

Usporedba lidarskih i terenskih podataka pri izmjeri visine stabala u urbanim područjima

Ante Seletković, Martina Kičić, Alen Berta, Renata Pernar, Mario Ančić, Jelena Kolić, Ivan Balenović

Nacrtak – Abstract

U radu je na temelju podataka dobivenih laserskim skeniranjem iz zraka prikazana obrada 3D oblaka točaka te različiti načini i mogućnosti uporabe podataka pri praćenju i izmjeri vegetacije urbanih područja. U istraživanju su korišteni lidarski (engl. LiDAR = Light Detection and Ranging) podaci dobiveni u Zagrebu, točnije na Lenucijevoj potkovi, na Trgu Nikole Šubića Zrinjskoga. Na istraživanom području za svako je locirano stablo određena vrsta i mjerena njegova visina (m) ultrazvučnim visinomjerom Vertex III. Terenskom izmjerom obuhvaćeno je 146 stabala (od toga 140 hibridnih platana (*Platanus × hispanica*) i 6 stabala javora mlječa (*Acer platanoides L.*). Prosječna izmjerena visina uređajem Vertex III iznosila je 24,0 m s rasponom od 5,60 m za najniže stablo do 36,0 m za najviše izmjereno stablo. Srednji prsni promjer iznosio je 74 cm s rasponom od 8 cm do 160 cm. Laserskim skeniranjem iz zraka i obradom prikupljenih podataka dobiven je georeferencirani 3D oblak točaka razvrstan u četiri razreda kao proizvod obrade sirovih podataka u softveru LAStools te prikazan u softveru QTM za vizualizaciju oblaka točaka. Prilikom očitavanja visine iz oblaka točaka izdvojena su 134 stabla. Srednja izmjerena visina stabala temeljem oblaka točaka iznosi 23,07 m, najniže izmjereno stablo visine je 5,31 m, a najviše 33,34 m. Statističkom obradom i usporedbom podataka dobiveni su koeficijent korelacije $r_s = 0,91$ i koeficijent determinacije $R^2 = 0,83$, dok je $p = 0,000$ ($p < 0,05$), što upućuje na statističku značajnost dobivene korelacije, a što potvrđuje validnost te upotrebljivost lidarskih podataka pri izmjeri i praćenju urbane vegetacije.

Ključne riječi: LiDAR, 3D oblak točaka, visina stabala, urbane šume, parkovni nasadi

1. Uvod – Introduction

Urbana vegetacija, osobito drveće, nudi mnoge pogodnosti koje mogu poboljšati kvalitetu okoliša i zdravlje građana u gradovima i u njihovoј okolini (Nowak i dr. 2008). Urbane šume omogućuju i pružaju mnoge prednosti, kao što su štednja energije, poboljšanje upravljanja vodama, smanjenje onečišćenja zraka i povezivanje urbanih stanovnika s prirodom (McPherson 2006).

Unaprijeđenje korištenja i pogodnosti koje pružaju zahtjeva provođenje inventure urbane vegetacije radi uspješnijega planiranja i upravljanja. Osnovne informacije koje sadrži takva inventura uključuju: broj pojedinačnih stabala, vrste drveća, habitusna obilježja, dimenzije, prostorni raspored i zdravstveno stanje.

Tradicionalno se takvi podaci prikupljaju terenskom izmjerom koja je skupa, fizički zahtjevna i koja oduzima mnogo vremena. Dodatno, terenske se izmjere mogu provoditi samo na područjima koja su dostupna za izmjeru, a nedostupni su podaci s privatnih posjeda i ostalih nepristupačnih područja. Daljinska su istraživanja stoga postala prihvatljiva alternativa terenskim izmjerama u inventuri vegetacije zbog ukupno manjega troška izmjere, veće obuhvaćene površine i redovitoga ciklusa prikupljanja podataka (Zhang i Qiu 2012). Iako se u uporabi mogu naći različite vrste senzora kojima se prikupljaju informacije o šumskoj vegetaciji, lidarska tehnologija (engl. LiDAR = Light Detection and Ranging) u posljednje se vrijeme sve više primjenjuje za pridobivanje podataka o površinama obraslim drvećem jer može pružiti veoma točne informacije o obliku proma-

tranoga objekta uz pomoć georeferenciranih 3D točaka (Kwak i dr. 2007).

Prema Wehru i Lohru (1999) LiDAR je akronim za engl. *Light Detection and Ranging*, iako je svojedobno postojala tendencija uvođenja pojma LADAR, odnosno akronima za engl. *Laser Detection and Ranging* kako bi se naglasila primjena lasera. Riječ je o potpuno automatiziranom, aktivnom, optičko-mehaničkom postupku prikupljanja prostornih podataka dostupnih s aktualnih snimališta (Gajski 2007). Jedno je od glavnih svojstava toga sustava njegova mogućnost prikupljanja velikoga broja visoko točnih trodimenzionalnih prostornih podataka velikih područja u razmijerno kratkom razdoblju. Lidarski sustav temelji se na laserskom skeniranju koje mjeri udaljenost između skenera i objekta izmjere, a ona se računa pomoću brzine svjetlosti i vremena potrebnoga da emitirano lasersko zračenje dođe do objekta (Baltsavias 1999). Jedna je od prednosti toga sustava njegova iznimna preciznost koja se ogleda u činjenici da se prilikom laserskoga skeniranja iz zraka ponekad mogu dobiti podaci koji su precizni u centimetar, dok je lasersko skeniranje sa zemlje još preciznije i ide u milimetarske točnosti.

Lidar je aktivni sustav koji je neovisan o danjem svjetlu, ali zato traži čistu atmosferu prilikom skeniranja (bez smoga ili magle koji bi onemogućili ili produljili vrijeme skeniranja). Osim toga laser se ne može koristiti za kišna vremena jer većina emitiranoga zračenja ne može prodrijeti kroz vodu. U ovisnosti o platformi koja nosi skener, tehnologija laserskoga skeniranja može se podijeliti na:

- ⇒ lasersko skeniranje sa zemlje (engl. *Terrestrial Laser Scanning – TLS*)
- ⇒ lasersko skeniranje iz zraka (engl. *Airborne Laser Scanning – ALS*)
- ⇒ lasersko skeniranje iz svemira (engl. *Spaceborne Laser Scanning – SLS*) (Petrie i Toth 2009, Balenović i dr. 2013, Berta 2017).

Od navedenih najčešće se koristi lasersko snimanje iz zraka (ALS), pri kojem su avion ili helikopter platforme koje nose skener. Lasersko skeniranje iz zraka omogućuje najbolji pristup velikim površinama terena i nudi mogućnost velike pokretljivosti skenera, dok su laserska snimanja sa zemlje (TLS) pogodnija za ograničena područja, izuzetno strme terene te pojedinačna detaljna snimanja. Podroban prikaz i opis glavnih svojstava lidarskoga sustava dali su Balenović i dr. (2013).

Mogućnosti lidarske tehnologije prepoznate su u svijetu te se ona počinje intenzivnije istraživati početkom 21. stoljeća. Otada se može pratiti sve veći broj objavljenih znanstvenih radova na temu njezine primjene u brojnim sferama koje i dalje rastu, što je dokaz njezine relevantnosti i svestranosti.

Mnogi svjetski znanstvenici u svojim istraživanjima ispituju mogućnosti lidarske tehnologije u kompleksnom urbanom prostoru. Kada se pritom analizira urbana vegetacija, onda se može pronaći nekoliko glavnih interesnih skupina: generiranje preciznih digitalnih modela terena (Chen i dr. 2012), određivanje volumena zelenila (Hecht i dr. 2008), procjene gustoće vegetacije (engl. *Leaf Area Index – LAI*) (Hopkinson i dr. 2013, Alonso i dr. 2015, Lin i West 2016, Klinberg i dr. 2017), determinacija i kartiranje pojedinačnoga stabla (Kim i dr. 2009, Holopainen i dr. 2013). U posljednje se vrijeme sve više lidarska tehnologija spaja s hiperspektralnim snimkama kako bi se omogućila i ispitala preciznija determinacija vrste drveća ovom metodom daljinskih istraživanja (Zhang i Qiu 2012, Alonso i dr. 2014, Alonso i dr. 2016, Liu i dr. 2017).

Pregled hrvatske literature na temu lidarske tehnologije te njezine primjene u šumarstvu donosi relativno malen broj radova. Gajski (2007) daje definiciju i obrađuje osnove laserskoga skeniranja iz zraka. Benko i Balenović (2011) na primjeru istraživanja provedenih u svijetu preporučuju ovu tehnologiju daljinskih istraživanja za inventure šuma u Hrvatskoj, potom Balenović i dr. (2013) podrobno prikazuju principe rada i mogućnosti lidarske tehnologije u šumarstvu jugoistočne Europe. Žmegač (2015) i Božić (2016) u svojim radovima analiziraju dinamiku prašuma uz pomoć lidarskih snimaka, a Berta (2017) primjenjuje tu tehnologiju za procjenu šumske biomase u degradiranim šumama brežuljkastoga i nizinskoga vegetacijskoga pojasa.

Budući da je u Hrvatskoj vrlo malo dostupnih rezultata istraživanja primjene lidarske tehnologije u urbanom šumarstvu, u radu će se podrobno analizirati mogućnosti obrade i primjene podataka dobivenih laserskim skeniranjem iz zraka u izmjeri i interpretaciji vegetacije urbanih prostora.

Cilj je rada na temelju podataka dobivenih laserskim skeniranjem iz zraka u Zagrebu prikazati obradu 3D oblaka točaka, klasifikaciju, vizualizaciju i različite načine i mogućnosti uporabe takvih podataka pri praćenju i izmjeri vegetacije urbanih područja. Nadalje, na odabranom primjeru parkovnoga nasada istražiti će se uspješnost primjene lidarskoga snimanja za razlučivanje pojedinačnih stabala te određivanje njihove totalne visine usporedbom s visinom određenih teretički ultrazvučnim daljinomjerom.

2. Materijal i metode – Material and Methods

2.1 Područje istraživanja – Study Area

Kako se ne radi o ciljanom istraživanju, područje je istraživanja određeno dostupnim lidarskim podacima



Slika 1. Lenucijeva potkova s označenim Trgom Nikole Šubića Zrinskoga

Fig. 1 Lenuci's Horseshoe with the marked Square of Nikola Šubić Zrinskog

koje je ustupio Grad Zagreb. Za područje istraživanja izabrana je Lenucijeva potkova, konkretno Trg Nikole Šubića Zrinskoga (Zrinjevac) (slika 1).

Lenucijeva potkova ili Zelena potkova skupni je naziv za slijed od sedam perivojnih trgova i jednoga perivoja koji uokviruju središte Donjega grada – jezgru središta Zagreba. To su Trg Nikole Šubića Zrinskoga (Zrinjevac), Trg Josipa Jurja Strossmayera, Trg kralja Tomislava, Trg Ante Starčevića, Botanički vrt, Trg Marka Marulića, Trg Mažuranića i Trg maršala Tita (Bojanić Obad Šćitaroci i Obad Šćitaroci 2004).

Trg Nikole Šubića Zrinskoga ili, kako se popularno zove, Zrinjevac prvi je u nizu perivojnih trgova zagrebačke Lenucijeve potkove. Zrinjevac je istočno ishodište potkove. Projekt za Zrinski trg izradio je 1870. gradski inženjer Rupert Melkus. Ploha perivoja površine 2,74 ha bila je podijeljena na četiri pravilna pravokutna polja, neznatno zaobljena na uglovima, a na sjecištu je dviju staza kružno proširenje. Vanjske i unutarnje šetnice obrubljene su drvoređima platana (*Platanus × hispanica*). Platane, dopremljene iz Udina (Italija), posadene su 1872. (Bojanić Obad Šćitaroci i Obad Šćitaroci 2004). Do kraja 19. stoljeća Zrinjevac je prošao tri značajnija preoblikovanja i otada do danas nije se znatnije mijenjao.


Zrinjevac je prava zelena oaza u samom središtu grada Zagreba, omiljeno odredište građanima, ali i sve

većemu broju turista. Zbog svoje lokacije, izuzetno urbaniziranoga okoliša koji ga okružuje i stogodišnjih drvoređa platana koje mu daju prepoznatljiv izgled, ovaj je perivojni trg idealna lokacija za prikaz mogućnosti koje nudi laserska tehnologija snimanja iz zraka s naglaskom na prikaz i analizu pojedinačnih stabala.

2.2 Terenski podaci – Field Data

Prikupljanje terenskih podataka napravljeno je 18. srpnja 2017. godine. Na istraživanom području svakomu pojedinačnomu stablu pridružena je oznaka, determinirana je vrsta drveća, izmjerena totalna visina (m) ultrazvučnim visinomjerom Vertex III s očitanjem na jednu decimalu te opseg (cm) na prsnoj visini (1,30 m od tla) iz kojega je izračunat prsni promjer.

Tijekom prikupljanja terenskih podataka, radi lakšega snalaženja prilikom obrade podataka, korišten je Katastar zelenila (URL 1) izrađen za Zagrebački holding, podružnicu Zrinjevac. Katastar zelenila je digitalna zbirka drveća, grmlja i ostalog bilja u kojem su sistematizirani i inventarizirani podaci o sadržajima javnih gradskih površina. O svakom stablu u Katastru postoje osnovne informacije, kao što su: latinski i hrvatski naziv bilje, prostorni raspored, zaštitni elementi oko stabla (ako postoje), promjer stabla, promjer krošnje i visina stabla. Ti su podaci informativnoga karaktera te se ne mogu uzeti kao pouzdane i refer-



Slika 2. Trg Nikole Šubića Zrinskog s oznakama stabala mjerjenih terestički visinomjerom

Fig. 2 The Square of Nikola Šubić Zrinski with tree markings measured terrestrially by hypsometer

entne vrijednosti, stoga se prilikom terenske izmjere koristio samo prikaz prostornoga rasporeda stabala. Prije samoga izlaska na teren svako je stablo označeno (obrojčano) (slika 2), tim je redoslijedom obavljana izmjera i pod tom je oznakom ono bilo uključeno u sve daljnje analize izmjerjenih i snimljenih podataka.

2.3 Lidarski podaci – LiDAR Data

Lidarski podaci snimljeni su tijekom travnja 2012. godine. Snimanje je obavila tvrtka GISDATA za naručitelja Grad Zagreb. Podaci su snimani senzorom Leica

ALS-50 II (tablica 1) uz minimalnu gustoću skeniranja 0,5 točaka/m² te s poprečnim preklopom od 20 %.

2.4 Obrada lidarskih podataka – LiDAR Data Processing

Obrada »sirovih« (neobrađenih i neklasificiranih) lidarskih podataka napravljena je pomoću softvera LAStools (Rapidlasso GmbH, Gilching, Germany) koji sadrži niz modula (alata) za razredbu, ekstrakciju i pretvorbu lidarskih podataka. Prilikom obrade podataka ovim softverom primijenjena je metodologija

Tablica 1. Tehnička svojstva lidarskoga senzora (LEICA Geosystems) i podataka**Table 1** Technical characteristics of LiDAR sensor (LEICA Geosystems) and data

Vrsta senzora – Sensor type	»Discrete return« (snima pojedine povrate) – »Discrete return« (records individual returns)
Visina snimanja – Recording height	Max. 6000 m
Širina snimanja (FOV) – Field of view (FOV)	75°
Broj povrata – Number of returns	Prvi, drugi, treći i zadnji – First, second, third and last
Brzina snimanja – Recording speed	90 Hz pri 10° FOV / 30 Hz pri 75° FOV
Brzina emitiranja laserskih zraka – Laser emission rate	150 kHz (150 000 zraka) pri visini snimanja 500 m / 22 kHz pri visini snimanja 6000 m 150 kHz (150.000 bems) at recording height 500 m / 22 kHz at recording height 6000 m
Vrijeme snimanja – Recording time	26. 3. 2012.
Inercijalni sustav – Inertial system	Applanix 310
Softver za planiranje leta – Flight planning software	Fplan
Sustav za navigaciju GPS-om – GPS navigation system	MASON
Avion za snimanje – Airplane	Cessna 402B
Visina leta – Height of flight	2000 m (nominalno) – 2.000 m (nominal)
Lidarski senzor – LiDAR sensor	Leica ALS-50 II
Softver za postprocesnig (LiDAR) – Software for postprocessing	ALS Post Processor

prikazana u Berta (2017). Ovo je nužan korak u analizi lidarskih podataka, jer je dobiveni proizvod u obliku obrađenoga i klasificiranoga oblaka točaka podloga za daljnje detaljne analize željenoga područja.

Izvorni se lidarski podaci čuvaju kao datoteke, gdje svaka predstavlja jedan let. Iako je podatke moguće obrađivati na razini leta, pristupilo se spajjanju dobivenih podataka i spremanjem dobivene datoteke u .las format.

LAS format je javni format podataka za razmjenu 3D oblaka točaka među korisnicima. Iako je razvijen primarno za potrebe razmjene lidarskih podataka, danas podržava razmjenu bilo kojih 3D x, y, z nizova. Uspješno zadržava sve informacije karakteristične za lidar (intenzitet, broj povrata signala ...) i pritom ostaje jednostavan (Ivšić i dr. 2016).


Budući da su podaci dostavljeni u projekciji UTM 33, WGS84 radi preklapanja sa željenim područjem, oni se najprije transformiraju u projekciju HTRS96/TM te se izdvajaju željena područja alatom lasclip. Zatim se računa gustoća točaka na izdvojenom željenom području i uređuje se oblak točaka pomoću alata las-noise, koji pronalazi usamljene točke te ih klasificira ili uklanja.

Nakon utvrđivanja kvalitete korištenoga oblaka točaka pristupa se automatskoj klasifikaciji na točke tla (engl. ground points) i točke iznad tla (engl. non-ground points) s alatom lasground. Taj se postupak u literaturi naziva filtriranje (engl. lidar data filtering)

(Zhang i Qiu 2012, Ivšić i dr. 2016). Također se alatom lasheight svakoj točki računa nadmorska visina, što je potrebno za daljnje klasificiranje ili za izradu digitalnoga modela terena.

Nakon automatske klasifikacije oblaka točaka, a radi poboljšanja dobivenih rezultata preporučuje se provesti i manualnu klasifikaciju. Naime, iako daje dobre rezultate, softverski algoritam nije savršen, osobito pri klasifikaciji složenijih objekata i površina poput stabala i šumskih sastojina. Po utvrđivanju pogrešno svrstanih točaka moguće ih je reklassificirati bilo manualno ili automatski. Postupak reklassifikacije točaka terena i ostalih točaka iznad terena ponavlja se dok god se ne dobiju zadovoljavajući rezultati. Taj je korak ključan jer izravno uvjetuje kvalitetu generiranja digitalnih modela terena (Ivšić i dr. 2016).

Nakon filtriranja i reklassifikacije oblaka točaka, da bi se izdvojile samo točke vegetacije alatom lasclassify, nastavlja se daljnja klasifikacija na vegetaciju, zgrade, puteve i ostale objekte u prostoru. Kao neki oblik vegetacije (niska, srednja, visoka) klasificiraju se sve točke koje se nalaze 0,5 m iznad tla. Kako navodi Berta (2017, preuzeto od Garcia i dr. 2010), prag od 0,5 m iznad tla za klasifikaciju točaka kao točaka vegetacije u skladu je s postojećim istraživanjima. Prilikom klasificiranja vegetacije korisno je iskoristiti informacije o broju povrata signala s obzirom na to da se prepostavlja da će vegetacija imati više povrata jer će se signal najprije odbiti od krošnje stabla, zatim od grane, pa tek onda od tla (Ivšić i dr. 2016).



Slika 3. Prikaz izdvojenoga oblaka točaka u softveru QTM: neklasificirano (class 1), tlo (class 2), visoka vegetacija (class 5) i zgrade (class 6)

Fig. 3 Display of the separated cloud of points in the QTM software: unclassified (Class 1), soil (Class 2), high vegetation (Class 5) and buildings (Class 6)

Daljnja obrada i vizualizacija podataka provedena je na izdvojenom i klasificiranom oblaku točaka (slika 3) u softveru Quick Terrain Modeler (QTM) (Applied Imagery, Chevy Chase, MD, USA) za vizualizaciju, uređivanje i analizu lidarskoga oblaka točaka.

Kako bi se moglo pristupiti analizi pojedinoga stabla, ona se prvo moraju detektirati iz lidarskoga oblaka točaka, a to se radi u dva bitna koraka. Prvi je izrada digitalnoga modela terena, a drugi je detekcija pojedinačnoga stabla, što uključuje identifikaciju njegove krošnje (Zhang i Qiu 2012). Digitalni model terena (DMT) klasificirane su točke tla, dok sve točke vegetacije zajedno čine digitalni model visine krošnja (DMVK). Visinu stabla predstavlja visinska razlika između DMT i DMVK.


Danas postoje brojni računalni algoritmi koji automatski iz oblaka točaka detektiraju krošnje i označuju visinu stabla. U ovom je radu prikazan manualni način dobivanja visine stabala iz oblaka točaka kako bi se pojasnila i približila tehnologija i metodologija rada s podacima dobivenim laserskim skeniranjem iz zraka.

Analiza vegetacije na području istraživanja provedena je u softveru QTM na temelju prethodno obrađenih i klasificiranih lidarskih podataka. S obzirom na to da je Trg Nikole Šubića Zrinskoga pravilna,


pravokutna oblika i da su stabla u drvoredu, moguća je pojedinačna analiza svakoga stabla. Iz oblaka točaka poligonom su izdvojena pojedinačna stabla odnosno njihove krošnje, i to unaprijed određenim redoslijedom, onim kojim je napravljena i terenska izmjera. Visina svakoga pojedinačnoga stabla određena je, odnosno bila je jednaka visini najviše točke u izdvojenom oblaku točaka (poligonom).

Poligonom je označena i selektirana odabrana krošnja, zatim se u glavnom izborniku softvera QTM odabralo »Analyst« te u padajućem izborniku »Find Highest Point in Area« (slika 4). Novootvoreni prozor daje osim podatka o najvišoj točki (z koordinata) na selektiranom području i mnoge druge informacije poput intenziteta točaka ili broja povrata.

S obzirom na prirodu vegetacije i činjenicu da stabla na mjerenoj plohi nisu iste dobi, odnosno neka su zamijenjena tijekom vremena zbog opasnosti za sigurnost i život građana, do visine mlađih i nižih stabala nije se moglo doći opisanim postupkom jer se prvi (i najviši) povrat zrake odbio od grane višega (starijega) stabla. Alternativan način utvrđivanja visine nižega stabla bila je izrada vertikalnoga profila iz oblaka točaka, iz kojega je vidljiv presjek svih točaka do tla te iz kojega se može jasno razabrati i izmjeriti niže stablo (slika 5).



Slika 4. Poligonom izdvojena krošnja iz oblaka točaka
Fig. 4 Crown separated by polygon from the cloud of points



Slika 5. Vertikalni profil izrađen iz oblaka točaka
Fig. 5 Vertical profile made from the cloud of points

Softver QTM omogućuje izradu profila iz prikupljenih podataka za detaljne analize ili vizualizacije terena. Pomoću alata »Measurement line« označava se

željeno područje na DMT-u ili u oblaku točaka za koje treba izraditi profil, zatim se u padajućem izborniku odabire opcija »Profile Analysis Tool« na temelju koje se

prikazuju sve točke s pripadajućom nadmorskom visinom u zadanim okvirima (duljina i širina obuhvata). Prilikom interpretacije točke se mogu i vizualno razdvojiti tako da se obojaju različitim bojama ovisno o njihovoj visini.

Svaka je visina stabala na zadanom području očitana na dvije decimalne prikazane načinima te je upisana redom očitavanja u *.dbf datoteku uz podatke s terenske izmjere. Za svako je stablo uz podatke o vrsti, opsegu debla, prsnom promjeru te visini izmjerene uređajem Vertex III upisana i ona dobivena očitavanjem iz lidarskoga oblaka točaka.

2.5 Statistička analiza podataka – Statistical Data Analysis

Statistička obrada podataka održana je pomoću softvera Statistica 10.0. Uključivala je izradu osnovne deskriptivne statistike za svaku izmjерu (uređajem Vertex III i očitavanjem iz oblaka točaka), izradu grafikona za prikaz odnosa dobivenih visina, te za provođenje korelacijske analize kojom se ispituje validnost i povezanost podataka dobivenih laserskim skeniranjem iz zraka i terenski izmjereni podataka.


Spajanje svih prikupljenih informacija o pojedinačnom stablu u jedinstvenu bazu podataka omogućio je programski paket ArcGIS 9.3.

3. Rezultati i rasprava – Results and Discussion

Referentne vrijednosti za usporedbu i validaciju laserski prikupljenih podataka dobivene su izlaskom na teren i izmjerom svih stabala na Trgu Nikole Šubića Zrinskoga. Iako je u Katastru zelenila prikazano 149 stabala, odlaskom na teren utvrđilo se kako su tri stabla uklonjena, stoga je terenskom izmjerom obuhvaćeno 146 stabala (od toga 140 hibridnih platana */Platanus × hispanica/* i šest stabala javora mlječa */Acer platanoides L./*). Prosječna izmjerena visina uređajem Vertex III iznosila je 24,0 m s rasponom od 5,60 m za najniže stablo do 36,0 m za najviše izmjereno stablo. Srednji prsnji promjer iznosio je 74 cm s rasponom od 8 cm do 160 cm.

Laserskim skeniranjem iz zraka i obradom prikupljenih podataka dobiven je georeferencirani 3D oblak točaka klasificiran u četiri razreda, kao proizvod obrade sirovih podataka u softveru LAStools te prikazan u softveru QTM za vizualizaciju oblaka točaka (slika 6). Prikupljen broj točaka za analizirano područje iznosi 32 995, a gustoća je prikupljenih točaka 1,03 točke/m². Četiri su izdvojena razreda: neklasificirano (class 1), tlo (class 2), visoka vegetacija (class 5) i zgrade (class 6).

3D oblak točaka omogućuje podroban uvid u snimljeni prostor i sve njegove sastavnice. S obzirom



Slika 6. Trodimenzionalni prikaz klasificiranih točaka Trga Nikole Šubića Zrinskoga

Fig. 6 Three-dimensional representation of classified points of the Square of Nikola Šubić Zrinski

na to da on zadržava stvarne prostorne i visinske odnose objekata u prostoru, već se njegovom vizualnom interpretacijom mogu donijeti osnovni zaključci o promatranom terenu. U slučaju Trga Nikole Šubića Zrinskog jasno je vidljiv prostorni raspored stabala i ostalih objekata u prostoru (glazbeni paviljon), a u odnosu na fotointerpretaciju dvodimenzionalnih tipova podataka (aerofotogrametrijskih i satelitskih snimaka) sa sigurnošću se mogu vidjeti i utvrditi visinski odnosi među stablima, a po potrebi i izdvojiti krošnje svakoga od njih za detaljne analize.

Model je moguće spojiti i s različitim podlogama, često su to karte analiziranoga područja koje omogućuju precizniju interpretaciju ili objašnjavaju određene pojave u samom modelu. Pri izradi ovoga rada koristio se već spomenutī Katastar zelenila Grada Zagreba. Preuzeti prikaz prostornoga rasporeda stabala koji je služio kao predložak za terensku izmjeru georeferenciran je te postavljen kao podloga oblaku točaka. Dobiveni je rezultat izuzetno dobro preklapanje krošnji iz oblaka točaka i njihova prikaza u Katastru (slika 7), što upućuje na primjenjivost lidarskih podataka u podrobnim prostornim raščlambama.

Prilikom očitavanja visine iz oblaka točaka izdvojena su 134 stabla, 12 stabala manje nego terenskom izmjerom (tri stabla za koja se terenskom izmjerom


utvrdilo da nedostaju pronađena su u oblaku točaka) i 15 stabala manje od predviđenoga Katastrom zelenila. Razlozi se za to mogu tražiti u niskoj gustoći oblaka točaka ($1,03 \text{ točka/m}^2$), vremenu leta (ožujak – netom prije početka listanja vegetacije), mogućim pogreškama prilikom leta (različiti prekopi letnih linija) ili u obradi sirovih podataka te promjenama u samom prostoru.

Srednja izmjerena visina stabala iz oblaka točaka iznosi $23,07 \text{ m}$, najniže izmjereno stablo visine je $5,31 \text{ m}$, a najviše $33,34 \text{ m}$. U takvu prikazu podataka može se primijetiti kako su oni, za razliku od terenske izmjere, izraženi na dva decimalna mjesta, dok softver ima mogućnost prikaza i na tri.

Ovdje valja napomenuti da su lidarski podaci iz 2012. godine, a podaci terenske izmjere iz 2017. godine, stoga je očekivano da će se dobivene vrijednosti visine stabala razlikovati.


Pri tome treba imati na umu da većinu mjerениh stabala čine stogodišnje platane, čiji visinski godišnji prirast stagnira. Dakako, nisu sva stabla iste dobi, te na plohi postoje i mlađa stabla s većim i izraženijim godišnjim prirastom, koji će se vidjeti u usporedbi dobivenih podataka.

Usporedba visine dobivene terenskom izmjerom (Vertex III) i iz lidarskih podataka (3D oblak točaka)



Slika 7. Prikaz oblaka točaka s Katastrom zelenila kao podlogom

Fig. 7 Display of cloud of points with Greenery Cadastre as background



Slika 8. Usporedba visine za svako stablo izmjerena uređajem Vertex III i iščitana iz lidarskoga oblaka točaka: a) po oznaci stabla; b) po prsnom promjeru

Fig. 8 Height measured with Vertex III device vs. height read from LiDAR cloud of points for each tree: a) by tree marking; b) by DBH

na razini svakoga stabla prikazana je na slici 8a, a na slici 8b prikazani su usporedni podaci o visini prema prsnom promjeru.


Kao što je potvrđeno i deskriptivnom statistikom, visina očitana iz oblaka točaka dobivenih laserskim skeniranjem iz zraka nešto je manja od one s terenske izmjere. Može se primjetiti kako linija lidarski dobivenih visina dosta vjerno prati onu s referentnim visina-

ma izmjerenim terenskom izmjerom, što je dobar pokazatelj vjerodostojnosti dobivenih podataka iz oblaka točaka. Razlika u visini između dviju izmjera predstavlja djelomično i višegodišnji visinski prirast koji zbog različite dobi, položaja i vitalnosti stabala na plohi nije ujednačen među svim jedinkama. Također, jedan od uzroka podcenjivanju lidarski izmerene visine u odnosu na terenski izmjerenu jest relativno

mala gustoća oblaka točaka. Zbog toga je vrlo vjerojatno da svakomu stablu nije detektiran sam vrh stabla, tj. da laserska zraka nije »pogodila« vrh stabla, nego dio krošnje pored vrha (Balenović i dr. 2013). Prema Andersenu i dr. (2006) minimalna je gustoća točaka za točnu determinaciju vrhova pojedinačnih stabala 4–5 točaka/m². Osim relativno male gustoće snimanja otežavajući je čimbenik pri određivanju vrhova stabala u ovom radu i vrijeme snimanja, koje je provedeno u ožujku, tj. na samom početku vegetacije, kada se lisna površina krošnje još nije razvila.

U slučajevima kada se precijeni visina, tj. kada je visina dobivena iz oblaka točaka značajnije veća od visine dobivene terenskom izmjerom istoga stabla, mogući su razlozi pogreške pri detekciji i ekstrakciji krošnje iz sklopa u softveru QTM ili pogreške prilikom same terenske izmjere. Spomenuto je kako postoje brojni računalni algoritmi koji se koriste kod ekstrakcije krošnja iz laserski prikupljenih podataka i time smanjuju mogućnost grešaka. Budući da se radilo manualno na modelu vegetacije s niskom gustoćom točaka, a na terenu u bučnom okruženju središta grada, što je stvaralo poteškoće prilikom terenske izmjere (uređaj Vertex III koristi se ultrazvučnim valovima i mjeri vrijeme potrebno signalu da priđe udaljenost od uređaja do transpondera i natrag), nastale razlike u pojedinačnim izmjerama nisu dovoljne kako bi se na temelju njih odbacila točnost i primjenjivost lidarskih podataka u analizi vegetacije urbanih područja.

Tomu u prilog ide izračunati koeficijent korelacije između terenske izmjere i podataka o visini dobivenih očitavanjem iz lidarskoga oblaka točaka, koji pokazuje i statistički značajan stupanj povezanosti tih dviju varijabli (slika 9). Grafički uspoređeni podaci u dijagramu raspršenosti o visini prikazuju linearnu povezanost izmjera, no promatrane distribucije izmjerene visine stabala za svaki instrument ne prate normalnu (Gaussovu) distribuciju. S obzirom na nepostojanje normalne distribucije podataka Artusi i dr. (2002) preporučuju primjenu Spearanova koeficijenta korelacije, kod kojega nije uvjet da podaci budu normalno distribuirani. Prilikom računanja korelacije u izračun su uvrštena samo ona stabla za koja postoje obje izmjere ($N = 131$). Dobiveni koeficijent korelacije iznosi $r_s = 0,91$, koeficijent determinacije $R^2 = 0,83$, dok je $p = 0,000$ ($p < 0,05$), što potvrđuje statističku značajnost dobivene korelacije. U većini objavljene literature, u kojoj se uspoređuju lidarske i terenske izmjere stabala, R^2 iznosi između 0,76 i 0,98 (Falkowski i dr. 2006, Heurich i dr. 2008, O'Beirne 2012). S obzirom na taj podatak ova se korelacija može svrstati među srednje jake povezanosti, ali treba imati na umu da je između dviju prikazanih izmjera petogodišnje vegetacijsko razdoblje. Statistička



Slika 9. Usporedba povezanosti visine izmjerene uređajem Vertex III i iščitane iz lidarskoga oblaka točaka

Fig. 9 Correlation of height measured with the Vertex III device and read from the LiDAR cloud of points

analiza korelacijske potvrđuje tezu da razlike u pojedinačnim izmjerama nisu dovoljne kako bi se odbacila primjenjivost lidarskih podataka.

Sve prikazano može potvrditi kako su podaci o stablima dobiveni laserskim skeniranjem iz zraka upotrebljivi u analizama urbane vegetacije. Statistička je analiza pokazala značajnu korelaciju između dviju izmjera, dok je grafički prikaz pokazao kako se lidarski podaci mogu koristiti i za prostorne analize odnosa među stablima s obzirom na to da linija lidarskih očitanja vjerno prati onu terenske izmjere, a razlika srednjih vrijednosti između izmjera samo je 1 m.

Prednost upotrebe laserski dobivenih podataka u analizi urbane vegetacije nije isključivo u mogućnosti točne izmjere stabala, koja je ovdje samo dana kao primjer upotrebe, ona se očituje u vizualizaciji prostora i odnosa vegetativnih elemenata u njemu, u mnogobrojnim raščlambama koje se mogu obaviti iz dobivenih podataka, od podrobnih strukturnih analiza urbanih šuma do izračuna vrijednosti općekorisnih funkcija koje pruža urbana vegetacija, te u velikom obuhvatu prostora koji se zahvaća prilikom leta, što smanjuje intenzitet terenskoga rada. Pri tome je jako važno uspješno izdvajanje pojedinačnih stabala razlučivanjem u oblaku točaka, tj. objedinjavanje točaka krošnje pripadajućemu stablu. Naravno, sve ovisi o kakvoći lidarskih podataka (gustoći, vremenu snimanja).

4. Zaključci – Conclusions

U radu je podrobno prikazan postupak obrade lidarskih podataka dobivenih zračnim laserskim skeniranjem te istražene neke od mogućnosti njihove primjene u analizi vegetacije urbanih područja. Osim relativno niske gustoće snimanja ($1,03 \text{ točaka/m}^2$) i vremena snimanja (rano proljeće, netom prije početka vegetacije), glavni ograničavajući čimbenik u radu bio je vremenski razmak između prikupljanja lidarskih i terenskih podataka. Unatoč tomu statističkom usporedbom lidarskih podataka o visini stabala s referentnom terenskom izmjerom istih stabala dobivena je statistički značajna korelacija $r_s = 0,91$, čime je potvrđena validnost i upotrebljivost lidarskih podataka pri izmjeru i praćenju urbanih stabala. Kako bi se utvrdile stvarne mogućnosti lidarske tehnologije u analizi vegetacije urbanih područja, potrebno je provesti daljnja kompleksnija istraživanja u kojima će se vrijeme prikupljanja lidarskih i terenskih podataka podudarati.

5. Literatura – References

- Alonzo, M., B. Bookhagen, D. Roberts, 2014: Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sensing of Environment*, 148: 70–83.
- Alonzo, M., B. Bookhagen, J. McFadden, A. Sun, D. Roberts, 2015: Mapping urban forest leaf area index using penetration metrics and allometry. *Remote Sensing of Environment*, 162: 141–153.
- Alonzo, M., J. McFadden, D. Nowak, D. Roberts, 2016: Mapping urban forest structure and function using hyperspectral imagery and lidar data. *Urban Forestry & Urban Greening*, 17: 135–147.
- Andersen, H-E., S. E. Reutebuch, R. J. McGaughey, 2006: A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. *Canadian Journal of Remote Sensing*, 32(5): 355–366.
- Artusi, R., P. Verderio, E. Marubini, 2002: Bravais-Pearson and Spearman correlation coefficients: meaning, test of hypothesis and confidence interval. *The International Journal of Biological Markers*, 17(2): 148–151.
- Balenović, I., G. Alberti, H. Marjanović, 2013: Airborne Laser Scanning – the Status and Perspectives for the Application in the South-East European Forestry. *South-east European forestry*, 4(2): 59–79.
- Baltsavias, E. P., 1999: A comparison between photogrammetry and laser scanning. *Journal of Photogrammetry & Remote Sensing*, 54(2–3): 89–94.
- Benko, M., I. Balenović, 2011: Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj. *Šumarski list* 135(13): 272–281.
- Berta, A., 2017: Procjena šumske biomase pomoću lidar tehnologije u degradiranim šumama brežuljkastog i nizinskog vegetacijskog pojasa u središnjoj Hrvatskoj. Disertacija, Šumarski fakultet, Zagreb.
- Bojanic Obad Šćitaroci, B., M. Obad Šćitaroci, 2004: Gradske perivoje Hrvatske u 19. stoljeću: javna perivojna arhitektura hrvatskih gradova u europskom kontekstu. Šćitaroci, Zagreb, 264 str.
- Božić, A., 2016: Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukove prašume Medvjedak. Diplomski rad, Šumarski fakultet, Zagreb.
- Chen, Z., B. Devereux, B. Gao, G. Amable, 2012: Upward-fusion urban DTM generating method using airborne Lidar data. *Journal of Photogrammetry and Remote Sensing*, 72: 121–130.
- Falkowski, M. J., A. M. S. Smith, A. T. Hudak, P. E. Gessler, L. A. Vierling, N. L. Crookston, 2006: Automated estimation of individual conifer tree height and crown diameter via two-dimensional spatial wavelet analysis of lidar data. *Canadian Journal of Remote Sensing*, 32(2): 153–161.
- Gajski, D., 2007: Osnove laserskog skeniranja iz zraka. Ekscentar, 10: 16–22.
- Garcia, M., D. Riaño, E. Chuvieco, M. Danson, 2010: Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sensing of Environment*, 114(4): 816–830.
- Hecht, R., G. Meinel, M. F. Buchroithner, 2008: Estimation of Urban Green Volume Based on Single-Pulse LiDAR Data. *IEEE Transactions on Geoscience and Remote Sensing*, 46(11): 3832–3840.
- Heurich, M., 2008 Automatic recognition and measurement of single trees based on data from airborne laser scanning over the richly structured natural forests of the Bavarian Forest National Park. *Forest Ecology and Management*, 255(7): 2416–2433.
- Holopainen, M., V. Kankare, M. Väistärinta, X. Liang, Y. Lin, M. Vaaja, X. Yu, J. Hyppä, H. Hyppä, H. Kaartinen, A. Kukko, T. Tanhuapää, P. Alho, 2013: Tree mapping using airborne, terrestrial and mobile laser scanning – A case study in a heterogeneous urban forest. *Urban Forestry & Urban Greening*, 12(4): 546–553.
- Hopkinson, C., J. Lovell, L. Chasmer, D. Jupp, N. Kljun, E. van Gorsel, 2013: Integrating terrestrial and airborne lidar to calibrate a 3D canopy model of effective leaf area index. *Remote Sensing of Environment*, 136: 301–314.
- Ivšić, L., B. Pribičević, A. Đapo, B. Kordić, L. Babić, M. Govorčin, 2016: Klasifikacija LiDAR podataka na području urbanog jezera Jarun i analiza kvalitete podataka. Ekscentar, 19: 98–103.
- Kim, S., R. J. McGaughey, H. Andersen, G. Schreuder, 2009: Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. *Remote Sensing of Environment*, 113(8): 1575–1586.

- Klinberg, J., J. Konarska, F. Lindberg, L. Johansson, S. Thorsson, 2017: Mapping leaf area of urban greenery using aerial LiDAR and ground-based measurements in Gothenburg, Sweden. *Urban Forestry & Urban Greening*, 26: 31–40.
- Kwak, D. A., W. K. Lee, J. H. Lee, G. S. Biging, P. Gong, 2007: Detection of individual trees and estimation of tree height using LiDAR data. *Journal of Forest Research*, 12(6): 425–434.
- Lin, Y., G. West, 2016: Retrieval of effective leaf area index (LAIe) and leaf area density (LAD) profile at individual tree level using high density multi-return airborne LiDAR. *International Journal of Applied Earth Observation and Geoinformation*, 50: 150–158.
- Liu, L., N. C. Coops, N. W. Aven, Y. Pang, 2017: Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. *Remote Sensing of Environment*, 200: 170–182.
- McPherson, E. G., 2006: Urban Forestry in North America. *Renewable Resources Journal*, 24(3): 8–12.
- Nowak, D. J., D. E. Crane, J. C. Stevens, R. E. Hoehn, J. T. Walton, J. Bond, 2008: A Ground Based Method of Assessing Urban Forest Structure and Ecosystem Services. *Arboriculture & Urban Forestry*, 34(6): 347–358.
- O'Beirne, D., 2012: Measuring the Urban Forest: Comparing LiDAR Derived Tree Heights to Field Measurements. Diplomski rad, San Francisco State University.
- Petrie, G., C. K. Toth, 2009: Airborne and Spaceborne Laser Profilers and Scanners. *Topographic Laser Ranging and Scanning: Principles and Processing*, CRC Press, 31–34.
- Wehr, A., U. Lohr, 1999: Airborne laser scanning – an introduction and overview. *Journal of Photogrammetry and Remote Sensing*, 54(2): 68–82.
- Zhang, C., F. Qiu, 2012: Mapping Individual Tree Species in an Urban Forest Using Airborne Lidar Data and Hyperspectral Imagery. *Photogrammetric Engineering & Remote Sensing*, 78(10): 1079–1087.
- Žmegač, A., 2015: Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukovo-jelove prašume Čorkova uvala – Čudinka. Diplomski rad, Šumarski fakultet, Zagreb.
- URL 1: <https://gis.zrinjevac.hr/>, 25.09.2017.

Abstract

Comparison of Lidar and Field Data Survey in Measuring Tree Height in Urban Areas

This paper shows a procedure of processing Light Detection and Ranging (LiDAR) data collected by airborne laser scanning (ALS) for the urban vegetation area of Zagreb (Nikola Šubić Zrinski Square). Furthermore, the comparison between tree heights obtained from LiDAR data and field survey was conducted. For each tree in the research area, tree species was determined and tree height (m) was measured by using ultrasonic Vertex III hypsometer. Field survey included 146 trees (out of which 140 were Platanus x hispanica and 6 were Acer platanoides L. trees). The average height was 24.0 m, ranging between 5.60 m and 36.0 m. Average diameter at breast height was 74 cm, ranging between 8 cm and 160 cm. From raw LiDAR data, a georeferenced point cloud was obtained and classified into 4 categories using LAStools software, while QTM software was used for visualization. In total, 134 trees were extracted from classified point clouds. The average tree height measured from the point cloud was 23.07 m, while the minimum and maximum tree heights were 5.31 m and 33.34 m, respectively. Statistical analysis and comparison between LiDAR and field data confirmed high (correlation coefficient $r_s = 0.91$; coefficient of determination $R^2 = 0.83$) and statistically significant correlation ($p = 0.000$) indicating the great potential of LiDAR data for measuring and monitoring urban vegetation.

Keywords: LiDAR, 3D point cloud, tree height, urban forests

Adrese autorâ – *Authors' addresses:*

Izv. prof. dr. sc. Ante Seletković *

e-pošta: aseletkovic@sumfak.hr

Prof. dr. sc. Renata Pernar

e-pošta: rpernar@sumfak.hr

Doc. dr. sc. Mario Ančić

e-pošta: mancic@sumfak.hr

Dr. sc. Jelena Kolić

e-pošta: jkolic@sumfak.hr

Zavod za izmjerenje i uređivanje šuma

Šumarski fakultet Sveučilišta u Zagrebu

Svetosimunska 25

10 000 Zagreb

HRVATSKA

Martina Kičić, mag. ing. silv.

e-pošta: martina.kicic@gmail.com

Grička 8, Sesvete

10360 Zagreb

HRVATSKA

Dr. sc. Alen Berta

e-pošta: aberta@oikon.hr

Oikon d.o.o. – Institut za primijenjenu ekologiju

Trg senjskih uskoka 1–2

10020 Zagreb

HRVATSKA

Dr. sc. Ivan Balenović

e-pošta: ivanb@sumins.hr

Zavod za uređivanje šuma i šumarsku ekonomiku

Hrvatski šumarski institut

Trnjanska cesta 35

10 000 Zagreb

HRVATSKA

* Glavni autor – *Corresponding author*

Primljeno (*Received*): 28. 8. 2017.

Prihvaćeno (*Accepted*): 15. 9. 2017.