

MEDŽIO TŪRIO NUSTATYMAS NAUDOJANT UAV LiDAR DUOMENIS

Dalia RUZGIENĖ, Vytauto Didžiojo universitetas, Žemės ūkio akademija, Miškų ir ekologijos fakultetas, el. paštas: dalia.ruzgiene@vdu.lt

Santrauka

Nuotoliniai tyrimai miškininkystėje sparčiai įsitvirtina kaip priemonė efektyviau ir detaliau nustatyti miško išteklius, todėl būtina vertinti, kiek tiksliai šios technologijos gali pakeisti ar papildyti tradicinius lauko matavimus. Šiame tyrime vertinta, kaip UAV LiDAR duomenys tinka paprastosios pušies (*Pinus sylvestris*) medžių tūriui nustatyti.

Lauko matavimai atlikti šešiuose skirtingų savybių pušynų bareliuose, o didelio tankio LiDAR taškų debesys panaudoti lajos aukščio modeliui sudaryti (angl. canopy height model, CHM). Palyginus kelias lajos aukščio metrikas, tiksliausiai lauko matavimus atitiko 90-asis lajos aukščio percentilis (P90), todėl jis naudotas parenkant tinkamiausią buferio zoną. Vėliau medžių tūrio modeliavimui taikytas platesnis iš CHM išvestų metrikų rinkinys.

Remiantis CHM metrikomis, išbandyti keli regresiniai tūrio modeliai, o jų tikslumas vertintas kryžmine patikra pagal barelius, taikant apmokymo schemą, kai kiekvieno ciklo metu vienas barelis paliekamas už mokymo imties ribų (angl. leave-one-plot-out). Tiksliausi rezultatai gauti taikant neuroninį tinklą (angl. Neural Network), kurio vidutinė tūrio paklaida (RMSE) siekė apie 0,30 m³. Ryškiausias sisteminis nuvertinimas nustatytas jauniausiame, mažiausio tūrio barelyje. Tuo tarpu brandesniuose medynuose modelio paklaidos buvo mažesnės ir neturėjo tokio aiškaus kryptingumo. Analizėje taip pat identifiкуotos pavienės išskirtys, kurios turėjo didesnę įtaką bendram paklaidų pasiskirstymui, tačiau jų pašalinimas sumažino bendrą tūrio nuokrypį. Sujungus duomenis barelių mastu paklaidos sumažėjo, o bendras tūrio nuokrypis liko nedidelis.

Gauti rezultatai rodo, kad UAV LiDAR duomenys gali gana tiksliai atkurti medžio aukštį ir suteikti patikimus ploto lygmens tūrio įverčius, tačiau, prieš taikant metodą naujose sąlygose, rekomenduojama atlikti lokalią tikslumo patikrą.

Reikšminiai žodžiai: UAV LiDAR, medžio tūris, lajos aukščio modelis, CHM, nuotoliniai tyrimai, miškų inventurizacija.

Įvadas

Miško išteklių būklei suprasti ir pagrįstiems valdymo sprendimams priimti reikalingi tikslūs taksaciniai matavimai. Kaip pažymi P. W. West (2015), patikimi dendrometriniai rodikliai leidžia vertinti medžių augimo eigą ir sukauptos medienos potencialą, o tai yra esminė miško ūkio planavimo dalis. Tūris išlieka vienu svarbiausių taksacinių rodiklių, nes, kaip nurodo A. K. Patra (2021), jis yra plačiausiai taikomas medienos kiekio matas, glaudžiai susijęs su ekonomine grąža, išteklių apskaita ir ilgalaikiu planavimu.

Nors tradiciniai matavimo metodai tebėra plačiai taikomi, jie turi tam tikrų apribojimų. K. Stereńczak ir kt. (2019) pabrėžia, kad lauko matavimai yra lėti, brangūs ir dažnai nepakankamai tikslūs dėl sudėtingų sąlygų tankiuose medynuose bei matuotojo patirties įtakos. J. C. White ir kt. (2016) taip pat akcentuoja, kad lauko inventurizacijų sąnaudos didėja proporcingai plotui, tuo tarpu nuotolinių tyrimų metodų duomenys suteikia mastelio ekonomiką. Papildomai Y. Wang ir kt. (2019) parodė, kad aukščio matavimo neapibrėžtumas didėja sudėtingos struktūros medynuose, todėl turį įvertinti tampa sudėtingiau.

Augant poreikiui greitai ir detalai įvertinti miškų būklę, miškininkystėje ryškėja perėjimas nuo vizualiais vertinimais paremtų inventurizacijų prie modeliais grįstų nuotolinių metodų. M. Maltamo ir kt. (2021) nurodo, kad nuotoliniai duomenys sudarė galimybę pereiti prie objektyvesnių, erdviškai nuoseklių inventurizacijų, o F. E. Fassnacht ir kt. (2024) pažymi, kad šios technologijos tapo neatsiejama šiuolaikinės inventurizacijos dalimi. Iš nuotolinių metodų ypač išsiskiria UAV LiDAR, leidžiantis surinkti itin tankius taškų debesis. R. Neuville ir kt. (2021) parodė, kad UAV LiDAR duomenys leidžia išskirti medžių kamienus ir analizuoti miško struktūrą, o P. Qiu ir kt. (2019) ir B. Vandendaele ir kt. (2021) tyrimai patvirtino šių duomenų tinkamumą individualių medžių aukščio, skersmens ir kitų struktūrinių rodiklių vertinimui, ypač esant palankioms skenavimo sąlygoms.

Todėl šiame tyrime siekiama patikrinti, kaip UAV LiDAR duomenys gali būti naudojami nustatant individualių medžių savybes pušynuose. Darbe taip pat įvertinamas šių duomenų tikslumas, apskaičiuojant paprastosios pušies taksacinius rodiklius bei palyginant juos su tradiciniais lauko matavimais.

Tyrimo tikslas – įvertinti paprastųjų pušų (*Pinus sylvestris*) aukščio ir tūrio nustatymo tikslumą medžio lygmeniu, naudojant aukštos skiriamosios gebos UAV LiDAR duomenis ir tradicinius lauko matavimus.

Iškeltam tikslui pasiekti sprendžiami šie **uždaviniai**:

1. Surinkti tyrimo duomenis, atliekant tradicinius lauko matavimus ir UAV LiDAR skenavimą pasirinktuose pušynų plotuose.

2. Apdoroti UAV LiDAR duomenis ir parengti lajos aukščio modelį (CHM), iš kurio medžio lygmeniu apskaičiuoti lajos aukščio metrikas.

3. Įvertinti nuotolinių taksacinių rodiklių (aukščio ir tūrio) nustatymo tikslumą, juos lyginant su tradiciniu medžio taksacijos metodu.

4. Sumodeliuoti medžių tūrį medžio lygmeniu, siejant lauko matavimų duomenis su LiDAR metrikomis ir įvertinti sudarytų modelių tikslumą.

Tyrimų objektas ir metodai

Tyrimas atliktas Kauno rajone, VĮ Valstybinių miškų urėdijos Dubravos regioninio padalinio Ežerėlio girininkijos pušynuose. Tyrimo objektą sudarė IV miškų grupės paprastosios pušies (*Pinus sylvestris*) medynai, kuriuose išmatuoti šeši vienkartiniai matavimų bareliai (B01–B06). Šie bareliai pasirinkti taip, kad apimtų skirtingas medynų struktūras: amžius svyravo nuo 45 iki 100 metų, skalsumas – nuo 0,8 iki 1,1, o augavietės tipai apėmė Nbl, Ncl ir Lbl. Lauko darbuose iš viso išmatuota 380 pušų, o tolesnei analizei (suderinus lauko ir LiDAR informaciją) naudotas 360 medžių rinkinys.

Kiekvienam medžiui lauko matavimais nustatytas skersmuo krūtinės aukštyje (DBH, 1,3 m), medžio aukštis ir tikslios GNSS koordinatės. DBH matuotas žerglėmis, o aukštis – optiniu aukštimačiu Suunto PM-5. Medžių padėtis registruota naudojant Trimble Catalyst DA2 imtuvą, o po lauko darbų atliktas duomenų tikslinimas GIS aplinkoje, siekiant tiksliau suderinti lauko ir LiDAR informaciją. Medžio tūris gautas pagal DBH ir aukštį, taikant Lietuvos Respublikos aplinkos ministro 2002-12-10 įsakymo Nr. 631 medienos tūrio lenteles. Šios reikšmės tyrime laikomos atskaitos duomenimis (V_{field}).

UAV LiDAR duomenys surinkti naudojant droną DJI Matrice 350 RTK ir lazerinio skenavimo jutiklį Zenmuse L2. Skrydžiai vykdyti 100 m aukštyje virš reljefo paviršiaus, skenavimo juostų perdengimas siekė 62 proc., o vidutinis taškų tankis sudarė apie 360 taškų·m⁻². Gauti taškų debesys eksportuoti LAS formatu ir apdoroti ArcGIS Pro. Visų pirma naudojant žemės taškus sudarytas skaitmeninis reljefo modelis (DTM), paskui iš pirmojo atspindžio taškų – skaitmeninis paviršiaus modelis (DSM). Abu modeliai generuoti 0,25 m gardelės dydžiu. Lajos aukščio modelis (CHM) apskaičiuotas kaip DSM – DTM.

Medžių padėtys CHM atžvilgiu koreguotos vizualiai, naudojant *hillshade* atvaizdus. Tais atvejais, kai viršūnė buvo aiškiai matoma, medžio koordinatės patikslintos. Aplink kiekvieną patikslintą medžio tašką sudaryti 0,5 m ir 1,0 m spindulio buferiai, iš kurių zoninėmis statistinėmis funkcijomis išgautos aukščio metrikos: P90, P95, H_{MAX}, H_{MEAN}, H_{SD} bei interkvartilinis aukščio diapazonas H_{IQR} (apskaičiuotas kaip P75 – P25). Aukščio tikslumas vertintas lyginant P90 su lauko aukščiais, apskaičiuojant Bias, MAE ir RMSE. Kiekvienam barelyje atrinktas tas buferio spindulys, kuriam aukščio nuokrypis buvo mažiausias.

Tūrio modeliavimo etape naudotas iš LiDAR taškų gautų metrikų rinkinys. Prognozuotas tūris (V_{pred}) apskaičiuotas taikant kelis regresinius modelius, tarp jų – daugiasluoksnį neuroninį tinklą. Modelių tikslumas vertintas kryžmine patikra, kai kiekviename cikle vienas barelis paliekamas testavimui už mokymo ribų, o likę – mokymui (angl. leave-one-plot-out). Remiantis kryžminės patikros rezultatais, apskaičiuoti Bias, MAE, RMSE, taip pat santykiniai rodikliai rMAE ir rRMSE. Šie rodikliai leido įvertinti UAV LiDAR metrikų tinkamumą medžio lygmens taksaciniams rodikliams nustatyti ir jų atitikimą tradiciniams matavimams. Galiausiai vertintas suminis tūrio nuokrypis barelių mastu, siekiant įvertinti, ar individualios paklaidos kompensuojasi ploto lygmeniu.

Tyrimų rezultatai ir jų aptarimas

Vertinant UAV LiDAR duomenų tinkamumą tūrio modeliavimui, visų pirma analizuotas aukščio metrikų atitikimas lauko matavimams. Daugumoje barelių P90 metrika gerai atkartojė lauko aukštį, o santykinės paklaidos rRMSE_H svyravo nuo 3,4 iki 5,1 proc., nė viename barelyje neviršydamos 10 proc. Kadangi, skirtinguose bareliuose optimalus buferio spindulys buvo nevienodas, P90 tikslumo vertinimas naudotas nustatyti, kuris buferis kiekvienu atveju yra tinkamiausias. Pasirinkus optimalų spindulį, iš atitinkamo buferio buvo apskaičiuotos kitos CHM metrikos, kurios vėliau naudotos tūrio modeliavimo etape. Tokie rezultatai rodo, kad lajos aukščio metrikos gana tiksliai atspindi medžių viršūnių padėtį ir sudaro patikimą pagrindą tolimesnei tūrio analizei. Mažesnės paklaidos dažniausiai gautos vidutinio amžiaus ir vienodesnės struktūros pušynuose, o didesnė nuokryptai nustatyti ten, kur lajos persidengia arba viršūnių identifikavimas sudėtingesnis (žr. 1 lentelę).

1 lentelė. Aukščio įverčių tikslumas (P90 palyginti su H_{field})

Table 1. Accuracy of height estimates (P90 vs H_{field})

Barelis	Buferis	mean(H _{field}), m	RMSE _H , m	rRMSE _H , %
B01	0,5 m	25,65	0,9	3,51
B02	1,0 m	17,13	0,79	4,61
B03	0,5 m	25,39	0,9	3,55
B04	0,5 m	24,75	1,19	4,81
B05	1,0 m	28,71	0,99	3,44
B06	1,0 m	22	1,13	5,12
Visi	parinkta pagal barelį	24,23	1,02	4,2


Toliau palyginti keli regresiniai metodai, o jų tikslumas įvertintas kryžmine patikra paliekant po vieną barelį testavimui. Geriausiai pasirodė daugiasluoksnis neuroninis tinklas (angl. Neural Network), kurio vidutinė absoliuti paklaida visam duomenų rinkiniui siekė $MAE \approx 0,214 \text{ m}^3$, o šakninis vidutinis kvadratinis nuokrypis $RMSE \approx 0,306 \text{ m}^3$. Reikšmė $R^2 (\approx 0,544)$ rodo, kad modelis paaiškina daugiau nei pusę individualių medžių tūrio skirtumų, o likusi dalis susijusi su natūraliu medžių formų nevienodumu ir LiDAR metrikų ribotumu. Tai yra įprastas lygis modeliuojant individualių medžių tūrį iš UAV LiDAR metrikų. Atsitiktinių miškų modelis (Angl. Random Forest) taip pat pasižymėjo panašiu tikslumu, tačiau neuroninis tinklas išsiskyrė mažesnėmis paklaidomis tiek medžio, tiek barelio mastu. Kiti metodai (kNN ir tiesinė regresija) pasižymėjo mažesniu tikslumu, ypač tankesniuose ir struktūriškai įvairesniuose medynuose (žr. 2 lentelę).

2 lentelė. Modelių palyginimo rezultatai kryžminėje patikroje (paliekant vieną barelį testavimui).

Table 2. Comparison of modelling methods in leave-one-plot-out validation

Grupė	Modelis	Bias, m^3	MAE, m^3	RMSE, m^3	R^2	rMAE (%)	rRMSE (%)
Visi medžiai (n=360)	Neural Network	0,044	0,214	0,306	0,544	29,5	42,2
Visi medžiai (n=360)	Random Forest	0,038	0,232	0,319	0,502	32,0	44,0
Grupė A (B01, B03, B04) (n=201)	Neural Network	0,022	0,248	0,350	0,442	28,5	40,2
Grupė A (B01, B03, B04) (n=201)	Random Forest	0,006	0,260	0,350	0,441	29,8	40,2
Grupė B (B02, B05, B06) (n=159)	Neural Network	0,071	0,172	0,238	0,546	31,9	44,1
Grupė B (B02, B05, B06) (n=159)	Random Forest	0,078	0,197	0,276	0,393	36,5	51,1

Prognozuoto (V_{pred}) ir lauko (V_{field}) tūrio palyginimas parodė, kad dauguma taškų telkiasi aplink 1:1 liniją. Tai reiškia, kad modelis gana tiksliai atkuria bendrą tūrio lygį visame intervale. Didesnė sklaida pastebėta stambesnių medžių srityje, kur lajų forma ir šakų architektūra labiau varijuoją, todėl LiDAR metrikos ne visada visiškai atspindi kamieno tūrį. Santykinė paklaida rRMSE sudarė apie 42 proc., todėl modelis tinkamas bendram tūrio pasiskirstymo vertinimui ir orientacinėms įžvalgoms medžio lygmeniu. Tačiau tokio tikslumo nepakanka priimant individualius sprendimus. Pavienių medžių atveju prognozės gali gerokai nutolti nuo tikrojo tūrio, todėl būtina papildoma kontrolė lauke (žr. 1 pav.).



1 pav. Lauko tūrio (V_{field}) ir kryžminės patikros prognozuoto tūrio (V_{pred}) skaidos diagrama (n = 360). Raudona linija žymi idealią 1:1 priklausomybę.

Fig. 1. Scatterplot of field-measured volume (V_{field}) vs predicted volume (V_{pred})

Tūrio tikslumas skyrėsi tarp barelių. Mažiausios absoliučios paklaidos nustatytos B02 ir B06 bareliuose, o didžiausios – B01 ir B03, kuriuose vyrauja stambesni medžiai ir įvairesnė lajų sandara. Vertinant santykinės paklaidas matyti, kad B02 išsiskiria ryškiu kryptingu tūrio nuvertinimu ($rRMSE \approx 49$ proc.), nors absoliutūs nuokrypiai yra nedideli. Ši situacija susijusi su mažais tūrio dydžiais – bet koks absoliutus nuokrypis procentine išraiška tampa ryškesnis. Brandesniuose bareliuose (pvz., B04) paklaidos buvo mažesnės ir stabilesnės (žr. 3 lentelę).

3 lentelė. Tūrio prognozių tikslumo rodikliai pagal barelius.

Table 3. Volume prediction accuracy by sample plot

Barelis	Medžių skaičius	Bias, m^3	MAE, m^3	rMAE, %	RMSE, m^3	rRMSE, %
1 (B01)	103	0,066	0,281	28,3	0,384	38,7
2 (B02)	45	0,118	0,120	39,4	0,150	49,2
3 (B03)	54	0,027	0,234	28,9	0,365	45,1
4 (B04)	44	-0,086	0,186	28,1	0,225	34,0
5 (B05)	51	0,145	0,263	28,9	0,343	37,6
6 (B06)	63	-0,022	0,135	33,2	0,179	44,0

Vertinant barelio mastu, daugumos barelių suminis prognozuotas tūris buvo artimas lauko matavimams. Visų barelių mastu modelis nuvertino tūrį apie 6 proc., o tai atitinka vidutinio tikslumo modeliams būdingą poslinkį. Absoliučios individualios paklaidos dažnai kompensuojasi sumuojant, todėl bendras tūris plote vertinamas gana tiksliai. Išimtimi išliko B02 barelis, kuriame nustatytas ryškesnis suminis nuvertinimas. Tai iš dalies susiję su mažais šio barelio tūrio dydžiais, dėl kurių procentinė paklaida tampa jautresnė, tačiau absoliutus nuokrypis taip pat išliko didesnis. Kadangi B02 barelyje nebuvo identifikuota statistinių išskirčių, tikėtina, kad čia pasireiškia kryptingas poslinkis, kai mažesni medžiai nuosekliai įvertinami žemesnėmis tūrio reikšmėmis.

4 lentelė. Suminis tūris pagal barelius.

Table 4. Total volume by sample plot.

Barelis	Medžių skaičius	V_field m ³	V_pred m ³	$\Sigma(V_{\text{field}} - V_{\text{pred}})$ m ³	$\Sigma(V_{\text{field}} - V_{\text{pred}})$ %
B01	103	102,277	95,500	6,777	6,6
B02	45	13,719	8,387	5,332	38,9
B03	54	43,668	42,223	1,445	3,3
B04	44	29,158	32,933	-3,775	-12,9
B05	51	46,470	39,073	7,397	15,9
B06	63	25,617	27,031	-1,414	-5,5
Iš viso	360	260,909	245,147	15,762	6,0

Siekiant įvertinti modelio jautrumą pavienėms didelėms paklaidoms, atlikta statistinių išskirčių analizė. Išskirtys nustatytos taikant $1,5 \times \text{RMSE}$ kriterijų, kuris leidžia atskirti įprastą paklaidų sklaidą nuo reikšmingai didesnių nuokrypių, bet neišima per daug duomenų. Pagal šį slenkstį ($\text{AbsErr} > 0,458 \text{ m}^3$) identifikuotos 32 išskirtys, daugiausia B01, B03 ir B05 bareliuose. Šiuose bareliuose didesni nuokrypiai buvo susiję su sudėtingesne lajų struktūra ir lokaliais duomenų pririšimo neatitikimais. Pašalinus išskirtis, bendras suminio tūrio nuokrypis sumažėjo iki $-0,4 \text{ proc.}$, todėl dauguma paklaidų ploto mastu iš esmės kompensuojasi. B02 barelis išliko išskirtinis: jame išskirčių nebuvo, tačiau kryptingas nuvertinimas išliko, kas rodo sisteminį poslinkį, o ne pavienių situacijų įtaką.

Išvados

1. UAV LiDAR duomenys leido pakankamai tiksliai nustatyti paprastosios pušies aukštį, todėl iš LiDAR duomenų išvestos metrikos yra tinkamos naudoti tūrio modeliavimui.
2. Iš LiDAR taškų metrikų sudarytuose tūrio modeliuose, tiksliausias buvo daugiasluoksnis neuroninis tinklas, kuris išsiskyrė mažiausiomis absoliučiomis paklaidomis.
3. Tūrio tikslumas skyrėsi tarp barelių. Jauniausiame B02 nustatytas kryptingas nuvertinimas, o brandesniuose ir vienodesnės struktūros medynuose modelio paklaidos buvo mažesnės ir stabilesnės.
4. Ploto mastu modelio tikslumas buvo geresnis nei pavienių medžių lygmeniu, nes individualios paklaidos dažnai kompensuojasi. Pašalinus išskirtis, suminis nuokrypis sumažėjo iki nereikšmingo lygio.
5. Metodas tinkamas bendram medyno tūrio įvertinimui, tačiau pavienių medžių tūrio įverčiai dėl santykinės paklaidos dydžio turėtų būti tikrinami papildomais matavimais.

Literatūra

1. Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2024). Remote sensing in forestry: current challenges, considerations and directions. *Forestry*, 97(1), 11–37. <https://doi.org/10.1093/forestry/cpad024>
2. Maltamo, M., Packalen, P., & Kangas, A. (2021). From comprehensive field inventories to remotely sensed wall-to-wall stand attribute data — a brief history of management inventories in the Nordic countries. *Canadian Journal of Forest Research*, 51(2), 257–266. <https://doi.org/10.1139/cjfr-2020-0322>
3. Neuville, R., Bates, J. S., & Jonard, F. (2021). Estimating Forest Structure from UAV-Mounted LiDAR Point Cloud Using Machine Learning. *Remote Sensing*, 13(3), Article 352. <https://doi.org/10.3390/rs13030352>
4. Patra, A. K. (2021). Forest mensuration. In A. K. Patra, *Introductory Forestry*. Springer.
5. Qiu, P., Wang, D., Zou, X., Yang, X., Xie, G., Xu, S., & Zhong, Z. (2019). Finer Resolution Estimation and Mapping of Mangrove Biomass Using UAV LiDAR and WorldView-2 Data. *Forests*, 10(10), Article 871. <https://doi.org/10.3390/f10100871>
6. Stereńczak, K., Mielcarek, M., Wertz, B., Bronisz, K., Zajączkowski, G., Jagodziński, A. M., Ochał, W., & Skorupski, M. (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>
7. Vandendaele, B., Fournier, R. A., Vepakomma, U., Pelletier, G., Lejeune, P., & Martin-Ducup, O. (2021). Estimation of Northern Hardwood Forest Inventory Attributes Using UAV Laser Scanning (ULS): Transferability of Laser Scanning Methods and Comparison of Automated Approaches at the Tree- and Stand-Level. *Remote Sensing (Basel, Switzerland)*, 13(14), Article 2796. <https://doi.org/10.3390/rs13142796>
8. Wang, Y., Lehtomäki, M., Liang, X., Pyörälä, J., Kukko, A., Jaakkola, A., Liu, J., Feng, Z., Chen, R., & Hyypä, J. (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>

9. West, P. W. (2015). *Tree and forest measurement* (3rd ed.). Springer. <https://doi.org/10.1007/978-3-319-14708-6>

ESTIMATION OF TREE VOLUME USING UAV LIDAR DATA

Abstract

Remote sensing is rapidly establishing itself in forestry as a means of determining forest resources more efficiently and in greater detail, so it is necessary to assess the extent to which this technology can replace or supplement traditional field measurements. This study evaluated the suitability of UAV LiDAR data for determining the volume of Scots pine (*Pinus sylvestris*) trees.

Field measurements were taken in six pine stands with different characteristics, and high-density LiDAR point clouds were used to create a canopy height model (CHM). After comparing several canopy height metrics, the 90th percentile of canopy height (P90) most accurately matched the field measurements and was therefore used to select the most suitable buffer zone. Subsequently, a broader set of metrics derived from the CHM was applied to model tree volume.

Based on the CHM metrics, several regression volume models were tested, and their accuracy was evaluated by cross-validation using plots, applying a training scheme where one plot was left out of the training sample during each cycle (leave-one-plot-out). The most accurate results were obtained using a Neural network, with an average volume error (RMSE) of about 0.30 m³. The most significant systematic underestimation was found in the youngest stand with the smallest volume. Meanwhile, in more mature stands, the model errors were smaller and did not have such a clear directionality. The analysis also identified isolated outliers that had a greater impact on the overall distribution of errors, but their removal reduced the overall volume deviation. After combining the data at the stand level, the errors decreased and the overall volume deviation remained small.

The results show that UAV LiDAR data can accurately reproduce tree height and provide reliable area-level volume estimates, but it is recommended to perform a local accuracy check before applying the method in new conditions.

Keywords: UAV LiDAR, tree volume, canopy height model, CHM, remote sensing, forest inventory.