Klasifikacija 3D oblaka točaka iz zračnog laserskog skeniranja

Srdoč, Tedi

Master's thesis / Diplomski rad

2018

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:108:791629

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

SVEUČILIŠTE U ZAGREBU ŠUMARSKI FAKULTET

ŠUMARSKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ URBANO ŠUMARSTVO,

ZAŠTITA PRIRODE I OKOLIŠA

TEDI SRDOČ

KLASIFIKACIJA 3D OBLAKA TOČAKA IZ ZRAČNOG LASERSKOG SKENIRANJA

DIPLOMSKI RAD

Zagreb, 2018.

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ŠUMARSKI ODSJEK

KLASIFIKACIJA 3D OBLAKA TOČAKA IZ ZRAČNOG LASERSKOG SKENIRANJA

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: Tedi Srdoč

JMBAG: 0068219985

Broj indeksa: 881/2016

Datum odobrenja teme: 20. travnja 2018.

Datum predaje rada: 20. rujna 2018.

Datum obrane rada: 21. rujna 2018.

Zagreb, rujan 2018.

PODACI O DIPLOMSKOM RADU

Naslov:	Klasifikacija 3D oblaka točaka iz zračnog laserskog skeniranja
Title:	Classification of 3D point clouds from airborne laser scanning
Zavod:	Zavod za izmjeru i uređivanje šuma
Predmet:	Analiza i valorizacija prostora
Mentor:	Izv. prof. dr.sc. Ante Seletković
Student:	Tedi Srdoč
JMBAG:	0068219985
Akad. godina:	2017./2018.
Mjesto, datum obrane:	Šumarski fakultet Sveučilišta u Zagrebu, 21. rujna 2018. godine
Sadržaj rada:	Stranica: 22 Slika: 13 Tablica: 0 Navoda literature: 29
Ključne riječi:	3D oblak točaka, zračno lasersko skeniranje, LiDAR, urbane šume, daljinska istraživanja
Key words:	3D point clouds, airborne laser scanning, LiDAR, urban forests, remote sensing

Sažetak:

Visoko precizni trodimenzionalni 3D oblak točaka dobiven zračnim laserskim skeniranjem omogućuje karakterizaciju vertikalne strukture šumskih sastojina, a time i procjenu šumskih sastojina i pojedinačnih stabala. Cilj ovog diplomskog rada je na temelju podataka dobivenih laserskim skeniranjem iz zraka područja Grada Zagreba, prikazati obradu 3D oblaka točaka, klasifikaciju, vizualizaciju i različite načine i mogućnosti uporabe takvih podataka pri praćenju i izmjeri vegetacije urbanih područja. Za područje istraživanja određen je Grad Zagreba, konkretno Park Ribnjak.
Rezultati laserskog skeniranja su točni, prostorno određeni, trodimenzionalni 3D oblaci točaka koji vjerno opisuju skenirani prostor i odnose elemenata u njemu.
Glavni produkti dobiveni laserskim skeniranjem iz zraka (ALS) su točno izrađen DMT - digitalni model terena i DMVK – digitalni model visina krošanja.
Na temelju takvih podataka moguće je brzo i točno odrediti (izmjeriti) različite parametre vegetacije (visina, širina i površna krošanja).
Dobiveni rezultati ovog istraživanja prikazuju neke od mogućosti upotrebe 3D podataka dobivenih laserskim skeniranjem iz zraka i otvaraju nove mogućnosti u analizama i interpretaciji funkcija urbanih šuma i parkova.
Kroz daljnja istraživanja treba ispitati mogućnosti i usporediti točnost podataka dobivenih laserskim skeniranjem iz zraka i klasičnim aerofotogrametrijskim snimanjem iz zraka.

Summary:

High precision 3D point cloud obtained by airborne laser scanning allows the characterization of the vertical structure of forest stands, and estimation of forest stands and individual trees. The aim of this graduate thesis is to provide 3D point cloud processing, classification, visualization and various ways of using such data in monitoring and measurement of urban areas vegetation based on the data obtained by airborne laser scanning the Zagreb City area. The City of Zagreb, specifically Park Ribnjak, was designated for the area of research. Laser scanning results are accurate, spatially determined, three-dimensional 3D point clouds that faithfully describe the scanned space and the relationship of elements in it. The main products obtained by airborne laser scanning (ALS) are the DTM - digital terrain model and the CHM - a canopy height model. Based on such data, it is possible to quickly and precisely determine (measure) different vegetation parameters (height, width and canopy surface). The results of this research show some of the potential for using 3D data obtained by laser scanning from the air and open up new possibilities in analyzing and interpreting the functions of urban forests and parks. Further investigations should explore possibilities and compare the accuracy of data obtained by laser scanning from the air and classical aero-photogrammetric scanning from the air.

	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 *koristio* drugim izvorima osim onih koji su u njemu navedeni.″

_____

Tedi Srdoč

U Zagrebu, *20. rujna 2018.*

SADRŽAJ

1. UVOD 1

2. LIDAR 3

2.1. LASERSKO SKENIRANJE SA ZEMLJE 4

2.2. LASERSKO SKENIRANJE IZ ZRAKA 4

3. CILJ ISTRAŽIVANJA 7

4. MATERIJALI I METODE 8

4.1. PODRUČJE ISTRAŽIVANJA 8

4.1.1. Park Ribnjak 8

4.2. LIDARSKI PODACI 9

5. REZULTATI 13

5. ZAKLJUČAK 21

6. LITERATURA 22

1. UVOD

Šume, kao najrasprostranjeniji ekosustav na Zemlji, pružaju mnogo izravnih i neizravnih koristi za ljudsku dobrobit. One predstavljaju najveća zemaljska skladišta ugljika, imaju ključnu ulogu u globalnom ciklusu ugljika i regulaciji klime (Randerson i sur. 1997), olakšavaju ljudske zahtjeve za potražnju drva kroz proizvodnju biomase (Fisher i Turner 2008), a nedavno su prepoznate kao značajan ponor atmosferskog ugljika (Nabuurs i sur. 2003, Luyssaert i sur. 2010, Pan i sur. 2011) s važnom ulogom ublažavanja klimatskih promjena (FAO 2007, 2009).

Funkcije šuma urbanih prostora kao i šuma općenito mogu se definirati kao usluge, odnosno koristi koje može ostvariti ljudska populacija, direktno ili indirektno od funkcioniranja toga ekosustava (Constanza i sur. 1997). U današnjim promijenjenim ekološkim uvjetima, osobito u urbanim područjima sve značajnije postaju i druge, tzv. općekorisne funkcije šuma. Općekorisne funkcije šuma sastoje se od ekoloških (zaštitnih), socijalnih (društvenih) i kombiniranih socijalno-ekoloških funkcija. Iako je većina tih usluga indirektna i neopipljiva, one imaju vrlo važnu ulogu u održivom gospodarenju urbanim ekosustavima i značajno doprinose dobrobiti lokalne zajednice. U posljednje vrijeme šira društvena zajednica postaje sve svjesnija tih usluga koje pružaju urbani šumski ekosustavi te postoje brojne studije koje ih pokušavaju identificirati i kvantificirat (Posavec i sur. 2010).

Društvo prepoznaje urbane šume kao vrijednu imovinu za rast i napredak.

Gradska stabla ne samo da imaju pozitivan utjecaj na vrijednost imovine i pomoć u očuvanju energije zasjenom i hlađenjem zgrada, ona također pridonose broju zdravstvenih koristi poboljšanjem kvalitete našeg zraka i vode (Krueger i Seidel 2016).

Da bi identificirali i kvantificirali vrijednost takvih urbanih šuma potrebno je sakupiti što više kvalitetnih informacija o samom drveću i njegovom stanju unutar urbanih područja. Upravo metode daljinskih istraživanja omogućuju brz i efikasan način prikupljanja velikog broja kvantitativnih i kvalitativnih podataka o urbanom drveću i vegetaciji.

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 oblaka 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 (Kičić i sur. 2017).

Nekoliko je pravaca istraživanja LiDAR tehnologije za potrebe urbanog šumarstva; prepoznavanje i kartiranje pojedinačnih stabala (Holopainen i sur., 2013), određivanje indeksa lisne površine (LAI) (Lin i West, 2016; Klinberg i sur., 2017), izrada preciznih digitalnih modela terena (Chen i sur., 2012), procjenu biomase (Berta 2017, Gleason i sur., 2012., Shao i sur., 2018, Wang i sur., 2016) itd.

U ovom diplomskom radu prikazati će se dio upotrebe i mogućnosti LiDAR tehnologije, pri praćenju vegetacije urbanih područja, konkretno Parkova Grada Zagreba.

2. LIDAR

LIDAR potpuno automatiziran, aktivan, optičko-mehanički postupak prikupljanja prostornih podataka dostupnih s aktualnih snimališta (Gajski 2007). LIDAR je skraćenica od LIght Detecting And Ranging - detekcija i određivanje udaljenosti objekata pomoću svjetlosnih valova.

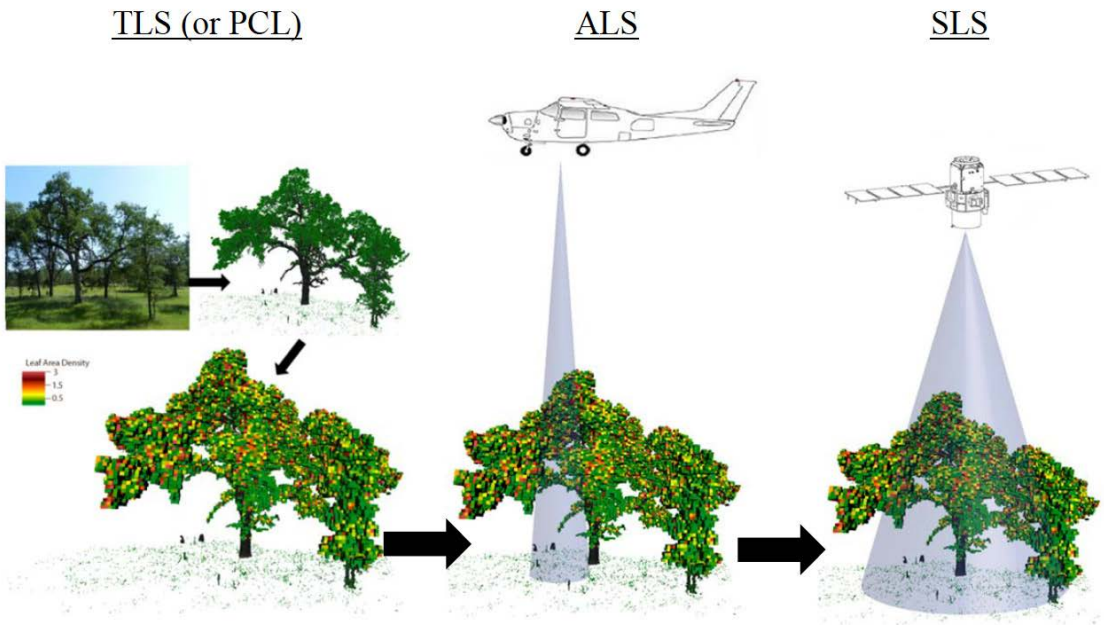
LIDAR sustav koristi blisko-infracrveni dio elektro-magnetskog spektra (1064 nm) za aktivno prikupljanje podataka, danju ili noću, u sjeni, ali i u uvjetima slabije vidljivosti (npr. pod oblacima).

U ovisnosti o platformi koja nosi skener (slika 1), 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) pomoću svjetlosnih valova.



Slika 1. Podjela laserskog skeniranja s obzirom na nositelja uređaja za snimanje.

2.1. LASERSKO SKENIRANJE SA ZEMLJE

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 (Kičić 2017).

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).

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 (Kičić 2017).

2.2. LASERSKO SKENIRANJE IZ ZRAKA

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 (Kičić, 2017.)

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).

Prilikom laserskog skeniranja iz zraka linije snimanja su uobičajeno okomite na smjer leta letjelice koja nosi skener. Pulsni skener pritom emitira 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 raspršti 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).

Prvotna namjena laserskih skeniranja iz zraka bila je 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).

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 (Kičić, 2017.).

Balenović i dr., (2013) navode da su dva osnovna načina (pristupa) pridobivanja podataka o šumskim sastojinama na temelju ALS podataka, ovisno da li se radi o procjeni parametara pojedinačnih stabala (eng. individual-tree-based approach - ITB) ili procjeni srednjih sastojinskih parametara (eng. area-based approach - AB) (Reutebuch i dr., 2005; Yu i dr., 2010).

Kod AB metoda srednje (prosječne) sastojinske vrijednosti za određeno područje (npr. ploha, sastojina) procjenjuju se primjenom statističkih (regresijskih, neparametarskih, diskriminantnih) analiza i uspostavljenih odnosa (modela) između ALS podataka (procesirani oblak točaka, digitalni model visina i visina krošnje) i terenski izmjerenih varijabli.

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…(Berta, 2017.)

3. CILJ ISTRAŽIVANJA

Visoko precizni trodimenzionalni 3D oblak točaka dobiven zračnim laserskim skeniranjem omogućuje karakterizaciju vertikalne strukture šumskih sastojina, a time i procjenu šumskih sastojina i pojedinačnih stabala. Cilj ovog diplomskog rada je na temelju podataka dobivenih laserskim skeniranjem iz zraka područja Grada Zagreba, prikazati obradu 3D oblaka točaka, klasifikaciju, vizualizaciju i različite načine i mogućnosti uporabe takvih podataka pri praćenju i izmjeri vegetacije urbanih područja.

4. MATERIJALI I METODE

4.1. PODRUČJE ISTRAŽIVANJA

Za područje istraživanja određen je Grad Zagreb, konkretno Park Ribnjak. LiDAR-ski podaci (snimanje je obavila tvrtka GISDATA u proljeće 2012. godine za naručitelja Grad Zagreb), ustupljeni su od strane Grada Zagreba za potrebe istraživanja i ovim putem zahvaljujemo.

4.1.1. Park Ribnjak

Uz istočne zidine Kaptola proteže se park Ribnjak (slika 2). Nalazi se između ulice Ribnjak (na istoku) i zidina zagrebačke Katedrale. Ulica Ribnjak je, iako ne najveća najširа ni najduža (već upravo suprotno), jedna od najvažnijih gradskih ulica koja spaja Donji grad sa Medveščakom, Mihaljevcem i ostalim sjevernim dijelovima Grada. Ribnjak je naziv biskupskog parka istočno od stolne crkve - današnje zagrebačke Katedrale). Ime je dobio po biskupskim ribnjacima, koji su se ovdje nalazili sve do 19. stoljeća. Tada je cijeli prostor pretvoren u perivoj engleskog tipa, s vodopadima, egzotičnim biljkama i ukrasnim kipovima. Park je uređen na poticaj biskupa Alagovića, 1829. godine.

Ribnjak je trebao postati i parkom skulptura, ali ta ideja nikada nije do kraja ostvarena. U njemu se nalazi tek spomenik Stid, Antuna Augustinčića, te spomenik hrvatskom pjesniku Ivanu Goranu Kovačiću.

Park se danas prostire na gotovo 40.000 četvornih metara površine i u njemu se može vidjeti trideset godina stara tisa, stari primjerak atlaskog cedra, mnoštvo magnolija i likvidambara….



Slika 2. Park Ribnjak

4.2. LIDARSKI PODACI

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

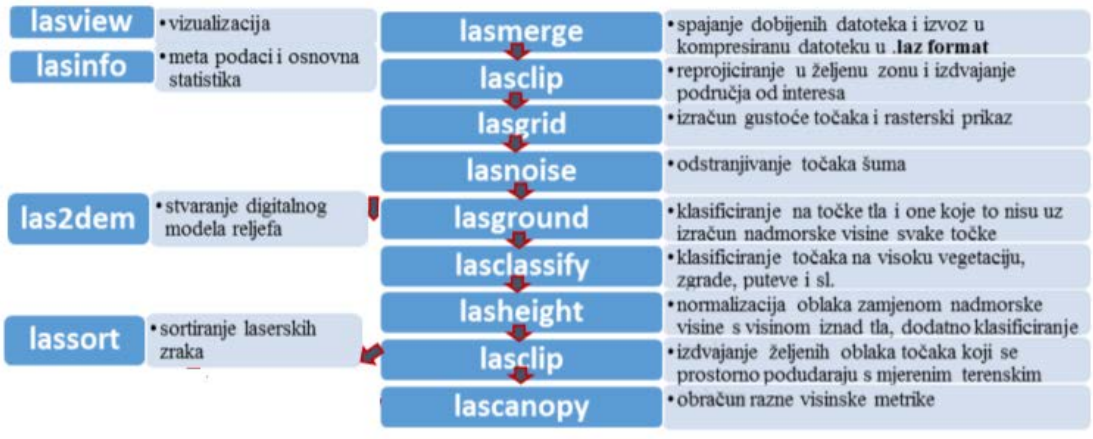
Tehničke karakeristike LiDAR senzora (LEICA Geosystems):

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

Sva obrada prikupljenih LiDAR-skih podataka (vizualizacija, obrada, klasifikacija, pretvorba i ekstrakcija „sirovih” podataka) obavljena je pomoću LAStools i Quick Terrain Modeler (QTM) softvera.

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).

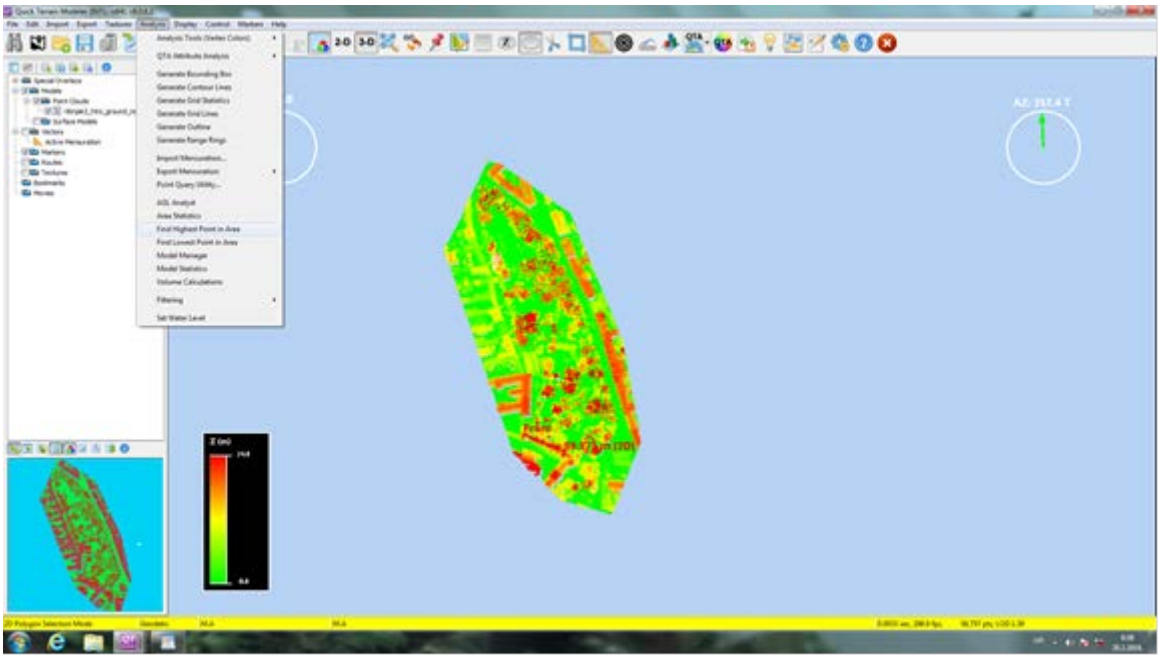
Korišteni alati i proces rada je prikazan u navedenoj shemi (Berta 2017);



Slika 3. Korišteni alati i shema procesa rada

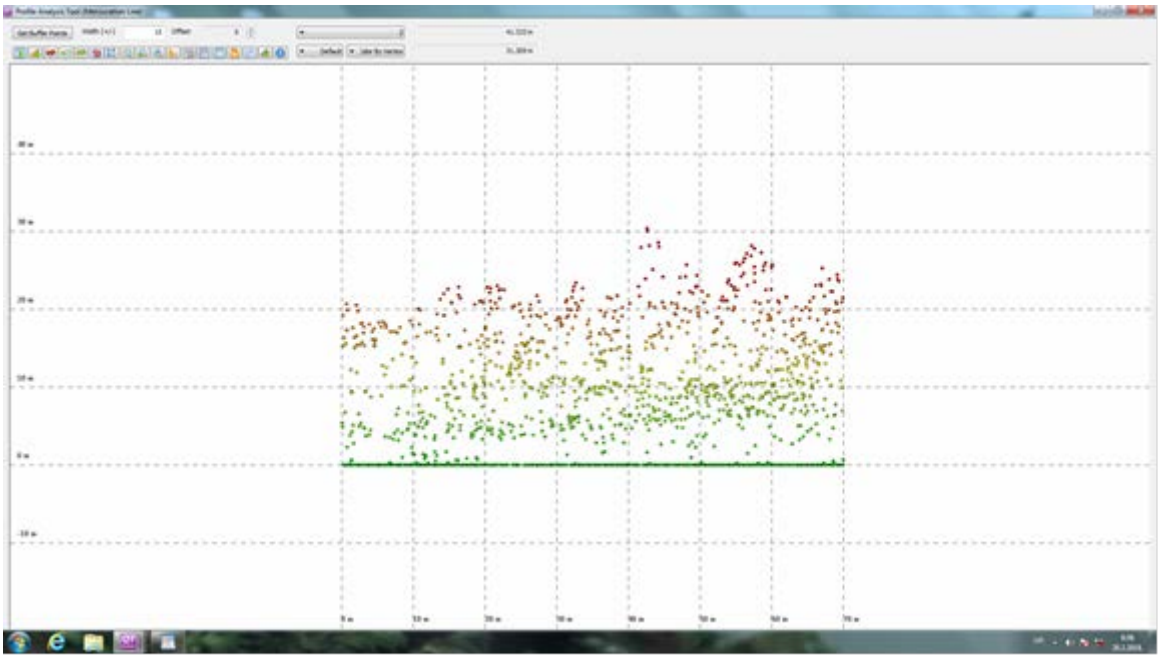
Kako bi se moglo pristupiti analizi pojedinog stabla, ona se prvo moraju detektirati iz LiDAR oblaka točaka, a to se radi kroz dva bitna koraka. Prvi je izrada digitalnog modela terena, a drugi je detekcija pojedinačnog stabla što uključuje identifikaciju njegove krošnje (Zhang i Qiu, 2012). Digitalni 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 (Kičić, 2017).

Pomoću Quick Terrain Modeler (QTM) softvera, iz 3D oblaka točaka poligonom se izdvajaju pojedinačna stabla odnosno njihove krošnje, a visina stabla se poistovjećuje s najvišom točkom u izdvojenom oblaku točaka (slika 4).



Slika 4. Prikaz visine stabala pomoću najviše izdvojene točke iz oblaka

QTM nam omogućuje i izradu vertikalnog profila drvoreda, pomoću 'Measuration line' alata, opcija 'Profile Analysis Tool' čime se otvara novi prozor u kojem su pokazane sve točke u zadanim okvirima (duljina i širina obuhvata). Svaka točka predstavljena je određenom vrijednosti nadmorske visine (slika 5).



Slika 5. Vertikalni prikaz oblaka točaka i njihova pripadajuća visina

5. REZULTATI

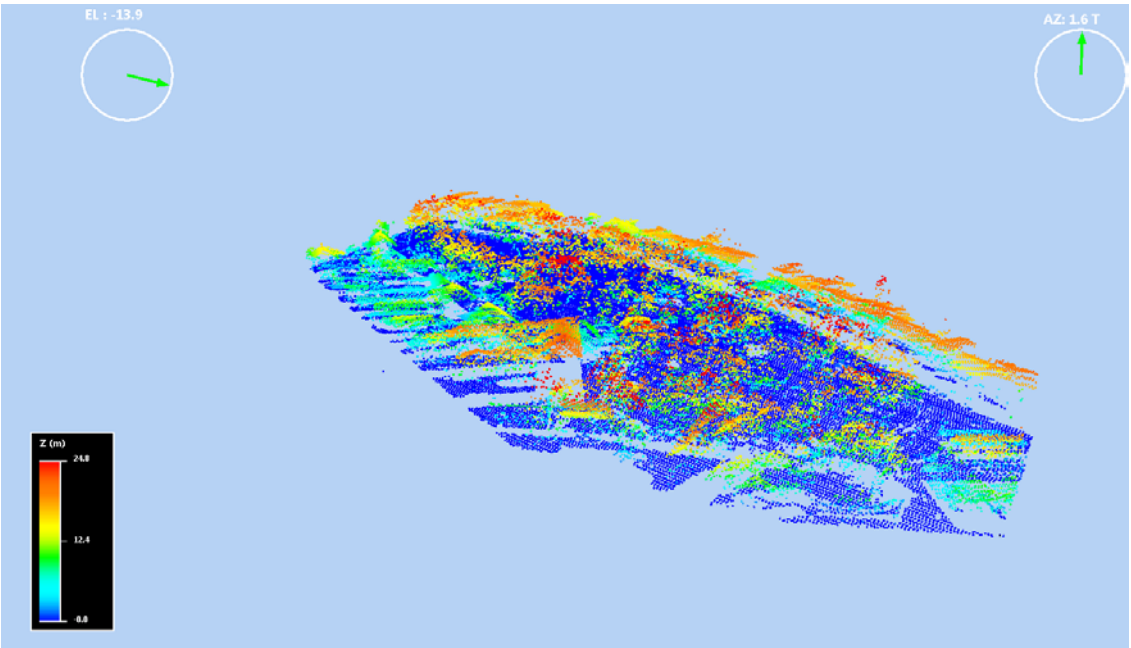
Na temelju obrađenih Lidarskih podataka za Park Ribnjak izdvojene su četiri klase (kategorije);

- Tlo
- Vegetaciju višu od jednog metra
- Zgrade (objekti)
- Neklasificirano

```
lasinfo

umber of first returns:        46835
number of intermediate returns: 851
number of last returns:         46830
number of single returns:       37759
covered area in square meters/kilometers: 97412/0.10
point density: all returns 0.58 last only 0.48 (per square meter)
      spacing: all returns 1.31 last only 1.44 (in meters)
overview over number of returns of given pulse: 37759 16480 2426 92 0 0 0
histogram of classification of points:
            4424  unclassified (1)
           29126  ground (2)
           14729  high vegetation (5)
            8478  building (6)
```

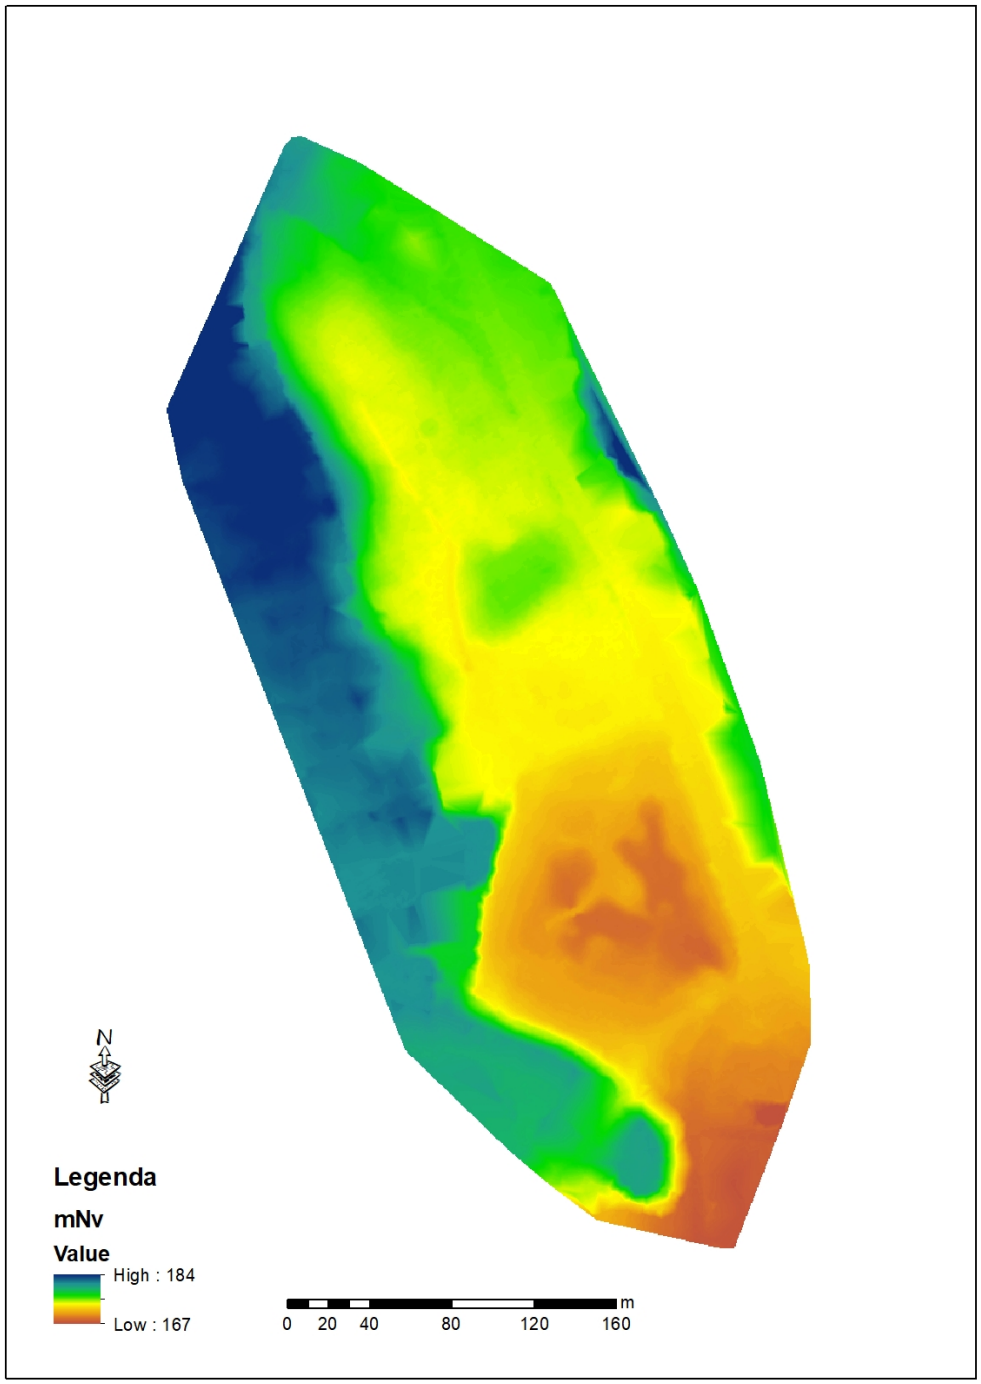
Slika 6. Prikaz obrađenih Lidarskih podataka; vrijednosti odbijanja, gustoće točaka, klasifikacija



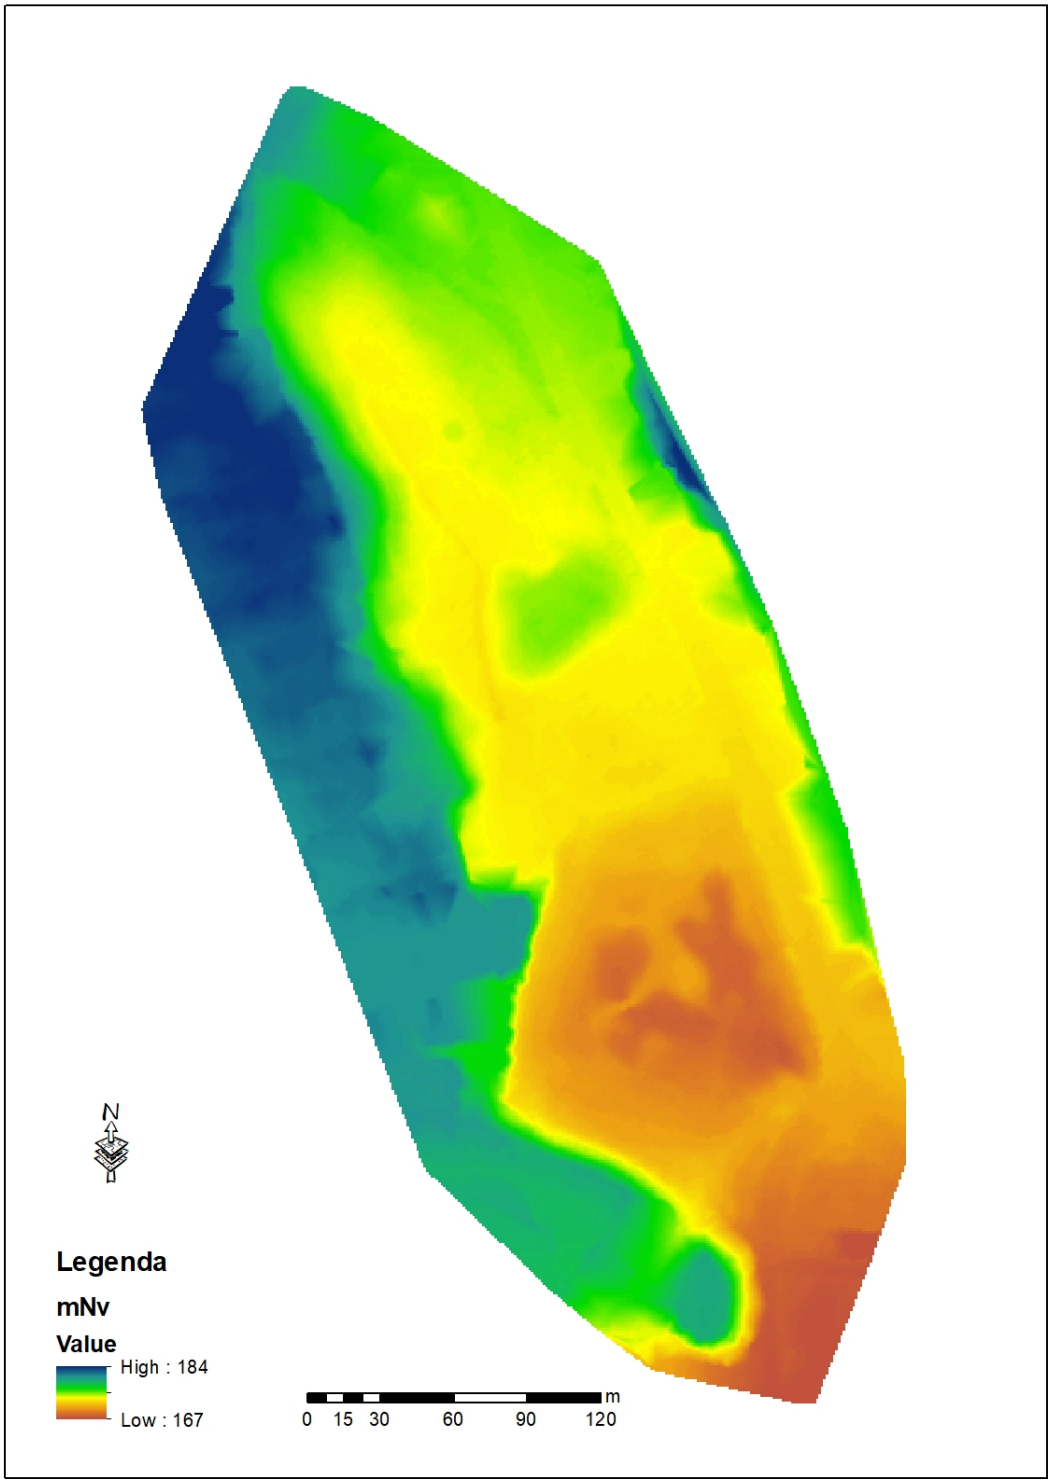
Slika 7. Prikaz 3D oblaka točaka za prethodno navedene četiri klase; tlo, vegetacija viša od jednog metra, zgrade (objekti) i neklasificirano

Dobiven je 3D oblak točaka za navedene četiri kategorije (slika 7), koji 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. Na taj način omogućena je relativno jednostavna izmjera i prepoznavanje pojedinačnih stabala od drugih objekata. Dobro provedena klasifikacija omogućila je točnu izmjeru visina pojedinih stabala jer daje vrlo precizne podatke o nadmorskoj visini svake točke unutar 3D oblaka podataka.

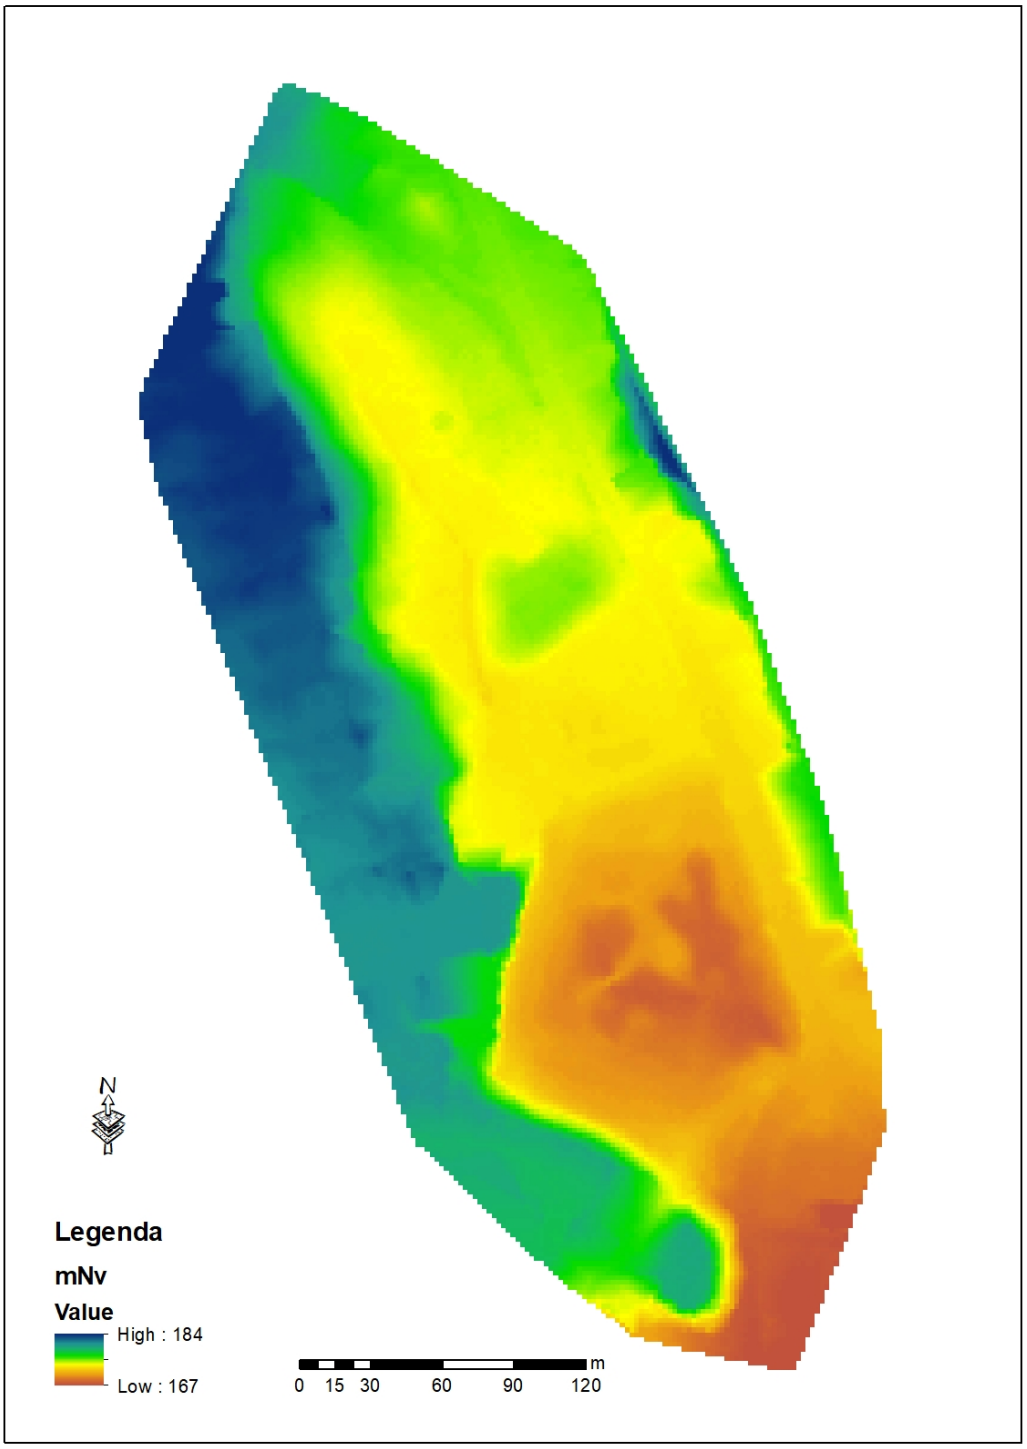
Izrađeni su i digitalni modeli terena - DMT (različite veličine piksela; 0,5m, 1m, 2m i 5m) i visina krošanja (DMVK) za istraživano područje (slika 8, slika 9, slika 10, slika 11). Na taj način (razlikom vrijednosti između DMVK i DMT) izmjerene su visine pojedinačnih stabala na istraživanom području. Sama točnost izrađenih DMT-a i DMV-a ovisi o gustoći podataka unutar 3D oblaka točaka.



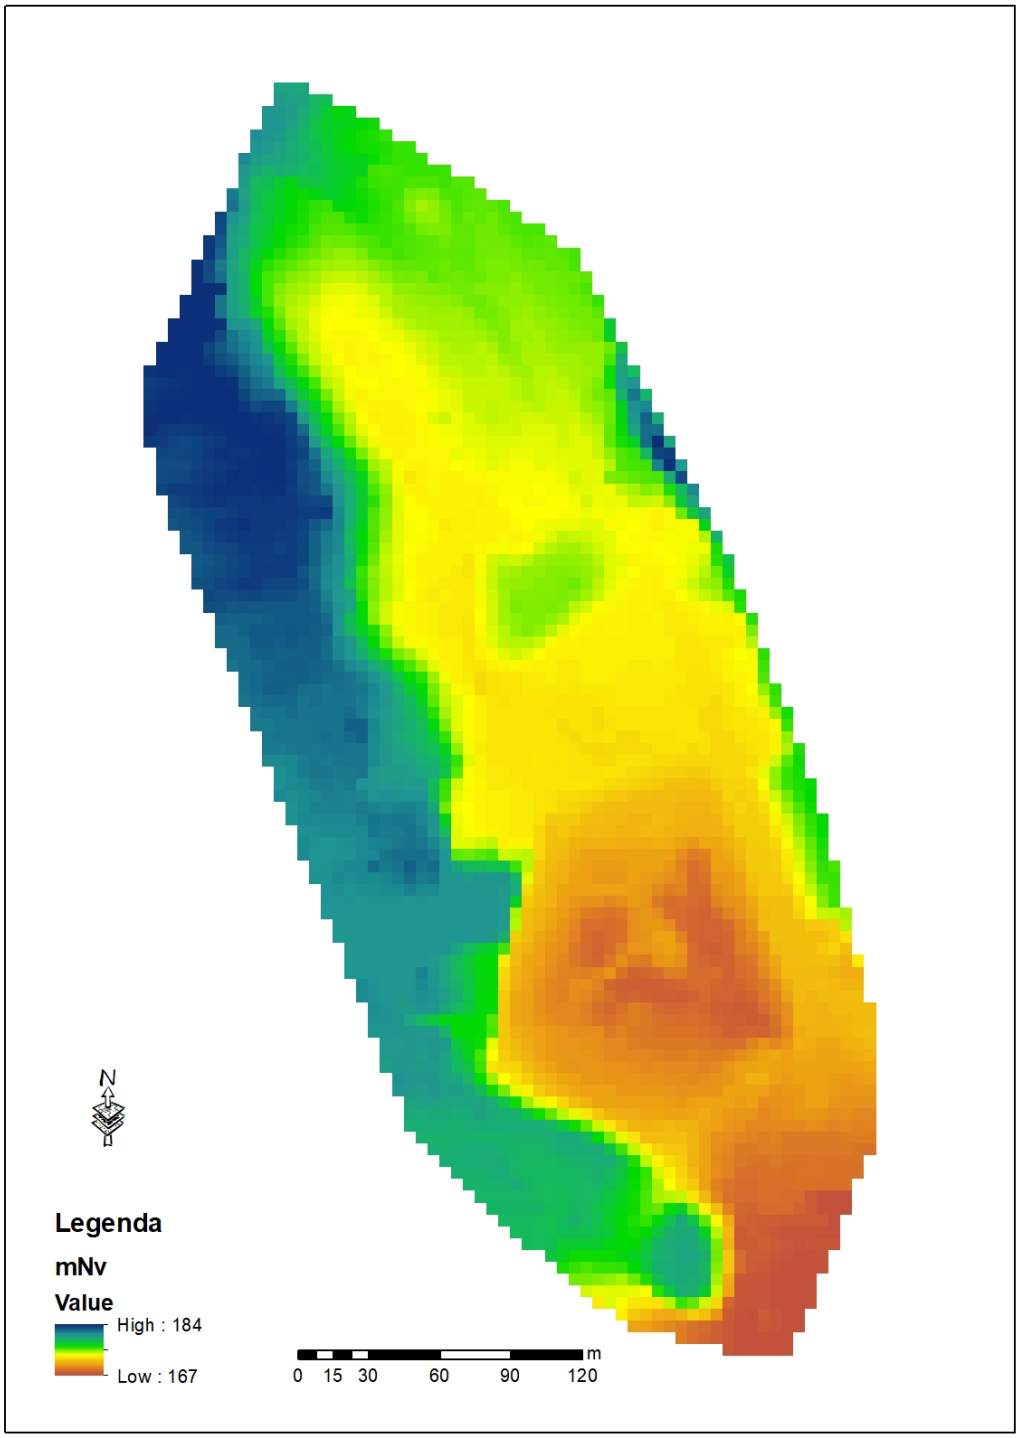
Slika 8. Prikaz Digitalnog modela terena (DMT) sa veličinom piksela 0,5m



Slika 9. Prikaz Digitalnog modela terena (DMT) sa veličinom piksela 1m



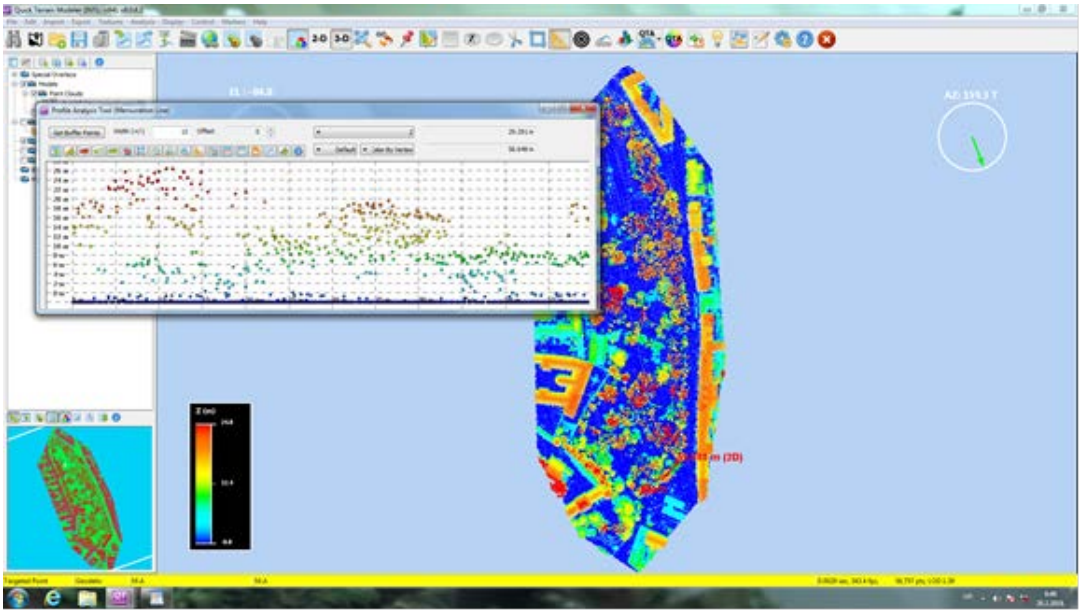
Slika 10. Prikaz Digitalnog modela terena (DMT) sa veličinom piksela 2m



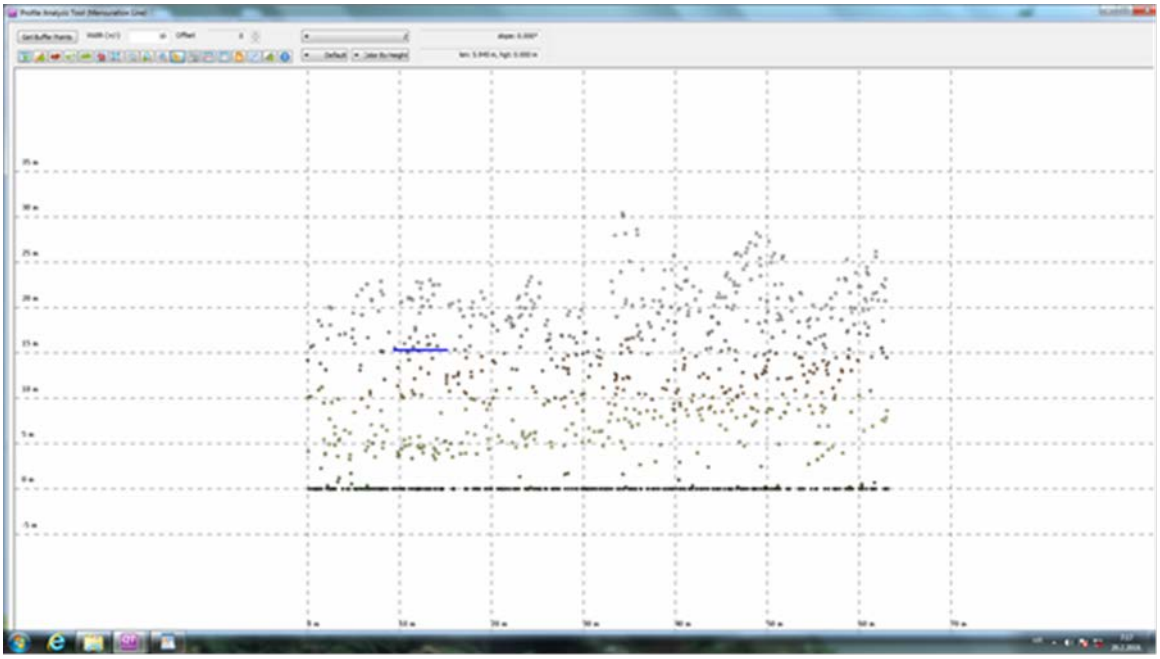
Slika 11. Prikaz Digitalnog modela terena (DMT) sa veličinom piksela 5m

Na temelju izrađenih modela terena (DMT) i visina krošanja (DMVK) i očitavanjem najviših visinskih vrijednosti u 3D oblaku točaka moguće je odrediti i visinu pojedinačnog stabla (Visinu stabla predstavlja visinska razlika između DMT i DMVK)., kao i delineirati krošnju i na taj način odrediti njezinu površinu.

Izrađeni su i vertikalni profili pomoću kojih se može jasnije razdvojiti pojedinačno stablo i točnije odrediti njegova visina i širina krošnje (slika 12 i 13).



Slika 12. Očitanje najviše visinske vrijednosti i delineacija krošnje



Slika 13. Određivanje širine krošanja i visine stabala

Kao što je prikazano na slikama 12 i 13, obavljena je izmjera visina i širina krošanja za cijelo istraživano područje.

U diplomskom radu su prikazane metodološke mogućnosti upotrebe laserskog zračnog skeniranja pri izmjeri i klasifikaciji pojedinačnih stabala. Razvidno je da nam lasersko zračno skeniranje kao rezultat daje visoko precizni trodimenzionalni 3D oblak točaka pomoću kojeg generiramo visoko precizni digitalni model terena (DMT) kao i digitalni model visina (DMV). Prednost ovakvog načina prikupljanja prostornih podataka očituje se u brzini obrade, visokoj preciznosti i plastičnosti samih modela. Nadalje laserski sustavi su aktivni sustavi koji za razliku od pasivnih sustava pružaju mogućnost dobivanja podataka i o objektima koji se nalaze ispod gornjeg sloja npr. vegetacije. Na taj način osim preciznih podataka o vrijednostima gornjeg sloja vegetacije možemo i imamo uvid u vertikalnu strukturu šume ili sastojine, te možemo izdvojiti pojedinačna stabla.

Lidarske snimke na kojima je odrađeno ovo istraživanje nisu visoke gustoće oblaka točaka, naprotiv na pojedinim dijelovima gustoća je između 0,5 – 1,5 točaka/m^2, a i snimljene su u ožujku kada vegetacija nije pod listom. Unatoč tome i takav materijal predstavlja jako dobru podlogu za praćenje, planiranje i izmjeru stabala u urbanom području.

Upotreba podataka iz laserskog zračnog snimanja u analizi urbane vegetacije ne očituje se samo kroz mogućnost izmjere pojedinačnih stabala, već u mogućnosti vizualizacije prostora, analiza, prikupljanja podataka o stanju vegetacije...

5. ZAKLJUČAK

- Rezultati laserskog skeniranja su točni, prostorno određeni, trodimenzionalni 3D oblaci točaka koji vjerno opisuju skenirani prostor i odnose elemenata u njemu.

- Glavni produkti dobiveni laserskim skeniranjem iz zraka (ALS) su točno izrađen DMT - digitalni model terena i DMVK – digitalni model visina krošanja.

- Na temelju takvih podataka moguće je brzo i točno odrediti (izmjeriti) različite parametre vegetacije (visina, širina i površna krošanja).

- Dobiveni rezultati ovog istraživanja prikazuju neke od mogućosti upotrebe 3D podataka dobivenih laserskim skeniranjem iz zraka i otvaraju nove mogućnosti u analizama i interpretaciji funkcija urbanih šuma i parkova.

- Kroz daljnja istraživanja treba ispitati mogućnosti i usporediti točnost podataka dobivenih laserskim skeniranjem iz zraka i klasičnim aerofotogrametrijskim snimanjem iz zraka.

6. LITERATURA

1. 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
2. Berta, A., 2017.: Procjena šumske biomase pomoću lidar tehnologije u degradiranim šumama brežuljkastog i nizinskog vegetacijskog pojasa u središnjoj Hrvatskoj, Disertacija, Šumarski fakultet, Zagreb
3. 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
4. Costanza, R., R. d'Arge, R. de Groot, S. Farber, M. Grasso, B. Hannon, K. Limburg, S. Naeem, R. V. O'Neill, J. Paruelo, R. G. Raskin, P. Sutton, M. van der Belt, 1997.: The value of the world's ecosystem services and natural capital, Nature, 387: 253-260
5. FAO 2007: The State of food and agriculture, Paying farmers for environmental services
6. FAO 2009: The State of food and agriculture, Livestock in the balance
7. Fisher, B., K. Turner, M. Zylstra, R. Brouwer, R. de Groot, S. Farber, P. Ferraro, R. Green, D. Hadley, J. Harlow, P. Jefferiss, C. Kirkby, P. Morling, S. Mowatt, R. Naidoo, J. Paavola, B. Strassburg, D. Yu, A. Balmford, 2008.: Ecosystem services and economic theory: Integration for policy-relevant research, Ecological applications, 18 (8): 2050-2067
8. Gajski, D. 2017.: Osnove laserskog skeniranja iz zraka, Ekscentar, 10: 16-22
9. Gleason, Colin J., J. Im, 2012.: Forest biomass estimation from airborne LiDAR dana using machine learning approaches, Remote Sensing of Enviroment, 125: 80-91
10. Holopainen, J.K., J. D. Blande, 2013.: Where do herbivore-induced plant volatiles go?, Frontiers in Plant Science, 4
11. Klinberg, J., J. Konarska, F. Lindberg, L. Johansson, S. Thorsson, 2017.: Mapping leaf area of urban greenery using aerial LiDAR and ground-based measurments in Gothenburg, Sweden, Urban Forestry & Urban Greening, 26: 31-40
12. Krueger, J. i M. Seidel, 2016.: LiDAR Supports Urban Forrestry Application in the Chicago Region, LiDAR Magazine, 6 (3)

13. 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
14. Lefsky, M. A., B. W. Cohen, G. G. Parker, D. J. Harding, 2002.: Lidar Remote Sensing for Ecosystem Studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists, BioScience, 52 (1): 19-30, https://doi.org/10.1641/0006-3568(2002)052[0019:LRSFES]2.0.CO;2
15. Lin, Y., G. West, 2016.: Retrieval of effective leaf area indeks (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
16. Luyssaert, S., P. Ciais, S. L. Piao, E.-D. Schultze, M. Jung, S. Zaehle, M. J. Schelhaas, M. Reichstein, G. Churkina, D. Papale, G. Abril, C. Beer, J. Grace, D. Loustau, G. Matteucci, F. Magnani, G. J. Nabuurs, H. Verbeeck, M. Suklava, G. R. van der Werf, I. A. Janssens, 2010.: The European carbon balance. Part 3: forests, Global Change Biology, 16 (5): 1429-1450
17. Miler, M., A. Đapo, B. Kordić, I. Medved, 2007: Terestrički laserski skeneri, Ekscentar 10: 35-38
18. Nabuurs, G. J., M. J. Schelhaas, 2003.: Spatial distribution of whole-tree carbon stocks and fluxes across the forests of Europe: where are the options for bio-energy?, Biomass and Bioenergy, 24 (4-5): 311-320
19. Pan, Y., R. A. Birdsey, J. Fang, R. Houghton, P. E. Kauppi, W. A. Kurz, O. L. Phillips, A. Shvidenko, S. L. Lewis, J. G. Canadell, P. Ciais, R. B. Jackson, S. W. Pacala, A. D. McGuire, S. Piao, A. Rautiainen, S. Sitch, D. Hayes, 2011.: A Large and Persistent Carbon Sink in the World's Forests, Science, 333 (6045): 988-993
20. 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
21. Posavec, S., J. Franjić, Ž. Škvorc, M. Lovrić, 2010.: Koliko cijenimo socio-ekološke funkcije šuma?, Hrvatsko Komunikološko Društvo, Međunarodni Znanstveni Skup DIT 2010.

22. Randerson, J.T., M.V. Thompson, T.J. Conway, I.Y. Fung, C.B. Field, 1997.: The contribution of terrestrial sources and sinks to trends in the seasonal cycle of atmospheric carbon dioxide, Glob. Biogeochem. Cycles, 11: 535-560
23. Reutebuch, S. E., H. E. Andersen, R. J. McGaughey, 2005.: Light detection and ranging (LiDAR): An emerging tool for multiple resource inventory, Journal of Forestry, 103 (6): 286-292
24. Seletković, A., M. Kičić, A. Berta, R. Pernar, M. Ančić, J. Kolić, I. Balenović, 2017.: Usporedba lidarskih i terenskih podataka pri izmjeri visine stabala u urbanim područjima, Nova mehanizacija šumarstva : Časopis za teoriju i praksu šumarskoga inženjerstva, 38 (1): 43-56
25. Shao, G., G. Shao, J. Gallion, Michael R. Saunders, … S. Fei 2018.: Improving Lidar-based aboveground biomass estimation of temperate hardwood forests with varying site productivity, Remote Sensing of Environment, 204: 872-882
26. Wang, C., Q. Chen, Ronald E. McRoberts, Philip J. Radtke , 2016.: Forest aboveground biomass mapping and estimation across multiple spatial scales using model-based inference, Remote Sensing of Enviroment, 184: 250-260
27. Wehr A., U. Lohr, 1999.: Airborne laser scanning – an introduction and overview, ISPRS Journal of Photogrammetry & Remote Sensing, 54: 68-82
28. Yu, X., J. Hyyppxä, M. Holopainen, M. Vastaranta, 2010: Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes, Remote Sens 2 (6): 1481-1495, DOI: http://dx.doi.org/10.3390/rs2061481
29. Zhang C., F. Qiu, 2012: Mapping Individual Tree Species in an Urban Forest Using Airborne Lidar Dana and Hyperspectral Imagery, Photogrametric Engineering & Remote Sensing 78 (10): 1079-1087