

Uporaba iPhone lidar tehnologije za izmero dreves na vzorčnih ploskvah gozdne inventure

Use of iPhone LiDAR technology for measuring tree parameters in forest inventories sampling plots

Jaka Križaj, Mitja Skudnik

UDK: 630*58:004
Klasifikacija prispevka po COBISS.SI: 1.01
Prispelo: 13. 3. 2025
Sprejeto: 14. 5. 2025

DOI: 10.15292/geodetski-vestnik.2025.03.301-315
SCIENTIFIC ARTICLE
Received: 13. 3. 2025
Accepted: 14. 5. 2025

IZVLEČEK

Lasersko skeniranje dreves je lahko koristna tehnologija za dopolnitev in overitev informacij, pridobljenih s klasično gozdno inventuro. Profesionalni terestrični in mobilni skenerji so dragi in zahtevajo usposobljene uporabnike. Zato smo v delu preizkusili uporabnost cenovno dostopnejše tehnologije Apple iPhone lidar, in sicer za pridobivanje dveh pglavitnih informacij o drevesih na vzorčnih ploskvah gozdne inventure: to sta premer drevesa na višini 1,3 metra nad tlemi ($d_{1,3}$) in oddaljenost drevesa od središča ploskve. Na štirih krožnih raziskovalnih ploskvah na Rožniku smo v treh ločenih ekipah gozdarskih strokovnjakov izmerili referenčne podatke za vsa drevesa z $d_{1,3} \geq 10$ cm s tradicionalnimi metodami, nato smo ploskve poskenirali še z napravo Apple iPhone 13 Pro Max. Podatke skeniranja smo obdelali z odprtokodnimi programi. Ugotovili smo, da so vrednosti $d_{1,3}$, pridobljene iz podatkov laserskega skeniranja, v povprečju precenjene za 0,95 centimetra (RMSE = 2,43 cm), napaka je značilno večja pri tanjših drevesih. Horizontalne razdalje so bile večinoma podcenjene, v povprečju za 6,7 centimetra (RMSE = 24,1 cm). Napaka v horizontalni razdalji se z naraščajočim časom skeniranja povečuje, medtem ko trajanje skeniranja ne vpliva na vrednosti prsnih premerov. Prav tako smo ugotovili, da so lesne zaloge, izračunane iz podatkov skeniranja, v povprečju precenjene za 2,6 %.

KLJUČNE BESEDE

iPhone, Apple lidar, nizkocenovni lidar, gozdna inventura, prsni premer, lokacije dreves

ABSTRACT

Laser scans of trees in the field could represent a useful technology for complementing and controlling information measured in the context of classic forest inventory. Professional terrestrial and mobile laser scanners remain, however, expensive and require professional handling. For this purpose, we wanted to evaluate the application of low-cost Apple lidar technology for measuring two important forest inventory parameters – the diameter of trees at 1.3 m above ground level ($d_{1,3}$) and horizontal distances to the centre of sampling inventory plots. These parameters were measured by four independent groups of forest inventory experts on four circular plots near the Slovenian Forestry Institute for all trees with $d_{1,3} \geq 10$ cm, using traditional methods. Subsequently, the plots were scanned with lidar-equipped Apple iPhone 13 Pro Max. The scan data were analysed using open-source software. On average $d_{1,3}$ values from laser scans were 0.95 cm (RMSE = 2.43 cm) greater than reference values, with larger discrepancies for thinner trees. Conversely, horizontal distances were on average underestimated by 6.7 cm (RMSE = 24.1 cm). Discrepancies in horizontal distances were greater for trees that were measured toward the end of the scanning process, while no such influence of the scanning time was apparent for $d_{1,3}$. Additionally, we found that growing stock values were overestimated by 2.6%.

KEY WORDS

iPhone, Apple lidar, low-cost lidar, forest inventory, diameter at breast height, tree locations

1 UVOD

Podatki, zbrani z gozdno inventuro, so glavni vir informacij za spremljanje trajnostnega gospodarjenja z gozdovi. Pomemben del rezultatov gozdne inventure so podatki, zbrani na vzorčnih ploskvah. Po tej metodi v poznanih časovnih intervalih ponavljamo snemanja različnih drevesnih in sestojnih znakov na vzorčnih ploskvah z znano površino, ki so razporejene v prostoru tako, da zagotavljajo reprezentativen vzorec za območje interesa. Snemanja ponavljamo na istih lokacijah in istih drevesih, kar nam omogoča tudi spremljanje rasti dreves in spremljanje gozda skozi čas (Laar in Akça, 2007).

Eden najpomembnejših kazalnikov, ki ga merimo, je premer drevesa na višini 1,3 metra nad tlemi ($d_{1,3}$ oziroma prsni premer). Ta je namreč izhodišče za izračun ali izpeljavo številnih drugih znakov o drevesu (npr. volumna ali biomase). Trenutno se prsni premer meri z gozdarsko premerko ali merskim trakom (pi-metrom). Metoda je zamudna in izmere so deloma izpostavljene subjektivnim napakam merilca, ki jih v naslednjih fazah preverjanja in obdelave podatkov ni mogoče izslediti (Gollob et al., 2021). Zato so koristna vsa orodja, ki omogočajo večjo objektivnost zajetih podatkov, zlasti pa njihov kasnejši pregled ter kontrolo brez ponovnega obiska vzorčne ploskve. Zaradi nujne kontrole meritev na podvzorcju ploskev se namreč strošek inventure še dodatno poveša.

Lokacijo drevesa na vzorčni ploskvi opišemo z njegovo horizontalno oddaljenostjo od središča vzorčne ploskve ter kotom med severom in smerjo lokacije drevesa (azimut). Horizontalna oddaljenost je pomembna, saj je od nje odvisno, ali bo drevo vključeno v vzorec ali ne. Eno zgrešeno (ali pomotoma vključeno) drevo na vzorčni ploskvi pri ekstrapolaciji podatkov za širše območje enega hektarja pomeni tudi bistveno manjše (ali večje) število dreves in posledično podcenjeno (ali precenjeno) lesno zalogo.

1.1 Tehnologija lidar

Laserska skeniranja različnih vrst so v literaturi pogosto predstavljena kot zelo uporabna tehnologija za daljinsko pridobivanje podatkov v gozdarstvu (Coops et al., 2021). Predvsem so se zelo uveljavili digitalni modeli višin krošenj, ki so izdelani na podlagi podatkov, pridobljenih z letalskim laserskim skeniranjem (ALS), katerega raba v gozdarstvu sega že v osemdeseta leta prejšnjega stoletja (Nelson et al., 1984). Vendar pri letalskemu skeniranju še vedno ni mogoče dovolj natančno razbrati nekaterih kazalnikov posameznih dreves, med katere spada prsni premer, saj sedanja tehnologije ne omogoča dovolj velike gostote odbojev laserskih pulzov, dodatno pa lahko skeniranje debela ovirajo krošnje dreves (Gollob et al., 2021).

Za potrebe merjenja teh kazalnikov so primernejši terestrični oziroma terenski laserski skenerji, s katerimi lahko gozd skeniramo s tal. Tovrstne skenerje glede na postavitev in uporabo delimo na stacionarne (skeniranje poteka statično z izbranega stojišča) in mobilne (snemanje poteka dinamično s premikanjem skenerja po interesnem območju). Slabost te visokotehnološke merske opreme je, da morajo z njo delati usposobljeni strokovnjaki, ki potrebujejo primerno strojno in programsko opremo za interpretacijo rezultatov, poleg tega je cenovno manj dostopna.

1.2 iPhone lidar

Leta 2020 sta na trg prišla dva nova modela Applovih naprav: iPad Pro in iPhone Pro 12+ (v nadaljevanju: iPad in iPhone), ki sta opremljena z vgrajenim laserskim senzorjem in programsko opremo za razvoj namenskih aplikacij. Tako so bila omogočena laserska skeniranja s cenejšimi komercialnimi napravami,

kmalu pa so se začele vrstiti raziskave o uspešnosti obeh naprav oziroma o točnosti podatkov, ki jih je mogoče razbrati iz oblakov točk, pridobljenih z njima (Gollob et al., 2021; Luetzenburg et al., 2021; Mokroš et al., 2021; Tatsumi et al., 2022).

Do sedaj je bilo ugotovljeno, da med laserskimi skenerji na napravah iPhone in iPad ni razlik (Luetzenburg et al., 2021). Za merjenje razdalj do objektov se uporablja infrardeči laserski impulz. Potencialna gostota točk je logaritmčno odvisna od razdalje in znaša pri razdalji 25 centimetrov 7225 točk na kvadratni meter, pri razdalji 250 centimetrov pa 150 točk na kvadratni meter. Največji domet naprave je pet metrov (Luetzenburg et al., 2021).

V magistrski nalogi je Vipavec (2023) primerjal, kakšno kakovost oblaka točk dosega iPad v primerjavi s skeni naprave Leica BLK360 TLS za namene pridobivanja kakovostnih geodetskih podatkov. Potrdil je pričakovanja, da daje Appleova naprava občutno slabše rezultate, njene prednosti pa so enostavnost uporabe, cenovna ugodnost in časovna gospodarnost. Na podlagi tega, da lasersko skeniranje z napravo iPad v temi ni delovalo, sklepa, da se naprava za orientacijo v prostoru zanaša na posnetke, ki so narejeni s kamero.

V širšem geodetskem kontekstu so preverili uporabnost tehnologije Apple iPhone za ustvarjanje 3D modela geoloških značilnosti (Luetzenburg et al., 2021), za izris tlorisov notranjih prostorov stavb (Askar in Sternberg, 2023), merjenje terena in ustvarjanje topografskih kart (Nik Azhan Hakim et al., 2023) itd.

1.3 Uporaba tehnologije Apple lidar v gozdarstvu

V objavah, ki obravnavajo Appleove naprave za laserska skeniranja gozda in pridobivanje podatkov, so vrednosti celotnih napak (*angl.* root mean square error, RMSE) pri izračunu prsnih premerov do sedaj znašale med 2,2 in 3,2 centimetra (Gollob et al., 2021; Križaj, 2023; Mokroš et al., 2021; Singh et al., 2024; Tatsumi et al., 2022). V navedenih objavah tudi opazajo, da so prsni premeri za tanjša drevesa načeloma precenjeni.

Tatsumi et al. (2022) so razvili prvo aplikacijo, ki je namenjena ravno gozdni inventuri z uporabo tehnologije Apple lidar. Pri izmeri prsnih premerov so z aplikacijo dosegli RMSE 2,3 centimetra. Primerjali so tudi vložek časa za pridobitev lokacij dreves in izmero prsnih premerov s klasičnimi metodami in svojo aplikacijo. Pri izmeri prsnih premerov so bili štirikrat hitrejši, za izmero koordinat pa približno desetkrat. V diplomski nalogi, v okviru katere so bili pridobljeni referenčni podatki in 3D oblaki točk tudi za ta prispevek, je torej Križaj (2023) uporabil napravo iPhone 13 Pro Max za pridobitev horizontalnih razdalj in prsnih premerov posameznih dreves. Glede na v diplomski predstavljen metodologijo je dosegel RMSE vrednost 2,7 centimetra za prsne premere in 24,7 centimetra za horizontalne razdalje.

Singh et al. (2024) so z napravo iPhone 12 Pro primerjali izpeljane vrednosti prsnih premerov za 123 dreves, v primerjavo rezultatov so vključili dva različna algoritma obdelave oblakov točk. Pokazali so, da ni statistično značilnih razlik med dvema algoritmoma, vendar da obstaja statistično značilen vpliv vrste, odvisno od uporabljenega algoritma. Vrednost RMSE je za algoritma znašala 2,2 oziroma 2,6 centimetra.


Namen prispevka je preizkusiti tehnologijo Apple iPhone lidar za izmero dreves na vzorčnih ploskvah gozdne inventure v pestrih rastiščnih in sestojnih pogojih. Osredotočili smo se na prsne premere dreves, iz katerih smo nato izračunali še lesno zalogo na ploskvah. Izvirnost prispevka je testiranje izmere

horizontalne oddaljenosti dreves od središča vzorčne ploskve iz oblaka točk. Da bi pridobili čim bolj natančne referenčne podatke, so drevesa na vsaki vzorčni ploskvi izmerile tri med seboj neodvisne ekipe gozdarskih strokovnjakov.

2 METODE

2.1 Raziskovalni objekt

V raziskavo smo vključili štiri med seboj strukturno različne krožne vzorčne ploskve na območju Rožnik-Šišenski hrib v Ljubljani (slika 1). Ena od ploskev je na ravnem terenu, ostale so na pobočju. Vzorčna mreža je bila vzpostavljena za potrebe spremljanja stanja mestnih gozdov v okviru projekta EmonFur, ki ga je izvajal Gozdarski inštitut Slovenije v sodelovanju z mestno občino Ljubljana. Središče ploskev je označeno z železnim količkom, njihova površina znaša 600 m². Znotraj te površine smo obravnavali vsa drevesa s prsnim premerom vsaj 10 centimetrov. Podatki na terenu so bili zbrani v okviru diplomske naloge (Križaj, 2023).



Slika 1: Lokacije trajnih vzorčnih ploskev v mestnih gozdovih Rožnik-Šišenski hrib.

2.2 Terenska izmera dreves na vzorčnih ploskvah

Najprej smo s tradicionalnimi metodami med 3. in 7. aprilom 2023 izmerili drevesa na trajnih vzorčnih ploskvah. Pri tem smo se ravnali po navodilih za terensko delo Nacionalne gozdne inventure (Skudnik

et al., 2020). Prsni premeri so bili izmerjeni s pi-metrom na višini 1,3 metra od tal. Za določitev višine prsnega premera smo ob deblo postavili mersko palico. Geolokacija dreves je bila izmerjena z razdaljemerom Vertex Laser Geo (Haglöf Sweden, n. d.). Po navedbah proizvajalca ima ta pri merjenju razdalj napako do 1 %, pri merjenju azimutov ima RMSE do 1,5°.


Podatke tradicionalne izmere so na vsaki ploskvi zajele tri neodvisne ekipe merilcev, ki so vse vključene v letno izmero ploskev Nacionalne gozdne inventure. Podatke vseh ekip smo združili v eno podatkovno bazo, pri čemer smo za referenčne podatke upoštevali povprečje meritev lokacij in prsnih premerov.

2.3 Izmera z napravo iPhone 13 Pro Max

Podatke laserskega skeniranja smo zajeli med 17. aprilom in 5. majem 2023 z mobilno napravo iPhone 13 Pro Max v brezplačni aplikaciji 3D Scanner App, dostopni v App Storu (Križaj, 2023). Uporabili smo nastavek skeniranja »lidar advanced«, v kateri smo določili parameter dometa na 5 metrov, ločljivost skeniranja točk pa na 10 milimetrov. Vsako drevo posebej smo obhodili in poskenirali z vseh strani, med prehodom od enega drevesa do drugega smo skenirali tla. Predhodno smo določili drevesa, ki naj bodo vključena v skeniranje, in pot skeniranja, ki je potekala približno po naraščajočem azimutu. Nato je v ekipi dveh sodelavcev prvi izvajal skeniranje z mobilno napravo, medtem ko ga je drugi usmerjal k naslednjemu drevesu, določenemu za vključitev.

Za naknadno georeferenciranje oblaka točk smo na ploskev postavili dve trasirki in ju poskenirali z mobilno napravo. Prvo smo postavili v središče ploskve, drugo pa v smeri severa. Pridobljeni oblak točk smo iz 3D Scanner Appa izvozili v *.PLY formatu.

Na podlagi horizontalnih oddaljenosti dreves od središča ploskev in azimutov smo vsakemu drevesu izračunali polarno koordinato (slika 2, levo). Aplikacija snema potek skeniranja telefona (slika 2, desno).




Slika 2: Razporeditev dreves na ploskvi R08 glede na izračunane polarne koordinate (levo) in izris poteka skeniranja z aplikacijo 3D Scanner App (desno). Z rdečim X je označeno središče ploskve, rdeči krogi so posamezna drevesa na ploskvi, z zeleno črto je vrisana pot skeniranja.


2.4 Obdelava podatkov laserskega skeniranja

2.4.1 Predobdelava oblaka točk

Oblak točk, ki smo ga ustvarili s 3D Scanner Appu, smo uvozili v odprtokodni program za obdelavo točk CloudCompare (v2.13.alpha, 2023) (slika 3).



Slika 3: Prikaz obarvanega 3D oblaka točk za vzorčno ploskev R09 v programu CloudCompare.



Slika 4: Primer pojava dvojnega oboda debla, ki nastane zaradi napake skeniranja.

V programu CloudCompare smo oblak točk z lokacijo trasirk orientirali tako, da je bil center središčne trasirke čim bližje x, y , koordinatam 0, 0, center severne trasirke pa čim bližje x koordinati 0. Iz izvirnega oblaka točk smo z orodjem *Segment* odstranili nekatere napake skeniranja in točke šuma v bližini drevesnih debel. Primer večje napake, kakršno smo pred nadaljnjo obdelavo poskušali čim bolj odstraniti, je dvoslojni obod na delu debla, ki se občasno pojavi zaradi napake pri sprotni lokalizaciji oblaka točk (slika 4). Pridobljen

pravilno orientiran oblak točk, iz katerega smo odstranili napake skeniranja, smo shranili v *.las formatu. Metoda predobdelave oblaka točk je podrobno predstavljena tudi v diplomski nalogi Križaj (2023).

2.4.2 Klasifikacija tal

Za klasifikacijo tal smo uporabili programski jezik R (R Core Team, 2023). Pri tem smo uporabili knjižnico *lidR* (Roussel et al., 2020), v kateri je temu namenjena funkcija *classify_ground()*. Uporabili smo algoritem klasifikacije tal, kot so ga opisali Zhang et al. (2016), ki je vključen v funkciji *csf()*. Ustvarili smo digitalni model reliefa s funkcijo *rasterize_terrain()*, na podlagi katerega smo nato normalizirali oblak točk s funkcijo *normalize_height()*. Klasifikacijo smo opravili na razredčenem oblaku točk, kjer je bila minimalna razdalja med točkami 1 centimeter, nato smo jo interpolirali za vse točke izvirnega oblaka točk.


2.4.3 Identifikacija debel v oblaku točk

Za klasifikacijo posameznih debel iz normaliziranega oblaka točk smo obdržali točke z višinskimi z vrednostmi nad 0,5 metra. Na teh točkah smo uporabili funkciji *optics()* in *extractDBSCAN()* iz knjižnice *dbscan* (Hahsler et al., 2019). Funkciji sta namenjeni prepoznavanju oziroma filtriranju množic točk v dvo- ali večdimenzionalnem prostoru, ki pripadajo istemu objektu. V našem primeru smo želeli razločiti posamezna debla dreves iz oblaka točk.

2.4.4 Izračun prsnega premera in lokacije osi drevesa

Vsem zaznamim deblom smo naredili prerez točk na višini $1,3 \text{ m} \pm 2 \text{ cm}$. Točkam prereza smo z aritmetično funkcijo iskanja krogov *circlefit()* iz knjižnice *pracma* (Borschers, 2022) izračunali središče, ki je bilo informacija o lokaciji osi drevesa. Za to lokacijo smo nato izračunali azimut in oddaljenost (oziroma polarne koordinate) glede na središče ploskve.

Za končni izračun prsnega premera smo uporabili podobno metodo kot Gollob et al. (2021). Z generaliziranimi aditivnimi modeli smo razdaljo do osi drevesa modelirali kot funkcijo azimuta. Uporabili smo funkcijo *gam()* iz knjižnice *mcgv* (Wood, 2017). Z ustvarjenim modelom smo predvideli vrednosti razdalj do osi drevesa za 360° (oziroma od $-\pi$ do π). Pridobljene polarne koordinate smo transformirali v kartezijske koordinate. Te so predstavljale poligon, ki smo mu izračunali površino s funkcijo *area.owin()* iz knjižnice *spatstat* (Baddeley in Turner, 2005). Nazadnje smo iz površine poligona drevesu izračunali premer (slika 5).



Slika 5: Postopek izračuna prsnega premera drevesa iz prereza oblaka točk na višini 1,3 metra. Predstavljen primer na tej višini nima polnega oblaka točk.

Po pridobljenih podatkih smo za prsne premere dreves izračunali še lesno zalogo. To smo naredili na podlagi enovhodnih deblovnic, kot so definirane v Gozdarskem priročniku (Kotar, 2003). Podatke o tarifnih razredih smo pridobili iz spletnega Pregledovalnika podatkov o gozdovih (Zavod za gozdove Slovenije, 2023).

2.5 Statistične analize odstopanj izpeljanih znakov od terensko izmerjenih

Za pridobljene podatke o vrednostih izračunanih znakov iz oblakov točk smo izračunali povprečno odstopanje in relativno odstopanje (*angl.* bias (δ), relative bias) podatkov glede na terensko izmerjene vrednosti s funkcijama *bias()* in *percent_bias()* iz knjižnice *Metrics* (Hanmer in Frasco, 2018). Odstopanje se izračuna po naslednji enačbi:

$$\delta = \frac{\sum (x_{_ter_i} - x_{_izr_i})}{N} \quad (1)$$

Kjer so:

δ ... povprečno odstopanje znaka,

$x_{_ter_i}$... izračunana vrednost izbranega znaka za i-ti element v vzorcu,

$x_{_izr_i}$... terensko izmerjena vrednost izbranega znaka za i-ti element v vzorcu,

N ... velikost vzorca.

Prav tako smo izračunali vrednost celotne napake (*angl.* root mean square error, RMSE) s funkcijo *rmse()* iz knjižnice *Metrics* (Hanmer in Frasco, 2018). Celotno napako se izračuna po naslednji enačbi:

$$RMSE = \sqrt{\frac{\sum (x_{_izr_i} - x_{_ter_i})^2}{N}} \quad (2)$$

Kjer so:

$RMSE$... celotna napaka znaka,

$x_{_izr_i}$... izračunana vrednost izbranega znaka za i-ti element v vzorcu,

$x_{_ter_i}$... terensko izmerjena vrednost izbranega znaka za i-ti element v vzorcu,

N ... velikost vzorca.

Predpostavko o normalnosti podatkov o odstopanjih med izračunanimi in terensko izmerjenimi vrednostmi prsnega premera ter horizontalnimi razdaljami smo ovrednotili grafično in testirali s Shapiro-Wilk testom. Razlike med tradicionalno izmerjenimi podatki in rezultati laserskega skeniranja smo statistično testirali s t-testom parov. T-test parov preizkuša, ali je povprečna razlika med pari meritev statistično značilno različna od 0. Glavni rezultat testa predstavlja p-vrednost, ki pomeni verjetnost, da pridemo do določenih rezultatov, če zares drži, da je povprečna razlika med pari meritev enaka 0. Postopek smo ponovili za vse vrednosti tako prsnih premerov kot horizontalnih razdalj, nato smo podatke obdelali še z vidika različnih kategorij, in sicer glede na posamezno ploskev ter prsne premere glede na razširjene debelinske razrede po 10 centimetrov. Drevesa s prsnim premerom nad 50 centimetrov smo zaradi manjšega vzorca združili v en debelinski razred.

Napake v horizontalnih razdaljah smo razdelili glede na kvadrante azimutov po 90°, saj je pot skeniranja približno sledila naraščajočemu azimutu, kar pomeni, da so bila drevesa v posameznem kvadrantu poskenirana v enakemu časovnem intervalu.

3 REZULTATI


V analizo je bilo vključenih 87 dreves na štirih trajnih vzorčnih ploskvah. Na terenu je bilo vsako drevo izmerjeno večkrat (v povprečju trikrat) in tako smo oblak točk 87 dreves primerjali z vsemi meritvami dreves na terenu, iz katerih smo nato izračunali povprečja po drevesih. Povprečni standardni odklon meritev prsnih premerov je znašal 0,2 centimetra, horizontalnih razdalj pa 11,1 centimetra za drevesa z več kot eno meritvijo teh znakov. Z opisano metodologijo smo uspešno prepoznali in obdelali oblake točk za vsa drevesa.

3.1 Prsni premeri

V povprečju so bile vse terensko izmerjene vrednosti prsnih premerov za 0,95 centimetra oziroma 5,6 % manjše od izračunanih, RMSE pa je znašala 2,43 centimetra (preglednica 1). Povprečno odstopanje je bilo najnižje na ploskvi R08 (−0,43 cm) in najvišje na R04 (−1,47 cm). T-test parov za posamezne ploskve je pokazal statistično značilno odstopanje od terensko izmerjenih prsnih premerov le za ploskev R04. Razlike med prsnimi primeri parnih primerjav so bile statistično značilne tudi, če smo v istem vzorcu skupno obravnavali vsa izmerjena drevesa (preglednica 1, slika 6).

Preglednica 1: Primerjava odstopanj med terenskimi in izračunanimi vrednostmi prsnih premerov glede na posamezne ploskve

Ploskev	R03	R04	R08	R09	Skupno
Število dreves	17	38	16	16	87
Povprečno odstopanje (cm)	−1,00	−1,47	−0,43	−0,49	−0,95
Povprečno relativno odstopanje (%)	−8,4	−6,1	−4,2	−3,1	−5,6
RMSE (cm)	2,83	2,57	2,29	1,60	2,43
t-test parov, p-vrednost	0,149	< 0,001***	0,472	0,226	< 0,001***




Slika 6: Odstopanja od terensko izmerjenih prsnih premerov po ploskvah.

V nadaljevanju smo preizkusili še odstopanja od terensko izmerjenih vrednosti prsnega premera po razširjenih 10-centimetrskih debelinskih razredih. Statistično značilna odstopanja so se pojavila v prvem (10–19,9 centimetra prsnega premera, $p < 0,001$) debelinskem razredu (preglednica 2). Odstopanje je bilo pri tanjših drevesih večje, pri debelejših pa manjše, za drevesa nad 50 centimetri prsnega premera so bili izračunani prsni premeri v povprečju manjši od terensko izmerjenih (slika 7).

Preglednica 2: Primerjava odstopanj med terenskimi in izračunanimi vrednostmi prsnih premerov glede na posamezne debelinske razrede

Debelinski razred	10–19,9 cm	20–29,9 cm	30–39,9 cm	40–49,9 cm	50+ cm
Število dreves	39	14	10	9	15
Povprečno odstopanje (cm)	–1,48	–1,22	–0,97	–0,67	0,49
Povprečno relativno odstopanje (%)	–9,9	–5,2	–2,7	–1,7	0,8
RMSE (cm)	2,53	2,45	1,75	2,88	2,21
t-test parov, p-vrednost	< 0,001***	0,060	0,077	0,519	0,406




Slika 7: Odstopanja od terensko izmerjenih prsnih premerov po razširjenih debelinskih razredih.

3.2 Horizontalne razdalje

V povprečju so bile vse izračunane vrednosti horizontalnih razdalj za 6,7 centimetra oziroma 1,0 % manjše od terensko izmerjenih, RMSE je znašala 24,1 centimetra (preglednica 3). T-test parov za posamezne ploskve posebej je pokazal statistično značilno odstopanje od terensko izmerjenih horizontalnih razdalj za ploskvi R03 in R08 (slika 8).

Preglednica 3: Primerjava odstopanj med terenskimi in izračunanimi vrednostmi horizontalnih razdalj glede na posamezne ploskve

Ploskev	R03	R04	R08	R09	Skupno
Povprečno odstopanje (cm)	25,7	–3,8	13,0	5,7	6,7
Povprečno relativno odstopanje (%)	3,2	–0,01	1,4	0,5	1,0
RMSE (cm)	34,4	22,8	21,5	14,6	24,1
t-test parov, p-vrednost	< 0,001***	0,309	0,010**	0,122	0,008**




Slika 8: Odstopanja od terensko izmerjenih horizontalnih razdalj po ploskvah.


Opravili smo še analizo podatkov o odstopanjih vrednosti horizontalnih razdalj po kvadrantih azimutov (0–90°, 90–180°, 180–270°, 270–360°), s statistično značilnimi razlikami le v tretjem kvadrantu (preglednica 4, slika 8). Iz naraščajočih vrednosti RMSE pa je razvidno, da so izračunane razdalje po kvadrantih vse manj natančne, še posebej v četrtem kvadrantu (270–360°) (slika 9). Napaka ocene razdalje začne naraščati po izmerjenem azimutu 180°, kar pomeni, da so razdalje natančnejše v prvi polovici skeniranja dreves na vzorčni ploskvi in se kasneje odstopanja začnejo bistveno povečevati (slika 10).

Preglednica 4: Primerjava odstopanj med terenskimi in izračunanimi vrednostmi horizontalnih razdalj glede na posamezne kvadrante

Kvadrant	I	II	III	IV
Število dreves	18	23	22	24
Povprečno odstopanje (cm)	3,4	4,2	18,7	1,0
Povprečno relativno odstopanje (%)	0,4	1,3	2,4	–0,3
RMSE (cm)	9,7	11,8	26,6	35,5
t-test parov, p-vrednost	0,145	0,090	< 0,001***	0,897




Slika 9: Odstopanja od terensko izmerjenih horizontalnih razdalj po kvadrantih.



Slika 10: Odstopanja med terensko izmerjenimi in izračunanimi horizontalnimi razdaljami za vsa drevesa na ploskvah v odvisnosti od azimuta drevesa in s tem daljšega časa skeniranja dreves na vzorčnih ploskvi.

3.3 Volumen dreves in lesna zaloga ploskev

Izračunana lesna zaloga za ploskve je izražena v m^3 na hektar površine. Primerjali smo lesno zalogo, ki smo jo pridobili z merjenim prsnim premerom, in lesno zalogo, ki smo jo pridobili iz prsnih premerov, izračunanih iz oblakov točk (preglednica 5). Lesna zaloga, izračunana iz podatkov oblaka točk, je v povprečju za $11,1 \text{ m}^3/\text{ha}$ (oziroma 2,6 %) večja od te, ki je izračunana iz tradicionalno pridobljenih podatkov. Ker je lesna zaloga odvisna od premera dreves, so bila torej največja odstopanja od terenskih vrednosti na ploskvi R04. Na tej ploskvi je lesna zaloga precenjena kar za $40,3 \text{ m}^3/\text{ha}$ (oziroma 9,5 %), medtem ko je najmanjše odstopanje na ploskvi R03, kjer je lesna zaloga precenjena za $2,5 \text{ m}^3/\text{ha}$ (oziroma 0,7 %) (slika 11).



Slika 11: Primerjava lesnih zalog, izračunanih iz oblaka točk, z lesnimi zalogami, izračunanimi iz tradicionalno izmerjenih podatkov za posamezne ploskve.

Preglednica 5: Primerjava odstopanj med terenskimi in izračunanimi vrednostmi lesnih zalog

Ploskev	R03	R04	R08	R09
LZ izračunana iz terenskih podatkov (m³/ha)	351,5	423,3	345,0	273,9
LZ izračunana iz podatkov oblaka točk (m³/ha)	353,9	463,6	341,1	279,5
Razlika (m³/ha)	−2,4	−40,3	3,9	−5,4
Razlika (%)	−0,7	−9,5	1,1	−2

4 RAZPRAVA

Ugotovili smo, da so vrednosti prsnih premerov, ki so s predstavljeno metodologijo izračunane na podlagi oblakov točk, pridobljenih z napravo iPhone, precenjene v povprečju za manj kot 1 centimeter. RMSE vrednost, ki smo jo pridobili, je skladna z izsledki dosedanjih raziskav, v katerih so uporabnost aplikacije testirali v gozdovih severnega in zmernega pasu (Gollob et al., 2021; Križaj, 2023; Mokoš et al., 2021; Singh et al., 2024; Tatsumi et al., 2022). Dodatno bi izpostavili, da na pridobljene rezultate lahko znatno vpliva debelinska struktura dreves v vzorcu. Napaka je namreč večja za tanjša drevesa, medtem ko so debelejša drevesa razmeroma bolje ocenjena, zato pomeni večje število tanjših dreves v splošnem manj točne rezultate pri izračunu prsnih premerov.

V primerjavi z diplomskim delom (Križaj, 2023) smo proces dela izpopolnili tako, da smo uporabili bolj avtomatiziran postopek pridobivanja podatkov iz oblaka točk – namesto ročne uporabe algoritma RANSAC smo uporabili bolj avtomatizirano klasifikacijo in normalizacijo oblaka točk, obenem smo za izpeljavo prsnih premerov uporabili funkcije, ki se bolje prilegajo sami obliki oboda drevesa, kar se pozna v manjših odstopanjih prsnih premerov. Tako smo zmanjšali količino dela, potrebne za obdelavo podatkov, in dosegli boljše rezultate.

Po ploskvah smo zaznali statistično značilna odstopanja od referenčnih vrednosti prsnih premerov samo pri ploskvi R04. Na ploskvi je veliko tanjših dreves, pri katerih so premeri bolj precenjeni. Dodatno so drevesa na ploskvi pogosto izraščala v šopih. To pomeni, da je treba med skeniranjem obhoditi celoten šop, kar je pri delu z napravo iPhone prineslo pogoste napake v oblaku točk debela in posledično manj točne rezultate.

Odstopanjem v horizontalnih razdaljah od središča ploskev v literaturi še niso posvečali veliko pozornosti. Gollob et al. (2021) so sicer delali na krožnih ploskvah z manjšim radijem (7 metrov), dodatno tudi niso snemali dreves po naraščajočem azimutu, zaradi česar morda niso opazili večjih odstopanj. Vendar je informacija zaradi pomena pri vključevanju dreves v vzorec ključnega pomena, saj ob velikosti vzorčne ploskve 600 m² predstavlja eno vključeno ali izpadlo drevo 16,7 drevesa na hektar. Ugotovili smo, da oddaljenost skeniranja od začetne lokacije močno vpliva na natančnost izračuna lokacije drevesa. Razlog je v tem, da se v postopku registracije oblaka točk kopičijo manjše napake v pozicioniranju naprave v prostoru. Takšne napake so zasledili tudi v literaturi, ki obravnava skeniranja z Applovimi napravami (Luetzenburg et al., 2021; Vipavec, 2023).

Prav tako v literaturi še nismo zasledili, da bi izračunali in primerjali vrednosti lesnih zalog tradicionalne izmere z vrednostmi iPhone skeniranja. Tu opazimo, da se vpliv precenjenih tanjših premerov v večini primerov izravna, saj tanjša drevesa nimajo tako velikega vpliva na skupno lesno zalogo kot debela dre-

vesa. Tako je bilo odstopanje od lesnih zalog, izračunanih iz merjenih premerov dreves, večje od 2 % le na eni od štirih vzorčnih ploskev.

Z vključitvijo novih tehnologij v gozdno inventuro bi lahko opravljali kontrolo izmere iz pisarne, kar bi prihranilo na stroških prevoza in ponovnega obiska ploskve brez veliko dodatnega dela. Sedaj je namreč običajno, da se po izmeri vnovič obišče 5–10 % vzorčnih ploskev, na katerih se meritve ponovijo. To je zamuden proces, ki še dodatno poveča stroške gozdne inventure.

S stališča potreb na gozdarskem področju je za zdaj gotovo največja omejitev skenerja njegov dolet do 5 metrov. To pomeni, da še ni mogoče skenirati debel, višjih od nekaj metrov, kaj šele pridobiti zanesljive podatke o višini dreves.

Verjamemo, da tehnologija Apple lidar že na sedanji stopnji ponuja številna področja uporabe. Med najbolj izstopajočimi prednostmi je zagotovo hiter zajem podatkov. V raziskavi smo za posamezno skeniranje ploskve porabili od 5 do 15 minut, odvisno od zahtevnosti terena in števila dreves na ploskvi. Za primerjavo, meritev dreves s klasično metodo traja približno od 20 minut do ene ure, pri čemer je trajanje močno odvisno od gostote dreves na vzorčni ploskvi ter zahtevnosti terenskih razmer. Obdelava podatkov v pisarni je zahtevala od 25 do 35 minut na ploskev, odvisno od števila dreves na ploskvi in števila napak v oblaku točk. Bi pa bilo mogoče v prihodnje posamezen del delovnega procesa avtomatizirati in s tem časovno skrajšati. Pokazali smo, da je obdelava podatkov mogoča tudi s popolnoma brezplačnimi odprtokodnimi rešitvami na procesorsko povprečnih računalnikih.

Zahvala

Avtorji se zahvaljujemo Pahernikovi ustanovi, ki je prek finančne podpore v obliki štipendije za študente gozdarstva pomembno prispevala in omogočila nadgradnjo raziskave.

Zahvaljujemo se tudi recenzentom za koristne napotke, kako izboljšati kakovost članka.

Raziskava je bila izvedena v okviru naslednjih projektov, ki so pomembno prispevali k njenemu razvoju:

- 1. V4-2422: Analiza in predlog nadaljnjega razvoja sistema gozdnih inventur javne gozdarske službe
- 2. J2-3055: ROVI – Združevanje in obdelava radarskih in optičnih časovnih vrst satelitskih posnetkov za spremljanje naravnega okolja
- 3. P4-0059: Gozd, gozdarstvo in obnovljivi gozdni viri

Literatura in viri:

- Askar, C., Sternberg, H. (2023). Use of Smartphone Lidar Technology for Low-Cost 3D Building Documentation with iPhone 13 Pro: A Comparative Analysis of Mobile Scanning Applications. *Geomatics*, 3 (4): 563–579. DOI: <http://dx.doi.org/10.3390/geomatics3040030>
- Baddeley, A., Turner, R. (2005). spatstat: An R Package for Analyzing Spatial Point Patterns. *Journal of Statistical Software*, 12 (6), 1–42. DOI: <https://doi.org/10.18637/jss.v012.i06>
- Borchers H (2022). _pracma: Practical Numerical Math Functions_. R package version 2.4.2, <https://CRAN.R-project.org/package=pracma>, pridobljeno 15. 9 2023.
- CloudCompare (v 2.13.alpha) [GPL Software]. n. d. <http://www.cloudcompare.org/>, pridobljeno 25. 2. 2025.
- Gollob, C., Ritter, T., Kraßnitzner, R., Tockner, A., Nothdurft, A. (2021). Measurement of Forest Inventory Parameters with Apple iPad Pro and Integrated LiDAR Technology. *Remote Sensing*, 13 (16). DOI: <https://doi.org/10.3390/rs13163129>
- Coops, N. C., Tompalski, P., Goodbody, T. R. H., Queinnec, M., Luther, J. E., Bolton, D. K., White, J. C., Wulder, M. A., van Liere, O. R., Hermosilla, T. (2021). Modelling lidar-derived estimates of forest attributes over space and time: A review of approaches and future trends. *Remote Sensing of Environment*, 260, 112477. <https://doi.org/10.1016/j.rse.2021.112477>
- Haglöf Sweden: Laser Geo. n. d. . <https://haglofsweden.com/project/laser-geo-2/>, pridobljeno 18. 8. 2023.
- Hahsler, M., Piekenbrock, M., Doran, D. (2019). dbscan: Fast Density-Based

- Clustering with R. *Journal of Statistical Software*, 91 (1), 1–30. DOI: <https://doi.org/10.18637/jss.v091.i01>
- Nik Azhan Hakim, N., Razali, R., Mohd Said, M., Muhamad, M., Abdul Rahim, H., Mokhtar, M. (2023). Accuracy Assessment on Detail Survey Plan Using iPhone 13 Pro Max LiDAR Sensor. *International Journal of Geoinformatics*, 19 (5), 79–86. DOI: <https://doi.org/10.52939/ijg.v19i5.2665>
- Hanmer, B., Frasco, M. (2018). *_Metrics: Evaluation Metrics for Machine Learning_*. R package version 0.1.4, <https://CRAN.R-project.org/package=Metrics>, pridobljeno 30. 4. 2025.
- Kotar, M. (2003). Gozdarski priročnik (p. 414). *Biotehniška fakulteta, Oddelek za gozdarstvo in obnovljive gozdne vire; Repozitorij Univerze v Ljubljani*. <https://repozitorij.uni-lj.si/lzpisGradiva.php?lang=slv&id=126374>, pridobljeno 25. 2. 2025.
- Luetzenburg, G., Kroon, A., Bjørk, A. A. (2021). Evaluation of the Apple iPhone 12 Pro LiDAR for an Application in Geosciences. *Scientific Reports*, 11 (1), Article 1. DOI: <https://doi.org/10.1038/s41598-021-01763-9>
- Križaj, J. (2023). Ocena uporabnosti tehnologije Apple iPhone lidar za izmero dreves na vzorčnih ploskvah gozdne inventure. Diplomsko naloga. Ljubljana: Univerza v Ljubljani, Biotehniška fakulteta. <https://repozitorij.uni-lj.si/lzpisGradiva.php?lang=slv&id=149253>, pridobljeno 30. 4. 2025.
- Mokroš, M., Mikita, T., Singh, A., Tomašič, J., Chudá, J., Wężyk, P., Kuželka, K., Surový, P., Klímánek, M., Zięba-Kulawik, K., Bobrowski, R., Liang, X. (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. DOI: <https://doi.org/10.1016/j.jag.2021.102512>
- Nelson, R., Krabill, W., MacLean, G. (1984). Determining forest canopy characteristics using airborne laser data. *Remote Sensing of Environment*, 15 (3), 201–212. DOI: [https://doi.org/10.1016/0034-4257\(84\)90031-2](https://doi.org/10.1016/0034-4257(84)90031-2)
- R Core Team (2023). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>, pridobljeno 15. 9. 2023.
- Roussel, J.-R., Auty, D., Coops, N. C., Tompalski, P., Goodbody, T. R. H., Meador, A. S., Bourdon, J.-F., de Boissieu, F., Achim, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251, 112061. DOI: <https://doi.org/10.1016/j.rse.2020.112061>
- Singh, A., Pavlenko, V., Mokroš, M. (2024). Tree parameter estimation with iPhone point cloud data using multiple algorithms. *International Journal of Remote Sensing*, 45 (24), 9443–9460. DOI: <https://doi.org/10.1080/01431161.2024.2409996>
- Skudnik, M., Žlogar, J., Poljanec, A., Pisek, R., Pintar, A. M., Kušar, G., Guček, M., Grah, A., Kovač, M. (2020). Nacionalna gozdna inventura: Interna navodila za terensko delo (2020–2024): (Ver. 02/2022): Dopolnitve 13. 5. 2022. *Gozdarski inštitut Slovenije; Digitalni repozitorij raziskovalnih organizacij Slovenije*. <https://dirros.openscience.si/lzpisGradiva.php?lang=slv&id=15132>, pridobljeno 25. 2. 2025.
- Tatsumi, S., Yamaguchi, K., Furuya, N. (2022). ForestScanner: A mobile application for measuring and mapping trees with LiDAR-equipped iPhone and iPad. *Methods in Ecology and Evolution*. DOI: <https://doi.org/10.1111/2041-210x.13900>
- Van Laar, A., Akça, A. (2007). Forest mensuration. Springer, Dordrecht. 383 str.
- Vipavec, J. (2023). Ocena kakovosti laserskega skenerja v tabličnem računalniku Apple [Quality Assessment of Laser Scanner in Apple Tablet]. Magistrska naloga. Ljubljana: Univerza v Ljubljani. <https://repozitorij.uni-lj.si/lzpisGradiva.php?lang=slv&id=145700>, pridobljeno 25. 2. 2025.
- Wood, S. N. (2017). Generalized additive models: An introduction with R. CRC press. DOI: <https://doi.org/10.1201/9781315370279>
- Zavod za gozdove Slovenije (2023). Pregledovalnik podatkov o gozdovih, Odseki – gozdni. <https://prostor.zgs.gov.si/pregledovalnik/>, pridobljeno 11. 9. 2023.
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G. (2016). An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sensing*, 8 (6). DOI: <https://doi.org/10.3390/rs8060501>



Križaj J., Skudnik M. (2025). Uporaba iPhone lidar tehnologije za izmero dreves na vzorčnih ploskvah gozdne inventure.

Geodetski vestnik, 69 (3), 301–315.

DOI: <https://doi.org/geodetski-vestnik.2025.03.301-315>

Jaka Križaj, dipl. inž. gozd.

Univerza v Ljubljani, Biotehniška fakulteta,
Oddelek za gozdarstvo in obnovljive gozdne vire
Jamnikarjeva 101, 1000 Ljubljana
e-naslov: Jakakrizaj2k@gmail.com

doc. dr. Mitja Skudnik

Univerza v Ljubljani, Biotehniška fakulteta,
Oddelek za gozdarstvo in obnovljive gozdne vire
Jamnikarjeva 101, 1000 Ljubljana
e-naslov: mitja.skudnik@bf.uni-lj.si in
Gozdarski inštitut Slovenije, Večna pot 2, 1000 Ljubljana
e-naslov: mitja.skudnik@gozdis.si