019). Vandendaele i dr. (2022) već su raspravljali kako PLS može davati točnije procjene visina stabala nego TLS jer je TLS statički sustav i stoga pod većim utjecajem zaklanjanja (okluzije). Nadalje, brojna istraživanja (npr. Li i dr. 2023, Guan i dr. 2024b, Mîzgaciu i dr. 2025, Tupinambá-Simões i dr. 2025) potvrdila su da ULS podaci pokazuju tendenciju podcjenjivanja visina stabala zbog zaklonjenosti vrhova krošnji, manje gustoće točaka na vrhovima stabala i filtriranja izoliranih točaka tijekom obrade. Ipak, da bi se sa sigurnošću moglo potvrditi da PLS daje najtočnije procjene visina stabala, potrebno je provesti dodatna istraživanja izravne usporedbe različitih metoda, uz pouzdane referentne podatke (npr. izmjera dužina oborenih stabala predviđenih za sječu tijekom prorjeda ili oplodnih sječa).

ZAKLJUČCI
CONCLUSIONS

U ovom istraživanju testirana je točnost ručnog laserskog skeniranja (PLS) korištenjem trenutno najsuvremenijeg komercijalnog instrumenta za procjenu prsnog promjera i visina stabala u staroj sastojini hrasta lužnjaka. Procjene dobivene iz PLS podataka uspoređene su s referentnim vrijednostima prsnih promjera izmjerenih terenski mjernom vrpcom, odnosno visina stabala procijenjenih iz TLS podataka.

Dobiveni rezultati pokazali su vrlo visoku točnost PLS procjena za oba analizirana atributa stabala. Procjene prsnog promjera ostvarene su s prosječnim odstupanjem (MD) od 0,62 cm (1,28 %) i RMSE od 1,04 cm (2,13 %), uz tendenciju blagog precjenjivanja. Procjene visina stabala pokazale su još veću točnost, s prosječnim odstupanjem (MD) od 0,22 m (0,69 %) i RMSE od 0,30 m (0,95 %), također uz blagi trend precjenjivanja. Utvrđena visoka podudarnost s referentnim vrijednostima (r = 0,995) potvrđuje gotovo savršenu slaganje između PLS procjena i terenskih izmjera prsnih promjera te PLS i TLS procjena visina stabala. Rezultati su u skladu s ranijim istraživanjima koja ukazuju na blago precjenjivanje prsnih promjera i visina pri primjeni PLS tehnologije, ali uz vrlo visoku točnost procjena. Mogući uzroci odstupanja uočeni u ovom istraživanju povezani su sa strukturom sastojine i morfološkim značajkama stabala, osobito debljom i hrapavom korom starijih stabala lužnjaka.

Na temelju provedenog istraživanja može se zaključiti da PLS tehnologija pruža vrlo točne procjene prsnog promjera i visina stabala te predstavlja iznimno perspektivnu metodu za primjenu u operativnoj inventuri šuma. Unatoč tome, nužna su daljnja istraživanja u različitim tipovima šuma i sastojinskim uvjetima radi definiranja smjernica najbolje prakse i veće integracije PLS tehnologije u operativne inventure šuma.

ZAHVALA
ACKNOWLEDGMENT

Ovaj rad sufinancirala je Hrvatska zaklada za znanost projektom HRZZ-IP-2022-10-9246 (Blizu-predmetna daljinska istraživanja za preciznu inventuru šuma; CLOSER-FORINVENT) te dijelom kroz Program znanstveno-istraživačkog rada (ZIR) Hrvatskih šuma d.o.o. projektom „Primjena terestričkog laserskog skeniranja u preciznoj operativnoj izmjeri šuma (LASSCAN-2)".

LITERATURA
REFERENCES

- Balenović, I., X. Liang, L. Jurjević, J. Hyyppä, A. Seletković, A. Kukko, 2021: Hand-held personal laser scaning – Current status and perspectives for forest inventory application. Croatian Journal of Forest Engineering 42 (1): 165–183. https://doi.org/10.5552/crojfe.2021.858
- Balenović, I., A. Kokeza, K. Indir, D. Kuric, F. Domazetović, I. Marić, L. Jurjević, 2024: Prva godina projekta „Primjena terestičkog laserskog skeniranja u preciznoj operativnoj izmjeri šuma". Radovi 49 (1): 1–10. https://hrcak.srce.hr/324565
- 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
- Bragg, D.C., 2014: Accurately measuring the height of (real) forest trees. Journal of Forestry 112 (1): 51–54. https://doi.org/10.5849/JOF.13-065
- Cabo, C., S. Del Pozo, P. Rodríguez-Gonzálvez, C. Ordóñez, D. González-Aguilera, 2018: Comparing terrestrial laser scanning (TLS) and wearable laser scanning (WLS) for individual tree modeling at plot level. Remote Sensing 10 (4): 540. https://doi.org/10.3390/rs10040540
- Calders, K., G. Newnham, A. Burt, S. Murphy, P. Raumonen, M. Herold, D. Culvenor, V. Avitabile, M. Disney, J. Armston, M. Kaasalainen, 2015: Nondestructive estimates of above-ground biomass using terrestrial laser scanning. Methods in Ecology and Evolution 6 (2): 198–208. https://doi.org/10.1111/2041-210X.12301
- Disney, M., A. Burt, K. Calders, C. Schaaf, A. Stovall, 2019: Innovations in ground and airborne technologies as reference and for training and validation: Terrestrial laser scanning (TLS). Surveys in Geophysics 40: 937–958. https://doi.org/10.1007/s10712-019-09527-x
- Dragčević, D., M. Pavasović, T. Bašić, 2016: Pouzdanost službenih rješenja geoida Republike Hrvatske na području Grada Zagreba. Geofizika 33 (2): 183–206. https://doi.org/10.15233/gfz.2016.33.9
- Durrieu, S., C. Vega, M. Bouvier, F. Gosselin, J.-P. Renaud, L. Saint-André, 2015: Optical remote sensing of tree and stand heights. U (Thenkabail, P.S., ur.): Land Resources Monitoring, Modeling, and Mapping with Remote Sensing. CRC Press, Boca Raton, Florida, pp. 1–30. https://doi.org/10.1201/b19322

- Ganz, S., Y. Käber, P. Adler, 2019: Measuring tree height with remote sensing – A comparison of photogrammetric and LiDAR data with different field measurements. Forests 10 (8): 694. https://doi.org/10.3390/f10080694
- Giannetti, F., L. Passarino, G. Aleandri, C. Borghi, E. Vangi, S. Anzilotti, S. Raddi, G. Chirici, D. Travaglini, A. Maltoni, B. Mariotti, A. Bravo-Oviedo, Y. Giambastiani, P. Rossi, G. D'Amico, 2024: Efficiency of mobile laser scanning for digital marteloscopes for conifer forests in the Mediterranean Region. Forests 15 (12): 2202. https://doi.org/10.3390/f15122202
- 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) Ttechnology. Remote Sensing 12 (9): 1509. https://doi.org/10.3390/rs12091509
- Gollob, C., R. Krassnitzer, T. Ritter, A. Tockner, G. Erber, M. Kühmaier, F. Hönigsberger, T. Varch, A. Holzinger, K. Stampfer. A. Nothdurft, 2023: Measurement of individual tree parameters with carriage-based laser scanning in cable yarding operations. Croatian Journal of Forest Engineering 44 (2): 401–417. https://doi.org/10.5552/crojfe.2023.2252
- Guan, T., Y. Shen, Y. Wang, P. Zhang, R. Wang, F. Yan, 2024a: Advancing forest plot surveys: A comparative study of visual vs. LiDAR SLAM technologies. Forests 15: 2083. https://doi.org/10.3390/f15122083
- Guan, H., W. Li, Q. Wang, Y. Xu, 2024b: Evaluating UAV LiDAR for tree height and crown detection in temperate forests. Remote Sensing of Environment 302: 113–129. https://doi.org/10.1016/j.rse.2023.113129
- Henrich, J., J. van Delden, D. Seidel, T. Kneib, A.S. Ecker, 2024: TreeLearn: A deep learning method for segmenting individual trees from ground-based LiDAR forest point clouds. Ecological Informatics 84: 102888. https://doi.org/10.1016/j.ecoinf.2024.102888
- Hrdina, M., J.A. Molina-Valero, K. Kuželka, S. Tatsumi, K. Yamaguchi, Z. Melichová, M. Mokroš, P. Surový, 2025: Obtaining the highest quality from a low-cost mobile scanner: A comparison of several pipelines with a new scanning device. Remote Sensing 17 (15): 2564. https://doi.org/10.3390/rs17152564
- Hyyppa¨, E., X. Yu, H. Kaartinen, T. Hakala, A. Kukko, M. Vastaranta, J. Hyyppa¨, 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: 3327. https://doi.org/10.3390/rs12203327
- Jurjević, L., X. Liang, M. Gašparović, I. Balenović, 2020: Is field-measured tree height as reliable as believed – Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. ISPRS Journal of Photogrammetry and Remote Sensing 169: 227–241. https://doi.org/10.1016/j.isprsjprs.2020.09.014
- 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
- Kokeza, A., L. Jurjević, F. Domazetović, I. Marić, A. Šiljeg, D. Medak, K. Indir, D. Kuric, I. Balenović, 2024: Testing the performance of hand-held personal laser scanning systems for precision forest inventory. U (Gašparović, M., ur.): Proceedings of the International Conference of Environmental Remote Sensing and GIS (ICERS), Zagreb, Croatia, July 11–12, 2024, pp. 117–120. https://doi.org/10.5281/zenodo.11657299
- Kokeza, A., D. Medak, F. Domazetović, I. Marić, A. Šiljeg, A. Seitz, I. Balenović, 2025: Influence of vegetation period on personal laser scanning accuracy for tree attribute estimation in pedunculate oak and European beech forests. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (u tisku).
- Korning, J., K. Thomsen, 1994: A new method for measuring tree height in tropical rain forest. Journal of Vegetation Science 5 (1): 139–140. https://doi.org/10.2307/3235647
- Kükenbrink, D., M. Marty, N. Rehush, M. Abegg, C. Ginzler, 2025: Evaluating the potential of handheld mobile laser scanning for an operational inclusion in a national forest inventory – A Swiss case study. Remote Sensing of Environment 321: 114685. https://doi.org/10.1016/j.rse.2025.114685
- Larsen, D.R., D.W. Hann, S.C. Stearns-Smith, 1987: Accuracy and precision of the tangent method of measuring tree height. Western Journal of Applied Forestry 2 (1): 26–28. https://doi.org/10.1093/wjaf/2.1.26
- Li, Z., S. Chen, X. Liang, 2023: Performance of UAV-based LiDAR in estimating forest structural attributes compared with TLS. ISPRS Journal of Photogrammetry and Remote Sensing 196: 45–59. https://doi.org/10.1016/j.isprsjprs.2023.01.002
- Liang, X., V. Kankare, J. Hyyppä, Y. Wang, A. Kukko, H. Haggrén, X. Yu, H. Kaartinen, A. Jaakkola, F. Guan, M. Holopainen, 2016: Terrestrial laser scanning in forest inventories. ISPRS Journal of Photogrammetry and Remote Sensing 115: 63–77. https://doi.org/10.1016/j.isprsjprs.2016.01.006
- Liang, X., J. Hyyppä, H. Kaartinen, M. Lehtomäki, J. Pyörälä, N. Pfeifer, M. Holopainen, G. Brolly, P. Francesco, J. Hackenberg, H. Huang, H.W. 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. Luoma, X. Yu, L. Chen, M. Vastaranta, N. Saarinen, Y. Wang, 2018: 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, I. Balenović, N. Saarinen, S. Junttila, V. Kankare, M. Holopainen, M. Mokroš, et al., 2022: Close-range remote sensing of forests: The state of the art, challenges, and opportunities for systems and data acquisitions. IEEE Geoscience and Remote Sensing Magazine 10 (3): 32–71. https://doi.org/10.1109/MGRS.2022.3168135
- Luoma, V., N. Saarinen, M.A. Wulder, J.C. White, M. Vastaranta, M. Holopainen, J. Hyyppä, 2017: Assessing precision in conventional field measurements of individual tree attributes. Forests 8 (2): 38.
- Mîzgaciu, D., A. Ganne, S. Legros, S. Mermoz, A. Bouvet, T. Le Toan, 2025: A comparative analysis of UAV LiDAR and mobile laser scanning for tree height and canopy structure estimation. Forests 16 (9): 1481. https://doi.org/10.3390/f16091481
- Mokroš, M., T. Mikita, A. Singh, J. Tomaštík, J. Chudá, P. Wężyk, K. Kuželka, P. Surový, M. Klimánek, K. Zięba-Kulawik, R. Bobrowski, X. Liang, 2021: Novel low-cost mobile mapping systems for forest inventories as terrestrial laser scanning alternatives. International Journal of Applied Earth Observation and Geoinformation 104: 102512. https://doi.org/10.1016/j.jag.2021.102512
- Rahlf, J., J. Breidenbach, S. Solberg, E. Næsset, R. Astrup, 2014: Comparison of four types of 3D data for timber volume estimation. Remote Sensing of Environment 155: 325–333. https://doi.org/10.1016/j.rse.2014.08.036
- Ryding, J., E. Williams, M.J. Smith, M.P. Eichhorn, 2015: Assessing handheld mobile laser scanners for forest surveys. Remote Sensing 7 (1): 1095–1111. https://doi.org/10.3390/rs70101095
- Sofia, S., F. Giannetti, S. Buscarini, G. Chirici, C. Serena, F. Maetzke, M. Miozzo, D. Travaglini, D.S. La Mela Veca, 2024: View of comparing efficiency, timing and costs of different walking paths in HMLS LIDAR survey. Annals of Forest Research 67: 87–107. https://doi.org/10.15287/afr.2024.3671
- Stereńczak, K., M. Mielcarek, B. Wertz, K. Bronisz, G. Zajączkowski, A.M. Jagodziński, W. Ochał, M. Skorupski, 2019: Factors influencing the accuracy of ground-based tree-height measurements for major European tree species. Journal

of Environmental Management 231: 1284–1292. https://doi.org/10.1016/j.jenvman.2018.09.100.

- Tompalski, P., N.C. Coops, J.C. White, M.A. Wulder, 2014: Simulating the impacts of error in species and height upon tree volume derived from airborne laser scanning data. Forest Ecology and Management 327: 167–177. https://doi.org/10.1016/j.foreco.2014.05.011
- Tupinambá-Simões, F., A. Pascual, J. Guerra-Hernández, 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
- Tupinambá-Simões, F., S. Saatchi, R. Dubayah, M.L. Clark, K. Calders, C.A. Silva, 2025: Combining hand-held and drone-based LiDAR for forest carbon monitoring. European Journal of Forest Research 144 (2): 345–362. https://doi.org/10.1007/s10342-025-01772-7
- Vandendaele, B., O. Martin-Ducup, R.A. Fournier, G. Pelletier, P. Lejeune, 2022: Mobile laser scanning for estimating tree structural attributes in a temperate hardwood forest. Remote Sensing 14 (18): 4522. https://doi.org/10.3390/rs14184522
- Wang, Y., M. Lehtomäki, X. Liang, J. Pyörälä, A. Kukko, A. Jaakkola, J. Liu, Z. Feng, R. Chen R, 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
- Wilkes, P., A. Lau, M. Disney, K. Calders, A. Burt, J.G. de Tanago, H. Bartholomeus, B. Brede, M. Herold, 2017: Data acquisition considerations for terrestrial laser scanning of forest plots. Remote Sensing of Environment 196: 140–153. https://doi.org/10.1016/j.rse.2017.04.030

SUMMARY

This study evaluated the accuracy of the latest, high-end commercial personal laser scanner (PLS) in estimating diameter at breast height (DBH) and tree height in an old pedunculate oak (*Quercus robur* L.) stand. The research was conducted in the state-owned management unit Šiljakovačka Dubrava (Forest Office Velika Gorica, Forest Administration Zagreb, Croatian Forests Ltd.) in Central Croatia, in a 145-year-old oak stand. Three circular sample plots (20 m in radius each) were established, including 40 oak trees in total (Figure 1). Reference data were collected by detailed field measurements and terrestrial laser scanning (TLS). DBH was measured using a diameter tape, while TLS (FARO Focus Premium 150) was used as the reference for tree height. TLS data were acquired using a multi-scan approach from five scan positions per plot (Figure 3a), whereas PLS data were collected using FARO Orbis according to a predefined walking scheme (Figure 3b). Both scanners, along with their technical specifications, are presented in Figure 2 and Table 1.

Before extracting individual tree attributes, a pre-processing of the collected TLS and PLS data was carried out. TLS data were pre-processed (registration, georeferencing) using FARO SCENE v2025.1.1, while PLS data were pre-processed using FARO Connect v2025.1 (Figure 4). Processing of TLS and PLS data (point clouds) was performed in the same manner using LiDAR360 v8.1. After normalising the point clouds, DBH of each tree was semi-automatically estimated; firstly, by approximate determination of diameter by the operator, which was secondly approximated by the fit-by-circle method, i.e., by the software algorithm that approximates DBH using the least squares method to fit a circle from the x-y coordinates of input points. Stems fitted by the circle method were used as seed points for individual tree segmentation (Point Cloud Segmentation from Seed Points algorithm; Figure 5). Within the segmentation process, the heights (H) were automatically estimated and then manually checked for any inconsistencies or errors (Figure 6). The measured and estimated DBH and tree height values for each tree, obtained from field measurements, as well as TLS and PLS data, are provided in the appendix (Table A1).

The accuracy assessment compared PLS-derived attributes against reference data using the correlation coefficient (r), mean difference (MD) and root mean square error (RMSE). Results for DBH (Table 2) showed a strong correlation with reference values (r = 0.995), with deviations ranging from –0.99 cm to 3.02 cm. The MD was 0.62 cm (1.28 %), and the RMSE was 1.04 cm (2.13%). Figure 7 illustrates the slight, systematic overestimation of PLS-derived DBH. Tree height estimates (Table 2) were even more accurate, with deviations between –0.13 m and 0.92 m. The correlation with TLS reference data was r = 0.995. MD was 0.22 m (0.69%), and RMSE was 0.30 m (0.95%). Figure 8 demonstrates the close agreement between PLS and TLS estimates, again with a slight overestimation trend.

The results confirm the high accuracy and reliability of PLS data for both DBH and height estimation in an old oak stand. Minor biases can be attributed to structural and morphological characteristics of trees, such as thick and furrowed bark in old oaks, which may cause an overestimation of DBH. Overall, the findings align with previous studies (e.g., Jurjević et al. 2020, Hyypä et al. 2020, Vandendaele et al. 2022, Kokeza et al. 2024, 2025), which report a slight overestimation but high accuracy of PLS-derived tree attributes.

In conclusion, when high-end instruments are used, the PLS technology provides highly accurate and efficient estimates of DBH and tree height, demonstrating strong potential for integration into operational forest inventory. Further research across different stand types and conditions is recommended to establish best-practice guidelines for PLS data acquisition and processing.

KEY WORDS: personal laser scanning (PLS), LiDAR, diameter at breast height, tree height, forest inventory

DODATAK
APPENDIX

Tablica A1. Izmjerene i procijenjene vrijednosti atributa pojedinačnih stabla: DBH_{REF} – referentni prsni promjer izmjeren mjernom vrpcom, DBH_{PLS} – prsni promjer procijenjen iz PLS podataka, H_{TLS} – referentna visina stabala procijenjena iz TLS podataka, H_{PLS} – visina stabala procijenjena iz PLS podataka.
Table A1 Measured and estimated attribute values for individual trees: DBH_{REF} – reference diameter at breast height measured with a diameter tape, DBH_{PLS} – diameter at breast height estimated from PLS data, H_{TLS} – reference tree height estimated from TLS data, H_{PLS} – tree height estimated from PLS data.

ID stabla *Tree ID*	Ploha ***Plot***	Broj stabla ***Tree No***	X (°)	Y (°)	DBH_{REF} (cm)	DBH_{PLS} (cm)	H_{TLS} (m)	H_{PLS} (m)
1	4	1	465171,06	5058756,20	49,66	50,95	32,50	32,75
2	4	2	465172,91	5058753,32	39,79	40,14	31,54	31,83
3	4	3	465169,07	5058748,24	42,97	45,85	30,75	31,67
4	4	4	465170,62	5058738,49	45,84	46,00	30,25	30,55
5	4	5	465173,58	5058735,93	44,56	46,41	30,94	31,03
6	4	6	465160,68	5058735,86	35,01	36,43	25,92	26,64
7	4	7	465159,30	5058737,95	61,75	61,41	31,54	31,55
8	4	8	465163,65	5058748,07	45,20	48,22	30,87	31,51
9	4	9	465152,00	5058752,14	49,66	50,72	31,35	31,80
10	4	10	465156,58	5058756,62	49,02	49,28	32,02	32,26
11	4	11	465153,02	5058762,05	43,61	44,17	31,81	32,08
12	4	12	465159,18	5058764,83	42,34	43,34	32,35	32,82
13	4	13	465160,60	5058767,61	35,01	35,33	30,55	30,76
14	4	14	465167,35	5058761,55	51,57	51,53	34,15	34,33
15	4	15	465174,83	5058766,17	54,11	54,24	33,51	33,55
16	4	16	465176,37	5058764,38	52,20	52,16	33,67	33,71
17	5	1	465165,79	5058595,19	67,48	67,85	33,44	33,38
18	5	2	465159,81	5058581,65	34,38	35,45	30,40	30,41
19	5	3	465154,18	5058588,26	42,97	43,56	30,09	30,43
20	5	4	465153,90	5058591,96	33,74	34,12	26,36	26,66
21	5	5	465150,09	5058587,80	35,33	36,15	25,44	25,58
22	5	6	465153,60	5058578,85	53,16	53,97	32,38	32,56
23	5	7	465143,99	5058586,86	51,88	52,05	29,61	29,72
24	5	8	465138,72	5058581,80	53,16	52,17	30,48	30,60
25	5	9	465134,16	5058601,23	59,52	59,82	33,46	33,72
26	5	10	465150,50	5058597,55	41,38	41,27	31,15	31,26
27	5	11	465149,18	5058602,41	42,97	42,80	30,31	30,19
28	5	12	465158,50	5058597,54	46,15	46,72	32,50	32,69
29	5	13	465146,36	5058611,01	63,03	65,63	33,44	33,45
30	6	1	465036,49	5058594,31	65,25	64,75	35,07	35,23
31	6	2	465031,00	5058593,78	56,66	56,72	31,95	32,13
32	6	3	465032,67	5058599,18	41,38	42,39	30,20	30,41
33	6	4	465022,48	5058592,09	44,56	45,64	30,50	30,95
34	6	5	465019,59	5058594,40	44,25	44,58	31,93	32,16
35	6	6	465008,23	5058596,06	47,75	47,98	32,53	32,46
36	6	7	465002,94	5058587,40	60,48	61,07	33,27	33,27
37	6	8	464996,76	5058589,01	53,79	54,00	34,02	34,18
38	6	9	465005,87	5058580,18	47,75	48,25	33,18	33,32
39	6	10	465012,60	5058577,71	57,93	58,06	32,31	32,59
40	6	11	465022,40	5058581,78	55,70	56,67	31,59	31,75