Procjena šumske biomase pomoći LIDAR tehnologije u degradiranim šumama brežuljkastoga i nizinskoga vegetacijskog pojasa u središnjoj Hrvatskoj

Berta, Alen

Doctoral thesis / Disertacija

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:108:171875

Rights / Prava: Attribution-NonCommercial-ShareAlike 4.0 International/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 4.0 međunarodna

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

Sveučilište u Zagrebu

Šumarski fakultet

Alen Berta

PROCJENA ŠUMSKE BIOMASE POMOĆU LIDAR TEHNOLOGIJE U DEGRADIRANIM ŠUMAMA BREŽULJKASTOGA I NIZINSKOGA VEGETACIJSKOGA POJASA U SREDIŠNJOJ HRVATSKOJ

DOKTORSKI RAD

Mentor:

Izv.prof.dr.sc. Ante Seletković

Zagreb, 2017

Sveučilište u Zagrebu

Šumarski fakultet

Alen Berta

FOREST BIOMASS ASSESSMENT BY LIDAR TECHNOLOGY IN DEGRADED FORESTS OF HILLY AND LOWLAND VEGETATION AREA IN CENTRAL CROATIA

DOCTORAL THESIS

Supervisor:

Associate prof. Ante Seletković, PhD

Zagreb, 2017

PODACI O MENTORU

Ante Seletković rođen je 28. rujna 1975. godine u Zagrebu. Po narodnosti je Hrvat, te državljanin Republike Hrvatske. Osnovnu školu i gimnaziju općeg smjera završio je u Zagrebu. Šumarski fakultet Sveučilišta u Zagrebu upisao je 1994. godine. Diplomirao je u veljači 1999. godine obranivši diplomski rad "Ispitivanje klijavosti sjemena Crne johe“.

Nakon odsluženja vojnog roka, 14. veljače 2000. godine, zapošljava se u Šumarskom institutu Jastrebarsko kao znanstveni novak.

Poslijediplomski znanstveni studij “Uređivanje šuma” upisao je akademske godine 2000/2001., a magistarski rad pod naslovom "Upotrebljivost višefaznog uzorka u inventarizaciji šumskog prostora" obranio je 4. prosinca 2003. godine. Od 01. rujna 2004. godine radi na Šumarskom fakultetu Sveučilišta u Zagrebu, Zavodu za izmjeru i uređivanje šuma, kao asistent na predmetima «Izmjera terena s osnovama kartografije» i «Daljinska istraživanja i GIS u šumarstvu».

Doktorski rad pod naslovom „Usporedba digitalne i vizualne interpretacije satelitske snimke visoke rezolucije“ obranio je 18. prosinca 2007. godine i time stekao akademski stupanj doktora znanosti. U suradničko zvanje višega asistenta izabran je 28. veljače 2008. godine, a u znanstveno-nastavnom zvanju docenta je od 21. siječnja 2009. godine. U znanstvena zvanja biran je 07. listopada 2008. godine (znanstveni suradnik), 24. veljače 2010. godine (viši znanstveni suradnik) i 15. lipnja 2016. godine (znanstveni savjetnik). U znanstveno nastavno zvanje izvanredni profesor izabran je 20. ožujka 2013. godine.

U Popis znanstvenika i istraživača Ministarstva znanosti, obrazovanja i športa upisan je pod registarskim brojem 232823.

Znanstvenoistraživačku djelatnost ostvaruje u sklopu projekata Ministarstva znanosti, obrazovanja i športa te ugovornih projekata Šumarskoga fakulteta s poduzećem "Hrvatske šume" d.o.o. Zagreb. Do sada je vodio ili vodi dva nacionalna znanstveno-istraživačka projekta: Primjena satelitskih snimaka visoke rezolucije pri planiranju i gospodarenju nizinskih šuma hrasta lužnjaka (2006.-2010.) - HŠ d.o.o, Mogućnosti interpretacije satelitskih snimaka za potrebe planiranja i gospodarenja šumama (2011.-2015.) - HŠ d.o.o.

Kao suradnik je sudjelovao na 6 nacionalna znanstveno-istraživačka projekata: Rast i razvoj šuma posebne namjene (MZOŠ 00240105, 2000.-2002.), Oplemenjivanje i šumsko sjemenarstvo (MZOŠ 0024001, 2002.-2005.), Praćenje zdravstvenog stanja šuma metodama daljinskih istraživanja (MZOŠ 068-0681966-2786, 2007. -)....

Do sada je, samostalno ili u koautorstvu, objavio više od 40 znanstvenih i stručnih radova. Sudjelovao je na petnaest domaćih i međunarodnih znanstveno-stručnih skupova i seminara. Recenzirao je više radova za časopise: Croatian Journal of Forest Engineering, Radovi - Jastrebarsko, Nova mehanizacija šumarstva, Šumarski list, Periodicum biologorum.

Od 2010. godine član je uredničkog odbora časopisa: Šumarski list (ISSN 0373-1332).

U okviru nastavnih aktivnosti sudjeluje u izvođenju predavanja, vježbi i terenske nastave iz više predmeta na preddiplomskim, diplomskim i poslijediplomskim studijima na Šumarskom fakultetu Sveučilišta u Zagrebu. Od 2011. godine voditelj je prediplomskog studija Urbano šumarstvo zaštita prirode i okoliša.

Član je Hrvatskog šumarskog društva, Hrvatskog kartografskog društva, Hrvatskog biometrijskog društva, Znanstvenog vijeća za daljinska istraživanja i fotointerpretaciju pri HAZU. Aktivno se služi engleskim jezikom. Oženjen je i otac dvoje djece.

SAŽETAK

Radi praćenja količine vezanog (tzv. priljeva) i emitiranog (tzv. odljeva) ugljika, kao i praćenja promjena, pozitivnih i negativnih, u veličini rezervoara (ponora) ugljika potrebno je razviti brze i jednostavne metode pomoću kojih se u vrlo kratkom roku mogu sakupiti velike količine podataka na velikom području, potrebnih za obračun ovih parametara. To se može postići implementirajući LIDAR tehnologiju za obračun nadzemne biomase vegetacije na velikim područjima i posljedično obračun vezanog ugljika odnosno ugljičnog dioksida, što u Republici Hrvatskoj predstavlja prvo istraživanje ovakvog tipa.

Jedan od ciljeva ovog istraživanja je izraditi model za utvrđivanje nadzemne biomase degradiranih šumskih područja u stadiju šikara (*hipoteza 1*), što je jedan od glavnih nedostajućih podataka pri određivanju količine vezanog ugljika i promjena u rezervoaru ugljika prilikom izrade Nacionalnog izvješća o stakleničkim plinovima.

Također će se utvrditi utjecaj manjih gustoća oblaka točaka na konačni rezultat (*hipoteza 2*). Korištenje nižih gustoća LIDAR oblaka radi dobivanja zadovoljavajućih i dovoljno preciznih podataka je direktno povezano s troškom snimanja koje predstavlja najveću stavku troška u ovakvim projektima.

Dio istraživanja je proveden u nizinskom području nadmorske visine približno 120 m, a drugi dio istraživanja je proveden u brežuljkastom području na nadmorskim visinama od približno 250 do 550 m. Terenskim prikupljanjem podataka (68 ploha), obradom LIDAR podataka (prosječne gustoće 1,38 točaka/m^2) i na kraju regresijskim analizama izrađeni su regresijski modeli za procjenu biomase degradiranih šumskih područja nizinskog i brdskog vegetacijskog pojasa.

Utvrđeno je da je izrađeni model za nizinsko područje koeficijenta determinacije (R^2) 0,75, dok je za brdsko područje 0,60. Također je utvrđeno da gustoća oblaka točaka nema utjecaja na prikladnost modela do određenih granica (do 0,4 točke/m^2) čime su obje *hipoteze* uspješno potvrđene.

Primjenom izrađenih modela na cijelo područje, izračunate su vrijednosti šumske nadzemne biomase za cijelo istraživano područje. Isto tako, napravljena je usporedba prikladnosti izrađenih modela na osnovu riječih oblaka točaka za primjenu na cijelom području.

Na kraju ovog istraživanja, osim taksativno navedenih određenih praktičnih zaključaka i ograničenja pri samom istraživanju (vremenska nesukladnost LIDAR i terenskih podataka, nepostojanje lokalnih modela za procjenu biomase pojedinih stabala i sl.), navedene su i preporuke za daljnja istraživanja (prevladavanje postojećih ograničenja, ponavljanje ovog tipa istraživanja za biogeografska područja koja nisu obuhvaćena ovim istraživanjem i uvrštavanje dodatnih podloga i sl.).

SUMMARY

In order to enable monitoring of the sequestered and emitted carbon quantities as well as changes, both positive and negative, in the carbon pool size (sink), it is necessary to develop fast and simple methods that can be used to collect large amounts of data on vast areas in order to calculate these parameters. The aforementioned can be achieved by implementing LIDAR technology for the calculation of above-ground biomass in vast areas and, consequently, for the calculation of sequestered carbon i.e. carbon dioxide, which is the first research of this kind in the Republic of Croatia.

One of the goals of this research is to create a model for determining above-ground biomass of degraded forest areas in thicket stadium (*hypothesis 1*), which is one of the main missing data for determining sequestered carbon quantities and changes in carbon sinks needed to create the Greenhouse Gasses National Inventory Report.

Also, the influence of thinner point cloud to the final result (in comparison to the initial one) shall be established (*hypothesis 2*). Lower density LIDAR cloud utilization with the aim of achieving satisfactory and precise enough data directly correlates to the costs of scanning that is the single highest cost in such projects.

A part of this research was conducted in the lowland area with altitude of approximately 120 m, whilst the other part of research was conducted in the hilly area with altitudes ranging from 250 to 550 m. Through field data collection (68 plots), processing of LIDAR data (average denstiy of 1.38 points/m^2) and in the end regression analyses, regression models for the assessment of degraded forests biomass of lowland and hilly vegetation zone were developed.

It was determined that the model for the lowland area had determination coefficient (R^2) of 0.75, whilst for hilly area this coefficient was 0.60. The results also show that cloud point density does not affect appropriateness of the model to a certain extent (up to 0.4 points/m^2) which successfully confirms both hypotheses.

The application of created models to the entire area enabled calculation of forest above-ground biomass values for the whole researched area. Also, the comparison of

appropriateness of thinner point cloud based models for the implementation on the entire area was conducted.

Finally, apart from the list of practical conclusions and limitations that have arisen during the research (time incompliance of LIDAR and field data, lack of local models for the assessment of above-ground tree biomass, etc.), recommendations for further researches are stated ie. overcoming existing restrictions, repeating this kind of the research for the bio-geographic areas that were not encompassed with this research and introduction of additional data.

SADRŽAJ

PODACI O MENTORU ..... **I**

SAŽETAK ..... **III**

SUMMARY ..... **V**

SADRŽAJ ..... **VII**

POPIS TABLICA ..... **XI**

POPIS SLIKA ..... **XIII**

1 UVOD **1**

1.1 LIDAR 2

1.2 DOSADAŠNJA ISTRAŽIVANJA 7

1.3 PODRUČJE ISTRAŽIVANJA 13

1.3.1 Zemljopisni položaj *13*

1.3.2 Reljef i geološko-litološka obilježja *14*

1.3.3 Tlo *16*

1.3.4 Klima *17*

1.3.5 Korištenje zemljišta *20*

1.4 CILJ ISTRAŽIVANJA 21

2 MATERIJALI I METODE **23**

2.1 KREIRANJE UZORKA 23

2.1.1 Izbor područja *23*

2.1.2 Stratifikacija područja *23*

2.1.3 Određivanje lokacija za izmjeru *25*

2.2 TERENSKI RADOVI 28

2.2.1 Prikupljeni podaci *31*

2.3 PODACI PRIKUPLJENI LIDAR-OM 32

2.4 OBRADA PODATAKA 34

2.4.1 Obrada terenskih podataka *34*

2.4.2 Obrada LIDAR podataka *41*

2.4.2.1 Priprema LIDAR podataka za testiranje hipoteze 2 53

2.5 STATISTIČKA OBRADA PODATAKA 55

3 REZULTATI S RASPRAVOM **59**

3.1 REZULTATI TERENSKE IZMJERE 59

3.2 UTVRĐIVANJE KOLIČINE NADZEMNE BIOMASE 66

3.2.1 Primjena modela na cijelo područje 74
3.2.2 Usporedba mjerenih i modeliranih podataka 83
3.2.3 Unaprijeđenje modela i mogućnosti primjene 87
3.3 TESTIRANJE PRIMJENE RJEĐIH OBLAKA TOČAKA ZA OBRAČUN NADZEMNE BIOMASE 91
3.3.1 Usporedba „glavnih" modela i modela na osnovu prorijeđenih oblaka točaka 96
3.3.1.1 Nizinsko područje 96
3.3.1.2 Brdsko područje 98
3.4 OGRANIČENJA I PREPORUKE 99
4 ZAKLJUČCI 101
PRILOG 1 – IZGLED TERENSKOG OBRASCA 102
PRILOG 2A PRIMJER SLIKANE PANORAME PLOHE 5 103
PRILOG 2B PRIMJER SLIKANE PANORAME PLOHE 11 104
PRILOG 2C PRIMJER SLIKANE PANORAME PLOHE 67 105
PRILOG 3 – PRIKAZ MJERENIH KOORDINATA I KOORDINATA CENTRA PLOHI 106
PRILOG 4 DISTRIBUCIJA TOČAKA PREMA POVRATIMA I KLASIFIKACIJI ZA SVAKU PLOHU 108
PRILOG 5 TABLIČNI PRIKAZ VRIJEDNOSTI IZRAČUNATIH VARIJABLI 112
LITERATURA 120
ŽIVOTOPIS 131

POPIS KRATICA

Kratica	Engleski naziv	Hrvatski naziv
LIDAR	LIght Detecting And Ranging	detekcija i određivanje udaljenosti objekata pomoću svjetlosnih valova
CO_2		ugljični dioksid
GPG LULUCF	Good Practice Guidance for reporting in Land-Use, Land-Use Changes and Forestry	Mjere dobre prakse za procjenu i izvještavanje u području korištenja zemljišta, promjene korištenja zemljišta te šumarstva
EU	European union	Europska unija
NIR	National Inventory Report	Izvješće o inventaru stakleničkih plinova
UNFCCC	United Nations Framework Convention on Climate Change	Okvirna Konvencija Ujedinjenih naroda o promjeni klime
LULUCF	Land-Use, Land-Use Changes and Forestry	korištenje zemljišta, promjene korištenja zemljišta te šumarstvo
TLS	Terrestrial Laser Scaning	lasersko skeniranje sa zemlje
ALS	Airborne Laser Scanning	lasersko skeniranje iz zraka
SLS	Spaceborne Laser Scanning	lasersko skeniranje iz svemira
DMR	digitalni model reljefa	digitalni model reljefa
DMK	digitalni model krošnji	digitalni model krošnji
DMP	digitalni model površine	digitalni model površine
DMV	digitalni model visina	
DMVK	digitalni model visina krošnje	
GPS	Global positional system	globalni pozicijski sustav
GIS		Geografsko-informacijski sustav
IMU	inertial measurement unit	
ITB	*individual-tree-based approach*	
AB	*area-based approach*	
SAD		Sjedinjene američke države
UK		Ujedinjeno Kraljevstvo
R^2		koeficijent determinacije
R		koeficijent korelacije
RMSE	Root Mean Square Error	srednja kvadratna pogreška
EVI	Enhanced vegetation index	
NDVI	Normalized difference vegetation index	
LAI	Leaf area index	
SAVI	Soil-adjusted vegetation index	
NDWI	Normalized Difference Water Index	
RH		Republika Hrvatska
CORINE	COoRdination of INformation on the Environment	

Kratica	Engleski naziv	Hrvatski naziv
CORINE2012		Baza podataka o pokrovu zemljišta za 2012. godinu
CLC	CORINE Land Cover	CORINE pokrov zemljišta
RTK	Real Time Kinematic	Satelitsko pozicioniranje u realnom vremenu
GNSS		Globalni navigacijski satelitski sustavi
GLONAS		Ruski satelitski navigacijski sustav
CROPOS		Hrvatski pozicijski sustav
OTB		Ostala tvrda bjelogorica
m		metar
m^2		kvadratni metar
kg		kilogram
t		tona
kg/ha		kilograma po hektaru
t/ha		tona po hektaru
t/m^3		tona po metru kubnom
m^3/ha		kubnih metara po hektaru
BEF	biomass expansion factor	Faktor ekspanzije biomase
NN		Narodne novine
N		broj, veličina skupine
ESA		Europska Svemirska agencija
N16		Model izrađen s razrijeđenim oblakom točaka 16 % izvorne gustoće oblaka
N33		Model izrađen s razrijeđenim oblakom točaka 33 % izvorne gustoće oblaka
N50		Model izrađen s razrijeđenim oblakom točaka 50 % izvorne gustoće oblaka
N100		Model izrađen na osnovu 18 izabranih od 23 nizinske plohe izvorne gustoće oblaka točaka
B1		Model izrađen na osnovu 18 (od 45 u brdskom području) izabranih ploha raspona oblaka točaka od 0,36 do 1,00 točke/m2
B2		Model izrađen na osnovu 18 (od 45 u brdskom području) izabranih ploha raspona oblaka točaka od 1,00 do 1,75 točke/m2
B3		Model izrađen na osnovu 9 (od 45 u brdskom području) izabranih ploha oblaka točaka iznad 1,75 točke/m2

POPIS TABLICA

Tablica 2-1 Istraživana površina, broj ploha te njihov omjer 27
Tablica 2-2 Prikaz broja uzorkovanih stabala, te stabala kojima su izmjerene visina i prirast prema debljinskim stupnjevima 31
Tablica 2-3 Sumarni prikaz LIDAR podataka za istraživano područje 33
Tablica 2-4 Određeni parametri prirasnih krivulja za mjerene vrste odnosno grupe vrsta 35
Tablica 2-5 Određeni parametri visinskih krivulja mjerenih vrsta tj. grupa vrsta 36
Tablica 2-6 Pregled korištenih jednadžbi za obračun biomase stabla i parametara s izvorima (Y-nadzemna biomasa stabala, D-prsni promjer, H-visina stabla) 38
Tablica 2-7 Podaci o broju točaka i gustoći oblaka točaka iz kojeg su izuzete točke "šûma" . 44
Tablica 2-8 Distribucija točaka nakon klasificiranja 45
Tablica 2-9 Distribucija točaka prema kategorijama nakon dodatne klasifikacije 46
Tablica 2-10 Distribucija točaka prema povratima i gustoća 46
Tablica 2-11 Distribucija točaka prema klasifikaciji 46
Tablica 2-12 Prikaz osnovnih statističkih osobina za broj i gustoću točaka po plohama 47
Tablica 2-13 Osnovne karakteristike oblaka točaka plohe 5 48
Tablica 2-14 Osnovne karakteristike oblaka točaka plohe 67 49
Tablica 2-15 Osnovne karakteristike oblaka točaka plohe 11 50
Tablica 2-16 Raspored ploha i gustoća oblaka prema određenim grupama 54
Tablica 3-1 Broj uzorkovanih stabala s osnovnim statističkim karakteristikama po vrstama drveća 59
Tablica 3-2 Prikaz prevladavajućih vrsta drveća na mjerenim plohama 60
Tablica 3-3 Prikaz težine suhe tvari po plohi i po hektaru 61
Tablica 3-4 Osnovne statističke karakteristike obračunate šumske nadzemne biomase po plohama 62
Tablica 3-5 Osnovne statističke karakteristike obračunate šumske nadzemne biomase po plohama i po područjima 62
Tablica 3-6 Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za brdsko i nizinsko područje 66
Tablica 3-7 Model nizinskog područja (zavisna varijabla drugi korijen biomase-sqrt_biomasa) 67

Tablica 3-8 Model brdskog područja (zavisna varijabla drugi korijen biomase-sqrt_biomasa) 67
Tablica 3-9 Statističke karakteristike modela za istraživana područja..... 67
Tablica 3-10 Sažetak stepwise regresijske analize za nizinsko područja..... 68
Tablica 3-11 Sažetak stepwise regresijske analize za brdsko područja 68
Tablica 3-12 Analiza varijance regresijskog modela nizinskog područja..... 68
Tablica 3-13 Analiza varijance regresijskog modela brdskog područja 69
Tablica 3-14 Sumarni prikaz rezultata na osnovu izrađenih modela 74
Tablica 3-15 Minimalne i maksimalne mjerene i modelirane vrijednosti 84
Tablica 3-16 Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama..... 84
Tablica 3-17 Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za prorijeđene oblake točaka nizinskog dijela 91
Tablica 3-18 Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za grupirane podatke prema gustoćama oblaka za brdsko područje 92
Tablica 3-19 Izrađeni modeli sa pripadajućim dobivenim parametrima..... 92
Tablica 3-20 Statističke karakteristike modela uz korištene raspone oblaka točaka 92
Tablica 3-21 Sažetak stepwise regresijske analize za grupu podataka N100..... 93
Tablica 3-22 Prikaz sumarnih i osnovnih statističkih osobina rezultata modela nastalih u okviru Hipoteze 1 i 2 za nizinsko područje..... 96
Tablica 3-23 Usporedba raspona biomasa prema modelima prorijeđenih oblaka točaka po pikselima s rasponom biomase prema modelu s neprorijeđenih oblakom točaka 97
Tablica 3-24 Prikaz sumarnih i osnovnih statističkih osobina rezultata modela nastalih u okviru Hipoteze 1 i 2 za brdsko područje 98
Tablica 3-25 Usporedba raspona biomasa prema modelima prorijeđenih oblaka točaka po pikselima s rasponom biomase prema modelu s neprorijeđenih oblakom točaka 99

POPIS SLIKA

Slika 1-1 Prikaz raznih povrata (return) pojedine LIDAR zrake (Ivšić i dr., 2016) 3
Slika 1-2 Način rada LIDAR sustava (preuzeto s http://vcgi.vermont.gov/sites/vcgi/files/aboutvcgi/lidar/How_LiDAR_Works.jpg)..... 4
Slika 1-3 Prostorni položaj Grada Zagreba u odnosu na okolne županije (oznaka A- nizinski dio istraživanog područja; oznaka B- brdski dio istraživanog područja)..... 14
Slika 1-4. Pojednostavljena litostratigrafska karta Grada Zagreba (iz arhive Oikona)..... 15
Slika 1-5. Pedološka karta Grada Zagreba 16
Slika 1-6 Ruža vjetrova za meteorološku postaju Zagreb Maksimir (2000-2016) 17
Slika 1-7 Walterov klima-dijagram za postaju Maksimir 18
Slika 1-8 Walterov klima-dijagram za postaju Pleso 18
Slika 1-9 Prikaz broja oblačnih i vedrih dana te prosječne mjesečne naoblake za Maksimir.. 18
Slika 1-10 Prikaz broja oblačnih i vedrih dana te prosječne mjesečne naoblake za Pleso 18
Slika 1-11 Karta korištenja zemljišta Grada Zagreba prema CORINE 2012 (iz arhive Oikona) 20
Slika 2-1 Primjer izdvojenih površina za dalju analizu (brdsko područje) 24
Slika 2-2 Područja istraživanja i odabrane plohe - brdski dio..... 26
Slika 2-3 Područje istraživanja i odabrane plohe –istočni dio nizinskog dijela..... 26
Slika 2-4 Područje istraživanja i odabrane plohe - zapadni dio nizinskog dijela..... 27
Slika 2-5 Skica terenske primjerne plohe s podplohama 28
Slika 2-6 Primjer snimanja precizne koordinate za plohu 10..... 30
Slika 2-7 Primjer snimanja precizne koordinate za plohu 10 (bliži pogled)..... 30
Slika 2-8 Tečajni debljinski prirast za grupu vrsta Javor mliječ, gorski javor, obični orah i divlja trešnja R^2=0,17..... 35
Slika 2-9 Korišteni alati i shema procesa rada 41
Slika 2-10 Prikaz alata lasclip 42
Slika 2-11 Primjerni prikaz gustoće LIDAR točaka 43
Slika 2-12 Prikaz oblaka točaka na plohi 5 sa smjerom prikazanog pogleda 48
Slika 2-13 Prikaz oblaka točaka na plohi 5 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije..... 48
Slika 2-14 Prikaz oblaka točaka na plohi 67 sa smjerom prikazanog pogleda 49

Slika 2-15 Prikaz oblaka točaka na plohi 68 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije 49
Slika 2-16 Prikaz oblaka točaka na plohi 11 sa smjerom prikazanog pogleda 50
Slika 2-17 Prikaz oblaka točaka na plohi 11 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije 50
Slika 2-18 Hillshade područja točke 5 i 6 52
Slika 2-19 Nagibi oko područja točke 5 i 6 52
Slika 2-20 Hillshade područja točke 2, 10 i 11 52
Slika 2-21 Nagibi oko područja točke 2, 10 i 11 52
Slika 2-22 Hillshade područja točka 67 52
Slika 2-23 Nagibi oko područja točke 67 52
Slika 2-24 Prikaz faktorskih težina korištenih varijabli 57
Slika 3-1 Prikaz rezultata modeliranih vrijednosti naspram ostataka modela nizinskog područja 69
Slika 3-2 Prikaz modeliranih vrijednosti naspram mjerenih vrijednosti modela nizinskog područja 69
Slika 3-3 Normalna vjerojatnost ostataka modela nizinskog područja 69
Slika 3-4 Distribucija mjerenih vrijednosti biomase tj korijena biomase nizinskog područja. 69
Slika 3-5 Distribucija modeliranih vrijednosti nizinskog područja 69
Slika 3-6 Distribucija vrijednosti ostataka modela nizinskog područja 69
Slika 3-7 Prikaz rezultata modeliranih vrijednosti nasuprot ostataka modela brdskog područja 70
Slika 3-8 Prikaz modeliranih vrijednosti naspram mjerenih vrijednosti modela brdskog područja 70
Slika 3-9 Normalna vjerojatnost ostataka modela brdskog područja 70
Slika 3-10 Distribucija mjerenih vrijednosti biomase tj korijena biomase brdskog područja . 70
Slika 3-11 Distribucija modeliranih vrijednosti brdskog područja 70
Slika 3-12 Distribucija vrijednosti ostataka modela brdskog područja 70
Slika 3-13 Ortofoto prikaz dijela istraživanog nizinskog područja 75
Slika 3-14 Prikaz 95-og percentila visine 75
Slika 3-15 Prikaz 15-og percentila visine 76
Slika 3-16 Prikaz 10-og percentila visine 76

Slika 3-17 Prikaz postotka točaka vegetacije između 10 i 20 m 77
Slika 3-18 Obračunata biomasa prema modelu za nizinsko područje 77
Slika 3-19 Ortofoto prikaz dijela istraživanog brdskog područja 78
Slika 3-20 Prikaz 90-og percentila visine 78
Slika 3-21 Prikaz postotka točaka vegetacije između 2,5 i 5 m 79
Slika 3-22 Obračunata biomasa prema modelu za brdsko područje 79
Slika 3-23 Prikaz obračunate biomase-nizinsko područje - mjerilo 1 : 12.500 (pregledna 1 : 150.000) 80
Slika 3-24 Prikaz obračunate biomase-zapadni dio brdskog područja- mjerilo 1 : 15.000 (pregledna 1 : 100.000) 81
Slika 3-25 Prikaz obračunate biomase-istočni dio brdskog područja- mjerilo 1 : 15.000 (pregledna 1 : 100.000) 82
Slika 3-26 Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama za nizinski dio istraživanog područja 85
Slika 3-27 Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama za brdski dio istraživanog područja 85

1 UVOD

Živimo u vremenu brzih i ekstremnih promjena. Brzi razvoj tehnologije, rast populacije čovječanstva te iskorištavanje prirodnih resursa ozbiljno su narušili prirodnu ravnotežu okoliša. Jedan od najznačajnijih učinaka ove neravnoteže je količina ugljičnog dioksida (CO_2) u atmosferi koja je viša nego ikad u povijesti čovječanstva. Posljedično, efekt staklenika koji onemogućava prirodno hlađenje Zemljine površine i oceana nesumnjivo je jedan od najvećih okolišnih problema današnjice, pogotovo kada je situacija s globalnim zatopljenjem prešla iz faze "globalno zatopljenje je neizbježno" u fazu "globalno zatopljenje je potvrđeno" **(IPCC 40th, 2014).** Stoga šume kao jedan od mogućih odljeva ugljika (uz mora i tla) igraju bitnu ulogu u ublažavanju posljedica ili redukciji ispuštenog CO_2. Sva živa bića na Zemlji sastavljena su od određene količine ugljika, a biljke, prvenstveno drveće s obzirom na njihov volumen u biosferi, su jedine koje ga mogu apsorbirati iz atmosfere i ugraditi ga u svoju biomasu procesom fotosinteze.

Sukladno mjerama dobre prakse za procjenu i izvještavanje u području korištenja zemljišta, promjene korištenja zemljišta te šumarstva (GPG LULUCF; **(IPCC, 2003)**, živa biomasa je jedan od tri moguća terestrička ponora ugljika (uz mrtvu organsku tvar i organsku tvar u tlu). Nadalje, živa biomasa se dijeli na nadzemnu i podzemnu biomasu. Nadzemna biomasa označava svu živu biomasu iznad tla uključujući stablo, panj, grane, koru, sjeme, lišće/iglice i cvijet, dok podzemna biomasa označava svo živo korijenje.

Radi praćenja količine vezanog (tzv. priljeva) i emitiranog (tzv. odljeva) ugljika, kao i praćenja promjena, pozitivnih i negativnih, u veličini rezervoara (ponora) ugljika potrebno je razviti brze i jednostavne metode s kojima se u vrlo kratkom roku mogu skupiti velike količine podataka (kvalitativno zadovoljavajućih, točnošću primjerenih, preciznošću prihvatljivih) na velikom području, potrebnih za obračun ovih parametara.

Iz perspektive Kyoto protokola i EU Climate policy 20-20-20 proizašle iz Kyoto protokola, kao i obaveza proizašlih iz toga (npr. Izvješće o inventaru stakleničkih plinova- NIR; UNFCCC), moramo moći odrediti mogućnosti vezivanja te veličinu i opseg promjena u rezervoarima ugljika. To se može postići primjenom LIDAR tehnologije za obračun nadzemne biomase vegetacije na velikim područjima i posljedično obračun vezanog ugljika tj. ugljičnog dioksida. Opetovanom primjenom ove tehnologije, svakih nekoliko godina, može se

uspostaviti efektivno praćenje promjena. Pozitivne promjene očitovale bi se u povećanju površine pod vegetacijom ili povećanjem količine biomase po jedinici površine, a negativne promjene uzrokovane sječom, požarima ili nekontroliranom gradnjom bi se očitovale u gubitku površine za koju bi onda postojao podatak o količini nadzemne šumske biomase koja je bila na toj površini.

1.1 LIDAR

LIDAR (LIght Detecting And Ranging) tehnologija se intenzivno upotrebljava već 10-ak godina te su već razvijeni modeli za obračun nadzemne biomase ali većinom u visokim šumama odnosno šumama sjemenjačama dok primjena ove tehnologije nije dovoljno istraživana u degradiranim šumama (**Reutebuch i dr., 2005)**.

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

Ovisno o mjestu na kojem se nalazi uređaj za snimanje, odnosno gdje su i na što LIDAR sustavi montirani, može se podijeliti na: lasersko skeniranje sa zemlje (eng. Terrestrial Laser Scaning-TLS), lasersko skeniranje iz zraka (eng. Airborne Laser Scanning-ALS) i lasersko skeniranje iz svemira (eng. Spaceborne Laser Scanning-SLS).

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). Njegova karakteristika je da se pri kontaktu s vegetacijom dio odbije registrirajući visinu vegetacije, a dio zrake prolazi do druge površine od koje će se odbiti dio zrake odnosno do tla ili tvrde i nepropusne podloge od koje će se odbiti cijela zraka (Slika 1-).

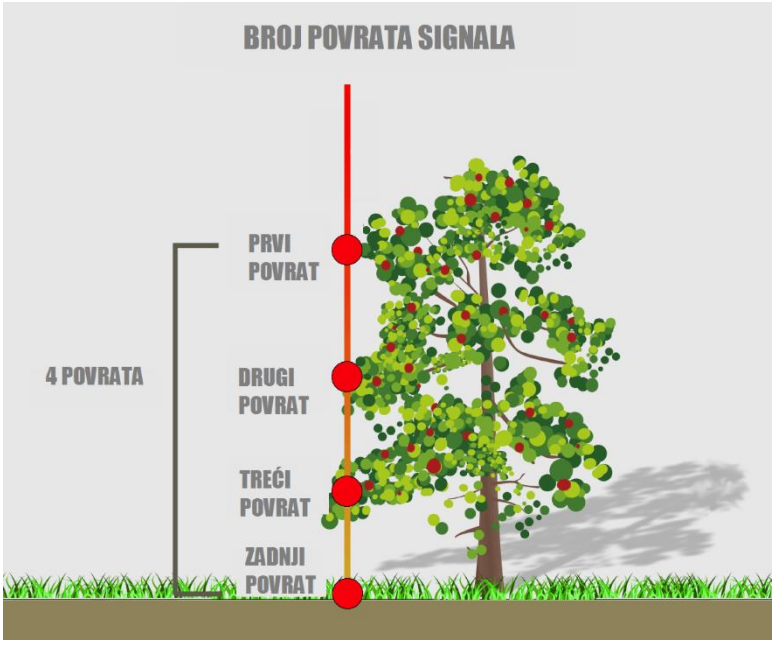

Slika 1- *Prikaz raznih povrata (return) pojedine LIDAR zrake* (**Ivšić i dr., 2016**)

Na ovaj način se može dobiti precizna informacija o visini i gustoći vegetacije, a također koristeći automatske i polu-automatske tehnike filtriranja podataka moguće je iz izvornih podataka kreirati nekoliko proizvoda: digitalni model reljefa (DMR), digitalni model krošnji (DMK), digitalni model površine (DMP).

Način rada LIDAR-skog sustava:

-emitira se impuls laserske svjetlosti uz precizno bilježenje vremena (npr. korišteni uređaj Leica ALS-50 II emitira do **150.000 laserskih zraka u sekundi**)- Slika 1-,

-detektira se refleksija tog impulsa ili njegovog dijela od objekta uz precizno bilježenje vremena,

-u slučaju kada impuls prolazi kroz vegetaciju, detektiraju se i sve naknadne refleksije dok se kumulativno ne reflektira cijeli impuls,

-koristeći konstantnu brzinu svjetlosti vremenska razlika između emitiranja i reflektiranja koristi se za računanje direktne udaljenosti između senzora i objekta,

-uz pomoć vrlo točnog položaja senzora dobivenog iz satelitske navigacije (GPS) i orijentacije senzora dobivene iz inercijalne jedinice (IMU) izračunavaju se pravokutne XYZ koordinate točaka reflektirajuće površine.

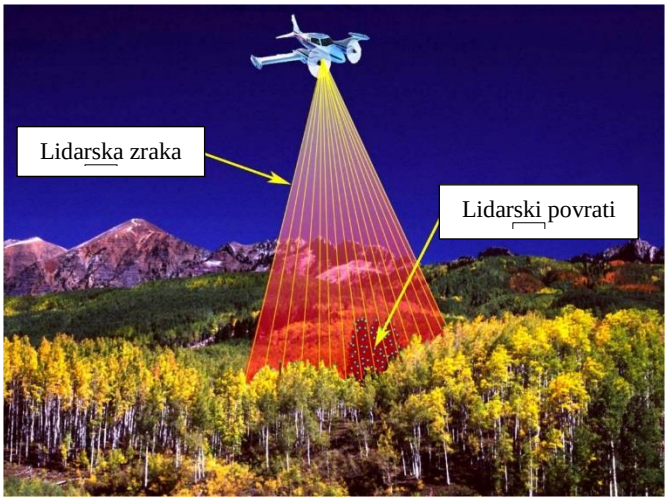

Slika 1- *Način rada LIDAR sustava (preuzeto s http://vcgi.vermont.gov/sites/vcgi/files/aboutvcgi/lidar/How_LiDAR_Works.jpg)*

Na ovaj se način dobije oblak točaka koji ovisno o brzini i visini leta te o brzini i snazi emitiranog impulsa odnosno zrake, može biti gustoće od 15 točaka po m^2 (u slučaju avionskog snimanja) do čak 100 točaka po m^2 (u slučaju snimanja bespilotnom letjelicom-dronom). Najveća prednost ovakvog načina prikupljanja prostornih podataka je taj da će se uvijek dovoljan broj zraka probiti i odbiti od tla, omogućavajući izradu vrlo preciznog digitalnog modela reljefa koji je osnova za daljnje analize.

Kako navode **Balenović i dr. (2013)** ovisno o načinu mjerenja udaljenosti između lasera i objekta, razlikuju se dva osnovna tipa ALS sustava: pulsni (eng. *discrete return system*) i fazni laserski skeneri (eng. *continuous wave system tj. full waveform system*). Fazni laserski skeneri konstantno emitiraju lasersko zračenje, a udaljenost se određuje iz razlike faza reflektiranog zračenja. Do promjene u fazama reflektiranog zračenja dolazi kada emitirano lasersko zračenje pogodi prepreku. U proteklih 20-tak godina, tj. od samih početaka značajnije praktične primjene ALS tehnologije, na tržištu su u znatno većoj mjeri bili zastupljeni pulsni laserski skeneri.

Balenović i dr., (2013) također 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,

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. Na temelju tako procijenjenih varijabli te pomoću postojećih jednadžbi i modela računaju se ostale potrebne varijable (npr. prsni promjer, temeljnica, volumen, biomasa, zaliha ugljika, goriva tvar itd.). Izrada i validacija statističkih modela za procjenu parametara pojedinačnih stabala provodi se kao i kod AB metoda na skupu terenskih podataka, ali je u ovom slučaju potrebna znatno manja količina referentnih podataka. Za razliku od AB metoda, ITB metode zahtijevaju ALS podatke većih gustoća oblaka točaka.

LIDAR podaci mogu i imaju primjenu pri praćenju i kvantificiranju drugih okolišnih problema, kao što su npr.:

- promjene u načinu korištenja zemljišta- automatiziranim postupcima mogu se pratiti zaraštanja travnjaka i pašnjaka uz kartiranje sukcesije (**Falkowski i dr., 2009)**, količina prenamjenjenog poljoprivrednog zemljišta, šumskog i drugog u izgrađeno, opožareno i sl.

- promjene vezane za tlo - erozija rijekama, vodom i vjetrom; praćenje i predikcija klizišta; nezakonita eksploatacija mineralnih sirovina i sl.

- izrada preciznog digitalnog modela reljefa koji se može koristiti za precizna modeliranja poplava, bujica i zračnih onečišćenja te projektiranje prometnica (šumskih, protupožarnih i ostalijh prometnica) i sl.

- izrada vrlo preciznog digitalnog modela površina (DMP) za korištenje pri modeliranju buke ili pregleda zgrada, mostova i ostalih objekata radi oštećenja

- kartiranje suhozida, pronalaz novih arheoloških lokaliteta koji nisu vidljivi zbog vegetacijskog pokrova ili čiji uzorci jednostavno nisu uočljivi **(Jarić Dauenhauer, 2016).**

Ove tehnologije uvelike se koriste u SAD-u, Kanadi, Kini i skandinavskim zemljama koje je koriste već više od desetljeća u operativnom uređivanju šuma. A neke od tih zemalja čak idu u smjeru da LIDAR tehnologiju počnu upotrebljavati prilikom Nacionalnih inventura šuma kao pomoćno sredstvo, značajno umanjujući potrebu za terenskim prikupljanjem podataka.

Optimizacija troška korištenja ove tehnologije, tj. onoga što čini njen najveći dio troška, samo snimanje, je moguća uz primjenu istih podloga za druge svrhe. Kako se pri LIDAR snimanju snima cijelo područje, ovi podaci imaju primjenu u puno drugih područja znanosti i privrede kao što su naprimjer geologija, arheologija, ekologija, hidrologija, poljoprivreda i sl. Stoga je iznimno bitno što više je implementirati u postojeće procese, čime će rastom tržišta cijene snimanja padati te će ona postojati sve dostupnija i isplativija za korištenje. Brojne države (UK, SAD-Aljaska, obalna područja, Filipini, neke njemačke savezne države- Thuringen, sjeverni dio Španjolske, neki švicarski kantoni, Slovenija, itd; *http://www.laszip.org/*) su to prepoznale i potpomogle ovu implementaciju time što su omogućile besplatno korištenje LIDAR podataka snimljenih na razini cijelih država, često i vrlo visoke gustoće.

Prednost LIDAR oblaka točaka leži u tome što uistinu pruža ogroman broj informacija prikupljenih u kratkom roku, iznimne preciznosti koja ima vrlo široku primjenu. S obzirom na razvoj tehnologije, moguće je dobiti slične podatke i fotogrametrijski. Međutim fotogrametrijski uređaji za snimanje (npr. ortofoto i infracrvene kamere) imaju jedan značajan nedostatak, oni „ne vide“ kroz oblake, vegetaciju i vodu, u čemu je LIDAR tehnologija gotovo nezamjenjiva, pri čemu još daje informaciju i o onome kroz što prolazi u vidu XYZ koordinate i intenziteta.

Trenutno, razina implementacije i mogućnosti LIDAR (a djelomično i fotogrametrijska) tehnologija mogu se usporediti sa uporabom GIS-a i GPS tehnologije krajem 80-ih i početkom 90-ih godina prošlog stoljeća, koja je revolucionirala pojmove „snalaženje u prostoru“, „prikupljanje prostornih podataka“, „način prikaza prostora“, „prostorne analize“ i sl. LIDAR tehnologija je „kvantni skok“ u toj revoluciji koja omogućava sve gore navedeno ali sa stajališta šumarstva, geologije, hidrologije, arheologije i sl. na „kvantnoj“ odnosno centimetarskoj ili čak milimetarskoj razini. Kako ova tehnologija ima vrlo malu ili gotovo nikakvu primjenu u RH, iznimno je bitno uhvatiti priključak sa tom tehnologijom kroz edukaciju zainteresirane javnosti i na vrijeme početi istraživati, ukazivati i primjenjivati njene mogućnosti, u čemu će zasigurno i ova disertacija pomoći.

1.2 DOSADAŠNJA ISTRAŽIVANJA

Prva istraživanja koja su koristila LIDAR tehnologiju u šumarske svrhe provođena su sredinom 80-ih **(Maclean i Krabill, 1986)**. Osim za obračun biomase, LIDAR tehnologija koristi se i za dobivanje raznih informacija o sastojini ili stablu. Na razini stabla (ITB metoda), LIDAR možemo ponajprije koristiti za: procjene visine stabala (**Nasset 1997a, 1997b; Popescu i dr., 2002; Lee i Lucas, 2007; Leitold i dr., 2015**), procjene broja stabala (**Nasset i Bjerknes, 200**1), volumen biomase pojedinih stabala (**Popescu, 2007; Figueiredo i dr., 2016**), delineacije i izmjere dimenzija krošanja (**Nasset i Okland, 2002; Goodwin i dr., 2006**). Na razini sastojine (AB metoda) možemo doći do sljedećih informacija: omjer smjese vrsta drveća (**Donoghue i dr., 2007**), gustoća sastojine (**Nasset, 1997b; Lee i Lucas, 2007**), temeljnica (**Holmgreen, 2004**), drvna zaliha (**Nasset, 1997b; Holmgreen, 2004; Hollaus i dr., 2007**), biomasa i zaliha ugljika u sastojinama (**Zhao i dr., 2009; García i dr, 2010; Chirici i dr., 2016; Ferraz i dr., 2016**) te razvoja spomenutih sastojinskih elemenata (**Yu, 2007; Woodget i dr., 2007**) i dr.

Sposobnost da se simultano vizualizira teren i model krošanja sastojine pruža značajne prednosti za šumarsku struku. LIDAR podaci pružaju značajan napredak u odnosu na tradicionalne načine dobivanja podataka (**Sumerling, 2010**) te sve veći broj organizacija vezanih za šumarstvo upotrebljavaju LIDAR za izmjere i inventure šuma. Navedeno je u skladu s time, da je sve veći broj istraživanja (npr. **Nasset i dr., 2013**) koja potvrđuju korisnost i mogućnost primjene LIDAR-a na velikim područjima (npr. nacionalne inventure šuma). Ovime bi se smanjio opseg terenskih izmjera, a sama biomasa/drvna masa bi se obračunala za cijelo područje.

Na području Republike Hrvatske, ovo je prvo istraživanje u kojem je korišten avionski LIDAR sustav (ALS) za potrebe šumarstva. Do sada je provedeno nekoliko istraživanja s terenskim LIDAR sustavom (TLS) na području nacionalnog parka Plitvička jezera (**Žmegač, 2015; Božić, 2016).**

Iako postoji dosta istraživanja o uporabi LIDAR-a za određivanje „šumarskih“ parametara, ona kao objekt istraživanja većinom imaju starije sastojine, šume ili plantaže, odnosno područja s jednoličnijom sastojinskom strukturom. Isto tako, mnogo je više istraživanja

provedeno na četinjačama nego na listačama, a osobito nisu provođena na mješovitim sastojinama listača. Primarni razlog je, što u ovim istraživanja prednjače skandinavske zemlje, sjeverni dio SAD-a i Kanada, čiji šumski ekosustavi imaju jednoličnije strukture i većih su površina čime su prikladnije za uporabu metoda daljinskih istraživanja.

Istraživanje, koje je svojim ciljem i istraživanim sastojinama najbliže istraživanju provedenom u sklopu ove disertacije, proveli su **Hawbaker i dr., (2010)** na mješovitim raznodobnim šumama tvrdih listača (4580 ha) koje se nalaze u sjevernom dijelu SAD. Ove su šume nastale zaraštanjem prijašnjih poljoprivrednih površina, te raznolikim gospodarenjem u prošlosti, a sastoje se pretežno od raznih vrsta hrastova, jasena i karije s udjelom šećernog javora, crvenog javora i američke lipe. Na 114 ploha radijusa 15,25 m, mjerena su sva stabla iznad 12,7 cm (5 inča), a korišteni oblak točaka bio je gustoće 0,7 točaka/m^2. Dobiveni modeli za obračun iskoristivog volumena drva bili su koeficijenata determinacije od 0,63 do 0,65.

Arumae i Land (2014) proveli su istraživanje na dva područja u Estoniji veličine 15x15 km^2 sa ALS-om, te je izmjereno po 450 ploha u svakom od ovih područja. Jedno je područje obraslo pretežno crnogoričnim šumama (bijeli bor i obična smreka), a drugo bjelogoričnim šumama obične bukve. Gustoća LIDAR točaka je bila 0,5-1 impuls/m^2. Razvijeni model za procjenu visine sastojine imao je koeficijent determinacije (R^2) 0,96, dok je model za procjenu volumena sastojine zasnovan na visinskim percentilima točaka i pokrovnošću imao R^2 od 0,82.

Bollandsas i dr. (2013) koristili su LIDAR da bi odredili promjenu u količini biomase tj. prirast s pomoću dva snimanja u dva vremenska intervala s razmakom od 4 godine. Istraživano područje veličine 10 km^2 prekriveno je u najvećoj mjeri običnom smrekom. Terenska izmjera (50 ploha) i lasersko snimanje provedeno je na početku i na kraju razdoblja. Veličina ploha je bila od 88 do 1134 m^2 te su mjerena sva stabla iznad 5 cm prsnog promjera. Oblak točaka dobiven avionskim laserskim snimanjem se kretao od 3 do 5 točaka po m^2. U ovom su istraživanju utvrdili, na osnovu tri različite korištene metode utvrđivanja prirasta, da za dvije od njih gotovo nema razlike između mjerenog i prirasta na osnovu LIDAR podataka (promatrajući RMSE).

Gobakken i dr. (2012) odredili su biomasu cijelog područja okruga Hedmark u Norveškoj, na preko 27.000 km^2 uz pomoć 2300 ploha izmjerenih u sklopu nacionalne inventure šume i LIDAR-skih podataka. Područje je pokriveno većinom običnim borom i običnom smrekom.

Oblak LIDAR točaka bio je gustoće oko 3 točke /m^2. Regresijski modeli za svaki pokrov zemljišta (produktivne šume> visoko, srednje, niske i mlade šume te za neproduktivne šume, planinska područja ili izgrađena područja) su dobiveni na ukupno 662 plohe koristeći razne visinske percentile. Najmanji R^2 je bio za mlade šume te za neproduktivne šume (od 0,80 do 0,88), veći za nisko produktivne šume (0,89), te najveći za srednje i visoko produktivne šume (0,94 i 0,95).

Corona i dr. (2008) ispitivali su povezanost između volumena mjerenog na manjim plohama (384 m^2) i parametara dobivenih iz DMVK odnosno metrike visina krošnji izračunatih iz LIDAR oblaka točaka u poplavnim hrastovim šumama u centralnoj Italiji. Korelacijski koeficijent (R) je bio 0,78.

Barbati i dr. (2009) su testirali isti pristup u primorskim mediteranskim borovim šumama s crnikom u podstojnoj etaži na 406 ha prirodnog rezervata Tomboli di Cecina. Izmjerili su 43 plohe radijusa 20 m, a LIDAR oblak točaka je bio gustoće 3 točke po m^2. R^2 izrađenog modela procjene biomase iznosio je 0,77.

Montagnoli i dr. **(2015)** su izvršili istraživanje na području od 2 x 2 km na području Lombardije, obraslo mezofilnim panjačama kestena, bukve, breze, lipe, poljskog jasena i trepetljike. Koristili su plohe radijusa 10 m te su izmjerili sva stabalca iznad 5 cm prsnog promjera na 27 ploha. Uz korištenje LIDAR oblaka gustoće od 2 točke/m^2, utvrdili su vezu između različitih percentila visine i drvne biomase s koeficijentom determinacije od 0,76.

Floris i dr. (2010) su proveli istraživanje u procjeni nadzemne biomase u alpskom okruženju u smrekovim sastojinama na površini od 2500 ha, mjereći 39 ploha radijusa 13 ili 20 m. Koristeći LIDAR podatke gustoće 5 točaka/m^2 povezali su percentile visine i volumen sastojina s R^2 od 0,87. Također su ustvrdili da je procjena biomase LIDAR tehnologijom usporediva ili čak i bolja od totalne izmjere stabala nekog područja.

Također u alpskim uvjetima, **Tonolli i dr. (2011)** su na mjerenih 799 ploha na području cijele provincije Trento analizirali vezu volumena i parametara iz ALS i multispektralnih satelitskih podataka. Provincija Trento ima približno 335.500 ha šuma od gotovo 0 m.n.v do granice vegetacije, te dvije trećine površine zauzimaju četinjače (obična smreka, obična jela, europski ariš i bijeli bor), a skoro trećinu listače (obična bukva, obični grab, hrastovi i javori). LIDAR oblak točaka je bio gustoće 0,5 točaka/m^2, a multispektralni podaci rezolucije 23,5 m. Radili

su regresijske modele grupirane po četinjačama/listačama, pojedinoj vrsti drveća, nadmorskoj visini, nagibu i sl. te su utvrdili da je bolje kada se sastojine mogu razvrstati prema uređajnom razredu, dobi, tlu, produktivnosti i sl. R^2 se kretao od 0,60 do 0,78, a korištenjem multispektralnih podataka on se neznatno poboljšao.

Straub i Koch (2011) su proveli istraživanje na 9,5 km^2 površine u južnoj Njemačkoj, u mješovitim šumama od čega je 50 % površine pokriveno običnim borom, a ostatak čine kitnjak, obična bukva, crveni hrast i obični grab. Izmjereno je 108 ploha promjenjivih radijusa od 2-12 m pri čemu su u najmanjem krugu mjerena sva stabla iznad 7 cm prsnog promjera, od 2 do 3 m sva stabla iznad 10 cm, od 3 do 6 m sva stabla iznad 15 cm, a od 6 do 12 radijusa sva stabla iznad 30 cm. Gustoća oblaka točaka iznosila je 16 točaka/m^2. Međutim, zbog udjela raznih vrsta i zbog toga što su još naknadno dobivenu nadzemnu biomasu diferencirali u mogući ostatak od ekonomskog iskorištavanja (nadzemna biomasa umanjena za masu trupca odnosno samo masa krošnje, granja i stabala manjih promjera neprikladnih za industrijsku uporabu) dobili su koeficijent determinacije (R^2) od 0,58. S obzirom na cilj istraživanja, može se zaključiti da je i ovo značajna korelacija.

Zhao i dr. (2009) su proveli istraživanje nad 4800 ha šumskog područja centralnog Texasa pokrivenog crnogoričnim i hrastovim šumama različitih starosti. Koristeći svega 62 plohe radijusa 0,01 ha za mlade šume i 0,1 ha za starije šume te LIDAR oblake točaka gustoće 3-5 točaka/m^2 ostvarili su R^2 od 0,8 za crnogorišne šume i 0,88 za listopadne šume.

U istraživanju provedenom na 10 km^2 degradiranih mediteranskih šuma tj. niskih makija hrasta oštrike (**Estornell i dr., 2012**) broj terenskih ploha je bio 29, a LIDAR podaci su bili gustoće od 4 do 8 točaka/m^2. U tom istraživanju, na osnovu izrađenog modela koji uključuje varijable dobivene LIDAR-om i multispektralnim snimanjem, R^2 je bio 0,79 pokazujući visok stupanj determinacije. Koristeći samo parametre dobivene LIDAR-om, R^2 je bio 0,67. Prag za obradu LIDAR podataka kao točaka vegetacije je bio 0,25 m iznad tla.

García i dr. (2010) pri istraživanju provedenom u borovim šumama centralne Španjolske (crni, bijeli i primorski bor) sa podstojnom etažom koju čine borovice i razni hrastovi, osim metrike dobivene iz oblaka točaka, koristili su i podatke o intenzitetu svakog povrata. Na ovaj način svaka točka u prostoru osim XYZ koordinate ima i podatak o intenzitetu. Što je veći intenzitet povrata, znači da je ploha kroz koju je zraka prošla ili se odbila, veća odnosno nepropusnija. Gustoća LIDAR oblaka je bila od 1,5 do 4,5 točaka/m^2. Na područje od 382

km^2 su izmjerili 45 ploha radijusa 10 m, gdje su mjerili sva stabla iznad 10 cm prsnog promjera. Za obradu LIDAR podataka koristili su prag od 0,3 m iznad tla da ne bi uvrstili pojedine točke tla (ground points) u analizu. Koristeći sve plohe skupa, dobiven je R^2 od 0,67 koristeći varijable visine i intenziteta. Međutim, razvrstavajući plohe prema dominantnoj vrsti (crni bor, borovica ili hrast crnika) i izradom modela za svaku specifičnu vrstu, dobili su puno veće R^2. R^2 uz korištenje samo visinskih varijabli je bio; 0,58 (borovica), 0,73 (crni bor), te 0,93 (crnika), dok je uz korištenje i varijabli intenziteta R^2 bio znatno povećan (0,72, 0,88 i 0,98). Za crni bor se pokazalo bolje koristiti samo varijable intenziteta, gdje je koeficijent determinacije onda bio 0,91 (umjesto 0,88 tj. 0,73). Reducirajući oblak točaka utvrdili su da promatrajući sve podatke skupa, nema značajne promjene u veličini determinacije. Međutim promatrajući na razini glavne vrste, rijeđa gustoća oblaka je različito utjecala na R^2. Za crni bor je neznatno smanjen, za borovicu je čak i povećan, dok je za hrast crniku korelacija značajno smanjena (sa 0,98 na 0,67).

Promatrajući navedena istraživanja, možemo uočiti da su korišteni razni parametri LIDAR oblaka kao ulazni podaci za regresijske analize (udio točaka ovisno od visine iznad tla, visina određenog postotka točaka iznad tla, intenzitet točaka te ostale standardne statističke veličine). Neka su istraživanja koristila i dodatne podatke dobivene iz satelitskih multispektralnih snimki (poput raznih vegetacijskih indeksa; EVI, NDVI i sl. ili vrijednosti pojedinih kanala) radi povećanja pouzdanosti modela, s većim ili manjim uspjehom. Isto tako, korištene su različite veličine primjernih ploha i praga izmjere (5 ili 10 cm prsni promjer), a svi su obračunavali drvnu zalihu ili biomasu na osnovu prijašnjih, postojećih regresijskih parametara. Ovisno o vrsti istraživanja, korišteni su i različiti visinski pragovi pri obradi LIDAR podataka i klasifikaciji točaka vegetacije.

Međutim, gotovo svi modeli/istraživanja su imali visoke stupnjeve determinacije koji više-manje ovise o vrsti (viši su za četinjače), udjelu vrsta, visinskoj strukturi krošanja (veće vrijednosti su za jednoličnije strukture) ili starosti.

Iz ovoga je razvidno da postoji iznimno malo istraživanja primjene LIDAR tehnologije u degradiranim, raznodobnim i mješovitim sastojinama, gdje se uočio prostor za provedbu ovog istraživanja.

U skladu s tim, pristupilo se ovom istraživanju odnosno istraživanju prikladnosti uporabe ove tehnologije za određivanje količine šumske nadzemne biomase na tim područjima, bez obzira na mogući pozitivni ili negativni ishod[1].

[1] "Nisam pogriješio. Samo sam otkrio 10.000 načina koji ne rade" Thomas Alva Edison (tj. u ovom slučaju jedan način, op.a.)

1.3 PODRUČJE ISTRAŽIVANJA

S obzirom na dostupne LIDAR podatke, istraživanje je provedeno na području Grada Zagreba. Kako je ovo područje visokog stupnja izgrađenosti i naseljenosti, pogodna područja se nalaze na rubnim dijelovima administrativnog područja Grada Zagreba.

1.3.1 Zemljopisni položaj

Grad Zagreb smješten je na razmeđu sjeverne i središnje Hrvatske, između Zagrebačke županije na jugu i Krapinsko-zagorske županije na sjeveru (Slika 1-).

Kako se navodi u Programu zaštite okoliša Grada Zagreba **(Šorgić i dr. - Oikon d.o.o., 2015)**, područje Grada Zagreba moguće je na temelju prirodno-geografskih obilježja podijeliti na nekoliko osnovnih prostorno-funkcionalnih cjelina koje se pak, ovisno o stupnju antropogenog utjecaja, dijele na nekoliko podcjelina:

- Medvednica - padine južne ekspozicije:
    - šumom obrasle padine većih nadmorskih visina,
    - urbano područje naselja Zagreb na padinama nižih nadmorskih visina
    - suburbano područje različitog stupnja urbaniziranosti na padinama nižih nadmorskih visina
- šire područje Savske nizine
    - urbano područje naselja Zagreb i Sesvete
    - suburbana područja različitog stupnja urbaniziranosti
- SI padine Vukomeričkih Gorica
    - suburbano područje različitog stupnja urbaniziranosti

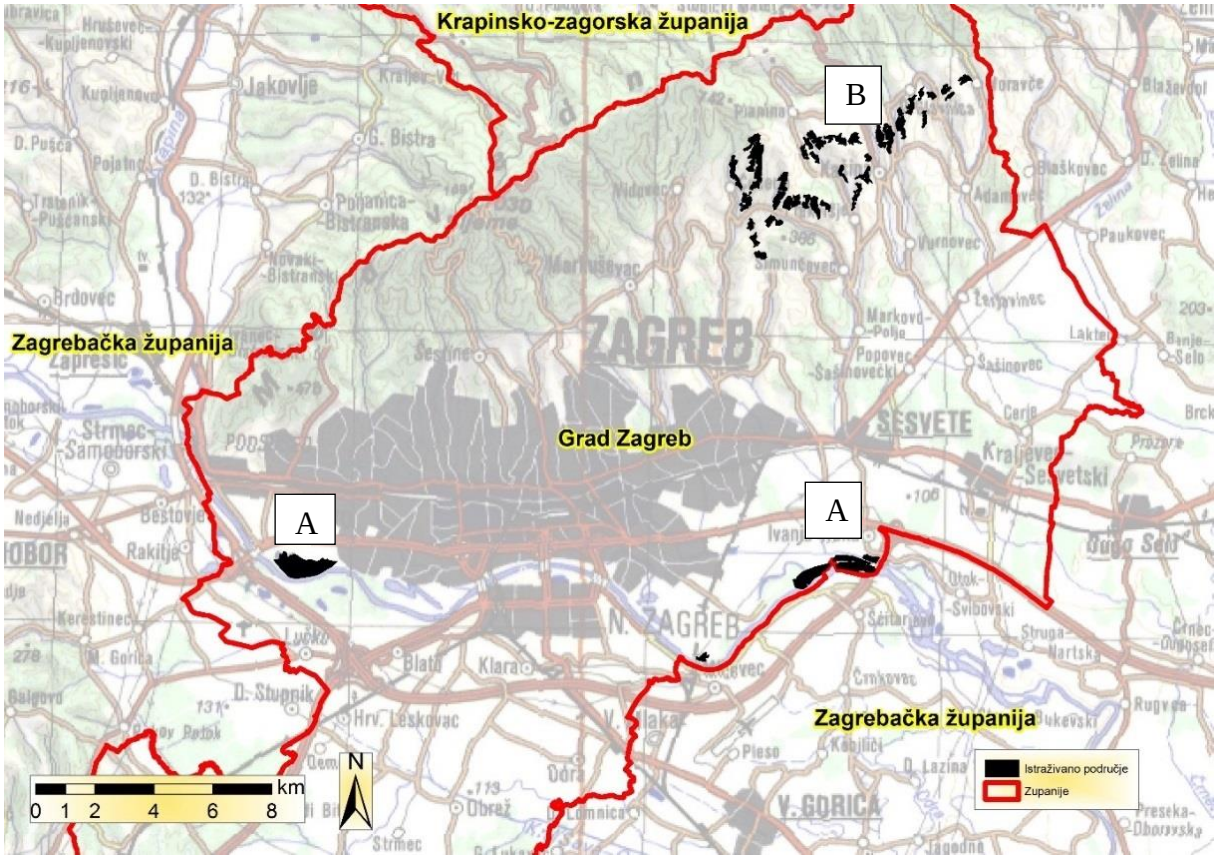

Slika 1- Prostorni položaj Grada Zagreba u odnosu na okolne županije (oznaka A- nizinski dio istraživanog područja; oznaka B- brdski dio istraživanog područja)

1.3.2 Reljef i geološko-litološka obilježja

Na području Grada Zagreba zastupljeni su dolinski (aluvijalna ravan rijeke Save) i brežuljkasti reljef (do 200 m.n.v.), te nisko brdoviti (200 – 600 m.n.v.) i visoko brdoviti reljef (600 – 1000 m.n.v.). Prevladavaju nizinski krajevi do 200 m nadmorske visine, budući da se samo Medvednica (1035 m) i Vukomeričke gorice (255 m) uzdižu iznad 200 metara nadmorske visine.

Dio istraživanja je proveden u nizinskom području (u blizini rijeke Save) nadmorske visine približno 120 m, a drugi dio istraživanja je proveden u brežuljkastom području (SI dio Grada Zagreba) na nadmorskim visinama od približno 250 do 550 m.

Zagrebački prostor vrlo je složene geološke građe. Tektonske aktivnosti u prošlosti bile su vrlo izražene, a njihov intenzitet različito se manifestira na pojedinim dijelovima promatranog prostora. Prisutne su vrlo raznorodne stijene, kako po svojoj stratigrafskoj pripadnosti, tako i

u litološkom pogledu. Po stratigrafskoj pripadnosti zastupljene su stijene paleozojske, mezozojske i kenozojske starosti, popraćene magmatskim, sedimentnim i metamorfnim stijenama različitih tipova (Slika 1-).

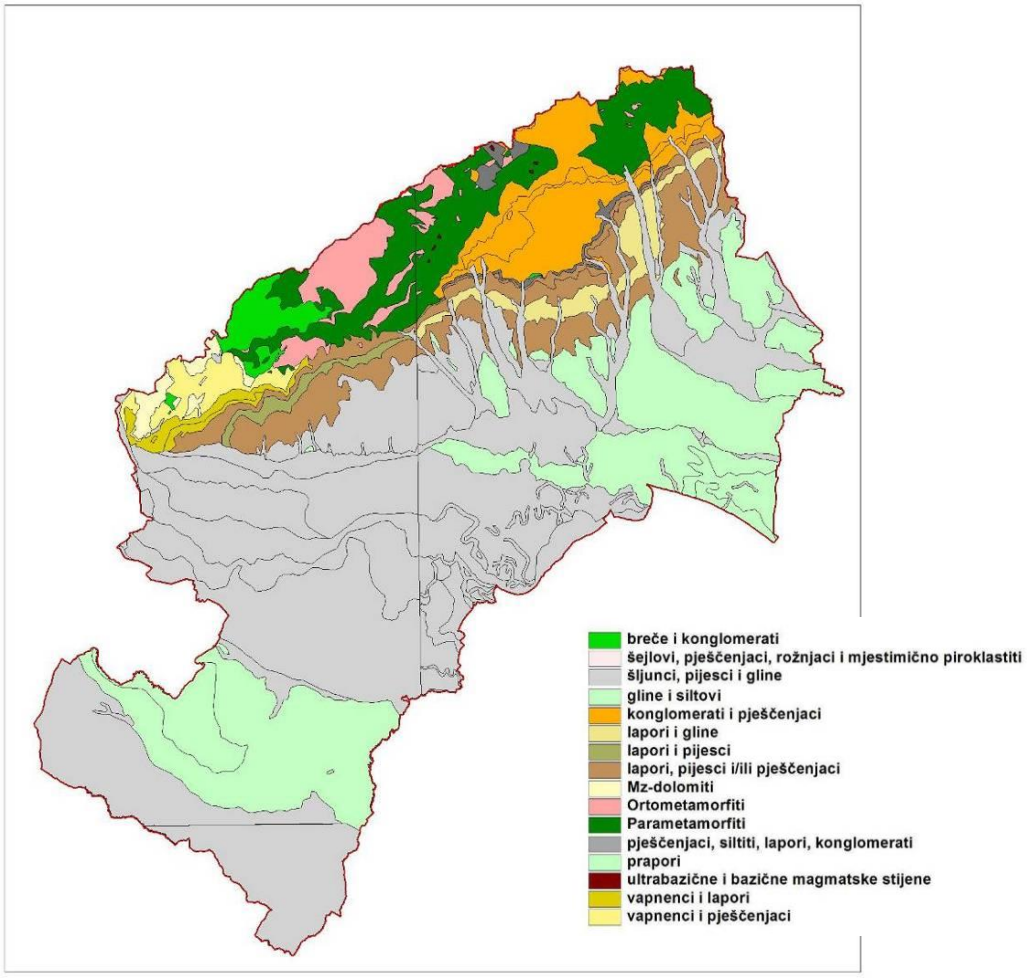

Slika 1-. Pojednostavljena litostratigrafska karta Grada Zagreba (iz arhive Oikona)

1.3.3 Tlo

Heterogenost zemljišnog pokrivača odnosno tipova tala na području Grada Zagreba povezana je s izrazitim varijacijama reljefa te s tim povezane geološko-litološke podloge.

Prostorni raspored tala na području Grada Zagreba prikazan je na pedološkoj karti (Slika 1-), izrađenoj na temelju Osnovne pedološke karte RH. Na karti je prikazana razdioba 11 kartiranih jedinica, odnosno dominantnih tipova tla.

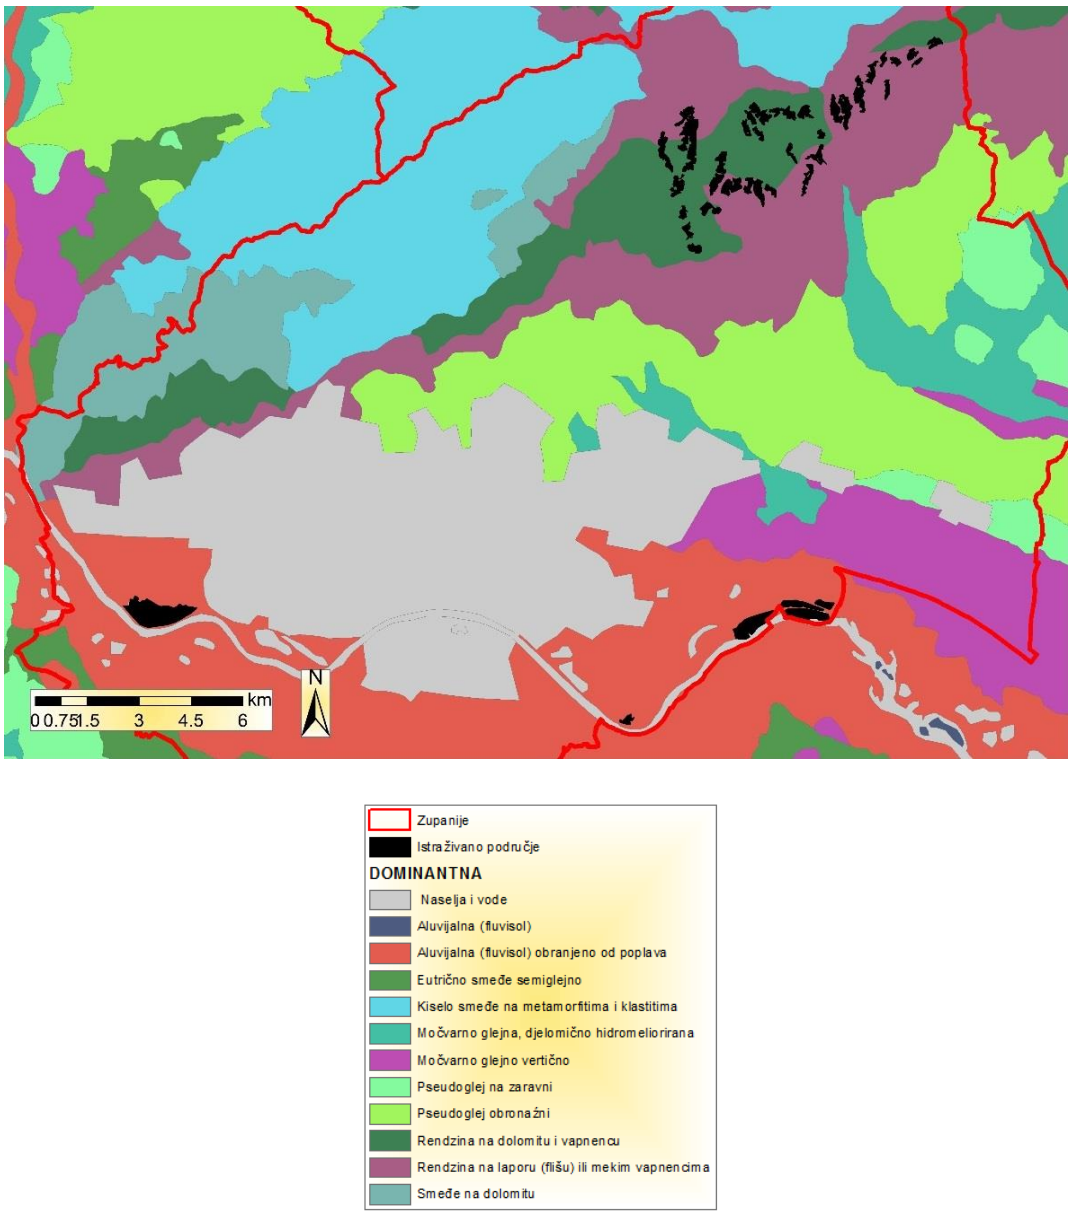

Slika 1-. Pedološka karta Grada Zagreba

Istraživane površine u nizinskom području (u blizini rijeke Save) se nalaze na aluvijalnim tlima, dok se drugi (brdski) dio površina nalazi na rendzinama koje su djelomično na dolomitu i vapnencu, a djelomično na flišu ili mekom vapnencu.

1.3.4 Klima

Grad Zagreb nalazi se u središnjoj Hrvatskoj na geografskom položaju gdje je sa sjeverne strane okružen obroncima Medvednice, a sa južne strane ograđen gotovo cijelom dužinom tokom rijeke Save. Medvednica i rijeka Sava su ujedno najbitniji čimbenici na klimatologiju i lokalne meteorološke karakteristike grada Zagreba. S jedne strane, Medvednicom se definirao dominantni sjeverni i sjeveroistočni vjetar (Slika 1-).

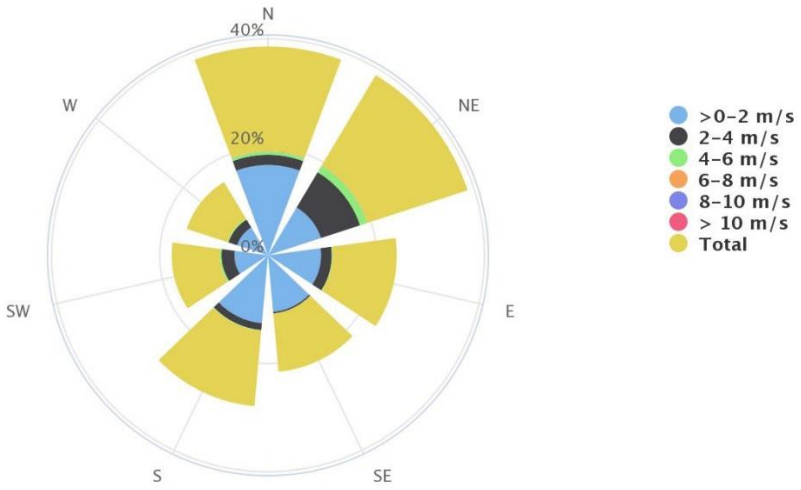

Slika 1- Ruža vjetrova za meteorološku postaju Zagreb Maksimir (2000-2016)

Položaj Medvednice ujedno i ograničava kretanja fronti i naoblake koje dolaze iz smjera zapada što najčešće rezultira kao povećana količina oborine na zapadnijem dijelu okolice grada Zagreba. Ova razlika se djelomično primijeti i na dvije izabrane meteorološke postaje – Zagreb Maksimir (Slika 1-) i Zagreb Pleso (Slika 1-). Ove dvije postaje su izabrane kao najbliže istraživanom području, gdje bi Zagreb Maksimir predstavljala osobine klime za brdski dio istraživanog područja, a Zagreb Pleso za nizinski dio istraživanog područja.

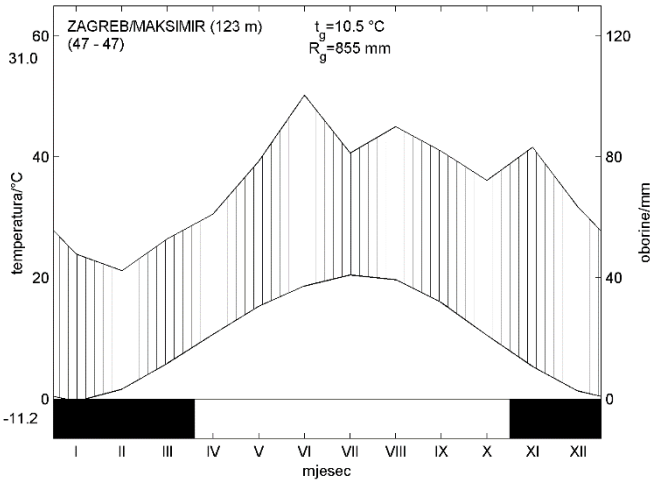

Slika 1- Walterov klima-dijagram za postaju Maksimir

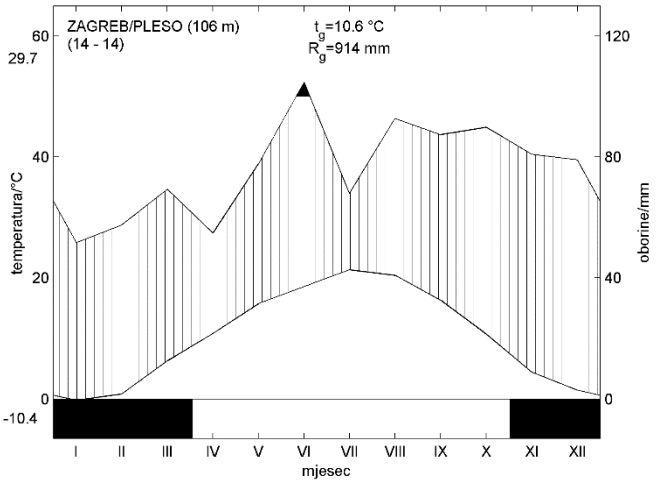

Slika 1- Walterov klima-dijagram za postaju Pleso

Graf prosječne mjesečne naoblake (izražen u 1/8 neba) te broja vedrih dana (naoblaka < 1,4 osmine neba) i oblačnih dana (naoblaka > 6,4 osmina neba) pokazuje da ukupno gledajući broj oblačnih dana u godini (118,5-postaja Maksimir, Slika 1-; 115,5 postaja Pleso, Slika 1-) daleko premašuje broj vedrih dana (44,2- Maksimir,
Slika 1-; 54,4 -Pleso, Slika 1-).

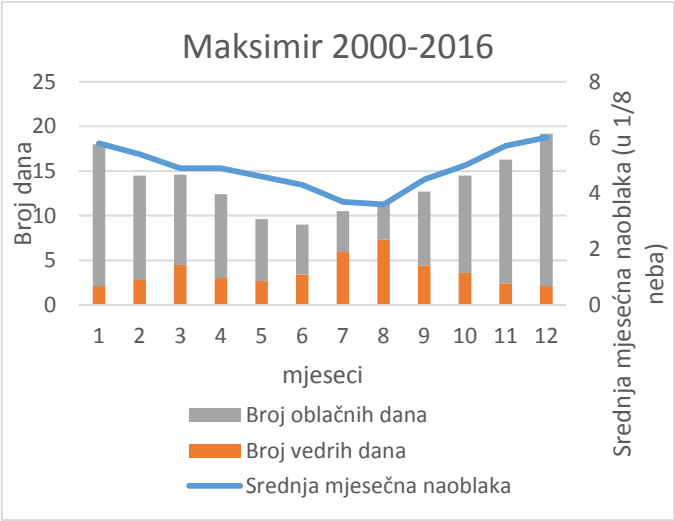

Slika 1- Prikaz broja oblačnih i vedrih dana te prosječne mjesečne naoblake za Maksimir

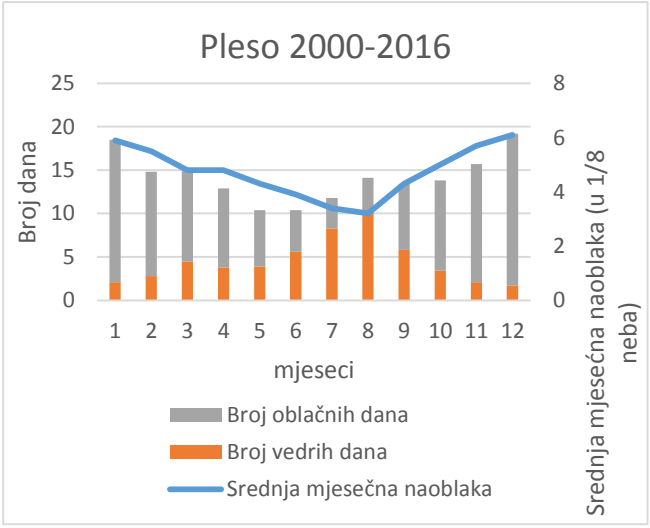

Slika 1- Prikaz broja oblačnih i vedrih dana te prosječne mjesečne naoblake za Pleso

Promatrajući vegetacijsko razdoblje (3.-10. mjesec), ovaj odnos je malo povoljniji, ali je i dalje u korist oblačnih dana (postaja Maksimir 59,9:34,8; postaja Pleso 56:45,7).

Prema Thortweitovoj klasifikaciji klime baziranoj na odnosu količine vode potrebne za potencijalnu evapotranspiraciju i oborinske vode, Zagreb pripada humidnoj klimi kao i cijelo područje središnje Hrvatske.

Prema prikazanim klima-dijagramima (Slika 1- i Slika 1-.) se pokazuje da područje Grada Zagreba ima umjereno topli kišni tip klime bez izrazito suhog razdoblja zimi uz prisutna kišna razdoblja u rano ljeto i (kasnu) jesen, iskazano formulom Cfwbx“, slijedećeg značenja:

C = umjereno topla kišna klima (srednja temperatura najhladnijeg mjeseca je između -3°C i 18°C)

fw = nema izrazito suhog razdoblja (najsušniji mjesec nema barem 3 puta manju količinu oborine od najkišnijeg mjeseca), a minimalna oborina se javlja zimi (siječanj)

b = srednja temperatura najtoplijeg mjeseca niža je od 22°C, ali barem u 4 uzastopna mjeseca tijekom godine je srednja temperatura viša od 10°C (ovdje je to ispunjeno u 6 mjeseci – od mjeseca travnja do listopada)

x“ = pojava dva kišna razdoblja – u rano ljeto (lipanj) te kasnu jesen (ovdje je sekundarni maksimum oborine pomaknut u ranu jesen – rujan, no i u studenom postoji zamjetna količina oborine, malo manja nego u rujnu)

Iz Walterovog dijagrama uočljivo je da krivulja oborine gotovo posve leži iznad temperaturne krivulje (nema izrazito suhog razdoblja) – jedini blagi manjak oborine u odnosu na temperaturu se može uočiti u srpnju (premda tada nije prisutan minimum oborine).

Ovakve klimatske prilike pogodne su za vegetaciju bukve (Cfw = „klima bukve“) te od poljoprivrednih kultura za uzgoj kukuruza (Cfbx = „klima kukuruza“).

1.3.5 Korištenje zemljišta

U nastavku su prikazane karakteristike područja Grada Zagreba prema CORINE (COoRdination of INformation on the Environment) Land Cover klasifikaciji, s obzirom da je kao jedna od podloga za analizu prostora istraživanja korištena i karta pokrova zemljišta (više u poglavlju *2.1.2 Stratifikacija područja*).

Područje Grada Zagreba je daleko najgušće naseljeno područje u RH **(Popis stanovništva 2011),** što je vidljivo i iz prostornog rasporeda pokrova zemljišta prema CORINE 2012 (Slika 1-) te omjera izgrađenog i ostalih načina korištenja zemljišta.

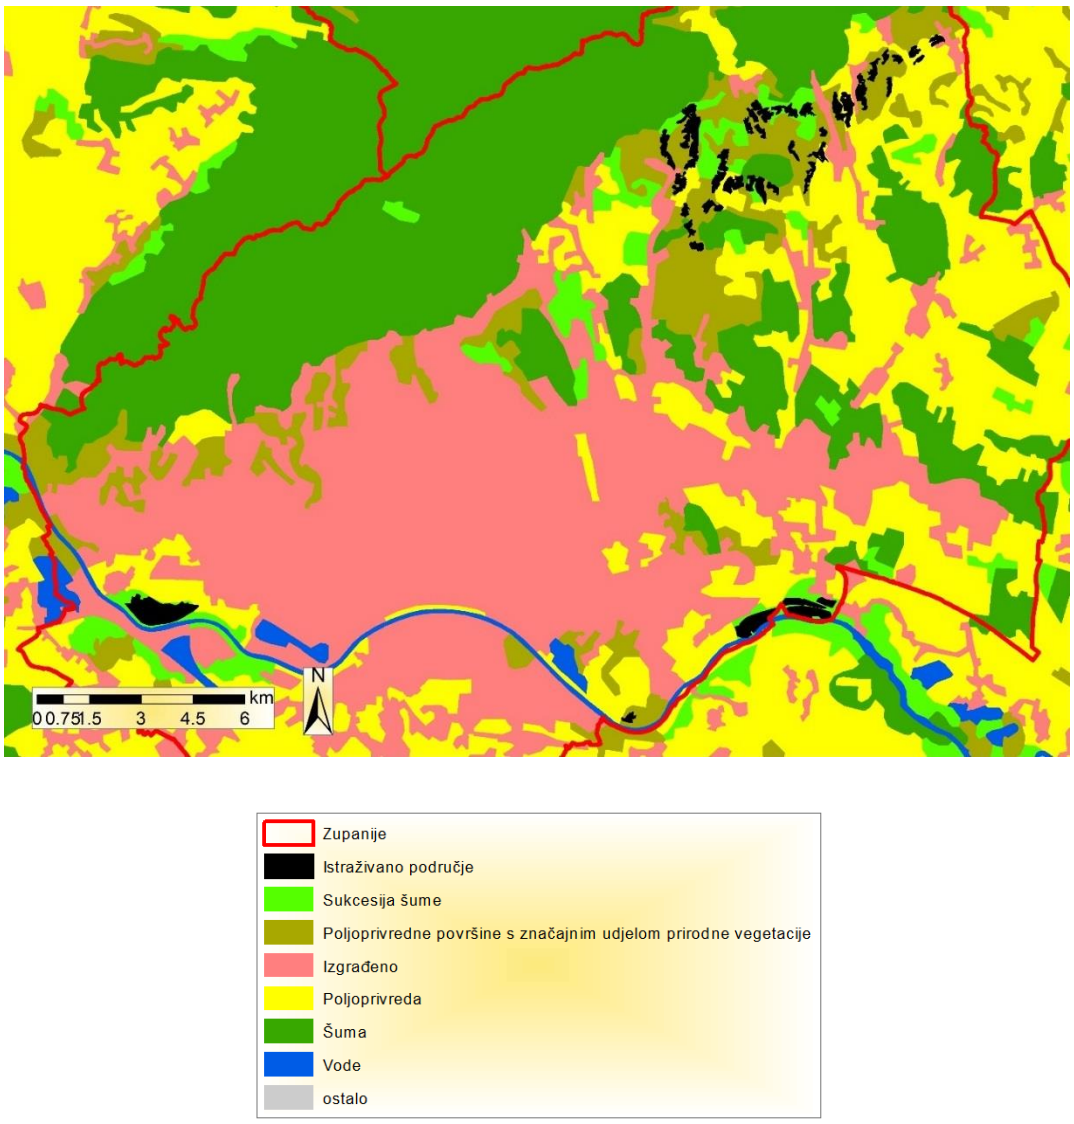

Slika 1- Karta korištenja zemljišta Grada Zagreba prema CORINE 2012 (iz arhive Oikona)

Kategorije „Sukcesija šume“ i „Poljoprivredne površine s značajnim udjelom prirodne vegetacije“ nisu spojene sa drugim srodnim kategorijama s obzirom da se na tim kategorijama zemljišta nalaze istraživana područja.

1.4 CILJ ISTRAŽIVANJA

Osnovni cilj ovog istraživanja je izraditi model za utvrđivanje nadzemne biomase[2] degradiranih šumskih područja u stadiju šikara, što je jedan od glavnih problema pri određivanju količine vezanog ugljika i promjena u rezervoaru ugljika. Naime, ovim istraživanjem bi se pokušao premostiti trenutni nedostatak podataka, s obzirom da se do sada za šikare u Programima/Osnovama gospodarenja šumama nije iskazivala drvna masa i prirast na osnovu koje bi se mogla izračunati količina i povećanje biomase i vezanog ugljika, kao što je slučaj sa šumama panjačama i sjemenjačama. Kako je prije navedeno, LIDAR tehnologija se većinom koristi za određivanja sastojinskih parametara u jednoličnijim sastojinama, dok za istraživanja šumske površine nastale degradacijom ili sukcesijom, LIDAR tehnologija služi samo kao sustav za detekciju i automatsku klasifikaciju zaraštenih/degradiranih površina (**Falkowski i dr., 2009; Kolecka i dr., 2016**).

Također će se utvrditi utjecaj manjih gustoća oblaka točaka (od onog početnog) na konačni rezultat. Utvrđivanje nižih gustoća LIDAR oblaka radi dobivanja preciznih podataka je direktno povezano s troškom snimanja koje predstavlja najveću stavku troška u ovakvim projektima. Naime, snimanje manjeg intenziteta odnosno manje preciznosti znači da se prilikom prikupljanja LIDAR podataka može letjeti na većoj visini, što znači snimanje šireg područja u jednom preletu, te posljedično manji broj preleta, brže snimanje i manji trošak snimanja. Nadalje, primjenom izrađenih modela na osnovu različitih gustoća točaka po m^2 (u odnosu na onu izvornu) i usporedbom tih rezultata s rezultatima izračunatih s izvornim, neprorijeđenim modelima, utvrditi će se odstupanja te da li su ona značajna (u tom slučaju predmetna gustoća oblaka nije prihvatljiva) ili nisu značajna (u tom slučaju predmetna

[2] Nadzemna biomasa odnosno šumska nadzemna biomasa u smislu ovog istraživanja se odnosi na ukupnu nadzemnu biomasu drvenastih ili grmovitih jedinki koje su dosegle prsnu visinu (1,3 m iznad tla) te minimalno 1 cm prsnog promjera

gustoća oblaka daje rezultate zadovoljavajuće preciznosti u odnosu na rezultate dobivene od oblaka početne gustoće).

Osnovni ciljevi istraživanja

-Istražiti mogućnost procjene šumske nadzemne biomase u degradiranim šumskim sastojinama (u stadiju šikara) brežuljkastoga i ravničarskoga (nizinskoga) vegetacijskoga pojasa na osnovu podataka dobivenih laserskim snimanjem LIDAR tehnologijom

-Analizirati mogućnost korištenja LIDAR-skih podataka niže gustoće za dobivanje statistički prihvatljivih rezultata primjenom modela razvijenih u ovom istraživanju

Da bi se ostvarili ciljevi istraživanja postavljene su sljedeće hipoteze istraživanja:

Hipoteza 1

Pomoću podataka dobivenih avionskim snimanjem LIDAR tehnologijom može se efikasno, brzo i dovoljno točno (primjenom modela razvijenih u sklopu ovog istraživanja) odrediti količina nadzemne šumske biomase u degradiranim šumskim sastojinama (u stadiju šikare) brežuljkastoga i nizinskoga vegetacijskoga pojasa kontinentalnog dijela Hrvatske (šire područje Grada Zagreba).

Hipoteza 2

Korištenjem podataka niže gustoće odnosno rjeđeg oblaka točaka, što korespondira s većom visinom i brzinom leta pri snimanju, a samim tim i obuhvaćenim većim područjem uz manje troškove, moguće je na osnovu izrađenih modela dobiti rezultate s prihvatljivom točnošću i preciznošću za željenu namjenu.

2 MATERIJALI I METODE

2.1 KREIRANJE UZORKA

2.1.1 Izbor područja

Uzimajući u obzir da su LIDAR tehnologija i avionska LIDAR snimanja u Republici Hrvatskoj tek u začecima, a posljedično s time i visoku cijenu samog snimanja, područje istraživanja je određeno dostupnim LIDAR podacima. Stoga je za šire područje istraživanja izabrano administrativno područje Grada Zagreba, s obzirom da je tvrtka GISDATA izvršila snimanje avionskim LIDAR sustavom u proljeće 2012. godine.

2.1.2 Stratifikacija područja

Prva stratifikacija područja je obavljena na osnovu podloga pokrova zemljišta prema CORINE 2012, čime su izdvojene kategorije „Sukcesija šume“ i „Poljoprivredne površine s značajnim udjelom prirodne vegetacije“ (**Kolecka i dr., 2016**).

CORINE Land Cover (CLC)

CORINE program je donesen i prihvaćen 1985. godine **(85/338/EEC)** od strane Europske zajednice kao program za koordinaciju informacija o okolišu i prirodnim resursima pod nazivom CORINE. Svrha CORINE programa je identifikacija i smislena kategorizacija pokrova zemljišta, koja uključuje definiranu nomenklaturu kodiranja i stvaranja kvalitetne baze podataka, potrebne za nadgledanje, organiziranje i upravljanje prirodnim resursima na regionalnom i nacionalnom nivou.

Kako navode **Kušan i dr**. **(2015)**, CLC nomenklatura uključuje 44 klase u trećem nivou, 15 klasa u drugom nivou i 5 klasa u prvom nivou (Umjetne površine, Poljodjelska područja, Šume i poluprirodna područja, Vlažna područja, Vodene površine). CORINE Land Cover je temeljen na fotointerpretaciji satelitskih snimaka (Landsat 5 i Landsat 7) u dostupnim GIS programima automatiziranim procedurama uz kontrolu. Do sada su za područje Hrvatske izrađene CLC baze površina za 1980., 1990., 2000., 2006. i 2012. godinu te pripadajuće baze promjena 1980. – 1990., 1990. – 2000., 2000. – 2006. i 2006. – 2012. Osnovne karakteristike baze podataka pokrova zemljišta su, da je minimalno područje kartiranja 25 ha, a minimalna

širina poligona je 100 m, dok je pri praćenju promjena najmanja jedinica 5 ha odnosno ne evidentiraju se promjene manje od 5 ha na pojedinačnim poligonima.

Upravo zbog ovih uvjeta/ograničenja i činjenice da kategorija „poljoprivredno zemljište s znatnim udjelom prirodne vegetacije“ predstavlja mozaični raspored poljoprivrednog i obraslog zemljišta, pristupilo se drugoj, preciznijoj stratifikaciji područja. Ovo je izvršeno na temelju ortofoto snimki, dostupnih preko WMS mrežnih servisa Državne geodetske uprave. Fotointerpretacijom i delineacijom izdvojenih kategorija CLC izostavile su se sve poljoprivredne, izgrađene i pašnjačke površine, a u dalju proceduru uvrštene su obrasle površine degradiranim oblicima šume veće od 4 ha. Fotointerpretacija je obavljena u programu QGIS, uzimajući u obzir parametre koje je moguće odrediti okularnom procjenom kao što su na primjer: nejednolika visinska struktura, mjestimično nepotpuna obraslost, postojane drvenastih i grmolikih elemenata i sl.

Primjer izdvojene površine za daljnju analizu na Slici 2-1.

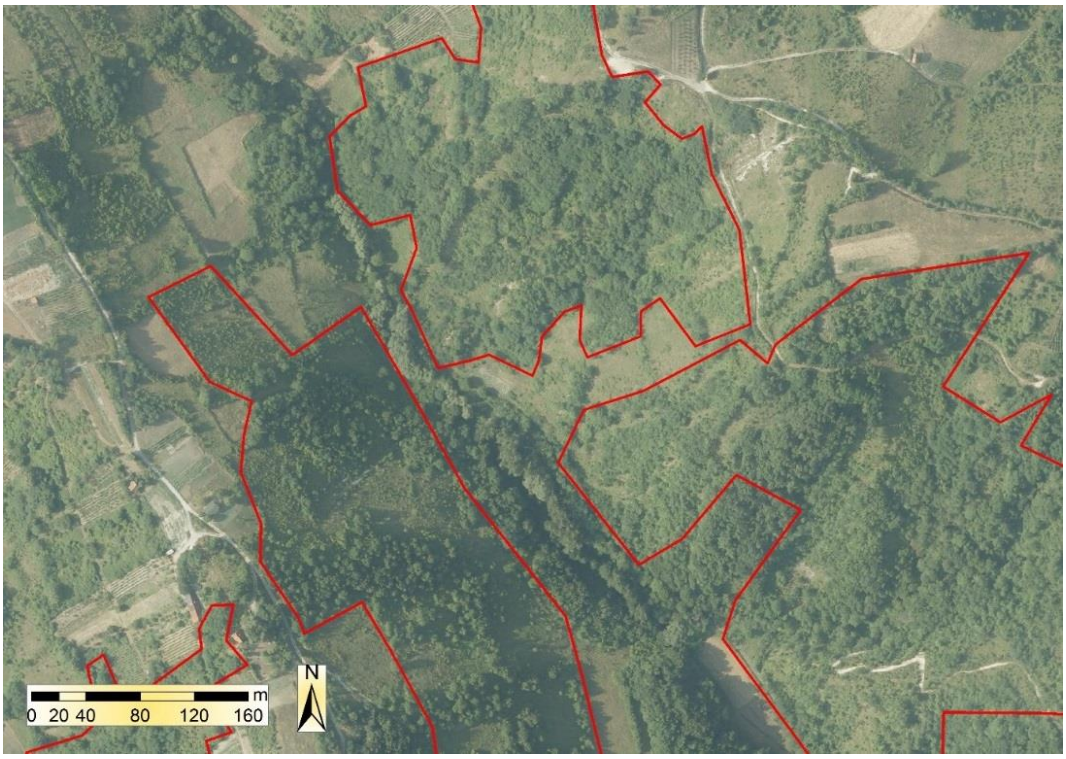

Slika 2- Primjer izdvojenih površina za dalju analizu (brdsko područje)

Ovom stratifikacijom je izdvojeno ukupno 43 poligona koji zadovoljavaju navedene uvjete tj. 553,93 ha, od čega se 343,88 ha nalazi u brdskom području (Slika 2-), a 210,05 ha u nizinskom (Slika 2- i Slika 2-).

2.1.3 Određivanje lokacija za izmjeru

U skladu s dostupnom relevantnom literaturom i radovima, za ovo istraživanje je određeno da će se odabrati po jedna terenska lokacija za mjerenje na svakih 5-10 ha istraživane površine. Ovo je znatno gušća mreža postavljenih ploha u odnosu na sukladna istraživanja **(Barbati i dr., 2009; Bollandsas i dr., 2013; Arumae i Land, 2014 i dr**), ali s obzirom na nejednoliku sastojinsku strukturu istraživanih degradiranih/progradiranih šumskih površina, procijenjeno je da će ovo zadovoljiti potrebe istraživanja. Lokacije ploha unutar obraslih i izabranih poligona su određivane, uz pomoć fotointerpretacije i uz konzultaciju ostalih dostupnih podloga (vegetacijskih karata, podataka iz digitalnog modela reljefa i sl.) da bi se obuhvatio što veći raspon strukture sastojina (drvne zalihe, obrasta i sl.), ekspozicija, nagiba, nadmorske visine i sl.

U konačnici je postavljeno 68 ploha, od čega 45 u brdskom dijelu područja (Slika 2-), a 23 u ravničarskom dijelu područja (Slika 2- i Slika 2-).

To je u skladu s preporukama (**Laes i dr., 2011**), gdje se navodi da je potrebno izmjeriti dovoljno terenskih ploha za statističku ispravnost, kao i da plohe moraju pokriti cijeli raspon varijabilnosti mjerenog interesa. Isto tako, modeli se ne mogu primjenjivati univerzalno, te se moraju razvijati za svako specifično područje. Stoga je istraživano područje Grada Zagreba podijeljeno na dva područja koja se razlikuju po reljefnim, hidrografskim, orografskim i vegetacijskim karakteristikama.

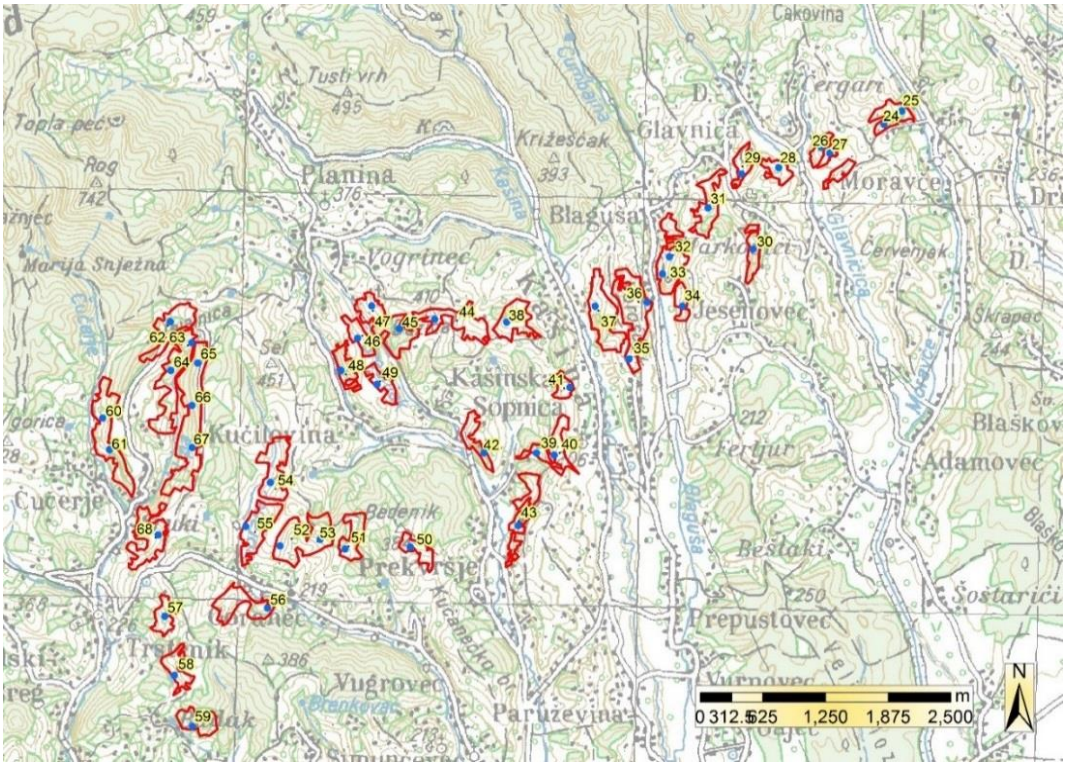

Slika 2- Područja istraživanja i odabrane plohe - brdski dio

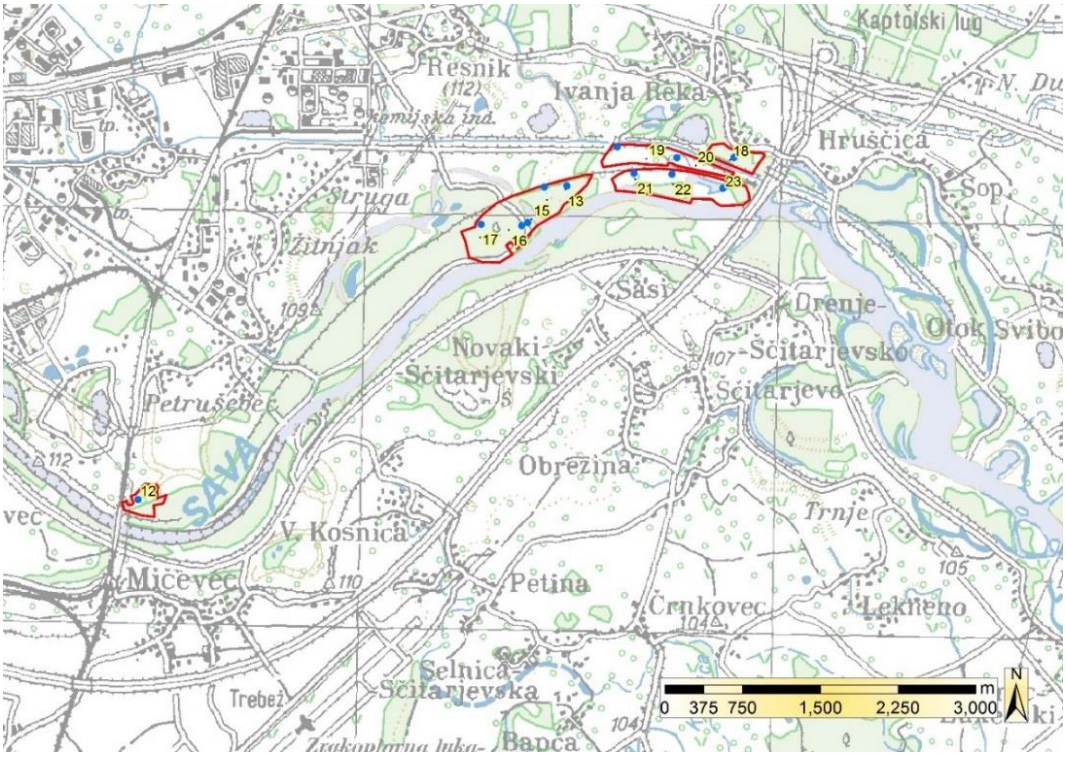

Slika 2- Područje istraživanja i odabrane plohe –istočni dio nizinskog dijela

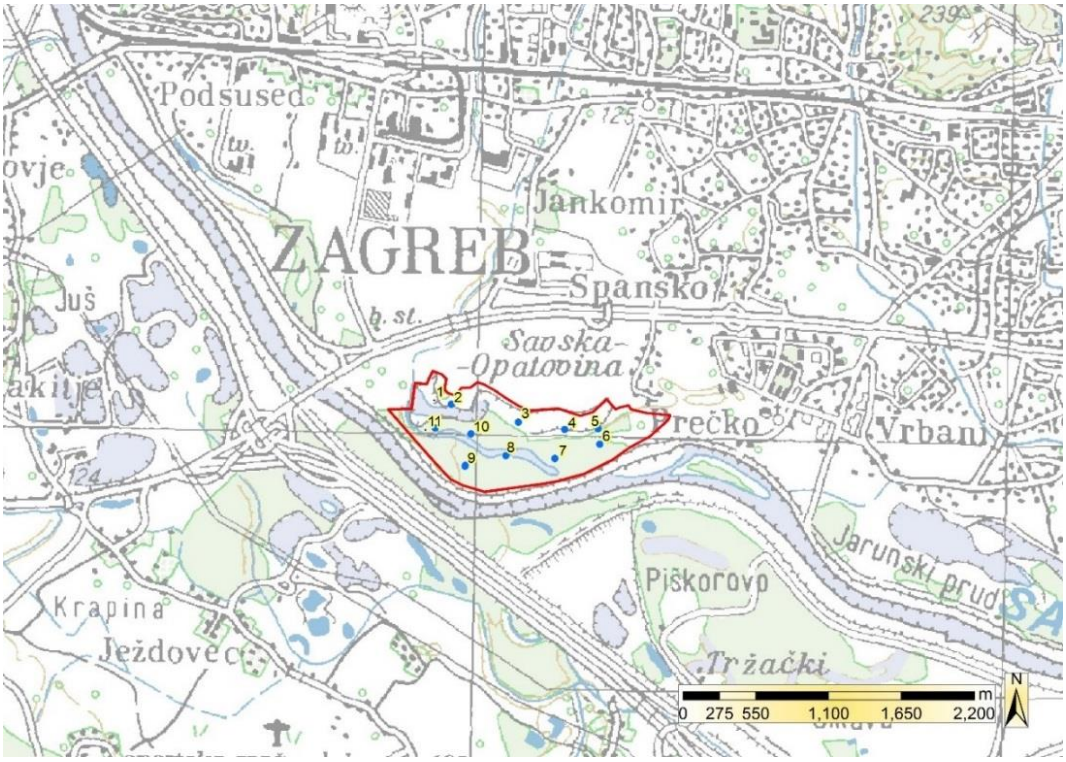

Slika 2- Područje istraživanja i odabrane plohe - zapadni dio nizinskog dijela

Odnos broja ploha i istraživane površine je prikazan u Tablici 2-1.

Tablica 2- Istraživana površina, broj ploha te njihov omjer

Područje	Površina (ha)	Broj ploha	Omjer ploha/površina
Brdsko	343,88	45	1 : 7,64
Nizinsko	210,05	23	1 : 9,13
Ukupno	553,93	68	1 : 8,15

2.2 TERENSKI RADOVI

Terenski radovi su obavljani u razdoblju od 14.11.2016. do 28.12.2016. godine. Ukupno je bilo 19 radnih dana terenskih radova.

Primjerna ploha je bila kružnog oblika, polumjera 12 m (452 m^2). Na njoj su izmjerena samo stabla prsnog promjera iznad 10 cm. Na podplohi kvadratnog oblika 6 x 6,5 m (39 m^2 -oznaka 1, Slika 2-) su se mjerila sva stabla prsnog promjera iznad 5 cm. Na podplohi 2 kvadratnog oblika 3,0 x 3,5 m (10,5 m^2) su se evidentirala samo stabla do 5 cm prsnog promjera (oznaka 2, Slika 2-).

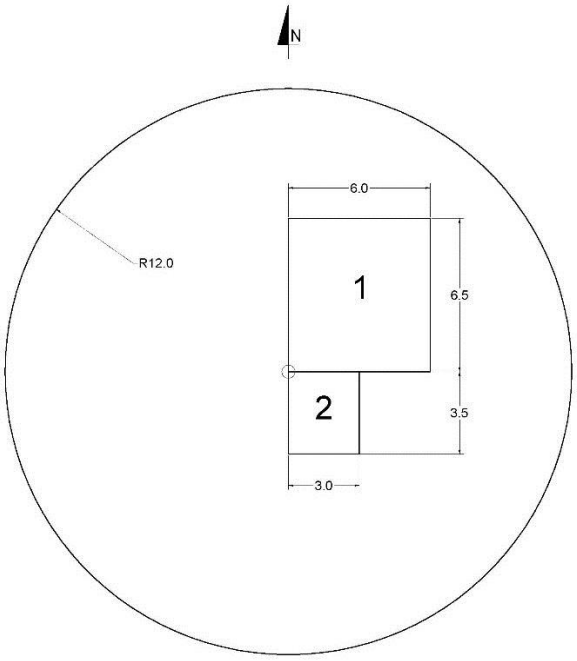

Slika 2- Skica terenske primjerne plohe s podplohama

Primijenjena metodologija polaganja ploha je bazirana na metodologiji Prve nacionalne inventuri šuma u Hrvatskoj **(Čavlović i Božić, 2008)** s jedinom razlikom, što su podplohe kvadratnog oblika. Kvadratne površine su izabrane radi pretpostavljenog teškog kretanja i postavljanja samih podploha u šikarama. Kvadratne plohe se mogu iskolčiti i potom se lakše uočavaju rubovi ploha u takvim sastojinama.

Postavljanjem centra plohe i nakon popunjavanja općih podataka (broj plohe, nagib, sklop, opis sastojine), pristupilo se izmjeri prsnih promjera svih stabala debljih od 5 cm na podplohi

1 dimenzija 6 x 6,5 m (39 m^2), odnosno debljih od 10 cm na cijeloj plohi prema vrstama drveća.

Uz mjerenje prsnih promjera i utvrđivanja vrste (prema šifrarniku **Pravilnika o uređivanju šuma, NN 79/15)**, određenom broju dominantnih stabala (2 - 4) se mjerila visina, azimut i točna udaljenost od centra, radi kasnije eventualne usporedbe LIDAR-skih i terenskih podataka na razini stabla. Također, mjerio se i određen broj visina po vrstama u različitim debljinskim stupnjevima radi izrade lokalne visinske krivulje.

Na podlohi 2 kvadratičnog oblika 3,0 x 3,5 m su se evidentirala samo stabalca prema vrsti drveća 1 - 5 cm prsnog promjera u dva debljinska razreda (1 - 3 cm, te 3 - 5 cm) na način da se evidentirao broj stabala u određenom debljinskom rasponu uz upisivanje prosječne visine za taj debljinski raspon po vrsti.

Terenski obrazac je priložen u Prilogu 1.

Prsni promjeri su se mjerili HAGLOF aluminijskom promjerkom s milimetarskom podjelom, a visine i udaljenosti ultrazvučnim daljinomjerom VERTEX IV. Visina je mjerena na decimetarsku točnost, a udaljenost na centimetarsku.

Radi određivanja prosječnog debljinskog prirasta, na svakoj plohi uzorkovala su se stabla glavne vrste na određenoj plohi, tj. prevladavajuće vrste u određenom debljinskom stupnju. Na svakoj plohi su uzorkovana 2 do 4 stabla u debljinskom stupnju 1 do 5 cm, 2 do 4 u debljinskom stupnju 5 do 10 cm, te minimalno 2 stabla u debljinskim stupnjevima iznad 10 cm. Za stabalca iznad 5 cm prsnog promjera uzimani su izvrtci Presslerovim svrdlom i očitavani na terenu, a za stabalca manjih promjera korištene su vinogradarske škare, da bi se to stabalce odnosno šiba prerezala i očitali godovi na prerezu. Očitana je širina zadnjih 10 godova u milimetrima, osim u slučajevima kada je to stabalce bilo mlađe od 10 godina, kada je zapisan i broj očitanih godova uz njihovu ukupnu širinu.

Za svaku plohu je snimljena i panoramska fotografija, odnosno slijed od više fotografija da se pokrije puni krug, s tim da je prva fotografija uvijek prema sjeveru (Prilog 2a, Prilog 2b i Prilog 2c).

Nakon obavljene izmjere, snimana je i točna lokacija centra plohe RTK/GNSS prijamnikom STONEX S10N te STONEX SX4 kontrolerom, koji osiguravaju centimetarsku točnost (Slika 2- i Slika 2-).

Slika 2- Primjer snimanja precizne koordinate za plohu 10

Slika 2- Primjer snimanja precizne koordinate za plohu 10 (bliži pogled)

Za određene plohe, uslijed gušćeg sklopa i konfiguracije terena nije bilo moguće snimiti koordinate centra plohe željene preciznosti (8 mm; FIXED mode). U takvim slučajevima je snimljena određena točka u blizini centra plohe za koju uređaj postiže željenu preciznost, te je od nje izmjerena udaljenost u centimetrima ultrazvučnim daljinomjerom VERTEX IV uz izmjeru azimuta od centra plohe prema snimljenoj koordinati, radi rekonstrukcije točne lokacije centra plohe. Upravo je za ovaj dio terenskog procesa trošeno značajno vrijeme (naime, skoro je za dvostruko produžavao provedeno vrijeme na plohi), kako se kod svake plohe uređaj trebao upaliti, spojiti sa GPS i GLONAS satelitima te CROPOS mrežom, postići točnost traženjem pogodne mikrolokacije, i na kraju pričekati da uređaj napravi 10 mjerenja radi izračuna preciznosti mjerenja (standardne devijacije).

Popis svih lokacija s XYZ koordinatama u HTRS96 TM koordinatnom sustavu se nalaze u Prilogu 3.

2.2.1 Prikupljeni podaci

S obzirom na istraživani tip sastojina, naglasak pri ovom istraživanju je bio na prsnim promjerima manjih dimenzija, odnosno na mjerenju visina i prirasta tih stabala što je vidljivo iz prikazane distribucije broja stabala (Tablica 2-2).

U narednim tablicama sumarno su prikazani mjereni podaci dobiveni nakon unosa i osnovne analize u EXCEL bazi podataka.

Tablica 2- prikazuje koliko je sveukupno izmjereno stabala na plohama te broj stabala kojima je očitana visina i prirast razvrstano po debljinskim stupnjevima širine 5 cm. Vidljivo je da izmjereno 2257 pojedinih stabala, od čega je 53,74 % mjerenih stabala bilo prsnog promjera ispod 10 cm, a 80,99 % stabala je bilo ispod 15 cm prsnog promjera.

Tablica 2- Prikaz broja uzorkovanih stabala, te stabala kojima su izmjerene visina i prirast prema debljinskim stupnjevima

	Debljinski stupanj (sredina debljinskog stupnja, cm)														
Mjerena varijabla	2,5*	7,5**	12,5	17,5	22,5	27,5	32,5	37,5	42,5	47,5	52,5	57,5	62,5	87,5	Ukupno
Prsni promjer	771	422	635	233	81	60	27	8	10	5	1	1	2	1	2257
Visina stabla	771	261	331	132	53	43	19	5	9	4	1	1	2	2	1634
Prirast	186	179	70	25	11	7	1	1	2						482

*suma mjerenih stabala na podplohi 2 (3x3,5 m)

**suma mjerenih stabala na podlohi 1 (6x6,5m)

Radi većeg broja podataka i preciznijeg ulapanja krivulja za veće promjere, iskorišteni su podaci nastali prilikom izrada programa gospodarenja šumama za područja unutar kojih se nalaze područja istraživanja. Dijelovi područja istraživanja (u višem stupnju progradacije) su obuhvaćeni tim Programima, ali za njih nisu određivani sastojinski parametri. Podaci mjereni o prirastu i visinama izmjereni u okolnim područjima su podaci o stablima koja su rasla u sličnim klimatsko-ekološko-sastojinskim uvjetima, stoga su iskoristiva za ovo istraživanje. Brdski dio područja se djelomično nalazi u sklopu gospodarske jedinice šumoposjednika „Čučerje-Šašinovec“ (**Berta i dr. - Oikon d.o.o., 2017)**, koja je trenutno u izradi i bit će važenja od 2017. do 2026. godine, a nizinski dio područja pripada ili se nalazi uz gospodarsku jedinicu Hrvatskih voda „Sava Zagreb“, koja je važenja od 2012. do 2021. godine **(Stojsavljević i dr. - Oikon d.o.o., 2012**).

Iz gospodarske jedinice „Čučerje-Šašinovec“ je preuzeto 2575 visina te 530 izvrtaka, a iz GJ „Sava Zagreb“ je preuzeto 393 izmjerene visine i 102 izmjerena debljinska prirasta za relevantne vrste drveća.

2.3 PODACI PRIKUPLJENI LIDAR-OM

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

Tehničke karakteristike LIDAR podataka su sljedeće:

- 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

Snimljeno je cijelo administrativno područje Grada Zagreba, te je evidentirano približno 1.500.000.000 (milijardu i pol) točaka.

Za istraživanje su dostavljeni georeferencirani i neobrađeni podaci za šire područje (izdvojene CORINE Land Cover kategorije), te su preklopom izdvojeni podaci za istraživano područje od 553,93 ha.
Kratki sumarni prikaz LIDAR podataka za istraživano područje prikazan je u Tablici 2-3.

Tablica 2- Sumarni prikaz LIDAR podataka za istraživano područje

Broj povrata	Broj točaka	Postotak (%)
Prvi	6.220.695	81,23
Drugi	1.354.462	17,69
Treći	81.843	1,07
Četvrti	1.517	0,02
Ukupno točaka	7.658.517	100,00

Prosječna gustoća točaka je 1,37 točaka/m^2 promatrajući sve točke. Međutim, promatrajući točke prvog povrata, koje bi predstavljale pravu gustoću točaka po jedinici površine, s obzirom da su ostali povrati dio iste zrake, vidljivo je da je prosječni broj točaka po m^2 i dalje veći od onog u specifikacijama (1,12 točaka/m^2), međutim daljnjom analizom će se utvrditi da li je ta gustoća ravnomjerno raspoređena na cijeloj površini snimanja.
S obzirom na vrijeme snimanja, LIDAR podaci predstavljaju vegetaciju bez lista, međutim istraživanja su pokazala da ta činjenica nema signifikantni utjecaj na konačni rezultat, osobito prilikom istraživanja koja se odnose na razinu plohe, sastojine ili područja (**Nasset, 2005; Anderson i Bolstad, 2013; White i dr. 2015**).

LIDAR-ski podaci korišteni pri izradi disertacije su obrađeni programom **Lastools,** koji služi za vizualizaciju, obradu, klasifikaciju, pretvorbu i ekstrakciju "sirovih" podataka. Ovo je program tvrtke **Rapidlasso,** a predstavlja kolekciju visoko učinkovitih alata koji mogu raditi na više jezgri te ih je moguće skriptirati radi automatiziranog i povezanog procesa izvršavanja zadataka. Program odnosno alate je moguće koristiti samostalno ili u okviru drugih programa kao npr. ArcGIS, QGIS ili ERDAS IMAGINE. Program je djelomično besplatan (osnovne funkcije), a tvrtka omogućava besplatnu tromjesečnu punu licencu za potrebe istraživanja u svrhu izrade disertacija, tj. u nekomercijalne svrhe. Tvrka Rapidlasso je dodijelila punu licencu za ovaj programski paket 2.1.2017. godine u trajanju od 99 dana.

2.4 OBRADA PODATAKA

2.4.1 Obrada terenskih podataka

Obradom terenskih podataka i njihovim unošenjem u Excel bazu podataka, pristupilo se izradi prirasnih i visinskih krivulja. Radi dovoljnog broja podataka za kvalitetno određivanje krivulja, podaci su grupirani za biološko-ekološki bliske vrste drveća za određene vrste.

Za potrebe izrade prirasnih krivulja grupirane su sljedeće vrste:

- Javor mliječ, gorski javor, obični orah i divlja trešnja
- Obični grab i crni grab
- Crna joha, poljski jasen, bijela vrba, vrba iva i krhka vrba
- Azijska platana, crna topola, trepetljika i bijela topola
- Divlja kruška, mukinja, brekinja, malolisna lipa i velelisna lipa
- OTB, obična lijeska, glog i obična borovica

Za potrebe izrade visinskih krivulja grupirane su sljedeće vrste:

- Javor mliječ i gorski javor,
- Mukinja, brekinja, malolisna lipa i velelisna lipa
- Bijela vrba, vrba iva i krhka vrba
- Crna topola, trepetljika i bijela topola
- OTB, obična lijeska, glog i obična borovica

Ovako složeni podaci uneseni su u program Statistica[3] pomoću kojeg su dobiveni parametri jednadžbi izjednačenja. Za izjednačavanje[4] mjerenih debljinskih prirasta (dvostruki radijalni prirast) je korištena sljedeća jednadžba $Y=b_0+b_1/X$, gdje je Y zavisna varijabla i u ovom slučaju predstavlja tečajni godišnji debljinski prirast, b_0 i b_1 su parametri funkcije izjednačenja (Tablica 2-), a X je nezavina varijabla (prsni promjer). Za funkciju izjednačenja je izabrana krivulja jer se uvidom u mjerene vrijednosti pretpostavilo da bi ona preciznije objasnila

[3] STATISTICA 6.0 Edition,. StatSoft inc.
[4] metodom najmanjih kvadrata

ovisnost prirasta o prsnom promjeru za manja stabalca s obzirom na njihovu sposobnost rasta u odnosu na starija i deblja stabla (Slika 2-8).

Tablica 2- Određeni parametri prirasnih krivulja za mjerene vrste odnosno grupe vrsta

Vrsta drveća	b_0	b_1	R^2	N
Klen	1,97365	-1,61079	0,194416	24
Obični grab i crni grab	1,85559	-1,56039	0,240744	36
Crni jasen	1,524452	-1,54521	0,474896	36
Obična bukva	2,66704	-5,05700	0,326341	158
Javor mliječ, gorski javor, obični orah i divlja trešnja	1,374935	-0,721611	0,167448	57
Hrast kitnjak	2,6852	-10,7675	0,358437	263
Hrast medunac	1,18810	-1,08261	0,213026	46
Obični bagrem	2,50940	-4,24858	0,396565	162
Crna joha, poljski jasen, bijela vrba, vrba iva i krhka vrba	3,35333	-5,90106	0,534118	65
OTB, obična lijeska, glog i obična borovica	1,122003	1,327783	0,245558	138
Negundovac	2,29976	-1,37490	0,149124	34
Azijska platana, crna topola, trepetljika i bijela topola	3,8943	-17,8446	0,679665	80
Divlja kruška, mukinja, brekinja, malolisna lipa i velelisna lipa	1,219084	-0,619691	0,329848	21

Iz prikazanih R^2 određenih prirasnih krivulja, razvidno je da su oni pretežno niski pokazujući iznimnu raznovrsnost prirasta što je i očekivano s obzirom na osobine istraživanih sastojina, a bile bi zasigurno i manje da nisu korišteni dodatni podaci. Na slici 2-8 je prikazan primjer mjerenih i izjednačenih vrijednosti tečajnog debljinskog prirasta za grupu vrsta *Javor mliječ, gorski javor, obični orah i divlja trešnja* vrlo niskog R^2. Ovo nije slučaj za grupe s brzorastućim vrstama gdje je R^2 visok, što bi se moglo objasniti time što su te vrste pretežno raspoređene u nizinskom dijelu gdje je manja varijabilnost uvjeta u staništu.

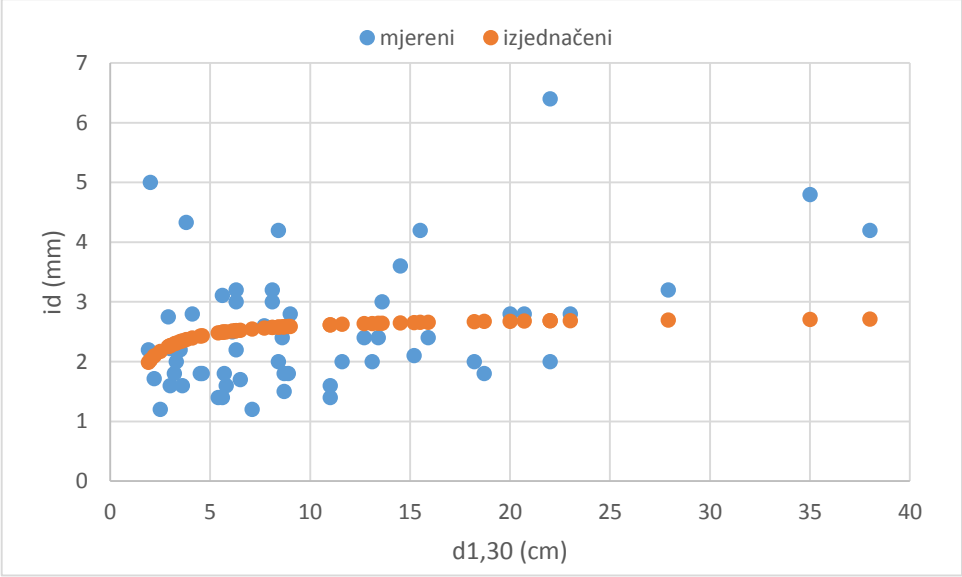

Slika 2- Tečajni debljinski prirast za grupu vrsta Javor mliječ, gorski javor, obični orah i divlja trešnja R^2=0,17

Za izjednačavanje[5] mjerenih visina je korištena Mihajlova jednadžba: $Y=1,3+b_0*(e^{b_1/X})$, gdje je Y zavisna varijabla i u ovom slučaju predstavlja visinu stabla, b_0 i b_1 su parametri funkcije izjednačenja (Tablica 2-), a X je nezavisna varijabla (prsni promjer).

Tablica 2- Određeni parametri visinskih krivulja mjerenih vrsta tj. grupa vrsta

Vrsta drveća	b_0	b_1	R^2	N
Klen	30,80848	13,93203	0,551995	67
Javor mliječ i gorski javor	34,18229	17,21684	0,669814	57
Crna joha	23,16302	7,45204	0,394622	37
Obični grab	29,41109	10,57614	0,47921	405
Obična bukva	34,23386	14,00775	0,670867	732
Poljski jasen	38,57844	16,82822	0,802957	16
Crni jasen	15,50765	7,05262	0,621176	103
Obični orah	13,86313	5,68522	0,412009	43
Crni grab	19,54585	11,13724	0,274494	32
Divlja trešnja	31,21956	17,08915	0,793919	68
Hrast kitnjak	34,23369	15,80595	0,557502	875
Hrast medunac	19,96592	13,05690	0,573243	173
Obični bagrem	31,31400	12,94811	0,724637	645
Bijela vrba, vrba iva i krhka vrba	23,91825	12,30173	0,749339	218
OTB, obična lijeska, glog i obična borovica	6,755292	2,537322	0,54629	630
Negundovac	21,52302	9,42804	0,498648	68
Crna topola, trepetljika i bijela topola	40,49961	23,43710	0,525443	286
Mukinja, brekinja, malolisna lipa i velelisna lipa	27,81250	16,73030	0,675011	84

Pomoću parametara prirasnih krivulja određen je promjer stabala u proljeće 2012. godine, odnosno prije 5 godina, oduzimajući petogodišnji debljinski prirast, nakon čega je pomoću parametara visinskih krivulja izračunata visina stabala prije 5 godina. Ovi izračunati podaci visina i prsnih promjera su bile nezavisne varijable korištene da bi se izračunala zavisna varijabla, nadzemna biomasa stabala prikazana u kg suhe tvari.

Za izračun biomase pojedinih stabala korištene su postojeće jednadžbe (modeli) iz dostupne domaće i strane literature. Kako nije bilo moguće pronaći specifične jednadžbe za svaku vrstu posebno, za neke vrste su korištene jednadžbe i parametri od druge vrste drveća sličnih biološko-ekoloških karakteristika (za mliječ od gorskog javora, za običnu borovicu od šmrike, za velelisnu lipu od malolisne lipe, za medunac od cera; Tablica 2-6). U drugom slučaju su bile dostupne jednadžbe i parametri na razini roda (npr. vrbe, odnosno topole). Za određene

[5] metodom najmanjih kvadrata

pronađene vrste u sklopu istraživanja postoje domaća istraživanja, ali relacije nisu iskoristive jer su istraživani npr. potencijali vrsta za plantaže i kulture kratke ophodnje (**Bogdan i dr., 2009; Kajba i Andrić, 2014**). Isto tako, određena istraživanja (**Topić i dr., 2008**) su obavljana na stablima premalih dimenzija da bi se koristila u ovom istraživanju ili se u sklopu ovog istraživanja nisu prikupljali svi potrebni prediktori da bi se mogli koristiti određeni modeli (npr. broj stabala iz panja ili promjer krošnje; **Topić i dr., 2000**). Međutim, sve regresijske jednadžbe imaju vrlo visoke R^2, a podaci na osnovu kojih su modeli izrađivani su potrebnih raspona (Tablica 2-6).

Na osnovu odabranih jednadžbi koje u većini slučajeva koriste samo prsni promjer za obračun nadzemne biomase stabla, a ponegdje i visinu ili opseg stabla umjesto prsnog promjera, izračunata je nadzemna biomasa svakog pojedinog stabla/stabalca te je zbrojena na razini plohe. Biomase stabalaca (<10 cm prsnog promjera) mjerenih na manjim plohama (3 x 3,5 m i 6 x 6,5 m) su prvo preračunate na razinu plohe polumjera 12 m, a nakon toga zbrojene sa biomasama ostalih stabala (> 10 cm prsnog promjera) mjerenih na plohi radijusa 12 m.

Pregled korištenih jednadžbi s pripadajućim parametrima i izvorima nalazi se u Tablici 2-6.

Tablica 2- Pregled korištenih jednadžbi za obračun biomase stabla i parametara s izvorima (Y-nadzemna biomasa stabala, D-prsni promjer, H-visina stabla)

Vrsta drveća (*lat*/hrv)	Jednadžba	Raspon promjera (cm)	Raspon visina (m)	Broj stabala	R^2	Parametri				Autor	Država u kojoj su izrađeni modeli
						a	b	c	d		
Acer campestre Klen	$Y = a \times D^b \times H^c$	1-13	3,1-10,8	48	0,9388	0,0339	1,5497	1,4926		**Albert i dr., 2014**	Njemačka (centralni dio)
Acer pseudoplatanus Gorski javor[6]	$Y = a \times D^{b+c\times D} \times H^d$	0,5-10,9	1,3-14,4	65	0,9743	0,0367	1,1261	0,0428	1,2648		
Acer platanoides Mliječ	$Y = a \times D^{b+c\times D} \times H^d$	0,5-10,9	1,3-14,4	65	0,9743	0,0367	1,1261	0,0428	1,2648		
Acer negundo Javor negundovac	$Y = a \times D^{b+c\times D} \times H^d$	0,5-10,9	1,3-14,4	65	0,9743	0,0367	1,1261	0,0428	1,2648		
Corylus avellana Obična lijeska	$Y = a \times H \times D^2 + b$	0,1-8,7	1,4-9,5	86	0,9279	0,0364	0,0308				
Alnus glutinosa Crna joha	$Ln\ Y = a + b \times Ln\ D$	8,3-47,3	/	16	0,926	–0,824827	1,9009			**Montero i dr., 2005**	Španjolska
Fraxinus ornus Crni jasen	$Ln\ Y = a + b \times Ln\ D$	7,2-52,2	/	27	0,963	–1,47166	2,21865				
Juniperus communis Obična borovica[7]	$Ln\ Y = a + b \times Ln\ D$	2,6-15,0	/	19	0,836	0,520337	1,29201				
Carpinus betulus Obični grab	$Y = a \times D^b$	7-24,9	prosj. 10,4;12,8	24	0,9254	0,258	2,1748			**Suchomel i dr., 2012**	Njemačka (jugozapadni dio)
Quercus petraea Hrast kitnjak	$Y = a \times D^b$	7-34,5	prosj. 15,8;163	24	0,9826	0,0927	2,5097				
Fagus sylvatica	$Y = a \times D^b \times H^c$	13-47	16,10-	15	0,972	0,9574	3,0460	–		**Stankić i dr.**	Hrvatska

[6] Korišten je model za *Acer Platanoides*

[7] Korišten je model za *Juniperus Oxycedrus*

Vrsta drveća (*lat*/hrv)	Jednadžba	Raspon promjera (cm)	Raspon visina (m)	Broj stabala	R^2	Parametri				Autor	Država u kojoj su izrađeni modeli
						a	b	c	d		
Obična bukva			31,50					1,1655		**2014**	
Fraxinus angustifolia Poljski jasen[8]	$\ln Y = a + b \ln H + c \ln D$	1,7-57,6	3,8-33,9	31	0,990	-2,9158	0,8088	1,9931		**Usoltsev i dr., 2016**	Euroazija[9]
Crategus monogyna Jednoplodnički glog	$\ln Y = a + b \ln H + c \ln D$	0,5-4,2	1,3-4,9	8	0,994	-0,8835	-0,4459	1,8918			Rusija
OTB[10]	$\ln Y = a + b \ln H + c \ln D$	0,5-4,2	1,3-4,9	8	0,994	-0,8835	-0,4459	1,8918			Rusija
Juglans regia Obični orah[11]	$\ln Y = a + b \ln H + c \ln D$	7,5-35,4	10-22,3	7	0,997	-2,9247	0,7603	1,9869			Rusija
Populus alba Bijela topola	$\ln Y = a + b \ln H + c \ln D$	1,6-37,4	3,4-23,8	513	0,988	-3,1864	0,7054	2,0151			Euroazija (Rusija, Kazahstan, Mongolija)
Populus nigra Crna topola	$\ln Y = a + b \ln H + c \ln D$	1,6-37,4	3,4-23,8	513	0,988	-3,1864	0,7054	2,0151			Euroazija (Rusija, Kazahstan, Mongolija)
Populus tremula Trepetljika	$\ln Y = a + b \ln H + c \ln D$	1,6-37,4	3,4-23,8	513	0,988	-3,1864	0,7054	2,0151			Euroazija (Rusija, Kazahstan, Mongolija)
Salix alba Bijela vrba	$\ln Y = a + b \ln H + c \ln D$	1,0-23,7	2,6-14,1	23	0,993	-3,0553	0,6430	1,9808			Euroazija (Rusija, Švedska)
Salix caprea Vrba iva	$\ln Y = a + b \ln H + c \ln D$	1,0-23,7	2,6-14,1	*23*	*0,993*	-3,0553	0,6430	1,9808			Euroazija (Rusija, Švedska)
Salix fragilis Krhka vrba	$\ln Y = a + b \ln H + c \ln D$	1,0-23,7	2,6-14,1	*23*	*0,993*	-3,0553	0,6430	1,9808			Euroazija (Rusija, Švedska)

[8] Korišten je model za *Fraxinus* spp

[9] model na osnovu podataka iz Rusije, Češke i Kine

[10] Korišten je model za *Crataegus spp.*

[11] Korišten je model za *Juglans manduriaca*

Vrsta drveća (*lat*/hrv)	Jednadžba	Raspon promjera (cm)	Raspon visina (m)	Broj stabala	R^2	Parametri				Autor	Država u kojoj su izrađeni modeli
						a	b	c	d		
Pyrus coomunis Pitoma kruška	$\ln Y = a + b \ln H + c \ln D$	7,5-35,4	10-22,3	7	0,997	-2,9247	0,7603	1,9869			Rusija
Sorbus aria Obična mukinja	$\ln Y = a+b(\ln D)$	0,9-8,25	2,5-8,12	20	0,970	-1,6365	1,9477			**Usoltsev V., 2016**	Rusija
Sorbus torminalis Brekinja	$\ln Y = a+b(\ln D)$	0,9-8,25	2,5-8,12	20	0,970	-1,6365	1,9477				
Tilia cordata Malolisna lipa	$Y = \exp(a+b \ln D+c \ln H)$ d	7,3-58,6	11,7-31,2	81	0,969	−3,032	2,115	0,538	1,020	**Čihák i dr., 2014**	Češka
Tilia platyphyllos Velelisna lipa[12]	$Y = \exp(a+b \ln D+c \ln H)$ d	7,3-58,6	11,7-31,2	81	0,969	−3,032	2,115	0,538	1,020		
Ostrya carpinifolia Crni grab	$Y = a + bD^2H + cD^2$	5,1-31,6	5,5-17,7	9	0,939	-4,5877	0,0052638	0,409		**Gasparini., 2006**	Italija
Platanus orientalis Azijska platana	$Y= a \times D^b$	3,4-10,9	1-11,7	22	0,97	0,3371	1,9			**Davis i Trettin, 2006**	SAD (Južna Karolina)
Prunus avium Divlja trešnja	$Y= \exp (a+b\ln D) c$	2,2-25,6	3,4-14,6	39	0,991	−2,216	2,450	1,009567		**Morhart i dr., 2016**	Njemačka
Quercus pubescens Hrast medunac[13]	$Y= a \times D^b$	2,5-325	/	10	0,935	0,0047	2,547			**LEONARDI i dr. 1999**	Italija (Etna)
Robinia pseudoacacia Obični bagrem	$Y=a+b(D^2xH)$	5-24,3	7,4-16,4	13	0,995	0,07	0,02			**Annighofer i dr., 2012**	Sjeverna Italija

[12] Prema *Tilia Cordata*

[13] Prema *Quercus cerris*

2.4.2 Obrada LIDAR podataka

Kako je prije spomenuto, LIDAR podaci obrađeni su programom LAStools[14] tvrtke Rapidlasso. Program predstavlja skup pojedinačnih alata koji se mogu pokretati samostalno ili usporedno, ovisno o procesu. U slučaju analize velikih područja, moguće je napraviti probni test na manjem području da bi se odredili željeni parametri, a nakon toga skriptirati potrebne korake s željenim parametrima i pokrenuti ih da program automatski izvrši zadano.

Korišteni alati i proces rada je prikazan u navedenoj shemi (Slika 2-9).

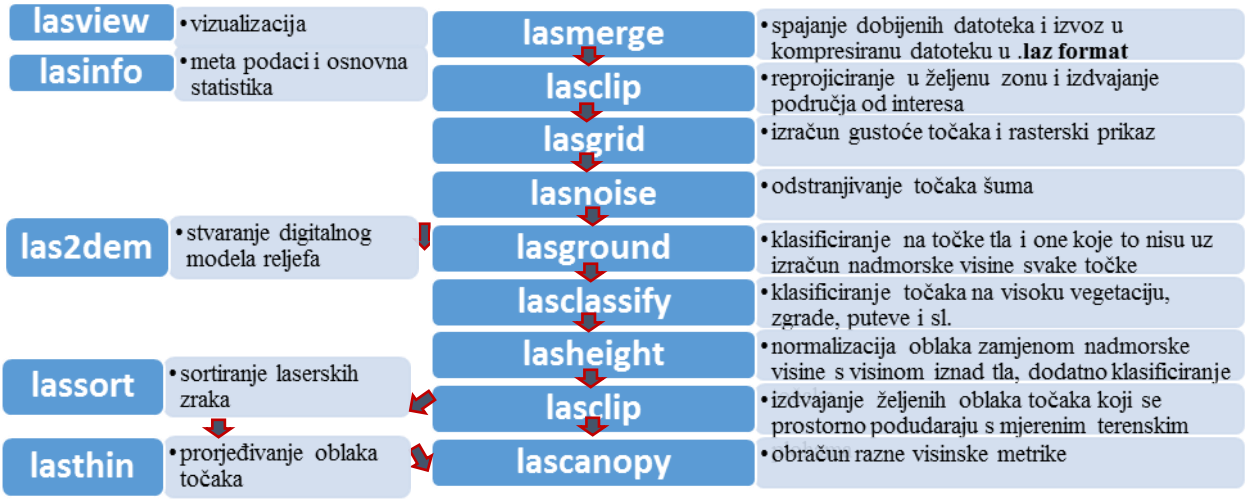

Slika 2- Korišteni alati i shema procesa rada

S obzirom da se izvorni LIDAR podaci čuvaju kao datoteke, gdje svaka predstavlja jedan let, podatke je moguće obrađivati na razini leta, ali s obzirom na tip istraživanja, prvo se pristupilo spajanju dobivenih podataka alatom **lasmerge** i izvozom dobivene datoteke u **.laz format.** Ovime se postigla učinkovita kompresija podataka od više gigabajta (Gb) u par stotina megabajta (Mb), čime se značajno štedi na prostoru tvrdog diska, s obzirom da se pri

[14] LAStools version 161114 (academic)

svakom koraku stvara nova datoteka. Format .LAZ je patent tvrtke Rapidlasso i predstavlja kompresiju približno 1:9 u odnosu na široko korišteni .LAS format.

Kako su dostavljeni podaci bili u zoni UTM 33, WGS84[15] radi preklapanja sa željenim područjem, podaci su morali biti reprojicirani i izdvojeni alatom **lasclip,** gdje su prvo podaci reprojicirani iz UTM 33 u HTRS TM zonu (EPSG code 3765), a nakon toga izdvojena su područja od interesa uz pomoć SHAPE datoteke u HTRS TM zoni. U nastavku se nalazi prikaz sučelja (Slika 2-) te naredbena linija (command line) u koje se vide odabrane postavke, a koje se po potrebi mogu dopunjavati i dodavati. Radi vizualizacije LIDAR podataka je potrebno pokrenuti alat **lasview**. U suprotnom, prostorni prikaz (Slika 2-10) je jednostavan i pokazuje samo obuhvat (extent) područja čime štedi računalne resurse prilikom izvršavanja naredbi.

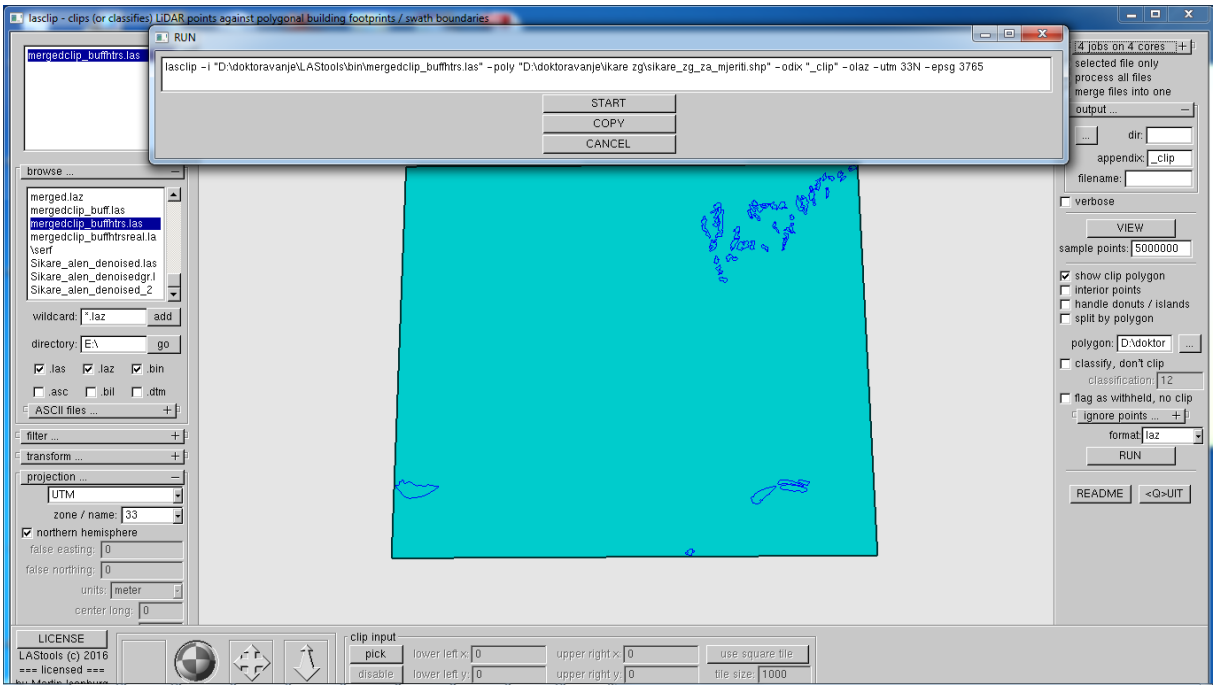

Slika 2- Prikaz alata lasclip

Nadalje, **lasinfo** nam pokazuje osnovne podatke o određenoj datoteci, u ovom slučaju području istraživanja (Tablica 2-).

[15] 33 zona UTM (**Universal Transverse Mercator**) mreže prema WGS 84 standardu (World Geodetic Standard 1984)

S pomoću alata **lasgrid**, među ostalim možemo izračunati gustoću točaka. Prikazana je gustoća točaka izračunata na 1 m^2 i prikazana kao raster. Vidljivo je da postoji nesrazmjer između gustoće točaka i određenih letova. Većinom su to gustoće između 1-2 točke/m^2, međutim vidljivi su kvadratići bez podataka (bez točaka), ali i oni preko 30 točaka (Slika 2-).

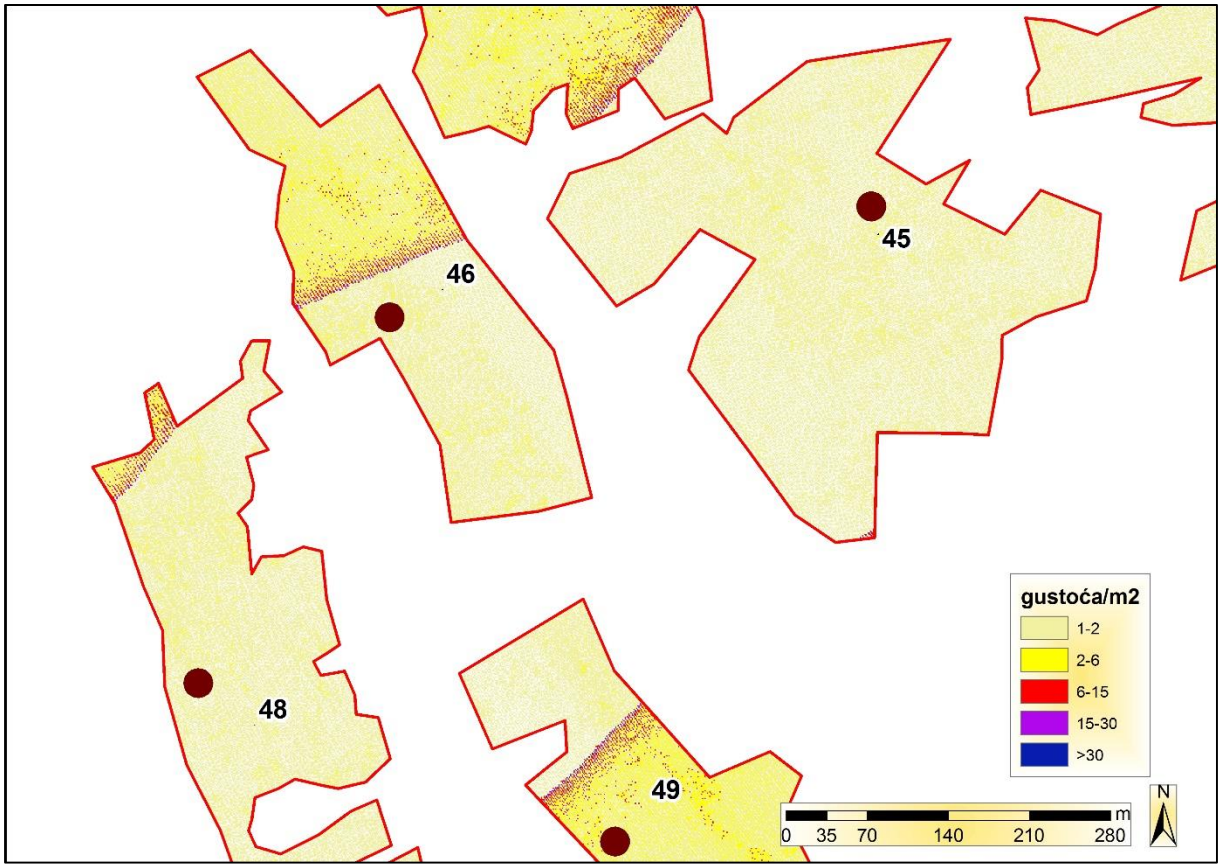

Slika 2- Primjerni prikaz gustoće LIDAR točaka

U nastavku, alat **lasnoise** pronalazi usamljene točke, te ih klasificira ili ih uklanja. Odabrana je opcija da ih ukloni koristeći zadane parametre („xy korak=4“, „z korak=1“, te izolirane 5), označavajući da traži izolirane točke u mreži 3 x 3 x 3 ćelije koja je svaka veličine 4 x 4 x 1 m, te da u tom skupu ćelija može biti do 5 točaka koje će u tom slučaju biti klasificirane kao „šum“ (noise). Ovime je izvorni oblak točaka za istraživano područje smanjen za približno 56.000 točaka (sa 7.658.517 na 7.602.654). Tablica 2- prikazuje raspored točaka prema povratima i gustoću smanjenog oblaka točaka.

Tablica 2- Podaci o broju točaka i gustoći oblaka točaka iz kojeg su izuzete točke "šûma"

Broj povrata	Broj točaka	Postotak (%)
Prvi	6.167.746	81,23
Drugi	1.351.611	17,69
Treći	81.780	1,07
Četvrti	1.517	0,02
Ukupno točaka	7.602.654	100,00
Gustoća točaka po m^2	1,37	
Gustoća prvog povrata po m^2	1,12	

Kada smo sigurni u kvalitetu korištenog oblaka točaka, možemo pristupiti idućoj klasifikaciji; na točke tla („ground points“) i točke iznad tla („non-ground points“) s alatom **lasground**. Prvotna klasifikacija je napravljena sa zadanim postavkama za divljinu („wilderness“) i prirodna područja („natural areas“) pri čemu je alat izbacivao razne pogreške („errors“). Razlog tomu je što u postavkama za divljinu odnosno prirodna područja, alat traži točke tla u 3 x 3 m i 5 x 5 m, za što je potreban veći broj točaka po m^2, a to ovdje nije slučaj. Stoga se nakon više ponavljanja odlučilo na sljedeće postavke koje su se pokazale najuspješnije; korišten je korak od 10 m (za rjeđe naseljena područja) uz to da ne uključuje šiljke (razliku u visini susjednih točaka) veće od 0,5 m, da nivelira i sve točke do 0,2 m iznad tla kao točke tla, te da koristi ekstrafini način pretrage za točkama tla što je preporučljivo na terene gdje postoje veći nagibi. Primjer naredbene linije:

lasground_new -i D:\doktoravanje\LAStools\bin\Sikare_alen_denoised.laz" -step 10 -down_spike 0.5 -offset 0.2 -extra_fine -compute_height -odix "_2gr" –olaz.

Također je dodana naredba da svakoj točki izračuna nadmorsku visinu, što se može i posebnim alatom **lasheight,** a potrebno je za daljnje klasifikacije ili za stvaranje digitalnog modela reljefa**.** Naredba „-odix“ predstavlja koji dodatak da doda imenu kreirane datoteke, a „-olaz“ definira output u formatu .laz. Na taj način je 4.250.680 točaka klasificirano kao točke tla, a ostalih 3.351.974 nije klasificirano.

Da bi smo izdvojili samo točke vegetacije, alatom **lasclassify** nastavlja se daljnja klasifikacija na vegetaciju, zgrade, puteve i sl. S obzirom da zadane postavke (korak 2 x 2 m i hrapavost („rugged“) 0,4 m) zbog gustoće oblaka nisu davale zadovoljavajuće rezultate, nakon više

iteracija i isprobavanja koraka do 6 x 6 m i hrapavosti do 1,5 m, najprecizniji rezultat[16] su dali sljedeći parametri; korak 4 x 4 m i hrapavost 0,6 m (korištena naredbena linija:

lasclassify -v -i "D:\doktoravanje\LAStools\bin\Sikare_alen_denoised_2gr.laz" -step 4 -rugged 0.6 -o "c16.laz").

Ovime se dobila sljedeća distribucija točaka prema kategorijama (Tablica 2-):

Tablica 2- Distribucija točaka nakon klasificiranja

Kategorija	Broj točaka	Postotak točaka (%)
Neklasificirano (kat.1)	878.675	11,56
Tlo (kat.2)	4.250.680	55,91
Visoka vegetacija (kat.5)	2.473.192	32,53
Zgrade (kat.6)	107	0,00
Ukupno	7.602.654	100,00

S obzirom da ovaj alat klasificira visoku vegetaciju samo onu iznad 2 m, velik broj točaka je ostao neklasificiran. Stoga se u **lasheight** alat unijela sljedeća naredbena linija:
lasheight -i "D:\doktoravanje\LAStools\bin\c16.laz" -replace_z -classify_below -1 7 -classify_between 0.5 1 3 -classify_between 1 2 4 -classify_between 2 30 12 -classify_above 40 18 -ignore_class 5 -ignore_class 6 -odix "_height" –olaz.
Na taj način:

- Izračunata je visina svake točke iznad točke tla, čime je oblak točaka normaliziran (tlo ima visinu 0 m)
- Radi dodatne sigurnosti sve točke ispod -1 m i iznad 40 m su klasificirane kao niski i visoki šum (kategorije 7 i 18)
- Sve točke od 0,5 do 1m klasificira kao nisku vegetaciju (kat.3), sve od 1 do 2 m da klasificira kao srednju vegetaciju (kat.4), a sve neklasificirano od 2 do 30 m iznad tla kao kategoriju 12 (preklop) pritom ignorirajući kategorije 5 i 6 (visoku vegetaciju i zgrade) da bi obuhvatio samo neklasificirane točke.

Ovime je približno 750.000 dodatnih točaka klasificirano kao neki tip vegetacije (kategorije 3, 4 i 12), te se dobila sljedeća distribucija točaka po kategorijama za istraživano područje (Tablica 2-):

[16] Na osnovu vizualne ortofoto provjere

Tablica 2- Distribucija točaka prema kategorijama nakon dodatne klasifikacije

Kategorija	Broj točaka	Postotak točaka (%)
Neklasificirano (kat.1)	131.899	1,73
Tlo (kat.2)	4.250.680	55,91
Niska vegetacija (kat.3)	109.266	1,44
Srednja vegetacija (kat.4)	571.067	7,51
Visoka vegetacija (kat.5)	2.473.192	32,53
Zgrade (kat.6)	107	0,00
Niski šuma (kat.7)	659	0,01
Preklop (kat.12)	65.784	0,87
Ukupno	7.602.654	100,00

Prag od 0,5 m iznad tla za klasificiranje točaka kao točaka vegetacije je u skladu s postojećim istraživanjima (**García i dr., 2010**), a izabran je također poštujući činjenicu da LIDAR tehnologija podcjenjuje visinu vegetacije (**Gaveau i Hill, 2003; Hopkinson i dr., 2005**) iz vrlo jednostavnog razloga što zraka lasera ne pogađa uvijek sami vrh stabla.

Nakon izvršenih klasifikacija, alatom **lasclip** su izdvojeni oblaci točaka koji se poklapaju s mjerenim terenskim plohama. Sveukupno, na 68 terenskih ploha radijusa 12 m nalazi se 44.814 točaka (Tablica 2-), što predstavlja prosječnu gustoću od 1,34 točke/m^2 ili 1,04 točku/m^2 promatrajući samo prvi povrat.

Tablica 2- Distribucija točaka prema povratima i gustoća

Broj povrata	Broj točaka	Postotak (%)
Prvi	34.450	76,87
Drugi	9.821	21,92
Treći	537	1,20
Četvrti	6	0,01
Ukupno točaka	44.814	100,00
Gustoća točaka po m^2	1,34	
Gustoća prvog povrata po m^2	1,04	

Promatrajući distribuciju točaka prema klasifikaciji (Tablica 2-) vidljivo je da su kao točke tla klasificirane 21.881 točka tj. 48,83 % svih točaka, a kao nekakav oblik vegetacije 22.132 točke tj. 49,39 % svih točaka. Dijeleći to s ukupnim brojem ploha (68) možemo zaključiti da je prosječni broj točaka vegetacije koji će se koristiti za modeliranje približno 659 točaka po plohi.

Tablica 2- Distribucija točaka prema klasifikaciji

Kategorija	Broj točaka	Postotak točaka (%)
Neklasificirano (kat.1)	801	1,79
Tlo (kat.2)	21.881	48,83
Niska vegetacija (kat.3)	816	1,82
Srednja vegetacija (kat.4)	3.926	8,76
Visoka vegetacija (kat.5)	17.117	38,20
Preklop (kat.12)	273	0,61
Ukupno	44.814	100,00

Međutim, promatrajući broj točaka i gustoću za svaku pojedinu plohu (Prilog 4) razvidno je da je situacija vrlo neujednačena te se kreće od 158 do 2838 točaka po plohi odnosno od 0,36 do 5,63 točke/m^2 (Tablica 2-). Ovo je prvenstveno rezultat nejednolikih visina i brzina leta aviona prilikom snimanja kao i različitih preklopa između letnih linija, a manje zbog postojanja vegetacije. Naime, postotak točaka koji predstavljaju drugi povrat zrake koji nastaje uslijed vegetacije je samo 21,92 % (Tablica 2-10).

Tablica 2- Prikaz osnovnih statističkih osobina za broj i gustoću točaka po plohama

Osobina	Broj točaka	Gustoća (točaka/m^2)
Aritmetička sredina	659,03	1,32
Standardna devijacija	484,63	0,95
0 % (minimum)	158,00	0,36
25 % (prvi kvartil)	315,50	0,65
50 % (medijana)	595,50	1,19
75 % (treći kvartil)	776,75	1,58
100 % (maksimum)	2.838,00	5,63

U nastavku su prikazane vizualne i tablične značajke tri izabrane plohe kao primjerne za različite gustoće točaka (***ploha 5***- Slika 2-12 i 2-13, Tablica 2-13*;* ***ploha 67***- Slika 2-14 i 2-15, Tablica 2-14*;* ***ploha 11***- Slika 2-16 i 2-17, Tablica 2-15*).*

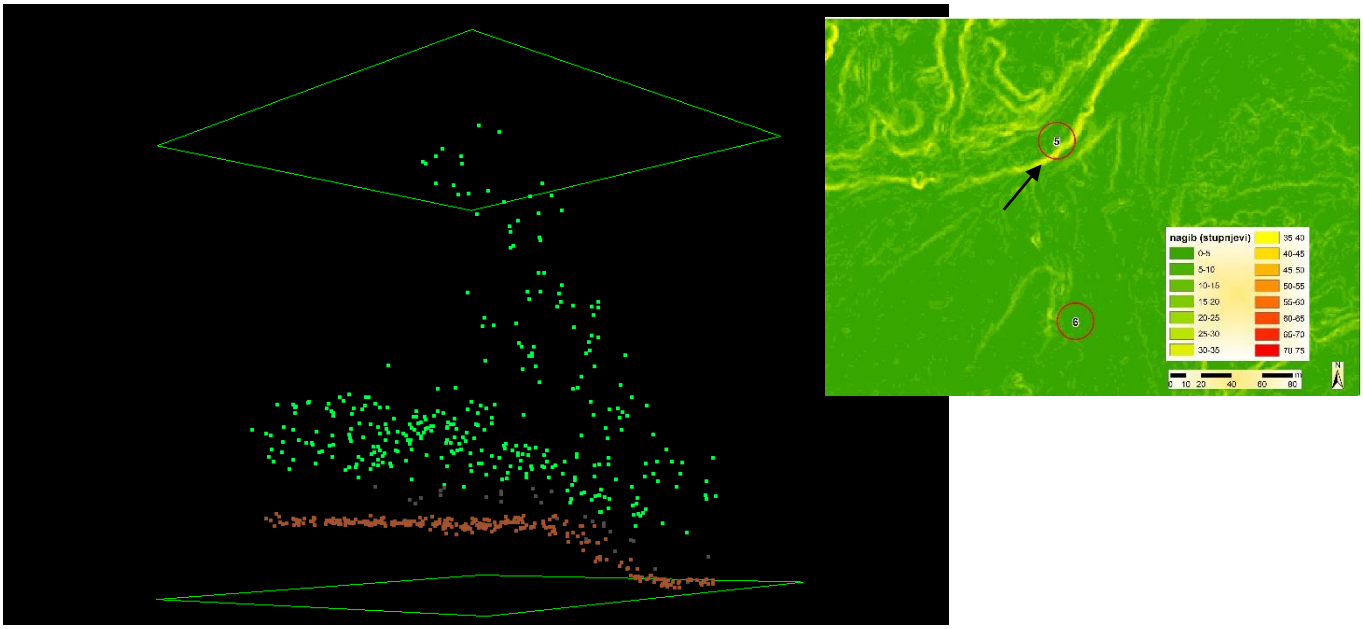

Slika 2- Prikaz oblaka točaka na plohi 5 sa smjerom prikazanog pogleda

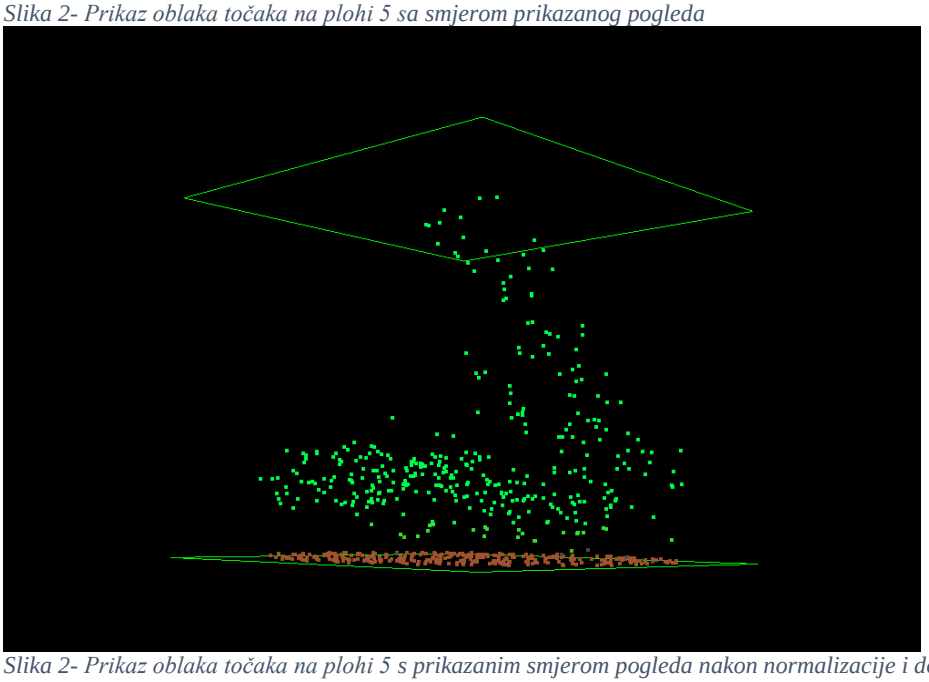

Slika 2- Prikaz oblaka točaka na plohi 5 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije

Tablica 2- Osnovne karakteristike oblaka točaka plohe 5

Ukupan broj točaka[17]	Točke vegetacije	Gustoća/m^2	Min. visina (m)	Maks. Visina (m)
660	359	1,31	0,67	20,3

[17] Smeđe točke> točke tla, sive>neklasificirano, zeleno>visoka vegetacija, svijetlozeleno>niska vegetacija, žuto>kategorija 12, preklop, neklasificirane točke vegetacije

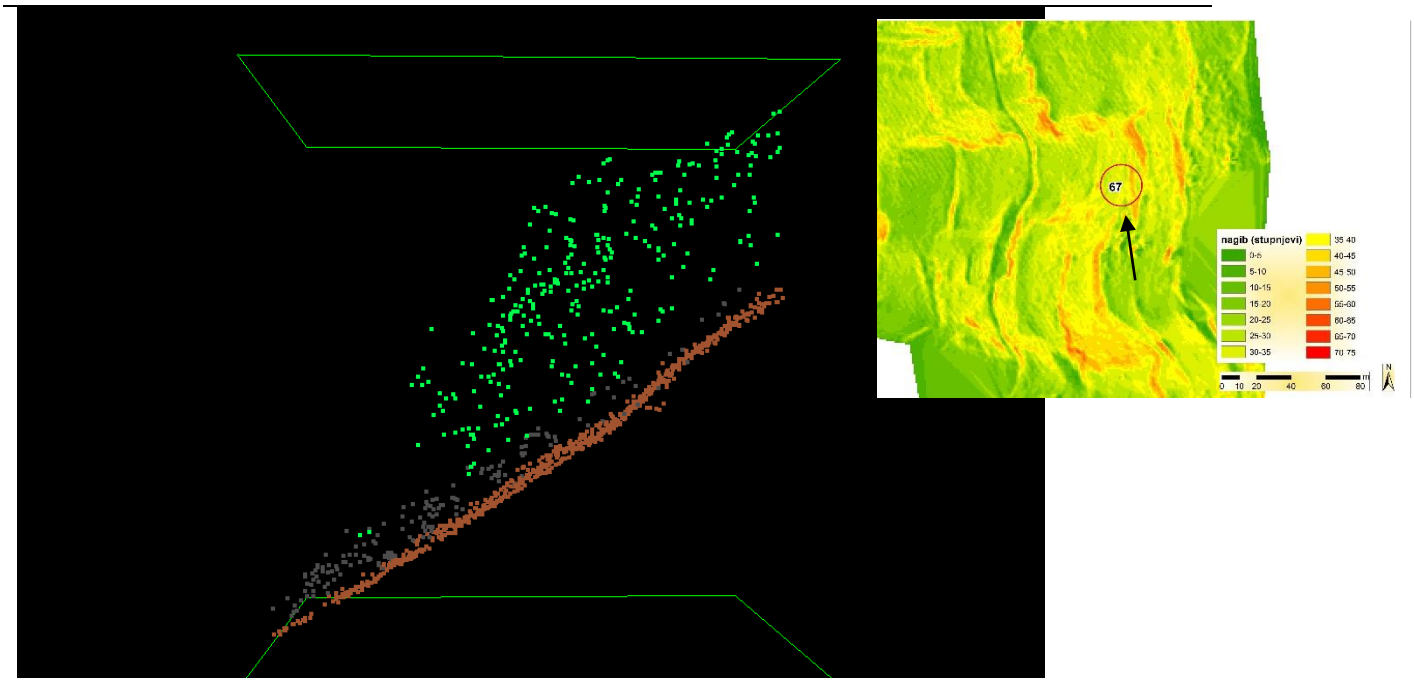

Slika 2- Prikaz oblaka točaka na plohi 67 sa smjerom prikazanog pogleda

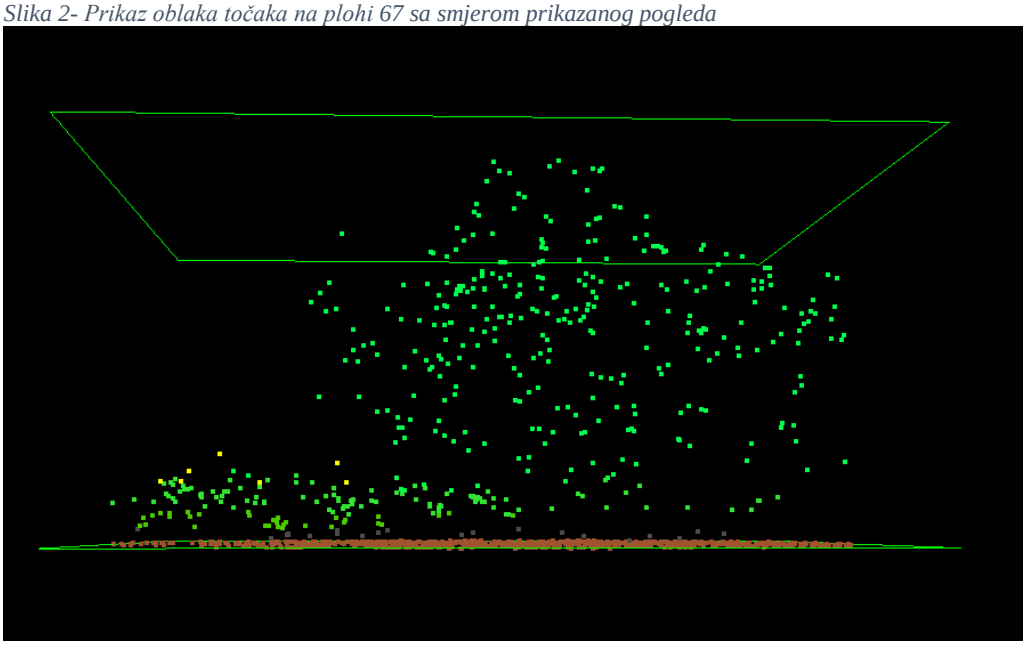

Slika 2- Prikaz oblaka točaka na plohi 68 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije

Tablica 2- Osnovne karakteristike oblaka točaka plohe 67

Ukupan broj točaka[18]	Točke vegetacije	Gustoća/m^2	Min. visina (m)	Maks. Visina (m)
1070	450	2,16	0,51	11,31

[18] Smeđe točke> točke tla, sive>neklasificirano, zeleno>visoka vegetacija, svijetlozeleno>niska vegetacija, žuto>kategorija 12, preklop, neklasificirane točke vegetacije

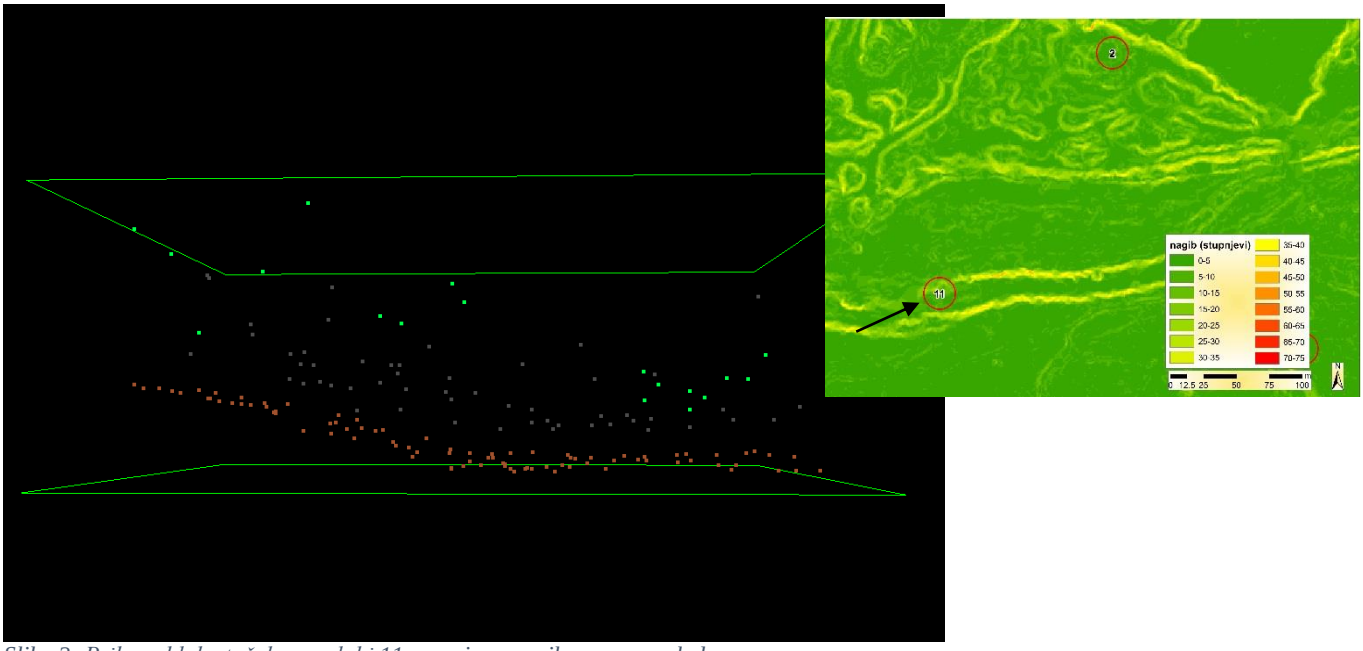

Slika 2- Prikaz oblaka točaka na plohi 11 sa smjerom prikazanog pogleda

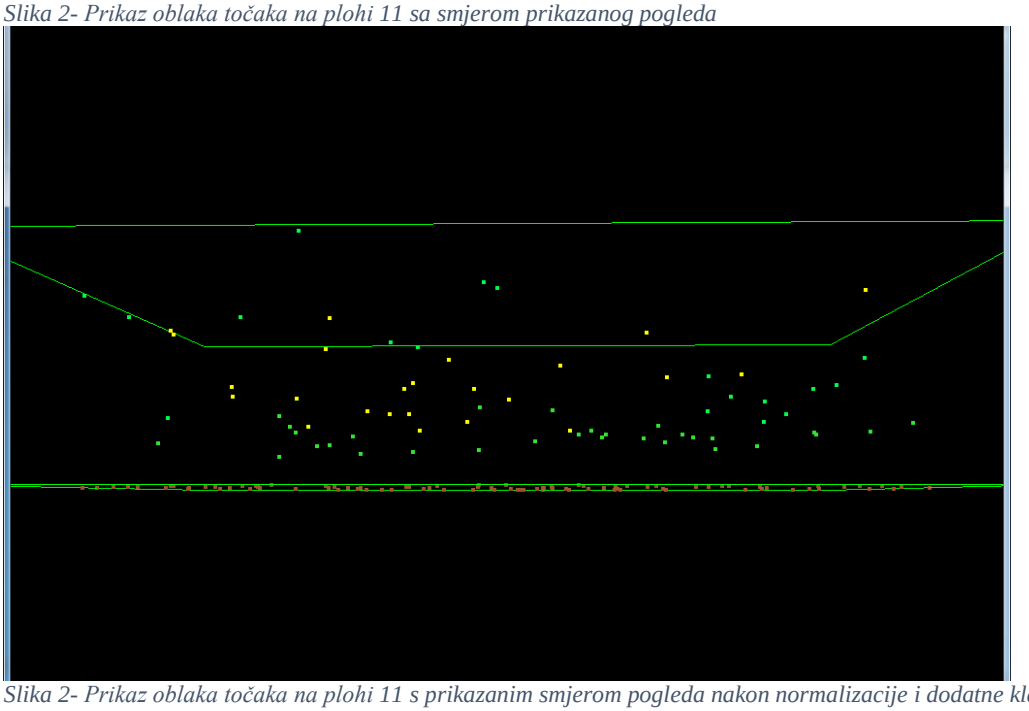

Slika 2- Prikaz oblaka točaka na plohi 11 s prikazanim smjerom pogleda nakon normalizacije i dodatne klasifikacije

Tablica 2- Osnovne karakteristike oblaka točaka plohe 11

Ukupan broj točaka	Točke vegetacije	Gustoća/m^2	Min. visina (m)	Maks. Visina (m)
160[19]	74	0,37	1,04	5,35

[19] Smeđe točke> točke tla, sive>neklasificirano, zeleno>visoka vegetacija, svijetlozeleno>niska vegetacija, žuto>kategorija 12, preklop, neklasificirane točke vegetacije

Konačno, s alatom **lascanopy** je za svaku plohu izračunata razna visinska metrika[20] kao ulazne varijable za daljnja modeliranja. Uz naredbu da analiza obuhvati samo točke iznad 0,5 m u kategorijama 3, 4, 5 i 12, izračunate su osnovne statističke osobine visine točaka vegetacije (minimum, maksimum, standardna devijacija, kvartilni razmak i sl.) te razni percentili[21], bicentili[22] i decili[23] točaka . Kako je vidljivo iz korištene naredbene linije:

lascanopy -i "D:\doktoravanje\LAStools\bin\c16_height.laz" –cores 4 -names -loc "D:\doktoravanje\statistička obrada\lokacije_lastools.txt" -height_cutoff 0.5 -keep_class 3 4 5 12 -all ***-min -max -avg -std -ske -kur -p 1 5 10 15 20 25 30 35 40 45 50 55 60 65 70 75 80 85 90 95 99 -b 10 20 25 30 40 50 60 70 75 80 90 -d 0.5 2.5 5 10 20 40 –cov –dns*** *ocsv*, ukupno je **izračunato 46 različitih varijabli.**

Uvidom u dosadađnja istraživanja uočeno je da su uspješno korištene još neke varijable kao npr. omjer točaka vegetacije koje pripadaju u gornju polovicu visine na plohi i svih točaka, nazvana „up_half_ratio“ (**Mitchell i dr., 2012**), koja je naknadno izračunata.

[20] Eng. Height metrics- razni podaci dobiveni na osnovu visina krošnje, stabla, pojedinih dijelova oblaka točaka i sl.

[21] Percentil visine predstavlja visinu određenog postotka točaka iznad tla npr. p35 predstavlja visinu 35 % točaka iz predmetnog oblaka iznad tla

[22] Bicentil visine predstavlja postotak točaka koji se nalazi između određenih visina određenih postotkom maksimalne visine predmetnog oblaka točaka npr. b55 predstavlja postotak točaka koji se nalazi između 0 % i 55 % visine te plohe/oblaka točaka

[23] Decili predstavljaju postotak točaka vegetacije između određenih, fiksnih raspona visine. U ovom slučaju između 0,5-2,5; 2,5-5; 5-10, 10-20 i >20 m

Radi dodatne karakterizacije područja i ploha, alatom **las2dem** je izrađen digitalni model reljefa s korakom 1 x 1 m, te je izabran format izlazne datoteke .bil (mogući su i drugi kao npr. ASC, IMG, FLT, XYZ, DTM, TIF, PNG ili JPG format). Nakon toga su u programu QGIS izrađeni rasteri hillshade (Slika 2-18, 2-20 i 2-22), nagib (slope) (Slika 2-19, 2-21 i 2-23) i ekspozicija radi vizualizacije i dodatnih informacija o terenskoj plohi. S obzirom na gustoću točaka, DMR se mogao izraditi s veličinom piksela od 0,5 x 0,5 m, a za neka i područja i s manjom veličinom piksela (gdje je oblak točaka gušći).

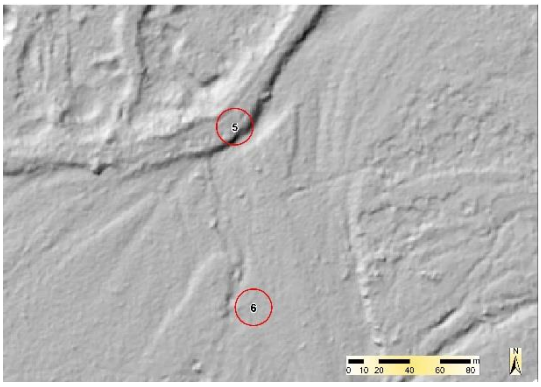

Slika 2- Hillshade područja točke 5 i 6

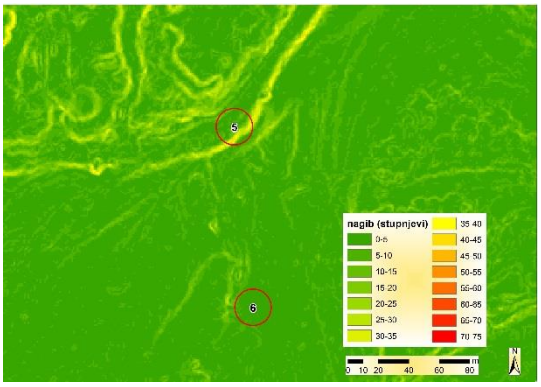

Slika 2- Nagibi oko područja točke 5 i 6

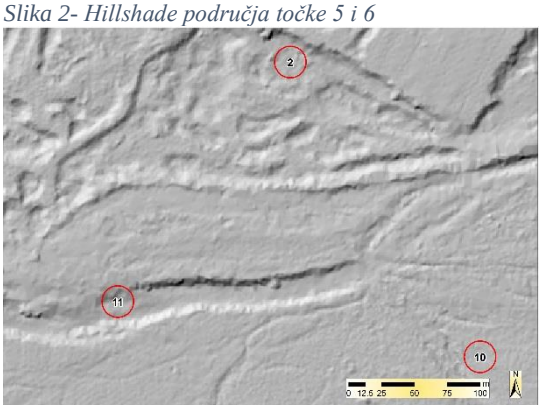

Slika 2- Hillshade područja točke 2, 10 i 11

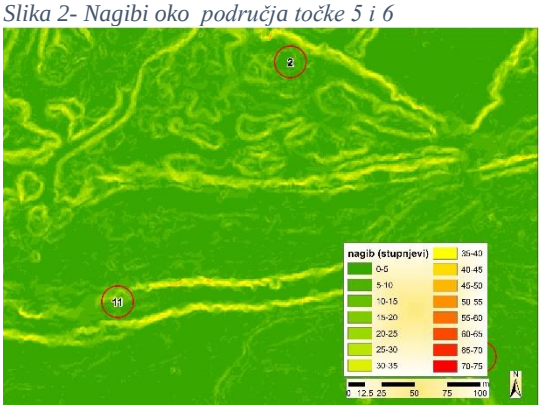

Slika 2- Nagibi oko područja točke 2, 10 i 11

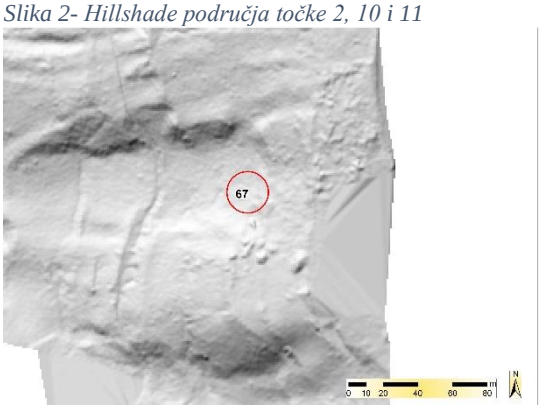

Slika 2- Hillshade područja točka 67

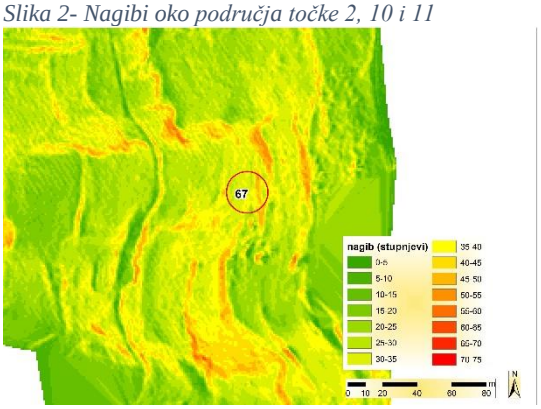

Slika 2- Nagibi oko područja točke 67

2.4.2.1 Priprema LIDAR podataka za testiranje hipoteze 2

Analizom gustoća oblaka točaka prema plohama i istraživanom području vidljivo je da je situacija u brdskom području vrlo raznolika, dok su gustoće točaka u nizinskom području ipak manjeg raspona (Prilog 4).

Kako je u brdskom području veći broj ploha, za testiranje Hipoteze 2, plohe su grupirane u tri grupe prema gustoćama točaka (Tablica 2-*)*. Ove grupe su korištene za izradu tri različita modela na osnovu različitih gustoća oblaka i provjeru njihove uporabljivosti.

S obzirom na manji broj ploha, za testiranje hipoteze 2 u nizinskom području korišten je dio ploha- izostavljajući dvije plohe s najrjeđim oblakom i tri plohe s najgušćim oblakom čime se dobio raspon gustoća od 0,63 do 1,66 točaka/m^2 čiji su se oblaci točaka onda dodatno prorijedili alatom **lasthin.** Alat **lasthin (**ili alat **las2las)** omogućava razne vrste filtriranja, selektiranja, označavanja i izdvajanja.

Koristeći jednostavno prorjeđivanje na način da se izdvoji svaku drugu ili treći točku, gustoća oblaka točaka će biti smanjena, međutim na taj način se izbriše doslovno svaka druga ili treća točka. Također se vjerojatno izbriše prvi povrat od zrake, a sačuva zadnji ili se izbriše drugi povrat, a sačuva prvi ili treći. Ovakav oblak točaka će imati vrlo različite karakteristike od oblaka s rjeđim zrakama, gdje su svi povrati sačuvani **(Isenburg, LAStools forum, 2014a)**.

Zato je bitno sačuvati/izostaviti sve povrate od određene zrake da bi se pravilno simulirala manja gustoća (odnosno manje laserskih zraka u sekundi) (**Isenburg, LAStools forum, 2015**).

Ovo je moguće prvo sortirajući zrake prema GPS vremenu (alatom **lassort-**koristeći naredbenu liniju *lassort -i "D:\doktoravanje\LAStools\bin\c16_height.laz" -gps_time -odix "_sort" –olaz*). Nakon čega se uvidom u raspored zraka prema vremenu (alatom **las2text** koristeći naredbenu liniju *las2txt -i "D:\doktoravanje\LAStools\bin\c16_height_sort.laz" -parse rnt*) vidjelo da je jedna zraka emitirana svakih približno 10 mikrosekundi. Stoga, da bi simulirali rijeđi oblak točaka, treba sačuvati po jednu zraku na 20 mikrosekundi (približno 50% izvornog oblaka), te 30 i 60 mikrosekundi da bi se izdvojila svaka treća, tj. šesta zraka za 33,3 odnosno 16,5 % izvornog oblaka.

Primjer korištene naredbene linije za dobivanje oblaka s 50 % početne gustoće:

lasthin -i "D:\doktoravanje\LAStools\bin\c16_height_sort.laz" –step 5 -thin_with_time 0.00002 -odix "_50" -olaz

Na ovaj način su za nizinsko područje pripremljeni podaci s prikazanim karakteristikama u Tablici 2-16.

Tablica 2- Raspored ploha i gustoća oblaka prema određenim grupama

Područje	Naziv grupe	Broj ploha	Raspon gustoća oblaka (točaka/m^2)	Prosječna gustoća oblaka (točaka/m^2)
Nizinsko[24]	Nx	18	0,63-1,66	1,20
	$Nx_{0,5}$	18	0,31-0,86	0,60
	$Nx_{0,33}$	18	0,22-0,61	0,41
	$Nx_{0,17}$	18	0,11-0,29	0,20
Brdsko	B1[25]	18	0,36-1,00	0,65
	B2[26]	18	1,00-1,75	1,54
	B3[27]	9	>1,75	2,64

Pripadnost ploha određenoj grupi prikazana je u sklopu Priloga 4.

Iako ovaj postupak omogućava simulaciju rjeđih laserskih zraka, pravo snimanje s rjeđim zrakama bi ipak bilo drukčije. Naime, ukoliko se smanji frekvencija laserskih zraka (broj emitiranih zraka u jedinici vremena), te zrake bi imale veću energiju i postojale bi veće mogućnosti za pojavljivanje više povrata. Isto tako, manja frekvencija znači i veći „footprint“ (trag, tlocrtni opseg svake zrake) samih zraka (**Isenburg, LAStools forum, 2014b)**.

Nakon prorjeđivanja oblaka točaka, uz pomoć alata **lascanopy,** izračunate su iste varijable kao i za inicijalnu gustoću oblaka.

[24] Plohe 1-23, izostavljene su 2, 11, 20, 21, 23
[25] Plohe 24, 25, 26, 27, 32, 33, 36, 37, 43, 44, 45, 48, 52, 53, 57, 60, 63, 64
[26] Plohe 29, 30, 34, 35, 38, 40, 41, 42, 46, 47, 50, 54, 55, 56, 58, 59, 61, 66
[27] Plohe 28, 31, 39, 49, 51, 62, 65, 67, 68

2.5 STATISTIČKA OBRADA PODATAKA

Razvijanje statističkog modela je vrlo kompleksan zadatak. Međutim, postoje općenite upute i usmjerenja koje osiguravaju da razvijeni model predstavlja stanje na terenu u prihvatljivim granicama pouzdanosti. Prema tome, **Laes i dr. (2011)** preporučuju da se koristi linearna regresija, koja je parametarska statistička metoda. Parametarske metode pružaju superiornije modele nad neparametarskim metodama, ali one podrazumjevaju par važnih pretpostavki o korištenim podacima kao npr. normalnost, homogenost varijance, ovisnost i sl. Eksploratornu podatkovnu analizu i izračun univarijantne statistike treba napraviti prije analize linearne regresije da se vidi da li je parametarska pretpostavka valjana i da se dobije uvid u strukturu podataka. Ukoliko se otkrije da je parametarska pretpostavka nije zadovoljena, postoje matematičke transformacije koje mogu transformirati zavisnu varijablu u normalnu distribuciju (npr. logaritmiranje, potenciranje, korjenovanje). U ovom slučaju, zavisna varijabla „biomasa_kg“ nema normalnu distribuciju, te je ta varijabla transformirana korjenovanjem drugim korijenom da bi se postigla normalna distribucija.

Cilj modeliranja je definirati najbolju jednadžbu koja predstavlja trend između dva seta varijabli i stvarnosti i treba biti oprezan prilikom uklapanja trenda da se ne bi pojedine točke previše uklopile/pretrenirale („over-fit“). Tijekom regresijske analize i uklapanja modela, koeficijent determinacije (R^2) je dobra vodilja. Međutim, potraga za najvećom vrijednosti R^2 može također dovesti do prevelikog uklapanja odnosno stvaranja prekompleksnog modela koji nestabilno reagira na najmanje promjene u podacima (Laes i dr. 2011).

Stoga se za procjenu prikladnosti modela koriste još mnogi pokazatelji, a u ovom slučaju će se promatrati „P“ vrijednost i vrijednost „F“ testa.

P vrijednost (eng. *probability* - vjerojatnost) pokazuje kolika je vjerojatnost da je rezultat točan, tj. da nije točan. Vrijednost manja od 0,05 (ili 0,01) – govori o tome da je vjerojatnost za neki događaj veća od 95% (99%) odnosno, što je ta vrijednost niža, vjerojatnost da će se izrađenim modelom dobiti točan rezultat je veća.

Vrijednost „F“ testa se računa prilikom analize varijance i pokazuje omjer varijance između skupina i unutar skupina. Što je ta vrijednost viša, to je model prikladniji za te podatke.

Laes i dr. (2011) navode da najbolji modeli prate općenita načela parsimonije (štedljivosti/sažetosti):

- Modeli trebaju imati što je manje moguće parametara
- Linearni modeli trebaju biti preferirani pred nelinearnim modelima
- Pokusi temeljeni na nekoliko pretpostavki trebaju imati prednost nad pokusima s puno pretpostavki
- Modeli trebaju biti pojednostavljeni sve do mjere dok nisu minimalni, a adekvatni.

Također, modeli bazirani na LIDAR podacima ne bi trebali imati više od tri varijable, svaka predstavljajući jednu od sljedećih vrsta metrike **(Laes i dr., 2011**):

1) Jedna vezana za visinu (percentili) odnosno visinska metrika
2) Jedna vezana za pokrovnost krošanja (bicentili, omjer točaka vegetacije i sl.) odnosno metrika krošnje
3) Jedna vezana za varijaciju podataka (standardna devijacija, varijanca i sl.).

Međutim, čak i kada su podaci linearno povezani, postoji opasnost od ekstrapolacije modelirane povezanosti izvan raspona terenski mjerenih podataka. Ovo se može izbjeći na način da postoji dovoljno ploha za statističku ispravnost kao i da plohe moraju pokriti cijeli raspon varijabilnosti mjerenog interesa. U ovom istraživanju se pazilo da se ovi uvjeti zadovolje što je vidljivo u rasporedu ploha prema područjima istraživanja (Tablica 2-), te u rasponu mjerenih podataka odnosno obračunate nadzemne biomase (Tablica 3-3).

S obzirom na mogućnost programa LAStools, do raznih varijabli je vrlo lako doći (uz preduvjet klasificiranog i pripremljenog oblaka točaka). Međutim, veliki broj varijabli može biti i prednost i nedostatak. Prednost jer imamo veću mogućnost izbora varijabli za modeliranje, a nedostatak jer to značajno otežava samo modeliranje i potrebna je veća stručnost radi izbora pravih varijabli.

Upravo radi toga je potrebno napraviti određenu predselekciju varijabli za daljnja modeliranja. U ovom slučaju, dostupne tj. izračunate varijable su podijeljene na grupe istovrsnih varijabli iz kojih je postepenom („stepwise“) regresijskom analizom određena statistički najznačajnija varijabla za svaku grupu varijabli u odnosu na određene grupe podataka (brdski/nizinski dio). Grupe su djelomično određene uz pomoć faktorske analize (Slika 2-) čime je dokazana istovrsnost određenih varijabli.

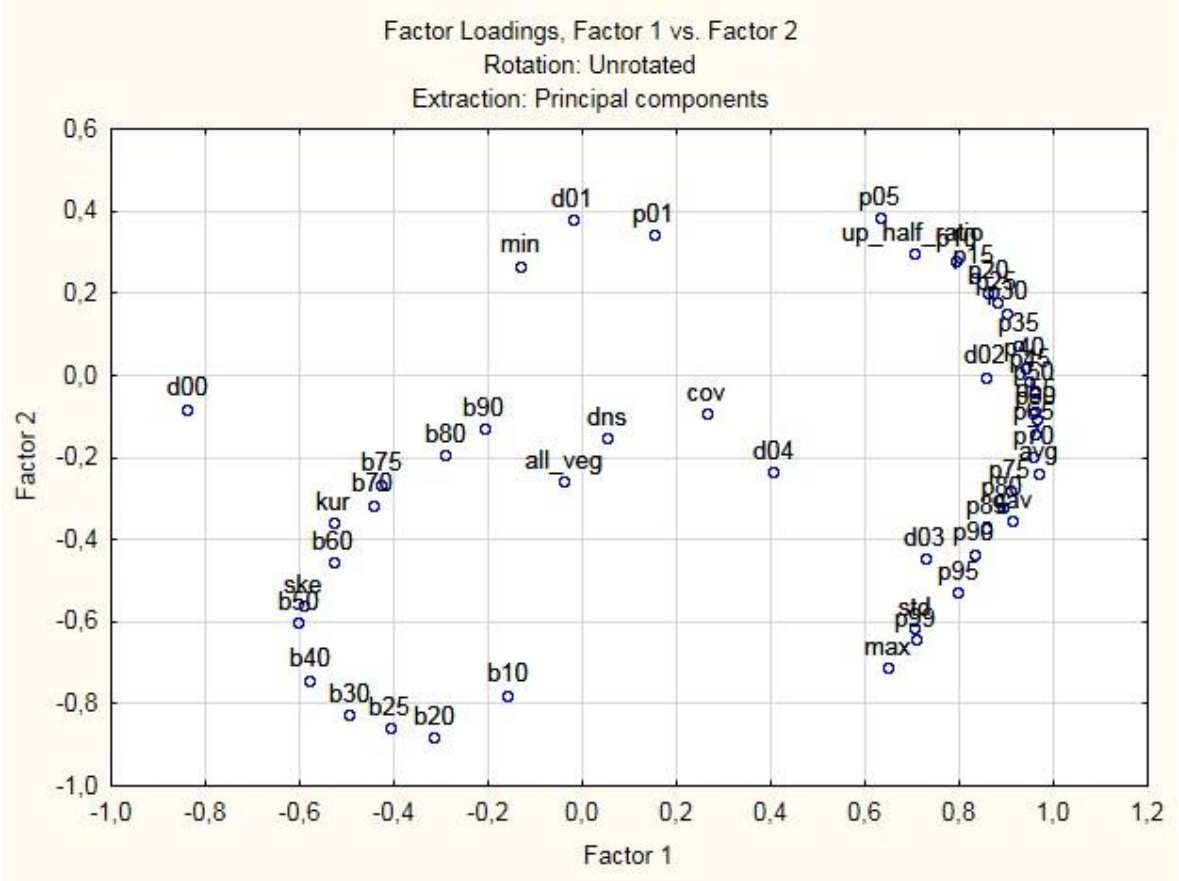

Slika 2- Prikaz faktorskih težina korištenih varijabli

Iz Slike 2-24 je vidljivo da su percentili grupirani na desnoj strani grafa, uz njihove statističke osobine (dolje desno), dok su bicentili grupirani na lijevoj strani grafa, a decili i varijable pokrovnosti u središnjem dijelu grafa.

Stoga na osnovu provedene faktorske analize i preporuka od strane **Laes i dr. (2011)**, varijable su grupirane u 4 različite grupe istovrsnih varijabli s ciljem izdvajanja najznačajnije varijable za svaku grupu:

Grupa 1- percentili visine (varijable oznake „**pXX**“)

Grupa 2- osnovne statističke osobine percentila visine (minimum> „**min**“, maksimum>“**max**“, prosjek>“**avg**“, standardna devijacija>“**std**“, kvartilni razmak>“**qav**“, asimetrija distribucije>“**ske**“ i zaobljenost distribucije>“**kur**“)

Grupa 3- bicentili visine (varijable oznake „**bXX**“)

Grupa 4- decili (**d00**> 0,5-2,5 m; **d01**>2,5-5 m;**d02**> 5-10 m; **d03**> 10-20 m; **d04**> 20-40 m), udio točaka vegetacije u ukupnom broju točaka (**cov**), udio prvog povrata točaka vegetacije u odnosu na ukupni broj točaka prvog povrata (**dns**), udio točaka vegetacije iznad 50 % visine vegetacije (up_half_ratio), itd

Postepenom („stepwise“) regresijskom analizom je za svaku grupu varijabli u određenoj grupi podataka (brdski/nizinski dio; plohe nizinskog dijela prorjeđivanog oblaka; grupirane brdske plohe po gustoći) determinirana statistički najznačajnija ili najznačajnije varijable ukoliko zadovoljavaju uvjet da im je pojedinačni koeficijent korelacije veći od 0,15 koje su uvrštene u konačnu postepenu „stepwise“ regresijsku analizu.

Za modeliranje i regresijske analize je korišten statistički program STATISTICA[28].

[28] STATISTICA 6.0 Edition,. StatSoft inc.

3 REZULTATI S RASPRAVOM

3.1 Rezultati terenske izmjere

Terensko istraživanje je provedeno na 68 ploha i ukupno je izmjereno 2257 stabala. Razdiobom mjerenih stabala (Tablica 3-1) uočavamo da je najviše stabala mjereno u kategoriji OTB. U ovu kategoriju su uvrštavane drvenaste vrste (pretežno grmolike) za koje ne postoji šifra **(Pravilnik o uređivanju šuma, NN 79/15)** kao što su na primjer svib, kalina, drijen, te šljiva i ostale voćkarice. One čine malo više od četvrtine mjerenih stabala (26,97 %) a nalaze se pretežno u najtanjem, prvom debljinskom razredu (474 od 608 mjerenih stabala).

Sljedeća vrsta po učestalosti je obični bagrem (16,61 %) gdje su većinom mjerena stabalca ispod 15 cm prsnog promjera (321 od 403 mjerenih jedinki). Obična lijeska, crni jasen, obični orah, hrast kitnjak, hrast medunac i bijela vrba su zastupljene sa po približno 5 %.

Tablica 3-1 prikazuje broj izmjerenih stabala po vrstama drveća.

Tablica 3- Broj uzorkovanih stabala s osnovnim statističkim karakteristikama po vrstama drveća

Vrsta drveća hrv.	Vrsta drveća lat.	Broj jedinki	Minimalni prsni promjer (cm)	Prosječni prsni promjer (cm)	Maksimalni prsni promjer (cm)	Standardna devijacija prsnog promjera (cm)
Klen	*Acer campestre*	23	5,3	12,1	21,7	3,11
Mliječ	*Acer platanoides L.*	5	11,1	15,9	18,7	3,09
Gorski javor	*Acer pseudoplatanus L.*	7	11,9	15,9	22,8	4,58
Crna joha	*Alnus glutinosa (L.) Gaertn.*	4	11,3	16,7	29,7	8,68
Obični grab	*Carpinus betulus L.*	11	4,0	8,9	16,4	4,58
Obična lijeska	*Corylus avellana L.*	103	2,0	3,3	10,2	1,51
Obična bukva	*Fagus sylvatica L.*	43	2,0	11,1	43,5	9,99
Poljski jasen	*Fraxinus excelsior L.*	21	5,7	12,4	21,6	4,71
Crni jasen	*Fraxinus ornus L.*	110	2,0	7,4	21,3	4,81
Obični orah	*Juglans regia L.*	65	20	18,1	36,6	7,43
Crni grab	*Ostrya carpinifolia Scop.*	39	6,9	13,0	22,3	3,27
Azijska platana	*Platanus orientalis L.*	4	8,3	10,8	15,3	3,08
Bijela topola	*Populus alba L.*	65	5,0	23,0	86,0	14,73
Crna topola	*Populus nigra L.*	46	6,5	23,0	62,0	12,58
Trepetljika	*Populus tremula L.*	19	5,0	12,0	15,5	3,12
Divlja trešnja	*Prunus avium L.*	61	2,0	9,2	30,1	6,32
Pitoma kruška	*Pyrus communis L.*	25	5,5	12,8	23,2	4,01
Hrast kitnjak	*Quercus petraea (Matt.) Liebl*	118	2,0	17,0	36,2	6,98

Hrast medunac	*Quercus pubescens Willd.*	169	2,0	14,0	50,7	6,94
Obični bagrem	*Robinia pseudoacacia L.*	403	2,0	10,0	27,1	4,81
Bijela vrba	*Salix alba L.*	87	2,0	10,6	44,3	8,50
Vrba iva	*Salix caprea L.*	32	10,0	14,7	30,7	5,18
Krhka vrba	*Salix fragilis L.*	34	2,0	10,3	37,9	9,93
Obična munjika	*Sorbus aria (L.) Crantz*	4	5,4	9,1	17,2	5,49
Brekinja	*Sorbus torminalis (L.) Crantz*	23	2,0	8,2	17,2	3,83
Malolisna lipa	*Tilia cordata Mill.*	13	10,5	20,6	39,5	9,32
Velelisna lipa	*Tilia platyphyllos Scop.*	2	25,0	28,1	31,1	4,31
Jednoplodnički glog	*Crataegus monogyna Jacq.*	60	2,0	7,3	18,1	3,93
OTB		608	2,0	4,4	31,4	4,30
Obična borovica	*Juniperus communis L.*	4	5,1	6,2	6,7	0,74
Negundovac	*Acer negundo L.*	49	2,0	7,8	13,2	3,57
Ukupno		**2257**	**2,0**	**9,8**	**86,0**	**8,18**

Prostorni raspored mjerenih vrsta se može prikazati na osnovu prevladavajućih vrsta na svakoj plohi. Kako je vidljivo (Tablica 3-2) u nizinskom području istraživanja su većinom zastupljene vrbe i topole, dok je u brdskom dijelu područja situacija očekivano raznovrsnija. Obični bagrem kao prevladavajuća vrsta se javlja na trećini ploha, a kitnjak i medunac na približno petini ploha. Plohe označene nazivom Voćkarice predstavljaju u nekoliko slučaja zarasle livadne površine divljom trešnjom, a u ostalima zašikarene i zapuštene voćnjake.

Tablica 3- Prikaz prevladavajućih vrsta drveća na mjerenim plohama

Područje istraživanja	**Prevladavajuća vrsta**	**Broj ploha**
Nizinsko	Obični bagrem	1
	Obični bagrem i topole	1
	Topole i javor negundovac	2
	Vrbe	1
	Vrbe i topole	18
Nizinsko ukupno ploha		**23**
Brdsko	Obični bagrem	11
	Obični bagrem i hrast medunac	1
	Obični bagrem i obični orah	4
	Obični bagrem i voćkarice	1
	Voćkarice	7
	Obična Bukva	1
	Hrast kitnjak i obična bukva	2
	Hrast kitnjak	9
	Hrast medunac	9
Brdsko ukupno ploha		**45**
Sveukupno		**68**

Primjenom izabranih jednadžbi za obračun nadzemne biomase stabla (Tablica 2-) i njihovim zbrojem dobivena je težina nadzemne biomase u kilogramima suhe tvari po plohama u godini snimanja LIDAR podataka (Tablica 3-3).

Tablica 3- Prikaz težine suhe tvari po plohi i po hektaru

Ploha	Biomasa po plohi (kg)	Biomasa po plohi (t)	Biomasa po hektaru (kg/ha)	Biomasa po hektaru (t/ha)
1	2.343,27	**2,34**	51.797,70	**51,80**
2	865,51	**0,87**	19.131,94	**19,13**
3	3.154,94	**3,15**	69.739,38	**69,74**
4	803,99	**0,80**	17.772,05	**17,77**
5	4.619,02	**4,62**	102.102,85	**102,10**
6	1.077,72	**1,08**	23.822,84	**23,82**
7	1.244,97	**1,24**	27.519,82	**27,52**
8	1.883,54	**1,88**	41.635,39	**41,64**
9	2.202,60	**2,20**	48.688,06	**48,69**
10	414,21	**0,41**	9.155,95	**9,16**
11	764,36	**0,76**	16.896,04	**16,90**
12	1.474,02	**1,47**	32.583,05	**32,58**
13	1.139,53	**1,14**	25.189,23	**25,19**
14	1.528,55	**1,53**	33.788,42	**33,79**
15	2.213,89	**2,21**	48.937,64	**48,94**
16	927,48	**0,93**	20.501,81	**20,50**
17	1.742,28	**1,74**	38.512,74	**38,51**
18	4.655,00	**4,65**	102.897,99	**102,90**
19	162,45	**0,16**	3.591,04	**3,59**
20	784,96	**0,78**	17.351,33	**17,35**
21	934,86	**0,93**	20.664,99	**20,66**
22	2.614,14	**2,61**	57.785,08	**57,79**
23	2.133,98	**2,13**	47.171,27	**47,17**
24	2.143,53	**2,14**	47.382,38	**47,38**
25	683,33	**0,68**	15.105,00	**15,10**
26	2.524,93	**2,52**	55.813,13	**55,81**
27	189,11	**0,19**	4.180,20	**4,18**
28	352,90	**0,35**	7.800,76	**7,80**
29	132,55	**0,13**	2.930,04	**2,93**
30	6.083,87	**6,08**	134.482,97	**134,48**
31	287,86	**0,29**	6.363,02	**6,36**
32	1.295,02	**1,30**	28.626,21	**28,63**
33	2.320,81	**2,32**	51.301,18	**51,30**
34	1.756,46	**1,76**	38.826,21	**38,83**
35	1.110,29	**1,11**	24.542,74	**24,54**
36	4.113,42	**4,11**	90.926,62	**90,93**
37	1.122,76	**1,12**	24.818,41	**24,82**
38	1.534,00	**1,53**	33.908,93	**33,91**
39	2.702,96	**2,70**	59.748,61	**59,75**
40	2.572,36	**2,57**	56.861,74	**56,86**
41	906,04	**0,91**	20.027,98	**20,03**
42	1.010,42	**1,01**	22.335,11	**22,34**
43	2.190,03	**2,19**	48.410,39	**48,41**
44	3.573,06	**3,57**	78.981,90	**78,98**
45	1.263,67	**1,26**	27.933,34	**27,93**
46	5.640,80	**5,64**	124.689,16	**124,69**
47	1.265,89	**1,27**	27.982,35	**27,98**
48	2.669,93	**2,67**	59.018,46	**59,02**
49	889,49	**0,89**	19.662,04	**19,66**
50	1.064,40	**1,06**	23.528,38	**23,53**
51	1.607,33	**1,61**	35.529,83	**35,53**
52	2.887,54	**2,89**	63.828,63	**63,83**
53	5.243,67	**5,24**	115.910,55	**115,91**
54	1.764,87	**1,76**	39.012,14	**39,01**
55	1.805,98	**1,81**	39.920,89	**39,92**
56	1.340,00	**1,34**	29.620,60	**29,62**
57	4.456,13	**4,46**	98.502,07	**98,50**
58	1.401,93	**1,40**	30.989,50	**30,99**
59	2.535,33	**2,54**	56.043,05	**56,04**
60	1.025,56	**1,03**	22.669,89	**22,67**
61	1.618,58	**1,62**	35.778,37	**35,78**
62	6.034,71	**6,03**	133.396,37	**133,40**
63	1.115,47	**1,12**	24.657,39	**24,66**
64	2.571,75	**2,57**	56.848,15	**56,85**
65	2.780,41	**2,78**	61.460,47	**61,46**
66	2.256,36	**2,26**	49.876,59	**49,88**
67	3.699,04	**3,70**	81.766,63	**81,77**
68	1.672,33	**1,67**	36.966,59	**36,97**

Tablica 3-3 prikazuje težinu suhe tvari nadzemne biomase po plohi u kilogramima i tonama,

uz te vrijednosti preračunate na hektar površine[29] (plohe 1-23- nizinski dio; plohe 24-68- brdski dio).

Osnovne statističke karakteristike obračunate biomase u tonama suhe tvari promatrajući sve plohe su vrlo šarolike, prikazujući plohe koje su tek u inicijalnoj fazi zaraštanja do ploha sa značajnom nadzemnom biomasom na njima, uslijed postojanja stabala i većih dimenzija ili uslijed velikog broja stabala (Tablica 3-4).

Tablica 3- Osnovne statističke karakteristike obračunate šumske nadzemne biomase po plohama

Statistička karakteristika	Biomasa na plohi (t)	Biomasa po hektaru (t)
Aritmetička sredina	2,02	44,75
Standardna devijacija	1,41	31,23
0 % (minimum)	0,13	2,93
25 % (prvi kvartil)	1,05	23,31
50 % (medijana)	1,65	36,37
75 % (treći kvartil)	2,57	56,85
100 % (maksimum)	6,08	134,48

Tablica 3-5 prikazuje osnovne statističke karakteristike obračunate šumske nadzemne biomase po plohama razvrstane po područjima. Ovdje je razvidno da je biomasa nizinskog područja niža od one u brdskom području.

Tablica 3- Osnovne statističke karakteristike obračunate šumske nadzemne biomase po plohama i po područjima

Statistička osobina	Nizinsko područje		Brdsko područje	
	t/ploha	t/ha	t/ploha	t/ha
Aritmetička sredina	1,76	38,14	2,16	47,75
Standardna devijacija	1,18	26,13	1,51	33,34
0 % (minimum)	0,16	3,59	0,13	2,93
25 % (prvi kvartil)	0,90	19,82	1,12	24,66
50 % (medijana)	1,47	32,58	1,76	38,83
75 % (treći kvartil)	2,21	48,81	2,67	59,02
100 % (maksimum)	4,66	102,90	6,08	134,48

Radi prikaza sastojinskih elemenata ovih sastojina uobičajenim šumarskim mjerama (npr. m^3/ha drvne zalihe iznad 7 cm ili broj stabala po hektaru) potrebno je preračunati mjerene ili obračunate vrijednosti.

[29] Vrijednost biomase na plohi množena s udjelom površine plohe u hektar površine (npr. ploha 30; 6,08 t*10000m^2/452m^2=134,48 t/ha)

Broj stabala (Tablica 2-2) u prvim debljinskim stupnjevima je velik. Naime, od 2257 mjerenih stabala na svim plohama, ispod uobičajene taksacijske granice (10 cm prsnog promjera) je 1192 stabalaca. Međutim, iako je to tek malo više od polovice mjerenih stabala, za debljinski stupanj do 5 cm su mjerena stabalca na podplohi 3 x 3,5 m, a stabla u debljinskom stupnju od 5-10 cm su mjerena na podplohi 6 x 6,5 m. Podijelivši ukupan broj mjerenih stabala po debljinskim stupnjevima sa brojem ploha i preračunavši ih na hektar površine razvidno je da se na istraživanim područjima prosječno nalazi 10.798 stabala po hektaru prsnog promjera do 5 cm, 1587 stabala po hektaru prsnog promjera 5 - 10 cm, te 346 stabala po hektaru iznad prsnog promjera od 10 cm. Dalje, od ovih 346 stabala iznad 10 cm prsnog promjera, 81,5 % tj. 293 stabala je prsnog promjera od 10 do 20 cm, a ostatak (53 stabala po hektaru) je prsnog promjera iznad 20 cm prsnog promjera.

Obračun volumena sastojina po hektaru je napravljen brzim (grubim) načinom, koristeći općeprihvaćene koeficijente. Prvi od njih je BEF (biomass expansion factor) koji se kreće između 1,15 za odrasla stabla do 4,12 za mlada stabla (**IPCC, 2003**), samo za potrebe ovog obračuna uzet će se vrijednost koeficijenta 3, u skladu s tim da je većina stabala vrlo malih promjera. Sljedeći koeficijent je gustoća drva koja je prema **Francescato i dr, 2008** za meke listače 0,45 - 0,55 t/m^3, dok je za tvrde listače 0,6 - 0,8 t/m^3 (pri 13 % vlage u drvu).

Promatrajući težinu suhe tvari, primjerice mjerene vrijednosti (Tablica 3-3 i 3-1) za nizinsko (srednja=38,14; max=102,90[30] t suhe tvari po hektaru) i brdsko područje (srednja=47,75 ; max= 134,48[31] t suhe tvari po hektaru), dijeleći ih sa BEF da bi dobili težinu suhe tvari drva iznad 7 cm debljine, uvećavajući te težine za 13 % vlage te ih dijeleći sa gustoćom suhe tvari da bi dobili volumen tvari, dolazimo do vrijednosti od približno 29 m^3/ha za srednju, tj. 77 m^3/ha za maksimalnu vrijednost za nizinsko područje odnosno približno 26 m^3/ha srednje, tj. 72 m^3/ha maksimalne vrijednosti za brdsko područje. Srednje vrijednosti su pravi pokazatelj stanja ovih sastojina, te su u skladu sa iskustvenom granicom[32] od približno 30 m^3/ha koja razdvaja zašikarene sastojine većinom ispod taksacijske granice od već formiranih panjača manjih dimenzija prsnog promjera. Maksimalne vrijednosti predstavljaju vrijednosti koje bi

[30] Ploha 18
[31] Ploha 30
[32]Stečenom pri dugogodišnjem uređivanju degradiranih šuma šumoposjednika na području cijele RH

imala već diferencirana panjača ili mlađa sjemenjača, međutim ovdje se radi o mjestimičnim manjim grupama starih stabala većih dimenzija unutar degradiranih površina koje su obuhvaćene terenskim istraživanjem radi veće varijabilnosti.

Ova dva sastojinska elementa (drvna zaliha, broj stabala) jasno pokazuju degradiranost istraživanih šumskih područja koji su u raznim stadijima degradacije ili sukcesije.

Degradiranih površina je nažalost sve više, za što je nekoliko razloga. Jedan od razloga je taj što se postojeće šumske površine u privatnom vlasništvu/posjedništvu često iskorištavaju nestručno i neprimjereno imajući u vidu samo kratkoročnu financijsku dobit. Kako je srednja površina tih čestica između 0,26 i 0,37 ha ovisno o regiji **(Berta i dr., 2017)**, ovakav način gospodarenja dovodi do mozaičnog rasporeda šumskih površina većeg ili manjeg stupnja degradacije koja je sve izraženija opetovanim neplanskim i neumjerenim iskorištavanjem.

Idući razlog je napuštanje poljoprivredne proizvodnje uslijed:

- razvoja industrijske proizvodnje (tijekom 60-ih i 70-ih godina), gdje se dosta stanovništva zaposlilo u tvornicama te im poljoprivreda i stočarstvo nije bila glavni izvor prihoda,
- Domovinskog rata i raseljavanja stanovništva uzrokovana ratom - čime su mnoga područja bila nedostupna više godina za proizvodnju, a nakon rata su neka područja minirana (trenutno je i dalje minirano 42,5 tisuća ha - **Hrvatski centar za razminiravanje, 2017**) a neka ostala slabo naseljena,
- nastavka depopulacije ruralnih područja kao i sve starijeg stanovništva u ruralnom području.

Navedeni razlozi su doveli do toga da je svaka treća čestica uključena u Programe gospodarenja šumama šumoposjednika katastarskog načina uporabe „Livada“, „Pašnjak“, „Oranica“ i sl. **(Berta i dr., 2016)** što je i razumljivo, jer voćnjaci, pašnjaci i livade koje nisu redovito održavane, vrlo brzo zauzima šuma i šumska vegetacija tvoreći površine u raznim stupnjevima sukcesije tj. progresije. Osobito površine kojima se ne gospodari od početka 90-ih godina prošlog stoljeća tj. od početka Domovinskog rata, na kojima su se sukcesijom već diferencirale šumske sastojine s promjerima iznad taksacijske granice čime su stekle uvjete za uvrštavanje u Programe gospodarenja.

Za površine odnosno sastojine koje su uključene u Programe gospodarenja postoje terenska mjerenja i obračuni drvne zaliha te ostalih sastojinskih parametara, osobito u kontinentalnom dijelu RH gdje je malo uređajnih razreda *Šikara* kao takvih. Razlog ovome je što se takve površinu ne uvrštavaju u Programe ukoliko nisu katastarskog načina uporabe „Šuma“ (**Čl. 3, Zakon o poljoprivrednom zemljištu, NN 39/13 i 48/15**). Međutim, dok te površine ne steknu uvjete da se mogu nazvati nekim uređajnim razredom (osim *Šikarom* ili zaraslim poljoprivrednim zemljištem) ili u slučaju Mediterana i Submediterana, gdje je vrlo čest uređajni razred *Šikara* ili *Makija* osobito u šumama šumoposjednika, tim površinama nisu određeni sastojinski parametri. Naime, prema **Pravilniku o uređivanju šuma (NN 79/15),** za površine uređajnog razreda *Šikara, Makija, Šibljak* ili *Garig* se ne određuje drvna zaliha.

Navedeno predstavlja sve veći problem osobito prilikom izrade NIR, odnosno izvješća o inventaru stakleničkih plinova. NIR je obveza Republike Hrvatske prema Okvirnoj Konvenciji Ujedinjenih naroda o promjeni klime (UNFCCC), proizašle iz Kyoto protokola, da razvija, nadopunjuje, poboljšava i izrađuje nacionalni inventar antropogenih emisija iz izvora i uklanjanje ponorima svih stakleničkih plinova. Upravo zbog konstantne obveze da se takav inventar nadopunjuje i poboljšava sve točnijim i preciznijim podacima i procedurama potrebno je imati mogućnost brzog, efikasnog i jednostavnog prikupljanja podataka.

Djelomični podaci o šumama već postoje kroz Programe gospodarenja, međutim oni su premale vremenske rezolucije, jer se izrađuju ili obnavljaju svakih 10 godine. Također, postojećim podacima se mora još manipulirati da bi se izračunala količina ugljika u njima (pretvorba u ukupni volumen nadzemne biomase, te pretvorba u težinu ovisno o vrsti drveća). Isto tako, još nisu izrađeni svi Programi gospodarenja za šume šumoposjednika.

Prilikom interpretacije rezultata *Hipoteze 1 i 2* treba imati u obzir ograničenja s kojima se ušlo u istraživanje. Jedno od njih je vremensko nepoklapanje LIDAR snimanja (2012) i terenskog uzorkovanja (2016), iako naprimjer **Fusco i dr. (2008)** nisu smatrali to kao ograničenje, te su radili modele za obračun nadzemne biomase na osnovu LIDAR-skih i terenskih podataka, čija su snimanja/uzorkovanja bila s razmakom od 5 godina u talijanskim panjačama kestena, bukve, breze i topole. Kako bi se premostio problem vremenskog nepoklapanja, u sklopu ovog istraživanja izrađene su prirasne krivulje, radi procjene prsnog promjera u godini snimanja.

3.2 Utvrđivanje količine nadzemne biomase LIDAR tehnologijom

Hipoteza 1

Uz pomoć podataka dobivenih avionskim snimanjem LIDAR tehnologijom se može efikasno, brzo i dovoljno točno (primjenom modela nastalih u sklopu ovog istraživanja) odrediti količina nadzemne biomase u degradiranim šumskim sastojinama (u stadiju šikare) brežuljkastog i nizinskog vegetacijskog pojasa kontinentalnog dijela Hrvatske (šire područje Grada Zagreba).

Primjenom postupka objašnjenog u Poglavlju 2.5 *Statistička obrada podataka*, odredile su se najznačajnije varijable po grupama varijabli (Tablica 3-6).

Tablica 3- Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za brdsko i nizinsko područje

Grupa varijabli	Nizinsko područje (N=23)		Brdsko područje (N=45)	
	nezavisna varijabla	R^2	nezavisna varijabla	R^2
1	p95	0,57	p90	0,56
	p10	0,12		
	p15	0,05		
2	qav	0,53	std	0,52
3	b80	0,11	b75	0,15
	b90	0,10	b30	0,06
4	d03	0,47	d03	0,36
	d00	0,11	d01	0,16

Uvrštavanjem predselektiranih varijabli prikazanih u Tablica 3- u još jednu, odnosno konačnu postepenu („stepwise“) regresijsku analizu uz iste uvjete kao u selekcijskim regresijskim analizama po grupa, izrađeni su sljedeći linearni modeli:

Nizinsko područje

Sqrt_biomasa= 13,64496 + 1,056438 **(p95)** + 47,070654 **(p15)**- 48,919278 **(p10)** + 0,621604 **(d03) (**Tablica 3-**), (**N=23, **R^2=0,75**; Tablica 3-)

Brdsko područje

Sqrt_biomasa= -1,10645 +4,77911 **(p90)** + 0,26462 **(d01)** (Tablica 3-**),** (N=45, **R^2=0,60**; Tablica 3-)

Tablica 3- Model nizinskog područja (zavisna varijabla drugi korijen biomase-sqrt_biomasa)

	b	St.pog.	t(18)	p vrijednost
Intercept	13,6450	7,89173	1,72902	0,100918
p95	1,0564	0,81801	1,29147	0,212880
p15	47,0707	14,33896	3,28271	0,004136
p10	-48,9193	16,72648	-2,92466	0,009050
d03	0,6216	0,38294	1,62324	0,121921

Tablica 3- Model brdskog područja (zavisna varijabla drugi korijen biomase-sqrt_biomasa)

	b	St.pog.	t(43)	p vrijednost
Intercept	-1,106446421	7,049979	-0,15694	0,876042
p90	4,779110613	0,598202	7,989128	5,79E-10
d01	0,26462022	0,121741	2,173626	0,035421

Tablica 3- Statističke karakteristike modela za istraživana područja

Područje	N	R	R^2	R^2 prilagođeni	F	p	St. Pogreška procjene
Nizinsko	23	0,86	0,75	0,70	13,66	0,000027	7,552517
Brdsko	45	0,78	0,60	0,59	32,11	0,000000003	10,272708

U nizinskom području, model tvore tri nezavisne varijable percentila (**p95, p15 i p10**) predstavljajući visinu na plohi 95, 15 i 10 % točaka vegetacije, te varijabla **d03** koja

predstavlja postotak točaka vegetacije između 10 do 20 m. Parcijalni R^2 95-og percentila u modelu je 0,57 (Tablica 3-), dok korekcijska kombinacija varijabli **p15** i **p10** poboljšava R^2 za preko 0,14, zbog čega je i zadržana u modelu.

Tablica 3- Sažetak stepwise regresijske analize za nizinsko područja

Varijabla	korak	višetruki R	višestruki R^2	R^2 promjena	F – ul/izl	p vrijednost	varijable
p95	1	0,756232	0,571887	0,571887	28,05246	0,000030	1
p15	2	0,785946	0,617711	0,045824	2,39734	0,137221	2
p10	3	0,846112	0,715905	0,098194	6,56715	0,019041	3
d03	4	0,867284	0,752182	0,036277	2,63492	0,121921	4

Promatrajući brdsko područje i parcijalne R^2, možemo zaključiti da je nezavisna varijabla **p90** koja predstavlja visinu iznad tla 90 % točaka vegetacije daleko najvažnija u modelu (R^2=0,56; Tablica 3-), dok postotak točaka između 2,5 do 5 m pridonosi modelu povećavajući koeficijent determinacije za 0,04. Obje varijable su pozitivno korelirane s korijenom biomase.

Tablica 3- Sažetak stepwise regresijske analize za brdsko područja

Varijabla	korak	višetruki R	višestruki R^2	R^2 promjena	F – ul/izl	p vrijednost	varijable
p90	1	0,748393	0,560091	0,560091	54,74758	0,000000003	1
d01	2	0,777543	0,604574	0,044482	4,724649	0,035420541	2

U nastavku biti će prikazane, posebno za nizinsko i brdsko područje, analize varijanci (Tablica 3- i 3-13) te grafički prikazi rezultata procjene nasuprot ostataka (Slika 3-1 i 3-7); vrijednosti procjene naspram mjerenih vrijednosti (Slika 3-2 i 3-8); normalnu vjerojatnost ostataka (Slika 3-3 i 3-9); te distribucije mjerenih (Slika 3-4 i 3-10), procjenjenih (Slika 3-5 i 3-11) i vrijednosti ostataka (Slika 3-6 i 3-12) prikazanih u kilogramima suhe biomase za zavisnu varijablu drugi korijen biomase.

Tablica 3- Analiza varijance regresijskog modela nizinskog područja

	suma	st. slobode	prosjek	F	p vrijednost
Regres.	3.116,346	4	779,0865	13,65848	0,000027
Ostatak	1.026,729	18	57,0405		
Ukupno	4.143,075				

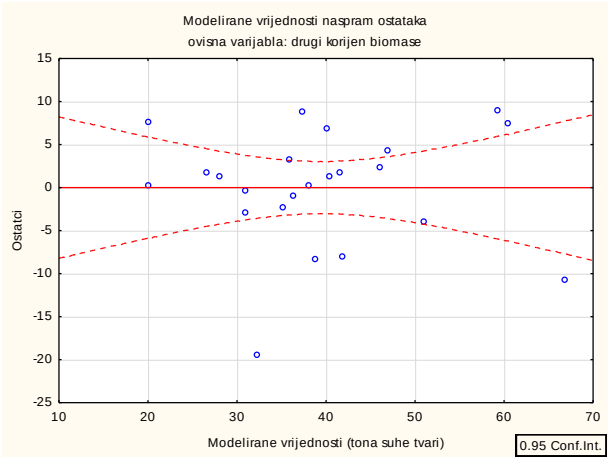

Slika 3- Prikaz rezultata modeliranih vrijednosti naspram ostataka modela nizinskog područja

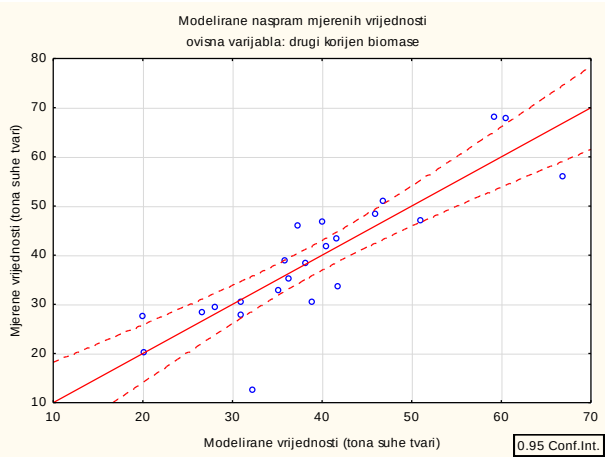

Slika 3- Prikaz modeliranih vrijednosti naspram mjerenih vrijednosti modela nizinskog područja

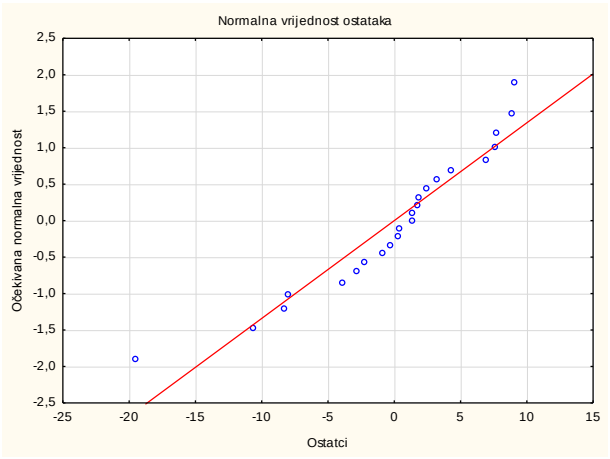

Slika 3- Normalna vjerojatnost ostataka modela nizinskog područja

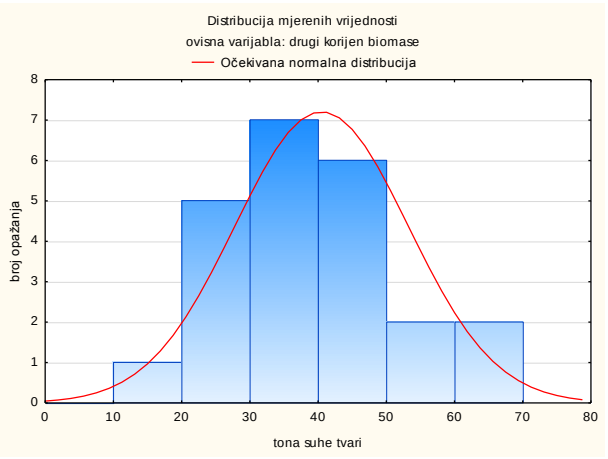

Slika 3- Distribucija mjerenih vrijednosti biomase tj korijena biomase nizinskog područja

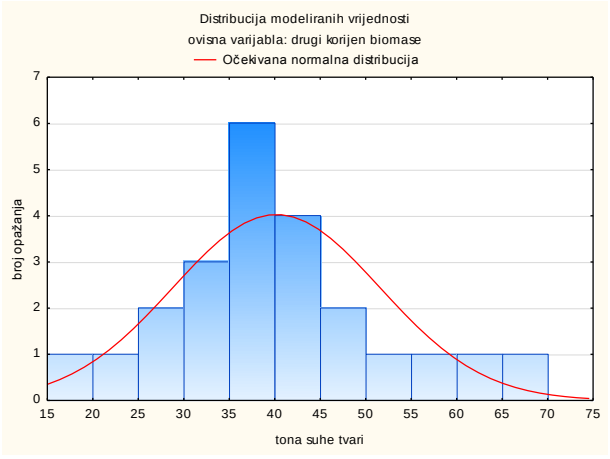

Slika 3- Distribucija modeliranih vrijednosti nizinskog područja

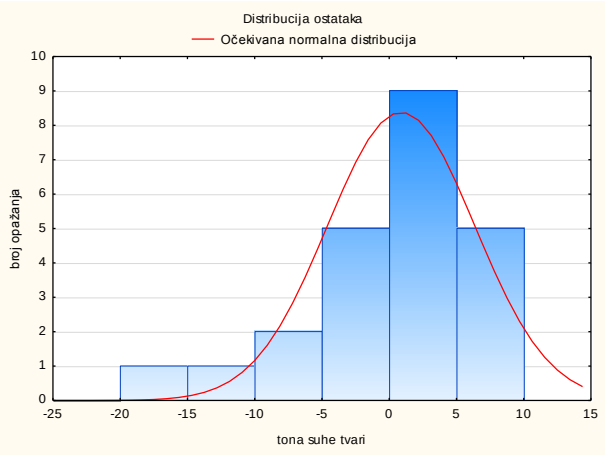

Slika 3- Distribucija vrijednosti ostataka modela nizinskog područja

Tablica 3- Analiza varijance regresijskog modela brdskog područja

	suma	st. slobode	prosjek	F	p vrijednost
Regres.	6.776,457254	2	3.388,229	32,10722	3,45E-09

Ostatak	4.432,198835	42	105,5285		
Ukupno	1.1208,65609				

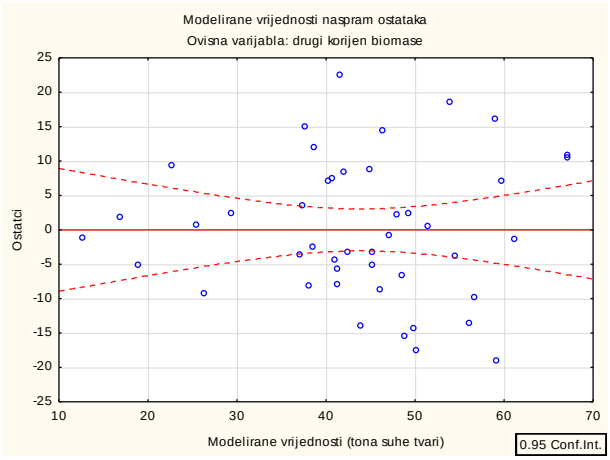

Slika 3- Prikaz rezultata modeliranih vrijednosti nasuprot ostataka modela brdskog područja

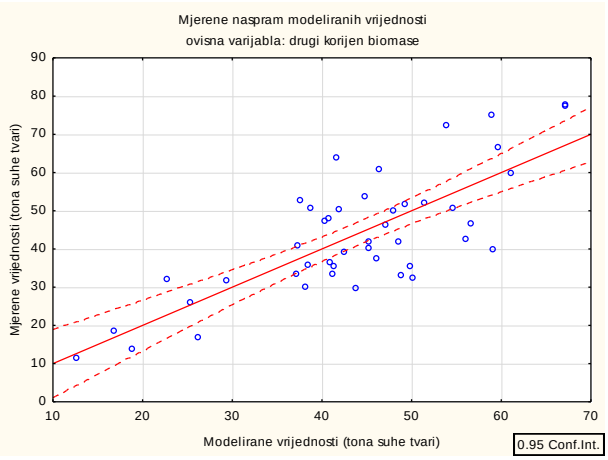

Slika 3- Prikaz modeliranih vrijednosti naspram mjerenih vrijednosti modela brdskog područja

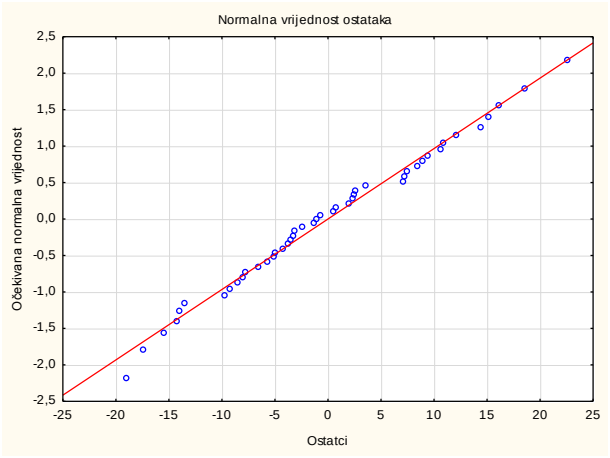

Slika 3- Normalna vjerojatnost ostataka modela brdskog područja

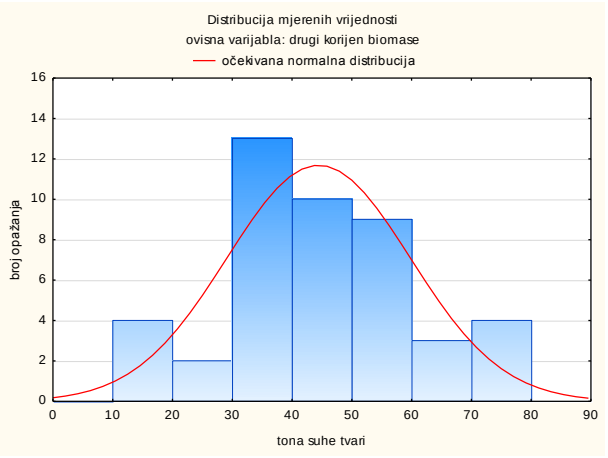

Slika 3- Distribucija mjerenih vrijednosti biomase tj korijena biomase brdskog područja

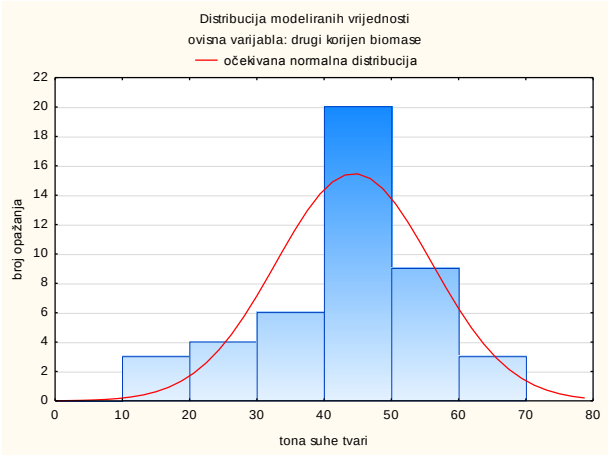

Slika 3- Distribucija modeliranih vrijednosti brdskog područja

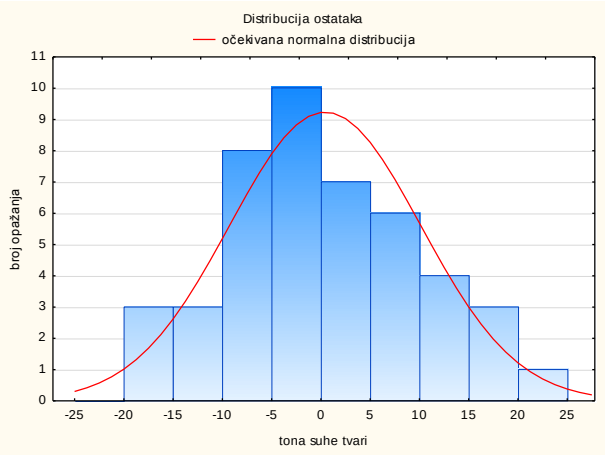

Slika 3- Distribucija vrijednosti ostataka modela brdskog područja

Već i same varijable u modelu kao i njihova pozitivna ili negativna korelacija nam mogu dati predodžbu o izgledu/stanju vegetacije na terenu. I u jednom i u drugom modelu najbitnija varijabla je visina većeg dijela vegetacije. Na osnovu ostalih varijabli dobivamo dodatne informacije o prostoru, kao na primjer u nizinskom području gdje je u modelu i gustoća točaka između 10 i 20 m iznad tla označavajući da je bitna i kodominanatna etaža, dodavajući time u biomasu informaciju o drugom sloju vegetacije, a veće razlike između **p15** i **p10** bi označavale plohe tj. piksele na kojima manji udio grmolike vegetacije, indirektno upućujući na gušći sklop i veću nadzemnu biomasu.

Model za brdsko područje pokazuje da i postotni udio vegetacije između 2,5 i 5 m pozitivno korelira s količinom nadzemne biomase na plohi, te da se biomasa proporcionalno povećava s povećanjem postotka vegetacije u podstojnoj etaži.

Informacija o visini vegetacije se može dobiti i na osnovu stereofotogrametrijske obrade kolor ortofoto ili infracrvenih kolor stereosnimki, međutim točnost očitanih visina uvelike o ovisi kvaliteti i preciznosti digitalnog modela reljefa koji se ne može producirati iz tih snimki već mora biti uključen kao dodatna informacija, što pri izraženijem reljefu može stvarati značajniju pogrešku **(Seletković i dr., 2016)**. Fotogrametrijskom obradom spomenutih snimki se mogu dobiti npr. i digitalni model površina (DMP) i model visina krošnje (DMVK) iz kojih se mogu izvući slične varijable **(Balenović i dr., 2017),** koje se uspješno mogu koristiti za određivanje volumena sastojina u nizinskim područjima, koristeći digitalni model reljefa niže rezolucije. Međutim, digitalni model površina i visina krošnji predstavlja vanjski plašt stabla vidljiv uređaju, čime se ne može uzeti u obzir gustoća krošnje ili postojanje podstojne etaže. Glavna prednost LIDAR tehnologije se nalazi u upravo u tome da istovremeno pruža informacije o vertikalnoj strukturi sastojine i omogućuje izradu vrlo preciznog digitalnog modela reljefa kao osnove za daljnje analize.

U ovom istraživanju, mogućnost LIDAR tehnologije da prodire unutar vegetacije u nizinskom području je više izražena gdje te varijable „unutar vegetacije“ značajno poboljšavaju model, dok u brdskom području (vjerojatno zbog nižih maksimalnih visina i raznovrsnije situacije), te varijable ne poboljšavaju značajno sami model.

Promatrajući R^2 (Tablica 3-)**,** možemo ustvrditi da je on sasvim zadovoljavajući (osobito za nizinsko područje), s obzirom na sve ono što karakterizira ovakve sastojine koje su u

određenim stupnjevima degradacije tj. sukcesije (progresije). Neke od tih karakteristika (koje su vidljive i iz prikupljenih terenskih podataka) su :

- nejednolika visinska i debljinska struktura na vrlo malom prostoru (na plohama su izmjereni promjeri od 1 cm do 86 cm prsnog promjera te od 2 do 26,8 m visine>Tablica 2-2),
- velik broj različitih vrsta u različitim omjerima s nepravilnim prostornim rasporedom (na plohama je zabilježeno preko 40 različitih drvenastih i grmolikih vrsta koje tvore čak 14 različitih kombinacija promatrajući prevladavajuće vrste na određenim plohama> Tablica 3-1 i 3-2)
- mjestimično nepotpuna obraslost (na plohama od 50 do 100 %).

Dobiveni rezultati (korištene varijable i R^2 iznosi) u ovom istraživanju u potpunosti su u skladu s **Hawbaker i dr. (2010)** koji su uz pomoć decila (postotak točaka u određenom visinskom rasponu), u ovom slučaju u rasponu od 1,8 do 2,7 m, te prvog i 70-og percentila visine, dobili R^2=0,65 za model iskoristive drvne zalihe. Istraživanje je provedeno na mješovitim raznodobnim šumama tvrdih listača (4580 ha), koje se nalaze u sjevernom dijelu SAD. Ove šume su nastale zaraštanjem, te raznolikim gospodarenjem u prošlosti, a sastoje se pretežno od raznih vrsta hrastova, jasena i karije s udjelom šećernog javora, crvenog javora i američke lipe.

U istraživanju **Garcia i dr. (2010),** varijable koje čine model su ovisno o glavnoj vrsti drveća: srednja visina (crni bor), 25-i percentil (za španjolsku borovicu), te 99-i percentil za hrast crniku. Navedeno istraživanje je koristilo i intenzitete povrata koje je samo mjestimično poboljšalo modele. U ovom istraživanju ove varijable nije bilo moguće upotrijebiti s obzirom da je raspon intenziteta na plohama (na kojima bi se izradio model) bio višestruko manji od raspona intenziteta koji se nalazi na cijeloj površini, čime je model prisiljen ekstrapolirati vrijednosti što uvijek predstavlja opasnost za točnost i vjerodostojnost rezultata. U ovom istraživanju, jednadžbe (bez uključenih varijabli intenziteta) za obračun biomase su imale R^2 za crni bor 0,73, borovicu 0,87, dok je za crniku čak 0,93.

Kwak i dr., 2014 su koristili varijable intenziteta gdje su za borove šume dobili vrlo visok R^2 (0,91) koristeći 30-i percentil visine svih točaka, 50-i percentil visine vegetacijskih točaka, standardnu devijaciju i spljoštenost distribucije intenziteta svih točaka i nagib distribucije intenziteta točaka vegetacije.

Hal i dr., 2005 su u borovim sastojinama samo na osnovu varijable postotka točaka tla koji su ujedno i prvi (jedini) povrat, dobili R^2 od 0,74 za model procjene nadzemne biomase.

Mitchell i dr., 2012 su proveli istraživanje na pretežno crnogoričnim šumama uz gustoću oblaka od 3 točke/m^2, te izradili model s R^2=0,74 i varijablom „up_half_ratio“ (korištene i u ovom istraživanju, ali bez utjecaja na model) i srednje visine na plohi.

Vidljivo je da razna istraživanja imaju različite varijable, stoga je iznimno bitno razvijati specifične jednadžbe i modele na razini određenog područja odnosno staništa.

3.2.1 Primjena modela na cijelo područje

Ovime je dokazan jedan dio Hipoteze 1 - da se šumska nadzemna biomasa može odrediti dovoljno točno, dok jedan dio efikasnosti ove metode prvenstveno leži u tome što se LIDAR-om prikupi ogromna količina podataka za velika područja u kratkom vremenu. Za procjenu efikasnosti obračuna i brzine, tj. utroška vremena za primjenu ove tehnologije, potrebno je primijeniti razvijene modele za procijenu nadzemne biomase na cijeloj istraživanoj površini.

Ovo se može vrlo jednostavno postići alatom **lascanopy,** izdvajajući željene varijable u obliku rastera željene veličine piksela, s kojima se dalje vrlo lako u GIS okruženju (u ovom slučaju, program QGIS) može izračunati nadzemna šumska biomasa za svaki pojedini piksel i dalje sumirati, analizirati ili računati prosječne vrijednosti. S obzirom na veličinu plohe korištene u ovom istraživanju (452 m^2), za rastere je izabrana veličina piksela 21 x 21 m (441 m^2).

Sumarni rezultati (u kilogramima, odnosno tonama suhe tvari) prema istraživanim područjima se nalaze u Tablici 3-14.

Tablica 3- Sumarni prikaz rezultata na osnovu izrađenih modela

	Nizinsko područje	Brdsko područje
broj piksela	5.107	9.674
minimum biomase (kg/piksel)	49,38	12,90
maksimum biomase (kg/piksel)	17.523,69	13.032,87
prosječno po pikselu (kg/piksel)	1.812,22	1.981,96
standardna devijacija	2.323,53	1.560,59
ukupna biomasa (kg)	9.258.081,22	19.173.571,07
ukupna površina piksela (ha)	225,22	426,62
prosječna biomasa (kg/ha)	41.107,07	44.942,97
prosječna biomasa (t/ha)	41,11	44,94

Grafički prikaz za izabrane dijelove brdskog i nizinskog područja s prikazanim rasterima varijabli uključenih u model te konačni rezultati su prikazani na slikama od 3-13 do 3-18 za nizinsko područje, te na slikama od 3-19 do 3-22 za brdsko područje.

Grafički prikazi cijelih područja s prikazanom obračunatom biomasom za svaki piksel istraživanog područja se nalaze na Slici 2-23 za nizinsko područje, te na Slikama 3-24 i 3-25 za brdsko područje.

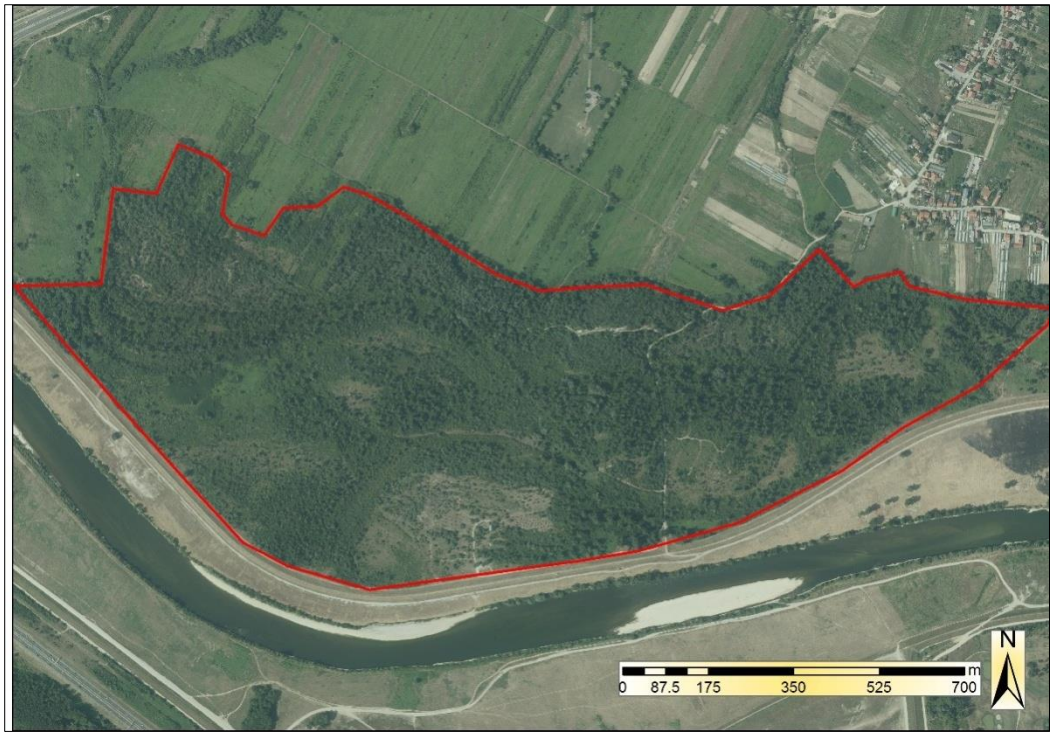

Slika 3- Ortofoto prikaz dijela istraživanog nizinskog područja

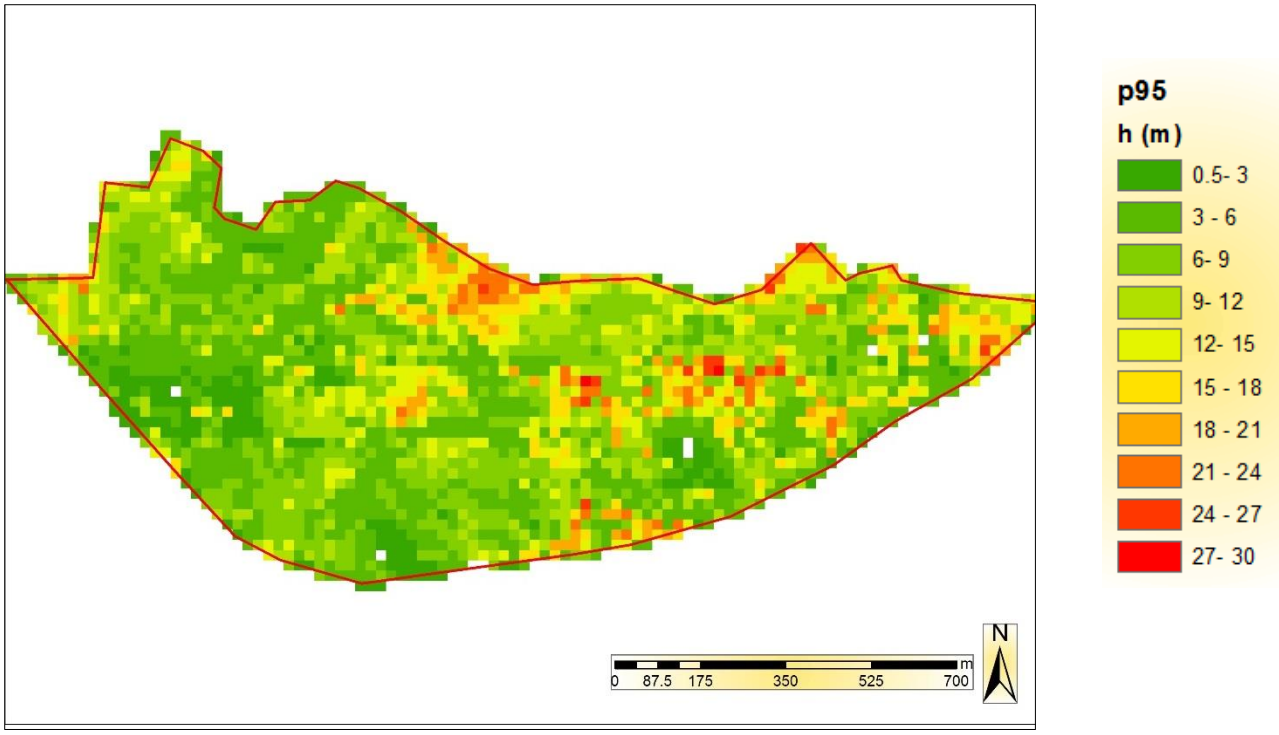

Slika 3- Prikaz 95-og percentila visine

Slika 3- Prikaz 15-og percentila visine

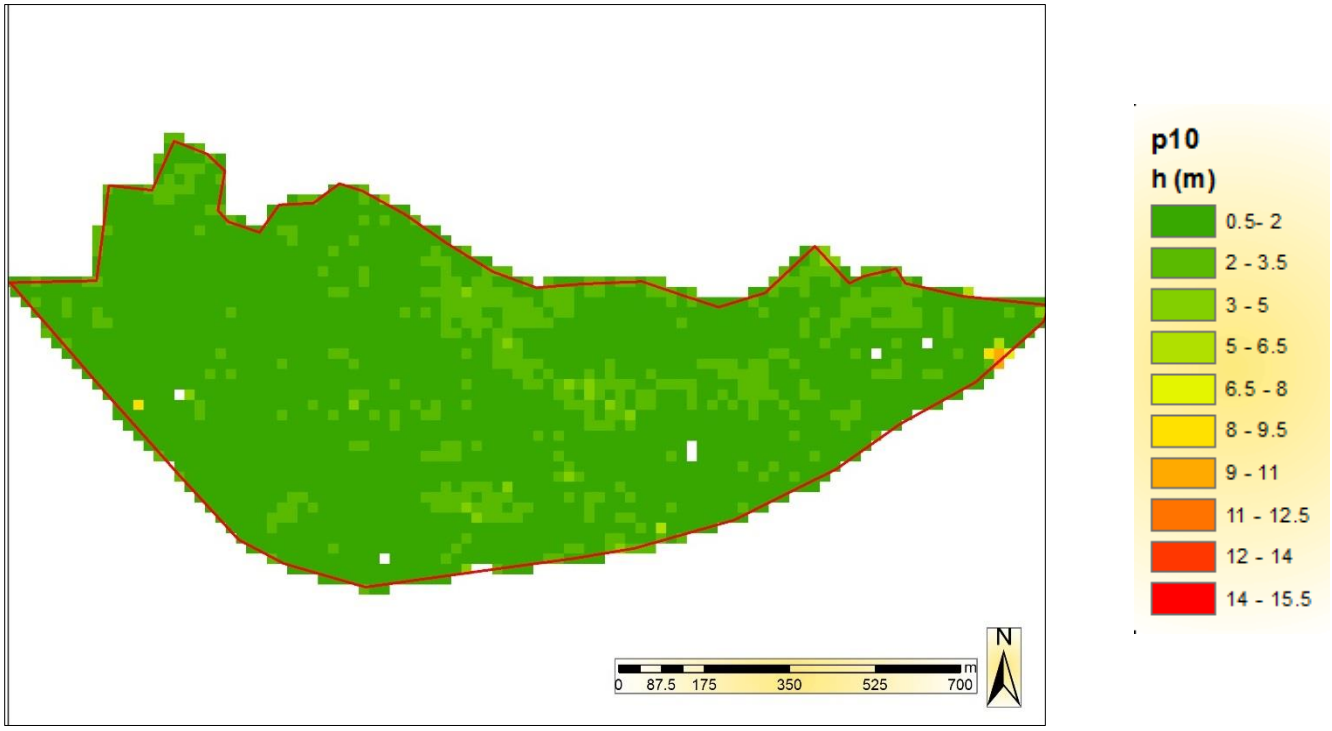

Slika 3- Prikaz 10-og percentila visine

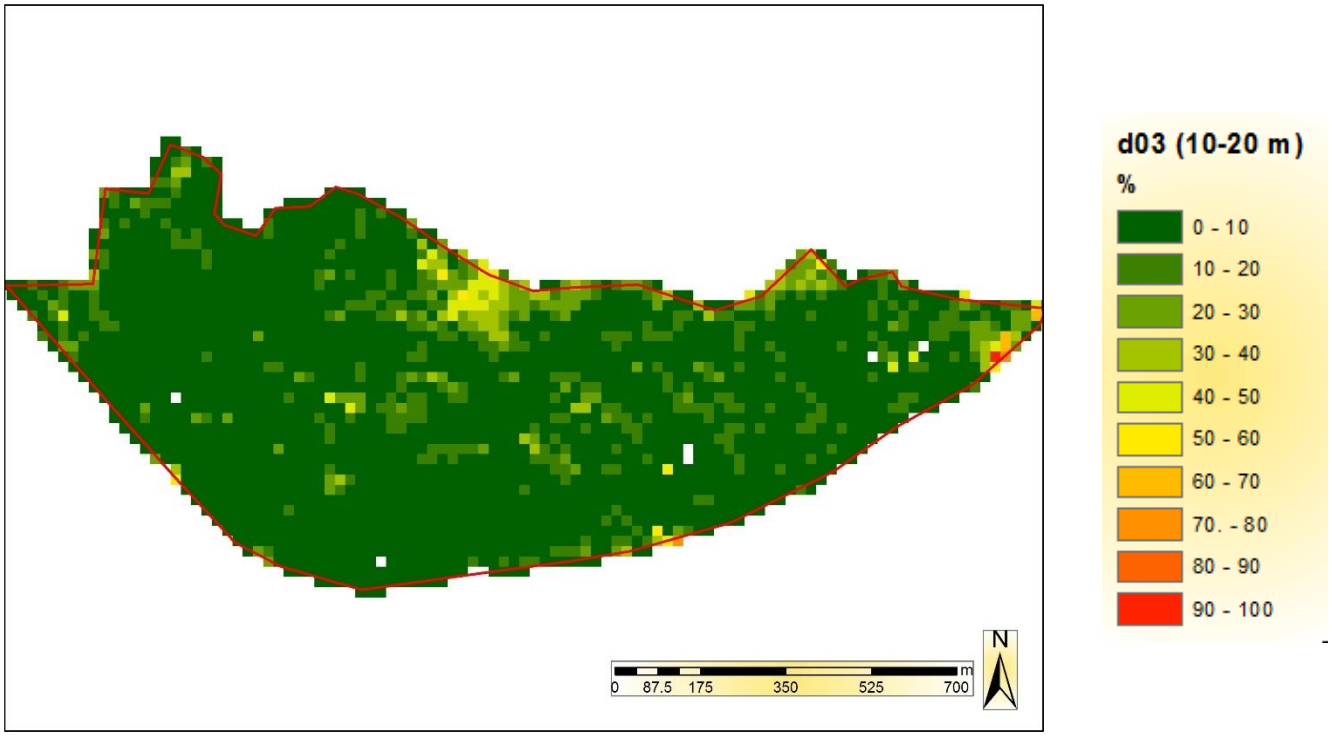

Slika 3- Prikaz postotka točaka vegetacije između 10 i 20 m

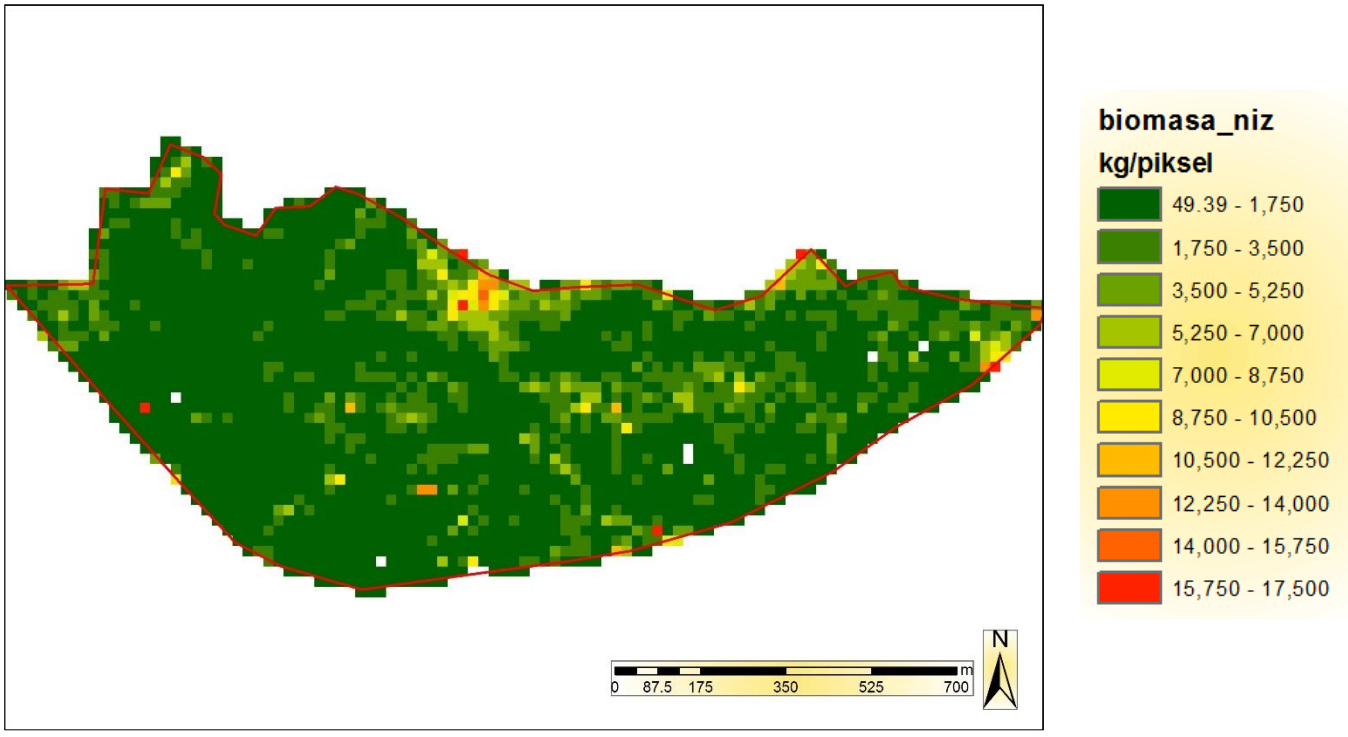

Slika 3- Obračunata biomasa prema modelu za nizinsko područje

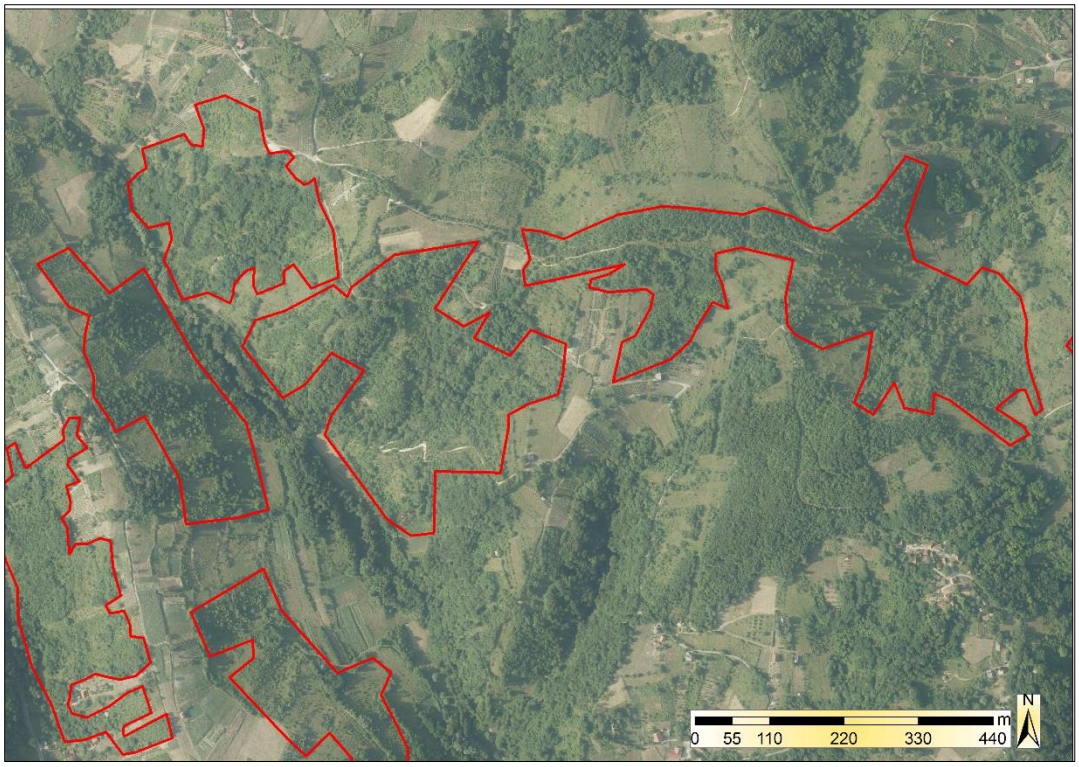

Slika 3- Ortofoto prikaz dijela istraživanog brdskog područja

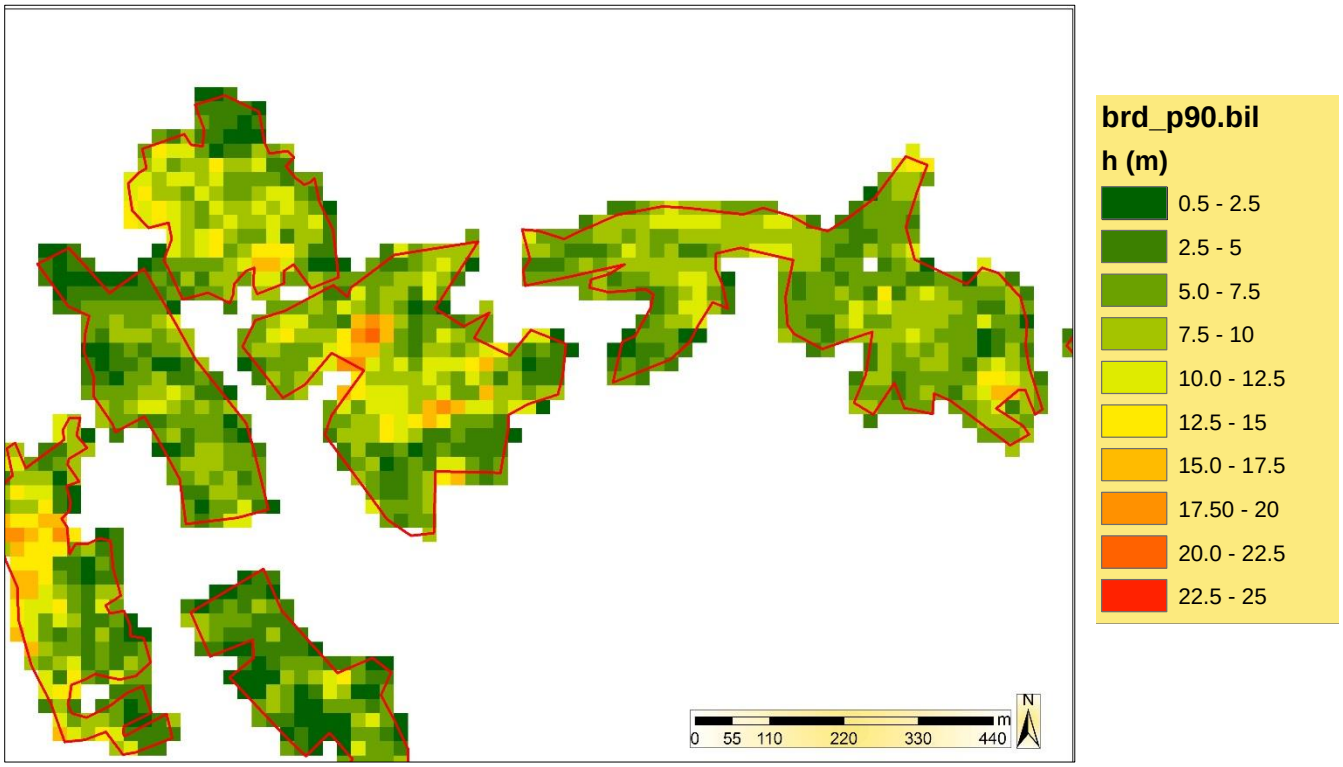

Slika 3- Prikaz 90-og percentila visine

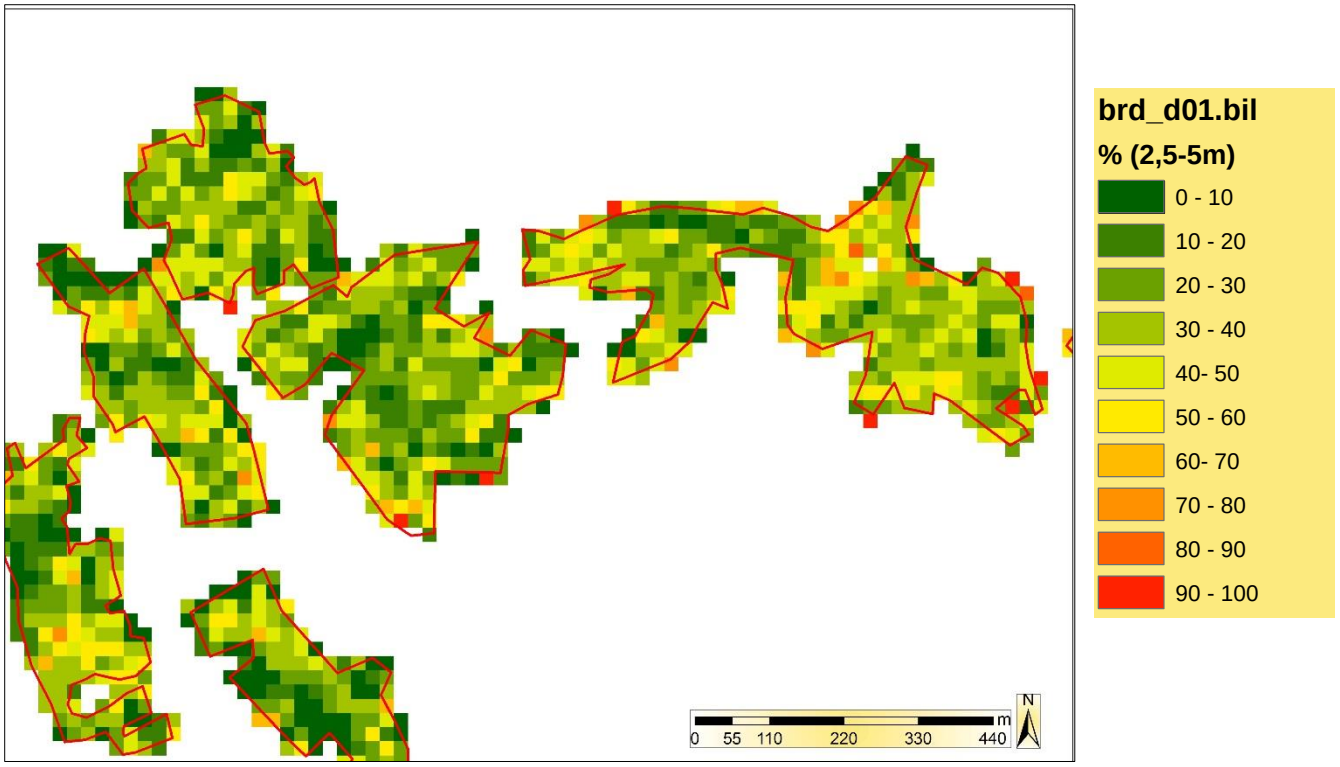

Slika 3- Prikaz postotka točaka vegetacije između 2,5 i 5 m

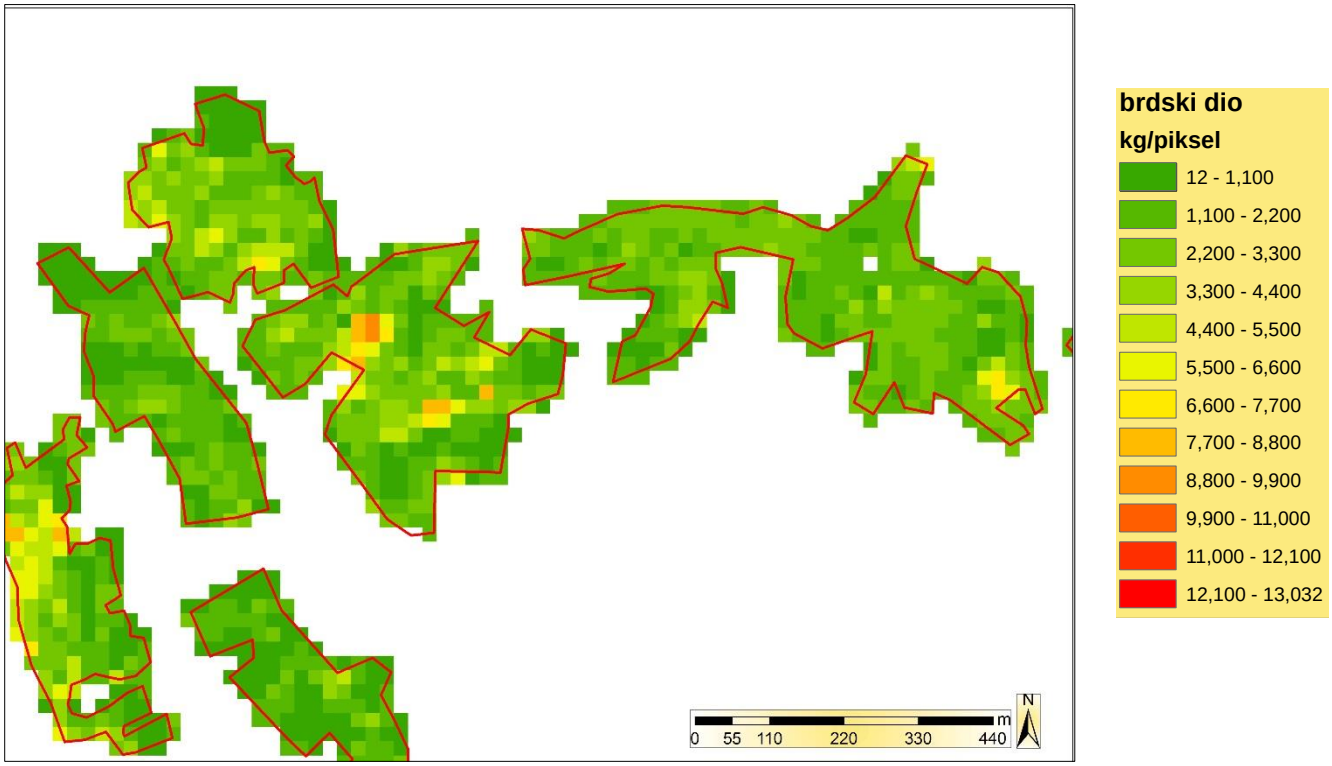

Slika 3- Obračunata biomasa prema modelu za brdsko područje

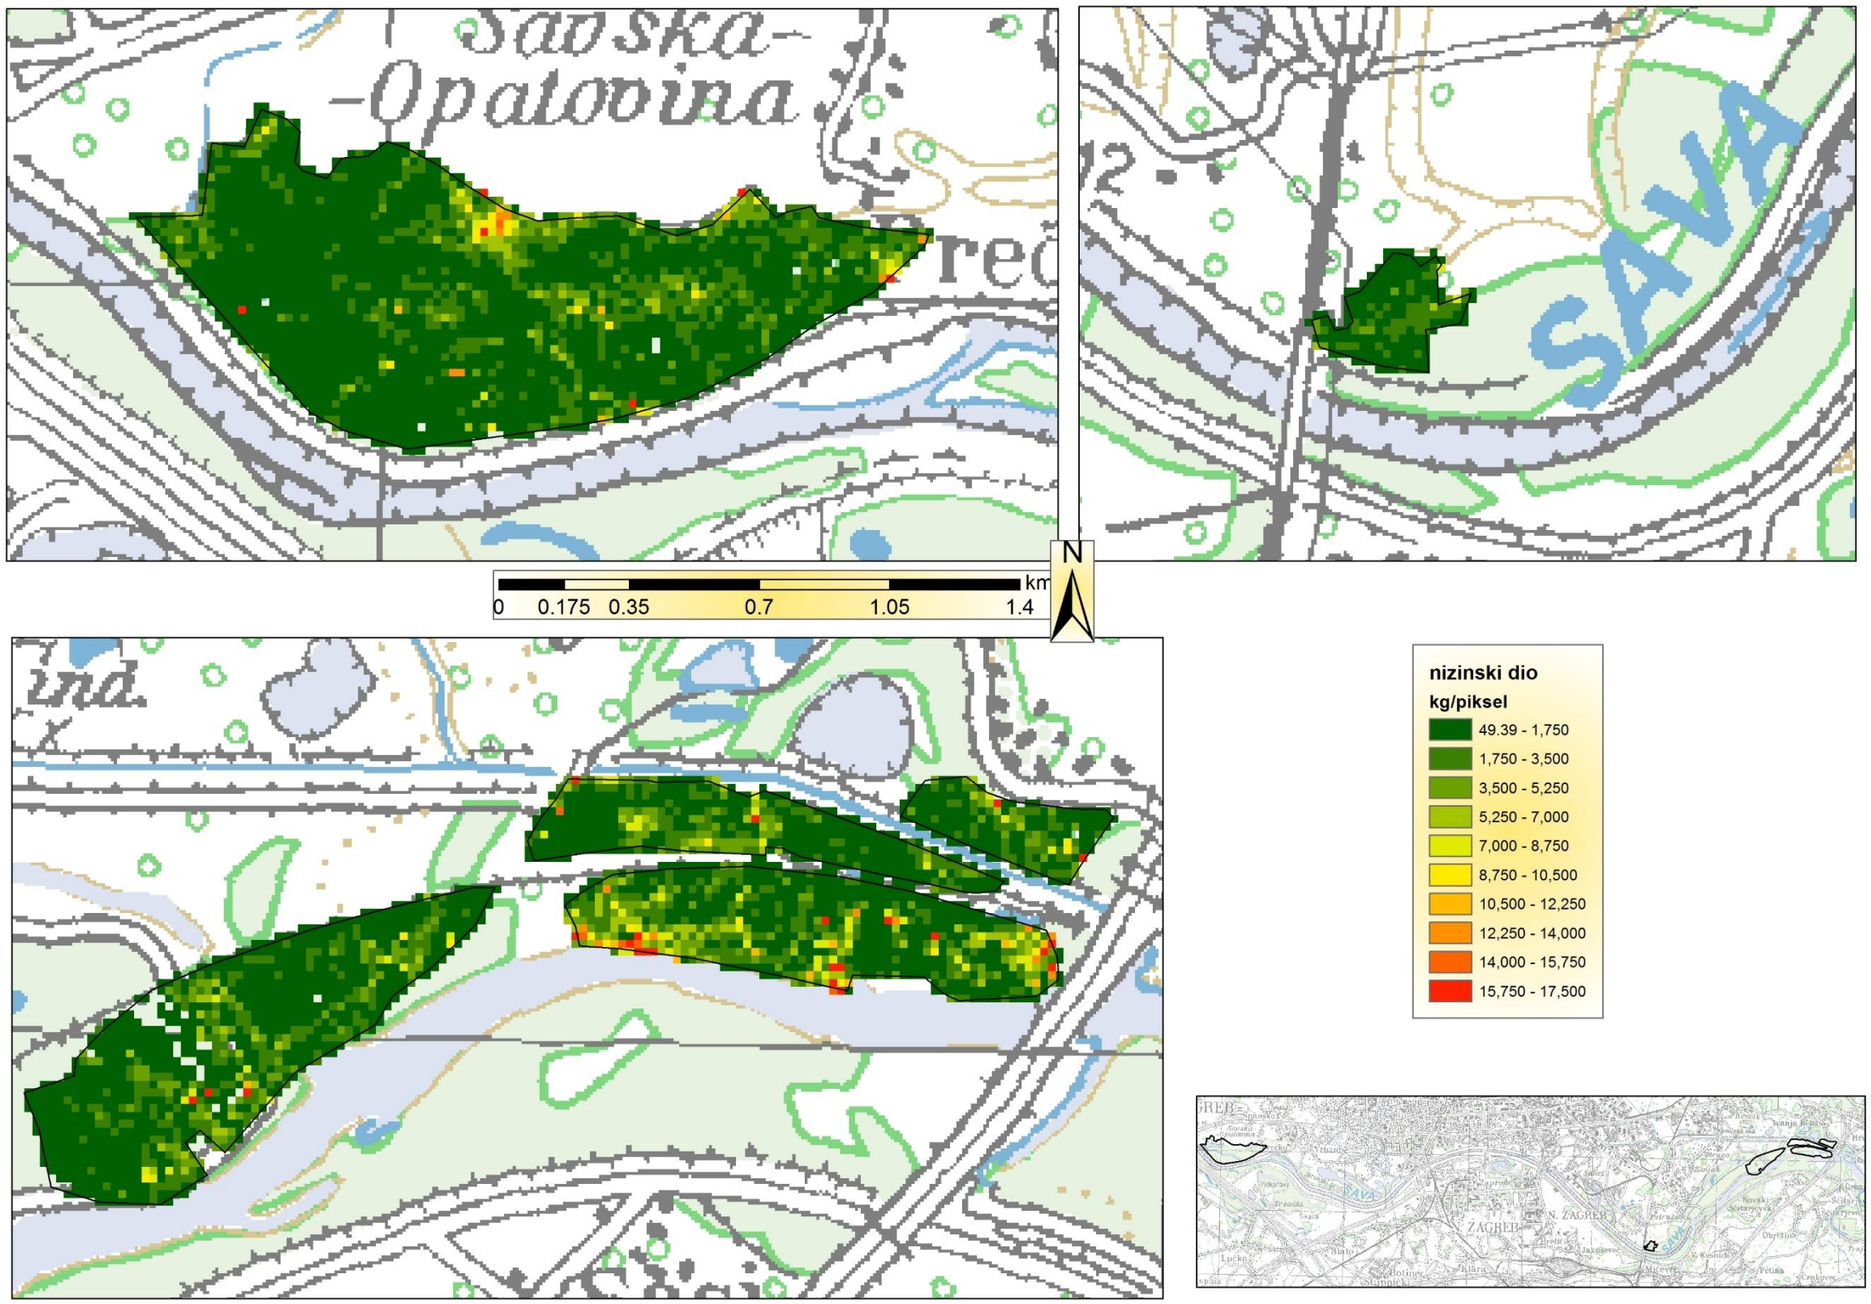

Slika 3- Prikaz obračunate biomase-nizinsko područje - mjerilo 1 : 12.500 (pregledna 1 : 150.000)

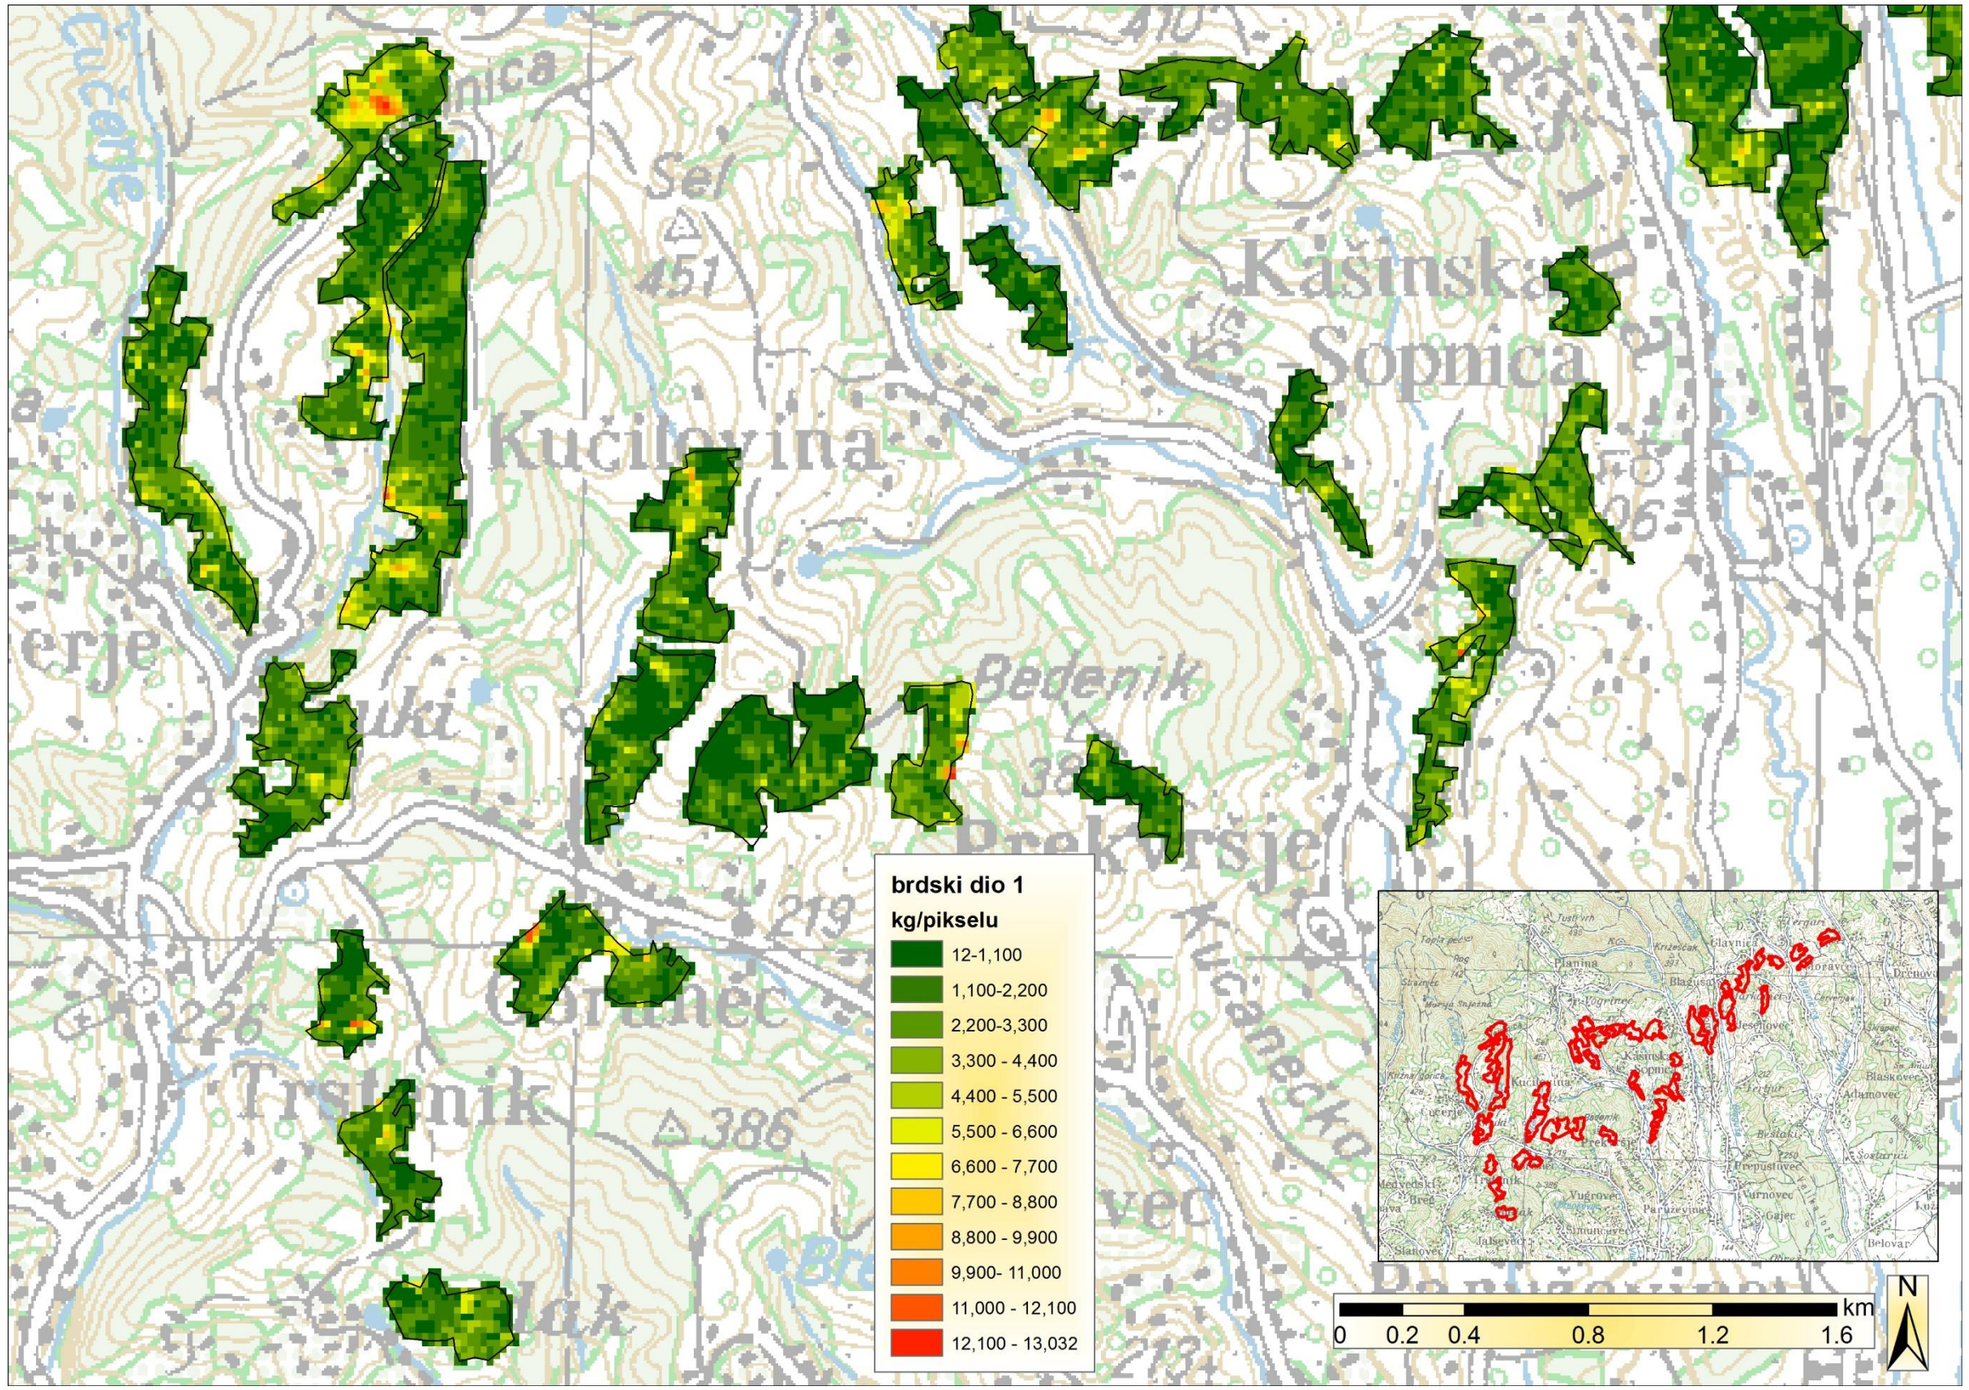

Slika 3- Prikaz obračunate biomase-zapadni dio brdskog područja- mjerilo 1 : 15.000 (pregledna 1 : 100.000)

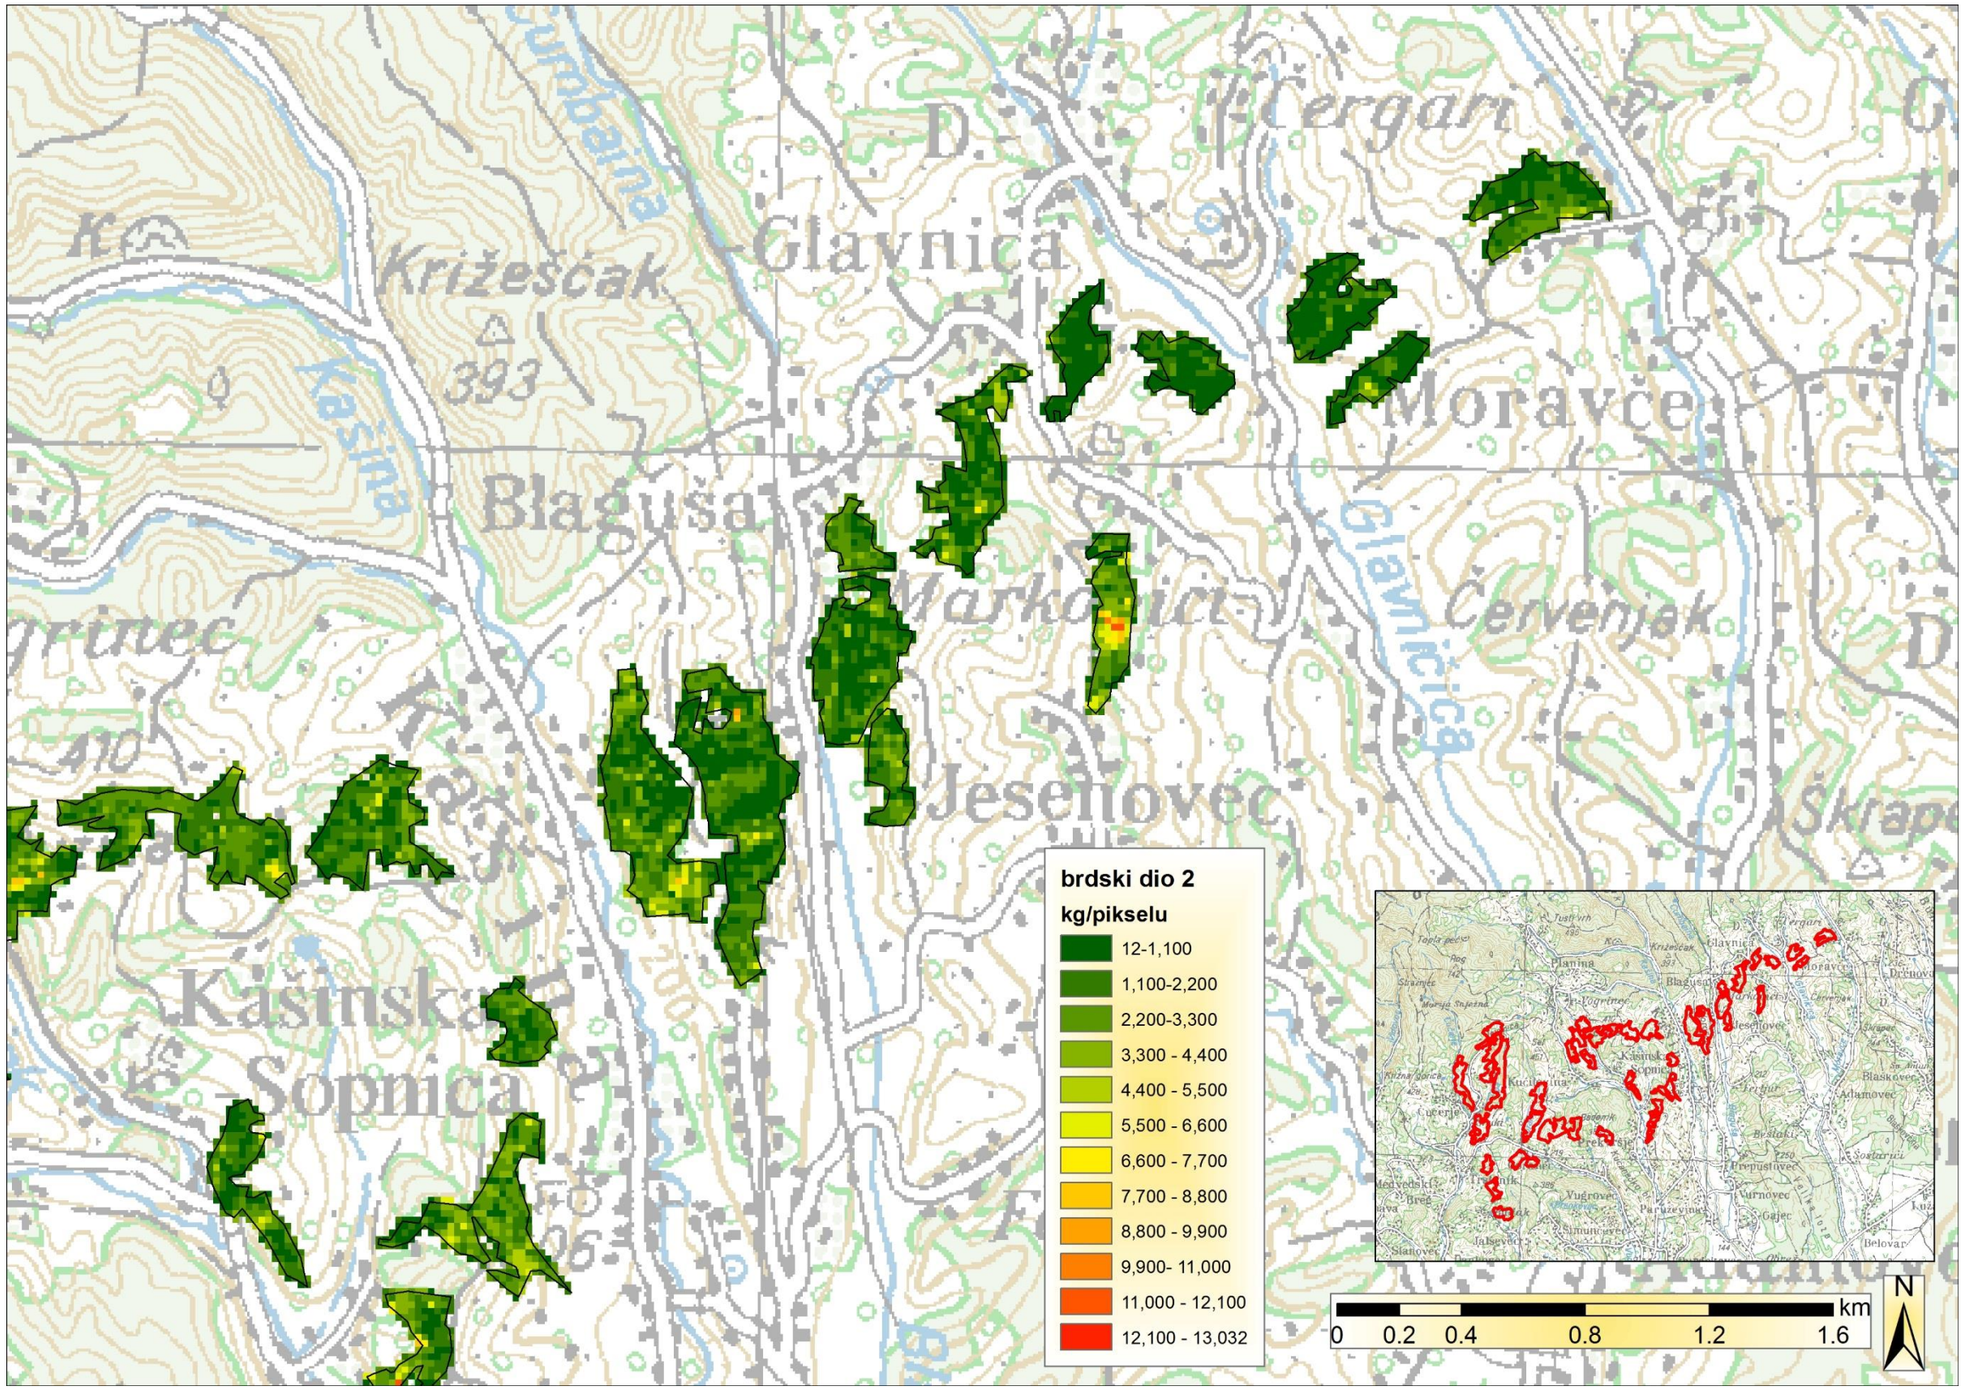

Slika 3- Prikaz obračunate biomase-istočni dio brdskog područja- mjerilo 1 : 15.000 (pregledna 1 : 100.000)

3.2.2 Usporedba mjerenih i modeliranih podataka

Iz Tablica 3-5 i 3-14 je razvidno da su mjereni i modelirani podaci nadzemne biomase vrlo sličnih vrijednosti (prosječna vrijednost-38,14 naprema 41,11 t /ha za nizinsko područje tj. 47,75 naprema 44,94 t/ha za brdsko područje). Ova razlika u nizinskom području je približno 5 % veća dok je u brdskom za 10-ak % niža u odnosu na mjerene vrijednosti.

Mjerene vrijednosti nadzemne biomase su dobivene na osnovu mjerenja približno 1 ha površine (23 plohe x 452 m^2) za nizinsko područje odnosno 2 ha površine (45 ploha x 452 m^2) za brdsko područje. Imajući u vidu da modeli računaju nadzemnu biomasu za svaki pojedini piksel veličine 441 m^2 na području istraživanja uvažavajući cjelokupnu raznovrsnost, sa velikom vjerojatnošću možemo ustvrditi da su modelirane srednje vrijednosti na razini istraživanih područja točnije.

Naravno, preduvjet za pouzdane modele je ispravno postavljeno terensko istraživanje. Upravo zato su se (kako je navedeno u poglavlju 2.1.3.) lokacije ploha terenske izmjere postavljale uz pomoć fotointerpretacije i drugih dostupnih podloga. Naime, zbog mjerenja relativno malog broja ploha (u odnosu na klasično uređivanje šuma) i zbog karakteristika ovakvih površina, sistematski uzorak bi zasigurno dao drukčije rezultate.

Da bi se dobio uvid u ispravnost ovakvog načina uzorkovanja, prikazana je količina piksela čiji rezultati modelirane nadzemne biomase izlaze iz raspona biomase koja je korištena za modeliranje. Prvo su izmjerene minimalne i maksimalne vrijednosti biomase po plohama i po područjima svedene na istu površinu za koju su računate modelirane vrijednosti (sa 452 m^2 na 441 m^2; Tablica 3-15). Nakon čega su se pikseli u konačnim rasterima za brdsko i nizinsko područje grupirali u mjerene raspone.

Uspoređujući minimalne i maksimalne mjerene i modelirane vrijednosti (Tablica 3-) primjećena su velika odstupanja, prvenstveno u maksimalnim vrijednostima.

Tablica 3- Minimalne i maksimalne mjerene i modelirane vrijednosti

Područje	Minimalna mjerenja na plohi (452 m^2)	Maksimalna mjerena biomasa na plohi (452 m^2)	Minimalna mjerena biomasa preračunata na površinu piksela (441 m^2)	Maksimalna mjerena biomasa preračunata na površinu piksela (441 m^2)	Minimalna procijenjena biomasa na pikselu	Maksimalna procijenjena biomasa na pikselu
Nizinsko	162,45	4.655,00	158,50	4.541,72	49,39	17.523,69
Brdsko	132,55	6.083,87	129,32	5.935,81	12,90	13.032,87

Međutim, kako je vidljivo iz Tablice 3-16, takvih je piksela vrlo malo, ispod 4 %, u odnosu na sve piksele određenog područja, te ne utječu na rezultat. Slična situacija je i sa minimalnim vrijednostima. Na osnovu ovoga možemo zaključiti da je terensko uzorkovanje zadovoljavajuće postavljeno pri čemu pokriva gotovo 92 % varijabilnosti nadzemne biomase na terenu.

Tablica 3- Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama

Područje	Pikseli s biomasom nižom od minimalne mjerene	Pikseli s biomasom unutar mjerenih raspona mjerene	Pikseli s biomasom višom od maksimalne mjerene	Ukupno
Nizinsko	37	4659	411	5107
Brdsko	484	8931	259	9674
Ukupno	521	13590	670	14781
Ukupno %	3,52	91,92	4,53	100,00

Za vizualnu usporedbu rasporeda piksela koji izlaze iz mjerenih raspona biomase na slici 3-26 je prikazan isti dio nizinskog područja istraživanja prikazan na slikama 3-13 do 3-18, dok je na slici 3-27 prikazan isti dio brdskog područja istraživanja kao na slikama 3-19 do 3-22. Vidljivo je, također, da su pikseli koji se nalaze izvan raspona mjerene biomase često nalaze u rubnim dijelovima područja. Uzrok ovome je izdvajanje oblaka točaka točno po granicama istraživanog područja, stoga rubni pikseli imaju „neprirodne“, odnosno djelomične oblake koji onda stvaraju problem pri primjeni modela.

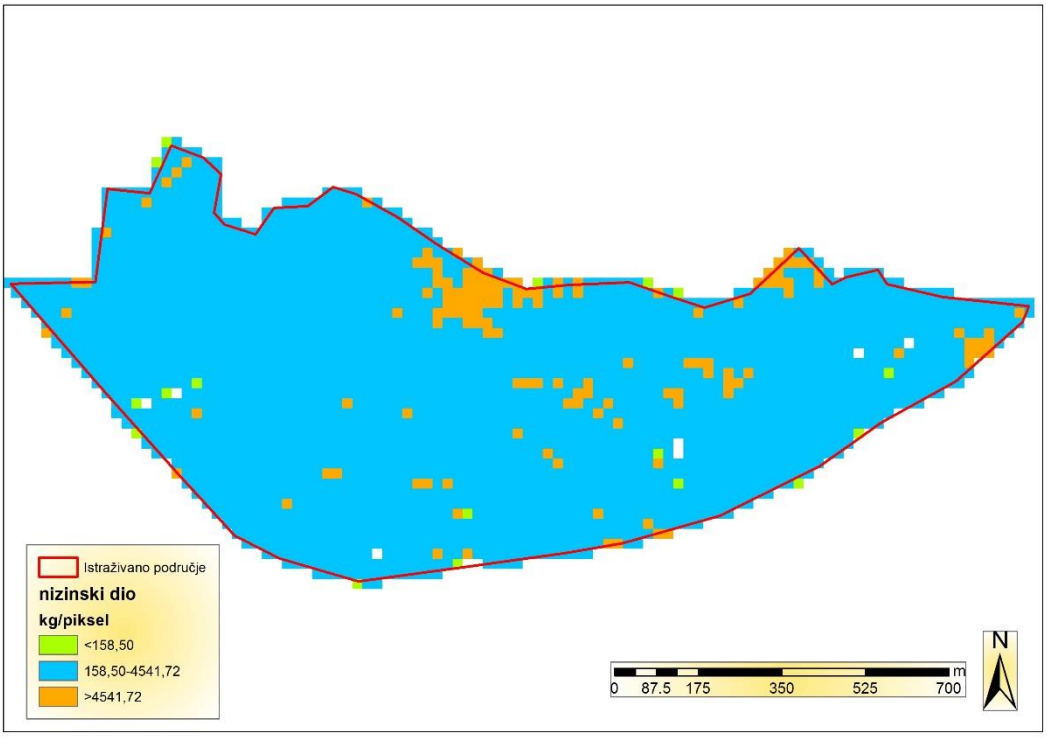

Slika 3- Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama za nizinski dio istraživanog područja

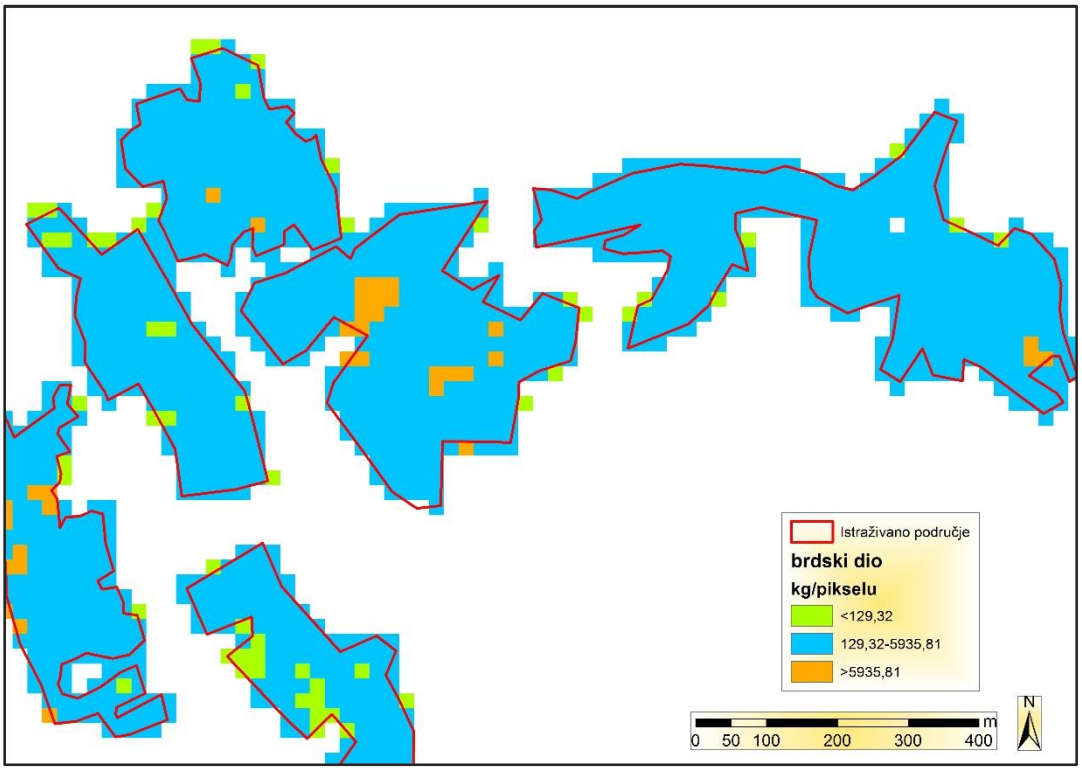

Slika 3- Usporedba raspona modelirane biomase po pikselima s mjerenim rasponom biomase po plohama za brdski dio istraživanog područja

Ovime je Hipoteza 1; „*Uz pomoć podataka dobivenih avionskim snimanjem LIDAR tehnologijom se može efikasno, brzo i dovoljno točno (primjenom modela nastalih u sklopu ovog istraživanja) odrediti količina nadzemne biomase u degradiranim šumskim sastojinama (u stadiju šikare) brežuljkastog i nizinskog vegetacijskog pojasa kontinentalnog dijela Hrvatske (šire područje Grada Zagreba)"* uspješno potvrđena.

To jest, uistinu **se može** uz pomoć LIDAR tehnologije **efikasno** (*ogroman broj podataka za veliko područje snimljenih u kratkom roku*), **brzo** (*brza obrada podataka, primjena modela na rastere željenih varijabli u GIS okruženju na razini svakog pojedinačnog piksela u par poteza*) i **dovoljno točno** (R^2*=0,75 za nizinsko tj. 0,60 za brdsko područje*) odrediti težina nadzemne biomase za istraživano područje.

3.2.3 Unaprijeđenje modela i mogućnosti primjene

Poboljšavanje modela izrađenih u sklopu ovog istraživanja moguće je na više načina.

Prvi i osnovni je ponovno snimanje LIDAR-om da bi se postigli oblaci veće gustoće točaka, međutim to iziskuje dodatna veća ulaganja. Nakon toga je dodatno mjerenje područja koja imaju veću modeliranu nadzemnu biomasu od mjerene da bi se i te korelacije uvrstile u model. Tijekom ovog istraživanja je također primijećeno da je potrebno obrađivati LIDAR podatke za malo šire područje od istraživanog („buffer“ zona), jer „prerezani“ oblaci (u rubnim pikselima) su nestabilni u modelima.

Dalje, potrebno je konstruirati lokalne jednadžbe i parametre za određivanje ukupne biomase stabala za vrste koje nalazimo u RH, jer za ovo istraživanje je samo jedna lokalna jednadžba bila uporabljiva **(Stankić i dr., 2014).** Ostale korištene jednadžbe su iz stranih istraživanja (Tablica 2-6), a za neke vrste je bilo potrebno koristiti jednadžu na razini roda. Ove jednadžbe, direktno korelirajući prsni promjer, visinu stabla i ukupnu biomasu, ukidaju potrebu za raznim pretvorbama volumena drva iznad 7 cm (koji se pretežno koristi u RH) u nadzemnu biomasu stabla, sprječavajući akumuliranje pogrešaka modela za ekspanziju drvne mase u biomasu, modela za obračun suhe tvari, te modela za pretvorbu volumena u težinu.

I na kraju, uvođenje dodatnih izvora podataka u obliku ortofoto snimki i dodjeljivanjem svakoj točki njene RGB vrijednosti ili uz korištenje multispektralnih snimki, nastalih avio ili satelitskim snimanjem.

Upravo su **satelitske multispektralne snimke** u zadnje vrijeme u ponovnom fokusu znanstvene zajednice, otkako je sredinom 2015. godine lansiran satelit Sentinel 2a. Ovaj satelit je dio porodice satelita Sentinel u sklopu Copernicus programa koji vodi ESA (Europska Svemirska agencija). Ovo je prvi od dva satelita (drugi je lansiran nedavno, početkom trećeg mjeseca 2017. godine), koji će činiti tandem omogućavajući multispektralni pogled na Zemlju snimajući svaku pojedinu točku na Zemlji u razmaku od 5 dana. Ovaj satelit prikuplja multispektralne podatke visoke i srednje prostorne rezolucije. Raspone elektromagnetskog zračenja u vidljivom dijelu spektra (crvena, plava i zelena boja) i infracrvenom dijelu spektra prostorne rezolucije od 10 m (a drugih 9 predviđenih raspona eletromagnetskog zračenja u prostornim rezolucijama od 20 odnosno 60 m). Još jedna od važnih značajki ovih snimki je da su besplatne za korištenje i dostupne za preuzimanje svima

zainteresiranima preko web-stranice ESA-e. Satelitske snimke se koriste za određivanje raznih vegetacijskih indeksa koji prikazuju biljni prirast, zdravlje, te stupanj stresa kod biljaka (NDVI, EVI, LAI, SAVI, itd.). Osim ovih mogućnosti korištenja pri određivanju prirasta i ostalih primjena vezanih za vegetaciju, Sentinel 2 se može koristiti za kartiranje promjena u korištenju zemljišta, pokrovu zemljišta, te šumama, čime pruža nezamjenjiv alat pri izvješćivanju u sklopu LULUCF sektora **(Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services, 2012).**

Korištenje satelitskih multispektralnih snimki sličnih rezolucija u obliku samih spektralnih kanala ili njihovim kombinacijama u obliku vegetacijskih indeksa i njihovo koreliranje sa biomasom pokazuje dobre rezultate uz visoke koeficijente determinacije čak i preko 0,90 **(Heiskanen, 2006; Güneralp i dr., 2014),** dok su neka istraživanja postigla niže koeficijente determinacije, npr. 0,68 - **Poulain i dr. (2012)**.

Postoje mnoga istraživanja koja kombiniraju podatke dobivene LIDAR i satelitskim snimanjem. Neka istraživanja **(Shendryk i dr., 2014)** koriste satelitske snimke za prvotno određivanje uređajnog razreda i modeliranje LIDAR podataka i biomase za svaki pojedini uređajni razred s vrlo dobrim koeficijentom determinacije od 0,8. Druga istraživanja (**Saeidi i dr., 2014**) opet koriste LIDAR podatke samo za stvaranje preciznog digitalnog modela reljefa čiji su derivati (nagib, ekspozicija i sl) jako bitni pri korištenju multispektralnih snimki. **Estronel i dr. 2012** npr. koristeći NDVI i zeleni kanal poboljšavaju model za procjenu biomase sastavljen od LIDAR metrike sa R^2=0,67 na 0,79. **Tonolli i dr. (2011)** koristeći LIDAR metriku i vegetacijski indeks NDWI su imali manje uspjeha, gdje se model poboljšao samo za 0,02-0,04 (u odnosu na početne vrijednosti R^2 od 0,68 do 0,75).

Implementacijom LIDAR tehnologije za obračun biomase vegetacije na velikim područjima i posljedično obračun vezanog ugljika odnosno ugljičnog dioksida se može prihvatljivo precizno, a efikasno i brzo doći do rješenja uvodno spomenutog problema. Osobito za podatke o količini ugljika na površinama u obraštanju, te za šikare (**kako je potvrđeno Hipotezom 1**) koje s obzirom na površinu mogu biti značajan dodatak trenutnoj veličini spremnika ugljika, a za koje se prema **Pravilniku o uređivanju šuma (NN 79/15)**, ne određuje drvna zaliha prilikom izrada Programa gospodarenja. Navedeno predstavlja sve veći problem osobito prilikom izrade NIR-a. Upravo zbog konstantne obveze da se takav inventar nadopunjuje i poboljšava sve točnijim i preciznijim podacima i procedurama potrebno je imati mogućnost

brzog, efikasnog i jednostavnog prikupljanja podataka. Izrađenim modelima moguće je doći do nedostajućih podataka za kontinentalno nizinsko i brdsko područje. Naime, rezultate ovog istraživanja (težinu suhe tvari) je vrlo lako pretvoriti u količinu ugljika množeći je s udjelom ugljika u suhoj tvari (koji se kreće oko 50 %). U skladu s tim, na istraživanom području u nadzemnoj šumskoj biomasi prosječno je vezano približno 19 t C/ha u nizinskom području odnosno približno 22 t C/ha u brdskom području.

Da bi odredili koliko je vezano CO_2 iz atmosfere, potrebno je težinu ugljika u drvu pomnožiti sa faktorom 3,67 (1 tona ugljika odgovara 3,67 t CO_2; **Chadderton, 1997**).

Kako je potrebno stvoriti ovakve modele za svako specifično područje **(Laes i dr., 2011)**, da bi se riješio problem na razini cijele Republike Hrvatske, potrebno je ovakva istraživanja provesti i za mediteranski, submediteranski te planinski dio RH, uz testiranje izrađenih modela na drugim brdskim i nizinskim područjima. Provedbom predloženih istraživanja stvorio bi se preduvjet za uporabu ovakvog način procjene biomase degradiranih šumskih površina na području cijele Republike Hrvatske. Što znači da bi terenska istraživanja bilo potrebno provesti samo jednom, a nakon toga slijedi avionsko snimanje LIDAR-om (čak i niske gustoće) i primjena izrađenih modela. Inače bi za prikupljanje ovakvih rezultata svakih *n* godina bilo potrebno provesti zahtjevna terenska istraživanja, što je u konačnici zasigurno skuplje. Nadalje, opetovanom primjenom ove tehnologije, svakih nekoliko godina, može se uspostaviti efektivni monitoring promjena.

LIDAR tehnologijom se može pratiti, odnosno kartirati sukcesija šume **(Falkowski i dr., 2009),** čime bi moglo odrediti područje na koje će se primijeniti izrađeni modeli za obračun biomase. Primjenom ove metode skratio bi se i pojednostavio postupak izlučivanja istraživanog područja primijenjen u ovom istraživanju (poglavlje *2.1.2 Stratifikacija područja*), ali LIDAR podaci nisu bili dostupni na početku ovog istraživanja.

Modeli za procjenu parametara sastojine napravljeni na osnovu oblaka točaka smanjene gustoće, kao u ovom istraživanju, su prikladni za procjenu parametara na razini sastojine ili područja („area based“). Razlog ovome je što je zbog male gustoće oblaka teško razlučiti pojedina stabla i njegove atribute, što je preduvjet za određivanje sastojinskih parametara na razini plohe ili parametara stabla („individual tree based“).

Za određivanje sastojinskih parametara na razini plohe potrebno je imati podatke veće gustoće oblaka točaka koji osiguravaju mogućnost razlučivanja pojedinačnih stabala. Međutim, postoje i pokušaji korištenja rijetkih oblaka gustoća, pri čemu je teško razlučiti pojedina stabla za npr. procjenu drvnih sortimenata stojećih stabala, kao što su koristili **Holopainen i dr. (2010)** pri čemu su dobili slabe rezultate promatrajući RMSE koji se kretao od 6,0 m^2/ha do 46,2 m^2/ha.

Kako je već napomenuto, na razini stabla (ITB metoda) LIDAR možemo ponajprije koristiti za: procijene visine stabala (**Nasset 1997a, 1997 b; Popescu i dr., 2002; Lee i Lucas, 2007; Leitold i dr., 2015**), procijene broja stabala (**Nasset i Bjerknes, 200**1), volumen biomase pojedinih stabala (**Popescu, 2007; Figueiredo i dr., 2016**), izdvajanje krošanja i izmjeru dimenzija krošanja (**Nasset i Okland, 2002; Goodwin i dr., 2006**). Na razini sastojine (AB metoda) možemo doći do sljedećih informacija: omjer smjese vrsta drveća (**Donoghue i dr., 2007**), gustoća sastojine (**Nasset, 1997b; Lee i Lucas, 2007**), temeljnica (**Holmgreen, 2004**), drvna zaliha (**Nasset, 1997b; Holmgreen, 2004; Hollaus i dr., 2007**), biomasa i zaliha ugljika u sastojinama (**Zhao i dr., 2009; García i dr, 2010; Chirici i dr., 2016; Ferraz i dr., 2016**) te razvoja spomenutih sastojinskih elemenata (**Yu, 2007; Woodget i dr., 2007**) i dr.

3.3 Testiranje primjene rjeđih oblaka točaka za obračun nadzemne biomase

Hipoteza 2

Korištenjem podataka niže gustoće odnosno rjeđeg oblaka točaka, što korespondira s većom visinom i brzinom leta pri snimanju, a samim tim i obuhvaćenim većim područjem uz manje troškove, moguće je na osnovu izrađenih modela dobiti rezultate s prihvatljivom točnošću i preciznošću za željenu namjenu.

Uporabom predselektiranih varijabli prikazanih u Tablici 3-17 za nizinsko područje (dobivenih na osnovu prorjeđivanja oblaka točaka izabranih 18 ploha koje tvore uži raspon oblaka točaka), te u Tablici 3-18 za brdsko područje (dobivenih na osnovu grupiranja svih 45 ploha u tri grupe raspona gustoća), pristupilo se postupnim („stepwise“) regresijskim analizama po pojedinim grupama podataka.

Tablica 3- Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za prorijeđene oblake točaka nizinskog dijela

Grupa varijabli	Nizinsko područje (N=18)							
	100%		50%		33%		16%	
	nezavisna varijabla	R^2	nezavisna varijabla	R^2	nezavisna varijabla	R^2	nezavisna varijabla	R^2
1	p95	0,60	p90	0,58	p90	0,55	p90	0,50
	p10	0,14	p25	0,14	p01	0,13	p30	0,10
	p01	0,11	p05	0,06	p99	0,05	p50	0,08
2	qav	0,52	qav	0,51	qav	0,52	qav	0,46
					min	0,06		
3	b80	0,14	b40	0,08	b80	0,09	b80	0,09
	b90	0,06	b80	0,07			b20	0,07
4	d03	0,41	d03	0,40	d03	0,44	d03	0,37
	d00	0,20	d00	0,15	d00	0,16	d00	0,11

Tablica 3- Prikaz izabranih varijabli za dalje modeliranje uz pripadajući R^2 za grupirane podatke prema gustoćama oblaka za brdsko područje

Grupa varijabli	Brdsko područje					
Grupa varijabli	B1 (N=18)		B2 (N=18)		B3 (N=9)	
	nezavisna varijabla	R^2	nezavisna varijabla	R^2	nezavisna varijabla	R^2
1	p90	0,47	p75	0,76	p99	0,76
	p10	0,15	p50	0,04	p20	0,19
	p50	0,11			p80	0,03
2	avg	0,36	qav	0,74	std	0,71
	kur	0,08			avg	0,11
	max	0,09				
3	b40	0,16	b10	0,26	b90	0,67
	b75	0,13	b60	0,22	b25	0,16
4	d00	0,29	d03	0,67	d00	0,55
	d03	0,17	d00	0,14	d04	0,12
	d01	0,06				

Rezultati odnosno izrađeni modeli sa najvećim R^2 i određenim koeficijentima se nalaze u Tablici 3-19, dok su statističke karakteristike modela uz raspon korištenih oblaka točaka prikazane u Tablici 3-20.

Tablica 3- Izrađeni modeli sa pripadajućim dobivenim parametrima

grupa	b0	b1	var. 1	b2	var. 2	b3	var. 3	b4	var. 4
N100	-220,35725	2,94840	**p95**	19,12432	**p01**	2,25001	**b90**	-0,22932	**d00**
N50	24,12605	2,68903	**p90**	-0,46998	**d00**				
N33	7,66287	3,77937	**p90**	14,98641	**p01**	-1,20452	**p99**	-0,17591	**d00**
N16	24,82348	2,55414	**p90**	-0,22184	**d00**				
B1	51,30124	4,08462	**p90**	0,65494	**d01**	-0,66151	**b75**		
B2	8,81753	11,71786	**p75**	-8,40849	**p50**				
B3	53,6643	74,2467	**std**	-24,7508	**p80**	-0,7262	**b25**		

Tablica 3- Statističke karakteristike modela uz korištene raspone oblaka točaka

grupa	N	raspon gustoće oblaka	prosječna gustoća oblaka	R	R^2	R^2 adjusted	F	p	Standardna pogreška procjene
N100	18	0,63-1,66	1,20	0,88	**0,75**	0,68	9,99	0,000641	8,235653
N50	18	0,31 -0,86	0,60	0,80	**0,63**	0,58	12,82	0,000546	9,376958
N33	18	0,22-0,61	0,41	0,86	**0,75**	0,67	9,61	0,000767	8,354967
N16	18	0,11-0,29	0,20	0,73	**0,55**	0,48	9,07	0,002618	10,409795
B1	18	0,36-1,00	0,65	0,82	**0,68**	0,61	9,70	0,001012	9,555262
B2	18	1,00-1,75	1,54	0,90	**0,81**	0,78	31,51	0,000004	7,168370
B3	9	>1,75	2,64	0,97	**0,94**	0,90	25,61	0,001838	6,199587

Promatrajući grupu N100, prvi izračunati model vrijednosti R^2 od 0,83 na osnovu varijabli iz tablice 3-15 i spomenutih ograničenja je sadržavao previše varijabli (Tablica 3-), čije

korištenje ne bi bilo u skladu s preporukama **Laes i dr, 2011**. Stoga je postojeći model izrađen od dvije najsnažnije varijable (p95, p01) uz po jednu iz ostalih grupa varijabli, da bi uključili što raznovrsniju metriku (u ovom slučaju b90 i d00).

Tablica 3- Sažetak stepwise regresijske analize za grupu podataka N100

Varijabla	korak	višetruki R	višestruki R^2	R^2 promjena	F – ul/izl	p vrijednost	varijable
p95	1	0,739377	0,546678	0,546678	19,29501	0,000454	1
p01	2	0,811937	0,659242	0,112564	4,95501	0,041768	2
b90	3	0,846691	0,716886	0,057644	2,85050	0,113486	3
b80	4	0,878442	0,771660	0,054775	3,11847	0,100868	4
d00	5	0,892385	0,796350	0,024690	1,45484	0,250995	5
p10	6	0,913050	0,833660	0,037310	2,46730	0,144538	6

Izrađeni modeli za **nizinsko područje** (N100, N50, N33, N16) se vrlo malo razlikuju po korištenim varijablama, gdje je najbitnija varijabla jedan od gornjih percentila visine (p90 ili p95), dok druga najbitnija (korektivna) varijabla predstavlja najniži decil (0,5-2,5 m). Ovo je razumljivo i za očekivati s obzirom da se radi o istim oblacima točaka, ali samo razrijeđenih na 50, 33 ili 16 % izvorne gustoće oblaka (od N100 odnosno 18 izabranih od 23 nizinske plohe).

Promatrajući koeficijente determinacije (R^2) uočavamo da oni variraju od gustoće do gustoće oblaka točaka, čime se ne može zaključiti da djelomično prorjeđivanje gustoće oblaka značajno utječe na kvalitetu i preciznost modela. Međutim, model izrađen na osnovu najrjeđeg oblaka točaka (N16) koji ima prosječnu gustoću oblaka 0,2 točke/m^2, ipak ima značajnije slabiji koeficijent determinacije i *p* vrijednost, iako druge statističke karakteristike modela nisu značajno lošije (promatrajući prikazane vrijednosti u Tablici 3-20). Bez obzira na slabiju vrijednost, *p* vrijednost modela N16 je i dalje ispod 0,05 označavajući da je model i dalje statistički značajan, iako je izrađen s oblacima točaka gdje postoji samo jedna točka (zapis, podatak) na 5 m^2 površine.

Izrađeni modeli za **brdsko područje** prikazuju važnost različitih varijabli u odnosu na grupe podataka (Tablica 3-18), što je isto tako razumljivo imajući u vidu činjenicu da su podaci za brdsko područje grupirani na osnovu gustoće oblaka i svaka grupa se sastoji od terenskih ploha koje se pojavljuju samo u jednoj grupi. Ovo ima za posljedicu da se u svakoj grupi nalazi skup oblaka različitih karakteristika.

Koeficijenti determinacije ovih modela pokazuju znatno poboljšanje ukoliko se koriste oblaci veće gustoće točaka, čak do 0,94 za grupu B3, gdje se nalaze plohe s gustoćama oblaka točaka od 1,75 do 5,63 točaka/ m^2. Ovu vrijednost R^2 treba uzeti s rezervom, jer je model napravljen samo na osnovu 9 ploha, gdje određeni parovi ploha imaju gotovo istu mjerenu biomasu (Tablica 3-3> ploha 51 i 68, te ploha 38 i 64), dodatno smanjujući varijabilnost i povećavajući točnost modela. Upravo zbog te male varijabilnosti vrijednost F-testa je veća, a *p* vrijednost niža u odnosu na ravijene modele brdskog područja.

Wu i dr. (2016) su istražili utjecaj gustoće ploha na kvalitetu modela sastavljenih samo od standardne devijacije, te nagiba ili spljoštenosti distribucije ovisno o modelu za procjenu biomase. Područje istraživanja je bilo u Arizoni, obraslo mješovitim crnogorično-bjelogoričnim sastojinama (tj. američkim borovima i hrastovima). Proučavajući gustoće oblaka od 8 točaka/m^2 do 0,5 točaka/m^2, uočili su pad determinacijske snage modela sa 0,59 na 0,46. Rezultati istraživanja vezani uz hipotezu 2 pokazuju sličan trend, iako uz nešto veću snagu modela najrjeđeg oblaka (R^2 sa 0,75 za 1,2 točke/m^2 na 0,55 za 0,2 točke/m^2).

Istražujući smanjenje gustoće oblaka točaka sa 10 tj. 20 točaka/m^2 do 1 točke po m^2 snimljenih na više različitih područja u sklopu različitih istraživanja, **Garcia i dr. (2017)** su zaključili da se koeficijent determinacije nije pogoršao u najnižim gustoćama. U navedenom istraživanju samo se mjestimično povećao RMSE, ipak ukazujući na djelomično pogoršavanje modela. Navedeno istraživanje je u skladu s ovim istraživanjem, promatrajući iste gustoće oblaka točaka istraživane u oba istraživanja. Naime, u istraživanju u sastavu ove disertacije također nema značajnog smanjenja R^2 do gustoće od 1 točke/m^2.

Singh i dr. (2015) su proučavali gustoće oblaka od 5,77 do 0,06 točaka/m^2 (srednje vrijednosti) na velikom području sastavljenom od hrastovo-karijino-borovih šuma. Varijable koje su činile modele su varijanca visine, medijana apsolutne devijacije od ukupnog moda visine, te 5-i percentil visine. Izrađeni modeli ovisno o gustoćama su imali R^2 od 0,82 za najgušći oblak, do 0,72 za najrjeđi (0,06 točaka/m^2) ne pokazujući značajan pad snage modela. Rezultati navedenog istraživanja nisu u potpunosti u skladu s rezultatima istraživanja u sklopu ove disertacije, jer je model na osnovu oblaka gustoće od 0,2 točke/m^2 pokazao značajniji pad R^2.

Promatrajući vrijednost R^2 za grupu B3, **Garcia i dr. (2010)** su također za jedan od modela dobili iznimno visok R^2 (0,93 za crniku). Međutim, taj model za crniku izrađen na osnovu samo 7 ploha (u ovom istraživanju je korišteno 9 ploha), te su i oni zaključili da taj model treba koristiti s oprezom.

Rezultati dobiveni kroz analizu *Hipoteze 2* su u potpunosti u skladu s preporukama **White i dr. (2013),** gdje navode da se za dobivanje parametara na razini sastojina/područja može ići do gustoće (rijetkoće) oblaka od 0,5 točaka/m^2 (u slučaju ovog istraživanja do 0,4 točke/m^2)

3.3.1 Usporedba „glavnih“ modela i modela na osnovu prorijeđenih oblaka točaka

Za usporedbu „glavnih“[33] i modela na osnovu prorijeđenih oblaka točaka[34], izvršit će se ista analiza kao i pri usporedbi rezultata glavnih modela (izrađenim prilikom testiranja Hipoteze 1) s mjerenim podacima.

3.3.1.1 Nizinsko područje

U nastavku (Tablica 3-) se nalaze usporedbe modela izrađenih na osnovu neprorijeđenih i prorijeđenih oblaka točaka za nizinsko područje.

Tablica 3- Prikaz sumarnih i osnovnih statističkih osobina rezultata modela nastalih u okviru Hipoteze 1 i 2 za nizinsko područje

	Nizinsko područje [35]	Nizinsko područje N100 [36]	N50	N33	N16
broj ploha za modeliranje	23	18	18	18	18
broj piksela	5.107	4.620[37]	4.655[38]	5.076	5.019
minimum biomase (kg/piksel)	49,38	0,00	0	0,01	15,54
maksimum biomase (kg/piksel)	17.523,69	35.941,24	10.393,80	90.456,82	11.223,91
prosječno po pikselu (kg/piksel)	1.812,22	1.684,04	1.376,67	1.669,65	1.573,85
standardna devijacija	2.323,53	1.732,38	1.349,42	3.163,35	1.301,79
ukupna biomasa (kg)	9.258.081,22	7.780.245,41	6.408.381,24	8.475.139,24	7.899.168,99
ukupna površina piksela (ha)	225,22	203,74	205,29	224,36	221,84
prosječna biomasa (kg/ha)	41.107,07	38.186,75	31.216,92	37.774,73	35.607,51
prosječna biomasa (t/ha)	41,11	38,19	31,22	37,77	35,61

Promatrajući ukupne i prosječne vrijednosti, vidljivo je da su one manje od vrijednosti dobivenih „glavnim“ modelom odnosno modelom izrađenim u sklopu Hipoteze 1. Razlog može biti u tome, što su se prilikom izostavljanja ploha koje su imale izrazito niske ili visoke

[33] Modela iz Hipoteze 1
[34] Modela iz Hipoteze 2
[35] Sve mjerene plohe
[36] Izostavljene plohe s rubnim vrijednostima gustoće oblaka
[37] Izostavljeno je 511 piksela čiji je izračunati korijen biomase bio negativan, a koji su većinom bili u rubnim dijelovima područjima
[38] Izostavljeno je 439 piksela čiji je izračunati korijen biomase bio negativan, a koji su većinom bili u rubnim dijelovima područjima

gustoće oblaka točaka (Plohe 2, 11, 20, 21 i 23; Prilog 4 i Tablica 3-3), slučajno izostavile plohe koje su imale nižu biomasu, te je model vjerojatno postao „neosjetljiv“ u tom području pokazujući manje vrijednosti.

Međutim, promatrajući iskustveno, ove razlike su dovoljno male da bi imale utjecaja npr. prilikom operativnog uređivanja šuma.

Promatrajući maksimalne vrijednosti nadzemne biomase po pikselima (Tablica 3-22), vidljivo je da su one mjestimično (N100 i N33) nerealno velike, uspoređujući ih sa maksimalnim vrijednostima modela izrađenog prilikom testiranja Hipoteze 1. Međutim, kod obračuna po modelu N100 to se događa samo na 4 piksela (Tablica 3-), a na modelu N33 se događa na samo 27 piksela, što u konačnici ne utječe značajno na ukupnu ili srednju vrijednost nadzemne biomase, samo povećava standardnu devijaciju podataka.

Tablica 3- Usporedba raspona biomasa prema modelima prorijeđenih oblaka točaka po pikselima s rasponom biomase prema modelu s neprorijeđenih oblakom točaka

Područje	Pikseli s biomasom nižom od minimalne prema glavnom modelu	Pikseli s biomasom unutar raspona prema glavnom modelu	Pikseli s biomasom višom od maksimalne prema glavnom modelu	Ukupno
N100	185	4431	4	4620
N50	100	4555	0	4655
N33	70	4979	27	5076
N16	106	4913	0	5019

3.3.1.2 Brdsko područje

U nastavku (Tablica 3-) se nalaze usporedbe modela izrađenih na osnovu neprorijeđenih i prorijeđenih oblaka točaka za brdsko područje.

Tablica 3- Prikaz sumarnih i osnovnih statističkih osobina rezultata modela nastalih u okviru Hipoteze 1 i 2 za brdsko područje

	Brdsko područje	B1	B2	B3
broj ploha za modeliranje	45	18	18	9
broj piksela	9.674	9.674	9.674	9407[39]
minimum biomase (kg/piksel)	12,90	0	111,06	0
maksimum biomase (kg/piksel)	13.032,87	21.622,15	33.355,04	125.735,65
prosječno po pikselu (kg/piksel)	1.981,96	2.266,90	1.838,10	2.097,40
standardna devijacija	1.560,59	2.100,01	1.992,37	3.393,57
ukupna biomasa (kg)	19.173.571,07	21.930.032,93	17.781.754,21	19.730.228,82
ukupna površina piksela (ha)	426,62	426,62	426,62	414,85
prosječna biomasa (kg/ha)	44.942,97	51.416,19	41.690,32	47.559,91
prosječna biomasa (t/ha)	44,94	51,42	41,69	47,56

U ovom slučaju jedan model daje veće, a drugi manje rezultate u odnosu na „glavni“ model izrađen u okviru Hipoteze 1, međutim s obzirom da su modeli rađeni samo na osnovu 18 odnosno 9 ploha, a onda primijenjeni na cijelu površinu, možemo zaključiti da su i to zadovoljavajući rezultati.

Promatrajući maksimalne vrijednosti po pikselima, razvidno je da su one dvo-, tro- i *n*- struko veće, uspoređujući ih sa maksimalnim vrijednostima modela za brdsko područje izrađenog u sklopu testiranja Hipoteze 1. Međutim, kod obračuna po modelu B1 to se događa samo na 160 piksela (Tablica 3-), na modelu B2 se događa na samo 26 piksela, a na modelu B3 na 82 piksela, što u konačnici ne utječe značajno na ukupnu ili srednju vrijednost, samo djelomično povećava standardnu devijaciju podataka.

[39] Izostavljeno je 267 piksela čiji je izračunati korijen biomase bio negativan, a koji su većinom bili u rubnim dijelovima područjima

Tablica 3- Usporedba raspona biomasa prema modelima prorijeđenih oblaka točaka po pikselima s rasponom biomase prema modelu s neprorijeđenih oblakom točaka

Područje	Pikseli s biomasom nižom od minimalne prema glavnom modelu	Pikseli s biomasom unutar raspona prema glavnom modelu	Pikseli s biomasom višom od maksimalne prema glavnom modelu	Ukupno
B1	316	9298	160	9674
B2	0	9652	22	9674
B3	49	9276	82	9407

Na osnovu prikazanog za nizinski i brdski dio istraživanog područja, možemo zaključiti da je i Hipoteza 2 **uspješno potvrđena** s obzirom da, iako su modeli točniji pri većoj gustoći točaka i sa rijetkim oblacima točaka (srednje gustoće od 0,41 točke po m^2; (Tablica 3-20, grupa N33) se dobiju modeli sličnih koeficijenta determinacije, čiji su rezultati prihvatljivi, a po vrijednostima neznatno odstupaju od onih obračunatih modelima napravljenim u sklopu Hipoteze 1.

3.4 Ograničenja i preporuke

Prilikom ovog istraživanja suočilo se sa sljedećim ograničenjima koje treba uzeti u obzir prilikom interpretacije rezultata:

- Vremensko nepoklapanje LIDAR snimanja (2012. godina) i terenskog uzorkovanja (2016. godina) radi čega su izrađene lokalne debljinsko-prirasne i visinske krivulje za procjenu stanja sastojina u godini snimanja,
- Oblaci točaka za nizinsko područje su „umjetno“ prorijeđeni i takav oblak samo simulira rjeđe stanje, ali je upotrijebljen postupak koji osigurava najtočniju moguću simulaciju rjeđih laserskih zraka,
- Rijeđi oblaci točaka mogu otežati samu klasifikaciju točaka u kategorije tla, vegetacije i sl. stoga su prorijeđivani već klasificirani oblaci točaka s obzirom da cilj istraživanja nije bio provjera mogućnosti programa za klasifikaciju oblaka točaka kao što je bio cilj **Ivšić i dr., 2016**,

- Za obračun biomase pojedinih stabala korišteni su većinom modeli izrađeni u stranim zemljama, a u pojedinim situacijama su korišteni modeli za razinu roda za određenu vrstu drveću.

Preporuke za buduća istraživanja su sljedeća:

- Potrebno je imati vremenski usaglašeno terensko uzorkovanje i avionsko LIDAR snimanje, da bi se izbjeglo akumuliranje određene pogreške prilikom procjene prsnog promjera i njegove visine prije *n* godina,
- Za usporedbu modela izrađenih na osnovu različitih gustoća oblaka, bi bilo potrebno imati više uzastopnih avionskih snimanja s različitim gustoćama oblaka točaka,
- Potrebno je izraditi lokalne modele za procjenu biomase stabla na osnovu prsnog promjera i/ili visine za sve vrste koje nalazimo na području RH,
- Radi dodatne provjere izrađenih modela u sklopu ovog istraživanja potrebno ih je primijeniti na drugim nizinskim i brežuljkastim područjima, po mogućnosti s većim gustoćama oblaka točaka,
- Testirati primjenu drugih podataka (dobivenih obradom ortofoto ili multispektralnih snimaka) u kombinaciji s LIDAR podacima radi utvrđivanja njihovog doprinosa povećanju točnosti modela,
- Radi dobivanja nedostajućih podataka o biomasi degradiranih šumskih područja za potrebe ispunjavanja obveza i raznih izvješća temeljem članstva RH u Europskoj Uniji i raznim organizacijama, potrebno je provesti isti tip istraživanja u mediteranskim, submediteranskim i planinskim područjima Republike Hrvatske.

4 ZAKLJUČCI

Na temelju provedenog istraživanja procjene šumske biomase pomoću LIDAR tehnologije u degradiranim šumama nizinskog i brežuljkastog vegetacijskog pojasa središnje Hrvatske utvrđeno je sljedeće:

1. Uz pomoć LIDAR tehnologije može se **efikasno** (*ogroman broj podataka za veliko područje snimljenih u kratkom roku*), **brzo** (*primjena modela na rastere željenih varijabli u GIS okruženju na razini svakog pojedinačnog piksela u par poteza*) i **dovoljno točno** (*R^2=0,75 za nizinsko tj. 0,60 za brdsko područje*) odrediti količina nadzemne biomase u raznodobnim degradiranim sastojinama kontinentalne Hrvatske,
2. Iako su modeli točniji pri većoj gustoći točaka, **i sa rijeđim oblacima točaka** do određene granice (N33; R^2=0,75; 0,4 točke/m^2) se dobiju **modeli sličnih koeficijenta determinacije,** čiji su rezultati primijenjeni na velikoj površini bliski vrijednostima onima obračunatima s „glavnim“ modelima pokazujući prihvatljivu točnost. Stoga u skladu s ovim istraživanjem, pri snimanju LIDAR-om, oblak točaka ne bi smio biti gustoće ispod 0,4 m^2 (odnosno jednog zapisa/podatka/točke na 2,5 m^2) što i dalje predstavlja rijetke LIDAR oblake točaka,
3. Za dobar i kvalitetan model koji se treba primjenjivati na većem prostoru mora biti i **dovoljan broj uzorkovanih terenskih ploha** (minimalno bar 1 ploha na 10 ha istraživane površine, a ovisno o terenskoj varijabilnosti i više),
4. Prilikom terenskog istraživanja je potrebno **prikupiti podatke i za ekstremne situacije** (po pitanju obrasta, količine biomase i sl.) da bi i ti podaci ušli u model i spriječili potrebu ekstrapolacije i njene nesigurnosti, osobito u ovako raznovrsnim područjima,
5. Prilikom obrade LIDAR podataka je potrebno **uzeti šire područje od istraživanog**, inače rubni pikseli u kreiranim rasterima pri obračunima biomase imaju „neprirodne“ oblake točaka, zbog kojih model izračunava nerealne rezultate.

Prilog 1 – Izgled terenskog obrasca

Točka broj	

Nagib	

Pokrovnost	

Opis točke

Vrsta	d (na mm)	visina	udalj-enost	azimut	Vrsta	d (na mm)	visina	udalj-enost	azimut

tanka 3x3,5

vrsta	*1-3 cm	pros. Visina	*3-5 cm	pros. Visina

prirast

vrsta	d	br. god	debljina 10 god

Datum _____

Prilog 2a Primjer slikane panorame plohe 5

Prilog 2b Primjer slikane panorame plohe 11

Prilog 2c Primjer slikane panorame plohe 67

Prilog 3 – Prikaz mjerenih koordinata i koordinata centra plohi

Ploha	Snimljena X koordinata	Snimljena Y koordinata	n,m,v	azimut prema centru	Pomak od centra (m)	Prava X koordinata centra	Prava Y koordinata centra
1	450695,7808	5072570,6130	117,75			450695,7808	5072570,6130
2	450827,3701	5072530,9510	117,20			450827,3701	5072530,9510
3	451325,7669	5072396,0010	119,32			451325,7669	5072396,0010
4	451677,5626	5072339,7060	119,88			451677,5626	5072339,7060
5	451931,0917	5072346,8010	119,43			451931,0917	5072346,8010
6	451943,3628	5072228,2300	118,32			451943,3628	5072228,2300
7	451604,7954	5072123,1810	118,79			451604,7954	5072123,1810
8	451235,0189	5072142,8510	118,52			451235,0189	5072142,8510
9	450924,4192	5072064,0570	119,73			450924,4192	5072064,0570
10	450971,5345	5072307,0600	119,66			450971,5345	5072307,0600
11	450696,2841	5072348,9950	116,83			450696,2841	5072348,9950
12	464819,8626	5069235,4850	107,89			464819,8626	5069235,4850
13	468961,9494	5072265,5680	104,58	134	1,390	468962,9444	5072264,5975
14	468743,3047	5072255,8760	104,38	234	1,700	468741,9245	5072254,8838
15	468585,1173	5071911,1170	104,58	81	1,035	468586,1403	5071911,2737
16	468526,8136	5071881,0290	103,81	198	2,250	468526,1075	5071878,8929
17	468132,5919	5071894,9570	103,89	133	1,835	468133,9274	5071893,6988
18	470577,2718	5072540,9610	102,97			470577,2718	5072540,9610
19	469448,8090	5072642,6100	103,96			469448,8090	5072642,6100
20	470023,8686	5072537,5650	103,85			470023,8686	5072537,5650
21	469608,2781	5072387,8550	104,10	284	0,730	469607,5707	5072388,0350
22	469978,4711	5072377,1050	101,71	289	1,830	469976,7439	5072377,7091
23	470469,4311	5072243,6300	101,75			470469,4311	5072243,6300
24	473705,9258	5088671,9310	233,06	358	0,730	473705,9034	5088672,6606
25	473883,5875	5088803,8310	236,23			473883,5875	5088803,8310
26	473078,9916	5088447,4420	253,10			473078,9916	5088447,4420
27	473164,1023	5088389,2810	232,63			473164,1023	5088389,2810
28	472654,8627	5088247,6810	215,57			472654,8627	5088247,6810
29	472281,8167	5088186,4530	249,44			472281,8167	5088186,4530
30	472398,9621	5087448,0410	215,90			472398,9621	5087448,0410
31	471948,4800	5087854,1360	259,61	147	0,580	471948,7937	5087853,6482
32	471560,5633	5087372,6810	247,91			471560,5633	5087372,6810
33	471491,8416	5087205,1040	232,01			471491,8416	5087205,1040
34	471693,0782	5086885,5710	239,64	331	0,630	471692,7753	5086886,1234
35	471157,9569	5086365,6910	255,51	59	0,890	471158,7218	5086366,1458
36	471342,2854	5086924,4850	221,48	297	4,800	471338,0191	5086926,6837
37	470820,2926	5086885,5590	230,31	215	2,020	470819,1263	5086883,9099
38	469935,7069	5086732,4880	302,04	182	5,030	469935,5069	5086727,4624
39	470232,2285	5085444,8180	244,67	121	2,280	470234,1770	5085443,6344
40	470409,8046	5085424,2960	272,56	72	7,600	470417,0431	5085426,6097
41	470566,2338	5086090,0770	216,80			470566,2338	5086090,0770
42	469709,1490	5085446,0200	257,20			469709,1490	5085446,0200
43	470050,1154	5084729,9340	216,72	255	9,250	470041,1699	5084727,5834
44	469216,4781	5086756,1960	380,41	103	7,970	469224,2341	5086754,3647
45	468859,9543	5086667,2940	324,05			468859,9543	5086667,2940

Ploha	Snimljena X koordinata	Snimljena Y koordinata	n,m,v	azimut prema centru	Pomak od centra (m)	Prava X koordinata centra	Prava Y koordinata centra
46	468443,9534	5086571,6610	320,30			468443,9534	5086571,6610
47	468585,7086	5086889,5540	331,26			468585,7086	5086889,5540
48	468279,9523	5086255,5530	264,45	304	1,440	468278,7627	5086256,3643
49	468638,6297	5086119,7360	296,76			468638,6297	5086119,7360
50	468972,1711	5084520,3490	317,00	203	2,885	468971,0306	5084517,6993
51	468320,2999	5084500,1240	330,19	20	7,610	468322,9390	5084507,2610
52	467672,1807	5084531,1610	332,20			467672,1807	5084531,1610
53	468071,2642	5084597,5990	328,46			468071,2642	5084597,5990
54	467573,1146	5085153,7690	300,01	284	0,890	467572,2523	5085153,9888
55	467327,8966	5084722,7270	267,69			467327,8966	5084722,7270
56	467545,8947	5083920,9620	306,43			467545,8947	5083920,9620
57	466519,7294	5083837,0646	348,50			466519,7294	5083837,0646
58	466615,3112	5083259,9860	293,92			466615,3112	5083259,9860
59	466796,3909	5082758,8170	283,49			466796,3909	5082758,8170
60	465898,0599	5085787,0590	327,02			465898,0599	5085787,0590
61	465965,4498	5085477,4820	340,98			465965,4498	5085477,4820
62	466572,9259	5086734,6980	442,86	332	1,455	466572,2498	5086735,9862
63	466787,8940	5086527,9370	424,72			466787,8940	5086527,9370
64	466579,1270	5086256,9530	398,03			466579,1270	5086256,9530
65	466847,6693	5086327,3580	416,94	326	0,570	466847,3531	5086327,8322
66	466789,3145	5085912,5370	402,75			466789,3145	5085912,5370
67	466791,8899	5085498,0370	365,63			466791,8899	5085498,0370
68	466452,2304	5084639,8390	316,63	286	1,650	466450,6469	5084640,3024

Prilog 4 Distribucija točaka prema povratima i klasifikaciji za svaku plohu

Ploha	Grupa podataka (hipoteza 2)	broj točaka	1. povrat	2. povrat	3. povrat	4. povrat	Gustoća ukupno (točaka /m^2)	Gustoća 1. povrat (točaka /m^2)	Kat. 1 (visina 0.2-0.5m)	Kat. 2 (točke tla)	Kat. 3 (niska veg. 0.5-1m)	Kat. 4 (srednja veg. 1-2m)	Kat 5. (visoka veg >2m)	Kat. 12 (ne klasificirano od 2-30m)
1	Nx	842	717	117	8	0	1,66	1,30	5	479	1	93	259	5
2	/	198	145	48	5	0	0,43	0,34	1	102	1	21	57	12
3	Nx	606	342	211	48	5	1,24	0,76	13	205	16	48	324	0
4	Nx	436	348	79	9	0	0,89	0,76	4	193	4	39	188	4
5	Nx	660	425	217	18	0	1,31	0,88	5	296	3	21	335	0
6	Nx	520	407	113	0	0	1,03	0,82	3	260	1	30	226	0
7	Nx	510	387	116	7	0	1,02	0,77	5	255	6	40	203	1
8	Nx	598	364	216	18	0	1,17	0,69	7	222	4	20	349	0
9	Nx	602	413	186	3	0	1,23	0,83	14	311	1	21	255	0
10	Nx	523	513	10	0	0	1,06	1,04	7	206	0	77	228	5
11	/	160	145	14	1	0	0,37	0,35	0	88	0	31	19	24
12	Nx	672	431	229	12	0	1,37	0,88	4	281	3	25	359	0
13	Nx	521	430	84	7	0	1,03	0,87	1	311	6	37	159	7
14	Nx	536	460	75	1	0	1,05	0,90	1	122	12	45	356	0
15	Nx	598	450	131	16	1	1,21	0,92	6	204	17	45	326	0
16	Nx	593	456	131	6	0	1,20	0,91	7	399	7	3	177	0
17	Nx	572	421	143	8	0	1,15	0,84	2	293	2	19	256	0
18	Nx	357	258	91	8	0	0,71	0,53	4	156	13	34	153	0
19	Nx	734	568	164	2	0	1,42	1,16	14	209	12	116	383	0
20	/	2483	1625	830	28	0	5,01	3,26	30	1176	6	38	1237	0
21	/	1271	1003	261	7	0	2,50	1,96	20	529	8	96	618	0
22	Nx	299	209	86	4	0	0,63	0,47	1	186	0	8	104	0
23	/	1506	1045	430	31	0	3,01	2,60	85	913	53	150	293	16
24	B1	267	173	87	7	0	0,57	0,37	0	144	1	3	118	1
25	B1	182	176	6	0	0	0,39	0,38	0	79	0	47	46	10
26	B1	172	154	17	1	0	0,38	0,36	2	136	5	12	10	7
27	B1	180	175	5	0	0	0,40	0,39	0	82	2	48	36	12
28	B3	1176	1155	21	0	0	2,30	2,27	7	689	14	290	176	0
29	B2	658	654	4	0	0	1,32	1,30	7	387	18	156	83	7
30	B2	640	476	152	12	0	1,26	0,98	10	391	7	31	200	1
31	B3	1920	1743	170	7	0	3,81	3,40	29	782	113	498	507	0
32	B1	224	188	36	0	0	0,48	0,41	0	100	0	30	93	0

Ploha	Grupa podataka (hipoteza 2)	broj točaka	1. povrat	2. povrat	3. povrat	4. povrat	Gustoća ukupno (točaka /m^2)	Gustoća 1. povrat (točaka /m^2)	Kat. 1 (visina 0.2-0.5m)	Kat. 2 (točke tla)	Kat. 3 (niska veg. 0.5-1m)	Kat. 4 (srednja veg. 1-2m)	Kat 5. (visoka veg >2m)	Kat. 12 (ne klasificirano od 2-30m)
33	B1	272	187	85	0	0	0,56	0,39	0	131	3	15	123	0
34	B2	846	584	255	7	0	1,67	1,11	42	415	9	22	357	0
35	B2	676	507	163	6	0	1,34	0,99	4	291	8	39	334	0
36	B1	224	174	48	2	0	0,50	0,41	1	108	2	14	93	6
37	B1	158	132	26	0	0	0,36	0,31	0	97	1	16	36	7
38	B2	771	573	196	2	0	1,48	1,10	13	317	12	71	347	11
39	B3	944	684	243	17	0	1,84	1,32	14	383	16	59	471	0
40	B2	867	536	303	28	0	1,69	1,03	15	347	18	30	459	0
41	B2	555	536	19	0	0	1,12	1,09	0	523	0	6	12	14
42	B2	565	543	21	1	0	1,18	1,13	3	408	7	54	77	16
43	B1	321	256	61	4	0	0,66	0,56	2	216	2	15	78	8
44	B1	457	283	156	18	0	0,95	0,60	4	197	10	13	233	0
45	B1	346	292	52	2	0	0,70	0,59	4	214	2	21	98	7
46	B2	561	349	195	17	0	1,16	0,73	0	262	4	18	277	0
47	B2	809	620	184	5	0	1,59	1,20	33	324	16	71	365	0
48	B1	346	287	59	0	0	0,70	0,61	3	253	0	27	76	4
49	B3	946	769	173	4	0	1,89	1,49	56	500	3	87	299	1
50	B2	554	443	104	7	0	1,07	0,86	3	220	3	56	272	0
51	B3	1009	638	333	38	0	1,90	1,18	38	442	6	37	486	0
52	B1	222	181	41	0	0	0,50	0,41	1	164	0	3	33	21
53	B1	265	197	66	2	0	0,58	0,44	1	111	7	29	112	4
54	B2	767	560	204	3	0	1,58	1,16	5	386	8	33	335	0
55	B2	794	556	230	8	0	1,58	1,13	12	300	6	40	436	0
56	B2	649	505	144	0	0	1,27	0,99	18	183	3	50	395	0
57	B1	211	164	46	1	0	0,47	0,42	2	160	3	14	18	14
58	B2	701	540	153	8	0	1,38	1,06	7	379	9	54	252	0
59	B2	662	545	113	4	0	1,31	1,06	4	400	6	44	208	0
60	B1	197	194	3	0	0	0,43	0,43	1	141	1	22	10	22
61	B2	686	591	93	2	0	1,31	1,14	62	471	3	16	129	5
62	B3	1163	838	298	27	0	2,34	1,65	7	686	2	26	442	0
63	B1	269	199	70	0	0	0,58	0,43	0	113	1	20	133	0
64	B1	245	197	48	0	0	0,52	0,42	0	103	4	31	106	1

Ploha	Grupa podataka (hipoteza 2)	broj točaka	1. povrat	2. povrat	3. povrat	4. povrat	Gustoća ukupno (točaka /m^2)	Gustoća 1. povrat (točaka /m^2)	Kat. 1 (visina 0.2-0.5m)	Kat. 2 (točke tla)	Kat. 3 (niska veg. 0.5-1m)	Kat. 4 (srednja veg. 1-2m)	Kat 5. (visoka veg >2m)	Kat. 12 (ne klasificirano od 2-30m)
65	B3	2838	2141	656	41	0	5,63	4,11	116	812	250	499	1163	2
66	B2	660	536	123	1	0	1,29	1,04	5	438	4	22	190	0
67	B3	1070	840	225	5	0	2,16	1,65	21	566	33	102	308	7
68	B3	972	817	152	3	0	1,93	1,67	10	634	18	78	221	11

Prilog 5 Tablični prikaz vrijednosti izračunatih varijabli

Prikaz statističkih osobina i bicentila oblaka točaka na plohama

točka	grupa	min	max	avg	qav	std	ske	kur	b10	b20	b25	b30	b40	b50	b60	b70	b75	b80	b90
1	N100	0,98	15,9	5,9	53,31	4,3	0,56	2,03	28,6	44,5	46,8	49,6	56,6	68,6	78,2	85,2	88,5	90,2	96,6
2	/	0,8	11,33	4,35	26,54	2,77	0,76	2,47	15,6	37,8	43,3	52,2	63,3	72,2	80	84,4	90	91,1	96,7
3	N100	0,53	20,05	6,9	75,04	5,25	0,84	2,61	23,1	44,7	51,4	58,4	65,6	75,1	82,8	86,9	89,2	91,5	95,4
4	N100	0,51	18,67	3,27	14,95	2,07	4,33	29,8	29,5	79,1	93,6	97,4	97,9	98,3	98,3	99,1	99,1	99,1	99,1
5	N100	0,67	20,3	5,75	49,05	4	1,87	6,11	10,6	46,1	69,7	77,8	84,4	88,9	91,1	92,8	93,9	95,3	98,1
6	N100	0,77	6,31	3,45	13,18	1,14	-0,09	2,32	0,4	6,2	11,7	16	28,8	47,5	64,6	82,9	87,9	94,6	98,8
7	N100	0,59	11,49	4,88	32,22	2,9	0,28	1,74	14,1	32,5	39,8	45,4	53	60,6	68,7	84,3	88	92,8	98,8
8	N100	0,58	13,07	5,85	42,36	2,86	0,27	2,11	5,6	18,5	26,3	35,8	50,5	61,3	72	86,8	90,6	94,9	98,1
9	N100	0,74	11,92	4,96	29,01	2,1	0,41	2,92	5	15	21,4	33,9	56,4	72,9	84,6	94,6	97,1	97,9	99,3
10	N100	1,16	5,1	2,37	5,98	0,6	0,77	5,62	0	4,8	10,6	21,3	46,8	78,7	96,5	98,7	98,7	98,7	98,7
11	/	1,04	5,35	2,48	7,31	1,08	0,88	2,91	0	12,2	28,4	37,8	56,8	70,3	79,7	85,1	89,2	93,2	95,9
12	N100	0,52	18,09	4,5	25,95	2,4	2,56	12,51	9,6	45,3	69,7	85,5	94	95,6	96,4	97,4	98,7	99	99,2
13	N100	0,59	18,69	4,19	31,25	3,71	2,39	8,56	28,2	70,8	79,9	85,6	88	91,9	93,3	94,7	95,7	96,2	97,1
14	N100	0,57	9,5	3,07	10,94	1,23	1,77	10,23	6,1	20,6	37,3	60,8	86,7	97,3	97,8	98,1	98,1	98,1	98,8
15	N100	0,5	18,3	4,53	34,24	3,7	1,92	6,04	22,4	65,7	77,3	82	86,6	88,7	89,9	93,3	94,3	95,9	98,7
16	N100	0,6	12,18	6,64	52,12	2,85	-0,3	2,26	4,8	14	17,2	22,6	28	44,6	58,1	73,1	79	87,1	96,2
17	N100	0,65	10,97	5,32	36,22	2,83	0,46	1,89	2,5	18,1	28,3	35,9	52,2	63,4	68,1	74,6	77,5	81,2	92,4
18	N100	0,59	19,07	7,27	86,1	5,79	0,49	1,68	29,6	46,2	49,2	53,3	57,8	65,8	70,4	76,4	80,4	84,4	98
19	N100	0,51	17,1	3,49	19,58	2,72	3,18	14,56	29,9	72,7	82,8	91	95,7	96,1	96,1	96,1	96,1	96,3	98
20	/	0,58	8,02	4,05	17,3	0,95	-0,48	4,33	1,2	3,4	6,6	9,2	23	56,7	87,3	97,7	98,7	99,6	99,8
21	/	0,63	9,17	3,97	19,3	1,89	0,39	2,23	5,2	23,6	35,3	40,2	51,8	63	80,9	90,9	93,1	95,7	98,4
22	N100	1,11	8,25	4,93	26,93	1,62	-0,7	2,81	0,9	7,2	9,9	12,6	20,7	28,8	44,1	72,1	82	91,9	98,2
23	/	0,51	15,79	3,68	22,54	3,01	1,52	4,93	39,9	57,1	69,9	79,3	88,6	89,4	91,6	96,7	98	98,6	99,6
24	B1	0,8	10,71	5,87	39,66	2,29	0,02	2,51	2,4	9,7	12,1	14,5	27,4	43,5	65,3	76,6	81,5	89,5	93,5
25	B1	1,04	4,84	2,31	6,09	0,86	0,95	3,55	0	7,8	16,7	32,4	52	67,6	84,3	89,2	92,2	94,1	96,1
26	B1	0,64	11,14	3,97	29,52	3,77	0,83	1,87	42,4	57,6	66,7	66,7	69,7	69,7	69,7	69,7	72,7	75,8	90,9
27	B1	0,92	7,6	2,22	6,06	1,08	2,75	12,41	6,2	47,4	69,1	81,4	90,7	95,9	95,9	96,9	96,9	96,9	99
28	B3	0,61	4,78	1,88	4,05	0,71	1,14	4,17	1	27,1	40,4	53,1	71,2	85,6	92,5	96,5	97,5	98,8	99,6
29	B2	0,62	4,48	1,76	3,37	0,53	0,74	5,44	3	19,3	32,2	45,1	75	90,9	98,9	99,2	99,2	99,2	99,6
30	B2	0,7	16,59	5,92	52,17	4,15	0,85	2,69	16,7	41,8	51,9	55,2	64,4	72,4	82,4	87,9	90	92,1	96,2
31	B3	0,51	8,66	2,25	6,9	1,35	1,35	4,7	27,5	59,9	70	76	84,3	92,4	97	98,8	99,5	99,6	99,6
32	B1	1,14	15,92	3,41	18,77	2,68	2,81	11,05	25,2	78	84,6	87,8	91,9	94,3	94,3	95,1	95,9	96,7	99,2
33	B1	0,86	11,9	4,03	19	1,67	0,64	5,33	7,9	22,1	30,7	42,9	76,4	92,1	98,6	99,3	99,3	99,3	99,3
34	B2	0,5	10,7	4,67	26,39	2,14	0,69	3,37	4,9	13,9	19,8	31,7	53,6	71,4	84	89,9	92	93,8	96,4

točka	grupa	min	max	avg	qav	std	ske	kur	b10	b20	b25	b30	b40	b50	b60	b70	b75	b80	b90
35	B2	0,63	11,19	4,51	25,66	2,32	0,64	2,66	5,5	23,6	32,7	43,7	59,9	74,3	82,7	89	91,9	95	99,2
36	B1	0,64	8,28	3,53	14,78	1,52	0,78	3,65	2,6	14,8	21,7	33	59,1	78,3	85,2	93	94,8	94,8	97,4
37	B1	0,81	7,17	3,24	13,02	1,6	0,75	2,63	1,7	15	31,7	43,3	56,7	68,3	80	85	88,3	90	93,3
38	B2	0,53	10,28	3,79	17,77	1,85	0,65	3,35	9,7	26,5	34,4	43,2	68,6	81,4	90,7	95,7	97,1	98,2	98,9
39	B3	0,51	12,84	4,6	28,9	2,78	1,01	3,44	9,3	34,2	46,2	55,5	69,2	78,8	86,4	91	93,8	94,9	97,1
40	B2	0,51	13,26	5,86	43,2	2,98	0,19	2,13	8,5	17,6	28,2	36,5	50,1	61,3	75,5	86	90,7	94,5	98
41	B2	1,13	6,08	3,43	13,8	1,44	0,12	1,85	0	6,3	15,6	18,8	34,4	50	59,4	71,9	71,9	78,1	90,6
42	B2	0,8	10,97	2,68	10,02	1,69	2,26	9,35	20,8	59,1	77,3	83,1	90,9	94,8	95,5	97,4	98,7	98,7	98,7
43	B1	0,93	13,45	4,86	33,24	3,12	0,92	2,8	13,6	36,9	46,6	58,3	68,9	75,7	82,5	89,3	90,3	93,2	99
44	B1	0,51	16,42	6,1	50,5	3,66	0,66	2,74	12,4	30,2	40,3	47,7	63,6	74,4	84,9	90,7	91,5	95	98,1
45	B1	0,56	11,77	4,54	29,2	2,95	0,91	2,79	10	35,4	44,6	55,4	63,1	71,5	81,5	86,2	89,2	92,3	93,8
46	B2	0,82	12,4	6,2	49,07	3,27	0,18	1,64	4	19	27	35,7	48,3	53	59,7	72	76	82,3	95
47	B2	0,53	12,03	3,95	19,98	2,09	0,57	3,04	13,9	33,8	43,8	55,1	69,7	85	94	98,2	98,9	99,3	99,3
48	B1	1,07	11,22	4,11	23,81	2,64	0,96	2,79	10,3	39,3	47,7	58,9	67,3	74,8	82,2	87,9	89,7	92,5	98,1
49	B3	0,75	9,65	3,97	20,57	2,2	0,6	2,31	7,7	31,3	37,7	44,6	60,8	70,8	77,9	86,9	89,7	93,6	98,2
50	B2	0,92	13,33	4,04	23,28	2,64	1,52	4,89	11,7	48,3	59,8	70,9	79,6	85,6	89,2	94,9	96,4	97	97,9
51	B3	0,61	14,82	7,19	64,09	3,51	-0,17	1,83	7,9	20,3	25,6	30,9	39	48,8	60,8	81	87,2	93,8	98,3
52	B1	1,4	9,26	4,47	22,93	1,74	0,4	2,98	0	8,9	16,1	21,4	35,7	62,5	83,9	89,3	89,3	94,6	98,2
53	B1	0,56	11,82	4,47	29,48	3,08	0,82	2,45	15,8	38,2	46,1	55,3	69,1	72,4	77	82,9	86,2	89,5	96,1
54	B2	0,69	10,74	4,3	22,52	2,01	0,5	2,69	5,9	21,5	31,1	41	59,3	75	85,4	93,1	96,5	98,4	99,2
55	B2	0,51	12,56	5	32,33	2,71	0,87	3,03	6,6	21,4	32,6	43,9	66,4	76,3	82,1	88	90,3	93,2	97,5
56	B2	0,55	7,56	3,48	14,05	1,39	0,7	2,97	0,7	10,3	19	29	53,6	70,3	80,6	88,6	92	95,1	97,8
57	B1	0,85	11,98	4,48	32,99	3,63	1,02	2,61	18,8	43,8	54,2	60,4	70,8	72,9	79,2	81,3	83,3	83,3	85,4
58	B2	0,54	13,4	4,05	23,01	2,58	1,49	5,34	16,8	41,3	54,3	65,1	81,6	88,3	91,7	94,9	95,9	96,2	97,5
59	B2	0,51	10,21	3,96	19,93	2,06	0,6	2,86	9,3	27,2	35,4	44,4	61,1	73,9	87,2	94,2	96,1	96,9	98,1
60	B1	0,82	3,97	2,13	5,04	0,7	0,25	2,32	0	3,6	12,7	25,5	40	54,5	65,5	85,5	94,5	94,5	98,2
61	B2	0,68	11,59	4,69	27,98	2,46	0,39	2,23	7,2	29,4	33,3	43,8	54,9	69,3	80,4	90,2	94,8	96,1	99,3
62	B3	0,53	20,53	8	83,08	4,38	0,51	2,97	9,6	30	33,4	37,7	51,9	73,4	87,7	93	93,6	95,1	96,8
63	B1	0,85	8,54	4,01	18,53	1,57	0,19	2,84	1,9	13,6	18,8	25,3	40,9	61,7	80,5	93,5	94,2	96,8	98,1
64	B1	0,6	8,2	3,28	13,61	1,7	0,76	3,01	8,3	27,1	33,3	45,8	61,1	76,4	86,1	91	92,4	93,8	98,6
65	B3	0,5	9,04	3,15	14,3	2,1	0,73	2,52	27,1	43,1	50	56,1	67,3	76,6	84,8	90,4	93,2	95,6	98,4
66	B2	0,55	6,44	3,68	15,49	1,4	-0,02	2,13	1,9	6,5	12,5	19,4	29,6	42,6	59,7	70,8	78,7	83,8	93,5
67	B3	0,51	11,32	5,14	36,97	3,25	0,08	1,54	22	35,3	38,1	41,2	46,8	53,4	62,7	73,6	81,4	88,7	96
68	B3	0,52	10,8	3,15	13,04	1,76	1,22	4,89	16,5	40,5	54,3	67,7	82,3	91,5	94,8	97,3	98,5	98,8	99,4

Prikaz percentila oblaka točaka na plohama

točka	grupa	p01	p05	p10	p15	p20	p25	p30	p35	p40	p45	p50	p55	p60	p65	p70	p75	p80	p85	p90	p95	p99
1	N100	1,08	1,27	1,39	1,55	1,68	1,93	2,07	2,33	2,75	3,64	5,18	6,43	7,02	7,61	8,42	9,2	10,07	11,05	12,8	13,91	15,12
2	/	1,11	1,32	1,42	1,52	1,81	1,97	2,3	2,53	2,76	3,31	3,7	4	4,35	4,92	5,39	6,16	6,89	8,06	8,37	9,72	10,5
3	N100	0,76	1,1	1,44	1,89	2,25	2,54	2,98	3,45	4,01	4,43	5,08	5,95	6,65	8,26	9,25	10,2	11,48	13,36	15,41	17,38	19,57
4	N100	0,83	1,37	1,63	1,83	1,99	2,12	2,34	2,55	2,69	2,79	2,95	3,06	3,28	3,41	3,65	3,93	4,15	4,5	4,83	5,2	13,03
5	N100	1,12	1,73	2,4	2,97	3,2	3,5	3,73	3,93	4,22	4,41	4,58	4,94	5,12	5,25	5,47	6,05	6,97	8,86	11,17	16,07	19,38
6	N100	1,14	1,51	1,79	2,2	2,37	2,63	2,85	3,02	3,15	3,33	3,46	3,61	3,87	3,99	4,15	4,28	4,47	4,67	4,93	5,21	5,77
7	N100	0,65	1,18	1,4	1,67	2,05	2,19	2,46	2,75	3,28	3,76	4,44	5,1	5,86	6,37	7,25	7,43	7,8	8,27	8,97	9,68	10,36
8	N100	0,97	1,68	2,41	2,74	3,13	3,56	3,83	4,17	4,51	4,94	5,43	6,05	6,68	7,09	7,69	8,23	8,69	9,08	9,73	10,57	12,34
9	N100	1,19	1,58	2,26	2,7	3,28	3,52	3,81	3,96	4,21	4,48	4,73	4,97	5,34	5,56	5,91	6,4	6,97	7,35	7,68	8,65	10,01
10	N100	1,25	1,4	1,61	1,74	1,84	1,97	2,07	2,15	2,25	2,3	2,37	2,47	2,53	2,6	2,66	2,73	2,84	2,91	3,05	3,13	4,67
11	/	1,07	1,22	1,42	1,51	1,59	1,62	1,72	1,79	1,96	2,05	2,14	2,31	2,52	2,65	2,9	3,05	3,39	3,8	4,08	4,47	5,28
12	N100	1,26	1,68	2,31	2,69	2,91	3,25	3,41	3,67	3,79	4	4,25	4,43	4,59	4,72	4,9	5,13	5,36	5,68	6,19	7,82	13,91
13	N100	0,72	1,19	1,5	1,76	1,95	2,21	2,34	2,44	2,59	2,82	3,04	3,26	3,47	3,69	4,08	4,53	4,93	5,82	8,49	13,22	18,45
14	N100	0,7	1,33	1,63	2,06	2,28	2,42	2,56	2,71	2,81	2,89	2,98	3,1	3,18	3,28	3,39	3,57	3,83	3,98	4,34	4,74	8,78
15	N100	0,59	1,12	1,51	1,89	2,13	2,41	2,63	2,87	3,05	3,37	3,48	3,63	3,8	3,98	4,34	4,78	5,23	7,15	11,06	14,41	16,73
16	N100	0,72	1,37	2,6	2,86	3,78	4,83	5,69	5,92	6,12	6,34	6,67	7,25	7,57	8,29	8,56	8,74	9,32	9,66	10	10,78	11,84
17	N100	1,25	1,78	2,14	2,47	2,61	2,87	3,18	3,53	3,87	4,18	4,54	5,14	5,42	6,11	6,99	7,85	8,69	9,24	9,54	10,16	10,82
18	N100	0,71	0,98	1,26	1,47	1,61	2,08	2,34	2,85	3,19	3,83	5,35	6,41	8,36	9,46	11,13	12,96	14,36	15,39	15,98	16,56	17,69
19	N100	0,62	1,18	1,39	1,65	1,82	1,95	2,17	2,43	2,6	2,79	3	3,15	3,3	3,48	3,69	4	4,44	4,77	5,35	6,15	15,92
20	/	1,15	2,2	2,92	3,28	3,43	3,56	3,67	3,77	3,88	3,96	4,1	4,21	4,33	4,45	4,56	4,69	4,83	4,94	5,08	5,38	6,22
21	/	0,99	1,35	1,73	2	2,14	2,25	2,43	2,65	3,07	3,41	3,76	4,21	4,61	4,89	5,21	5,43	5,63	5,94	6,43	7,3	8,37
22	N100	1,21	1,5	2,27	2,91	3,46	4,15	4,43	4,75	4,92	5,16	5,32	5,48	5,7	5,77	5,82	6,09	6,19	6,37	6,58	6,87	8,02
23	/	0,54	0,71	0,99	1,19	1,3	1,4	1,57	1,72	2,04	2,6	2,9	3,21	3,69	3,89	4,31	4,53	5,38	6,21	9,01	10,63	13,66
24	B1	1,01	2,27	2,59	3,5	3,88	4,46	4,76	4,98	5,27	5,66	5,8	5,98	6,24	6,47	7,04	7,44	8,07	8,43	8,65	9,78	10,66
25	B1	1,08	1,2	1,41	1,49	1,6	1,68	1,74	1,82	1,9	1,99	2,19	2,26	2,41	2,56	2,69	2,76	2,85	3,1	3,55	4,02	4,75
26	B1	0,64	0,67	0,97	1,01	1,04	1,17	1,28	1,43	1,51	1,62	2,01	2,15	2,56	2,81	4,98	8,49	9,12	9,3	9,61	10,37	11,03
27	B1	1	1,19	1,34	1,46	1,5	1,59	1,71	1,77	1,88	1,9	1,93	2,03	2,14	2,24	2,33	2,4	2,55	2,95	3,15	3,54	6,75
28	B3	0,89	1,05	1,15	1,23	1,3	1,34	1,41	1,48	1,56	1,63	1,71	1,79	1,87	1,97	2,16	2,28	2,38	2,56	2,87	3,33	4
29	B2	0,75	0,95	1,09	1,21	1,3	1,41	1,46	1,54	1,61	1,68	1,72	1,83	1,88	1,95	2,01	2,08	2,18	2,26	2,4	2,54	2,98
30	B2	0,88	1,22	1,58	1,91	2,33	2,62	2,94	3,21	3,61	3,99	4,31	5,29	5,87	7,11	7,94	8,67	9,42	10,76	12,45	14	16,37
31	B3	0,64	0,84	0,98	1,09	1,19	1,27	1,36	1,48	1,59	1,67	1,77	1,94	2,13	2,31	2,53	2,85	3,36	3,79	4,3	5	6,23
32	B1	1,16	1,35	1,61	1,73	1,89	2,01	2,11	2,27	2,44	2,52	2,66	2,84	2,97	3,12	3,3	3,49	3,7	4,23	5,78	9,86	14,04
33	B1	0,93	1,47	1,81	2,14	2,39	2,94	3,23	3,56	3,82	3,93	4,17	4,3	4,44	4,64	4,79	4,96	5,15	5,58	5,76	6,81	7,44
34	B2	0,58	1,51	2,21	2,75	3,03	3,24	3,44	3,74	3,93	4,1	4,37	4,68	4,89	5,18	5,46	5,76	6,11	6,79	7,64	9,15	10,38

točka	grupa	p01	p05	p10	p15	p20	p25	p30	p35	p40	p45	p50	p55	p60	p65	p70	p75	p80	p85	p90	p95	p99
35	B2	0,85	1,53	1,82	2,12	2,38	2,74	2,93	3,31	3,44	3,78	4,1	4,43	4,77	5,2	5,41	5,87	6,46	7,27	8,19	9	10,01
36	B1	0,99	1,36	1,65	2,05	2,41	2,53	2,74	2,93	3,06	3,21	3,3	3,55	3,61	3,77	4,01	4,26	4,44	5,12	5,54	6,37	7,91
37	B1	0,92	1,36	1,65	1,8	1,88	1,92	2,13	2,39	2,43	2,59	2,76	2,95	3,39	3,71	4,06	4,37	4,45	4,86	5,72	6,58	6,91
38	B2	0,73	1,16	1,48	1,76	2,04	2,36	2,69	2,97	3,23	3,52	3,75	3,93	4,07	4,23	4,48	4,76	5,23	5,73	6,28	7,12	9,31
39	B3	0,81	1,24	1,75	2,04	2,28	2,47	2,75	3,01	3,32	3,52	3,82	4,17	4,48	4,89	5,61	6,35	6,76	7,55	8,76	10,32	12,49
40	B2	0,66	1,17	2,04	2,66	3,2	3,49	3,85	4,18	4,73	5,05	5,57	6,2	6,69	7,21	7,84	8,12	8,69	9,25	9,98	10,76	12,25
41	B2	1,15	1,19	1,68	1,82	2,16	2,32	2,54	2,72	2,78	3,09	3,28	3,53	3,8	4,05	4,16	4,73	4,99	5,2	5,35	5,61	5,94
42	B2	0,85	1,07	1,21	1,4	1,53	1,6	1,69	1,84	1,99	2,11	2,23	2,41	2,6	2,75	2,9	3,04	3,47	3,75	4,46	5,77	9,14
43	B1	0,97	1,44	1,67	1,94	2,09	2,52	2,88	3,04	3,28	3,65	3,93	4,24	4,42	4,68	6,09	6,76	7,6	9,01	9,79	11,26	11,9
44	B1	0,63	1,15	1,96	2,29	3,01	3,31	3,65	4	4,35	4,89	5,51	5,98	6,51	6,95	7,67	8,55	9,34	10,05	11,37	13,2	15,32
45	B1	1	1,27	1,62	1,82	2,04	2,16	2,31	2,68	2,94	3,31	3,52	3,75	4,25	5,04	5,87	6,56	6,91	8,25	8,97	10,75	11,75
46	B2	0,94	1,85	2,27	2,61	2,92	3,31	3,67	4,01	4,32	4,69	5,68	6,76	7,71	8,01	8,61	9,33	9,88	10,24	10,73	11,19	12,02
47	B2	0,64	1,14	1,36	1,71	1,99	2,2	2,52	2,88	3,1	3,44	3,67	3,93	4,33	4,67	5,12	5,55	5,95	6,25	6,69	7,51	9,22
48	B1	1,14	1,26	1,56	1,72	1,87	2,03	2,26	2,47	2,64	2,93	3,26	3,55	3,83	4,15	4,85	5,76	6,51	7,25	8,58	9,68	10,18
49	B3	1,02	1,28	1,45	1,61	1,83	2,05	2,22	2,6	2,88	3,24	3,54	3,89	4,12	4,63	4,97	5,61	6,17	6,65	7,37	7,97	9,14
50	B2	1,08	1,46	1,69	1,86	2,03	2,18	2,34	2,63	2,78	2,97	3,18	3,44	3,71	3,97	4,19	4,91	5,67	6,6	8,35	9,44	12,97
51	B3	1	1,64	2,09	2,68	3,29	3,97	4,64	5,55	6,32	7,04	7,83	8,42	8,89	9,33	9,7	10,09	10,39	10,94	11,52	12,23	13,52
52	B1	1,4	1,91	2,23	2,48	2,77	3,32	3,53	3,94	4,17	4,35	4,54	4,63	4,76	4,94	5,2	5,5	5,54	5,96	6,79	7,48	8,72
53	B1	0,67	1,07	1,3	1,59	1,75	2,05	2,33	2,55	2,84	3,2	3,4	3,87	4,19	4,53	5,1	6,93	7,76	8,57	9,58	10,37	11,57
54	B2	0,83	1,38	1,89	2,2	2,46	2,76	3,01	3,3	3,5	3,73	4,04	4,24	4,65	4,97	5,31	5,61	6,13	6,54	7,2	7,95	9,17
55	B2	0,85	1,57	2,04	2,42	2,76	3,07	3,31	3,72	3,89	4,19	4,4	4,57	4,83	5,18	5,61	6,22	7,32	8,42	9,41	10,78	12,1
56	B2	1,24	1,6	1,89	2,11	2,29	2,48	2,65	2,77	2,88	3,06	3,19	3,35	3,61	3,78	4,01	4,23	4,68	5,14	5,58	6,13	7,14
57	B1	0,88	1	1,17	1,31	1,63	1,85	1,92	2,06	2,36	2,69	3,08	3,5	3,93	4,46	4,65	6,34	7,36	10,16	11,24	11,77	11,97
58	B2	0,78	1,08	1,42	1,73	1,92	2,25	2,55	2,86	3,05	3,23	3,44	3,74	4,07	4,36	4,55	4,81	5,31	6,35	7,21	9,54	12,59
59	B2	0,83	1,16	1,48	1,73	1,98	2,33	2,61	2,91	3,2	3,43	3,65	4,03	4,24	4,52	5	5,52	5,88	6,2	6,68	7,53	9,72
60	B1	0,94	1,19	1,29	1,38	1,42	1,51	1,6	1,7	1,88	2,06	2,08	2,2	2,42	2,53	2,63	2,67	2,71	2,82	2,99	3,15	3,68
61	B2	0,89	1,31	1,86	2,03	2,13	2,45	2,8	3,34	3,59	4,11	4,58	4,87	5,28	5,66	6,09	6,45	7,1	7,55	8	8,86	9,92
62	B3	1,24	1,85	2,5	3,02	3,38	3,91	4,49	6	7	7,84	8,18	8,79	9,29	9,7	10,05	10,58	11,22	11,66	13,09	16,23	19,66
63	B1	1,13	1,56	1,8	2,19	2,57	2,83	3,19	3,47	3,66	3,93	4,15	4,27	4,47	4,62	4,77	5,03	5,26	5,51	5,85	6,55	8,14
64	B1	0,82	1,2	1,34	1,47	1,68	1,94	2,26	2,48	2,64	2,76	3,01	3,11	3,46	3,79	4	4,22	4,67	4,96	5,61	6,76	7,7
65	B3	0,55	0,75	0,91	1,03	1,14	1,28	1,47	1,72	2	2,31	2,62	2,97	3,33	3,74	4,14	4,58	5,1	5,64	6,38	7,23	8,29
66	B2	0,88	1,41	1,81	2,07	2,29	2,53	2,9	3,08	3,39	3,53	3,68	3,83	4,04	4,28	4,55	4,75	4,98	5,33	5,57	5,98	6,31
67	B3	0,58	0,89	1,13	1,41	1,53	1,69	1,99	2,56	3,53	4,36	5,26	6,11	6,72	7,29	7,77	8,09	8,43	8,86	9,2	10	11,13
68	B3	0,65	0,99	1,31	1,49	1,58	1,82	1,98	2,24	2,51	2,67	2,87	3,07	3,18	3,45	3,69	3,99	4,46	4,88	5,4	6,59	8,77

Prikaz decila i ostalih korištenih varijabli oblaka točaka na plohama

točka	grupa	d00	d01	d02	d03	d04	cov	dns	first_all	all_veg	up_half_ratio
1	N100	38,8	10,6	30,2	20,4	0	0,448	0,424	717	358	0,16
2	/	34,1	30,8	31,9	3,3	0	0,581	0,464	145	91	0,17
3	N100	24,6	24,9	24,1	26,2	0,3	0,846	0,639	342	388	0,28
4	N100	33,6	59,6	5,1	1,7	0	0,632	0,541	348	235	0,01
5	N100	11,1	46	30,5	11,9	0,6	0,754	0,545	425	359	0,09
6	N100	22,9	67,8	9,3	0	0	0,617	0,493	407	257	0,33
7	N100	30,8	23,6	42	3,6	0	0,575	0,486	387	250	0,25
8	N100	10,7	34,6	45,6	9,1	0	0,848	0,619	364	373	0,40
9	N100	11,7	43,8	43,4	1,1	0	0,638	0,458	413	277	0,18
10	N100	56,9	42,8	0,3	0	0	0,604	0,592	513	310	0,13
11	/	58,7	37,3	4	0	0	0,5	0,46	145	74	0,15
12	N100	11,9	60,5	23,5	4,1	0	0,843	0,572	431	387	0,04
13	N100	37,1	42,9	12,4	7,6	0	0,444	0,4	430	209	0,04
14	N100	27,1	70,3	2,7	0	0	0,881	0,771	460	413	0,02
15	N100	27,8	50,1	10,8	11,3	0	0,773	0,647	450	388	0,10
16	N100	9,1	18,2	62,6	10,2	0	0,373	0,314	456	187	0,23
17	N100	15,5	38,6	38,6	7,2	0	0,608	0,484	421	277	0,24
18	N100	31,5	18	17,5	33	0	0,662	0,552	258	200	0,27
19	N100	37,8	50,3	8	3,9	0	0,821	0,696	568	511	0,04
20	/	7,7	79,1	13,2	0	0	0,764	0,514	1625	1281	0,34
21	/	31,7	35,1	33,2	0	0	0,679	0,569	1003	722	0,27
22	N100	10,7	29,5	59,8	0	0	0,488	0,372	209	112	0,38
23	/	43,8	35,4	13,1	7,8	0	0,389	0,338	1045	512	0,05
24	B1	9,6	25,6	60	4,8	0	0,655	0,463	173	123	0,40
25	B1	64,1	35,9	0	0	0	0,582	0,563	176	103	0,19
26	B1	58,8	11,8	20,6	8,8	0	0,199	0,195	154	34	0,07
27	B1	77,6	18,4	4,1	0	0	0,549	0,544	175	98	0,02
28	B3	84	16	0	0	0	0,415	0,407	1155	480	0,06
29	B2	91,3	8,7	0	0	0	0,403	0,4	654	264	0,04
30	B2	20,8	32,9	28,3	17,9	0	0,466	0,373	476	239	0,14
31	B3	69,3	25,6	5,1	0	0	0,624	0,579	1743	1118	0,05
32	B1	42,7	45,2	6,5	5,6	0	0,619	0,551	188	123	0,04
33	B1	21,3	53,9	24,1	0,7	0	0,727	0,516	187	141	0,06
34	B2	13,1	49,6	34,4	2,8	0	0,621	0,458	584	388	0,19

točka	grupa	d00	d01	d02	d03	d04	cov	dns	first_all	all_veg	up_half_ratio
35	B2	21,9	40,5	36,3	1,3	0	0,688	0,565	507	381	0,19
36	B1	22,4	61,2	16,4	0	0	0,619	0,511	174	115	0,14
37	B1	44,3	41	14,8	0	0	0,455	0,386	132	60	0,14
38	B2	27,1	51	21,7	0,2	0	0,744	0,574	573	441	0,14
39	B3	25,4	40,4	28,9	5,3	0	0,738	0,579	684	546	0,17
40	B2	14,2	29,9	46,1	9,8	0	0,797	0,583	536	507	0,37
41	B2	27,3	51,5	21,2	0	0	0,061	0,059	536	32	0,03
42	B2	56,8	34,2	7,7	1,3	0	0,28	0,273	543	154	0,01
43	B1	25	41,3	24	9,6	0	0,366	0,323	256	103	0,10
44	B1	17,4	29,7	37,5	15,4	0	0,74	0,563	283	256	0,23
45	B1	32,8	30,5	29	7,6	0	0,414	0,375	292	128	0,12
46	B2	14	33,2	34,9	17,9	0	0,766	0,533	349	299	0,40
47	B2	29,8	39,3	30,2	0,7	0	0,655	0,559	620	452	0,11
48	B1	35,2	35,2	27,8	1,9	0	0,362	0,312	287	107	0,09
49	B3	33,5	36,6	29,9	0	0	0,488	0,412	769	390	0,15
50	B2	32,9	42,8	20,4	3,9	0	0,695	0,599	443	331	0,11
51	B3	13,2	19,5	41,5	25,8	0	0,696	0,525	638	529	0,42
52	B1	15,8	50,9	33,3	0	0	0,313	0,254	181	57	0,12
53	B1	34	34,6	24,2	7,2	0	0,716	0,577	197	152	0,21
54	B2	20,7	44,8	34	0,5	0	0,637	0,489	560	376	0,17
55	B2	15,8	45,9	31,1	7,2	0	0,827	0,608	556	482	0,21
56	B2	26,1	57,9	16	0	0	0,874	0,691	505	448	0,26
57	B1	44,9	26,5	12,2	16,3	0	0,287	0,231	164	49	0,08
58	B2	29,1	47,8	19	4,1	0	0,548	0,448	540	315	0,07
59	B2	27,9	41,9	29,8	0,4	0	0,45	0,387	545	258	0,12
60	B1	64,3	35,7	0	0	0	0,286	0,281	194	55	0,13
61	B2	25,3	30,5	42,9	1,3	0	0,252	0,224	591	153	0,08
62	B3	9,8	21,2	38,4	29,7	0,8	0,504	0,404	838	470	0,15
63	B1	19,4	54,2	26,5	0	0	0,764	0,576	199	154	0,30
64	B1	36,6	49	14,5	0	0	0,687	0,582	197	142	0,17
65	B3	47,7	31,1	21,2	0	0	0,745	0,674	2141	1914	0,21
66	B2	24,4	55,8	19,8	0	0	0,4	0,327	536	216	0,23
67	B3	34,5	13,3	47,1	5,1	0	0,5	0,421	840	450	0,25
68	B3	39,2	47,7	12,8	0,3	0	0,388	0,336	817	328	0,03

LITERATURA

- [Mrežno] Chadderton David (a)// Building Services Engineering Spreadsheets / Taylor & Francis, 1997. - pristupljeno 18.05.2017. - https://books.google.hr/books?id=iAS__ii2ug8C&lpg=PA108&dq=1kg%20c%203.67%20c02&hl=hr&pg=PA108#v=onepage&q=1kg%20c%203.67%20c02&f=false.
- [Mrežno] ESA publications *Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services* // European space agency. – 03. 2012. - pristupljeno 19.03.2017. - http://esamultimedia.esa.int/multimedia/publications/SP-1322_2/.
- [Mrežno] Gisdata d.o.o. - 16. 05. 2012. - pristupljeno 04.01.2017. - http://croatia.gdi.net/?p=2573
- [Mrežno] // Hrvatski centar za raminiravanje. - 2017. - pristupljeno 19.03.2017. - https://www.hcr.hr/hr/minSituac.asp.
- [Mrežno] // IPCC 40th.- 02.11.2014. – pristupljeno 07.01.2017. - https://www.ipcc.ch/pdf/ar5/prpc_syr/11022014_syr_copenhagen.pdf.
- [Mrežno] Isenburg Martin (a) // LAStools forum. - 17. 7 2014. - pristupljeno 06.02.2017. - https://groups.google.com/forum/#!topic/lastools/VNPKA-ABsI0/discussion.
- [Mrežno] Isenburg Martin (b) // LAStools forum. - 28. 12. 2014. - 06. 02 2017. - https://groups.google.com/forum/#!topic/lastools/VNPKA-ABsI0/discussion.
- [Mrežno] Isenburg Martin // LAStools forum. - 06. 07. 2015. - pristupljeno 06.02.2017. - https://groups.google.com/forum/#!topic/lastools/6_v5-d-O-mI/discussion.
- [Mrežno] Jarić Dauenhauer Nenad *Otkrivači Superhengea istražuju drevnu Hrvatsku* // The dayly dot. - 29.01.2016. - pristupljeno 19.03.2017. - https://www.tportal.hr/vijesti/clanak/otkrivaci-superhengea-istrazuju-drevnu-hrvatsku-20160129.
- [Mrežno] LEICA Geosystems *LEICA ALS50 II broschure*. - pristupljeno 23. 04. 2017. - http://www.nts-info.com/inventory/images/ALS50-II.Ref.703.pdf.
- [Mrežno] POPIS STANOVNIŠTVA 2011 // Državni zavod za statistiku. - pristupljeno 04. 01. 2017. - http://www.dzs.hr/Hrv/censuses/census2011/results/htm/H02_02/H02_02.html.

- Albert, K., Annighöfer, P., Schumacher, J., i Ammer, C. (2014): Biomass equations for seven different tree species growing in coppice-with-standards forests in Central Germany Scandinavian Journal of Forest, 29(3), 210-221.
- Anderson, R., i Bolstad, P. (2013): Estimating Aboveground Biomass and Average Annual Wood Biomass Increment with Airborne Leaf-on and Leaf-off LiDAR in Great Lakes Forest Types. Northern Journal of Applied Forestry, 30(1), 16-22.
- Annighofer, P., Molder, I., Zerbe, S., Kawaletz, H., Terwei, A., i Ammer, C. (2012): Biomass functions for the two alien tree species Prunus serotina Ehrh. and Robinia pseudoacacia L. in floodplain forests of Northern Italy. Eur J Forest Res, 131, 1619–1635.
- Arumae, T., i Land, M. (2014): Estimation of forest characteristics from ALS data in Estonia. (04-07. 11 2014). Riva del Garda , Italy.
- Balenović, I., Alberti, G., i Marjanović, H. (2013): Airborne Laser Scanning - the Status and Perspectives for the Application in in the South-East European Forestry. SEEFOR 4(2), 59-79.
- Balenović, I., Simić Milas, A., i Marjanović, H. (2017): A Comparison of Stand-Level Volume Estimates fromImage-Based Canopy Height Models of Different Spatial Resolutions. Remote Sens., 9(205), 1-27.
- Barbati, A., Chirici, G., Corona, P., Montaghi, A., i Travaglini, D. (2009): Area-based assessment of forest standing volume by field measurements. International Journal of Remote Sensing, 30(19), 5177-5194.
- Berta, A., Kušan, V., Križan, J., Stojsavljević, D., i Hatić, D. (2017): Posjedovne i površinske značajke šuma šumoposjednika u Hrvatskoj prema regijama. Šumarski list, 1-2, 57-65.
- Berta, A., Kušan, V., Stojsavljević, D., i Hatić, D. (2016): VARIABILITY OF THE BASIC POSSESSION PARAMETERS IN PRIVATELY-OWNED FORESTS IN CROATIA. Green 2016 proceedings (str. 1-6). Zagreb: Faculty of Food Technology and Biotechnology. Dohvaćeno iz https://www.researchgate.net/publication/308892496_Berta_GREEN2016_paper
- Berta A., Stojsavljević D., Kušan V., Grubišić I., Horvat D., Gojak S., Borić D., Prebeg M., Augustinović M., Vinogradac J., Tomašević M., Bakić N., (2017): Program gospodarenja šumama šumoposjednika za gospodarsku jedinicu "Čučerje-Šašinovec" (2017-2026), Oikon d.o.o.

- Bogdan, S., Šporčić, M., Seletković, A., i Ivanković, M. (2009):. Biomass production of common adler (Alnus glutinosa /L./ Gaertn.) in pure plantations and mixed plantations with willow clones (Salix spp.) in Croatia). Croat. j. for. eng., 30, 99-112.
- Bollandsas, O., Gregoire, T., Nasset, E., i Oyen, B.-H. (2013): Detection of biomass change in a Norwegian mountain forest area using small footprint airborne laser scanner data. Stat. Method Appl, 22, 113-129.
- Božić, A. (2016): Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukove prašume Medvjeđak. Šumarski fakultet. Preuzeto 05. 01 2017 iz https://urn.nsk.hr/urn:nbn:hr:108:872185
- Chen, Q., McRoberts, R., Wang, C., i Radtke, P. (2016): Forest aboveground biomass mapping and estimation across multiple spatial scales using model-based inference. Remote Sensing of Environment, 184, 350-360.
- Chirici, G., McRoberts, R., Fattorini, L., Mura, M., i Marchetti, M. (2016): Comparing echo-based and canopy height model-based metrics for enhancing estimation of forest aboveground biomass in a model-assisted framework. Remote Sensing of Environment, 174, 1-9.
- Corona P., A. Lamonaca, C. Gherardo, D. Travaglini, M. Marchetti, E. Minari, A. Montaghi, D. Gianelle, D. Travglini, F. Mason , E. Minari, G. Chirici, i C. Chemini (2008): Estimation of growing stock of broadleaved forests by airborne laser scanning. (Ur.), Canopy Analysis and Dynamics of a Floodplain Forest (str. 39-44). Verona.
- Čavlović, J., i Božić, M. (2008): Nacionalna inventura šuma u Hrvatskoj-metode terenskog prikupljanja podataka. Zagreb: Šumarski fakultet.
- Čihák, T., Hlásny, T., Stolariková, R., Vejpustková, M., i Marušák, R. (2014): Functions for the aboveground woody biomass in Small-leaved lime (Tilia cordata Mill.). Lesn. Cas. For. J., 60, 150-158.
- Davis, A., i Trettin, C. (2006): Sycamore and sweetgum plantation productivity on former agricultural land in South Carolina. Biomass and Bioenergy, 30, 769–777.
- Donoghue, D., Warr, P., Cox, N., i Wilson, J. (2007): Remote sensing of species mixtures in conifer plantations using LIDAR height and intensity data. Remote Sensing of Environment, 110(4), 509-522.
- EEC: Council Decision of 27 June 1985 on the adoption of the Commission work programme concerning an experimental project for gathering, coordinating and

ensuring the consistency of information on the state of the environment and natural resources in the Community; 85/338/EEC

- Estornell, J., Ruiz, L., Velasquez-Marti, B., i Hermosilla, T. (2012): ESTIMATION OF BIOMASS AND VOLUME OF SHRUB VEGETATION USING LiDAR AND SPECTRAL DATA IN A MEDITERRANEAN ENVIRONMENT. Biomass and Bioenergy, 46, 710-721.
- Falkowski, M., Evans, J., Martinuzzi, S., Gessler, P., i Hudat, A. (2009): Characterizing forest succession with lidar data: An evaluation for the Inland Northwest, USA. Remote Sensing of Environment, 113(5), 946-956.
- Ferraz, A., Saatchi, S., Mallet, C., Jacquemoud, S., Gonçalves, G., Silva, C., Soares, P., Tome, M., Pereira, L. (2016): Airborne Lidar Estimation of Aboveground Forest Biomass in the Absence of Field Inventory. Remote Sens, 8(653), 1-18. Ferraz, António; Saatchi, Sassan; Mallet, Clément; Jacquemoud, Stéphane; Gonçalves, Gil; Silva, Carlos Alberto; Soares, Paula; Tomé, Margarida; Pereira, Luisa
- Figueiredo, E., Neves d'Oliveira, M., Braz, E., Papa, D., i Fearnside, P. (2016): LIDAR-based estimation of bole biomass for precision management of an Amazonian forest: Comparisons of ground-based and remotely sensed estimates. Remote Sensing of Environment, 187, 281-293.
- Floris, A., Clementel,, F., Farruggia, C., i Scrinzi, G. (2010): Stima su base LiDAR delle provvigioni legnose forestali:. Italian Journal of Remote Sensing, 42(3), 15-32.
- Francescato V., Antonini E., Zuccoli Bergomi L., (2008):*_Priručnik o gorivima iz drvne biomase*. Zagreb: Biomass trade centar/Regionalna energetska agencija Sjeverozapadne Hrvatske, 9
- Fusco, S., Pflugmacher, D., Kirschbaum, A., Cohen, W., Chiatante, D., i Montagnoli, A. (2008): USO DEI DATI LIDAR PER STIMA DELLA BIOMASSA FORESTALE IN UN BOSCO MISTO DI LATIFOGLIE UN CASO STUDIO IN VALSASSINA (LC). 12a Conferenza Nazionale ASITA, (str. 1163-1166). L'Aquila.
- Gajski, D. (2007): Osnove laserskog skeniranja iz zraka. Ekscentar(10), 16-22.
- García, M., Riaño, D., Chuvieco, E., i 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.

- Garcia, M., Saatchi, S., Ferraz, A., Silva, C., Ustin, S., Koltunov, A., i Balzter, H. (2017): Impact of data model and point density on aboveground forest biomass estimation from airborne LiDAR. Carbon Balance Manage, 12(4), 1-18.
- Gasparini, P., Nocetti, M., Tabacchi, G., i Tosi, T. (2006): Biomass equations and data for forest stands and shrublands of the Eastern Alps (Trentino, Italy). USDA Forest Service.
- Gaveau, D., i 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.
- Gobakken, T., Nasset, E., Nelson, R., Bolandsas, O., Gregoire, T., Stahl, G., Astrup, R. (2012): Estimating biomass in Hedmark County, Norway using national forest inventory fieldplots and airborne laser scanning. Remote Sensing of Environment, 123, 443-456.
- Goodwin, N., Coops, N., i Culvenor, D. (2006): Assessment of forest structure with airborne LIDAR and the effects of platform altitude. Remote Sensing of Environment, 103(2), 140-152.
- Güneralp, I., Filippi, S., i Randall, J. (2014): Estimation of floodplain aboveground biomass using multispectral remote sensing and nonparametric modeling. International Journal of Applied Earth Observation and Geoinformation, 33(1), 119-126.
- Hal, S., Burke, I., Box, D., Kaufmann, M., i Stoker, J. (2005): Estimating stand structure using discrete-return lidar: an example from low density, fire prone ponderosa pine forests. Forest Ecology and Management, 208, 189-209.
- Hawbaker, T., Gobakken, T., Lesak, A., Trømborg, E., Contrucci, K., i Radeloff, V. (2010): Light Detection and Ranging-Based Measures of Mixed Hardwood Forest Structure. Forest Science, 56(3), 313-326.
- Heiskanen, J. (2006): Estimating aboveground tree biomass and leaf area index in a mountain birch forest using ASTER satellite data. International Journal of Remote Sensing, 27(06), 1135-1158.
- Hollaus, M., Wagner, W., Maier, B., i Schadauer, K. (2007): Airborne Laser Scanning of Forest Stem Volume in a Mountainous Environment. Sensors, 7(8), 1559-1577.
- Holmgreen, J. (2004): Prediction of tree height, basal area and stem volume in forest stands using airborne laser scanning. Scandinavian Journal of Forest Research, 19(6), 543-553.

- Holopainen, M., Vastaranta, M., Rasinmäki, J., Kalliovirta, J., Mäkinen, A., Haapanen, R., Hyyppä, H. (2010): ESTIMATION OF TIMBER ASSORTMENTS USING LOW-DENSITY ALS DATA. U S. B. Wagner W. (Ur.), ISPRS TC VII Symposium – 100 Years ISPRS. 28, str. 59-64. Vienna: IAPRS,.
- Hopkinson, C., Chasmer, L., Sass, G., Creed, I., Sitar, M., Kalbfleisch, W., i Treitz, P. (2005): Vegetation class dependent errors in lidar ground elevation and canopy height estimates in a boreal wetland environment. Canadian Journal of Remote Sensing, 31(2), 191-206.
- IPCC. (2003): Good Practice Guidance for Land Use, Land-Use Change and Forestry. Hayama, Japan: Institute for Global Environmental Strategies (IGES).
- Ivšić, L., Pribičević, B., Đapo, A., Kordić, B., Babić, L., i Govorčin, M. (2016): Klasifikacija LiDAR podataka na području urbanog jezera Jarun i analiza kvalitete podataka. Zagreb: Researchgate. Preuzeto 29.03.2017. iz https://www.researchgate.net/publication/314288146
- Kajba, D., i Andrić, I. (2014): Selection of Willows (Salix sp.) for Biomass Production. South-east Eur for, 5(2), 145-151.
- Kolecka, N., Kozak, J., Kaim, D., Dobosz, M., Ginzler, C., i Psomas, A. (2016): MAPPING SECONDARY FOREST SUCCESSION ON ABANDONED AGRICULTURAL. The XXIII ISPRS Congress. XLI-B8, str. 931-935. Prague: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.
- Kušan V., Mesić H., Zovko M., Kolačko G., Steinberger A., Crnojević Ž., Križnjak D., Berta A., Mihulja A. (2015): Pokrov i korištenje zemljišta u RH- stanje i smjerovi razvoja 2012. Zagreb: Hrvatska Agencija za Okoliš i Prirodu/ Oikon d.o.o.. Dohvaćeno iz http://www.azo.hr/lgs.axd?t=16iid=5696
- Kwak, D.-A., Cui, Cui, G., Lee, W.-K., Hyun-Kook, C., Jeon, S., i Lee, S.-H. (2014): Estimating plot volume using lidar height and intensity distributional parameters. International Journal of Remote Sensing, 35(13), 4601-4629.
- Laes, D., Reutebuch, S., McGaughey, R., i Mitchell, B. (2011): Guidelines to estimate forest inventory parameters from lidar and field plot data. US Forest Service. Preuzeto 06. 02 2017 iz https://www.fs.fed.us/eng/rsac/lidar_training/Forest_Inventory_Modeling/story_content/external_files/sup_doc_guide.pdf

- Lee, A., i Lucas, R. (2007): A LiDAR-derived canopy density model for tree stem and crown. Remote Sensing of Environment, 111, 493-518.
- Leitold, V., Keller, M., Morton, D., Cook, B., i Shimabukuro, Y. (2015): Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. Carbon Balance and Management, 10(3). doi:10.1186/s13021-015-0013-x
- Leonardi, S., Failla, M., Sciacc, G., i Rapp, M. (1999): Above-ground biomass and nutrients in a turkey oak (Quercus cerris L.) stand on Mount Etna. Oecologia, 8, 1-5.
- Maclean, G., i Krabill, W. (1986): Gross merchantable timber volume estimation using an airborne lidar system. Canadian Journal of Remote Sensing, 12, 7-8.
- Mitchell, B., Walterman, M., Mellin, T., Wilcox, C., Lynch, A., Anhold, J., . . . Fisk, H. (2012): Mapping vegetation structure in the Pinaleño Mountains using lidar—phase 3: forest inventory modeling. Salt Lake City, USA: .S. Department of Agriculture, Forest Service, Remote Sensing Applications Center.
- Montagnoli, A., Fusco, S., Terzaghi, M., Kirschbaum, A., Pflugmacher, D., Cohen, W., Chiatante, D. (2015): Estimating forest aboveground biomass by low density lidar data in mixed broad-leaved forests in the Italian Pre-Alps. Forest Ecosystems, 2(10), 1-9.
- Montero, G., Ruiz-Peinado, R., i Muñoz, M. (2005): Producción de Biomasa y Fijación de CO2 Por Los Bosques Españoles. Madrid: Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria.
- Morhart, C., Sheppard, J., Schuler, J., i Spiecker, H. (2016): Above-ground woody biomass allocation and within tree carbon and nutrient distribution of wild cherry (Prunus avium L.) a case study. Forest Ecosystems, 3(4), 1-15.
- Nasset, E. (1997a): Determination of mean tree height of forest stands using airborne laser scanner data. ISPRS Journal of Photogrammetry i Remote Sensing, 52, 49–56.
- Nasset, E. (1997b): Estimating timber volume of forest stands using airborne laser scanner data. Remote Sensing of Environment, 61, 246-253.
- Nasset, E. (2005): Assessing sensor effects and effects of leaf-off and leaf-on canopy conditions on biophysical stand properties derived from small-footprint airborne laser data. Remote Sensing of Environment, 98, 356–370. Remote Sensing of Environment, 98, 356-370.

- Nasset, E., i Bjerknes, K.-O. (2001): Estimating tree heights and number of stems in young forests using airborne laser scanner data. Remote Sensing of Environment, 78(3), 328-340.
- Nasset, E., i Okland, T. (2002): Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. Remote Sensing of Environment, 79(1), 105-115.
- Nasset, E., Gobakken, T., Bollandsås, O. M., Gregoire, T. G., i Ståhl, G. (2013): Comparison of precision of biomass estimates in regionalfield sample surveys andairborne LiDAR-assisted surveys in Hedmark County, Norway. Remote Sensing of Environment, 130, 108-120.
- Popescu, S. (2007): Estimating biomass of individual pine trees using airborne lidar. Biomass and Bioenergy, 31(9), 646-655.
- Popescu, S., Wynne, R., i Nelson, R. (2002): Estimating plot-level tree heights with lidar: local. Computers and Electronics in Agriculture, 37, 71-95.
- Poulain , d., Peña , M., Schmidt , A., Schmidt , H., i Schulte , A. (2012): Aboveground biomass estimationin intervened and non-intervened Nothofagus pumilio forests using remotely sensed data. International Journal of RemoteSensing, 33(12), 3816-3833.
- Pravilnik o uređivanju šuma, Narodne novine 79/15
- Reutebuch, S. E., Andersen,, H.-E., i McGaughey, R. J. (2005): Light Detection and Ranging (LIDAR): An Emerging Tool for Multiple Resource Inventory. J Forest, 103(6), 286-292.
- Saeidi, V., Pradhan, B., Idrees, M., i Abd Latif, Z. (2014): Fusion of airborne LiDAR with multispectral SPOT 5 image for enhancement of feature extraction using dempster-shafer theory. IEEE Transactions on Geoscience and Remote Sensing, 52(10), 6017-6025.
- Seletković, A., Perić, M., i Balenović, I. (2016): Fotogrametrijska procjena srednjih sastojinskih visina odvojeno po vrstama drveća u mješovitim sastojinama središnje Hrvatske. Nova meh. šumar, 37, 15-23.
- Shendryk , S., Hellström , M., Klemedtsson , L., i Kljun , N. (2014): Low-Density LiDARand Optical Imagery for Biomass Estimation over Boreal Forest in Sweden. Forests, 5, 992-1010.

- Singh, K., Chen, G., McCarter, J., i Meentemeyer, R. (2015): Effects of LiDAR point density and landscape context on estimates of urban forest biomass. ISPRS Journal of Photogrammetry and Remote Sensing, 101, 310-322.
- Stankić, I., Marenče, J., Vusić, D., Zečić, Ž., i Benković, Z. (2014): STRUKTURA NADZEMNE DRVNE BIOMASE OBIČNE BUKVE U RAZLIČITIM SASTOJINSKIM UVJETIMA. Šumarski list, 9-10, 439–450.
- Stojsavljević D., Horvat D., Gojak S., Šćulac T., Grubišić I., Pavlačić K., Borić D., Prebeg M., Grgurić Z., Križan J., (2012): Program gospodarenja za gospodarsku jedinicu "Sava Zagreb" (2012-2021), Oikon d.o.o.
- Straub, D., i Koch, B. (2011): Enhancement of bioenergy estimations within forests usingairborne laser scanning and multispectral line scanner data. Biomass and Bioenergy, 35, 3561-3574.
- Suchomel, C., Pyttel, P., Becker, G., i Bauhus, J. (2012): Biomass equations for sessile oak (Quercus petraea (Matt.) Liebl.) and hornbeam (Carpinus betulus L.) in aged coppiced forests in southwest Germany. BIOMASS AND ENERGY, 46, 722-730.
- Sumerling, G. (2010): Lidar Analysis in ArcGIS 9.3.1 for Forestry Applications. Esri White Paper
- Šorgić B., Haramina T., Botinčan B., Kušan V., Štefanić M., Mihulja A., Berta A., Šćulac T., Antunović B., Gojak S., Peternel H., Desnica S., Klaić-Jančijev D., Koren Ž., Špirić Z., Rapić S. (2015): Program zaštite okoliša Grada Zagreba, Oikon d.o.o.
- Tonolli, S., Dalponte, M., Neteler, M., Mirco, R., Vescovo, L., i Gianelle, D. (2011): Fusion of airborne LiDAR and satellite multispectral data for the estimation of timber volume in the Southern Alps. Remote Sensing of Environment, 115, 2468-2498.
- Topić, V., Antonić, O., Španjol, Ž., i Vrdoljak, Ž. (2000): REGRESSION MODELS FOR ESTIMATING BIOMASS OF RESPROUTED PUBESCENT OAK (QUERCUS PUBESCENS WILLD.), ITALIAN OAK (QUERCUS FRAINETTO TEN.) AND HOLM OAK (QUERCUS ILEX L.). Glas. sum. pokuse, 37, 123-131.
- Topić, V., Butorac, L., Jelić, G., Perić, S., i Rosavec, R. (2008): Biomass of hop hornbeam (Ostrya carpinifolia Scop.) shrub on Velebit. PERIODICUM BIOLOGORUM, 110(2), 151–156.
- Usoltsev, V. (2016): ФИТОМАССА МОДЕЛЬНЫХ ДЕРЕВЬЕВ ЛЕСООБРАЗУЮЩИХ ПОРОД ЕВРАЗИИ: БАЗА ДАННЫХ, КЛИМАТИЧЕСКИ ОБУСЛОВЛЕННАЯ ГЕОГРАФИЯ, ТАКСАЦИОННЫЕ

НОРМАТИВЫ (SINGLE-TREE BIOMASS OF FOREST-FORMING SPECIES IN EURASIA: DATABASE, CLIMATE RELATED). YEKATERINBURG: MINISTRY OF EDUCATION AND SCIENCE OF RUSSIAN FEDERATION/RUSSIAN ACADEMY OF SCIENCES.

- Usoltsev, V., Chasovskikh, V., Noritsina, Y., i Noritsin, D. (2016): АЛЛОМЕТРИЧЕСКИЕ МОДЕЛИ ФИТОМАССЫ ДЕРЕВЬЕВ ДЛЯ ЛАЗЕРНОГО ЗОНДИРОВАНИЯ И НАЗЕМНОЙ ТАКСАЦИИ УГЛЕРОДНОГО ПУЛА ЛЕСАХ В ЕВРАЗИИ: СРАВНИТЕЛЬНЫЙ АНАЛИЗ. Siberian Journal of Forest Science, 4, 68-76.
- White, J., Arnett, J., Wulder, M., Tompalski, P., i Coops, N. (2015): Evaluating the impact of leaf-on and leaf-off airborne laser scanning data on the estimation of forest inventory attributes with the area-based approach. Can. J. For. Res., 45(11), 1498-1513.
- White, J., Wulder, M., Varhola, A., Vastaranta, M., Coops, N., Cook, B., Woods, M. (2013): A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach (Version 2.0) (INFORMATION REPORT FI-X-010 izd.). Ontario, Canada: CANADIAN FOREST SERVICE/CANADIAN WOOD FIBRE CENTRE.
- Woodget, A., Donoghue, D., i Carbonneau, P. (2007): An assessment of airborne lidar for forest growth studies. Ekscentar, 10, 47-52.
- Wu, Z., Dye, D., Stoker, J., Vogel, J., Middleton, i Middleton, B. (2016): Evaluating Lidar Point Densities for Effective Estimation of Aboveground Biomass. International Journal of Advanced Remote Sensing and GIS, 5(1), 1483-1499.
- Yu, X. (2007): Methods and techniques for forest change detection and growth estimation using airborne laser scanning data. Disertacija. Helsinki University of Technology.
- Yu, X., Hyyppä, J., Holopainen, M., i Mikko, V. (2010): Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes. Remote Sens, 2, 1481-1495.
- Zakon o poljoprivednom zemljištu, Narodne novine 39/13 i 48/15
- Zhao, K., Popescu, S., i Nelson, R. (2009): Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. Remote Sensing of Environment , 113, 182-196.

- Žmegač, A. (2015): Upotreba laserskog skenera (LIDAR) u istraživanju dinamike bukovo - jelove prašume Čorkova uvala- Čudinka. Zagreb: Šumarski Fakultet. Preuzeto 05. 01 2017 iz https://urn.nsk.hr/urn:nbn:hr:108:763759

ŽIVOTOPIS

Alen Berta, rođen 06.11.1982. u Novom Sadu, kao drugo i posljednje dijete Oskara, potomka mađarske obitelji doseljene u vojvođansko selo Maradik iz Debrecena, Mađarska početkom 19. stoljeća, te Đurđice Karatur rođene i odrasle u okolici Hrvatske Kostajnice, Hrvatska. Do svoje 14. godine je živio u Maradiku, multinacionalnom te i za vojvođanske pojmove velikom selu, nakon čega je, uslijed etničke netrpeljivosti, primoran preseliti se u skoro oslobođenu Hrvatsku Kostajnicu, u jesen 1996. godine.

Tamo se školuje za šumarskog tehničara i u jesen 2001. upisuje Šumarski fakultet. Apsolventsku godinu upisuje kao redovan student s tri ispita, nakon čega radi raznih studentskih poslova na godinu dana zanemaruje školovanje. Obranivši temu diplomskog rada pod nazivom „*Intenzitet zaraze stabala pitomog kestena (Castanea sativa Mill.) gljivom Cryphonectria parasitica (Murr.) Barr. na području Šumarije Hrvatska Kostajnica*“ u proljeće 2007. godine, vrlo brzo se zapošljava u Oikon d.o.o., Institutu za primijenjenu ekologiju na poslovima uređivanja privatnih šuma.

Stjecanjem uvjeta za stručna ovlaštenja od 2010. do 2012. godine stječe ovlaštenja za uređivanje šuma; opće šumarstvo te za šumske komunikacije. U isto vrijeme radeći na raznim projektima ekološke tematike ali i operativnog šumarstva, stječe i opsežna znanja i iz tih područja uz svakodnevno korištenje GIS-a i daljinskih istraživanja za brže, bolje i preciznije obavljanje zadataka.

2013. godine počinje njegov znanstveni interes za, novu i skoro nekorištenu u hrvatskom šumarstvu, LIDAR tehnologiju te upisom doktorskog studija na Šumarskom fakultetu u jesen 2013. godine, počinje ostvarivati svoj cilj da podrobnije istraži mogućnosti LIDAR tehnologije u šumarstvu.

2014. godine prisustvuje SPLIT Remote Sensing Summer School gdje je upoznao mogućnosti te tehnologije iz „prve ruke“ te je obučen za rad u programu LAStools od strane dr. Martina Isenburga, kreatora tog programa.

I tako nakon gotovo 10 godina stručnog i znanstvenog rada odnosno:

- sudjelovanja u izradi 47 Programa gospodarenja šumama šumoposjednika (za 25 Programa kao voditelj izrade);
- sudjelovanja u preko 80 raznih studija na okoliš, strateških procjena utjecaja na okoliš, programa zaštite okoliša, projekata revitalizacije staništa, programa upravljanja zaštićenim područjima, itd. obrađujući poglavlja šume, šumarstvo, lovstvo i korištenje zemljišta;

- jednotjednoj obuci za obradu i analizu LIDAR podataka te dvotjednom školovanju u ESA (European Space Agency) za obradu i analizu satelitskih snimki;
- sudjelovanja (i vođenja) u više projekata prikupljanja i obrade terenskih podataka i podataka dobivenih daljinskim istraživanja o šumskim ekosustavima, šumskoj biomasi i procjeni veličine rezervoara ugljika na regionalnoj i nacionalnoj razini;
- aktivnom sudjelovanju na desetak domaćih i stranih konferencija;

u proljeće 2017. godine završava ovu doktorsku disertaciju…

Oženjen je, otac jednog djeteta (Javora).

Popis publikacija i prezentacija

- **Alen Berta**, Vladimir Kušan, Josip Križan, Dalibor Hatić, Denis Stojsavljević (2017); **Posjedovne i površinske značajke šuma šumoposjednika u Hrvatskoj prema regijama**, Šumarski list, 1–2 (2017): 57–65

- **Alen Berta**, Vladimir Kušan, Zrinka Mesić, Denis Stojsavljević, Dalibor Hatić (2016): **Use of high resolution multispectral satellite images in determining the degree of productivity and age of uneven-aged stands of private forest owners in the Mediterranean and Submediterranean**, ESA EO Summer School, (Poster presentation, October 2016, Rome)

- **Alen Berta**, Vladimir Kušan, Denis Stojsavljević, Dalibor Hatić (2016): **VARIABILITY OF THE BASIC POSSESSION PARAMETERS IN PRIVATELY-OWNED FORESTS IN CROATIA** //GREEN2016, Conference proceedings, Zagreb, 2016, p.3-8

- **Alen Berta**, Vladimir Kušan, Višnja Šteko (2015): **Evaluation of vegetation as a landscape component: Case study Veli Brijun island**, Druga regionalna konferencija o procjeni utjecaja na okoliš (Usmeno izlaganje, rujan 2015, Novi Vinodolski)

- Nikolina Bakšić, **Alen Berta,** Višnja Šteko (2015): **Procjena rizika od pojave klizišta primjenom GIS-a: brza cesta Varaždin-Krapina**, 5. Hrvatski geološki kongres (Usmeno izlaganje, 22.-25.09.2015, Osijek)

- Škunca Marina, Mesić Zrinka, Šteko Višnja, **Berta Alen**, Peternel Hrvoje (2015): **AREA EVALUATION FROM THE ASPECT OF BIODIVERSITY: Method**

designed for overcoming data gaps, 6th Balkan Botanical Congress, (Usmeno izlaganje, September 14 – 18 2015., Rijeka)

- **Alen Berta**, Vladimir Kušan, Roman Danko, Dalibor Hatić, Oleg Antonić (2014): **Correlation of forest ecosystem management and carbon sequestration**, Natural resources, green technology and sustainable development (poster prezentacija, 26th-28th November 2014, Zagreb)

- Vladimir Kušan, **Alen Berta**, Denis Stojsavljević (2014): **Izrada planova gospodarenja za privatne šume i zaštita prirode**, 2. REGIONALNA KONFERENCIJA ŠUMOPOSJEDNIKA JIE (Usmeno izlaganje, 27.8.2014., Zagreb)

- **Alen Berta**, Vladimir Kušan, Roman Danko, Dalibor Hatić, Oleg Antonić (2014): **Methods for forest carbon pool measurement**, Natural resources, green technology and sustainable development (poster prezentacija, 26th-28th November 2014, Zagreb)

- **Alen Berta,** Vladimir Kušan, Roman Danko, Dalibor Hatić, Oleg Antonić (2013**): Bilanca ugljika za vjetroelektranu u šumi; primjer VE Fužine;** Prva regionalna konferencija o procjeni utjecaja na okoliš (Usmeno izlaganje, 18. -21. Rujan 2013, Zadar)

- Vujević, Dinko; Birov, Tena; Rapić, Sunčana; **Berta, Alen**; Rajković, Damir; Koren, Željko (2011) **COST-BENEFIT ANALYSIS IN EXPLOITATION OF STONE** // SEM2011, Conference Proceedings / Zagreb : Faculty of Chemical Engineering and Technology, 2011. Str. 313-319

- Špirić Z., Kušan V., Gojak S., Mrvoš D., Prebeg M., Mihulja A., Grgurić Z., **Berta A**., Klinčić M., Mesić Z. (2011): **Moss survey 2010 in Croatia**, 24 ICP Vegetation Annual Meeting, Book of abstracts, (Rapperswil-Jona, Switzerland, 31st January - 2nd February 2011)