Upotreba lidarskih podataka pri praćenju vegetacije urbanih područja

Kičić, Martina

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Forestry / Sveučilište u Zagrebu, Šumarski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:108:764295

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ŠUMARSKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ

URBANO ŠUMARSTVO, ZAŠTITA PRIRODE I OKOLIŠA

MARTINA KIČIĆ

UPOTREBA LIDARSKIH PODATAKA PRI PRAĆENJU VEGETACIJE URBANIH PODRUČJA

DIPLOMSKI RAD

ZAGREB, 2017.

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ŠUMARSKI ODSJEK

UPOTREBA LIDARSKIH PODATAKA PRI PRAĆENJU VEGETACIJE URBANIH PODRUČJA

DIPLOMSKI RAD

Diplomski studij: Urbano šumarstvo, zaštita prirode i okoliša

Predmet: Analiza i valorizacija prostora

Ispitno povjerenstvo:
1. Izv. prof. dr. sc. Ante Seletković
2. Prof. dr. sc. Renata Pernar
3. Doc. dr. sc. Mario Ančić

Student: Martina Kičić
JMBAG: 0068219478
Broj indeksa: 702/2015
Datum odobrenja teme: 20.04.2017.
Datum predaje rada: 12.09.2017.
Datum obrane rada: 22.09.2017.

Zagreb, 2017.

Dokumentacijska kartica

Naslov	**Upotreba lidarskih podataka pri praćenju vegetacije urbanih područja**
Title	**Using lidar data for monitoring vegetation in urban areas**
Autor	**Martina Kičić**
Adresa autora	**Grička 8, Sesvete**
Mjesto izrade	**Zagreb**
Vrsta objave	**Diplomski rad**
Mentor	**Izv. prof. dr. sc. Ante Seletković**
Izradu rada pomogao	**Doc. dr. sc. Mario Ančić**
Godina objave	**2017.**
Obujam	**34 str., 11 slika, 2 grafa + 41 navoda literature**
Ključne riječi	**Daljinska istraživanja, LiDAR, Zrinjevac, 3D oblak točaka, izmjera visina, GIS**
Key words	**Remote sensing, LiDAR, Zrinjevac, 3D point cloud, height measurement, GIS**
Sažetak	U ovom radu prikazan je način prikupljanja, obrade, analize i interpretacije podataka o urbanoj vegetaciji dobivenih laserskim skeniranjem iz zraka na primjeru Trga Nikole Šubića Zrinskoga u Zagrebu. Cilj ovog diplomskog rada je na temelju podataka dobivenih laserskim skeniranjem iz zraka, prikazati obradu 3D oblaka točaka, klasifikaciju, vizualizaciju i različite načine i mogućnosti uporabe takvih podataka pri praćenju i izmjeri vegetacije urbanih područja. Laserskim skeniranjem iz zraka i obradom prikupljenih podataka dobiven je georeferencirani 3D oblak točaka klasificiran u 4 klase. Dobiveni rezultati obuhvaćaju prikaz oblaka klasificiranih točaka u tri dimenzije koje zadržavaju sve svoje prostorne informacije (x, y, z koordinatu), statističku usporedbu i grafički prikaz podataka dobivenih terenskom izmjerom i laserskim skeniranjem iz zraka te uspostavu GIS baze podataka. Srednja vrijednost visina izmjerenih na terenu iznosi 24,02 m, a ona dobivena iz oblaka točaka 23,0 m. Statistička i grafička obrada su pokazale snažnu povezanost podataka. Koeficijent korelacije između dvije izmjere statistički je značajan i iznosi r_s=0,91. LiDAR tehnologija bazirana na laserskom skeniranju s tla ili iz zraka pokazuje se kao široko primjenjiva tehnologija koja svoju upotrebu pronalazi i u analizama vegetacije urbanih područja gdje omogućava dobivanje podataka koji nadopunjuju standardne metode fotointerpretacije.

This paper describes methods used for gathering, processing, analysis and interpretation of data on urban vegetation gained by laser scanning from the air, based on the example from Nikola Šubić Zrinski square in Zagreb. The goal of this thesis was to show processing of 3D point cloud data, classification, visualization and different methods and possibilities for implementing such data in measuring and monitoring vegetation in urban areas, based on the laser scanning from the air. Laser scanning from the air and analysis of gathered data resulted in georeferenced 3D point cloud, classified into 4 classes. Obtained results include the demonstration of classified point cloud data in three dimensions, keeping all the spatial information (x, y, z coordinates), statistical comparison and graphical display of data obtained from the field measuring and laser scanning from the air, and formation of GIS database. Average tree height form field measurements equated to 24,02 meters, while the average height obtained from the point cloud equated to 23,0 meters. Statistical and graphical analysis demonstrated strong correlation between data. Correlation coefficient between two measuring was statistically significant and equated to r_S=0,91. LiDAR technology, based on laser scanning from the air or from the ground, proved to be widely applicable technology that also finds usage in urban areas vegetation analysis where it enables data gathering which complements with standard photointerpretation methods.

	IZJAVA **O IZVORNOSTI RADA**	**OB ŠF 05 07**
		Revizija: 1
		Datum: 28.6.2017.

„Izjavljujem da je moj *diplomski rad* izvorni rezultat mojega rada te da se u izradi istoga nisam *koristila* drugim izvorima osim onih koji su u njemu navedeni“.

_____

vlastoručni potpis

Martina Kičić

U Zagrebu, *22.09.2017.*

SADRŽAJ

POPIS SLIKA ii
POPIS GRAFOVA iii
1. UVOD 1
1.1. POVIJESNI RAZVOJ LiDAR TEHNOLOGIJE 2
1.2. LiDAR 4
1.2.1. LASERSKO SKENIRANJE SA ZEMLJE 5
1.2.2. LASERSKO SKENIRANJE IZ ZRAKA 7
2. CILJ I PODRUČJE ISTRAŽIVANJA 13
2.1. TRG NIKOLE ŠUBIĆA ZRINSKOG 13
3. MATERIJAL I METODE RADA 15
3.1. PODACI PRIKUPLJENI LiDAR-OM 15
3.2. PRIKUPLJANJE TERENSKIH PODATAKA 16
3.3. OBRADA PODATAKA 18
4. REZULTATI RADA 23
5. ZAKLJUČAK 30
6. LITERATURA 31

POPIS SLIKA

Slika 1 - Prikaz raznih povrata pojedine LiDAR zrake (Ivšić i sur., 2016) 8
Slika 2 - Način rada LiDAR sustava (Berta, 2017) 9
Slika 3 - Lenucijeva potkova s označenim Trgom Nikole Šubića Zrinskoga 13
Slika 4 - Vertex III visinomjer/daljinomjer (Lukić i sur.,2005) 16
Slika 5 – Trg Nikole Šubića Zrinskog s odbrojčanim stablima za izmjeru na terenu 17
Slika 6 – Prikaz izdvojenog oblaka točaka u QTM softveru 19
Slika 7 - Poligonom izdvojena krošnja iz oblaka točaka 21
Slika 8 - Izrađen profil iz oblaka točaka 22
Slika 9 – Trodimenzionalni prikaz klasificiranih točaka Trga Nikole Šubića Zrinskog 24
Slika 10 – Prikaz oblaka točaka s Katastrom zelenila kao podlogom 24
Slika 11 - Jedinstvena GIS baza podataka istraživanog područja 29

POPIS GRAFOVA

Graf 1 - Usporedba visina za svako stablo izmjerenih Vertex III uređajem i iščitanih iz LiDAR oblaka točaka 26
Graf 2 - Usporedba povezanosti visina izmjerenih Vertex III uređajem i iščitanih iz LiDAR oblaka točaka 28

1. UVOD

Urbana vegetacija, naročito drveće, nudi mnoge pogodnosti koje mogu poboljšati kvalitetu okoliša i zdravlje građana u i oko gradskih područja (Nowak, 2008). Urbane šume omogućavaju i pružaju mnoge prednosti kao što su štednja energije, poboljšanje upravljanja vodama, smanjenje onečišćenja zraka i povezivanje urbanih stanovnika s prirodom (McPherson, 2006).

Kako bi se što više mogle koristiti te pogodnosti potrebno je provoditi inventuru urbane vegetacije u svrhu kvalitetnijeg planiranja i upravljanja njome. Osnovne informacije koje sadrži takva inventura uključuju: broj pojedinačnih stabala, njihove vrste, prostorni raspored i zdravstveno stanje. Tradicionalno se takvi podaci prikupljaju terenskom izmjerom koja je skupa, fizički zahtjevna i oduzima mnogo vremena. Dodatno, terenske se izmjere mogu provoditi samo na područjima koja su dostupna za izmjeru, malo ili ništa podataka se može prikupiti s privatnih posjeda i ostalih nepristupačnih područja. Daljinska istraživanja su stoga postala primamljiva alternativa terenskim izmjerama u inventuri vegetacije zbog ukupnog manjeg troška izmjere, veće obuhvaćene površine i redovitog ciklusa prikupljanja podataka (Zhang i Qiu, 2012). Iako se u uporabi mogu naći različite vrste senzora kojima se prikupljaju informacije o šumskoj vegetaciji, LiDAR tehnologija se u zadnje vrijeme sve više koristi za pridobivanje podataka o šumskoj površini budući da može pružiti veoma točne informacije o obliku promatranog objekta uz pomoć georeferenciranih 3D točaka (Kwak i sur., 2007).

Mogućnosti LiDAR tehnologije prepoznate su u svijetu te se ona počinje intenzivnije istraživati početkom 21. stoljeća. Od tada se može pratiti sve veći broj objavljenih znanstvenih radova na temu njene primjene u brojnim sferama koji i dalje raste što je dokaz njene relevantnosti i svestranosti.

Brojni svjetski znanstvenici u svojim istraživanjima ispituju mogućnosti LiDAR tehnologije u kompleksnom urbanom prostoru. Kada se pritom analizira urbana vegetacija onda se može pronaći nekoliko glavnih interesnih skupina: generiranje jako preciznih digitalnih modela terena (Chen i sur., 2012); određivanje volumena zelenila (Hecht i sur., 2008); procjene gustoće vegetacije (engl. *Leaf Area Index* – LAI) (Hopkinson i sur, 2013; Alonzo i sur., 2015; Lin i West, 2016; Klinberg i sur., 2017); determinacija i kartiranje pojedinačnog stabla (Kim i sur. 2009, Holopainen i sur., 2013) te se u posljednje vrijeme sve više LiDAR tehnologija spaja s hiperspektralnim snimkama kako bi se omogućila i ispitala preciznija determinacija drvenaste

vrste ovom metodom daljinskih istraživanja (Zhang i Qiu, 2012; Alonzo i sur., 2014; Alonzo i sur., 2016; Liu i sur., 2017).

Pregled hrvatske literature na temu LiDAR tehnologije te njene primjene u šumarstvu donosi relativno mali broj radova. Gajski (2007) prvi daje definiciju i obrađuje osnove laserskog skeniranja iz zraka, Benko i Balenović (2011) predstavljaju je na primjeru istraživanja provedenih u svijetu kao budućnost daljinskih istraživanja i inventure šuma u Hrvatskoj, potom Balenović i sur. (2013) u zasebnom radu detaljno prikazaju principe rada i potencijal LiDAR tehnologije u šumarstvu jugoistočne Europe. Žmegač (2015) i Božić (2016) u svojim radovima analiziraju dinamiku prašuma uz pomoć LiDAR-skih snimki, a Berta (2017) svoju doktorsku disertaciju brani na temu upotrebe LiDAR tehnologije za procjenu šumske biomase u degradiranim šumama brežuljkastoga i nizinskoga vegetacijskogapojasa.

U Hrvatskoj se još nije obrađivala tematika primjene LiDAR tehnologije u urbanom šumarstvu stoga je ovaj rad prvi koji će analizirati mogućnosti obrade i primjene snimaka dobivenih laserskim skeniranjem iz zraka u izmjeri i interpretaciji vegetacije urbanih prostora.

1.1. POVIJESNI RAZVOJ LiDAR TEHNOLOGIJE

Prema Wehr i Lohr (1999) LiDAR je akronim za engl. *LIght Detection And Ranging* iako je svojevremeno postojala tendencija uvođenja pojma LADAR, odnosno akronima za engl. *LAser Detection And Ranging* kako bi se naglasila primjena lasera.

Laser (engl. *Light Amplification by Stimulated Emission of Radiation*) je uređaj za stvaranje i pojačavanje koherentnog, elektromagnetskog, najčešće monokromatskog, usko usmjerenog zračenja.

Prvi laseri u svijetu konstruiraju se 60-tih godina 20. stoljeća. Nedugo nakon prvih konstruiranih lasera počinje njihova uporaba za mjerenje udaljenosti, ponajviše u avijaciji. Nelson (2013) navodi kako se lasersko snimanje iz zraka prvi put spominje 1964. godine na simpoziju održanom na Sveučilištu u Michiganu gdje su Rempel i Parker iznijeli da su složili i testirali plinski He-Ne laser spojen s barometrom kako bi se ustanovila visina letjelice i fotogrametrijskom kamerom kako bi njime snimili avionske piste jer radari nisu imali zadovoljavajuću preciznost. Već je tada uočena potencijalna široka primjena laserskog snimanja iz zraka (uz naravno, poboljšanje sustava) za brojne namjene, među njima i mogućnost primjene laserskog snimanja za određivanje visina stabala u šumi s velikom

preciznošću. Petrie i Toth (2009) spominju kako su 1965. godine Jensen i Ruddock razvili funkcionalni laserski profiler namijenjen za komercijalna topografska kartiranja. Spomenuti laserski sustavi funkcionirali su s plinskim He-Ne laserima s kontinuiranim zračenjem (engl. CW – *Continuous Wave*) koji su radili na frekvenciji od 0,633μm, a izlazni signal se mogao emitirati istovremeno na tri frekvencije – 1, 5 i 25 MHz.

Daljnim razvojem i unaprjeđivanjem tehnologije lasera sredinom 70-tih godina 20.st. razvio se Nd:YAG laser s krutom jezgrom postavivši temelje sadašnjeg laserskog skreniranja. Nd:YAG laser pripada impulsnim laserima koji se danas najčešće primjenjuju u laserskim snimanjima iz zraka zbog veće snage odaslanog impulsa (Wehr i Lohr, 1999). Razvojem novog laserskog sustava započinje i njegova šira primjena. Rani razvoj tehnologije s novom vrstom lasera pripisuje se NASA-i i brojnim pokušajima znanstvenika i istraživača u SAD-u i Kanadi koji su vršili razna hidrografska i batimetrijska istraživanja.

Kasnih 80-tih godina 20.st. upotreba GPS (engl. *Global Positioning System*) tehnologije postala je komercijalna i dostupna svima. Komponiranje GPS-a u sustav laserskog snimanja iz zraka omogućilo je rješavanje problema točnosti mjesta snimanja koje je do tada predstavljalo veliku zapreku u daljnjem razvoju tehnologije. Nakon toga slijede brojna istraživanja na Sveučilištu u Stuttgartu s laserskim profilerima u periodu 1988. – 1993. kojima se potvrđuje veliki potencijal geometrijske točnosti te se zadovoljavaju svi parametri za razvoj pravog sustava skeniranja Zemljine površine iz zraka što se i događa u nekoliko narednih godina (Ackermann, 1999). Razvoj laserskog skeniranja iz zraka potaknuo je razvoj tehnologije. Ono je u potpunosti postalo moguće korištenjem impulsnih lasera koji emitiraju svjetlost u bliskom IC-području kojoj se jasno mogao očitati povratni signal nakon difuzije i refleksije s tla. Precizno kinetičko pozicioniranje platforme omogućio je integrirani GPS i IMU (engl. *Inertial Measurement Unit*) sustav pri kojem GPS ima globalnu, a inercijalni mjerni instrumenti lokalnu točnost. Jednom kada je razvijen prihvatljiv mehanizam skeniranja, dizajnirani su i napravljeni prvi skeneri za laserska skeniranja iz zraka te su se ubrzo počeli koristiti za visinsku izmjeru velikih površina terena.

1999. godine „Journal od Photogrammetry & Remote Sensing“ objavljuje poseban broj posvećen tehnologiji laserskog skeniranja iz zraka što je imalo pozitivan utjecaj na daljnji razvoj LiDAR tehnologije, kako u znanstvenom, tako i u tehnološkom smislu (Yan i sur., 2015).

1.2. LiDAR

LiDAR je potpuno automatiziran, aktivan, optičko-mehanički postupak prikupljanja prostornih podataka dostupnih s aktualnih snimališta (Gajski, 2007).

Jedna od glavnih karakteristika LiDAR sustava je njihova mogućnost prikupljanja velikog broja visoko točnih trodimenzionalnih prostornih podataka velikih područja u razmjerno kratkom vremenskom periodu. LiDAR sustavi se temelje na laserskom skeniranju koje mjeri udaljenost između skenera i objekta izmjere, a ona se računa pomoću brzine svjetlosti i vremena potrebnog da emitirano lasersko zračenje dođe do objekta. (Baltsavias, 1999).

Jedna od prednosti LiDAR sustava je njegova iznimna preciznost koja se ogleda u činjenici da se prilikom laserskog 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.

Razvojem i pojavom LiDAR sustava metode daljinskih istraživanja su se promijenile. Razvoj metodologije i tehnologije snimanja pomoću laserskih sustava omogućilo je pristup do tada nepristupačnim terenima. Jedna od posebnosti zračnog laserskog skeniranja je činjenica da skener jednako dobro bilježi podatke na otvorenim terenima kao i terene prekrivene raznom vegetacijom što najbolje prikazuje njegovu mogućnost široke uporabe. Već 1999. Ackermann predviđa kako će se tada nova tehnologija laserskog snimanja iz zraka samo dalje širiti i pronalaziti svoju uporabu u brojnim strukama od šumarstva do prostornog planiranja.

LiDAR je aktivni sustav koji je neovisan o danjem svjetlu, ali zato zahtjeva čistu atmosferu prilikom vršenja skeniranja (bez smoga ili magle koji bi onemogućili ili produljili vrijeme skeniranja). Uz to, laser se ne može koristiti za kišnoga vremena jer većina emitiranog zračenja ne može prodrijeti kroz vodu.

U ovisnosti o platformi koja nosi skener, tehnologija laserskog skeniranja može se podijeliti na (Petrie i Toth, 2009; Balenović i sur., 2013; Berta, 2017):

a) Lasersko skeniranje sa zemlje (engl. *Terrestrial Laser Scanning* - TLS)
b) Lasersko skeniranje iz zraka (engl. *Airborne Laser Scanning* - ALS)
c) Lasersko skeniranje iz svemira (engl. *Spaceborne Laser Scanning* - SLS)

Od navedenih najčešće se u uporabi nalazi lasersko snimanje iz zraka (ALS) pri kojem su avion ili helikopter platforme koje nose skener. Lasersko skeniranje iz zraka omogućava 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. Unatoč tome što je princip određivanja koordinata mjerenih točaka kod oba sustava identičan, oni se razlikuju po svojoj tehnologiji pa će se svaki sustav zasebno prikazati s naglaskom na laserskim skeniranjima iz zraka.

1.2.1. LASERSKO SKENIRANJE SA ZEMLJE

Za razliku od skenera za snimanje iz zraka, razvoj terestričkih laserskih skenera tekao je razmjerno sporo. Trebalo je dosta vremena kako bi se tehnologija laserskog snimanja sa zemlje razvila te postala općeprihvaćena u (geo)industriji. Danas je ta tehnologija primjenjiva i korištena u brojnim strukama pogotovo onima koji teže dobivanju detaljnih digitalnih snimaka velikih objekata, ali i područja manjeg i srednjeg protezanja. Primarno je u uporabi za brzo prikupljanje trodimenzionalnih informacija o brojnim topografskim i industrijskim objektima. Kulturna dobra, mostovi, autoceste, litice uz more, automobili i još mnogo toga se može točno dokumentirati i modelirati koristeći lasersku tehnologiju.

Terestrički laserski skeneri su beskontakntni mjerni uređaji koji prikupljaju guste oblake točaka snimljenog objekta. Svaka točka sadržava x, y, z koordinatu, boju u RGB modelu boja te intenzitet refleksije.

Princip rada je veoma sličan klasičnim geodetskim instrumentima s laserom koji se upotrebljavaju već dulji niz godina. Laserska zraka odaslana iz mjernog instrumenta se reflektira od objekta snimanja i vraća natrag do mjernog instrumenta. Kombinacija izmjerene udaljenosti i kuta s određenog stajališta daje koordinate tražene točke u 3D prostoru. Razlika između ove nove tehnologije i klasičnog mjerenja laserskom zrakom je u brzini izvođenja mjerenja te preciznosti (Miler i sur., 2007).

Prilikom snimanja laser emitira koherentno i monokromatsko elektromagnetsko zračenje. Laserske zrake odaslane su veoma direktno i s mnogo snage, prolaze određenu udaljenost te se reflektiraju od mjerenog objekta natrag do uređaja. Reflektirano zračenje koje senzor bilježi ovisi o reflektivnim karakteristikama površine snimljenog objekta. Matematički se to može prikazati kao koeficijent refleksije koji je omjer reflektirane i odaslane energije. Koeficijent refleksije glatkih i svijetlih površine iznosi između 70% i 100%, dok kod grubih i tamnih površina koeficijent pada na svega 20%. Preciznost mjerenja ovisi o udaljenosti objekta snimanja i senzora za prihvat reflektirajućeg zračenja, divergenciji odaslane laserske zrake, oblika i reflektivnosti snimanog objekta te o okolišnim uvjetima pri kojima se vrši snimanje.

Prema načinu mjerenja udaljenosti terestrični laserski skeneri se mogu podijeliti na pulsne skenere i fazne skenere. Pulsni skeneri se temelje na principu mjerenja vremenskog intervala putovanja elektromagnetskog vala prema objektu snimanja te mjerenja vremena potrebnog da se odaslani val vrati. Oni omogućavaju mjerenja na veće udaljenosti te se koriste i prilikom laserskog snimanja iz zraka. U faznim skenerima udaljenost se računa iz fazne razlike između primljenog i odaslanog vala pri čemu se odaslana laserska zraka modulira harmonijskim valom. Točnost ovoga načina mjerenja udaljenosti je u granicama od nekoliko milimetara, ali je zbog toga ograničen domet snimanja.

Miler i sur. (2007) navode podjelu terestričnih laserskih skenera prema načinu snimanja na: skenere-kamere, panoramske skenere i hibridne skenere. Glavna razlika prema kojoj su oni podijeljeni je njihov prozor snimanja (engl. *Field Of View* – FOV). Skeneri-kamere imaju veoma ograničen FOV te snimaju samo ono što se nalazi u trenutnom prozoru snimanja, panoramski skeniraju sve oko sebe osim područja ispod postolja na kojem se nalazi, dok hibridni skeneri u horizontalnoj osi skeniraju 360º, a po vertikalnoj osi su ograničeni na snimanje u kutu od 60º od smjera gledanja.

Terestrički laserski skeneri se od zračnih laserskih skenera razlikuju u tome što omogućavaju iznimno detaljne i precizne izmjere objekata u prostoru, ali su pritom ograničeni svojim dometom. Laserski skeneri za skeniranje iz zraka ne daju toliko detaljnu sliku mjerenog područja, ali zato platforme koje nose skener pokrivaju velike površine tijekom izmjere.

Prilikom inventure šuma TLS se može koristiti kod mjerenja manjih ploha kako bi se dobile točne LAI (engl. *Leaf Area Index*) vrijednosti koje postaju referentne vrijednosti područja, dok se ALS pritom koristi za prikupljanje kvantitativnih podataka o LAI-u na velikim površinama (Lin i West, 2016).

Njihova zajednička uporaba može dati svoj doprinos u brojnim problemima vizualizacije prilikom razvoja gradova, prostornog planiranja, upravljanja velikim ekosustavima, raznih prostornih, infrastrukturnih i drugih analiza.

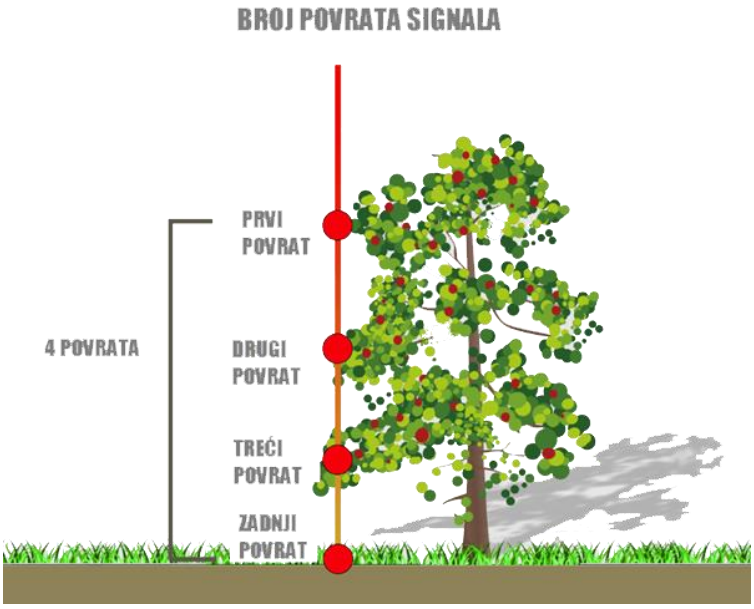
1.2.2. LASERSKO SKENIRANJE IZ ZRAKA

Fotogrametrija je znanost i tehnika određivanja oblika, veličine ili položaja nekog objekta snimanjem, mjerenjem i interpretacijom fotografskih snimaka. Bez fotogrametrije nije zamislivo niti kartiranje niti proučavanje površine planeta, također bez fotogrametrije ne bi se razvili niti današnji sustavi laserskog skeniranja iz zraka. Stara je to vještina koja je u uporabi i više od stotinu godina. Fotogrametrija se primarno bazira na obradi snimaka i njeni su produkti: digitalni modeli terena (engl. *Digital Terrain Model* - DTM), ortofoto, 2D i 3D rekonstrukcije snimljene površine te podloge za klasifikaciju i kartiranje, odnosno za izradu tematskih karata i vizualizacije (Baltsavias, 1999).

Lasersko skeniranje iz zraka relativno je nova metoda dobivanja prostornih podataka snimanjem zemljine površine iz letjelice koja se ne može odvojiti od fotogrametrije, već je bolje shvaćanje istog kao načina prikupljanja prostornih podataka s posebnom vrstom senzora.

Laser postavljen u letjelicu zajedno sa svom potrebnom opremom ima za cilj direktno georeferencirati, odnosno odrediti 3D koordinate (x, y, z) podataka iz oblaka točaka nastalog snimanjem određenog područja. Za razliku od 2D planimetrijskih podataka, oblak točaka koji je produkt izmjere s LiDAR tehnologijom eksplicitno opisuje profil snimljene Zemljine površine. Ostale prednosti LiDAR tehnologije očituju se u nepostojanju deformacija koje se događaju pri klasičnom snimanju terena iz aviona, mogućnosti prodora kroz vegetaciju te njegove neosjetljivosti na svjetlosne uvjete. Stoga, LiDAR tehnologija snimanja iz zraka se uspješno koristi pri izradi DMR-a, topografskih kartiranja, izrade 3D modela gradova te procjeni šteta kod katastrofalnih prirodnih nepogoda (Yan i sur., 2015).

Prilikom laserskog skeniranja iz zraka područje koje je predmet izmjere nadlijeće se letjelicom, koja može biti zrakoplov ili helikopter, a ona s donje strane nosi LiDAR. Njegova karakteristika je da se pri kontaktu s vegetacijom dio zrake odbije registrirajući visinu vegetacije, a dio zrake prolazi do druge površine od koje će se odbiti, odnosno do tla ili tvrde i nepropusne podloge od koje se odbija cijela zraka (Slika 1).



Slika 1 *- Prikaz raznih povrata pojedine LiDAR zrake (Ivšić i sur., 2016)*

Ovisno o vidnom kutu skenera (FOV) i visini leta tijekom jednog preleta moguće je izmjeriti pojas na terenu odgovarajuće širine, odnosno cijeli jedan niz. Cijelo se područje prema potrebi nadlijeće više puta kako bi se snimilo s potrebnim brojem nizova (Gajski, 2007). Visine leta variraju od 20 do 6000 m, no obično su u rasponu od 200 do 1000 m (200-300 m za helikoptere, odnosno 500-1000 m za zrakoplove).

Većina ALS sustava sastoji se od 4 glavne komponente (Balenović i sur., 2013):

a) laserski skener
b) GPS
c) IMU
d) računalo za pohranu i obradu prikupljenih podataka

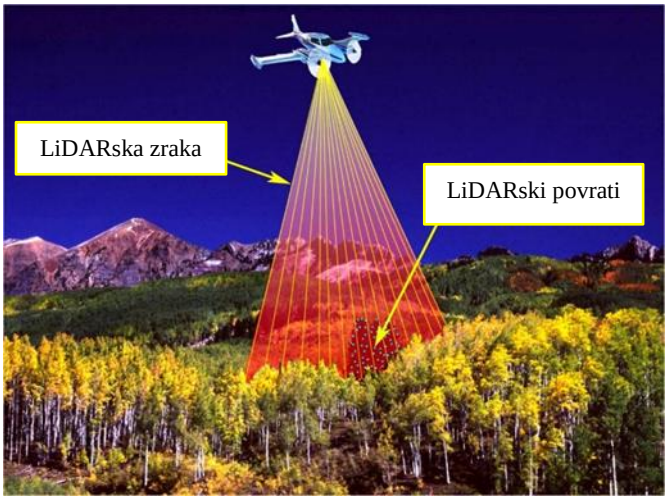
Laserski skener se sastoji od sljedećih glavnih dijelova (Gajski, 2007):

- impulsnog lasera, čija se učestalost pulsiranja može mijenjati
- mehanizma za skeniranje (npr. rotirajuće prizme, njišućeg zrcala)
- prijemnog senzora sa sklopom za mjerenje vremena putovanja laserskog impulsa

Laseri ALS sistema za snimanje vegetacije emitiraju svjetlost valnih duljina između 900 i 1064 nm (blisko IC-područje). Blisko IC-područje primarno se koristi zbog sigurnosti za ljudsko oko koje nije osjetljivo na te valne duljine stoga se mogu koristiti velike snage laserskog zračenja,

ali i činjenice da vegetacija u vidljivom dijelu spektra upija veliku količinu odaslanog elektromagnetskog zračenja što rezultira slabom refleksijom.

Kao i kod terestričnih laserskih sustava, i kod laserskih sustava za snimanje iz zraka postoje pulsni i fazni skeneri, no većinom su samo pulsni u primjeni. Jedan od češćih pulsnih lasera u primjeni je Nd:YAG laser koji emitira svjetlost u spomenutom bliskom IC-području (λ=1064 nm) i sa snagom od nekoliko MW (Wehr i Lohr, 1999). Prilikom laserskog skeniranja laserska se zraka namjerno divergira od 0.3 do 2 mrad kako bi pokrila područje od oko 0,3 do ≈ 2 m s relativne visine leta od 900 m. Na taj se način omogućava da dio laserske zrake dopre kroz lišće i granje do terena i da se nazad reflektira senzoru (Gajski 2007).



Slika 2 *- Način rada LiDAR sustava (Berta, 2017)*

Mehanizam za skeniranje otklanja lasersku zraku od referentne osi laserskog skenera što omogućuje izmjeru veoma širokog područja sa što je moguće gušćim rasporedom točaka u jednom preletu. Plošno pokrivanje područja koje se snima omogućava se otklanjanjem laserske zrake u poprečnom smjeru s obzirom da letjelica nosi LiDAR u smjeru leta (Slika 2). Otklanjanje laserske zrake u poprečnom smjeru formira Z-oblik uzorka skeniranja, ali u ovisnosti o tipu mehanizma za skeniranje razlikujemo i paralelne, eliptične, sinusoidalne i mnoge druge uzorke koji se formiraju prilikom skeniranja.

Postoji nekoliko različitih konstrukcija mehanizama za skeniranje, a danas su među češćima u uporabi (Gajski, 2007):

- skener s njišućim zrcalom
- skener s rotirajućom prizmom
- skener s optičkim vlaknima

Kod skenera s njišućim zrcalom se na putu laserske zrake nalazi njišuće zrcalo koje otklanja zraku okomito na smjer leta. Skeniranje je moguće provoditi u oba smjera, a zbog velike mase zrcala je frekvencija skeniranja razmjerno mala. Ovakvi se skeneri najčešće primjenjuju kod suvremenih ALS sustava zbog mogućnosti kontinuirane promjene brzine skeniranja i vidnog polja.

Prizma sa zrcalnim plohama po obodu koja se okreće određenom kutnom brzinom oko svoje osi se nalazi na putu laserske zrake kod skenera s rotirajućom prizmom. Za razliku od skenera s njišućim zrcalom, skener s rotirajućom prizmom skenira teren uvijek u istom smjeru, a gustoća i raspored skeniranih točaka mijenja se ovisno o brzini vrtnje prizme i promjeni frekvencije pulsiranja lasera. Skeneri s rotirajućom prizmom omogućuju znatno brže skeniranje od skenera s njišućim zrcalom.

Smjer svake laserske zrake fiksno je utvrđen smjerom dotičnog staklenog vlakna koja su smještena u jednoj lepezi postavljenoj okomito na smjer leta i to je princip skeniranja kod skenera s optičkim vlaknima. Ovaj način skeniranja omogućava pravilan, vrlo gust raspored skeniranih točaka te postizanje oštrih granica skeniranja. Mana kod ovog sustava je nemogućnost mijenjanja širine vidnog polja niti broja skeniranih točaka, već je to unaprijed zadano konfiguracijom samog skenera.

Prilikom laserskog skeniranja iz zraka linije snimanja su uobičajeno okomite na smjer leta letjelice koja nosi skener. Pulsni skener pritom emitra zrake u bliskom IC-području s prosječnim trajanjem od nekoliko nanosekundi (10^{-9}) i s veoma visokom frekvencijom skeniranja (do 300 kHz) što znači da je pulsni laser sposoban emitirati do 300 000 laserskih zraka u sekundi (Balenović i sur., 2013). Na svome putu laserska se zraka rasprši na vegetaciji i ostalim objektima u prostoru te se energija laserskog zračenja širi u svim smjerovima, a jedan njen manji dio se bilježi u senzoru. Količina reflektiranog zračenja zabilježenog u senzoru ovisi, pored intenziteta izračene energije, i o trenutnom kutu skeniranja te stupnju refleksije trenutno skeniranih objekata (Gajski, 2007).

Najraniji laserski sustavi mogli su zabilježiti samo jedan povratni signal (jeku, refleksiju) ili dva povratna signala (prvi i zadnji) odaslane laserske zrake. Stoga je prvotna namjena laserskih skeniranja iz zraka bila izrada digitalnih modela površina (engl. *Digital Surface Model* – DSM) ukoliko se zabilježio samo jedan povratni signal, odnosno digitalnih modela reljefa (DMR) ukoliko je senzor zabilježio dva povratna signala (Wehr i Lohr, 1999). Današnji, moderni tzv. 'multiple-return' sustavi omogućavaju zabilježavanje i do pet povratnih signala jedne odaslane laserske zrake (Lefsky i sur., 2002).

Sustavi koji omogućavaju zabilježavanje i nekoliko povratnih signala veoma su korisni prilikom skeniranja šumske vegetacije. Kako se laserska zraka dispergira prilikom svog doticaja s vegetacijom dio nje se vraća prema senzoru u letjelici, dok se drugi dio dalje probija skroz vegetaciju u niže predjele. Tako odbijeni signali mogu dati veoma dobru predodžbu o vertikalnoj strukturi skenirane sastojine.

Gustoća točaka, odnosno gustoća skeniranja jedna je od najčešće korištenih mjera za izražavanje prostorne rezolucije ALS podataka. Gustoća točaka izražava se kao broj zabilježenih povrata (točaka) po 1 m^2 i ona je u pozitivnoj korelaciji s kvalitetom i preciznošću dobivenih podataka nakon skeniranja.

Iako su spomenuti kao zasebni dijelovi ALS sustava, GPS i IMU se često integriraju u zajednički tzv. POS (engl. *Position and Orientation System*) sustav. Njihova je zadaća točno određivanje pozicije i orijentacije ALS sustava što omogućava direktno georefenrenciranje.

GPS, globalni položajni sustav, satelitski je radionavigacijski sustav za određivanje položaja na Zemlji ili u njenoj blizini. Kao takav GPS ne može dati lokacijske podatke zadovoljavajuće točnosti stoga se on integrira s inercijalnim mjernim uređajima (IMU) koji su svojevrsna kontrola i nadogradnja GPS-a zbog visoko točnih podataka koji se mogu dobiti njihovom uporabom. Gibanja koja se promatraju u navigaciji su translacijska i rotacijska pa se prema tome koriste dvije vrste inercijalnih mjernih uređaja, a to su žiroskopi i akcelometri. Akcelometri služe za mjerenje linearnih akceleracija, dok žiroskopi služe za mjerenje kutnih pomaka. Uređaji se integriraju na platforme koje zajedno s mikroprocesorom izračunavaju koordinatne razlike između dvije točke i time tvore inercijalne navigacijske sustave.

Rezultat laserskog snimanja terena iz zraka je gusti skup podataka o zabilježenim povratnim signalima s podacima o njihovoj udaljenosti i dodatnim pozicijskim informacijama iz POS sustava, a naziva se oblak točaka (engl. *point cloud*). Kako bi se dobili georeferencirani, validni

i dimenzijski točni podaci iz oblaka točaka u tzv. sirovom formatu mora se napraviti obrada podataka dobivenih terenskom izmjerom.

Korištenjem ALS podataka u generiranju DMT-a za različite svrhe pridonijelo bi smanjenju troškova snimanja terena i učinkovitijem korištenju sredstava (Alexander i sur., 2014).

Dva su osnovna načina (pristupa) pridobivanja podataka o šumskim sastojinama na temelju ALS podataka, ovisno da li se radi o procjeni parametara pojedinačnih stabala (engl. *Individual-Tree-Based Approach* - ITB) ili procjeni srednjih sastojinskih parametara (engl. *Area-Based Approach* - AB) (Reutebuch i sur., 2005; Yu i sur., 2010). Kod AB metoda srednje (prosječne) sastojinske vrijednosti za određeno područje (npr. ploha, sastojina) procjenjuju se primjenom statističkih (regresijskih, neparametrarskih, diskriminantnih) analiza i uspostavljenih odnosa (modela) između ALS podataka (procesirani oblak točaka, digitalni model visina i visina krošnje) i terenski izmjerenih varijabli. Prednost AB metoda je u tome što su primjenjive i pri manjim gustoćama skeniranja. Međutim, s druge strane zahtijevaju veću količinu referentnih terenskih podataka. Kod ITB metoda glavni je cilj direktnim mjerenjem snimljenih točaka ili raznim procesima segmentiranja razlučiti pojedinačna stabla ili grupe stabala iz ALS podataka (procesiranog oblaka točaka, DMV ili DMVK) te na temelju dobivenih informacija iz točaka (oblaka točaka) ili piksela (iz DMV ili DMVK) procijeniti visinu stabla, dimenzije krošnje, odrediti položaj stabla, vrstu drveća, itd.

2. CILJ I PODRUČJE ISTRAŽIVANJA

Cilj ovog diplomskog rada je na temelju podataka dobivenih laserskim skeniranjem iz zraka područja Grada Zagreb, prikazati obradu 3D oblaka točaka, klasifikaciju, vizualizaciju i različite načine i mogućnosti uporabe takvih podataka pri praćenju i izmjeri vegetacije urbanih područja.

Područje istraživanja je određeno dostupnim LiDAR podacima (snimanje je obavila tvrtka GISDATA u proljeće 2012. godine za naručitelja Grad Zagreb), ustupljenim od strane Grada Zagreba. Za područje istraživanja izabrano je administrativno područje Grada Zagreba, Lenucijeva potkova, konkretno Trg Nikole Šubića Zrinskoga (Zrinjevac).



Slika 3 *- Lenucijeva potkova s označenim Trgom Nikole Šubića Zrinskoga*

2.1. TRG NIKOLE ŠUBIĆA ZRINSKOG

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. Danas su to: Trg Nikole Šubića Zrinskog (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 hektara (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 drvoredima platana. Platane, dopremljene iz Udina (Italija), posađene su 1872. (Bojanić Obad Šćitaroci i Šćitaroci, 2004). Do kraja 19. stoljeća Zrinjevac je prošao tri značajnija preoblikovanja i od tada do danas nije se znatnije mijenjao.

Zrinjevac je prava zelena oaza u samom središtu grada Zagreba, omiljeno odredište kako turistima, tako i samim građanima. Zbog svoje lokacije, izuzetno urbaniziranog okoliša koji ga okružuje i stogodišnjih drvoreda 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 pojedinačnog stabla.

3. MATERIJAL I METODE RADA

3.1. PODACI PRIKUPLJENI LiDAR-OM

LiDAR-ski podaci su snimljeni tijekom travnja 2012. godine. Podaci su snimani uz minimalnu gustoću skeniranja 0,5 točaka/m^2 te s poprečnim preklopom od 20 %.

Tehničke karakteristike LiDAR podataka:

- vrijeme snimanja: 26.03.2012.
- inercijalni sustav: Applanix 310
- software za planiranje leta: Fplan
- sustav za GPS navigaciju: MASON
- avion za snimanje: Cessna 402B
- visina leta: 2.000 metara (nominalno)
- LiDAR senzor: Leica ALS-50 II
- software za postprocesnig (LiDAR): ALS Post Processor

Tehničke karakeristike LiDAR senzora (LEICA Geosystems):

- Vrsta senzora: „discrete return“ (snima pojedine povrate)
- Visina snimanja: max 6000 m
- Širina snimanja (FOV- Field of view): 75º
- Broj povrata: prvi, drugi, treći i posljednji
- Brzina snimanja: 90 Hz pri 10º FOV / 30 Hz pri 75º FOV
- Brzina emitiranja laserskih zraka: 150 kHz (150.000 zraka) pri visini snimanja od 500 m / 22 kHz pri visini snimanja od 6000 m

LiDAR-ski podaci korišteni pri izradi diplomskog rada su obrađeni softverom LAStools, koji služi za vizualizaciju, obradu, klasifikaciju, pretvorbu i ekstrakciju „sirovih” podataka te pomoću Quick Terrain Modeler (QTM) softvera.

3.2. PRIKUPLJANJE TERENSKIH PODATAKA

Prikupljanje terenskih podataka, potrebnih za izradu diplomskog rada, obavljeno je 18. srpnja 2017. godine. Na istraživanom području za svako je locirano stablo determinirana vrsta, mjerena njegova visina (m) instrumentom Vertex III s točnošću na jednu decimalu te opseg (cm) na prsnoj visini (1,30 m od tla) iz kojeg se izračunao prsni promjer preko formule za opseg kruga. Podaci prikupljeni na terenu upisivani su redom izmjere u terenski manual te kasnije uneseni u Excel bazu podataka.

Vertex III je instrument za mjerenje visina, udaljenosti, vertikalnih kutova, nagiba i trenutačne temperature. Iako ga je pri izmjeri visina moguće koristiti i bez transpondera (alternativni način određivanja udaljenosti), instrument potpunu funkcionalnost postiže u kombinaciji s njim, pri čemu je transponder, odnosno njegov dio koji prima i odašilje ultrazvuk pod kutem od 60º (transponder 60º) okrenut prema instrumentu. Za mjerenja udaljenosti instrument koristi ultrazvučne valove. Na temelju vremena potrebnog da ultrazvučni val prijeđe udaljenost od instrumenta do transpondera i natrag, uz poznatu brzinu kretanja ultrazvučnih valova, instrument određuje udaljenost (Lukić i sur., 2005).



Slika 4 *- Vertex III visinomjer/daljinomjer (Lukić i sur.,2005)*

Tijekom prikupljanja terenskih podataka radi lakšeg snalaženja prilikom obrade podataka korišten je Katastar zelenila (https://gis.zrinjevac.hr) izrađen za Zagrebački holding, podružnicu Zrinjevac. Katastar zelenila je digitalna zbirka zagrebačkog drveća, grmlja i ostalog bilja u kojem su sistematizirani i inventarizirani podaci o sadržajima javnih gradskih površina. O svakome stablu u katastru postoje osnovne informacije kao što su: latinski i hrvatski naziv biljke, prostorni raspored, zaštitni elementi oko stabla (ukoliko postoje), promjer stabla, promjer krošnje i visina stabla. Ti podaci su informativnog karaktera te se ne mogu uzeti kao pouzdane i referentne vrijednosti, stoga se prilikom terenske izmjere koristio samo prikaz prostornog rasporeda stabala. Prije samog izlaska na teren svako je stablo odbrojčano, tim je redoslijedom obavljana izmjera i pod tim brojem je ono bilo korišteno za sve daljnje analize prikupljenih podataka.



Slika 5 *– Trg Nikole Šubića Zrinskog s odbrojčanim stablima za izmjeru na terenu*

3.3. OBRADA PODATAKA

Obrada „sirovih“ (neobrađenih i neklasificiranih) podataka obavljena je pomoću LAStools softvera razvijenog od Rapidlasso gmbH grupe koji sadrži alate za klasifikaciju, ekstrakciju i pretvorbu LiDAR podataka. Prilikom obrade podataka ovim softverom koristila se metodologija prikazana u Berta (2017). Ovo je nužan korak u analizi LiDAR-skih podataka jer je dobiveni produkt u obliku obrađenog i klasificiranog oblaka točaka podloga za daljnje detaljne analize željenog područja.

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

LAS format je javni format podataka za razmjenu 3D oblaka točaka između korisnika. Iako je razvijen primarno za potrebe razmjene LiDAR 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 sur., 2016).

Budući da su podaci dostavljeni u UTM 33, WGS84 zoni radi preklapanja sa željenim područjem oni se najprije transformiraju u HTRS TM zonu te se izdvajaju željena područja. Zatim se računa gustoća točaka na izdvojenom željenom području i uređuje se oblak točaka pomoću alata lasnoise koji pronalazi usamljene točke te ih klasificira ili uklanja.

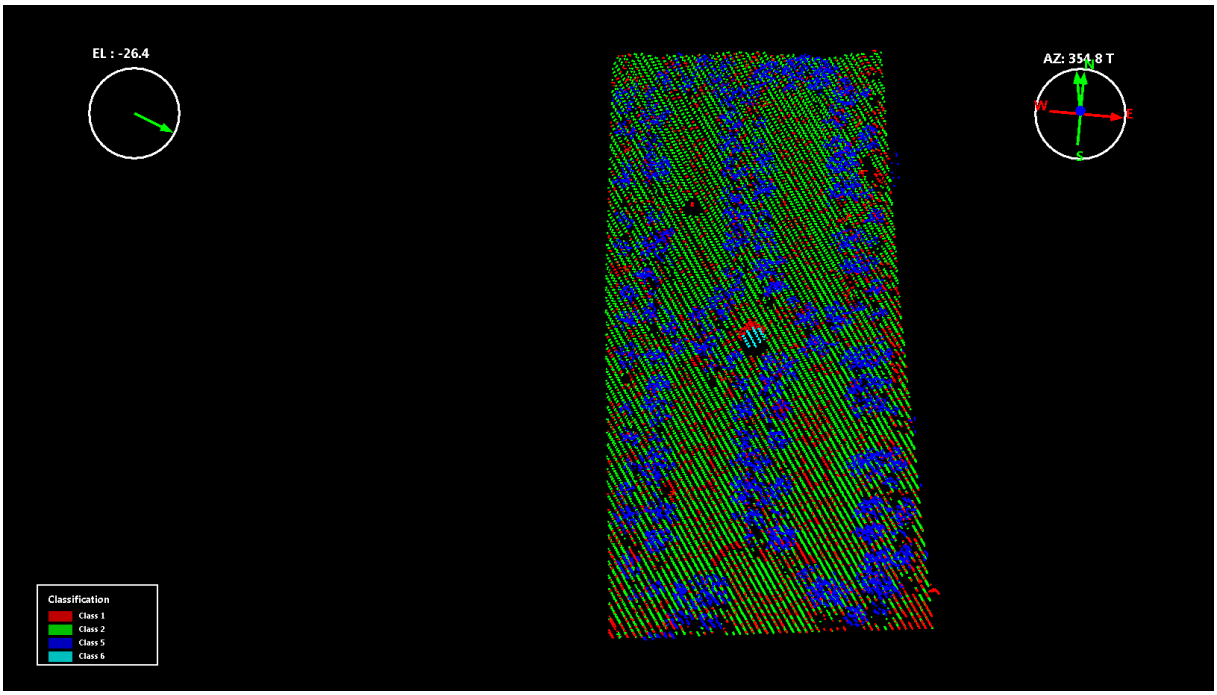
Nakon utvrđivanja kvalitete korištenog oblaka točaka pristupa se automatskoj klasifikaciji na točke tla (engl. *ground points*) i točke iznad tla (engl. *non-ground points*) s alatom lasground. Ovaj postupak se u literaturi naziva filtriranje (engl. *'lidar data filtering'*) (Zhang i Qiu, 2012; Ivšić i sur., 2016). Također se alatom lasheight svakoj točki računa nadmorska visina što je potrebno za daljnje klasificiranje ili za stvaranje digitalnog modela reljefa.

Iako se automatskom klasifikacijom mogu dobiti dobri rezultati, oni su još uvijek daleko od optimalnih i nužna je ručna intervencija jer softverski algoritam ne može prepoznati sitne detalje koje su čovjeku očigledne i jasne da pripadaju određenoj klasi. Po utvrđivanju pogrešno svrstanih točaka, iste je moguće reklasificirati bilo ručno ili automatski. Postupak reklasifikacije točaka terena i ostalih točaka iznad terena se provodi dokle god se ne dobiju zadovoljavajući rezultati. Ovaj korak je ključan jer direktno uvjetuje kvalitetu generiranja digitalnih modela terena (Ivšić i dr, 2016).

Nakon filtriranja i reklasifikacije oblaka točaka da bi se izdvojile samo točke vegetacije alatom lasclassify se nastavlja daljnja klasifikacija na vegetaciju, zgrade, putove 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) prag od 0,5 m iznad tla za klasifikaciju točaka kao točaka vegetacije je u skladu s postojećim istraživanjima (Garcia i sur., 2010), a izabran je također poštujući činjenicu da LiDAR tehnologija podcjenjuje visinu vegetacije (Gaveau i Hill, 2003; Hopkinson i sur., 2005) iz vrlo jednostavnog razloga što zraka lasera ne pogađa uvijek sami vrh stabla. Prilikom klasificiranja vegetacije korisno je iskoristiti informacije o broju povrata signala budući da se pretpostavlja da će vegetacija imati više povrata jer će se signal najprije odbiti od krošnje drveta, pa od grane pa tek onda od tlo (Ivšić i dr, 2016).

Nakon izvršenih klasifikacija, alatom lasclip se izdvojio oblak klasificiranih točaka koji se poklapao s izmjerenom terenskom plohom.

Daljnja obrada i vizualizacija podataka vrši se na izdvojenom i klasificiranom oblaku točaka u Quick Terrain Modeler (QTM) softveru. QTM je razvila kompanija Applied Imagery s jedinstvenom svrhom, a to je rad s LiDAR podacima koji omogućava vizualizaciju, uređivanje i analizu LiDAR oblaka točaka.



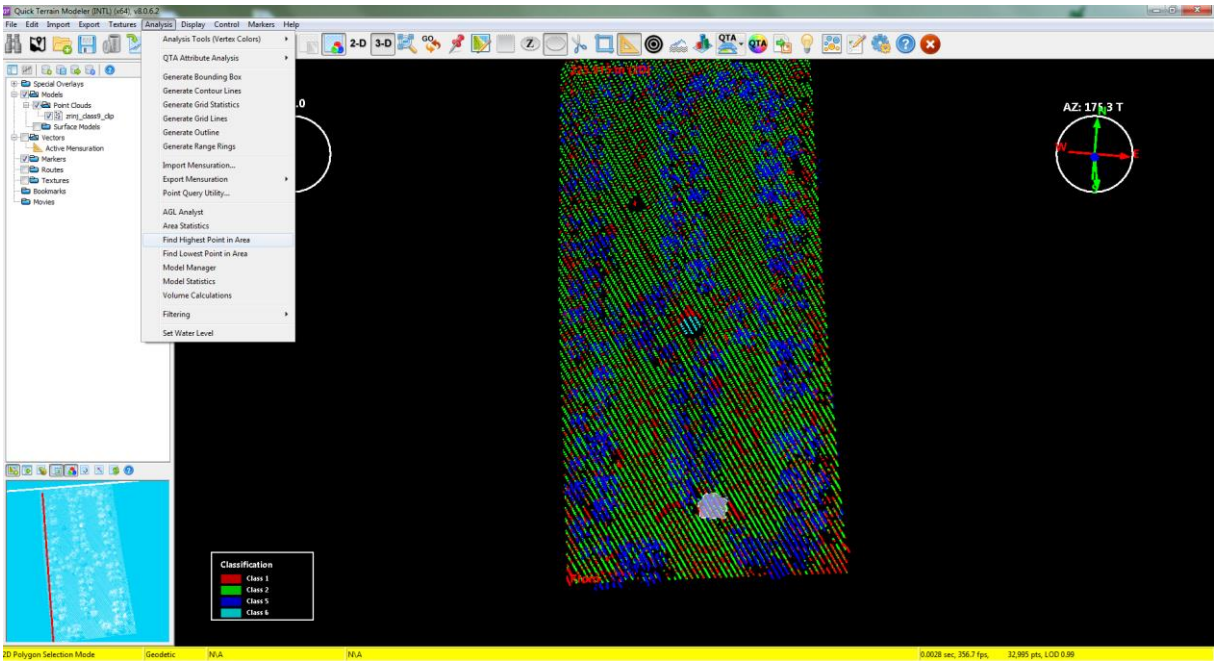
Slika 6 *– Prikaz izdvojenog oblaka točaka u QTM softveru*

Kako bi se moglo pristupiti analizi pojedinog stabla, ona se prvo moraju detektirati iz LiDAR oblaka točaka, a to se radi kroz dva bitna koraka. Prvi je izrada digitalnog modela terena, a drugi je detekcija pojedinačnog stabla što uključuje identifikaciju njegove krošnje (Zhang i Qiu, 2012). Digitalni model terena (DMT) su klasificirane točke tla koje su prilikom obrade sirovih podataka normalizirane na nadmorsku visinu od 0 m dok sve točke vegetacije zajedno čine digitalni model visina krošanja (DMVK). Visinu stabla predstavlja visinska razlika između DMT i DMVK.

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

Učitavanjem obrađenih i klasificiranih LiDAR podataka u QTM softver započinje analiza vegetacije Trga Nikole Šubiće Zrinskoga. S obzirom da je Trg Nikole Šubića Zrinskoga pravilnog, pravokutnog oblika i da su stabla u drvoredu, moguća je pojedinačna analiza svakoga stabla. Iz oblaka točaka poligonom se izdvajaju pojedinačna stabla odnosno njihove krošnje i to unaprijed određenim redoslijedom, onim kojim je vršena i terenska izmjera. Kako bi se izrazila visina stabla ona se poistovjećuje s najvišom točkom u izdvojenom oblaku točaka.

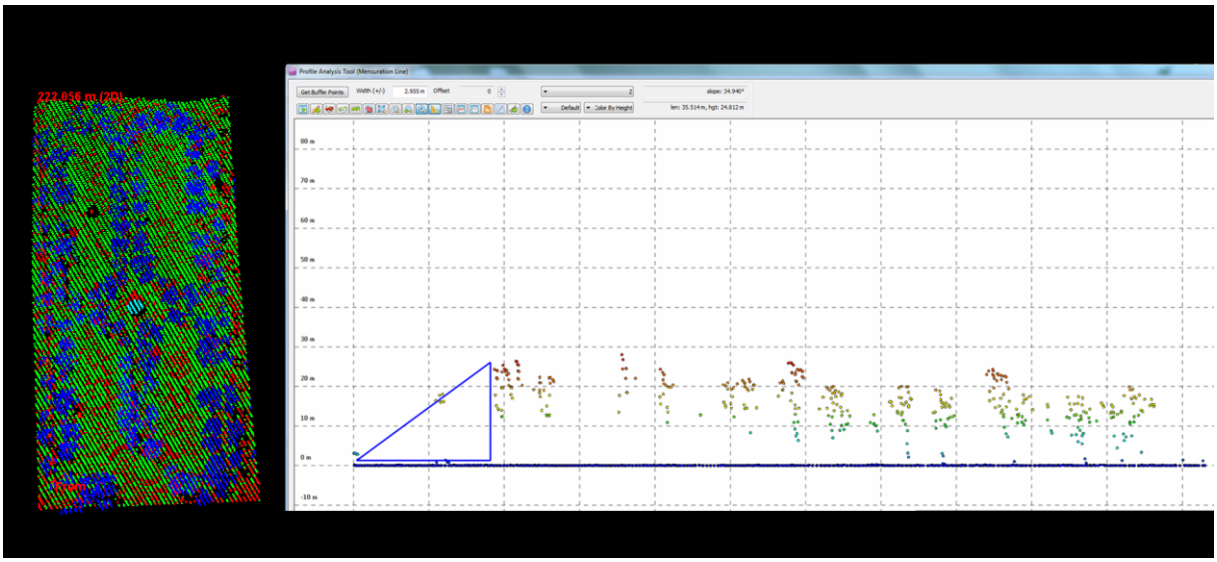
Poligonom se označila i selektirala odabrana krošnja, zatim se u glavnom izborniku odabrao 'Analyst' te u padajućem izborniku 'Find Highest Point in Area' (slika 7). Novootvoreni prozor daje osim podatka o najvišoj točki (z koordinata) na selektiranom području i mnoge druge informacije poput intenziteta točaka ili broja povrata.



Slika 7 *- Poligonom izdvojena krošnja iz oblaka točaka*

S obzirom na prirodu vegetacije i činjenicu da svo drveće na mjerenoj plohi nije iste dobi, odnosno neka su zamijenjena tijekom vremena zbog opasnosti po sigurnost i život građana, do visina mlađih i nižih stabala nije se moglo doći opisanim postupkom jer se prvi (i najviši) povrat zrake odbio od grane višeg starijeg stabla. Alternativan način dolaska do visine nižeg stabla je bila izrada profila oblaka točaka iz kojeg je vidljiv presjek svih točaka do tla te iz kojeg se može jasno razabrati i izmjeriti niže stablo (slika 8).

QTM softver omogućuje izradu profila iz prikupljenih podataka za detaljne analize ili vizualizacije terena. Pomoću 'Measuration line' alata označava se željeno područje na DMT-u ili u oblaku točaka za koje se treba izraditi profil, zatim se desnim klikom miša otvara padajući izbornik u kojem se odabere opcija 'Profile Analysis Tool' čime se otvara novi prozor u kojem su pokazane sve točke u zadanim okvirima (duljina i širina obuhvata). Svaka točka ima svoju nadmorsku visnu i do nje se može doći tako da se pokazivač miša stavi na nju a softver će automatski napisati njenu visinu. Prilikom interpretacije točke se mogu i vizualno razdvojiti tako da se obojaju različitim bojama ovisno o njihovoj visini.



Slika 8 *- Izrađen profil iz oblaka točaka*

Sve su visine stabala na zadanom području očitane s točnošću na dvije decimale prikazanim načinima te se upisale redom očitavanja u Excel bazu podataka uz podatke s terenske izmjere. Za svako stablo je uz podatke o vrsti, opsegu debla, prsnom promjeru te visini izmjerene Vertex III uređajem upisana i ona dobivena očitavanjem iz LiDAR oblaka točaka.

Statistička obrada podataka odrađena je pomoću softvera Statistica 10.0. Uključivala je izradu osnovne deskriptivne statistike za svaku izmjeru (Vertex III uređajem 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.

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

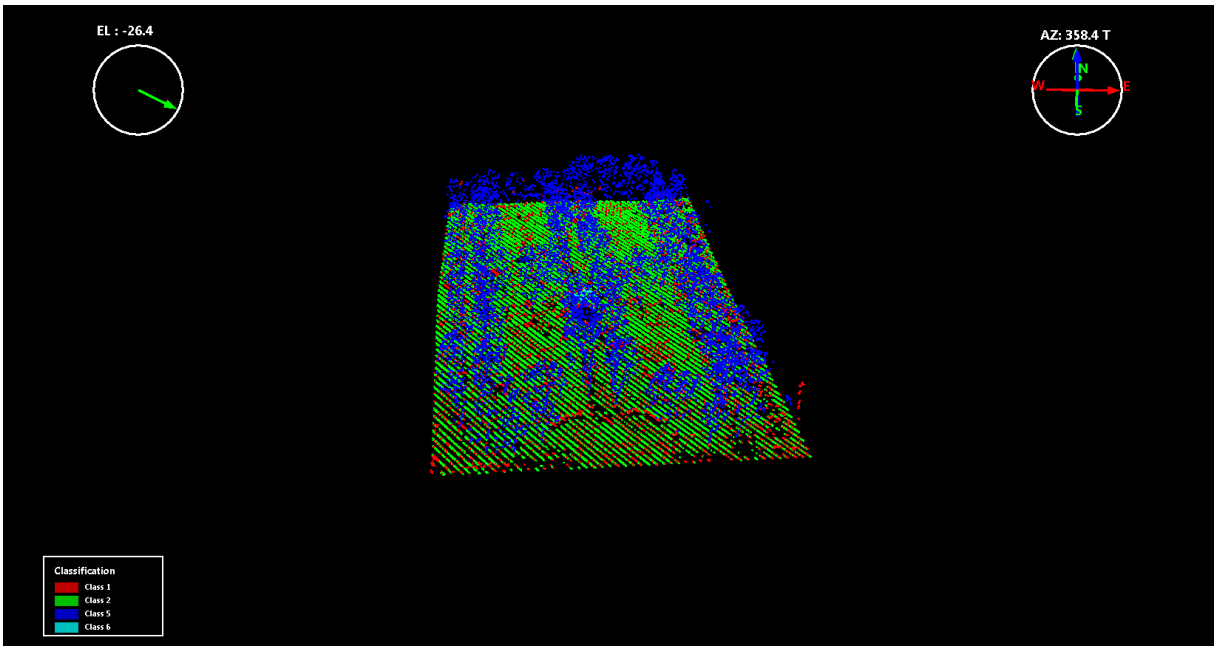
4. REZULTATI RADA

Cilj ovoga rada je prikazati neke od mogućnosti analize vegetacije koje nude podaci dobiveni laserskim snimanjem iz zraka terena urbanih područja. Te mogućnosti se kao rezultati ovoga rada pojavljuju u rasponu od 3D vizualizacije snimljenog prostora do dobivanja egzaktnih i višestruko iskoristivih podataka o vegetaciji na snimljenom području.

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 utvrdilo se kako su 3 stabla posječena, stoga je terenskom izmjerom obuhvaćeno 146 stabala (od toga 140 hibridnih platana (*Platanus* x *hispanica*) i 6 javora mliječa (*Acer platanoides* L.)). Prosječna izmjerena visina Vertex III uređajem 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 iznosi 74 cm s rasponom od 8 cm do 160 cm.

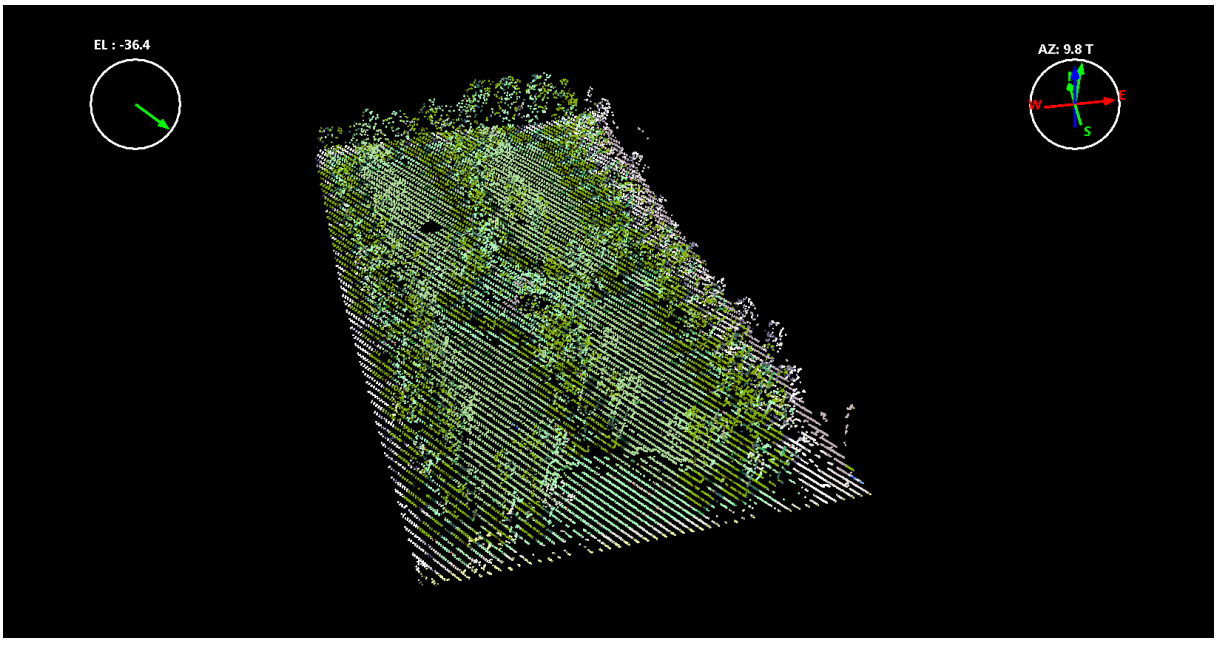
Laserskim skeniranjem iz zraka i obradom prikupljenih podataka dobiven je georeferencirani 3D oblak točaka klasificiran u 4 klase kao produkt obrade sirovih podataka u LAStools softveru te prikazan u QTM softveru za vizualizaciju oblaka točaka (slika 9). Prikupljen broj točaka za analizirano područje iznosi 32 995, a gustoća prikupljenih točaka je 1,03 točke/m^2, 4 izdvojene klase su: neklasificirano (class 1/crveno), tlo (class 2/zeleno), visoka vegetacije (class 5/tamno plavo) i zgrade (class 6/svijetlo plavo).

Model omogućava detaljan uvid u snimljeni prostor i sve njegove komponente. S obzirom 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 Zrinskoga jasno se vidi 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 između stabala, a po potrebi i izdvojiti krošnje svakog od njih za detaljne analize.



Slika 9 *– Trodimenzionalni prikaz klasificiranih točaka Trga Nikole Šubića Zrinskog*

Model je moguće spojiti i s različitim podlogama, često su to karte analiziranog područja koje omogućavaju precizniju interpretaciju ili objašnjavaju određene pojave u samom modelu. Pri izradi ovoga rada koristio se već spomenuti Katastar zelenila Grada Zagreba. Preuzeti prikaz prostornog rasporeda stabala koji je služio kao predložak za terensku izmjeru je georeferenciran te postavljen kao podloga oblaku točaka. Dobiveni rezultat je izuzetno dobro preklapanje krošnji iz oblaka točaka i njihovog prikaza u Katastru (slika 10) što upućuje na primjenjivost LiDAR-skih podataka u preciznim prostornim analizama.

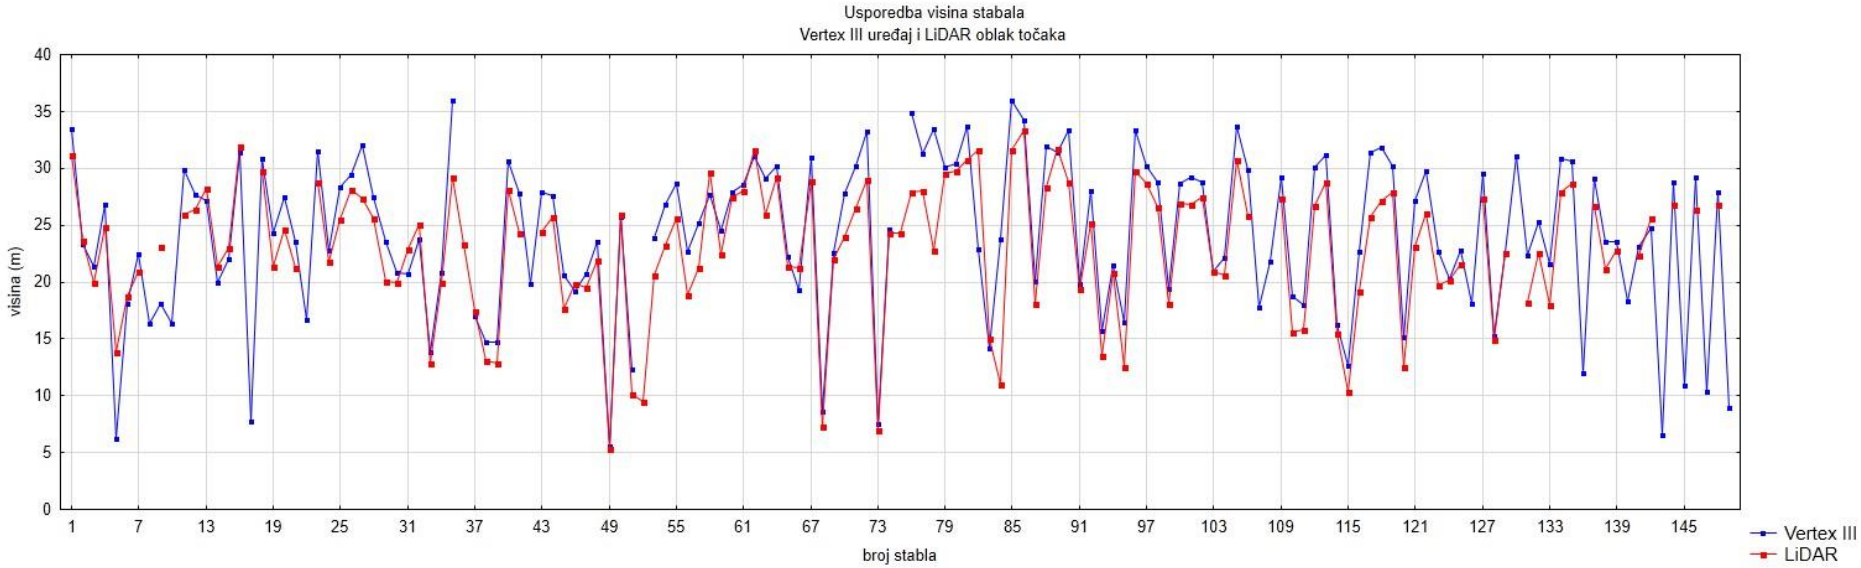


Slika 10 *– Prikaz oblaka točaka s Katastrom zelenila kao podlogom*

Prilikom očitavanja visina iz oblaka točaka izdvojeno je 134 stabla, 12 manje nego terenskom izmjerom (3 stabla za koja se terenskom izmjerom utvrdilo da nedostaju pronađeni su u oblaku točaka) i 15 manje od predviđenog Katastrom zelenila. Razlozi se za to mogu tražiti u niskoj gustoći oblaka točaka (1,03 točka/m^2), vremenu leta (ožujak – netom prije početka listanja vegetacije), mogućim pogreškama prilikom leta (različiti prekopi letnih linija) ili obrade sirovih podataka te promjenama u samom prostoru. Ovdje valja napomenuti kako su LiDAR-ski podaci iz 2012. godine, a podaci terenske izmjere iz 2017. godine, stoga je normalno da će se dobivene vrijednosti visina stabala razlikovati. S obzirom na to da većinu mjerenih stabala čine stogodišnje platane čiji je godišnji prirast slabiji, neće to u značajnijoj mjeri utjecati na prikaz i validaciju LiDAR rezultata. Dakako, nisu sva stabla iste dobi te na plohi postoje i mlađa stabla s većim i izraženijm godišnjim prirastom koji će se vidjeti u usporedbi dobivenih podataka.

Srednja izmjerena visina stabala iz oblaka točaka iznosi 23,07 m, najniže izmjereno stablo visine je 5,31 m, a najviše 33,34 m. U ovakvom prikazu podataka može se primjetiti kako su oni, za razliku od terenske izmjere, izraženi na dva decimalna mjesta, dok softver ima mogućnost prikaza i na tri što omogućuje i precizniju izmjeru.

Paralelna usporedba izmjerenih visina na razini svakog stabla prikazana je grafički u nastavku.



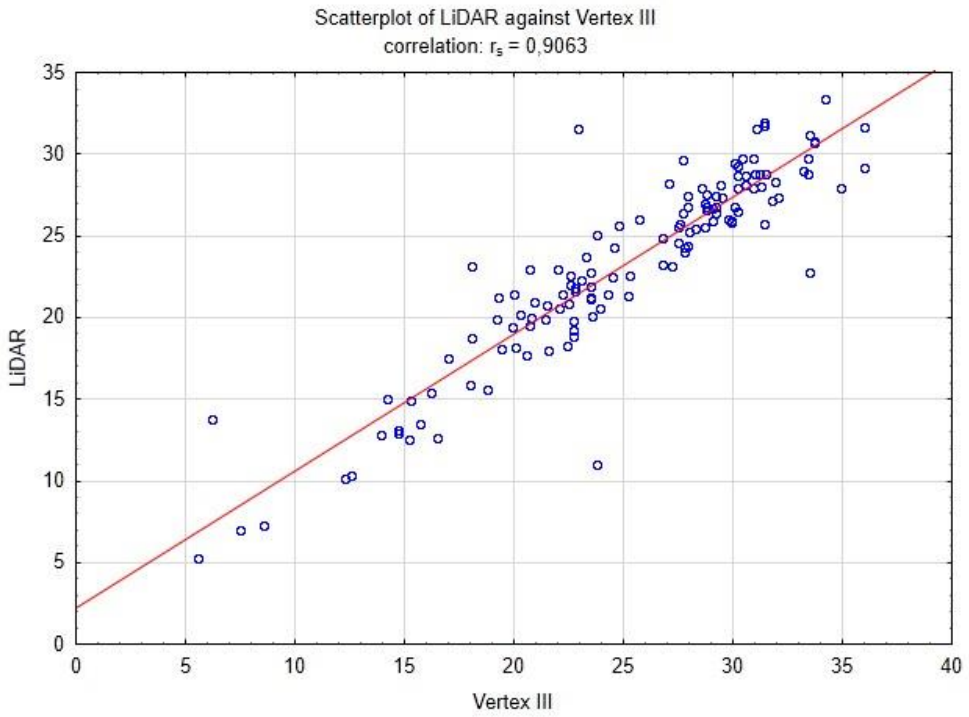
Graf 1 *- Usporedba visina za svako stablo izmjerenih Vertex III uređajem i iščitanih iz LiDAR oblaka točaka*

Kao što je potvrđeno i u deskriptivnoj statistici, a sada se i grafički može vidjeti, visine očitane iz oblaka točaka dobivenih laserskim skeniranjem iz zraka nešto su niže od onih s terenske izmjere. Isto tako, može se primijetiti kako linija LiDAR-ski dobivenih visina dosta vjerno prati onu s referentnim visinama izmjerenim terenskom izmjerom što je dobar pokazatelj vjerodostojnosti dobivenih podataka iz oblaka točaka. Razlika visina između dvije izmjere predstavlja djelomično i višegodišnji visinski prirast koji zbog različite dobi, položaja i vitalnosti stabala na plohi nije ujednačen među svim jedinkama.

U slučajevima kada su visine dobivene iz oblaka točaka značajnije više od visina dobivenih terenskom izmjerom istog stabla mogući su razlozi pogreške pri detekciji i ekstrakciji krošnje iz sklopa u QTM softveru ili pogreške prilikom same terenske izmjere. Spomenuto je kako postoje brojni računalni algoritmi koji se koriste kod ekstrakcije krošanja 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 centra grada koje je predstavljalo poteškoće prilikom terenske izmjere (Vertex III uređaj koristi ultrazvučne valove i mjeri vrijeme potrebno signalu da prijeđe udaljenost od uređaja do transpondera i natrag), nastale razlike u pojedinačnim izmjerama nisu dovoljne kako bi se na temelju njih odbacila točnost i primjenjivost LiDAR-skih podataka u analizi urbane vegetacije.

Tome u prilog ide izračunati koeficijent korelacije između terenske izmjere i visina dobivenih očitavanjem iz LiDAR oblaka točaka koji pokazuje i statistički značajan stupanj povezanost ove dvije varijable.

Grafički uspoređeni podaci u dijagramu raspršenosti o visinama prikazuju linearnu povezanost izmjera, no promatrane distribucije izmjerenih visina stabala za svaki instrument ne prate normalnu (Gaussovu) distribuciju. S obzirom na nepostojanje normalne distribucije podataka Artusi i sur. (2002) preporučuju korištenje Spearmanovog koeficijenta korelacije kod kojeg nije uvjet da su podaci 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 objavljenje literature u kojoj se uspoređuju LiDAR-ske i terenske izmjere stabala R^2 iznosi između 0,76 i 0,95 (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 dvije prikazane izmjere petogodišnje vegetacijsko razdoblje. Statistička analiza korelacije potvrđuje tezu da razlike u pojedinačnim izmjerama nisu dovoljne kako bi se odbacila primjenjivost LiDAR-skih podataka.

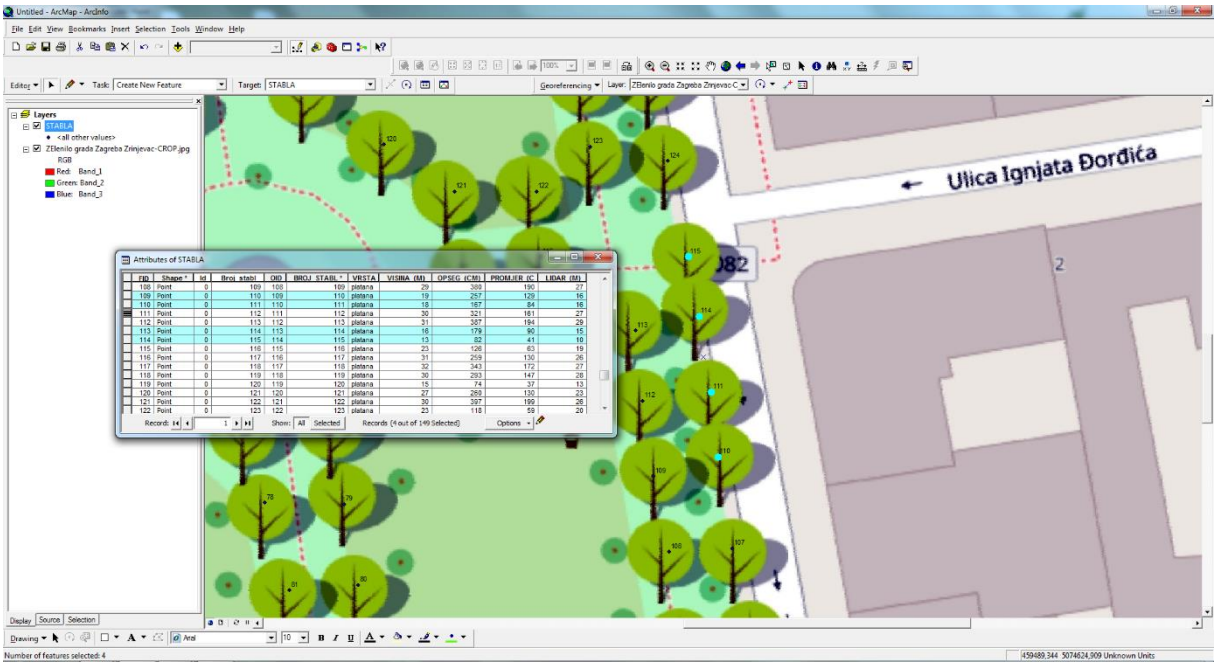


Graf 2 *- Usporedba povezanosti visina izmjerenih Vertex III uređajem i iščitanih iz LiDAR oblaka točaka*

Sve prikazano može potvrditi kako su podaci o stablima dobiveni laserskim skeniranjem iz zraka upotrebljivi u analizama urbane vegetacije. Statistička analiza je pokazala značajnu korelaciju između dvije izmjere dok je grafički prikaz pokazao kako se LiDAR-ski podaci mogu koristiti i za prostorne analize odnosa među stablima, budući da linija LiDAR-skih očitanja vjerno prati onu terenske izmjere, a razlika srednjih vrijednosti među izmjerama je samo 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 analizama koje se mogu obaviti iz dobivenih podataka od detaljnih strukturnih analizi urbanih šuma do izračuna vrijednosti općekorisnih funkcija koje pruža urbana vegetacija te u velikom obuhvatu prostora koji se zahvaća prilikom leta što utječe na dostupnost terenski nedostupnih područja.

Kao konačan rezultat napravljena je jedinstvena GIS baza podataka (slika 11) u kojoj je kao podloga postavljen georeferencirani prikaz Zrinjevca iz Katastra. Svako stablo u GIS bazi podataka ima svoj broj, isti onaj koji je imalo i na terenskoj izmjeri te su njemu pridružene sve prikupljene informacije tijekom ovog istraživanja (vrsta, opseg, promjer, visina mjerena Vertex III uređajem i ona dobivena iz LiDAR oblaka točaka).



Slika 11 *- Jedinstvena GIS baza podataka istraživanog područja*

5. ZAKLJUČAK

Na temelju postavljenih ciljeva i provedenog istraživanja u ovom radu došlo se do slijedećih zaključaka o upotrebi lidarskih podataka pri praćenju urbane vegetacije:

- Podaci prikupljeni laserskim skeniranjem iz zraka primjenjivi su u preciznim prostornim analizama budući da je rezultat laserskog skeniranja i obrade visoko točni, georeferencirani, trodimenzionalni i klasificirani oblak točaka koji vjerno opisuje skenirani prostor i odnose elemenata u njemu sa svim njihovim prostornim značajkama (x, y, z koordinata).

- Statističkom usporedbom laserski prikupljenih podataka o visini stabala s referentnom terenskom izmjerom istih tih stabala dobila se korelacija r_s=0,91 koja je statistički značajna, dokazuje povezanost dviju izmjera te potvrđuje validnost i upotrebljivost podataka dobivenih laserskim skeniranjem iz zraka pri izmjeri i praćenju urbane vegetacije.

- Lidarski podaci omogućavaju vizualizaciju urbanog prostora i vegetativnih elemenata u njemu te mnogobrojne analize od detaljnih strukturnih analizi urbanih šuma do računanja i izražavanja općekorisnih funkcija urbane vegetacije u ekosustavu.

- Terenska izmjera velikih površina skup je proces koji oduzima mnogo vremena, stoga se danas primjenjuju metode daljinskih istraživanja koje uvelike pojeftinjuju prikupljanje prostornih podataka. Trenutno su u upotrebi aero i satelitske snimke iz kojih se procesima fotointerpretacije i interpretacije izdvajaju i kartiraju obuhvati krošanja u urbanim područjima, obavlja izmjera visina i širina krošanja, procjenjuje zdravstveno stanje i još mnogo toga. LiDAR tehnologija bazirana na laserskom skeniranju s tla ili iz zraka svoju upotrebu pronalazi u analizama vegetacije urbanih područja gdje omogućava dobivanje validnih podataka kojima se mogu nadopuniti rezultati fotointerpretacije i interpretacije.

6. LITERATURA

Ackermann, F., 1999: Airborne laser scanning – present status and future expectations, Journal of Photogrammetry & Remote Sensing, 54: 64-67

Alexander, C., Klith Bøcher, P., Arge, L., Svenning, J.-C.., 2014: Regional-scale mapping of tree cover, height and main phenological tree types using airborne laser scanning data, Remote Sensing of Environment, 147: 156-172

Alonzo, M., Bookhagen, B., Roberts, D., 2014: Urban tree species mapping using hyperspectral and lidar data fusion, Remote Sensing of Environment, 148: 70-83

Alonzo, M., Bookhagen, B., McFadden, J., Sun, A., Roberts, D., 2015: Mapping urban forest leaf area index using penetration metrics and allometry, Remote Sensing of Environment, 162: 141-153

Alonzo, M., McFadden, J., Nowak, D., Roberts, D., 2016: Mapping urban forest structure and function using hyperspectral imagery and lidar data, Urban Forestry & Urban Greening, 17: 135-147

Artusi, R., Verderio, P., Marubini, E., 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., Alberti, G., Marjanović, H., 2013: Airborne Laser Scanning – the Status and Perspectives for the Application in the South-East European Forestry, SEEFOR, 4(2): 59-79

Baltsavias, E.P., 1999: A comparison between photogrammetry and laser scanning, Journal of Photogrammetry & Remote Sensing, 54: 89-94

Benko, M., Balenović, I., 2011: Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj, Šumarski list, Poseban broj: 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

Bojanić Obad Šćitaroci, B., Obad Šćitaroci, M., 2004: Gradski perivoji Hrvatske u 19. stoljeću: javna perivojna arhitektura hrvatskih gradova u europskom kontekstu, Šćitaroci, 264 str., Zagreb

Božić, A., 2016: Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukove prašume Medvjeđak, Diplomski rad, Šumarski fakultet, Zagreb

Chen, Z., Devereux, B., Gao, B., Amable, G., 2012: Upward-fusion urban DTM generating method using airborne Lidar data, Journal of Photogrammetry and Remote Sensing, 72: 121-130

Gajski, D., 2007: Osnove laserskog skeniranja iz zraka, Ekscentar, 10: 16-22

Garcia, M., Riaño, D., Chuvieco, E., Danson, M., 2010: Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data, Remote Sensing of Environment, 114: 816-830

Gaveau, D., Hill, R. 2003: Quantifying canopy height underestimation by laser pulse penetration in small-footprint airborne laser scanning data, Canadian Journal of Remote Sensing, 29(5): 650-657

Hecht, R., Meinel, G., Buchroithner, M.F., 2008: Estimation of Urban Green Volume Based on Single-Pulse LiDAR Data, IEEE Transactions on Geoscience and Remote Sensing, 46(11): 3832-3840

Holopainen, M., Kankare, V., Vastaranta, M., Liang, X., Lin, Y., Vaaja, M., Yu, X., Hyyppä, J., Hyyppä, H., Kaartinen, H., Kukko, A., Tanhuanpää, T., Alho, P., 2013: Tree mapping using airborne, terrestrian and mobile laser scanning – A case study in a heterogeneous urban forest, Urban Forestry & Urban Greening, 12: 546-553

Hopkinson, C., Chasmer, L., Sass, G., Creed, I., Sitar, M., Kalbfleish, W., Treitz, P., 2005: Vegetation clas deoendent errors in lidar ground elevation and canopy height estimates in a boreal wetland environment, Canadian Journal of Remote Sensing, 31(2): 191-206

Hopkinson, C., Lovell, J., Chasmer, L., Jupp, D., Kljun, N., van Gorsel, E., 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., Pribičević, B., Đapo, A., Kordić, B., Babić, L., Govorčin, M., 2016: Klasifikacija LiDAR podataka na području urbanog jezera Jarun i analiza kvalitete podataka, Ekscentar, 19: 98-103

Kim, S., McGaughey, R.J., Andersen, H., Schreuder, G., 2009: Tree species differentiation using intensity data derived form leaf-on and leaf-off airborne laser canner data, Remote Sensing of Environment, 113: 1575-1586

Klinberg, J., Konarska, J., Lindberg, F., Johansson, L., Thorsson, S., 2017: Mapping leaf area of urban greenery using aerial LiDAR and gound-based measurements in Gothenburg, Sweden, Urban Forestry & Urban Greening, 26: 31-40

Kwak, D.-A., Lee, W.-K., Lee, J.-H., Biging, G.S., Gong, P., 2007: Detection of individual trees and estimation of tree height using LiDAR data, Journal of Forest Research, 12: 425-434

Lefsky, M.A., Cohen, W.B., Parker, G.G., Harding, D.J., 2002: Lidar Remote Sensing for Ecosystem Studies, BioScience, 52(1): 19-30

Lin, Y., West, G., 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., Coops, N.C., Aven, N.W., Pang, Y., 2017: Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data, Remote Sensing of Environment, 200: 170-182

Lukić, N., Božić, M., Čavlović, J., Teslak, K., Novosel, D., 2005: Istraživanje primjenjivosti ultrazvučnog visinomjera/daljinomjera *Vertex III* u odnosu na najčešće korištene visinomjere u šumarstvu Hrvatske, Šumarski list, 9-10: 481-488

McPherson, E.G., 2006: Urban Forestry in North America, Renewable Resources Journal, 24(3), 8-12

Miler, M., Đapo, A., Kordić, B., Medved, I., 2007: Terestrički laserski skeneri, Ekscentar, 10: 35-38

Nelson, R.F., 2013: How did we get here? An early history of forestry lidar, Canadian Journal of Remote Sensing, 39(s1): 6-17

Nowak, D.J., Crane, D.E., Stevens, J.C., Hoehn, R.E., Walton, J.T., Bond, J., 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., Toth, C.K., 2009: Airborne and Spaceborne Laser Profilers and Scanners, Topographic Laser Ranging and Scanning: Principles and Processing, CRC Press: 29-85

Reutebuch, S.E., Andersen, H.-E., McGaughey, R.J., 2005: Light Detection and Ranging (LIDAR): An Emerging Tool for Multiple Resource Inventory, Journal of Forestry, 103(6): 286-292

Wehr, A., Lohr, U., 1999: Airborne laser scanning – an introduction and overview, Journal of Photgrammetry and Remote Sensing, 54: 68-82

Yan, W.Y., Shaker, A., El-Ashmawy, N., 2015: Urban land cover classification using airborne LiDAR data: A review, Remote Sensing of Environment, 158: 295-310

Yu, X., Hyyppä, J., Holopainen, M., Mikko, V., 2010: Comparison of Area-Based and Individual Tree-Based Methods for Predicting plot-Level Attributes, Remote Sensing, 2: 1481-1495

Zhang, C., Qiu, F., 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: https://gis.zrinjevac.hr/