

УНИВЕРЗИТЕТ У БЕОГРАДУ  
ГРАЂЕВИНСКИ ФАКУЛТЕТ



НЕНАД Д. БРОДИЋ

**СЕМАНТИЧКА СЕГМЕНТАЦИЈА ОБЛАКА  
ТАЧАКА ДОБИЈЕНОГ ЛАСЕРСКИМ  
СКЕНИРАЊЕМ ИЗ ВАЗДУХА КОРИШЋЕЊЕМ  
МЕТОДА МАШИНСКОГ УЧЕЊА**

докторска дисертација

БЕОГРАД 2023.



**UNIVERSITY OF BELGRADE  
FACULTY OF CIVIL ENGINEERING**



**NENAD D. BRODIĆ**

**SEMANTIC SEGMENTATION OF AIRBORNE  
LASER SCANNING POINT CLOUDS USING  
MACHINE LEARNING METHODS**

doctoral dissertation

BELGRADE 2023



## ПОДАЦИ О МЕНТОРУ И ЧЛАНОВИМА КОМИСИЈЕ

**Ментор:** др Жељко Цвијетиновић, дипл. инж. геод., ванредни професор,  
Универзитет у Београду, Грађевински факултет

**Комисија:** др Жељко Цвијетиновић, дипл. инж. геод., ванредни професор,  
Универзитет у Београду, Грађевински факултет

др Драган Михајловић, дипл. инж. геод., ванредни професор у  
пензији, Универзитет у Београду, Грађевински факултет

др Милева Самарцић–Петровић, дипл. инж. геод., ванредни  
професор, Универзитет у Београду, Грађевински факултет

др Драган Борота, дипл. инж. шум., доцент,  
Универзитет у Београду, Шумарски факултет

др Милутин Миленковић, дипл. инж. геод., истраживач,  
*International Institute for Applied Systems Analysis – IIASA*

Датум одбране докторске дисертације: \_\_\_\_\_



*Нини и Давиду.*





# ЗАХВАЛНИЦА

Као прво, желео бих да се захвалим професорима др Жељку Цвијетиновићу и др Драгану Михајловићу на великој помоћи, стрпљењу и разумевању које су имали током израде ове докторске дисертације, као и знању и мотивацији које су ми пренели током мог студирања и професионалног усавршавања.

Захвалан сам свим члановима комисије на корисним коментарима и препорукама за унапређење квалитета ове докторске дисертације. Посебну захвалност дугујем др Милутину Миленковићу за конструктивне идеје, корисне савете и велику помоћ током мог истраживања. Препоруке које сам добио од др Милеве Самарцић–Петровић су ми пуно помогле приликом истраживања и доношења кључних закључака након извршених експеримената. Колеги др Јовану Ковачевићу дугујем захвалност за помоћ при писању кода и сугестије за оптимизацију везане за експериментални део докторске дисертације. Колеги Николи Станчићу сам захвалан за помоћ и корисне савете пружене приликом писања истраживачког рада и докторске дисертације. Захваљујем се и Момиру Митровићу и фирми MapСофт за уступање и припрему података који су коришћени у једној фази истраживања.

Колегама са Катедре и Института за геодезију и геоинформатику захваљујем што су преузимали моје обавезе када је било неопходно и тиме олакшали писање ове дисертације.

На крају, највећу захвалност дугујем својој породици, мојој деци Нини и Давиду, којима посвећујем ову дисертацију, супрузи Ени, оцу, мајци и браћи што су имали разумевања и стрпљења приликом мог истраживања и рада, као и на љубави и подршци коју су ми несебично пружали.

*Ненад Бродић*



# САЖЕТАК

## СЕМАНТИЧКА СЕГМЕНТАЦИЈА ОБЛАКА ТАЧАКА ДОБИЈЕНОГ ЛАСЕРСКИМ СКЕНИРАЊЕМ ИЗ ВАЗДУХА КОРИШЋЕЊЕМ МЕТОДА МАШИНСКОГ УЧЕЊА

Технологија ласерског скенирања (енгл. *Light Detection and Ranging – LiDAR*) показала се као веома успешна за брзо прикупљање масовне количине просторних података о топографији физичке површи Земље. Семантичка сегментација облака тачака добијеног ласерским скенирањем из ваздуха (енгл. *Airborne Laser Scanning – ALS*) која се такође назива и класификација облака тачака, семантичко означавање као и семантичка класификација облака тачака, представља велики изазов због структуре облака тачака и типова класа које се могу идентификовати у том простору. Машинско учење, са друге стране, представља моћан математички апарат који се може искористити за различите примене укључујући и наведену процедуру. У овој дисертацији су анализирани методе машинског учења којим се добијају најбољи резултати семантичке сегментације облака тачака, поготово са сложеним ансамбл моделима машинског учења конструисаним слагањем више основних модела машинског учења. У овом истраживању је вршено и балансирање скупа података синтетичким генерисањем тачака које припадају мањинским класама док су тачке које припадају већинским класама знатно редуковане. Вршене су анализа типа претраге тачака суседства и анализа утицаја величине полупречника претраге, а испитана је и могућност вишеразног (енгл. *multiscale*) приступа претраге у циљу генерисања геометријских атрибута (карактеристика) тачака. Одређен је велики број различитих атрибута тачака и извршена селекција оних најзначајнијих за семантичку сегментацију облака тачака. Извођена је семантичка сегментација облака тачака коришћењем десет различитих метода машинског учења. Највиша укупна тачност (енгл. *Overall Accuracy – OA*) семантичке сегментације облака тачака добијеног ласерским скенирањем из ваздуха била је 83.5% за методу потпорних вектора (енгл. *Support Vector Machine*) примењену на *ISPRS* тест податке, док је над *GRSS* тест подацима ласерског скенирања постигнута укупна тачност од 93.6% када се користи сложени ансамбл модел базиран на наивном Бајесу (енгл. *Naive Bayes*) и слагању модела: случајне шуме (енгл. *Random Forest*), градијентног појачавања (енгл. *Gradient Boosting*) и логистичке регресије (енгл. *Logistic Regression*).

У неким применама, сегментација облака тачака добијеног ласерским скенирањем из ваздуха подразумева и издвајање објеката од интереса (крова зграде, крошње дрвета и слично). У оквиру овог истраживања обрађена је сегментација облака тачака пошумљеног подручја добијеног ласерским скенирањем са циљем детекције појединачних стабала. Наведени приступ подразумева филтрирање локалних максимума и сегментацију појединачних крошњи стабала на основу висинског модела крошњи стабала. Претходни поступак је битан за генерисање различитих типова атрибута на нивоу сегмената крошњи стабала које се користе за каснију класификацију кандидата врхова стабала у исправно и погрешно детектоване. Истраживање је спроведено за подручје мешовите шуме, претежно лишћарске,

сложене топографије и димензија  $0.6 \text{ km} \times 4 \text{ km}$ . Испитиване су перформансе класификације за пет метода машинског учења: случајне шуме, екстремно градијентно појачавање (енгл. *Extreme Gradient Boosting*), вештачке неуронске мреже (енгл. *Artificial Neural Network*), методе потпорних вектора и методе логистичке регресије. Овде је такође вршено балансирање класа скупа података у циљу постизања бољих перформанси у виду тачности класификације. Коначна класификација је извршена са моделом случајне шуме са којим се добијају најбоље перформансе у погледу тачности класификације. Укупна тачност ( $OA$ ) и капа коефицијент слагања ( $\kappa$ ) добијени десетоструком унакрсном валидацијом над тренинг подацима износили су 90.4% и 0.808. Применом истренираног модела на независном скупу података добијено је да је  $OA = 89.0\%$  и  $\kappa = 0.757$ .

На крају дисертације дате су смернице за даље истраживање и развој.

**Кључне речи:** семантичка сегментација облака тачака, машинско учење, детекција појединачних стабала, ласерско скенирање из ваздуха

**Научна област:** Геодезија

**Уже научне области:** Фотограмetriја и даљинска детекција, Земљишни информациони системи

# ABSTRACT

## SEMANTIC SEGMENTATION OF AIRBORNE LASER SCANNING POINT CLOUDS USING MACHINE LEARNING METHODS

*Light Detection and Ranging – LiDAR* technology has proven to be very successful for rapid collection of massive amounts of spatial data on the topography of the Earth's physical surface. Semantic segmentation of an Airborne Laser Scanning (*ALS*) point cloud, also called point cloud classification or semantic labeling as well as semantic point cloud classification is a major challenge due to the structure of the point cloud, as well as the types of classes that can be identified in that space. Machine learning (*ML*), on the other hand, represents a powerful mathematical tool that can be used for a variety of applications, including mentioned procedure. In this dissertation, *ML* methods are analyzed in the terms of achieving the best results for semantic segmentation of point cloud, especially with stacked ensemble *ML* models constructed by combining several fundamental *ML* methods. The *ALS* dataset was also balanced in such a way that points belonging to minority classes are synthetically generated while points belonging to the major classes are highly reduced. An analysis of the search type of neighborhood points and the sizes of the search radius were performed, and the possibility of using a multi-scale search approach in order to generate the geometric characteristics of the points. A large number of different features (attributes) of the points was determined and the selection of the features that are most significant for the semantic segmentation of the point cloud was carried out. Semantic segmentation of *ALS* point clouds was performed by using ten different *ML* methods. The highest overall accuracy of the semantic segmentation of the *ALS* point cloud was 83.5% for the support vector machine method predicted on the *ISPRS* test data, while the overall accuracy of 93.6% was achieved on the *GRSS* test *ALS* data when using the stacked ensemble model of naive Bayesian stacking of several *ML* models (Random Forest, Gradient Boosting and Logistic Regression).

In some applications, segmentation also implies extraction of the objects of interest (the building roof, the tree crown, etc.). Within this research, the segmentation of the *ALS* point cloud of a forested area was analyzed with the aim of Individual Tree Detection (*ITD*). The mentioned approach involves Local Maxima (*LM*) filtering and segmentation of individual tree canopies by using the Canopy Height Model (*CHM*). Previous procedure is important for generation of different segment-level type of features that are used for later classification of treetops into correctly and incorrectly detected ones. The study was conducted for a mixed temperate forest, predominantly deciduous, with complex topography and area size of 0.6 km × 4 km. Classification model training was performed by five machine learning approaches: Random Forest (*RF*), Extreme Gradient Boosting (*XGB*), Artificial Neural Network (*ANN*), Support Vector Machine (*SVM*) and Logistic Regression (*LR*). Here, the classes of the dataset were also balanced in order to achieve better performance in the terms of classification accuracy. The final classification was performed with the random forest model, which gives the best performance in terms of classification accuracy. The Overall Accuracy (*OA*) and the kappa coefficient of agreement ( $\kappa$ ) obtained from ten-fold cross validation for the training data were 90.4%

and 0.808, respectively. The application of the trained model on the independent set of data, resulted in  $OA = 89.0\%$  and  $\kappa = 0.757$ .

At the end of the dissertation, guidelines for further research and development are given.

**Keywords:** Semantic Segmentation of Point Clouds, Machine Learning, Individual Tree Detection, Airborne Laser Scanning

**Scientific field:** Geodesy

**Scientific subfields:** Photogrammetry and Remote Sensing, Land Information Systems

# ЛИСТА СКРАЋЕНИЦА

*ALS* – Airborne Laser Scanning

*LiDAR* – Light Detection and Ranging

*FW* – Full Waveform

*ML* – Machine Learning

*LR* – Logistic Regression

*SVM* – Support Vector Machine

*ANN* – Artificial Neural Networks

*DT* – Decision Tree

*RF* – Random Forest

*ERT* – Extremely Randomized Trees

*GB* – Gradient Boosting

*XGB* – eXtreme Gradient Boosting

*NB* – Naïve Bayes

*CRF* – Conditional Random Fields

*kNN* – k-Nearest Neighbors

*LDA* – Linear Discriminant Analysis

*OA* – Overall Accuracy

*IoU* – Intersection over Union

*CHM* – Canopy Height Model

*ITD* – Individual Tree Detection

*LM* – Local Maxima

*GA* – Genetic Algorithms

*RFE* – Recursive Feature Elimination

*VIM* – Variable Importance Measure

*MDG* – Mean Decrease Gini

*MDA* – Mean Decrease Accuracy

*SMOTE* – Synthetic Majority Oversampling Technique

*ISPRS* – International Society for Photogrammetry and Remote Sensing

*GRSS* – Geoscience and Remote Sensing Society

*NEWFOR* – NEW technologies for a better mountain FORest timber mobilization

*TIN* – Triangulated Irregular Network

*UAV* – Unmanned Aerial Vehicle

*ULS* – UAV Laser Scanning





# САДРЖАЈ

<b>ЗАХВАЛНИЦА</b> .....	<b>V</b>
<b>САЖЕТАК</b> .....	<b>VII</b>
<b>АВСТРАСТ</b> .....	<b>IX</b>
<b>ЛИСТА СКРАЋЕНИЦА</b> .....	<b>XI</b>
<b>САДРЖАЈ</b> .....	<b>XIII</b>
<b>СПИСАК СЛИКА</b> .....	<b>XVII</b>
<b>СПИСАК ТАБЕЛА</b> .....	<b>XXII</b>
<b>1 УВОД</b> .....	<b>1</b>
1.1 Предмет научног истраживања .....	3
1.2 Циљеви истраживања .....	5
1.3 Приступ .....	6
1.4 Кратак преглед .....	7
<b>2 ПРЕГЛЕД И АНАЛИЗА ДОСАДАШЊИХ ИСТРАЖИВАЊА</b> .....	<b>8</b>
2.1 Семантичка сегментација облака тачака .....	8
2.1.1 Семантичка сегментација облака тачака коришћењем традиционалних метода машинског учења .....	9
2.2 Детекција појединачних стабала и делинеација крошњи стабала коришћењем података ласерског скенирања .....	11
<b>3 ТЕОРИЈСКЕ ОСНОВЕ</b> .....	<b>15</b>
3.1 Методе машинског учења .....	15
3.1.1 Вештачке неуронске мреже .....	15
3.1.2 Метода потпорних вектора .....	16
3.1.3 Логистичка регресија .....	17
3.1.4 Наивни Бајесов класификатор .....	18
3.1.5 Стабло одлучивања .....	18
3.1.6 Ансамбл методе машинског учења .....	19
3.1.6.1 Случајна шума и екстремно насумична стабла .....	20
3.1.6.2 Градијентно појачавање и екстремно појачавање градијента .....	21
3.1.6.3 Слагање модела .....	21

3.1.7 Аутоматске методе машинског учења .....	23
3.2 Методологија семантичке сегментације облака тачака .....	23
3.2.1 Дефинисање суседства.....	24
3.2.2 Екстракција атрибута за семантичку сегментацију .....	26
3.2.3 Методе селекције атрибута .....	27
3.2.3.1 Селекција атрибута коришћењем генетских алгоритама.....	29
3.2.3.2 Рекурзивна елиминација атрибута .....	30
3.2.4 Узорковање тренинг података .....	31
3.2.5 Просторна регуларизација резултата семантичке сегментације .....	31
3.2.6 Коришћене методе машинског учења .....	32
3.3 Методологија за побољшање резултата детекције појединачних стабала .....	33
3.3.1 Генерисање <i>CHM</i> -а, <i>ITD</i> и сегментација крошњи стабала .....	34
3.3.2 Екстракција атрибута за детекцију врхова стабала .....	34
3.3.2.1 Атрибути облика сегмента.....	34
3.3.2.2 Метрике дрвећа .....	35
3.3.2.3 Атрибути базирани на сопственим вредностима.....	36
3.3.2.4 Атрибути уклапања облика.....	37
3.3.3 Балансирање класа скупа података .....	37
3.3.4 Означавање класа врхова стабала.....	38
3.4 Оцена тачности класификације .....	38
3.4.1 Унакрсна валидација.....	39
3.4.2 Квантитативне мере перформанси модела .....	40
<b>4 РАСПОЛОЖИВИ СКУПОВИ ПОДАТАКА ЛАСЕРСКОГ СКЕНИРАЊА .....</b>	<b>43</b>
4.1 <i>ISPRS</i> скуп података за семантичку сегментацију облака тачака.....	43
4.2 <i>GRSS</i> скуп података ласерског скенирања .....	45
4.3 <i>DublinCity</i> : Класификован облак тачака.....	47
4.4 <i>H3D</i> скуп података за семантичку сегментацију облака тачака високе резолуције .....	48
4.5 <i>NEWFOR</i> референтни подаци за детекцију појединачних стабала .....	49
4.6 Подаци ласерског скенирања из ваздуха коришћени за индивидуалну детекцију стабала .....	51
4.6.1 Подручје истраживања .....	52
4.6.2 Шумске парцеле .....	53

4.6.3	Подаци ласерског скенирања .....	53
4.6.4	Референтни подаци стабала .....	54
<b>5</b>	<b>ЕКСПЕРИМЕНТАЛНИ ДЕО .....</b>	<b>55</b>
5.1	Експеримент 1: Екстракција атрибута тачака .....	56
5.2	Експеримент 2: Семантичка сегментација <i>ISPRS</i> облака тачака .....	57
5.2.1	Одређивање хиперпараметара модела машинског учења .....	61
5.2.2	Важност атрибута .....	63
5.2.3	Селекција најважнијих атрибута .....	65
5.2.4	Резултати семантичке сегментације за комбинацију $D_2R_{1.5}$ .....	70
5.2.5	Резултати семантичке сегментације за комбинацију $D_2R_3$ .....	77
5.2.6	Резултати семантичке сегментације за вишеразмерну комбинацију .....	84
5.2.7	Упоредна анализа резултата семантичке сегментације <i>ISPRS</i> података коришћењем различитих комбинација атрибута .....	91
5.3	Експеримент 3: Семантичка сегментација <i>ISPRS</i> облака тачака са узоркованим тренинг подацима и вишеразмерном комбинацијом атрибута .....	94
5.3.1	Узорковање тренинг података вишеразмерне комбинације атрибута .....	95
5.3.2	Резултати семантичке сегментације узоркованих тренинг података вишеразмерне комбинације атрибута .....	96
5.4	Експеримент 4: Семантичка сегментација <i>GRSS</i> облака тачака .....	100
5.4.1	Примена модела истренираног са <i>GRSS</i> подацима на <i>ISPRS</i> тест податке .....	106
5.5	Експеримент 5: Побољшање резултата детекције појединачних стабала .....	107
5.5.1	Припрема података за класификацију врхова стабала .....	107
5.5.2	Балансирање и селекција најважнијих атрибута .....	108
5.5.3	Важност атрибута .....	110
5.5.4	Одређивање хиперпараметара модела машинског учења .....	111
5.5.5	Селекција метода машинског учења .....	114
5.5.6	Резултати класификације .....	115
<b>6</b>	<b>ДИСКУСИЈА .....</b>	<b>116</b>
6.1	Експеримент 1: Екстракција атрибута тачака .....	116
6.2	Експеримент 2: Семантичка сегментација <i>ISPRS</i> облака тачака .....	117

6.3	Експеримент 3: Семантичка сегментација <i>ISPRS</i> облака тачака са узоркованим тренинг подацима и вишеразмерном комбинацијом атрибута .....	123
6.4	Експеримент 4: Семантичка сегментација <i>GRSS</i> облака тачака .....	124
6.5	Експеримент 5: Побољшање резултата детекције појединачних стабала .....	126
6.5.1	Значај побољшања резултата детекције појединачних стабала у односу на већ устаљене методе.....	126
6.5.2	Селекција метода машинског учења .....	127
6.5.3	Резултати класификације.....	127
6.5.3.1	Резултати класификације у зависности од типа шуме .....	129
6.5.4	Важност атрибута.....	129
<b>7</b>	<b>ЗАКЉУЧНА РАЗМАТРАЊА.....</b>	<b>131</b>
7.1	Преглед извршених истраживања и добијених резултата .....	131
7.2	Смернице за даља истраживања.....	137
<b>8</b>	<b>ЛИТЕРАТУРА .....</b>	<b>139</b>
<b>9</b>	<b>ПРИЛОЗИ.....</b>	<b>156</b>
	Прилог 1: Резултати семантичке сегментације <i>ISPRS</i> података .....	156
	Прилог 2: Резултати семантичке сегментације <i>ISPRS</i> података за $D_2R_{1.5}$ комбинацију атрибута.....	166
	Прилог 3: Резултати семантичке сегментације <i>ISPRS</i> података за $D_2R_3$ комбинацију атрибута.....	170
	Прилог 4: Резултати семантичке сегментације <i>ISPRS</i> података за вишеразмерну комбинацију атрибута .....	174
	Прилог 5: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и $F1$ скорa ( $F1$ ) за све комбинације атрибута по класама за <i>ISPRS</i> податке .....	180
	Прилог 6: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и $F1$ скорa ( $F1$ ) за $D_2R_{1.5}$ , $D_2R_3$ и вишеразмерну комбинацију кад су коришћени сви атрибути и рекурзивна елиминација атрибута, са и без балансирања <i>ISPRS</i> података према класама.....	182
	Прилог 7: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и $F1$ скорa ( $F1$ ) <i>ISPRS</i> узоркованих података када је коришћена рекурзивна елиминација атрибута, са и без балансирања података према класама .....	185
	Прилог 8: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и $F1$ скорa ( $F1$ ) када је коришћена рекурзивна елиминација атрибута, са и без балансирања <i>GRSS</i> података према класама .....	186

# СПИСАК СЛИКА

Слика 3.1: Пример неуронске мреже са једним скривеним слојем. ....	16
Слика 3.2: Општи изглед стабла одлучивања. ....	19
Слика 3.3: Пример сложеног ансамбл модела насталог слагањем појединачних модела. ....	22
Слика 3.4: Методологија семантичке сегментације облака тачака. ....	24
Слика 3.5: Начини претраге суседства: а) лево, сфера претраге, б) десно, цилиндар претраге. ....	25
Слика 3.6: Принцип рада омотач–метода. ....	28
Слика 3.7: Илустрација комбинација атрибута као хромозома генетског алгоритма. ....	29
Слика 3.8: Принцип рада генетског алгоритма за селекцију подскупа атрибута. ..	30
Слика 3.9: Методолошки оквир побољшања резултата детекције појединачних стабала. ....	33
Слика 3.10: Пример одређивања хиперпараметара методе машинског учења коришћењем петоструке унакрсне валидације над тренинг подацима. Тест подаци служе за финалну евалуацију. ....	40
Слика 3.11: Матрица конфузије за три класе са ознакама броја исправних и погрешних погодака за класу А. ....	40
Слика 4.1: Тренинг (лево) и тест (десно) <i>ISPRS</i> скуп података са колоризованим класама тачака. ....	45
Слика 4.2: Део класификованог <i>GRSS</i> облака тачака за подручје Цексонвила. ....	46
Слика 4.3: Приказ <i>DublinCity</i> класификованог облака тачака. Слика је модификована верзија Сликe 2 преузете од <i>Zolanvari</i> и др., 2019. ....	47
Слика 4.4: Хијерархија класа за <i>DublinCity</i> податке. Слика је модификована верзија Сликe 1 преузете од <i>Zolanvari</i> и др., 2019. ....	48
Слика 4.5: <i>H3D</i> класификован облак тачака за епоху из марта 2018. године. Слика је модификована верзија Сликe 3 преузете са <i>H3D</i> веб-странице. ....	49
Слика 4.6: Подручја истраживања где су прикупљени подаци ласерског скенирања из ваздуха са приказом земаља које припадају Алпском простору. Слика је модификована верзија Сликe 2 преузете из извештаја о референтном скупу података за детекцију појединачних стабала. ....	50
Слика 4.7: Пример подручја истраживања, слика лево – поглед одозго, слика десно – поглед из профила где су тачке терена приказане љубичастом бојом, а тачке вегетације зеленом бојом. ....	51
Слика 4.8: Подручје истраживања са приказаним шумским парцелама и ортофото позадином. ....	52

Слика 4.9: Врхови референтних стабала обојени црвено у вертикалном профилу шумске парцеле. ....	54
Слика 5.1: Најбољи резултати семантичке сегментације ( <i>SVM</i> са вишеразмерном комбинацијом –лево под а) и најлошији ( <i>RF</i> са $D_2R_2$ комбинацијом – десно под б) над <i>ISPRS</i> тест подацима. ....	60
Слика 5.2: Одређивање хиперпараметара избором начина раздвајања ( <i>gini</i> или <i>extratrees</i> ) и броја атрибута за раздвајање приликом тренирања <i>RF</i> модела. ....	61
Слика 5.3: Оптимизација хиперпараметара методе случајне шуме са варирањем броја стабала одлучивања и атрибута за раздвајање приликом тренирања <i>RF</i> модела. ....	62
Слика 5.4: Оптимизација хиперпараметара опадања тежина и броја јединица у скривеном слоју вештачке неуронске мреже. ....	63
Слика 5.5: Важност атрибута код <i>RF</i> класификације сортиран по <i>MDG</i> за $D_2R_{1.5}$ комбинацију. ....	64
Слика 5.6: Важност атрибута код <i>RF</i> класификације сортиран по <i>MDG</i> за $D_2R_3$ комбинацију. ....	64
Слика 5.7: Важност атрибута код <i>RF</i> класификације сортиран по <i>MDG</i> за вишеразмерну комбинацију добијену са рекурзивном елиминацијом атрибута. ...	65
Слика 5.8: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом $D_2R_{1.5}$ комбинације атрибута. ....	66
Слика 5.9: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом $D_2R_3$ комбинације атрибута. ....	67
Слика 5.10: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом вишеразмерне комбинације атрибута. ....	68
Слика 5.11: Средња укупна тачност класификације за различит број атрибута одређених уклањањем високо корелисаних атрибута и рекурзивном елиминацијом вишеразмерне комбинације атрибута. ....	69
Слика 5.12: Најбољи резултати семантичке сегментације ( <i>SVM</i> – лево) и карта грешака семантичке сегментације (десно) добијени са $D_2R_{1.5}$ комбинацијом атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом. ....	71
Слика 5.13: Карта семантичке сегментације са приказаним грешкама на <i>ISPRS</i> скупу података. Приказани су резултати <i>SVM</i> класификатора над подацима генерисаним са $D_2R_{1.5}$ комбинацијом. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом. ....	72
Слика 5.14: Највеће грешке код семантичке сегментације. Кров ниже зграде (лево) и хоризонталан кров зграде (десно) са додељеном класом ниске вегетације и непропусних површина. ....	72
Слика 5.15: Најбољи резултати семантичке сегментације ( <i>SVM</i> – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом	

$D_2R_{1.5}$ комбинације атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом. ....	75
Слика 5.16: Најбољи резултати семантичке сегментације ( <i>ENS_NB</i> – лево) и карта грешака семантичке сегментације (десно) добијени са $D_2R_3$ комбинацијом атрибута. Белом бојом су приказане тачке мањинских класа које нису учествовале у семантичкој сегментацији.....	78
Слика 5.17: Карта са грешкама семантичке сегментације <i>ISPRS</i> скупа података. Приказани су резултати <i>ENS_NB</i> класификатора над подацима генерисаним са $D_2R_3$ комбинацијом атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом. ....	79
Слика 5.18: Најбољи резултати семантичке сегментације ( <i>SVM</i> – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом $D_2R_3$ комбинације атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији. ....	82
Слика 5.19: Најбољи резултати семантичке сегментације ( <i>SVM</i> – лево) и карта грешака семантичке сегментације (десно) добијена вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке мањинских класа које нису учествовале у семантичкој сегментацији.....	85
Слика 5.20: Карта са грешкама семантичке сегментације <i>ISPRS</i> скупа података. Приказани су резултати <i>SVM</i> класификатора над подацима генерисаним са вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији. ....	86
Слика 5.21: Највеће грешке семантичке сегментације <i>ISPRS</i> тест података. Кровови зграда (црвено) класификовани у класу ниске вегетације (светло зелено) и дрвеће (тамно зелено). ....	87
Слика 5.22: Најбољи резултати семантичке сегментације ( <i>ENS_ANN</i> – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом вишеразмерне комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији. ....	89
Слика 5.23: Поређење резултата семантичке сегментације благо нагнутог крова: а) референтни подаци, б) <i>SVM</i> са $D_2R_{1.5}$ комбинацијом, в) <i>ENS_NB</i> са $D_2R_3$ комбинацијом и г) <i>SVM</i> са вишеразмерном комбинацијом атрибута. У средини је дата позиција локације на том подручју. ....	92
Слика 5.24: Поређење резултата семантичке сегментације – грешака код ивица кровова: а) референтни подаци, б) <i>SVM</i> са $D_2R_{1.5}$ комбинацијом, в) <i>ENS_NB</i> са $D_2R_3$ комбинацији и г) <i>SVM</i> са вишеразмерном комбинацијом атрибута. У средини је дата позиција локације на том подручју.....	93
Слика 5.25: Поређење резултата семантичке сегментације крова класификованог као непропусне површине и ниска вегетација: а) референтни подаци, б) <i>SVM</i> са $D_2R_{1.5}$ комбинацијом, в) <i>ENS_NB</i> са $D_2R_3$ комбинацијом и г) <i>SVM</i> са вишеразмерном комбинацијом атрибута. У средини слике је дат преглед позиције локације на том подручју. ....	94

Слика 5.26: Утицај смањења количине тренинг података у односу на укупну тачност <i>RF</i> модела. ....	95
Слика 5.27: Најбољи резултати семантичке сегментације са <i>SVM</i> класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута узоркованих података.....	97
Слика 5.28: Карта са грешкама семантичке сегментације <i>ISPRS</i> скупа података. Дати су резултати <i>SVM</i> класификатора над узоркованим тренинг подацима вишеразмерне комбинације атрибута. ....	98
Слика 5.29: Приказ референтних података (лево) и додатних грешака семантичке сегментације облака тачака над узоркованим тренинг подацима вишеразмерне комбинације атрибута (десно). ....	98
Слика 5.30: Најбољи резултати семантичке сегментације са <i>ENS_NB</i> класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута <i>GRSS</i> података за Џексонвил. ....	101
Слика 5.31: Карта са грешкама семантичке сегментације <i>GRSS</i> скупа података за Џексонвил. Приказани су резултати <i>ENS_NB</i> класификатора над подацима генерисаним са вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији. ....	102
Слика 5.32: Најбољи резултати семантичке сегментације са <i>ENS_ANN</i> класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута <i>GRSS</i> података за Омаху.....	104
Слика 5.33: Карта класа са грешкама семантичке сегментације <i>GRSS</i> података за Омаху. Приказани су резултати <i>ENS_ANN</i> класификатора над подацима добијеним са вишеразмерном комбинацијом. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији. ....	105
Слика 5.34: Приказ резултата семантичке сегментације <i>GRSS</i> облака тачака Џексонвила (лево) и резултата семантичке сегментације <i>GRSS</i> облака тачака Омахе (десно). ....	106
Слика 5.35: Сегменти крошњи са детектованим врховима стабала. ....	108
Слика 5.36: Поређење <i>OA RF</i> модела машинског учења пре и после балансирања података. Медијана је приказана у виду црне тачке у правоугаонику, док први и трећи квантил дефинишу правоугаоник. Граничници дефинишу минимум и максимум података, док су грубе грешке приказане као плави кругови. ....	108
Слика 5.37: Селекција атрибута коришћењем <i>GA</i> са 100 итерација. Црвене тачке представљају укупну тачност добијену екстерном валидацијом, док су плаве тачке средња укупна тачност интерне валидације сваке итерације. ....	109
Слика 5.38: Важност селектованих атрибута изражена преко скалираног средњег опадања Џини индекса. ....	110
Слика 5.39: Одређивање хиперпараметара <i>mtry</i> и <i>ntree</i> за <i>RF</i> . ....	112
Слика 5.40: Избор одговарајућег кернела за <i>SVM</i> базиран на укупној тачности. ....	113
Слика 5.41: Одређивање хиперпараметара <i>size</i> и <i>decay</i> за <i>ANN</i> . ....	113



Слика 5.42: Поређење вредности $OA$ и $\kappa$ са различитим класификаторима над тренинг подацима. ....	114
Слика 6.1: Приказ интензитетске слике (лево) и слике негативне отворености површи (десно) за $D_2R_3$ комбинацију атрибута $ISPRS$ тренинг података.....	119
Слика 6.2: Вредност $F1$ скорa за сваку класу различитих метода за семантичку сегментацију $ISPRS$ података ( $PhD$ је приступ развијен у оквиру ове дисертације). .....	122
Слика 6.3: Вредност $IoU$ за сваку класу различитих метода за семантичку сегментацију $GRSS$ података ( $PhD$ је приступ развијен у оквиру ове дисертације). .....	125

# СПИСАК ТАБЕЛА

Табела 3.1 Преглед коришћених атрибута за семантичку сегментацију облака тачака. ....	26
Табела 3.2. Коришћени модели машинског учења и одговарајућа библиотека за <i>R</i> . ....	32
Табела 3.3 Преглед атрибута облика сегмента. ....	35
Табела 3.4 Преглед метрика дрвећа. ....	35
Табела 3.5 Преглед атрибута базираних на сопственим вредностима. ....	36
Табела 3.6 Преглед атрибута уклапања облика. ....	37
Табела 4.1 Шифре класа, њихов опис и укупан број припадајућих тачака за сваку класу. ....	44
Табела 4.2 Шифре класа, њихов опис и број тачака за сваку класу у зависности од скупа података. ....	46
Табела 5.1 Укупна тачност ( <i>OA</i> ) и капа кофицијент ( <i>κ</i> ) семантичке сегментације растерских продуката, резултата побољшаних просторном регуларизацијом и резултата семантичке сегментације облака тачака са различитим начинима и полупречницима претраге за <i>RF</i> , <i>SVM</i> , <i>ANN</i> и <i>XGB</i> класификатор над <i>ISPRS</i> подацима (задебљаним словима су приказани најбољи резултати). ....	58
Табела 5.2 Резултати семантичке сегментације <b>растерских продуката <i>ISPRS</i> облака тачака</b> са различитим класификаторима добијени са <b><i>D<sub>2</sub>R<sub>1.5</sub></i></b> комбинацијом атрибута. ....	70
Табела 5.3 Резултати семантичке сегментације <b><i>ISPRS</i> облака тачака</b> са различитим класификаторима добијени са <b><i>D<sub>2</sub>R<sub>1.5</sub></i></b> комбинацијом атрибута. ....	70
Табела 5.4 Резултати семантичке сегментације <b>растерских продуката <i>ISPRS</i> облака тачака балансираних класа</b> са различитим класификаторима добијени са <b><i>D<sub>2</sub>R<sub>1.5</sub></i></b> комбинацијом атрибута. ....	73
Табела 5.5 Резултати семантичке сегментације <b>растерских продуката <i>ISPRS</i> облака тачака балансираних класа</b> са различитим класификаторима добијени са <b><i>D<sub>2</sub>R<sub>1.5</sub></i></b> комбинацијом атрибута. ....	73
Табела 5.6 Резултати семантичке сегментације <b><i>ISPRS</i> облака тачака балансираних класа</b> са различитим класификаторима добијени са <b><i>D<sub>2</sub>R<sub>1.5</sub></i></b> комбинацијом атрибута. ....	74
Табела 5.7 Резултати семантичке сегментације <b>растерских продуката <i>ISPRS</i> облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <i>D<sub>2</sub>R<sub>1.5</sub></i> комбинације</b> атрибута. ....	74
Табела 5.8 Резултати семантичке сегментације <b><i>ISPRS</i> облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <i>D<sub>2</sub>R<sub>1.5</sub></i> комбинације</b> атрибута. ....	75

Табела 5.9 Семантичка сегментација <b>растерских продуката ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <math>D_2R_{1.5}</math> комбинације атрибута</b> .....	76
Табела 5.10 Семантичка сегментација <b>ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <math>D_2R_{1.5}</math> комбинације атрибута</b> .....	76
Табела 5.11 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> са различитим класификаторима добијени <b><math>D_2R_3</math> комбинацијом атрибута</b> .....	77
Табела 5.12 Резултати семантичке сегментације <b>ISPRS облака тачака</b> са различитим класификаторима добијени <b><math>D_2R_3</math> комбинацијом</b> прорачуна атрибута. ....	77
Табела 5.13 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b><math>D_2R_3</math> комбинацијом</b> атрибута. ....	80
Табела 5.14 Резултати семантичке сегментације <b>ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b><math>D_2R_3</math> комбинацијом</b> атрибута.....	80
Табела 5.15 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <math>D_2R_3</math> комбинацијом</b> атрибута. ....	81
Табела 5.16 Резултати семантичке сегментације <b>ISPRS облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <math>D_2R_3</math> комбинације</b> атрибута.....	81
Табела 5.17 Семантичка сегментација <b>растерских продуката ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом <math>D_2R_3</math> комбинације</b> атрибута. ....	82
Табела 5.18 Семантичка сегментација <b>ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b><math>D_2R_3</math> комбинацијом</b> прорачуна <b>рекурзивне елиминације</b> атрибута. ....	83
Табела 5.19 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута.....	84
Табела 5.20 Резултати семантичке сегментације <b>ISPRS облака тачака</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута. ....	84
Табела 5.21 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута. ....	88
Табела 5.22 Резултати семантичке сегментације <b>ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута. ....	88

Табела 5.23 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом вишеразмерне комбинације</b> атрибута. ....	88
Табела 5.24 Резултати семантичке сегментације <b>ISPRS облака тачака</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом вишеразмерне комбинације</b> атрибута. ....	89
Табела 5.25 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом вишеразмерне комбинације</b> атрибута. ....	90
Табела 5.26 Резултати семантичке сегментације <b>ISPRS облака тачака балансираних класа</b> са различитим класификаторима добијени <b>рекурзивном елиминацијом вишеразмерне комбинације</b> атрибута. ....	90
Табела 5.27 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута <b>узоркованих тренинг података</b> . ....	96
Табела 5.28 Резултати семантичке сегментације <b>ISPRS облака тачака</b> са различитим класификаторима добијени са <b>вишеразмерном комбинацијом</b> атрибута <b>узоркованих тренинг података</b> . ....	97
Табела 5.29 Резултати семантичке сегментације <b>растерских продуката ISPRS облака тачака</b> балансираних класа са различитим класификаторима ердобијени <b>вишеразмерном комбинацијом</b> прорачуна <b>рекурзивне елиминације атрибута узоркованим тренинг података</b> . ....	99
Табела 5.30 Резултати семантичке сегментације <b>ISPRS облака тачака</b> балансираних класа са различитим класификаторима добијени <b>вишеразмерном комбинацијом</b> прорачуна <b>рекурзивне елиминације атрибута узоркованих тренинг података</b> . ....	99
Табела 5.31 Укупна тачност ( $OA$ ), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – $R$ , прецизност – $P$ , $F1$ скор – $F1$ ) за све моделе семантичке сегментације <b>GRSS скупа података за Цексонвил</b> . Резултати су добијени коришћењем атрибута задржаних у моделу након рекурзивне елиминације атрибута. ....	100
Табела 5.32 Укупна тачност ( $OA$ ), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – $R$ , прецизност – $P$ , $F1$ скор – $F1$ ) за све моделе семантичке сегментације <b>GRSS балансираног скупа података за Цексонвил</b> . ....	102
Табела 5.33 Укупна тачност ( $OA$ ), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – $R$ , прецизност – $P$ , $F1$ скор – $F1$ ) за све моделе семантичке сегментације <b>GRSS скупа података за Омаху</b> . ....	103
Табела 5.34 Укупна тачност ( $OA$ ), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – $R$ , прецизност – $P$ , $F1$ скор – $F1$ ) за све моделе семантичке сегментације <b>GRSS балансираног скупа података за Омаху</b> . ....	105
Табела 5.35 Семантичка сегментација <b>ISPRS облака тачака</b> са моделом истренираним са <b>GRSS</b> подацима. ....	107

Табела 5.36 Оптимални хиперпараметри за сваки коришћени алгоритам машинског учења и одговарајући R пакети. ....	111
Табела 5.37 Мере перформанси ( $OA$ и $\kappa$ ) сваког класификатора предикцијом над тест подацима.....	114
Табела 5.38 Матрица конфузије свих шумских парцела и квантитативне мере перформанси модела. ....	115
Табела 6.1 Поређење резултата семантичке сегментације у погледу $\Phi 1$ скорa за <i>ISPRS</i> скуп података. ....	121
Табела 6.2 Поређење резултата семантичке сегментације у погледу $IoU$ по класама и $mIoU$ за <i>GRSS</i> скуп података. ....	124



# 1 УВОД

Метода ласерског скенирања (енгл. *Light Detection and Ranging – LiDAR*) показала се као веома успешна за брзо прикупљање масовне количине просторних података о топографији физичке површи Земље. Метода је заступљена већ неколико деценија и за разлику од фотограметријског приступа нуди могућност снимања терена испод крошњи дрвећа, пошто ласерски зрак пролази (пенетрира) кроз слој вегетације. Код ове методе се на основу једног послатог ласерског сигнала може регистровати више повратних одбитака (ехоа). Подаци добијени наведеном методом увелико се користе у различитим областима као што су: геодезија, шумарство, геологија, хидрологија, археологија и др.

Геопросторне базе података на основу којих се израђују топографске карте највећим делом се попуњавају подацима добијеним фотограметријским премером од стране државних агенција што захтева доста мануелног посла. Развојем технологије ласерског скенирања и екстракцијом објеката из добијеног облака тачака постижу се значајне уштеде у времену и новцу аутоматизацијом процеса картирања.

Као главни продукт ове технологије добија се геореференциран густ облак 3Д тачака које представљају одбитке ласерског сигнала од различитих појава на физичкој површи Земље, као што су: зграде, надземни водови, вегетација, терен и друго. За сваку од измерених тачака, поред 3Д координата, могу се водити и неки додатни атрибути који зависе од карактеристика скенера, природе простирања сигнала кроз медијум, а такође се, на основу суседства тачке, могу одредити и различити геометријски атрибути тачака. Управо се на основу тих додатних информација може успешно извршити класификација наведених тачака у зависности од тога од којих појава се ласерски сигнал одбио. Груписање тачака са сличним атрибутима у виду кластера који имају одређеног смисла назива се семантичка сегментација облака тачака.

Семантичка сегментација је термин који се најчешће користи код дигиталних слика, где се пиксели повезују са одређеним семантичким ознакама и групишу у сегменте по одређеним класама. Семантичка сегментација облака тачака је примена сегментације у 3Д простору, где се, уместо над пикселима растерске слике, сегментација врши над тачкама са правилном или неправилном дистрибуцијом у 3Д простору. Наведени термин је потекао из области компјутерске визије, док се у фотограметрији и даљинској детекцији користи термин „класификација облака тачака“, а у литератури се могу наћи и термини „семантичко означавање“ и „семантичка класификација облака тачака“. Семантичка сегментација облака тачака је много комплекснија од семантичке сегментације садржаја слика, будући да је присутна још једна димензија. Такође, суседство у облаку тачака далеко је

комплексније, јер су тачке најчешће неправилно распоређене у 3Д простору, што захтева развој компликованијих алгоритама.

Постоје два типа сегментације (класификације): надзирана и ненадзирана класификација. Кључна разлика је у томе што се код надзиране класификације користи тренинг скуп података за који се зна како резултат класификације треба да изгледа (подаци су разврстани у излазне класе). Код ненадзиране класификације се не користе тренинг подаци те се класификација тачака врши на основу неких карактеристика тих улазних података (геометријских, спектралних и других). Ненадзирана класификација данас најчешће представља корак који претходи надзираној класификацији, на тај начин што се тачке могу прво груписати у сегменте којим се после тога доделе класе. Будући да се код ненадзиране класификације не узимају у обзир семантичке информације, други назив за ову групу метода је сегментација облака тачака. Поред семантичке сегментације, постоји и виши ниво детекције објеката у облаку тачака који се назива сегментација инстанци. Сегментација облака тачака (ненадзирана класификација) дели се на неколико група метода које се базирају на детекцији ивица, расту региона, уклапању модела и кластерисању (Xie и др., 2020).

Постоји велики број метода развијених за потребе семантичке сегментације облака тачака. Већина успешних метода класификације базира се на томе да се прво изврши филтрирање тачака које припадају површи терена, то јест да се облак тачака класификује на тачке које припадају и не припадају терену. Након тога се врши даља класификација тачака које не припадају терену на зграде, вегетацију, надземне водове и друго. Ваљано филтрирање, тј. екстракција тачака терена има велики утицај на даљу успешност целокупне класификације, будући да се на основу висине тачке изнад терена (удаљености тачке од површи терена) могу извести веома корисни закључци о природи објекта ком тачка припада.

Семантичка сегментација облака тачака која се заснива на надзираним методама учења дели се на традиционалне методе машинског учења и методе дубоког учења. Weinmann и др., 2015. дели методе надзираног машинског учења на две групе. Прва група се базира на класификацији сваке тачке или групе тачака на основу њених атрибута. У ову групу метода убрајају се класификатори базирани на теорији максималне вероватноће као што су: метода потпорних вектора (енгл. *Support Vector Machine*), *AdaBoost* алгоритам, метода случајне шуме (енгл. *Random Forest*) и наивни Бајес (енгл. *Naive Bayes*). Процедуре семантичке сегментације код ових метода претходе четири корака: селекција суседа, екстракција атрибута тачака, селекција значајнијих атрибута тачака и избор тренинг узорка (Weinmann и др., 2015a). У другу групу метода убрајају се статистички контекстуални модели као што су: *Associative* и *Non-Associative Markov Networks*, *Conditional Random Fields*, *Simplified Markov Random Fields* и други.

За добијање најбољих резултата у погледу тачности семантичке сегментације облака тачака данас се користе приступи који су засновани на екстракцији атрибута скупа тачака из суседства коришћењем метода дубоког учења (неуронске мреже са великим бројем скривених слојева) на основу велике количине тренинг података (Griffiths и Boehm, 2019). Проблем који се јавља код наведеног приступа је што су неуронске мреже генерално тешке за интерпретацију. Такође, тренирање



неуронских мрежа је процесорски веома захтевно што изискује додатне рачунарске ресурсе као што су графичке картице високих перформанси. Ово је посебно изражено код дубоког учења примењеног на 3Д подацима. Као додатан неопходан ресурс подразумева се и велика количина тренинг података (тачака са информацијом о припадности одређеној класи) што најчешће захтева пуно мануелног рада и труда.

Стога, главни проблеми који се могу јавити код семантичке сегментације облака тачака су недостатак расположивих скупова података за тренирање и тестирање алгоритама, велики хардверски захтеви за процесирање података и неефикасност предложених метода у погледу постигнуте тачности и брзине извршавања.

Детекција појединачних стабала и сегментација крошњи дрвећа представља велики изазов и предмет је интензивног истраживања због саме структуре и комплексности шума (Zhen и др., 2016). Будући да технологија ласерског скенирања из ваздуха омогућава мерење тачака на објектима и површи терена испод крошњи дрвећа, током израде ове дисертације један део истраживања посвећен је коришћењу облака тачака за побољшање резултата детекције појединачног дрвећа у шумском подручју коришћењем метода машинског учења.

## 1.1 Предмет научног истраживања

Предмет истраживања у оквиру ове докторске дисертације су могућности и изазови примене метода машинског учења приликом процесирања облака тачака у 3Д простору. Конкретно, у оквиру дисертације предложен је и анализиран приступ семантичке сегментације облака тачака добијеног ласерским скенирањем топографије терена из ваздуха. Поред традиционалних метода машинског учења које су се показале као најјефикасније у досадашњим проблемима класификације, коришћени су и сложени ансамбл модели добијени слагањем више модела машинског учења (енгл. *stacked ensemble learning*).

Истраживање обухвата и побољшање тачности класификације облака тачака уз коришћење минималне количине релевантних тренинг података и сходно томе, краћег времена тренирања класификатора. На краће време тренирања нарочито утиче избор мањег броја најзначајнијих физичких и геометријских карактеристика (енгл. *features*) које треба одредити у виду атрибута за сваку тачку (Charaniya и др., 2004; Chehata и др., 2009; Weinmann и др., 2015a; Yao и др., 2011). Атрибути тачака се могу дефинисати тако да пружају информације о неравности и пропусности површине у окружењу сваке појединачне тачке као што је случај код вегетације или на малу количину расипања тачака око уклапане равни као што је случај код кровова зграда. Класе тачака које су коришћене у истраживању су оне које се иначе најчешће појављују у научној литератури и то су: терен, вегетација (висока, средња, ниска), зграде, вода и неклассификовано. Наведена стратегија машинског учења не треба да буде ограничена само за поменути проблем класификације. Она такође може бити примењена на генеричке проблеме као што је класификација врста

дрвећа у шумарству (*Dalponte* и др., 2012) или за потребе правилне детекције врхова стабала (*Lisiewicz* и др., 2022b).

На побољшање перформанси тренирања и бољих резултата утиче и избор најинформативнијих тренинг података који се налазе у различитом обухвату суседства тачке која се сврстава у одређену класу. Имајући ово у виду, у току истраживања спроведен је низ експеримената, који су за циљ имали селекцију најважнијих атрибута и балансирање одређених класа у погледу броја тренинг примерака (енгл. *samples*) и заступљености у подручју од интереса. Такође, у случају да и даље није било довољно кандидата одређене класе за тренирање модела, извршено је и синтетизовање додатних примерака. Репрезентативан скуп података представља оптималну селекцију атрибута тачака потребну за тренирање модела машинског учења којим ће се добити висока тачност класификације ако се примени над сасвим другим скупом података. Зато је веома битно одабрати релевантан скуп података са довољним бројем тачака које припадају свакој класи и за различите типове терена, поготово у случају различитог нивоа изграђености насеља и пошумљености подручја.

У овом истраживању дат је преглед јавно доступних скупова података намењених за упоређивање резултата у пољу класификације облака тачака, од којих су неки искоришћени за тренирање и тестирање модела (*Laefler* и др., 2017; *Le Saux* и др., 2019; *Niemeyer* и др., 2014; *Zolanvari* и др., 2019). Класификован облак тачака који се користи за тренирање класификатора подељен је на део за тренирање алгорита и на део за тестирање успешности методе. Применом методе унакрсне валидације над подацима за тренирање могуће је извршити избор хиперпараметара модела машинског учења са којим се постижу најбољи резултати. Са наведеним начином поделе података, након тренирања алгорита на основу одређене количине класификованих тренинг података, врши се оцена успешности класификације над расположивим тест подацима.

У дисертацији посебна пажња је посвећена начину дефинисања оптималног суседства сваке тачке у циљу екстракције физичких и геометријских атрибута за потребе класификације. Овде се мисли на избор параметара као што су: укупан број суседних тачака, полупречник претраге тачака, форма претраге у виду 3Д сфере или вертикалног цилиндра претраге за екстракцију информација из суседства. Посебан део је посвећен вишеразмерном приступу (енгл. *multiscale approach*) којим се генерише више истих типова атрибута, али са различитим начином претраге и различитим величинама полупречника претраге. Циљ је да се селектује суседство са тачкама које ће имати највећи утицај на правилну класификацију посматране тачке.

У последњих неколико деценија, технологија ласерског скенирања из ваздуха (енгл. *Airborne Laser Scanning – ALS*) је значајно унапредовала и показала велики потенцијал за мерење, картирање или праћење развоја шума (*Wulder* и др., 2013). Ласерски сигнал послат са *LiDAR* система продире кроз крошње шумског дрвећа одбијајући се од терена испод, што даје могућност одређивања вертикалне структуре крошње, висине стабала и карактеристика терена. Стога, *LiDAR* технологија има широку употребу у шумарству, с обзиром на то да се прикупљени

подаци могу успешно користити за генерисање 3Д модела терена и одређивање висина стабала у шумским подручјима.

Када се користе облаци тачака добијени ласерским скенирањем из ваздуха, могуће је детектовати појединачна стабла и одредити карактеристике појединачног дрвета, као што су висина, локација и димензије крошње, што даје прецизне процене за запремину дрвне масе и средњу висину стабала (*Huuppa* и *Inkinen, 1999a*). У последње две деценије развијени су бројни полуаутоматски или потпуно аутоматски алгоритми за детекцију појединачних стабала (енгл. *Individual Tree Detection – ITD*) и делинеацију крошњи (*Zhen* и др., 2016). Међутим, истраживања у овој области и даље остају велики изазов због сложености и хетерогености структурних карактеристика шума.

Зато је у овој дисертацији значајан део истраживања био посвећен побољшању резултата детекције стабала у шумским подручјима. Ово је изведено коришћењем традиционалних метода машинског учења које су тестиране и приликом семантичке сегментације облака тачака.

## 1.2 Циљеви истраживања

Основни циљ истраживања у оквиру ове дисертације био је развој методе семантичке сегментације облака тачака добијеног ласерским скенирањем. Наведени приступ представља комбинацију метода машинског учења где се користе правилности уочене у суседству већ класификованих података из тренинг скупа података. Из наведеног циља произилазе следећи парцијални циљеви истраживања:

1. Анализа постојећих метода семантичке сегментације облака тачака;
2. Анализа јавно доступних, референтних скупова података ласерског скенирања из ваздуха који се користе за такмичења у успешности метода семантичке сегментације;
3. Развијање процедуре за начин дефинисања оптималног суседства тачака којом се добијају најрепрезентативнији показатељи раздвојености између класа;
4. Екстракција и избор комбинације најзначајнијих физичких и геометријских атрибута тачака који указују на припадност појединим класама у циљу смањења потрошње ресурса приликом тренирања модела, али без значајних губитака у погледу тачности класификације;
5. Генерисање синтетичких класификованих тачака у случају небалансираних класа;
6. Тренирање модела и оптимизација параметара изабраног класификатора приликом валидације ради добијања што квалитетнијих резултата за што краће време;

7. Избор ансамбл модела машинског учења добијен слагањем више модела машинског учења у циљу добијања што квалитетнијих резултата класификације.
8. Примена метода машинског учења за потребе побољшања детекције појединачних стабала у пошумљеним подручјима података добијених ласерским скенирањем из ваздуха.

### 1.3 Приступ

Узимајући у обзир све наведено до сада, у овој дисертацији је обрађена могућност семантичке сегментације облака тачака коришћењем метода машинског учења. Додатно, један део истраживања везан је за коришћење неких од наведених метода машинског учења за побољшање детекције стабала у шумским подручјима. У оба случаја се захтева рачунање карактеристика или атрибута (енгл. *features*) на основу облака тачака. Атрибути су коришћени као предикторске варијабле приликом класификације неком од метода машинског учења. Разматрани су различити начини претраге оптималног суседства тачака (цилиндар или сфера претраге) и величина полупречника претраге са којом се добијају најрепрезентативнији показатељи раздвојености између класа. Додатни задатак било је генерисање вишеразмерног (енгл. *multiscale*) скупа података са атрибутима одређеним за више величина претраге суседства. Такође је након одређивања атрибута извршена селекција оних најзначајнијих који су коришћени за даљу класификацију без значајног губитка у погледу тачности класификације. Извршена је растеризација атрибута тачака у циљу смањења броја примерака потребних за тренирања модела семантичке сегментације. Спроведена је просторна регуларизација ознака класа ради уклањања шума у резултатима семантичке сегментације. Ради балансирања класа тачака заступљених у подацима вршено је синтетизовање примерака који припадају мањинској класи. На крају је тестирано више метода машинског учења од којих је најефикаснија одабрана за коначну семантичку сегментацију облака тачака. Такође су генерисани ансамбл модели настали слагањем (енгл. *stacking*) више модела машинског учења. Са тим приступом добиле су се још боље перформансе у погледу тачности семантичке сегментације облака тачака.

Код побољшања детекције појединачних стабала (енгл. *Individual Tree Detection – ITD*) из података ласерског скенирања из ваздуха, прво је генерисан висински модел крошње (енгл. *Canopy Height Model – CHM*) на основу тачака са нормализованим висинама, који је додатно интерполиран и углачан. Кандидати за врхове стабала су детектовани коришћењем традиционалне *ITD* методе са филтрирањем локалних максимума (енгл. *Local Maxima – LM*). Локални максимуми су коришћени као семе за раст сегмената крошњи стабала на основу *CHM*. Исти су затим означени као исправно и погрешно детектовани у односу на референтне податке о стаблима. Затим су одређене четири групе атрибута за сваки од сегмената које се користе као предикторске варијабле приликом класификације: метрике дрвећа, атрибути облика сегмента, атрибути засновани на сопственим вредностима и атрибути уклапања облика за сваки сегмент. Извршено је балансирање класа и

селекција атрибута ради бољег раздвајања између исправних и погрешних детекција врхова стабала. Селектовани атрибути коришћени су као тренинг подаци за класификацију коришћењем неколико метода машинског учења. Коначно, класификациони модел врхова стабала са најбољим перформансама тестиран је на независном скупу података чиме је извршена оцена тачности модела.

## **1.4 Кратак преглед**

Резултати истраживања у овој дисертацији су приказани кроз девет поглавља. У поглављу 2 дат је детаљан преглед и анализа досадашњих истраживања у овој области. У поглављу 3 дате су теоријске основе неопходне за истраживање у овој области. У поглављу 4 описана је већина јавно доступних, расположивих скупова ласерског скенирања, док се поглавље 5 односи на експериментални део рада. Поглавља 6 и 7 садрже дискусију након извршених експеримената и закључке истраживања, респективно. У поглављу 8 и поглављу 9 су наведена коришћена литература и прилози, тим редом.

## 2 ПРЕГЛЕД И АНАЛИЗА ДОСАДАШЊИХ ИСТРАЖИВАЊА

У овом поглављу биће направљен преглед истраживања из области семантичке сегментације облака тачака (поглавље 2.1) и метода детекције појединачних стабала и делинеације крошњи стабала у шумским подручјима (поглавље 2.2).

### 2.1 Семантичка сегментација облака тачака

Екстракција различитих типова објеката (зграде, путеви, вегетација итд.) из облака тачака добијеног ласерским скенирањем из ваздуха показало је велики потенцијал почевши од 2000–их. Наведеном истраживању претходила је класификација тачака на оне које припадају и не припадају класи терена (филтрирање тачака терена) која је била заснована на интерполацији (*Kraus и Pfeifer, 1998*), нагибу (*Vosselman, 2000*), сегментацији (*Tóvári и Pfeifer, 2012*) и морфолошким операторима (*Zhang и др., 2003*). Даљу класификацију тачака које не припадају класи терена истраживачи су базирали на атрибутима генерисаним на основу геометријских и текстуралних карактеристика тачака и њиховог суседства (*Matikainen и Kaartinen, 2007*). Касније студије су показале да се класификација поспешује укључивањем интензитета одбијеног *LiDAR* сигнала (*Charaniya и др., 2004*) код којих је претходно извршена ваљана радиометријска калибрација. Класификација је такође примењена над подацима добијеним фузијом *LiDAR* и мултиспектралних података (*Haala и Brenner, 1999; Rottensteiner и др., 2005; Secord и Zakhor, 2007*).

Наведена истраживања била су базирана на подацима добијеним *LiDAR* системом са дискретним одређивањем одбитка сигнала, док су од 2004. године уведени *full-waveform (FW)* системи одређивања комплетног облика сигнала. Овакав начин регистрације комплетног облика сигнала посебно је био битан код разликовања тачака вегетације од тачака које припадају другим објектима. Код овог система се сагледава расипање сигнала приликом проласка кроз медијум и његове интеракције са храпавошћу и текстуром површине од које се одбија. Стога се у циљу детекције подручја са вегетацијом врши класификација облака тачака над срачунатим *FW LiDAR* атрибутима (*Gross и др., 2007; Wagner и др., 2008*).

Већина студија које су се бавиле класификацијом облака тачака заснивале су генерисање атрибута на основу једноразмерног суседства (енгл. *single scale*). Параметар размере се најчешће одређује хеуристички или емпиријски сагледавањем података или саме сцене (*Filin и Pfeifer, 2005; Lee и Schenk, 2002; Linsen и Prutzsch, 2001*). Такође је било покушаја да се вредност параметра размере претраге одреди и аутоматски коришћењем приступа вођеним подацима (*Demantké и др., 2011; Weinmann и др., 2015a*). Други начин одређивања атрибута, при чему се узима у обзир више дефиниција суседства и више величина претраге суседства,

јесте вишеразмеран приступ одређивања атрибута (*Blomley* и др., 2016; *Blomley* и *Weinmann*, 2017; *Brodu* и *Lague*, 2012; *Niemeyer* и др., 2014; *Schmidt* и др., 2014).

### **2.1.1 Семантичка сегментација облака тачака коришћењем традиционалних метода машинског учења**

У новије време, семантичка сегментација облака тачака обично се дели на два корака: екстракцију репрезентативних атрибута тачака на основу карактеристика тачака из суседства и доделу предефинисане семантичке класе свакој тачки. Други корак, сама класификација, најчешће се врши коришћењем класификационих модела базираних на машинском учењу. У раним почецима ових истраживања дефинисани су различити атрибути тачака базирани на геометрији локалног суседства као што су густина, закривљеност и хрпавост (енгл. *roughness*). Затим су различити алгоритми коришћени за семантичку сегментацију облака тачака, као што су: надзирана класификација *Dempster–Shafer* фузијом података (*Rottensteiner* и др., 2005), *AdaBoost* алгоритам (*Lodha* и др., 2007), метода потпорних вектора (енгл. *Support Vector Machine – SVM*) (*Charaniya* и др., 2004; *Guo* и др., 2011; *Mallet* и др., 2008; *Secord* и *Zakhor*, 2007; *Steinsiek* и др., 2017; *Zhang* и др., 2013), стабла одлучивања (енгл. *Decision Trees – DT*) (*Ducic* и др., 2006; *Matikainen* и *Kaartinen*, 2007), случајна шума (енгл. *Random Forest – RF*) (*Babahajiani* и др., 2017; *Chehata* и др., 2009; *Kim* и *Sohn*, 2010; *Zeybek*, 2021) и др. *Lodha* и др. су 2007. користили *AdaBoost* алгоритам како би облак тачака добијен ласерским скенирањем из ваздуха класификовали у четири класе (путеве, травнате површине, зграде и дрвеће) на основу пет атрибута и то: висина тачке, варијација висина, варијација нормала, интензитет одбијања и интензитет слике. *Zhang* и др. су 2013. одредили укупно 13 геометријских, тополошких и радиометријских атрибута и карактеристика базираних на информацијама о одбитку ласерског сигнала. Затим су употребили *SVM* алгоритам за класификацију облака тачака добијеног ласерским скенирањем из ваздуха у урбаном подручју. *Chehata* и др. су 2009. користили *RF* алгоритам за класификацију облака тачака рачунањем 21 атрибута (четири базирана на висини, два генерисана на основу својстава одбитака сигнала, седам атрибута базираних на сопственим вредностима, четири базирана на уклапању локалне равни у тачке и четири одређена на основу особина комплетног облика сигнала). Они су такође користили селекцију најрелевантнијих атрибута елиминацијом уназад (енгл. *backward elimination*) пре даље класификације. У истраживању које су спровели *Lin* и др. 2014., метода потпорних вектора је коришћена за класификацију облака тачака коришћењем три геометријска атрибута (линеарност, планарност и сферичност).

Наведене (традиционалне) методе семантичке сегментације облака тачака заснивају се на приступу где се свака тачка третира као засебан ентитет и класификација тачака зависи само од карактеристика локалне геометрије. Стога се овим методама не узима у обзир просторна регуларност класне припадности тачака које се налазе у блиском суседству (*Blomley* и *Weinmann*, 2017). Зато су резултати класификације склони појави шума и неконзистентности у ознакама класа тачака. Појединачне студије су се бавиле решавањем овог проблема тако што су

укључиване контекстуалне информације у класификационе моделе: *Associative Markov Networks* (Munoz и др., 2009), *Non-Associative Markov Networks* (Shapovalov и др., 2010) и условна насумична поља (енгл. *Conditional Random Field – CRF*) (Han и др., 2020; Landrieu и др., 2017; Niemeyer и др., 2016, 2014, 2012; Schmidt и др., 2014; Steinsiek и др., 2017; Weinmann и др., 2015b).

Weinmann и др. су 2015. спровели свеобухватно истраживање у циљу одређивања оптималног суседства тачака, релевантних атрибута које је потребно одредити и ефикасних класификатора за семантичку сегментацију облака тачака. Тестирали су седам начина дефинисања суседства тачке, генерисали 21 геометријски атрибут, испробали седам приступа за селекцију најрелевантнијих атрибута и десет класификатора над два различита скупа података. *RF* метода се у њиховом експерименту показала као најбољи класификатор. Поједини аутори су се бавили и развијањем ансамбл методе машинског учења коју су назвали *JointBoost* за класификацију облака тачака (Guo и др., 2015). Ансамбл методом машинског учења генерисали су снажан класификатор комбиновањем више слабих класификатора. У њиховом истраживању 26 атрибута је екстраковано из облака тачака за сваку тачку. У свом истраживању, прво су вршили класификацију са *JointBoost* коришћењем 17 најважнијих атрибута. Затим су непоуздане или погрешно класификоване тачке поново класификоване коришћењем методе *k*-најближих суседа (енгл. *k-nearest neighbors – kNN*) са свим расположивим атрибутима. Ефикасност коришћења геометријских атрибута одређених на основу сопствених вредности оцењена је код надзиране класификације у истраживању Plaza–Leiva и др. од 2017. Класификација је у том истраживању вршена на три класе: зграде, природна и вештачки створена вегетација. Овде су, поред метода машинског учења заснованих на Гаусовој операцији, коришћене и методе потпорних вектора и вештачких неуронских мрежа. Неки аутори су за класификацију користили и методу градијентног појачавања коришћењем стабала одлучивања (енгл. *Gradient Boosting*) поред *RF* методе (Becker и др., 2018). Класификација облака тачака вршена је над четири различита скупа података коришћењем 15 геометријских карактеристика, као и атрибута у којим се чува информација о текстури тачке добијене на основу слика у боји. У студији коју су извели Cabo и др. (2019.), надзирана класификација вршена је и за насељена и за пошумљена подручја. Они су користили пет геометријских атрибута срачунатих на основу облака тачака: линеарност, планарност, сферичност, хоризонталност и промену висине. Као класификациони алгоритми коришћене су следеће методе: метода потпорних вектора, случајне шуме, логистичка регресија и линеарна дискриминаторна анализа (енгл. *Linear Discriminant Analysis – LDA*). Као резултат класификације са различитим полупречником претраге, постигнута је тачност од око 80% за насељено подручје и 93% за пошумљено подручје коришћењем *RF* класификатора.

Истраживање спроведено од стране Atik и др., (2021.) извршено је над три различита скупа података добијена ласерским скенирањем из ваздуха међу којима је и *ISPRS* скуп података за град Фајхинген који је коришћен и у овој дисертацији. Поменути истраживачи су користили геометријске атрибуте срачунате на основу сопствених вредности матрице коваријанси, а за класификацију је коришћено осам алгоритама надзиране класификације. Геометријски атрибути срачунати су по вишеразмерном приступу за сваку тачку са полупречником претраге од 0.5 m, 1 m, 1.5 m, 2 m и 3 m. Највиша укупна тачност постигнута за класификацију облака



тачака Фајхинген скупа података била је 79.71% коришћењем *SVM* алгоритма за полупречник претраге од 1.5 m и то само за тачке које припадају класама зграда, вегетације и дрвећа. *Vosselman* и др. су 2017. исто користили наведени *ISPRS* скуп података за подручје градова Фајхингена и Ротердама у свом истраживању. Они су генерисали 19 геометријских атрибута екстрактованих из облака тачака како би извршили класификацију облака тачака. Код њиховог приступа је облак тачака подељен на сегменте који су затим класификовани. У овој студији се као најбоља метода класификације показала условна насумична поља (*CRF*). *Blomley* и *Weinmann*, су 2017. извршили семантичку сегментацију над *ISPRS* скупом података. Они су одредили атрибуте на основу вишеразног суседства одређеног са више начина (путем цилиндра и сфере претраге) и применили *RF* класификатор. У свом истраживању су користили свих девет доступних класа овог скупа података (далеководи, ниска вегетација, непропусне површине, аутомобили, ограде, кровови, фасаде, жбуње и дрвеће) и стога су добили знатно нижу укупну тачност семантичке сегментације (68.1%). За класе непропусне површине, кровове и дрвеће добијали су прихватљиве резултате класификације.

## **2.2 Детекција појединачних стабала и делинеација крошњи стабала коришћењем података ласерског скенирања**

Област истраживања везана за детекцију стабала и делинеацију крошњи и даље представља велики изазов због сложености и хетерогености шумске структуре. Наведена истраживања започета су од стране *Нуурпја* и др. (*Нуурпја* и др., 2003, 2001; *Нуурпја* и *Inkinen*, 1999a) са детекцијом појединачних стабала четинарских шума користећи *ALS* податке са малим отиском сигнала. Након тога су многи аутори развијали *ITD* алгоритме за четинарске, лишћарске и мешовите шуме (*Ferraz* и др., 2016; *Koch* и др., 2006; *Persson* и др., 2002; *Popescu* и др., 2002; *Silva* и др., 2016). Постизање високе тачности *ITD* алгоритма и даље остаје велики изазов, јер је коришћење многих приступа који су иначе добро функционисали у четинарским шумама резултирало нижом тачношћу за лишћарске или мешовите шуме. Највећи проблеми детекције јављају се у сложеним шумама по структури са великим варијацијама у размаку између стабала, различитој старости и величини дрвећа, или када се крошње стабала у великој мери преклапају (*Zhen* и др., 2016). Стога, проблеми који се јављају током неког *ITD* приступа нису тривијални и за овај задатак је развијено више метода узимајући у обзир различите типове шума (*Hamraz* и др., 2016; *Stereńczak* и др., 2020; *Wang* и др., 2019; *Wu* и др., 2016). Перформансе *ITD* приступа такође могу зависити од карактеристика објекта снимања и карактеристика облака тачака. Карактеристике објекта снимања могу бити тип земљишног покривача (нпр. врста дрвећа, облик крошње и густина стабала – *Khosravipour* и др., 2015) и услови локације (нпр. топографија, типови терена – *Khosravipour* и др., 2015), док се карактеристике облака тачака односе на тип *LiDAR* сензора и параметре мисије снимања (нпр. висина лета, угао скенирања, начин скенирања, величина отиска сигнала и густина тачака – *Keränen* и др., 2016;

*Liu* и др., 2018). Променом неке од горе наведених карактеристика могу се изменити срачунате вредности метрика дрвећа од случаја до случаја и стога се постигнуте перформансе примењеног *ITD* приступа могу деградирати (*Liu* и др., 2018; *Roussel* и др., 2017).

*ITD* алгоритми се деле на: растерску групу метода које раде са растеризованим облаком тачака у форми висинског модела крошње (енгл. *Canopy Height Model – CHM*), векторску групу метода код којих се ради директно са облаком тачака (*Jakubowski* и др., 2013), и на групу метода код којих се за детекцију појединачних стабала комбинују растер, облак тачака и/или информације прибављене из других извора (*Koch* и др., 2014).

Растерски базиране методе имају широку примену због великог знања и искуства у области дигиталне обраде слике и могућности лаке примене наведених метода. Као што је већ наведено, ове методе углавном раде са висинским моделом крошње као основним подацима, који је генерисан на основу ласерског облака тачака, интерполован и углачан (*Koch* и др., 2014). Глачање *CHM*-а се врши у циљу попуњавања јама или уклањања шиљкова како би се што прецизније идентификовао тачан број врхова стабала на том подручју. После тога, примењује се филтрирање локалних максимума (енгл. *Local Maxima – LM*) коришћењем прозора претраге фиксне или променљиве величине (*Chen* и др., 2006; *Huuppa* и *Inkinen*, 1999b; *Popescu* и др., 2002). Детекција врхова стабала мора бити детаљно извршена, јер ће врхови стабала који недостају или су погрешно детектовани довести до недовољне или претеране сегментације крошње стабала у каснијој фази (*Khosravipour* и др., 2014; *Zhao* и др., 2013). Најчешће технике сегментације су засноване на: расту региона (енгл. *region growth – Dalponte* и *Coomes*, 2016; *Solberg* и др., 2006), делинеацији вододелница (енгл. *watershed – Chen* и др., 2006; *Jing* и др., 2012), праћењу долина (енгл. *valley following – Leckie* и др., 2003) или се ради о алгоритмима за кластерисање (енгл. *clustering – Gupta* и др., 2010; *Lindberg* и др., 2014).

Код *ITD* алгоритама базираних на директном процесирању облака тачака, фокус је на потпуној експлоатацији појединачних мерења у виду 3Д тачака без трансформације у растер. Као пример ове групе метода развијен је раст региона (*Li* и др., 2012), док су други аутори користили адаптивни алгоритам кластерисања којим се такође процесирање врши директно на нивоу облака тачака (*Lee* и др., 2010).

Хибридни *ITD* алгоритми који комбинују растерске продукте, облак тачака и информације из других извора користе додатни извор информација са *a priori* претпоставкама. Примери ових алгоритама су они који као додатни извор информација користе очекивану величину крошње и густину стабала (*Ene* и др., 2012; *Heinzel* и др., 2011), комбинују анализе слика и облака тачака (*Höfle* и *Hollaus*, 2010; *Reitberger* и др., 2009) и користе додатне информације у виду атрибута одбитак *ALS* система са реконструкцијом комплетног облика сигнала (енгл. *full-waveform*) у циљу побољшања сегментације крошње стабала (*Huuppa* и др., 2012; *Rutzinger* и др., 2008).

Већина актуелних *ITD* техника је још увек неефикасна за густе и сложене шуме по структури због високе стопе грешака уврштавања (енгл. *comission*) када су

детектовани врхови стабала који не постоје, и грешака изостављања (енгл. *omission*) када врх стабла није детектован алгоритмом (*Dong* и др., 2018). Детекција врхова крошње стабала мора бити обављена детаљно, јер ће прави врхови стабала који нису детектовани или који су погрешно детектовани довести до недовољне или претеране сегментације крошње стабала у каснијој фази (*Khosravipour* и др., 2014; *Zhao* и др., 2013). Претерана сегментација се дешава када се једна крошња подели на неколико кластера, док са недовољном сегментацијом неколико крошњи стабала буде спојено у један сегмент. Претерана сегментација се чешће јавља у лишћарским шумама (*Zhen* и др., 2016), јер се локални максимум који заправо није врх стабла може погрешно детектовати као врх стабла (*Yang* и др., 2016). Због тога су неки аутори покушали да спрече или минимизирају грешке недовољне или претеране сегментације користећи различите методе (*Dai* и др., 2018; *Lindberg* и др., 2014; *Liu* и др., 2015).

Велики број истраживача је вршио различите типове екстракције атрибута на основу *ALS* података, као што су: геометријски атрибути (*Dai* и др., 2018; *Jing* и др., 2012; *Wolf (né Straub)* и *Heipke*, 2007), атрибути 3Д уклапања облика (*Polewski* и др., 2015; *Reitberger* и др., 2009), атрибути суседства засновани на сопственим вредностима (*Cehata* и др., 2009; *Weinmann* и др., 2014; *West* и др., 2004) и метрике дрвећа (*Kathuria* и др., 2016; *Lisiewicz* и др., 2022b; *Wan Mohd Jaafar* и др., 2018).

До сада је објављено само неколико студија које се баве класификацијом *LM* у исправно и погрешно детектоване врхове стабала коришћењем *ITD* алгоритма заснованог на *CHM*-у (*Brodić* и др., 2022; *Kathuria* и др., 2016; *Lisiewicz* и др., 2022b). Истраживања у овој области била су више усмерена на смањење ефекта грешака сегментације како би се проценила тачност након побољшања класификације (*Dai* и др., 2018; *Holmgren* и *Lindberg*, 2019; *Krzystek* и др., 2020; *Mongus* и *Žalik*, 2015). Ово је извођено углавном без наглашавања тачности детекције грешака сегментације, или само уз наглашавање процентуалне разлике у постигнутом побољшању.

Најновија истраживања су највише окренута према коришћењу метода машинског учења за детекцију појединачних стабала (*Brodić* и др., 2022; *Kathuria* и др., 2016) и класификацији сегмената крошњи стабала у исправно, претерано или недовољно сегментоване (*Dai* и др., 2018; *Krzystek* и др., 2020; *Lisiewicz* и др., 2022b). *Dai* и др. су 2018. класификовали сегменте у исправно детектоване и претерано сегментоване са тачношћу од 84% користећи *SVM* као класификатор. У овом истраживању је одређено девет геометријских атрибута сегмената крошњи стабала који су коришћени као предикторске варијабле у класификацији. *Kathuria* и др. су 2016. развили *ITD* алгоритам заснован на приступу *LM* филтрирања којим се бира оптимални радијус претраге из облака тачака за детектовани *LM*. Они су као атрибуте користили метрике дрвећа добијене из локалног суседства тачака *LiDAR* података. За потребе класификације, одлучили су се за модел логистичке регресије (енгл. *Logistic Regression – LR*) истрениран над подацима добијеним од симулираних стабала и након тога су извршили тестирање модела над подацима добијеним ласерским скенирањем плантаже бора. *Lisiewicz* и др. су извршили свеобухватно истраживање где су се бавили детекцијом погрешно детектованих сегмената крошњи стабала (*Lisiewicz* и др., 2022b) и њиховом корекцијом (*Lisiewicz* и др., 2022a). *Lisiewicz* и др., су 2022b. развили методу за разликовање исправно и

погрешно детектованих сегмената крошњи стабала који су резултат *ITD* алгоритма заснованог на *СНМ*-у. Они су тестирали три методе машинског учења за класификацију: случајне шуме (*RF*), методу потпорних вектора (*SVM*) и *k*-најближих суседа (*kNN*), при чему је *RF* показао најбоље резултате. Групе атрибута биле су засноване на геометрији сегмента, структурним, као и интензитетским атрибутима облака тачака добијеним ласерским скенирањем из ваздуха. *Brodić* и др., су 2022. извршили побољшање резултата детекције врхова стабала у шумском подручју коришћењем пет метода машинског учења: случајне шуме, екстремног градијентног појачавања, вештачких неуронских мрежа, методе потпорних вектора и логистичке регресије. У њиховом истраживању је *RF* метода такође дала најбоље резултате са укупном тачношћу од 89% над тест подацима.

## 3 ТЕОРИЈСКЕ ОСНОВЕ

У овом поглављу прво су описане теоријске основе о методама машинског учења (поглавље 3.1). Затим су објашњене основе семантичке сегментације облака тачака које обухватају методологију са описом појединачних фаза тог поступка (поглавље 3.2). Поред начина претраге суседства у облаку тачака, представљени су најчешће коришћени атрибути у досадашњим истраживањима, врсте селекција најзначајнијих атрибута, као и методе машинског учења које се користе за семантичку сегментацију облака тачака. Потпоглавље 3.3 посвећено је методологији побољшања резултата методе детекције појединачних стабала коришћењем података ласерског скенирања из ваздуха. Последњи део поглавља покрива теоретске основе везане за мере перформанси које се користе за оцену тачности резултата семантичке сегментације/класификације (поглавље 3.4).

### 3.1 Методе машинског учења

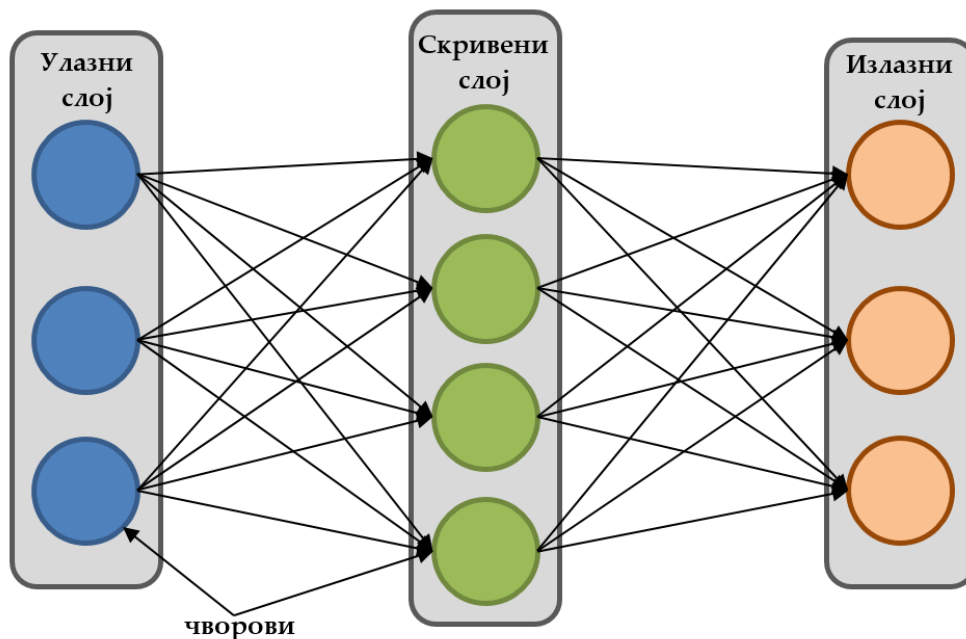
У оквиру овог потпоглавља дате су теоријске основе метода машинског учења које су коришћене за потребе решавања проблема код семантичке сегментације/класификације. У оквиру овог истраживања анализирана је и експериментално тестирана могућа примена десет метода машинског учења: вештачке неуронске мреже (*ANN*), метода потпорних вектора (*SVM*), логистичка регресија (*LR*), случајна шума (*RF*), градијентно појачавање (*GB*), екстремно појачавање градијента (*XGB*) и четири ансамбл методе слагања модела машинског учења са мета-моделима: случајне шуме – *ENS\_RF*, градијентног појачавања – *ENS\_GB*, вештачких неуронских мрежа – *ENS\_ANN* и наивног Бајеса – *ENS\_NB*. Такође је тестирана аутоматска метода машинског учења (*AML*) којом се врши аутоматски проналазак одговарајуће методе машинског учења којом се добијају најбољи резултати у погледу постигнуте тачности класификације.

#### 3.1.1 Вештачке неуронске мреже

Вештачка неуронска мрежа (енгл. *Artificial Neural Network – ANN*) је рачунарски систем учења који учи кроз мрежу међусобно повезаних слојева састављених од јединица које се зову чворови (енгл. *nodes*). Чворови су распоређени на улазном слоју, на једном или више скривених слојева и на излазном слоју. Чворови су међусобно повезани везама које имају дефинисану тежину и сваки чвор има свој праг вредности. Када излаз од једног чвора пређе одређени праг, наведени чвор се активира, а његови подаци се преносе на следећи слој у мрежи.

У овом раду, за класификацију је коришћена неуронска мрежа усмерена унапред (енгл. *feedforward*) са једним скривеним слојем (*Ripley, 1996*). Ово је најједноставнији тип вештачких неуронских мрежа када везе између чворова не

формирају циклус или петљу (*Schmidhuber, 2015*). Информације се крећу само ка напред, од улазних чворова, преко чворова скривеног слоја до излазних чворова. Наведени тип неуронских мрежа се показао ефикасним у раду са табеларним подацима.



Слика 3.1: Пример неуронске мреже са једним скривеним слојем.

### 3.1.2 Метода потпорних вектора

Метода потпорних вектора (енгл. *Support Vector Machine – SVM*) је непараметарска надгледана метода машинског учења коришћена и за класификацију и за регресију. Алгоритам се заснива на принципу минимизације (*Cortes и Vapnik, 1995*), и има за циљ да на основу означених (тренинг) података одреди класификациону хипер-раван или скуп хипер-равни како би поделио тест податке у унапред дефинисан број класа. Главни циљ *SVM* приступа је одређивање хипер-равни којом се постиже најбоља сепарација са највећом маргиналном удаљеношћу између најближих тачака две класе (*Thome, 2012*). Оптимална хипер-раван може бити одређена коришћењем израза (*Atik и др., 2021*):

$$f(x) = \omega^T x + b = \sum_{j=1}^N \omega_j x_j + b = 0 \quad (3-1)$$

где је  $x_j$  дати скуп примерака, док су  $\omega_j$  ( $j = 1, 2, \dots, n$ ) вектори нормала на хипер-раван и  $b$  скалар са којима се дефинише хипер-раван.

Подела се врши коришћењем оптималне максималне границе раздвајања између класа, са тачкама најближим границама које се називају „потпорни вектори“. *SVM* алгоритми користе скуп математичких функција које су дефинисане као језгра (енгл. *kernel*). Функција језгра је у томе да трансформише тренинг податке у захтевану форму за процесирање, тако да би се нелинеарна хипер–раван трансформисала у линеарну са више димензија. Различитим репрезентацијама облика језгра нуде се различита решења за лоцирање сложених хипер–равни између класа (*Cortes* и *Vapnik, 1995*; *Kebede* и др., 2022). Уобичајени типови језгра који се користе за класификацију су линеарни за линеарно одвојиве податке. Уколико то није случај, подаци се картирају у вишедимензионалном простору где су линеарно одвојиви неком од кернелских функција, као што су сигмоидна, полиномска, нормализациона, радијална базисна функција (енгл. *radial basis function – RBF*) и Лапласова радијална базисна функција (*Mallet* и др., 2008).

### 3.1.3 Логистичка регресија

Логистичка регресија (*Cox, 1958*) је статистички класификациони алгоритам базиран на вероватноћи, где се рачуна вероватноћа да излазна варијабла припада одговарајућој класи. Логистичком регресијом се генерише логистички модел за одређивање вероватноће да ли ће догађај да се деси или не (тзв. „шанса“ за дешавање догађаја), на основу датог скупа података независних варијабли. Алгоритам прави линеарну комбинацију атрибута (енгл. *features*) са вероватноћама излазне категоричке варијабле. Релационе хипотезе између категоричке излазне варијабле и једне или више категоричких улазних варијабли могу се објаснити и тестирати помоћу *LR* (*Peng* и др., 2002). Као резултат се за сваки примерак добија вероватноћа припадања одређеној категорији (класи). Логистичка регресија припада класи генерализованих линеарних модела. Математички модел за *LR* класификатор може се изразити као (*Duran* и др., 2021):

$$\ln \frac{P(Y=i)}{P(Y=C)} = \alpha_i + \sum_{j=1}^p \beta_j x_j \quad (3-2)$$

где је  $Y$  излазна варијабла,  $\alpha_i$  ( $i = 1, \dots, C$ ) и  $\beta_j$  ( $j = 1, \dots, p$ ) су коефицијенти модела, док су  $x_j$  ( $j = 1, \dots, p$ ) коваријате (предиктори). Основни математички концепт који дефинише логистичку регресију је логит функција, која се може дефинисати као природни логаритам односа двеју вероватноћа. Вредност природног логаритма се користи као коефицијент регресије класификатора логистичке регресије. Сваки примерак је додељен класи максималне вероватноће:

$$P(Y = i | X) = \frac{e^{\alpha_i + \sum_{j=1}^p \beta_j x_j}}{1 + e^{\alpha_i + \sum_{j=1}^p \beta_j x_j}} \quad (3-3)$$

### 3.1.4 Наивни Бајесов класификатор

Наивни Бајесов класификатор (енгл. *Naïve Bayes* – *NB*) припада фамилији алгоритама надзираног учења базираног на примени Бајесове теореме са „наивном“ претпоставком да постоји условна независност између сваког пара атрибута за добијену предиктовану вредност класе. Класификатор ради тако што одређује по једну функцију сепарације за сваку класу и додељује примерак класи у којој функција има највишу вредност (*Duda* и др., 2001). Функција сепарације за вектор атрибута која одговара и  $i$ -тој класи  $C_i$  може се изразити као (*Duda* и др., 2001):

$$f_i(E) = P(C_i) \prod_{j=1}^a P(A_j = v_{jk} | C_i) \quad (3-4)$$

где је  $A_j$  атрибут, а  $v_{jk}$  вредност атрибута  $A_j$ .

Класификатор добијен коришћењем наведеног скупа дискриминаторних функција којим се предиктују одговарајуће вероватноће у скупу података за тренирање је заправо Наивни Бајесов класификатор (*Domingos* и *Pazzani*, 1997). *NB* алгоритам је базиран на Бајесовој теореме условне вероватноће којом се оцењује вероватноћа везе између одређене тачке података  $x$  и класе  $C$  (*Dey* и др., 2016):

$$P(C|x) = \frac{P(x|C)}{P(x)} \quad (3-5)$$

при чему  $P(x)$  представља вероватноћу од  $x$  а  $P(C|x)$  условну вероватноћу класе  $C$  за дато  $x$ .

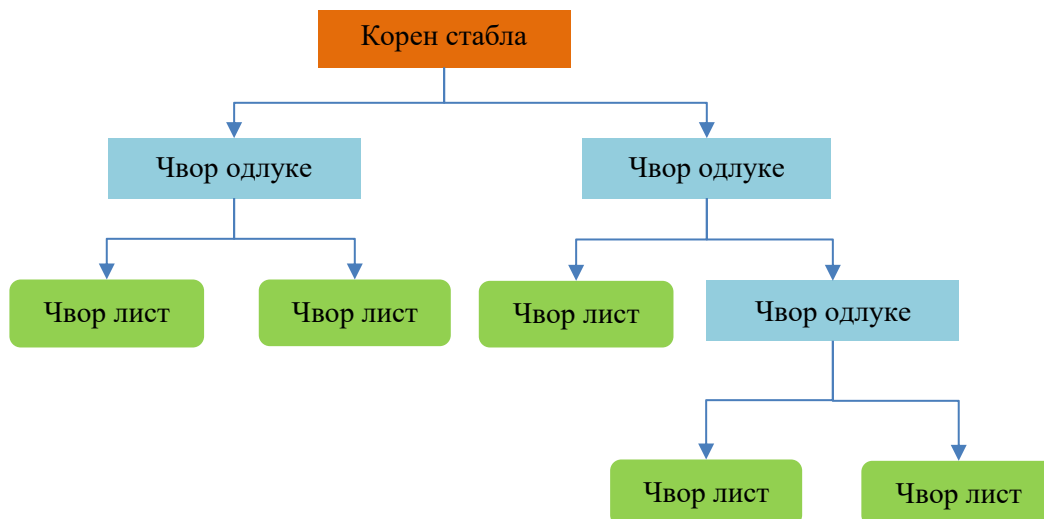
Гаусов Наивни Бајес (*Gauss Naïve Bayes* – *GNB*) је најчешће коришћен *NB* класификатор код ког се претпоставља да вероватноће атрибута следе Гаусову расподелу. Начин рачунања *GNB* дат је у следећој једначини (*Duran* и др., 2021):

$$P(x_i|C) = \frac{1}{\sqrt{2\pi\sigma_c^2}} \exp\left(-\frac{(x_i - \mu_c)^2}{2\sigma_c^2}\right) \quad (3-6)$$

### 3.1.5 Стабло одлучивања

Стабло одлучивања (енгл. *Decision Tree* – *DT*) је надзирана метода машинског учења која се најчешће користи за решавање проблема класификације (*Breiman* и др., 1984). То је класификатор са структуром стабла, где унутрашњи чворови представљају чворове одлуке, гране представљају правила одлучивања, а сваки завршни чвор (лист) представља излазну класу као резултат класификације. Почетни чвор одлуке стабла назива се корен стабла (Слика 3.2).





Слика 3.2: Општи изглед стабла одлучивања.

Класификација се врши тако што се прво у корену стабла врши упоређивање вредности атрибута посматраног примерка са вредношћу која је дефинисана у том чвору одлуке те се даље преусмерава на неку од грана. На тај начин се прође кроз све чворове одлуке на одређеној путањи и долази се до чвор листа који одређује циљну класу тј. резултат класификације посматраног примерка.

Приликом креирања стабла одлучивања, критичан је моменат избора одговарајућег атрибута и критеријума на основу којих се врши подела података на непреклапајуће и што хомогеније скупе у погледу циљне класе. Одабир најподеснијег атрибута утврђује се коришћењем функција којим се изражава нехомогеност или нечистоћа добијених подскупова (енгл. *impurity*). Мера нехомогености која је коришћена у овом истраживању је Џинијев индекс (енгл. *Gini index*) (Breiman и др., 1984). Џинијев индекс је заснован на уделима примерака различитих класа у укупном скупу и дефинисан је изразом (Kovačević, 2022):

$$G(S) = 1 - \sum_{i=1}^c \left(\frac{|S_i|}{|S|}\right)^2 \quad (3-7)$$

где је  $S$  почетни скуп података, а  $S_i$  резултујући подскупови са примерцима циљне класе  $C_i$ .

### 3.1.6 Ансамбл методе машинског учења

Код ансамбл метода машинског учења користи се више модела машинског учења како би се направио један оптимални модел за предикцију. Добијени модел би требало да има боље перформансе него сваки од модела појединачно. Генерална подела ансамбл метода машинског учења врши се на основу тога како се основна метода машинског учења користи у оквиру ансамбл методе: проста агрегација

(енгл. *bootstrap aggregation – bagging*), појачавање (енгл. *boosting*) и слагање (енгл. *stacking*).

У ансамбл методе са простом агрегацијом убрајају се методе случајне шуме и екстремно насумичних стабала. Градијентно појачавање и екстремно појачавање градијента су примери ансамбл метода са појачавањем. Ансамбл методе са слагањем модела се заснивају на томе да се више метода машинског учења, као што су метода случајне шуме, градијентно појачавање, наивни Бајес и вештачке неуронске мреже, комбинују како би се добио што бољи коначни модел.

### 3.1.6.1 Случајна шума и екстремно насумична стабла

Случајна шума (енгл. *Random Forest – RF*) је ансамбл метода машинског учења која се користи за класификацију и регресију (*Breiman, 2001*). Ансамбл случајне шуме заснива се на простој агрегацији већег броја стабала одлучивања, где се свако стабло формира над различитим подскуповима података. Свако стабло се гради коришћењем униформног узорковања са враћањем, које је познато и као „поновно узорковање“ (енгл. *bootstrap resampling*). Излазна вредност случајне шуме добија се агрегацијом резултата свих појединачних модела стабала који су истренирани над појединачним подскуповима података, при чему се већинско одлучивање користи код проблема класификације. *RF* класификатору се додељују два основна параметра: број стабала одлучивања која треба да буду генерисана и максималан број атрибута који се користе за поделу у сваком чвору како би се одредило најбоље место раздвајања. Као резултат наведених операција добија се укупна грешка модела која се рачуна као (*Atik и др., 2021*):

$$PE^* = PX,Y (mg(X,Y) < 0) \quad (3-8)$$

где је  $mg()$  маргинална функција. Овом функцијом се одређује разлика између средњег броја примерака који су додељени исправној класи ( $X$ ) и средњег броја примерака додељених било којој другој класи ( $Y$ ). Величина маргиналне вредности говори о поузданости класификације (*Lin и др., 2014*). *RF* најчешће користи Џинијев индекс као критеријум за место раздвајања како би се одредило по ком атрибуту треба раздвојити податке током фазе учења стабла одлучивања.

*RF* методом се одређује и мера важности атрибута (енгл. *Variable Importance Measure – VIM*), што је кључна предност у односу на друге алгоритме машинског учења (*Han и др., 2016*). Средње опадање тачности (енгл. *Mean Decrease Accuracy – MDA*) и средње опадање Џини индекса (енгл. *Mean Decrease Gini – MDG*) су две различите мере важности атрибута које се користе за идентификацију најрелевантнијих атрибута или приликом процедуре њихове селекције.

Једна од предности случајне шуме је та што се поновним узорковањем код случајне шуме постиже да су грешке појединачних стабала међусобно слабије корелисане. Ово даје робусније решење у односу на стабло одлучивања, јер је мања вероватноћа да ће доћи до претераног прилагођавања модела подацима (енгл. *overfitting*).

Још једна ансамбл метода заснована на случајној шуми којом се додаје додатна рандомизација целом процесу су екстремно насумична стабла (енгл. *Extremely Randomized Trees – ERT*) (Geurts и др., 2006). Главна разлика између наведених метода је у одабиру места раздвајања чворова. Код случајне шуме се бира оптимално место раздвајања док се код екстремно насумичних стабала место раздвајања бира насумично. Резултирајућа шума екстремно насумичних стабала садржи стабла која су варијабилнија, али и мање међусобно корелисана у односу на стабла у случајној шуми. Поред побољшане тачности, алгоритам екстремно насумичних стабала је рачунарски ефикаснији (Geurts и др., 2006).

### 3.1.6.2 Градијентно појачавање и екстремно појачавање градијента

Градијентно појачавање (енгл. *gradient boosting*) је такође ансамбл метода машинског учења формирана на основу стабала одлучивања. Основна идеја појачавања је инкрементално додавање модела у ансамбл узимајући у обзир понашање других модела. Нови модел који се додаје у ансамбл се гради тако да компензује грешке модела који већ јесу у ансамблу. На овај начин, модел по модел  $h_m(x)$ , врши се итеративно појачавање (енгл. *boosting*) ансамбла модела  $F_m$  (Kovačević, 2022):

$$F_{m+1}=F_m(x)+h_m(x) \quad (3-9)$$

где  $x$  представља скуп примерака над којима се креира модел.

Екстремно појачавање градијента (енгл. *eXtreme Gradient Boosting – XGB*) је један од најзаступљенијих приступа градијентног појачавања (Chen и Guestrin, 2016). Представља регуларизовано проширење традиционалних ансамбл метода појачавања, што га чини мање склоним претераном прилагођавању модела тренинг подацима.

### 3.1.6.3 Слагање модела

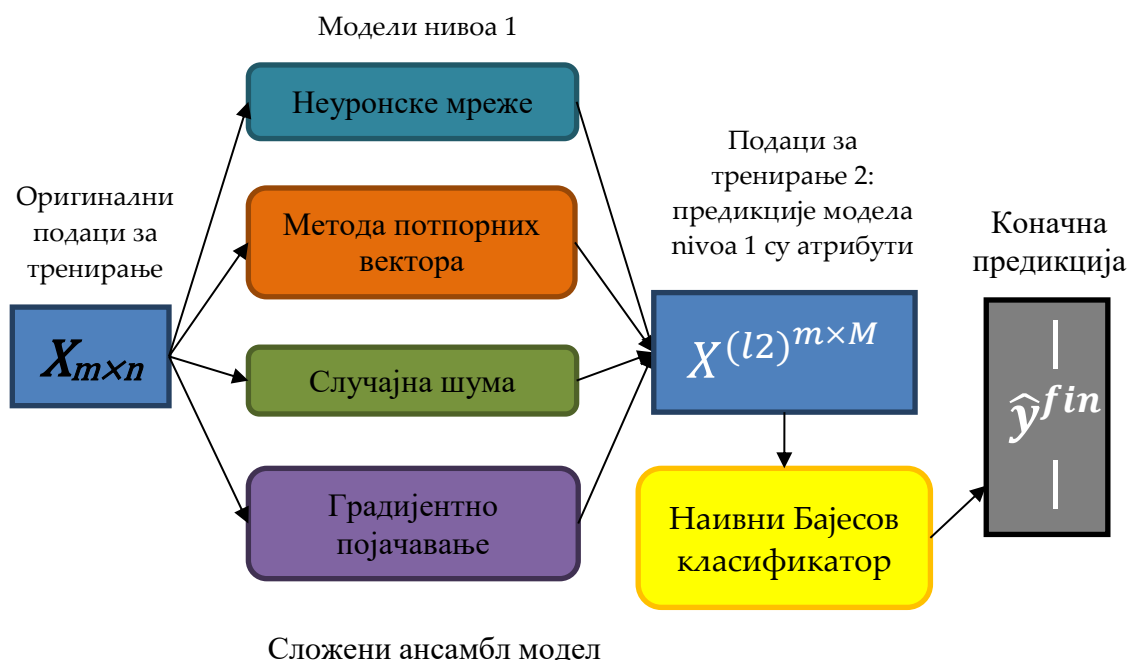
Код слагања модела (енгл. *stacking*) врши се тренирање модела базираног на комбинацији неколико модела машинског учења (Wolpert, 1992). За разлику од метода прости агрегације и појачавања, код метода слагања подразумева се коришћење више хетерогених „слабих модела“ који се комбинују да би се формирао „снажнији модел“. Код овог типа ансамбла се прво над истим подацима врши тренирање свих појединачних модела машинског учења првог нивоа. Затим се узимају све њихове предикције као улазни подаци за тренирање модела другог нивоа како би се добила што боља коначна предикција.

Уколико се модел добро конструише, слагањем модела се могу у потпуности искористити предности основних модела и добити бољи резултати од сваког модела појединачно, невезано од тога да ли се користи већинско гласање или осредњавање са додељеним тежинама (Ting и Witten, 1999). Такође се оваквим

моделима добијају робусније перформансе предикције у односу на појединачне моделе или осредњене ансамбл моделе машинског учења.

Тачност и разноликост основних модела значајно утиче на перформансе сложеног модела насталог њиховим слагањем (Dai и др., 2017). Разноликост (енгл. *diversity*) је мера зависности или комплементарности између модела (Kuncheva и Whitaker, 2003). Слагање основних модела који имају високу међусобну разноликост води до унапређења коначних резултата. Стога се слагање модела треба вршити само са основним моделима који уопште нису или су врло мало корелисани. Укупан број основних модела такође утиче на перформансе слагања модела, поред разноликости и тачности основних модела. Већи број основних модела неће увек значити и већу тачност предикције, али свакако ће захтевати искоришћавање додатног меморијског простора и укупног времена процесирања. У неким студијама је установљено да је довољно имати три до четири основна модела за слагање (Breiman, 1996).

Код примера сложеног ансамбл модела (Слика 3.3) као модели првог нивоа користе се неуронске мреже, метода потпорних вектора, случајна шума и градијентно појачавање, док се као модел другог нивоа (мета-модел) користи наивни Бајесов класификатор.



Слика 3.3: Пример сложеног ансамбл модела насталог слагањем појединачних модела.

За потребе овог истраживања, за моделе првог нивоа коришћене су методе случајне шуме, градијентног појачавања и логистичке регресије, док су за моделе другог нивоа (мета-моделе) коришћени: случајна шума (*ENS\_RF*), градијентно појачавање (*ENS\_GB*), наивни Бајес (*ENS\_NB*) и вештачке неуронске мреже (*ENS\_ANN*).

У теорији се обично постижу боље перформансе моделом насталим слагањем него сваким појединачним моделом машинског учења. Главна мана сложених модела

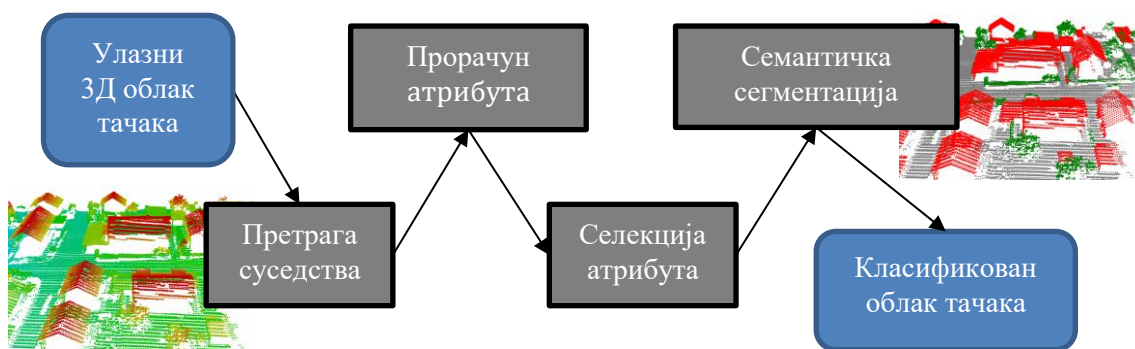
насталих слагањем је њихова комплексност, због чега се може знатно продужити укупно време тренирања модела. Уколико неки од основних модела има исте или боље перформансе од комбинованог модела, исти би требало и користити за даљу класификацију, зато што је лакши за опис и тренирање.

### **3.1.7 Аутоматске методе машинског учења**

Будући да је развијен велики број метода машинског учења, компликовано је испробавати сваку могућу методу над одређеним подацима и вршити тренирање модела са финим подешавањем хиперпараметара. За такав приступ би требало извршити пуно процесирања за шта би требало много времена, поготово ако се процесирање врши над великим скупом података са великим бројем генерисаних атрибута. Зато је у последње време актуелно аутоматизовање метода машинског учења тако што се за један проблем као што је класификација података на основу одређених атрибута у једном кораку може тестирати велики број различитих метода машинског учења и одабрати она која даје најбоље резултате. Строго гледано, аутоматска метода машинског учења коришћена у овој дисертацији није посебна метода машинског учења, већ софтверска имплементација више метода машинског учења где алгоритам проналази комбинацију сложене ансамбл методе машинског учења која даје најбоље перформансе за конкретне улазне податке.

## **3.2 Методологија семантичке сегментације облака тачака**

Устаљена процедура семантичке сегментације облака тачака (*Weinmann* и др., 2015a) (Слика 3.4) почиње дефинисањем суседства тачке тако што ће свакој појединачној тачки бити придружен одређен број околних тачака (поглавље 3.2.1). На основу 3Д геометрије дефинисаног суседства врши се рачунање различитих атрибута сваке тачке (поглавље 3.2.2) након чега се вредности атрибути облака тачака конвертују у растерске слике (растеризују). Затим се најчешће врши селекција најзначајнијих атрибута (поглавље 3.2.3) на основу којих ће се вршити тренирање модела машинског учења (поглавље 3.2.6). У тој фази се врши и одређивање оптималних хиперпараметара модела. Уколико се ради са великом количином података за тренирање, могуће је извршити претходно узорковање података (поглавље 3.2.4). Побољшање резултата семантичке сегментације може се постићи уклањањем шума просторном регуларизацијом ознака класа (поглавље 3.2.5). Истренираним моделом се врши семантичка сегментација тест података и оцењује се успешност семантичке сегментације преко различитих квантитативних мера перформанси над растерским продуктима облака тачака и самом облаку тачака (поглавље 3.4).



Слика 3.4: Методологија семантичке сегментације облака тачака.


### 3.2.1 Дефинисање суседства

Приликом одређивања атрибута неке тачке, најважније је правилно одабрати одговарајуће суседство које најбоље описује класу појаве којој та тачка припада. Понекад је боље истовремено разматрати више варијанти суседства тачке како би селекција суседства била универзалнија. Дефиниција суседства се базира на два приступа (*Blomley* и др., 2016):

- *Једноразмерно суседство* којим се описује локална 3Д структура са одређеном размером. Наведено суседство се најчешће дефинише са: а) сферним суседством (сфером претраге) формираним са свим тачкама које упадају у сферу фиксираниг полупречника описану око тачке (*Lee* и *Schenk*, 2002), б) цилиндричним суседством (цилиндар претраге) са свим тачкама које упадају у вертикални цилиндар чија оса пролази кроз тачку чије се суседство дефинише (*Filin* и *Pfeifer*, 2005) или в) суседством формираним са  $k \in \mathbb{N}$  најближих суседа наведене тачке (*Linsen* и *Prautzsch*, 2001). Величина размере се најчешће одређује на хеуристички или емпиријски начин, али постоји и неколико приступа где су аутори покушали да одреде параметар размере аутоматским путем (*Demantké* и др., 2011; *Mitra* и *Nguyen*, 2003; *Weinmann* и др., 2015a).
- *Вишеразмерно суседство* којим се може описати како се локална 3Д геометрија мења са различитим нивоом размере. За наведени приступ су коришћени цилиндри претраге са различитом величином полупречника (*Niemeier* и др., 2014; *Schmidt* и др., 2014), сфере претраге са различитим полупречником (*Brodu* и *Lague*, 2012) и комбинација цилиндара и сфера претраге са различитим полупречницима (*Blomley* и др., 2016). У свим наведеним случајевима се параметри размере (величине полупречника претраге) бирају хеуристичким или емпиријским путем на основу одређених знања о подацима и/или о самој сцени.

У овој дисертацији узимају се у обзир два начина претраге за дефинисање суседства у облаку тачака потребних за генерисање атрибута: први је сфера са одређеним полупречником, при чему је центар сфере у тачки чији се геометријски атрибути

одређују, а други приступ подразумева дефинисање вертикалног цилиндра претраге са одабраним полупречником (Слика 3.5).



Слика 3.5: Начини претраге суседства: а) лево, сфера претраге, б) десно, цилиндар претраге.

Наведени начини претраге за једноразмерно суседство су коришћени и код других аутора, али најчешће коришћењем само цилиндра претраге (*Chehata* и др., 2009; *Filin* и *Pfeifer*, 2005) или само сфере претраге (*Lee* и *Schenk*, 2002; *Linsen* и *Prautzsch*, 2001), док су неки истраживачи користили и оба начина претраге (*Blomley* и др., 2016). Разлика је и што су једни дефинисали суседство са полупречником претраге (*Chehata* и др., 2009; *Filin* и *Pfeifer*, 2005; *Lee* и *Schenk*, 2002), док су други формирали суседство коришћењем максималног број најближих суседа (*Linsen* и *Prautzsch*, 2001).

У овој дисертацији вредности полупречника претраге за цилиндри и сфере претраге били су 1 m, 1.5 m, 2 m и 3 m. Ово су вредности које су преузете од *Atik* и др., 2021. које су ти истраживачи користили у свом истраживању. Они су вршили претрагу само путем сфере, док су други аутори (*Niemeyer* и др., 2014; *Schmidt* и др., 2014) за ове податке додатно користили и полупречник претраге од 5 m, а претрагу суседства су вршили само коришћењем цилиндра претраге. Аутоматски приступ одређивања оптималног суседства базиран је на коришћењу сопствене енергије (енгл. *eigenentropy*) којим је одређен оптималан број суседа индивидуално за сваку тачку (*Weinmann* и др., 2015a). Управо је комбинација више типова претраге и више размера претраге за ове податке коришћена од стране *Blomley* и др., 2016., где су цилиндри претраге били формиран са полупречницима од 1 m, 2 m, 3 m и 5 m, док су сфере претраге биле формиране са оптималним бројем суседа као код *Weinmann* и др., 2015a. Мана код овог приступа били су поприлично лоши резултати семантичке сегментације, где се коришћењем више метода машинског учења за семантичку сегментацију показало да је највећу укупну тачност од 50.19% имао *LDA* класификатор.

### 3.2.2 Екстракција атрибута за семантичку сегментацију

Геометријски атрибути коришћени у овој дисертацији преузети су из великог броја студија које су се бавиле овом тематиком (*Cehata* и др., 2009; *Duran* и др., 2021; *Niemeyer* и др., 2014; *Pauly* и др., 2003; *Schmidt* и др., 2014; *Weinmann* и др., 2015a, 2014, 2013; *West* и др., 2004), а генерисани су и неки нови који су заступљени у софтверском систему *OPALS – Orientation and Processing of Airborne Laser Scanning data* (*Mandlbunger* и др., 2009; *Pfeifer* и др., 2014).

Геометријски атрибути било које тачке  $p$  облака тачака срачунати су са јединственим вредностима  $(\lambda_1, \lambda_2, \lambda_3)$  сопствених вектора  $(v_1, v_2, v_3)$  изведених од матрице коваријанси, при чему се коваријансе рачунају по формули:

$$\text{cov}(S) = \frac{1}{S} \sum_{p \in S} (p - \bar{p})(p - \bar{p})^t \quad (3-10)$$

где је  $\bar{p}$  центроид ослонца  $S$  (енгл. *support*). Велики број атрибута може бити срачунат коришћењем сопствених вредности као што су сума сопствених вредности, анизотропија, планарност, сферичност, линеарност, омниваријанса и др. За потребе овог истраживања, рачунање наведених вредности атрибута вршено је коришћењем софтверских модула *AddInfo*, *Normals*, *PointStats* и *EchoRatio* софтверског система *OPALS*.

У овој дисертацији, 29 атрибута је одређено за сваку тачку облака тачака. Неки од атрибута су засновани на већ расположивим карактеристикама који се добијају уз сваку тачку снимљену ласерским скенером (интензитет, редни број одбитка) док су други срачунати на основу локалне геометрије суседства тачке чији се атрибути оцењују (Табела 3.1). На основу добијених вредности атрибута тачака извршена је пројекција свих атрибута облака тачака у растерске слике са величином ћелије грида од 1 m.

Табела 3.1 Преглед коришћених атрибута за семантичку сегментацију облака тачака.

Број	Атрибут	Опис
1	<i>Amplitude</i>	јачина одбитка сигнала
2	<i>EchoNumber</i>	редни број одбитка
3	<i>EchoRatio</i>	однос одбитака као мера локалне транспарентности и неравности ( <i>Höfle</i> и др., 2009)
4	<i>RANGE</i>	распон – разлика висина највише и најниже тачке
5	<i>RANK</i>	ранг – релативан положај (0..100) тачке по висини унутар суседства
6	<i>MAX</i>	максимална вредност висине
7	<i>MIN</i>	минимална вредност висине
8	<i>PCOUNT</i>	укупан број тачака дефинисаног суседства
9	<i>PDENS</i>	однос броја тачака и површине цилиндра за претрагу или запремине сфере за претрагу
10	<i>PDIST</i>	просечна удаљеност између тачака у 2Д простору
11	<i>PosOpenness</i>	позитивна отвореност
12	<i>negOpenness</i>	негативна отвореност



13	<i>NormalEigenValue1</i>	највећа сопствена вредност $\lambda_1$
14	<i>NormalEigenValue2</i>	средња сопствена вредност $\lambda_2$
16	<i>NormalEigenValue3</i>	најмања сопствена вредност $\lambda_3$
16	<i>Anisotropy</i>	анизотропија $(\lambda_1 - \lambda_3)/\lambda_1$
17	<i>Planarity</i>	планарност $(\lambda_2 - \lambda_3)/\lambda_1$
18	<i>Curvature</i>	закривљеност $\lambda_3/(\lambda_1 + \lambda_2 + \lambda_3)$
19	<i>Sphericity</i>	сферичност $\lambda_3/\lambda_1$ као показатељ дистрибуције волумена
20	<i>Linearity</i>	линеарност $(\lambda_1 - \lambda_2)/\lambda_1$
21	<i>EigenvalueSUM</i>	сума сопствених вредности $\lambda_1 + \lambda_2 + \lambda_3$
22	<i>NormalizedZ</i>	$RANGE / RANK * 100$
23	<i>RelativeZ</i>	релативна висина тачке изнад дигиталног модела терена
24	<i>NormalSigma0</i>	стандардна девијација од оцене нормале
25	<i>Omnivariance</i>	омниваријанса – дескриптор 3Д дистрибуције тачака $\sqrt[3]{(\lambda_1 \lambda_2 \lambda_3)}$
26	<i>quadraticEntropy</i>	квадратна ентропија
27	<i>shannonEntropy</i>	ентропија дистрибуције тачака по висини
28	<i>stdDevMAD</i>	робустан процењивач стандардне девијације израчунат из медијане апсолутних одступања од медијане свих вредности атрибута
29	<i>Variance</i>	варијанса

### 3.2.3 Методе селекције атрибута

У циљу смањења времена процесирања потребног за тренирање модела машинског учења и каснију семантичку сегментацију облака тачака, било би пожељно извршити редукцију броја коришћених атрибута, али на такав начин да се не губи знатно на укупним перформансама. Редукцијом броја атрибута такође се смањује комплексност модела који се тренира тим подацима и стога га је и лакше интерпретирати. Овим поступком се смањује и могућност претераног прилагођавања подацима и тачност модела се чак и повећава уколико је одговарајући подскуп атрибута одабран (одстрањени атрибути који само уносе конфузију приликом класификације тј. шум у подацима).

У овом истраживању, као и у другим студијама које се баве обрадом *ALS* података, генерисан је велики број атрибута за процес класификације. Због тога је потребно смањити број атрибута како би се скратило време прорачуна и користили само они атрибути који су круцијални за тренирање модела. Тачност модела класификације може остати непромењена ако се користе само најважнији атрибути (*Millard* и *Richardson, 2013*), и смањењем броја атрибута може да се избегне претерано прилагођавање модела подацима у каснијој фази. Полази се од претпоставке да је велики број атрибута у високој корелацији, тако да је потребна одговарајућа метода селекције атрибута како би се изабрао коначни скуп атрибута и смањила могућност појаве мултиколинearности у моделима. Стандардни приступ подразумева да се прво елиминишу високо корелирани атрибути, а онда да се примене неке од метода селекције атрибута које су подељене у две основне категорије (*John* и др., 1994):

- *Омотач–методе* (енгл. *wrapper methods*) којима се оцењује више модела користећи процедуре додавања или уклањања атрибута, како би се нашла оптимална комбинација атрибута која даје најбоље перформансе модела.

Ове методе су заправо алгоритми претраге код којих се различите комбинације атрибута узимају као улаз и онда се оцењују перформансе модела као излаз који треба да се оптимизује.

- *Филтер–методе* (енгл. *filter methods*) којима се оцењује релевантност атрибута ван модела предикције и стога се моделују само атрибути који су прошли неки критеријум. Код проблема као што је класификација, сваки атрибут може да се индивидуално оцењује како би се проверило да ли постоји веза између тог атрибута и посматраних класа. Велики избор филтер метода описан је код *Saeys* и др., 2007.

И једна и друга категорија метода има своје предности и мане, тј. не постоји универзална метода селекције атрибута која ће се добро показати у свакој ситуацији. Омотач–методе су рачунарски захтевније, док филтер–методе оцењују сваки атрибут засебно и зато се може десити да су селектовани атрибути редундантни, односно високо корелисани. Код омотач–метода је пак већа вероватноћа да ће доћи до претераног прилагођавања подацима. Можда је најбољи приступ да се неком филтер–методом уклоне редундантни атрибути, а да се затим омотач–методом одабере подскуп најважнијих атрибута.

Код омотач–метода се важност атрибута мери на основу његове корисности при тренирању модела машинског учења. Код ових метода потребно је одлучити која метода машинског учења ће бити примењена и коју меру перформанси треба користити ради селекције најважнијих атрибута (Слика 3.6).



Слика 3.6: Принцип рада омотач–метода.

Вредност мере за оцену перформанси се одређују унакрсном валидацијом, при чему се код проблема класификације могу користити укупна тачност (енгл. *overall accuracy*), капа коефицијент слагања, површина испод *ROC* криве (енгл. *area under the ROC curve*) и др. Циљ је да се одреди онај подскуп атрибута са којим се постиже максимална вредност усвојене мере перформанси модела.


У овој дисертацији, коришћене су омотач методе селекције атрибута коришћењем генетских алгоритама (енгл. *Genetic Algorithms – GA*, детаљније објашњене у поглављу 3.2.3.1) и рекурзивне елиминације атрибута (енгл. *Recursive Feature Elimination – RFE*, детаљније објашњене у поглављу 3.2.3.2), при чему је рачунање критеријума важности вршено *RF* методом машинског учења. Примењене су омотач–методе јер се са њима увек може наћи комбинација атрибута са којом се добија највиша тачност модела, за разлику од филтер–метода код којих се могу отклонити и атрибути који могу бити веома битни за тренирање модела. Дуже време извршавања код ових метода није било проблематично када се радило са скуповима података у овој дисертацији. *RF* метода је коришћена јер се код тог

алгоритма истовремено рачуна и мера важности атрибута (*MDG*) на основу које може да се врши сортирање атрибута по важности и уклањање одређених атрибута рекурзивном елиминацијом атрибута. У неким радовима је установљено да је наведена мера поуздан индикатор важности атрибута (*Strobl* и др., 2007).

### 3.2.3.1 Селекција атрибута коришћењем генетских алгоритама

Као један од начина селекције атрибута коришћена је омотач–метода селекције подскупа атрибута коришћењем генетских алгоритама (енгл. *Genetic Algorithms – GA*). *GA* припада породици еволуционих алгоритама заснованих на биолошкој генетској еволуцији (*Mitchell, 1996*).

Комбинације атрибута се у генетским алгоритмима представљају као хромозоми у популацији (Слика 3.7). Генима су дефинисане позиције атрибута и њима се укључују и искључују појединачни атрибути (са вредностима 0 – укључен, и вредношћу 1 – искључен атрибут). У овом примеру дата су три хромозома који заправо представљају комбинацију шест атрибута, при чему је *A1* – празан скуп атрибута, *A2* – сви атрибути укључени, док је *A3* – укључени други, четврти и пети атрибут. Популација представља укупан број хромозома, тј. насумично генерисаних комбинација атрибута.



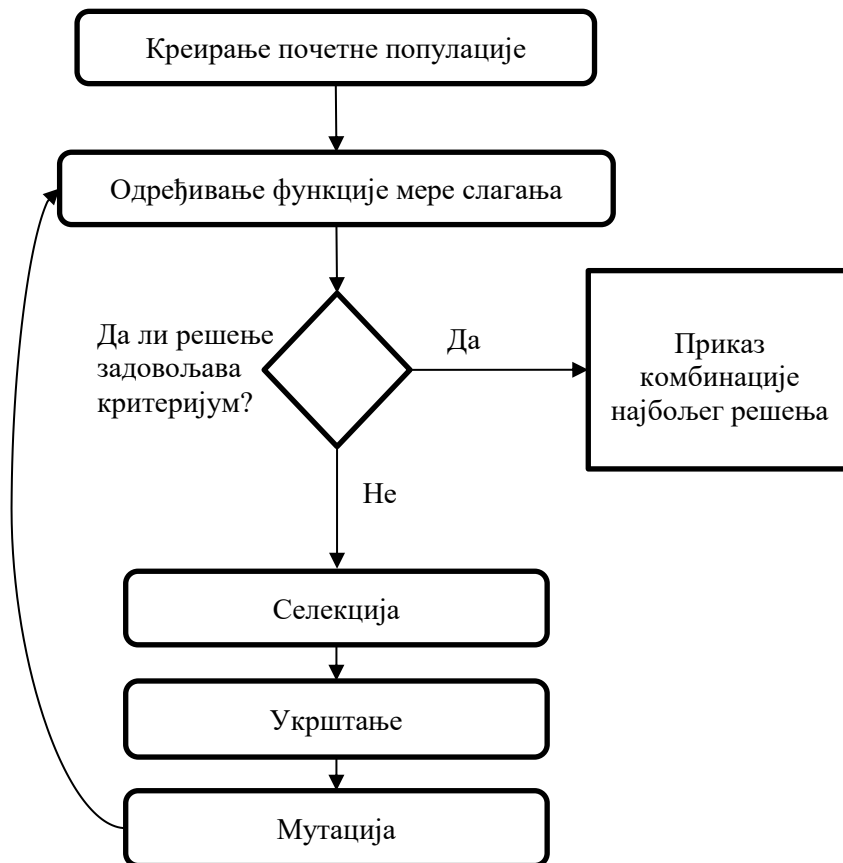
Слика 3.7: Илустрација комбинација атрибута као хромозома генетског алгоритама.

Основна идеја *GA* је да се генеришу насумичне комбинације атрибута и да се онда одреде комбинације које дају најбоља решења у итеративном процесу. Комбинације се генеришу коришћењем основних *GA* операција:

- *Селекција*: Задржававање комбинација са којима се добијају најбољи резултати у следећој генерацији (нпр. укупна тачност класификације).

- *Укрштање*: Креирање две нове комбинације на основу генома две комбинације. Ови наследници ће се појавити у следећој генерацији.
- *Мутација*: Промена насумичног гена у комбинацији (из 0 у 1).

Извршавањем наведених операција над сваком генерацијом популације, доћи ће до издвајања комбинација које дају све боље и боље резултате у наредним генерацијама (Слика 3.8). Успешност наведене комбинације атрибута биће одређивана рачунањем функције мере слагања. Процес се завршава или извршавањем свих итерација (генерација) алгоритма или постизањем унапред дефинисаног критеријума, као што је нпр. укупна тачност модела.



Слика 3.8: Принцип рада генетског алгоритма за селекцију подскупа атрибута.

### 3.2.3.2 Рекурзивна елиминација атрибута

Код омотач–методе рекурзивне елиминације атрибута (*RFE*) прво се истренира модел са свим атрибутима одабраном методом машинског учења. Затим се сваки атрибут рангира према важности коју има у истренираном моделу (*MDG*). Атрибути који су најниже ранжирани се елиминишу, па се тренирање модела понавља са редукованим бројем атрибута у новој итерацији. Поступак се понавља све док се не пронађе подскуп са што мање атрибута којим се добија модел са највећом вредношћу усвојене мере перформанси модела која се оцењује методом унакрсне валидације.

### 3.2.4 Узорковање тренинг података

Постоје различите методе којима се врши смањење количине података у циљу скраћења времена тренирања без великог утицаја на смањење перформанси модела. У овој дисертацији коришћено је класично партиционисање података са умањењем од по 10% укупне количине тренинг података при чему је вођено рачуна о томе да класе примерака остану балансиране. Довољна количина тренинг података којом се добијају најбоље перформансе у погледу тачности је проверавана тренирањем *RF* модела машинског учења над редукованим тренинг подацима и предикцијом над тест подацима. *RF* метода машинског учења је коришћена у овој дисертацији за ове потребе јер у већини случајева даје добре резултате и са мањим бројем стабала одлучивања. *RF* метода има кратко време извршавања, што је итекако битно кад се понавља тренирање модела више пута над различитим скуповима података.

### 3.2.5 Просторна регуларизација резултата семантичке сегментације

Као што је речено у претходним поглављима, традиционалним приступом семантичке сегментације одређују се локални атрибути за сваку тачку засебно, без узимања у обзир вероватноће припадности одређеној класи околних тачака. Тада се може десити да класа једне тачке буде другачија у односу на класу којој припадају тачке у њеном суседству. У овим случајевима постоји оправдана сумња да посматраној тачки такође треба придружити класу околних тачака, јер је вероватније да је извршена погрешна класификација као последица шума, него да је таква ситуација заиста и у реалности. Наведени приступ предложили су и *Weinmann* и др., 2015a. у виду просторног глачања ознака тачака (енгл. *spatially smooth labeling*). Наведено се постиже техникама глачања или техникама којима се укључују контекстуалне информације (*Han* и др., 2020; *Landrieu* и др., 2017; *Niemeyer* и др., 2016, 2014; *Schmidt* и др., 2014; *Steinsiek* и др., 2017; *Vosselman* и др., 2017; *Weinmann* и др., 2015b). Други термин који се користи за узимање просторне суседности означавања у обзир јесте просторна регуларизација (енгл. *spatial regularity*) коју су предложили *Blomley* и *Weinmann*, 2017. Наведеним техникама се уклања шум у класној заступљености тачака резултата семантичке сегментације.

Будући да се у овој дисертацији врши генерисање растерских слика атрибута на основу облака тачака, резултати семантичке сегментације биће такође добијени у виду растерских слика. Стога би просторну регуларизацију требало вршити над пикселима слике са вредношћу класа, што је лакше извести него над атрибутима класа тачака у склопу облака тачака. Једна велика мана наведене конверзије јесте губитак информација (енгл. *information loss*) приликом преласка из тродимензионалне у дводимензионалну представу података. Ово је највише изражено у случајевима када више тачака блиских по локацији а дистрибуираних по висини има различиту класу, нпр. код тачака које су измерене од ивица кровова зграде и терена поред ње.

Постоји више начина да се изврши просторна регуларизација класа, али један од једноставних и ефикасних јесте додељивање вредности класе која се најчешће појављује у том суседству ћелији у резултујућој слици (енгл. *majority*). На овај начин би пикселу у излазној слици била додељена вредност класе која има највећи број појављивања у том суседству. Овим приступом ће се одстранити усамљени пиксели одређених класа што ће имати утицај на повећање тачности семантичке сегментације, јер се отклања шум у добијеним резултатима.

### 3.2.6 Коришћене методе машинског учења

У овом истраживању, вршена је семантичка сегментација облака тачака добијена ласерским скенирањем из ваздуха коришћењем десет различитих метода машинског учења и једна процедура избора сложеног ансамбл модела машинског учења:

- Случајна шума (*RF*)
- Логистичка регресија (*LR*)
- Градијентно појачавање (*GB*)
- Екстремно градијентно појачавање (*XGB*)
- Метода потпорних вектора (*SVM*)
- Вештачке неуронске мреже (*ANN*)
- Ансамбл метода слагања модела машинског учења, где су *RF*, *LR* и *GB* модели првог нивоа, а модели другог нивоа (мета–модели):
  - Случајна шума (*ENS\_RF*)
  - Градијентно појачавање (*ENS\_GB*)
  - Наивни Бајесов класификатор (*ENS\_NB*)
  - Вештачке неуронске мреже (*ENS\_ANN*)
- Аутоматска метода машинског учења (*AML*)

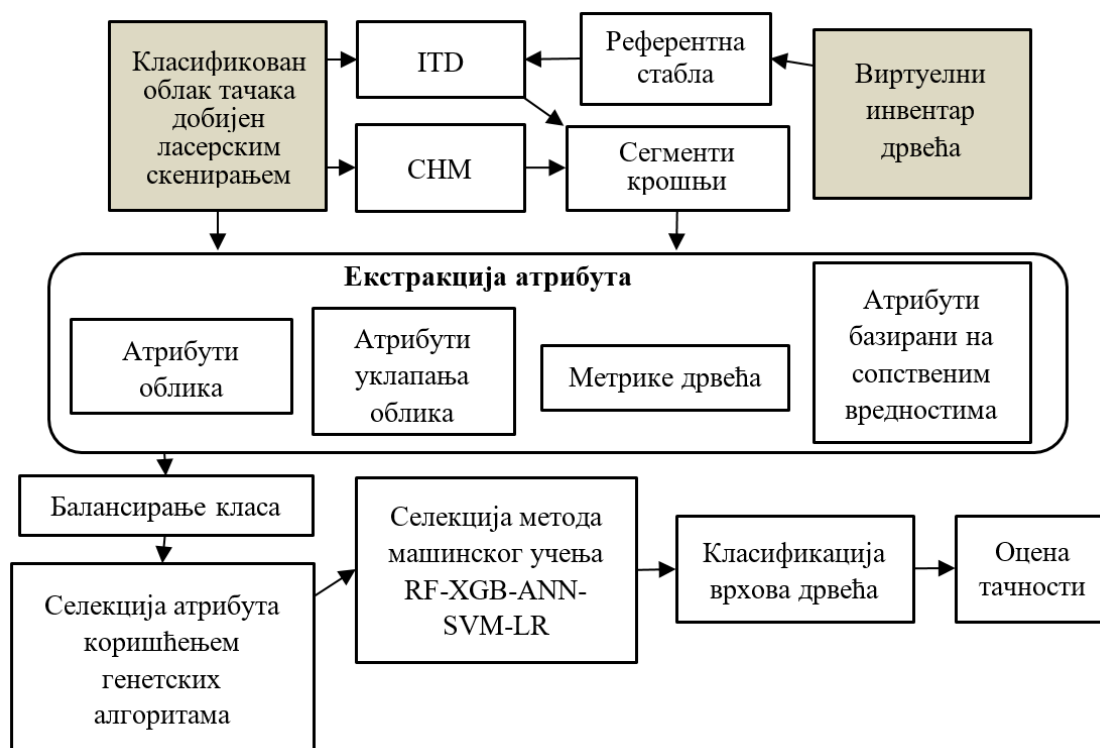
За имплементацију наведених метода коришћени су различити *R* пакети (Табела 3.2) *R* софтверског окружења (верзија 4.1.1) (“*R: The R Project for Statistical Computing*,” 2022) у *RStudio* (верзија 1.4.1717) развојном окружењу за *R*.

Табела 3.2. Коришћени модели машинског учења и одговарајућа библиотека за *R*.

Алгоритам	Метод/ <i>R</i> пакет
<i>RF</i>	<i>ranger</i> (Wright и Ziegler, 2017)
<i>XGB</i>	<i>xgboost</i> (Chen и др., 2022)
<i>SVM</i>	полиномски кернел/ <i>e1071</i> (Karatzoglou и др., 2022, 2004)
<i>ANN</i>	вештачка неуронска мрежа усмерена ка напред са једним скривеним слојем/ <i>nnet</i> (Venables и Ripley, 2002)
<i>LR</i> , <i>GB</i> , <i>ENS_RF</i> <i>ENS_GB</i> , <i>ENS_ANN</i> , <i>ENS_NB</i> , <i>AML</i>	сложени модели настали слагањем модела, <i>h2o</i> (LeDell и Poirier, 2020)

### 3.3 Методологија за побољшање резултата детекције појединачних стабала

Након извршене семантичке сегментације над *ALS* подацима, као једна од могућих примена над тачкама које припадају вегетацији је детекција појединачних стабала у шумском подручју. Методолошки оквир развијен за овај поступак почиње генерисањем *CHM*-а на основу тачака са нормализованим *ALS* висинама, који је затим интерполиран и углачан. Кандидати за врхове стабала детектовани су коришћењем добро успостављене *ITD* методе са филтрирањем локалних максимума (енгл. *Local Maxima – LM*) (Popescu и Wynne, 2004). Локални максимуми су даље коришћени као семе за раст региона у циљу добијања сегмената крошњи стабала на основу *CHM*. Кандидати за врхове стабала су затим означени у исправно и погрешно детектоване врхове користећи референтне податке стабала. У овом истраживању су одређене четири групе атрибута за сваки сегмент. Вршено је балансирање података према класама и селекција подскупа атрибута ради бољег раздвајања између исправних и погрешних детекција врхова стабала. Редуковани скупови атрибута су коришћени као тренинг подаци за класификацију коришћењем неколико метода машинског учења. На крају је модел класификације методе са најбољим перформансама примењен на тест подацима и извршена је оцена тачности класификације (Слика 3.9).



Слика 3.9: Методолошки оквир побољшања резултата детекције појединачних стабала.

### 3.3.1 Генерисање *CHM*-а, *ITD* и сегментација крошњи стабала

*CHM* ћелије грида од 0.5 m је генерисан коришћењем процедуре као што је описано у *Khosravipour* и др., 2014. Све *ALS* тачке изнад 2 m које представљају прве одбитке за сваку баферовану шумску парцелу коришћене су за генерисање *CHM*. *CHM* је накнадно додатно углачан и одстрањене су јаме попуњавањем пиксела без вредности.

Кандидати за врхове стабала су детектовани коришћењем *LM* филтрирања са фиксном величином прозора у облику квадрата. Ово је урађено коришћењем алгоритма публикованог у литератури (*Popescu* и *Wynne*, 2004). У овом поступку је коришћен за корак мањи прозор филтрирања од оптималног за сваку шумску парцелу, што је резултирало већим бројем кандидата за крошње стабала. Кандидат за врх стабла је једна *ALS* тачка која има највећу висину у одређеном суседству. *ITD* такође креира јединствени идентификатор за сваки сегмент крошње стабла и додељује га као атрибут свакој *ALS* тачки која припада том сегменту.

Алгоритам који су развили *Silva* и др., 2016. коришћен је за сегментацију крошњи стабала. Наведени алгоритам ради само са *CHM*-ом и стога сегменти крошње стабла имају назубљене, пикселизоване границе као резултат конверзије растера у вектор.

Генерисање *CHM*-а, детекција појединачних стабала (*ITD*) и сегментација крошњи стабала вршени су коришћењем *R* пакета *lidr* (*Roussel* и др., 2022) из *R* софтверског окружења (верзија 4.1.1) ("R: The R Project for Statistical Computing," 2022) у *RStudio* (верзија 1.4.1717) интегрисаном развојном окружењу.

### 3.3.2 Екстракција атрибута за детекцију врхова стабала

Генерисане су четири групе атрибута које су коришћене у овом истраживању: осам атрибута облика сегмента, 32 метрике дрвећа, 11 атрибута заснованих на сопственим вредностима и осам атрибута уклапања облика за сваки сегмент. Група атрибута заснована на сопственим вредностима је коришћена и приликом екстракције атрибута за потребе семантичке сегментације облака тачака (Табела 3.1). С обзиром на то да је сврха овог истраживања разликовање крошњи појединачних стабала у горњем делу крошње, атрибути су израчунати за све *ALS* тачке изнад половине средње висине стабла која припадају посматраној шумској парцели.

#### 3.3.2.1 Атрибути облика сегмента

Атрибути облика сегмента представљају морфометријске карактеристике полигона сегмента израчунате коришћењем функције *poly\_metrics* из *R* пакета *uavRst* (*Meyer* и *Reudenbach*, 2019). Ове карактеристике представљају неке од глобалних мера



облика (Haralick, 1974; Rosin, 2005). Укупно осам атрибута је одређено за ову групу атрибута (Табела 3.3).

Табела 3.3 Преглед атрибута облика сегмента.

Атрибути облика сегмента	Опис
<i>Lngt</i>	<i>length</i> – величина веће стране обухватног правоугаоника полигона
<i>ElnG</i>	<i>elongation</i> – однос дужине и ширине обухватног правоугаоника полигона
<i>EccBB</i>	<i>eccentricity bounding box</i> – однос веће и мање осе елипсе која описује полигон
<i>Solid</i>	<i>solidity</i> – однос површине полигона и површине конвексне љуске
<i>EccEgn</i>	<i>eccentricity eigenvalues</i> – сопствене вредности матрице ексцентрицитета
<i>Rect</i>	<i>rectangularity</i> – однос површине сегмента и површине његовог минималног обухватног правоугаоника (енгл. <i>Minimum Bounding Rectangle</i> )
<i>CircHar</i>	<i>Circularity Haralick</i> – Хараликова циркуларност облика (Haralick, 1974)
<i>Convex</i>	<i>Convexity</i> – конвексност, однос сопствених вредности (инерцијална оса)

### 3.3.2.2 Метрике дрвећа

Метрике дрвећа представљају дескриптивне статистике које се рачунају за сваки од сегмената *ALS* тачака коришћењем функције *stdmetrics* у *R* пакету *lidr* (Roussel и др., 2022), функције *CrownMetrics* имплементирани у *R* пакету *rLidar* (Silva и др., 2021) и функције *CloudMetrics* у софтверу *FUSION* (McGaughey, 2022). Табела 3.4 даје приказ метрика дрвећа са кратким описом метрике и софтверским решењем који се користи за њихово рачунање.

Табела 3.4 Преглед метрика дрвећа.

Метрика	Опис	Софтвер
<i>N</i>	број тачака сегмента крошње стабла	<i>lidr</i>
<i>Area</i>	површина растеризованог сегмента	
<i>Phabhm</i>	процент одбитака изнад средње висине	
<i>Hentr</i>	ентропија дистрибуције висине – нормализовани Шенонов индекс вертикалне сложености (Shannon, 1948)	
<i>Phabx</i>	процент одбитака изнад <i>x</i>	
<i>Hrcum</i> ( <i>x</i> = 1, ..., 9)	кумулативни процент одбитака у <i>i</i> -том слоју (Woods и др., 2008)	
<i>P</i> ( <i>x</i> = 1, 2, 3, 4, 5) <i>th</i>	процент <i>x<sup>th</sup></i> одбитака	
<i>Hmin</i>	минимална висина	<i>rLidar</i>
<i>Hmax</i>	максимална висина	
<i>Hmean</i>	средња висина	
<i>Hmed</i>	медијана висина	
<i>Hmod</i>	целобројни део висине који се најчешће појављује у сегменту	
<i>Hsd</i>	стандардна девијација дистрибуције висине	
<i>Hvar</i>	варијанса висине	
<i>Hcv</i>	коэффициент варијације висине	
<i>Hskew</i>	закривљеност дистрибуције висине	
<i>Hkurt</i>	мера врхуњења дистрибуције висине (енгл. <i>kurtosis</i> )	
<i>Hq</i> ( <i>x</i> =1, 5, ..., 95, 99)	<i>x<sup>th</sup></i> перцентил (квантил) дистрибуције висине	
<i>Ewidth</i>	ширина крошње стабла у источном правцу	

<i>Nwidth</i>	ширина крошње стабла у северном правцу	
<i>Diq</i>	интерквартилно растојање – мера дисперзије – разлика између трећег (75 перцентила) и првог квартила (25 перцентила)	<i>FUSION</i>
<i>Haad</i>	просечно апсолутно одступање висине	
<i>Hmadmed</i>	медијана апсолутних одступања од укупне медијане	
<i>Hmadmod</i>	медијана апсолутних одступања од укупне моде	
<i>HL(x = 1,2,3,4)</i>	L – моменти ( $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ )	
<i>HLcv</i>	L – моменти коефицијент варијације $\tau_2 = \lambda_1 / \lambda_2$	
<i>HLskew</i>	L – моменти закривљености $\tau_3 = \lambda_3 / \lambda_2$	
<i>HLkurt</i>	L – моменти мере врхуњења $\tau_4 = \lambda_4 / \lambda_2$	
<i>Hcrr</i>	однос рељефа крошње $((H_{mean} - H_{min}) / (H_{max} - H_{min}))$	
<i>Hsqmsq</i>	генерализоване средине за 2. степен (енгл. <i>height quadratic mean</i> )	
<i>Hsqmcube</i>	генерализоване средине за 3. степен (енгл. <i>height cubic mean</i> )	
<i>Hprofarea</i>	површина испод профила или криве висинског перцентила	

### 3.3.2.3 Атрибути базирани на сопственим вредностима

Атрибути базирани на сопственим вредностима одређени су коришћењем функције *stdshapemetrics* из *R* пакета *lidr* (Roussel и др., 2022) која је имплементирана на начин као што је то описано у Lucas и др., 2019. Наведени скуп атрибута, као и додатни параметри који су посебно коришћени за ово истраживање, описују дистрибуцију тачака суседства у простору (Chehata и др., 2009; Hoppe и др., 1992; Weinmann и др., 2014; West и др., 2004).

Поменути атрибути (линеарност, планарност и сферичност) и одређени додатни атрибути (анизотропија, закривљеност, омниваријанса, сопствена вредност и збир сопствених вредности), израчунати су за сваки сегмент ALS тачака (Табела 3.5). Наведени атрибути коришћени су и код семантичке сегментације облака тачака (Табела 3.1).

Табела 3.5 Преглед атрибута базираних на сопственим вредностима.

Атрибути базирани на сопственим вредностима	Опис
<i>NormalEigenValue1</i>	највећа сопствена вредност $\lambda_1$
<i>NormalEigenValue2</i>	средња сопствена вредност $\lambda_2$
<i>NormalEigenValue3</i>	најмања сопствена вредност $\lambda_3$
<i>Linearity</i>	линеарност $(\lambda_1 - \lambda_2) / \lambda_1$
<i>Planarity</i>	планарност $(\lambda_2 - \lambda_3) / \lambda_1$
<i>Sphericity</i>	сферичност $\lambda_3 / \lambda_1$
<i>Anisotropy</i>	анизотропија $(\lambda_1 - \lambda_3) / \lambda_1$
<i>Curvature</i>	закривљеност $\lambda_3 / (\lambda_1 + \lambda_2 + \lambda_3)$
<i>Omnivariance</i>	омниваријанса $\sqrt[3]{(\lambda_1 \lambda_2 \lambda_3)}$
<i>Eigentropy</i>	ентропија сопствених вредности $-(\lambda_1 \ln(\lambda_1) + \lambda_2 \ln(\lambda_2) + \lambda_3 \ln(\lambda_3))$
<i>EigenvalueSUM</i>	сума сопствених вредности $\lambda_1 + \lambda_2 + \lambda_3$

### 3.3.2.4 Атрибути уклапања облика

Модул *ZonalFit* софтверског система *OPALS* коришћен је за прорачун атрибута заснованих на уклапању полиномске површине другог реда на тачке које припадају сегменту крошње стабла (*Mandlburger* и др., 2009; *Pfeifer* и др., 2014). Минимум, максимум, медијана и средња квадратна грешка резидуала уклапања тачака одређени су коришћењем стриктног изравнања методом најмањих квадрата (Табела 3.6). Исти атрибути одређени су и са робусном оценом како би се елиминисале грубе грешке (атрибути са *robquad* у свом имену).

Табела 3.6 Преглед атрибута уклапања облика.

Атрибути уклапања облика	Опис
<i>Minquad</i>	минимум резидуала уклапања тачака на полиномску површину
<i>Maxquad</i>	максимум резидуала уклапања тачака на полиномску површину
<i>Medquad</i>	медијана резидуала уклапања тачака на полиномску површину
<i>RMSquad</i>	средња квадратна грешка резидуала уклапања тачака на полиномску површину
<i>Minrobquad</i>	робусни минимум резидуала уклапања тачака на полиномску површину
<i>Maxrobquad</i>	робусни максимум резидуала уклапања тачака на полиномску површину
<i>Medrobquad</i>	робусна медијана резидуала уклапања тачака на полиномску површину
<i>RMSrobquad</i>	робусна средња квадратна грешка резидуала уклапања тачака на полиномску површину

### 3.3.3 Балансирање класа скупа података

У овом поглављу разматран је утицај на резултате класификације који се добија балансирањем тренинг података према класама, као и начини којима се синтетички генеришу примерци који припадају мањинској класи. Израчунате метрике и атрибути коришћени су као предикторске варијабле током тренирања модела класификације. Пре ове процедуре, изведено је неколико корака како би се смањио број атрибута и балансирао скуп података према заступљеним класама. Укупна тачност се не може користити као одговарајућа мера перформанси модела уколико се ради са небалансираним скупом података. Небалансирана дистрибуција примерака у погледу класне припадности има и штетан ефекат на процес тренирања модела (*Chen* и др., 2004; *Criminisi* и *Shotton*, 2013). Уколико би се извршило узорковање примерака који припадају већинској класи, могло би се десити да би се кључни подаци изгубили и због наведеног поступка опала ефикасност касније класификације. Зато је пожељније извршити генерисање синтетичких примерака који припадају мањинској класи.

Због неуравнотеженог односа примерака који припадају класи врхова стабала и оним који то нису, генерисање додатних примерака за мањинску класу погрешно детектованих врхова стабала изведено је коришћењем *ADASYN* алгоритма (*ADaptive SYNthetic sampling approach for imbalanced learning – He* и др., 2008), као

унапређене верзије *SMOTE* алгоритма (*Synthetic Majority Oversampling Technique – Chawla и др., 2002*).

*SMOTE* је техника синтетичког узорковања примерака која синтетише нову мањинску инстанцу између једне мањинске инстанце и њених  $k$  најближих суседа. Мањинска класа је допуњена узимањем сваког узорка који припада мањинској класи и генерисањем синтетичких примерака за ту класу. Ово се врши спајањем сегмената од  $k$  – најближих суседа који припадају мањинској класи. *SMOTE* приступом се могу постићи бољи резултати од самог подузорковања (енгл. *undersampling*) примерака који припадају већинској класи или дуплицирања постојећих примерака који припадају мањинској класи (енгл. *oversampling*).

*ADASYN* алгоритам заснива се на идеји адаптивног генерисања примерака мањинске класе према њиховим дистрибуцијама класа у суседству. Код овог алгоритма се стога води рачуна и о „нечистоћи“ (енгл. *impurity*) суседства у погледу класне заступљености. То подразумева увођење тежина као односа броја суседа који припадају мањинској класи и броја суседа који припадају већинској класи. Већа тежина додељена синтетичком примерку је показатељ да је теже научити модел да класификује такав примерак у мањинску класу. Коришћењем овог алгоритма генерише се већи број синтетичких података за примерке који припадају мањинској класи са којима се теже учи, у односу на оне примерке мањинске класе са којима је лакше учење модела. Највеће предности овог поступка у односу на *SMOTE* су у томе што се не врши класично умножавање примерака који припадају мањинској класи и што се генерише више примерака са којима је теже научити модел.

### 3.3.4 Означавање класа врхова стабала

Срачунати атрибути су додељени кандидату за врх стабла који припада одговарајућем сегменту крошње стабала. Ознаке које одређују да ли откривени *LM* представља исправно или погрешно детектован врх стабла, а које су одређене поређењем са референтним стаблима (близина локације и висинска разлика), додељују се кандидату за врх стабла. Пратећи стратегију коју су предложили *Reitberger* и др. 2009., сматра се да је врх стабла исправно детектован ако је: (1) растојање између кандидата за врх стабла и одговарајућег референтног стабла мање од 60% средње удаљености између стабала унутар шумске парцеле и (2) висинска разлика између кандидата за врх стабла и референтног стабла мања од 20% висине највећег стабла у шумској парцели.

## 3.4 Оцена тачности класификације

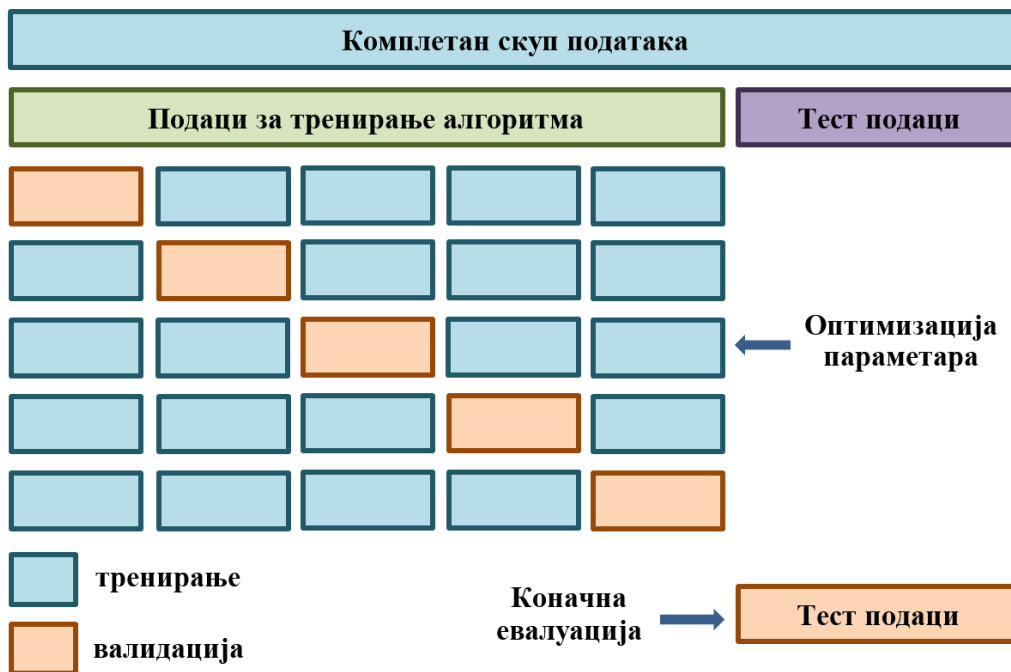
У овој дисертацији коришћене су различите методе за одређивање вредности хиперпараметара за тренирање модела машинског учења и за квантитативну оцену перформанси модела. За оцену квалитета приликом тренирања модела коришћена је унакрсна валидација са оценом средње укупне тачности док су за коначну

тачност класификације узете квантитативне мере добијене предикцијом над тест подацима и то: укупна тачност (енгл. *overall accuracy*), капа коефицијент слагања (енгл. *kappa coefficient of agreement*), одзив (енгл. *recall*), прецизност (енгл. *precision*), F1 скор (енгл. *F1 score*) и пресек преко уније (енгл. *intersection over union*). Унакрсна валидација и наведене квантитативне мере перформанси су детаљно описане у наредним поглављима.

### 3.4.1 Унакрсна валидација

Унакрсна валидација (енгл. *cross-validation*) је статистички метод који се користи за оцену перформанси модела и за фину параметризацију модела (енгл. *hyperparameters tuning*). Циљ кросвалидације је одређивање коначних хиперпараметара за што боље перформансе модела. Кросвалидација подразумева поступак да неки подаци не учествују у изградњи модела, тј. изостављају се из скупа улазних података и користе се само за валидацију. Поступак се огледа у томе да се подаци поделе на одређен број једнаких или скоро једнаких непреклапајућих подскупова. После тога се узима један део и задржава као валидациони скуп података, док се преостали делови обједињују у један скуп података који служи за тренирање модела. Затим се валидациони скуп података даље користи за оцену перформанси добијеног модела, постигнута тачност се меморише и цео процес се понавља за други подскуп података који ће се користити као валидациони. На крају се укупна оцена квалитета модела добија као осредњена вредност свих оцена перформанси модела добијених предикцијом над издвојеним појединим подскуповима података који су се користили за валидацију (Слика 3.10).

У овој дисертацији примењена је унакрсна валидација код параметризације модела која се врши над подскупом података издвојеним за потребе тренирања модела семантичке сегментације. Предикцијом над тест подацима добија се коначна оцена модела. Скупови података који се користе у овом истраживању су, према условима коришћења јавно доступних података, већ подељени на део за тренирање и део за тестирање рада алгоритма. На овај начин нема места за „улепшавање“ резултата класификације избором делова података који ће се користити за тренирање и за тестирање алгоритма. Стога је и поређење добијених резултата са резултатима алгоритма других аутора исправно јер се врши над истим подацима.



Слика 3.10: Пример одређивања хиперпараметара методе машинског учења коришћењем петоструке унакрсне валидације над тренинг подацима. Тест подаци служе за финалну евалуацију.

### 3.4.2 Квантитативне мере перформанси модела

Мере перформанси модела добијају се поређењем предиктованих класа тачака у тест скупу података са референтним ознакама класа за те тачке. Наведено поређење се може сагледати у матрици конфузије за вишекласни проблем (Слика 3.11).

		Референтна класа		
		А	В	С
Предиктована класа	А	$TP_A$ – тачно предвиђена припадност	$FP_A$ – нетачно предвиђена припадност	$FP_A$ – нетачно предвиђена припадност
	В	$FN_A$ – нетачно предвиђена неприпадност	$TN$ – тачно предвиђена неприпадност	$TN$ – тачно предвиђена неприпадност
	С	$FN_A$ – нетачно предвиђена неприпадност	$TN$ – тачно предвиђена неприпадност	$TN$ – тачно предвиђена неприпадност

Слика 3.11: Матрица конфузије за три класе са ознакама броја исправних и погрешних погодака за класу А.

Матрица конфузије намењена за семантичку сегментацију облака тачака има више класа (три или четири), док је класификацију врхова стабала у исправне и погрешне бинарна јер садржи само две класе. Стога се и матрица конфузије проблема класификације врхова стабала састоји из два реда и две колоне са класама исправно и погрешно детектованих врхова стабала.

Вредности у матрици конфузије представљају број примерака скупа података намењеног за тестирање модела који су исправно класификовани (елементи по дијагонали матрице конфузије) и примерака којима су класе погрешно предиктоване (елементи ван дијагонале матрице конфузије). Бројеви предиктованих примерака по класама дати су по редовима матрице, док колоне представљају бројеве примерака који припадају стварним, референтним ознакама класа. Свака ћелија у матрици има број који представља укупан број предиктованих/референтних вредности комбинације.

*TP* (енгл. *true positive*) је тачан погодак за неку класу ако је исправно означен од стране модела, док је *TN* (енгл. *true negative*) тачан промашај за неку класу ако је стварна и предиктована класа припадају другој класи. Ови елементи се налазе на дијагонали матрице конфузије. *FP* је нетачан погодак (енгл. *false positive*) који је нетачно означен као та класа, док је *FN* нетачан промашај (енгл. *false negative*) који припада тој класи али је нетачно означен као припадник друге класе. *FP* и *FN* елементи се налазе ван дијагонале матрице конфузије.

Будући да се код јавно доступних података ласерског скенирања коришћених у овој дисертацији прецизност, осетљивост/одзив,  $\Phi 1$  скор, пресек преко уније и укупна тачност користе за оцењивање перформанси означавања класа 3Д облака тачака, и у овој дисертацији су такође ове мере усвојене. Поред наведених, капа коефицијент слагања (енгл. *kappa coefficient of agreement* –  $\kappa$  – *Olofsson* и др., 2014), је такође срачунат како би са укупном тачношћу био коришћен за оцену квалитета класификације сваким моделом машинског учења.

Укупна тачност (*OA*) је мера којом се оцењује удео тачака које су исправно класификоване и дефинисана је као проценат исправно класификованих тачака у односу на укупан број тачака у скупу података за тестирање. Рачуна се као однос суме дијагоналних чланова са сумом свих чланова матрице конфузије:

$$OA = \frac{N_I}{N_U} \quad (3-11)$$

где је  $N_I$  укупан број тачних погодака, а  $N_U$  укупан број свих примерака у скупу података за тестирање. Овом мером перформанси модела се свеукупно гледа на то како модел предиктује над целим скупом података.

Капа коефицијент слагања ( $\kappa$ ) је квантитативна мера перформанси базирана на укупној тачности, коригована за случајне утицаје. Добија се по следећој формули (*Cohen, 1960*):

$$\kappa = \frac{OA - SU}{1 - SU} \quad (3-12)$$

где *SU* представља случајни утицај.

Прецизност представља способност класификатора да од свих предикција пронађе предикције класе које су заправо исправне. Другим речима, прецизност говори колико се може веровати моделу када предиктује неки примерак као исправан. Прецизност неке класе представља однос тачних предвиђања припадности класи и укупног броја предвиђања за класу  $k$  (тачних и погрешних):

$$P_k = \frac{TP_k}{TP_k + FP_k} \quad (3-13)$$

где број тачних погодака  $TP_k$  за одређену класу  $k$  представља примерке који су исправно означени, док су нетачни погодци  $FP_k$  примерци који су погрешно означени као припадници класе  $k$  (Слика 3.11). Укупан број предикција класе  $k$  ( $TP_k + FP_k$ ) добија се кад се саберу сва поља у реду који се односи на класу  $k$ .

Кроз осетљивост или одзив (енгл. *recall*) се сагледава способност класификатора да правилно предиктује класу примерака који припадају тој класи. Осетљивост се добија као однос броја тачно класификованих примерака и укупног броја припадника те класе, невезано за то да ли су исправно предиктовани или не:

$$R_k = \frac{TP_k}{TP_k + FN_k} \quad (3-14)$$

где су нетачни промашаји  $FN_k$  примерци који припадају класи  $k$  али су означени као припадници друге класе (Слика 3.11). Укупан број стварних припадника класе  $k$  ( $TP_k + FN_k$ ) добија се кад се саберу сва поља у колони која се односи на класу  $k$ .

F1 скором као мером перформанси, покушава се да се измери способност модела да добро предиктује све класе. Ова мера се уводи у случају небалансираног скупа података када би нпр. могло да резултује у веома високом одзиву док би прецизност била веома ниска, или обрнуто. Рачуна се као хармонијска средина прецизности и осетљивости:

$$F1_k = 2 * \frac{P_k * R_k}{P_k + R_k} \quad (3-15)$$

где је  $P_k$  прецизност а  $R_k$  осетљивост. F1 скор стога узима у обзир и прецизност и осетљивост модела класификације и генерално је погоднији у случају кад класе у подацима нису подједнако заступљене. F1 скор може узимати вредности од 0 до 1. Релативан допринос прецизности и одзива је подједнак у F1 скору и хармонијска средина је корисна за проналажење најбољег компромиса између ове две мере (*Sasaki, 2007*).

За један коришћени скуп података било је потребно срачунати и средњу вредност пресека преко уније (енгл. *mean Intersection over Union – mIoU*) за све класе, док се пресек преко уније (*IoU*) за сваку класу  $k$  добија као:

$$IoU_k = \frac{TP_k}{TP_k + FP_k + FN_k} \quad (3-16)$$



## 4 РАСПОЛОЖИВИ СКУПОВИ ПОДАТАКА ЛАСЕРСКОГ СКЕНИРАЊА

У овој дисертацији дат је преглед неколико јавно доступних скупова података превасходно намењених за такмичења у семантичкој сегментацији облака тачака добијеног ласерским скенирањем из ваздуха. Скупови података се разликују у величини подручја које је снимано, густини облака тачака и заступљеним класама тачака које припадају различитим типовима објеката на том подручју. Такође су описани и скупови података ласерског скенирања који обухватају искључиво шумска подручја и намењени су за детекцију појединачних стабала. Експериментима вршеним у овој докторској дисертацији обухваћени су скупови података *ISPRS* (поглавље 4.1), *GRSS* (поглавље 4.2) и подаци ласерског скенирања коришћени за индивидуалну детекцију стабала (поглавље 4.6).

### 4.1 *ISPRS* скуп података за семантичку сегментацију облака тачака

Међународна заједница за фотограметрију и даљинску детекцију (енгл. *International Society for Photogrammetry and Remote Sensing – ISPRS*) је невладина организација посвећена развоју међународне сарадње за унапређење фотограметрије и даљинске детекције и њихових примена. Једна од главних активности овог удружења јесте подстицање научних истраживања у области фотограметрије и даљинске детекције. Један од начина да се ове активности подстакну је и обезбеђивање јавно доступних скупова података који ће истраживачима омогућити верификацију предложених метода и поређење добијених резултата.

Управо зато ова заједница повремено објављује и поставља различите скупове података ласерског скенирања и фотограметријског снимања који се могу користити за упоређивање резултата различитих алгоритама у циљу детекције и реконструкције различитих типова објеката као што су нпр. зграде, путеви итд. За такмичење у урбаној класификацији, реконструкцији 3Д зграда и семантичкој сегментацији намењени су подаци фотограметријског и *LiDAR* снимања насеља Потсдам и Фајхинген у Немачкој (*Cramer, 2010; Niemeyer* и др., 2014; *Rottensteiner* и др., 2012). За подручје неколико блокова Фајхингена извршено је ласерско скенирање и семантичка сегментација добијеног облака тачака, тако да се он

користи за поређење резултата семантичке сегментације добијених различитим методама<sup>1</sup>.

Подручје од интереса укључује три раздвојена региона покривена са укупно десет редова скенирања изведених *Leica ALS50* системом, на просечној висини лета од 500 m изнад земље и са углом гледања од 45° (*Cramer, 2010*). Просечна густина тачака унутар појединачног реда скенирања била је 4 тачке/m<sup>2</sup>. Подаци о облаку тачака дати су у виду текстуалног фајла, где се за сваку тачку у једном реду чувају просторне 3Д координате (XYZ), вредност интензитета, укупан број одбитака, редни број одбитка и шифра једне од девет класа којој тачка припада (Табела 4.1).

Табела 4.1 Шифре класа, њихов опис и укупан број припадајућих тачака за сваку класу.


Шифра класе	Опис класе	Број тачака	
		Тренинг подаци	Тест подаци
0	Далеководи	546	600
1	Ниска вегетација	180 850	98 690
2	Непропусне површине	193 723	101 986
3	Аутомобили	4 614	3 708
4	Ограде	12 070	7 422
5	Кровови	152 045	109 048
6	Фасаде	27 250	11 224
7	Жбуње	47 605	24 818
8	Дрвеће	135 173	54 226
Укупно тачака		753 876	411 722

Према условима коришћења *ISPRS* података, три региона снимања су подељена у два дела; један за тренирање алгоритма и два за тестирање успешности алгоритма (Слика 4.1). Треба напоменути да су у оквиру овог истраживања подаци за тестирање служили искључиво за коначну евалуацију добијеног модела, тј. они нису били коришћени приликом тренирања или валидације модела.

За потребе ове дисертације разматране су само тачке које припадају ниској вегетацији, непропусним површинама, крововима и дрвећу. Ово је изведено са циљем лакшег поређења са резултатима других аутора и предикције моделом истренираним другим скупом података који су се користили у овој дисертацији. Тачке које припадају класама далеководи, аутомобили, ограде, фасаде и жбуње су елиминисане зато што су имале премало примерака које припадају тој класи. Исти приступ у погледу одабира класа изведен је у истраживању од стране *Atik* и др., 2021. Треба додати да тачке које припадају класама ограде, фасаде и жбуње имају

<sup>1</sup> <https://www.isprs.org/education/benchmarks/UrbanSemLab/3d-semantic-labeling.aspx>.

веома сличне карактеристике у геометријском смислу и било би веома тешко раздвајати тачке које припадају овим класама. Стога се коришћени скуп података састоји из дела предвиђеног за тренирање модела који садржи 661 791 тачака и дела за тестирање који садржи 363 950 тачака.



Слика 4.1: Тренинг (лево) и тест (десно) *ISPRS* скуп података са колоризованим класама тачака.

Условима коришћења ових података дефинисано је да укупна тачност (*OA*) буде коришћена као једна од мера за оцену перформанси семантичке сегментације 3Д облака тачака. Наведеном мером се оцењује свеукупна тачност класификације за све класе и дефинисана је као проценат правилно класификованих тачака у односу на укупан број тачака у скупу података који служи за тестирање алгоритма.


## 4.2 *GRSS* скуп података ласерског скенирања

Удружење за геонауке и даљинску детекцију (енгл. *The Geoscience and Remote Sensing Society – GRSS*) Института инжењера електротехнике и електронике (енгл. *Institute of Electrical and Electronics Engineers – IEEE*) публиковало је скуп података *Urban Semantic 3D (US3D)* добијен ласерским скенирањем из ваздуха ради упоређивања резултата различитих алгоритама 3Д семантичке сегментације облака тачака (Слика 4.2)<sup>2</sup>.

Ово је само један део такмичења *DFC 2019 IEEE – GRSS* фузије података (*Bosch* и др., 2018; *Le Saux* и др., 2019). У оквиру ове иницијативе обезбеђен је облак тачака добијен ласерским скенирањем из ваздуха за подручје од око 100 квадратних

<sup>2</sup> <https://iee-dataport.org/open-access/data-fusion-contest-2019-dfc2019>

километара и са око 200 милиона тачака за одређене регионе града Џексонвила у Флориди и Омахе у Небраски, САД. Циљ овог дела такмичења био је доделити ознаку класе за сваку тачку од неколико предефинисаних семантичких класа. Номинални размак између суседних тачака био је око 0.8 m. За сваку од тачака се чувају 3Д просторне координате (XYZ), интензитет, редни број одбитка и шифра класе.



Слика 4.2: Део класификованог GRSS облака тачака за подручје Џексонвила.

Скуп података за тренирање се састоји из 110 тајлова облака тачака (71.4 милиона тачака) са одговарајућим класама. Скуп података за тестирање садржи десет тајлова са додељеним класама (8.3 милиона тачака). Подаци су дати као текстуални фајлови у формату  $\{x, y, z, \text{интензитет}, \text{број одбитка}\}$ . Ознаке класификације тачака за наведени скуп података одговарају LAS спецификацији (Табела 4.2).

Табела 4.2 Шифре класа, њихов опис и број тачака за сваку класу у зависности од скупа података.

Шифра класе	Опис класе	Број тачака	
		Тренинг подаци	Тест подаци
2	Терен	48 069 788	6 148 920
5	Висока вегетација	10 775 292	1 321 488
6	Кровови зграда	10 269 771	782 455
9	Водене површине	1 356 899	19 266
17	Мостови	934 545	25 034
Укупно тачака		71 406 295	8 297 163


У овој дисертацији су разматране само тачке које припадају класама терена, високе вегетације и крововима зграда, како би се могло извршити тренирање модела са овим подацима и применити на *ISPRS* скуп података. Стога се коришћени скуп података састоји из дела предвиђеног за тренирање модела који садржи 69 114 851 тачака и дела за тестирање који садржи 8 252 863 тачака.

Ради лакше визуелизације и упоређивања резултата семантичке сегментације, за потребе ове дисертације коришћен је само један тајл који припада Џексонвилу и један тајл података који припада Омахи.

### 4.3 *DublinCity*: Класификован облак тачака

Група за урбано моделирање Универзитетског колеџа из Даблина (енгл. *University College Dublin*) снимила је *ALS* системом централно подручје града Даблина (од око 5.6 km<sup>2</sup>) користећи хеликоптер као платформу 2015. године. Висина лета је била око 300 m и цела мисија снимања садржи 41 ред снимања<sup>3</sup>.

Главно подручје од интереса где је већина тачака класификована величине је око 2 km<sup>2</sup> (Слика 4.3). У овом скупу података је семантички означено око 260 милиона тачака од укупно 1.4 милијарде. Приказано подручје се налази унутар дела облака тачака са највећом густином (од 250 до 348 тачака по m<sup>2</sup>) и потпуно је покривено авио–снимцима.

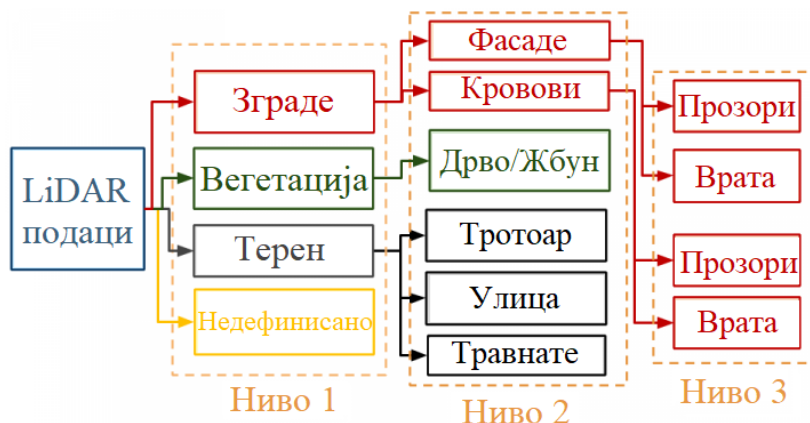


Слика 4.3: Приказ *DublinCity* класификованог облака тачака. Слика је модификована верзија Слика 2 преузете од Zolanvari и др., 2019.

---

<sup>3</sup> <https://v-sense.scss.tcd.ie/dublincity/>

Облак тачака је класификован на тај начин да постоји хијерархија означавања са три нивоа детаљности и укупно 13 класа (Слика 4.4).



Слика 4.4: Хијерархија класа за *DublinCity* податке. Слика је модификована верзија Слика 1 преузете од *Zolanvari* и др., 2019.

Наведени скуп података није коришћен у оквиру дисертације због превелике густине тачака и обимне количине података.

#### 4.4 *H3D* скуп података за семантичку сегментацију облака тачака високе резолуције

Циљ *H3D* иницијативе био је да се обезбеди референтан скуп података који се може користити од стране заинтересованих истраживача како би тестирали своје методе и алгоритме за семантичку сегментацију облака тачака. Подаци су сакупљени за подручје насеља Хесигхајм у оквиру пројекта покренутог од стране Универзитета у Штутгарту и Федералног института за хидрологију Немачке (*BfG*)<sup>4</sup>. Процес геореференцирања снимака и изравнања високе тачности описан је у *Cramer* и др., 2018. и *Naala* и др., 2020. Наведени скуп података садржи *LiDAR* облаке тачака велике густине снимљене у четири различите епохе. Облаци тачака су мануелно класификовани у 11 класа, при чему је облак тачака прво подељен у сегменте, а затим су додељиване одговарајуће класе сегментима (кластерима тачака који представљају неке целине – Слика 4.5).

<sup>4</sup> <https://ifpwww.ifp.uni-stuttgart.de/benchmark/hessigheim/default.aspx>



Слика 4.5: *H3D* класификован облак тачака за епоху из марта 2018. године. Слика је модификована верзија Сликe 3 преузете са *H3D* веб-странице<sup>5</sup>.

Снимци из ваздуха и *LiDAR* подаци су прикупљени *Riegl VUX-ILR* скенером и помоћу две камере *Sony Alpha 6000* интегрисане на *RIEGL Ricopter* летелици као платформи за снимање у марту 2016. године, марту и новембру 2018. године и марту 2019. године. Висина снимања изнад терена је била 50 m са величином отиска ласерског сигнала од 3 cm. Густина тачака је у неким деловима снимљеног подручја ишла чак до 800 тачака по m<sup>2</sup>. Подаци облака тачака се састоје из *XYZ* координата сваке тачке, редног броја одбитка, укупног броја одбитака и измерене рефлектансе одбитка сигнала. Облак тачака је колоризован на основу снимака из ваздуха и класе су ручно додељене свакој тачки.

Наведени скуп података није коришћен у оквиру дисертације због превелике густине тачака и количине података добијене снимањем са беспилотне летелице (енгл. *Unmanned Aerial Vehicle – UAV*).

## 4.5 NEWFOR референтни подаци за детекцију појединачних стабала

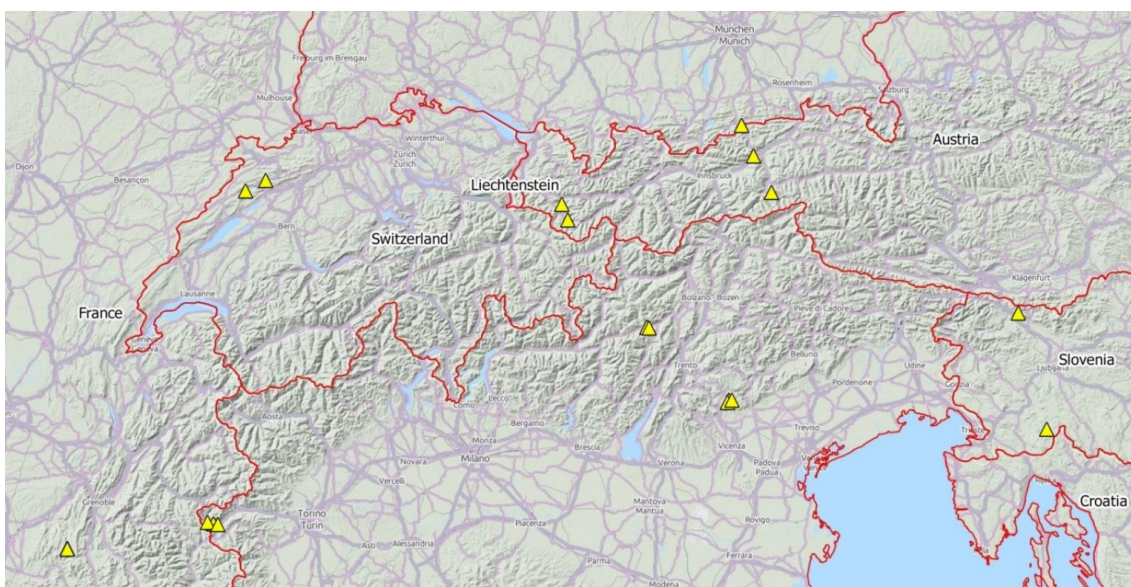
У оквиру истраживачког пројекта *NEWFOR (NEW technologies for a better mountain FORest timber mobilization)* учествовало је 14 институција из шест земаља које послују у области шумарства и даљинске детекције. Пројекат је имао за циљ побољшање ланца снабдевања дрвном грађом из шума у подручју Алпа. Наведено

<sup>5</sup> <https://ifpwww.ifp.uni-stuttgart.de/benchmark/hessigheim/details.aspx>

су планирали остварити унапређењем процене дрвне грађе коришћењем нових технологија даљинске детекције.

Један од циљева пројекта било је и тестирање постојећих и успостављање нових метода екстракције информација о појединачним стаблима на основу података даљинске детекције. За те потребе је и формиран референтни скуп података добијен ласерским скенирањем из ваздуха за детекцију појединачних стабала<sup>6</sup>. У оквиру пројекта испробано је осам метода детекције појединачних стабала у различитим регионима у оквиру Алпског простора који покривају различита подручја истраживања и типова шума са различитим структурама.

У оквиру десет пилот подручја одређених у оквиру *NEWFOR* конзорцијума, за 21 подручје истраживања која су дистрибуирана у оквиру пет земаља доступни су подаци за потребе овог дела пројекта (Слика 4.6).



Слика 4.6: Подручја истраживања где су прикупљени подаци ласерског скенирања из ваздуха са приказом земаља које припадају Алпском простору. Слика је модификована верзија Сликe 2 преузете из извештаја о референтном скупу података за детекцију појединачних стабала<sup>7</sup>

За свако подручје истраживања доступни су *ALS* подаци у *LAS* формату и дигитални модел терена у растерском формату са величинама ћелија грида од  $1.0 \times 1.0 \text{ m}$  и  $0.5 \times 0.5 \text{ m}$ . Поред наведених података, доступни су и подаци инвентуре шума (енгл. *Forest Inventory*) за све шумске парцеле које се налазе у подручјима истраживања. Подаци који су мерени на терену били су координате центра или ћошкова шумске парцеле коришћењем диференцијалног ГНСС уређаја, док су позиције и висине стабала мерене са: компасом, инклинометром, даљиномером и висиномером или хипсометром. Прикупљени атрибути за свако

<sup>6</sup> <https://www.newfor.net/download-newfor-single-tree-detection-benchmark-dataset/>


<sup>7</sup> [https://www.newfor.net/wp-content/uploads/2015/02/DL16-Report-Benchmark-NEWFOR\\_Final.pdf](https://www.newfor.net/wp-content/uploads/2015/02/DL16-Report-Benchmark-NEWFOR_Final.pdf)



дрво били су: јединствени број стабла, врста дрвећа, координате позиције стабла, пречник стабла на прсној висини (енгл. *Diameter at breast height*), висина стабла и запремина дрвета. *ALS* подаци за подручје шумских парцела су баферовани, тј. подручје за које су подаци прикупљени је проширено за вредности од 25 m до 50 m од границе парцеле, како би се уклонили ефекти који се појављују на границама шумских парцела кад се врши детекција стабала над *ALS* подацима.

Густина тачака података ласерског скенирања се кретала од 5 тачака по  $m^2$  до 120 тачака по  $m^2$ . Подаци који су доступни за сваку *ALS* тачку су: координате тачке, редни број одбитка сигнала, укупан број одбитака и ознака класе (терен или вегетација).

Пример података ласерског скенирања дат је за шумску парцелу у месту Сент Ањан у Француској (Слика 4.7).



Слика 4.7: Пример подручја истраживања, слика лево – поглед одозго, слика десно – поглед из профила где су тачке терена приказане љубичастом бојом, а тачке вегетације зеленом бојом.

Наведени скуп података није коришћен у оквиру дисертације због превеликих одступања у измереној локацији подножја стабла на терену и врха детектованог стабла из *ALS* података што је знатно отежавало идентификацију стабала у овим подацима.

## 4.6 Подаци ласерског скенирања из ваздуха коришћени за индивидуалну детекцију стабала

Подаци потребни за овај део истраживања издвојени су из комерцијалног снимања шумског подручја Босне и Херцеговине, будући да није било одговарајућих, јавно доступних скупова података ласерског скенирања за ове потребе. Подручје истраживања детаљно је описано у поглављу 4.6.1. У поглављу 4.6.2 дат је опис шумских парцела дигитализованих за ове потребе, поглавље 4.6.3 садржи опис

целокупне мисије ласерског скенирања, док је у поглављу 4.6.4 покривен део о референтним стаблима која су морала ручно бити картирана коришћењем облака тачака.

#### 4.6.1 Подручје истраживања

Подручје истраживања покрива 270 ha шуме која се налази у североисточном делу Босне и Херцеговине. Димензије снимљеног подручја су око  $0.6 \times 4$  km и подручје се простире у правцу север – југ (Слика 4.8). Наведено подручје је најчешће брдовитог терена са знатним висинским разликама и великим нагибом терена (330 – 600 m изнад средњег нивоа мора). Доминантне шумске врсте у овом делу земље обухватају лишћарске шуме, углавном букве (*Fagus sylvatica*) и храста китњака (*Quercus petraea*), као и мешовите шуме лишћарских и четинарских врста дрвећа, углавном букве и јеле (*Abies alba* Mill.) са смрчом (*Picea abies*).



Слика 4.8: Подручје истраживања са приказаним шумским парцелама и ортофото позадином.

#### 4.6.2 Шумске парцеле

Заступљене шумске врсте на подручју истраживања су шуме букве, четинарске шуме јеле са смрчком и мешовите лишћарске и четинарске шуме – букве и јеле са смрчком. Укупно 20 кружних парцела пречника од 50 метара је дистрибуирано по читавом подручју истраживања (Слика 4.8). На овај начин је издвојено 15 лишћарских шумских парцела, четири у којим су били четинари и једна у којој се налазио део мешовите шуме (лишћарске и четинарске).

Шумске парцеле су подељене на део који је намењен за тренирање и део намењен за тестирање, и то тако што је осам парцела намењено за тестирање, а осталих 12 за тренирање модела машинског учења. Тест подаци садрже пет парцела лишћарске шуме, две парцеле четинарске шуме и једну парцелу са мешовитом шумом. Идентификација и класификација шумских парцела извршена је визуелном интерпретацијом са ортофотоа овог подручја величине ћелије грида од 5 cm, као и посматрањем колоризованог облака тачака. Категоризација шумских парцела које припадају тест подацима је била неопходна за каснију оцену тачности класификације за сваки тип шуме (лишћарску, четинарску и мешовиту).

#### 4.6.3 Подаци ласерског скенирања

Прикупљање података ласерског скенирања из ваздуха извршено је крајем јануара 2021. године у току периода без наглашене вегетације. Коришћен је ласерски скенер са дискретним мерењем повратног сигнала *Galaxy T1000 (Teledyne Optech, Канада)*. Наведени систем одликује ефективна фреквенција мерења од 1 000 kHz са константном ширином обухвата појаса снимања и цик-чак шаблоном скенирања. Лет је изведен са просечном висином лета од 550 m изнад нивоа терена, са 30% преклопом између низова скенирања и максималним углом скенирања од  $\pm 45^\circ$ . Генерисани облак тачака има просечну густину тачака од 192 тачке/m<sup>2</sup> са свим одбицима и од 85 тачака/m<sup>2</sup> са само последњим одбицима, са вертикалном и хоризонталном тачношћу вишом од 5 cm. Наведени систем има могућност да региструје до осам одбитака за сваки емитовани ласерски пулс. Облак тачака је добијен са средњом величином отиска сигнала пречника 15 cm. Да би се покрила читава област од интереса, изведена су 24 низа снимања. Подручје од интереса за ово истраживање обухвата само мањи део целе мисије снимања.

*ALS* подаци су добијени првим, последњим и средишњим одбицима за сваки снимљени ласерски пулс. *ALS* тачке су геореференциране и класификоване у тачке које припадају терену и које не припадају терену коришћењем софтверског решења *TerraScan (Terrasolid)* у ком је имплементиран алгоритам за класификацију који користи модел неправилне мреже троуглова (енгл. *Triangulated Irregular Network – TIN*). Овом методом се филтрирају тачке које не припадају терену на основу методе итеративног растојања и итеративног угла (*Axelsson, 2000*).

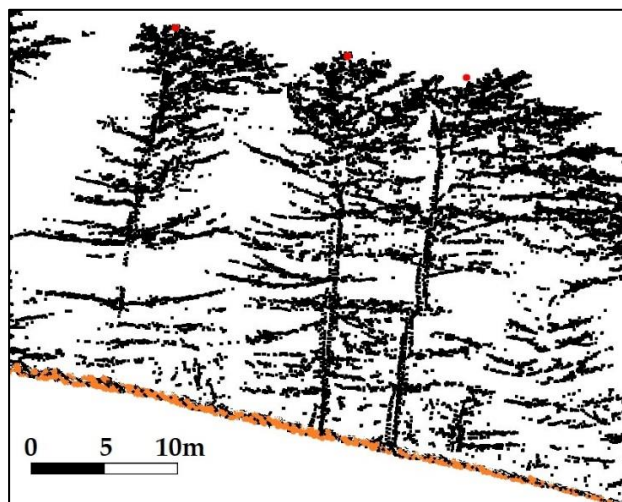
Висине тачака су нормализоване одузимањем висине терена од апсолутне висине тачака чиме су се добиле тачке са висинама које се односе на ниво терена. Висине терена за сваку тачку одређене су линеарном интерполацијом коришћењем *TIN*

модела генерисаног на основу тачака које припадају класи терена. *ALS* подаци који одговарају свакој шумској парцели, укључујући бафер од 10 m око сваке парцеле, опсечени су из облака тачака и наведени сегменти су коришћени за све даље прорачуне. Наведена величина бафера је изабрана како би се осигурало да свака крошња стабла буде у потпуности лоцирана унутар ове бафероване области за свако дрво мерено унутар шумске парцеле.

#### 4.6.4 Референтни подаци стабала

Поузданост локација референтних стабала је веома важна за *ITD* комплетност и тачност (*Zhen* и др., 2016). Локације стабала нису мерене на терену већ су прикупљане ручно, мануелним картирањем тих локација на основу 3Д облака тачака од стране једног искусног оператера. Локације стабала мерене на терену често имају значајно хоризонтално померање у односу на врх крошње које настаје због нагнутости дрвета или веома нагнутог терена. Ово се посебно дешава код лишћарских врста дрвећа због великог одступања врха стабла у односу на подножје. Такође, постоји могућност одређивања погрешне локације подножја стабла као последица непоузданости мерења због слабог ГНСС сигнала, што се дешава испод густих крошња стабала. Пошто *ITD* алгоритми откривају врхове стабала, поређење ових места са локацијама стабала које су мерене на терену није исправно.

Инвентар дрвећа (локације врхова и висине стабала) унутар 20 шумских парцела одређен је у стерео режиму (користећи наочаре са активним затварачима) од стране једног оператера са високим нивоом искуства. Референтна стабла су такође откривена, где је било потребно, посматрањем вертикалних профила облака тачака (Слика 4.9). Измерено је само доминантно дрвеће, док друго дрвеће испод крошњи доминантних стабала није узимано у обзир приликом картирања локација стабала. Наведена фотоинтерпретација изведена је у софтверском решењу *Trimble Inpho*. Укупно је идентификовано 923 референтна стабла на 20 шумских парцела. Од тог броја, 615 је било лишћарских, а 308 четинарских врста стабала.



Слика 4.9: Врхови референтних стабала обојени црвено у вертикалном профилу шумске парцеле.

## 5 ЕКСПЕРИМЕНТАЛНИ ДЕО

У овом поглављу представљен је експериментални део дисертације подељен у пет експеримената којима су покривени дефинисани циљеви истраживања.

Експеримент 1 односи се на екстракцију атрибута тачака који су коришћени као предиктори приликом семантичке сегментације облака тачака. Овде су тестирана два начина претраге суседства са различитим полупречницима претраге, као и вишеразмерни приступ где се истовремено користи више полупречника претраге суседства.

Експеримент 2 покрива резултате семантичке сегментације који се добијају кроз три комбинације екстракованих атрибута, било да су коришћени сви предиктори или само они добијени рекурзивном селекцијом атрибута. Коришћено је укупно десет различитих модела машинског учења над овим комбинацијама атрибута. Извршена је селекција најважнијих атрибута само код оних комбинација атрибута које су дале најбоље резултате семантичке сегментације коришћењем четири традиционалне методе машинског учења. Описано је и одређивање оптималних хиперпараметара за неке од метода машинског учења. У једном делу експеримента вршено је сортирање коришћених атрибута према важности коју су имали приликом семантичке сегментације. Такође је извршено и поређење резултата семантичке сегментације када је вршено балансирање података према класама и повећање тачности које се добија просторном регуларизацијом ознака класа.

У експерименту 3 вршено је узорковање тренинг података добијених вишеразмерном комбинацијом атрибута. Циљ овог експеримента био је да се провери да ли се редукцијом података добијају значајно лошији резултати науштрб краћења времена тренирања модела.

Претходна три експеримента су се односила на *ISPRS* податке, док је у експерименту 4 вршена семантичка сегментација над *GRSS* подацима. На крају експеримента 4, модел истрениран над *GRSS* подацима примењен је на тест податке *ISPRS* скупа података како би се утврдило који се ниво универзалности примене добија коришћењем предложене методологије. Са *ISPRS* подацима се детаљно прошло кроз све наведене фазе, док је над *GRSS* подацима извршена семантичка сегментација користећи атрибуте добијене рекурзивном елиминацијом, будући да су *GRSS* подаци превише обимни.

Експеримент 5 односи се на побољшање резултата детекције појединачних стабала у шумским подручјима коришћењем метода машинског учења. Овде су такође извршени балансирање података према класама и редукција броја репрезентативних атрибута коришћењем генетских алгоритама, а срачуната је и важност појединих атрибута у целом процесу класификације. У овом делу је тестирано неколико метода машинског учења, извршено фино одређивање оптималних параметара модела и анализирано која метода даје најбоље резултате.

## 5.1 Експеримент 1: Екстракција атрибута тачака

Циљ овог експеримента је генерисање свих атрибута дефинисаних у поглављу 3.2.2, са начинима претраге у виду вертикалног цилиндра и сфере претраге. Претрага суседства тачке вршена је коришћењем различитих полупречника од 1 m, 1.5 m, 2 m и 3 m како би се оценило која размера претраге је најбоља за семантичку сегментацију *ISPRS* података. Касније су те вредности усвојене и за *GRSS* податке како би се модел истрениран над једним подацима могао применити над другим. Наведене вредности размере претраге преузете су из истраживања спроведеног од стране *Atik* и др., 2021. јер су и у овом експерименту и њиховом истраживању коришћени исти *ISPRS* подаци. У њиховом истраживању је коришћено готово три пута мање атрибута (13) спрам укупног броја колико је генерисано у овој дисертацији (29 – Табела 3.1). Такође је у овој дисертацији извршено генерисање вишеразмерне (*MultiScale*) комбинације атрибута генерисањем геометријских атрибута са свим расположивим величинама полупречника цилиндара и сфера претраге. Са овом комбинацијом атрибута би се направио универзалан модел који може бити примењен на облаке тачака различите густине. Поред вишеразмерне комбинације, направљено је укупно шест комбинација атрибута од којих свака има кодиран назив ( $D_xR_y$ ). Под  $D_2$  се мисли на вертикални цилиндар претраге, под  $D_3$  на сферу претраге, а бројем уместо ознаке  $y$  у оквиру  $R_y$  се означавају величине полупречника претраге, и то где:

- $D_2R_1$  представља комбинацију са цилиндром претраге полупречника 1 m;
- $D_2R_{1.5}$  представља комбинацију са цилиндром претраге полупречника 1.5 m;
- $D_2R_2$  представља комбинацију са цилиндром претраге полупречника 2 m;
- $D_2R_3$  представља комбинацију са цилиндром претраге полупречника 3 m;
- $D_3R_2$  представља комбинацију са сфером претраге полупречника 2 m;
- $D_3R_3$  представља комбинацију са сфером претраге полупречника 3 m;
- *MultiScale* представља комбинацију више размера са цилиндрима претраге ( $D_2$ ) и сферама претраге ( $D_3$ ) полупречника 0.5 m, 1 m, 1.5 m, 2 m и 3 m.

Свака од наведених комбинација  $D_xR_y$  има 29 генерисаних атрибута (Табела 3.1), док се са вишеразмерном комбинацијом (*MultiScale*) добило чак 100 различитих варијанти атрибута од различитих комбинација. Код вишеразмерне комбинације је за једну групу атрибута била генерисана само по једна варијанта (*Amplitude*, *EchoNumber*, *RelativeZ*), за другу групу су срачунате по две варијанте за сваки атрибут и то кад се користи цилиндар –  $d2$  или сфера претраге –  $d3$  (*Anisotropy*, *Curvature*, *Linearity*, *NormalEigenValue1*, *NormalEigenValue2*, *NormalEigenValue3*, *NormalSigma0*, *Omnivariance*, *Planarity*, *Sphericity* и *SUMeigenvalues*), док је за све остале атрибуте срачунато по пет варијанти са различитим цилиндрима претраге полупречника од 0.5 m, 1 m, 1.5 m, 2 m и 3 m (*EchoRatio*, *MAX*, *MIN*, *negOpenness*, *NormalizedZ*, *PCOUNT*, *PDENS*, *PDIST*, *PosOpenness*, *quadraticEntropy*, *RANGE*, *RANK*, *shannonEntropy*, *stdDevMAD* и *Variance*).

Након одређивања атрибута/варијанти атрибута за сваку тачку облака тачака за тренинг и тест податке, генерисане су растерске слике са величином ћелије грида од 1 m са вредностима сваке варијанте атрибута за то подручје. Наведени приступ конверзије из тродимензионалног облака тачака у дводимензионалне растерске

слике (растеризације) коришћен је код великог броја аутора (*Chehata* и др., 2009; *Yang* и др., 2017; *Zhao* и др., 2018). Приликом растеризације атрибута, разматрано је да ли се прикладније вредности у смислу раздвајања по класама добијају када се користи вредност медијане, максималне или минималне вредности атрибута од свих тачака које упадају у ту ћелију растерске слике. Визуелним поређењем атрибутских слика са минималном, максималном и вредношћу медијане за сваки појединачни атрибут тачака које упадају у тај пиксел одлучено је која ће се статистика користити за тај атрибут који се користи за семантичку сегментацију. Једино је код растерске слике са вредностима референтних класа, као излаза за тренирање модела, додељивана вредност атрибута најчешће референтне класе (енгл. *majority*) свих тачака које упадају у ту ћелију.

## 5.2 Експеримент 2: Семантичка сегментација *ISPRS* облака тачака

Предмет овог експеримента је вршење семантичке сегментације облака тачака, и то узимајући у обзир различите начине претраге и величине полупречника претраге. Такође су анализирани и бенефити који се постижу балансирањем података према класама и ефекат који се добија смањењем скупа података за тренирање модела селекцијом најзначајнијих атрибута. Главни циљ наведеног експеримента јесте тестирање великог броја метода машинског учења над различитим комбинацијама атрибута у циљу проналаска оне методе и комбинације која даје најбоље резултате семантичке сегментације. Разматрана је и вишеразмерна комбинација атрибута са којом су обухваћене вишеструке величине претраге околине тачке приликом рачунања атрибута.

Резултати семантичке сегментације се материјализују у виду растерских слика предикција просторне резолуције 1 m, где свака вредност пиксела представља ознаку класе којој припада већина тачака које упадају у одговарајуће подручје које покрива тај пиксел. Накнадно се врши предиктовање класа за тачке у наведеном подручју на основу вредности пиксела растерске слике за сваку локацију и то као додатног атрибута тачке – предиктоване класе. Затим се формира матрица конфузије где се пореде референтне класе тачака за тестирање и класе које су добијене предикцијом за сваку тачку. Ово се врши само за класе тачака које припадају терену, крововима зграда и вегетацији, јер су то заједничке класе за оба скупа података који се користе у овој дисертацији за семантичку сегментацију (*ISPRS* и *GRSS*).

Као што је већ речено, у овом истраживању обухваћена су два начина претраге суседства тачке (цилиндар и сфера претраге), као и више величина полупречника претраге (од 1 m, 1.5 m, 2 m и 3 m) за *ISPRS* скуп података. Такође је за потребе овог истраживања направљена вишеразмерна комбинација са атрибутима генерисаним за више полупречника (од 0.5 m, 1 m, 1.5 m, 2 m и 3 m) са оба начина претраге суседства. За сваку од добијених комбинација генерисане су атрибутске растерске слике са величином ћелије грида од 1 m на основу података за тренирање.

У првом кораку истренирани су *RF*, *SVM*, *ANN* и *XGB* модели машинског учења и извршена је предикција над растеризованим подацима за тестирање. Разлог зашто су у овом кораку коришћени само традиционални модели за семантичку сегментацију био је у смањењу броја комбинација начина претраге суседства и величине полупречника претраге. Није имало смисла вршити прорачун са свим комбинацијама атрибута са свим методама машинског учења ако поједине комбинације дају баш лоше резултате са четири наведене методе машинског учења. Зато је било потребно, пре вршења даљих анализа, усвојити само оне комбинације атрибута које су давале најбоље резултате са овим моделима машинског учења. У другом кораку су тестиране све описане методе машинског учења из поглавља 3.1, али само над комбинацијама атрибута издвојеним у првом кораку. Овде су такође упоређени резултати семантичке сегментације који се добијају са балансираним подацима, као и са подацима редукованим са селекцијом најважнијих атрибута.

Добијено је укупно 79 114 примерака (енгл. *samples*) за тренирање алгорита и 38 092 примерка за тестирање постигнуте тачности семантичке сегментације. Сваки примерак представља локацију пиксела атрибутских слика за коју се везује велики број атрибута (по 29 атрибута за  $D_2R_1$  комбинације и 100 атрибута за вишеразмерну комбинацију). Након извођења семантичке сегментације над растеризованим тест подацима, примењена је функција за уклањање изолованих пиксела класа агрегацијом вредности пиксела суседства. Ово је вршено у циљу побољшања резултати тачности тако што је вршена просторна регуларизација ознака класа на начин како је то описано у поглављу 3.2.5. Напослетку је на основу добијене карте класификације вршена додела класе свакој тачки облака тачака који служи за тестирање и добијени су коначни резултати семантичке сегментације.

Као квантитативне мере перформанси модела коришћене су *OA* и  $\kappa$ , при чему су вредности мера перформанси срачунате за чисту растерску предикцију, за резултате побољшане просторном регуларизацијом ознака класа (поглавље 3.2.5) и резултате пројектоване директно на облак тачака тест скупа података (Табела 5.1).

Табела 5.1 Укупна тачност (*OA*) и капа кофицијент ( $\kappa$ ) семантичке сегментације растерских продуката, резултата побољшаних просторном регуларизацијом и резултата семантичке сегментације облака тачака са различитим начинима и полупречницима претраге за *RF*, *SVM*, *ANN* и *XGB* класификатор над *ISPRS* подацима (задебљаним словима су приказани најбољи резултати).

Начин и полупречник претраге	Начин класификације	<i>RF</i>		<i>SVM</i>		<i>ANN</i>		<i>XGB</i>	
		<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$
$D_2R_1$	растерска предикција	78.2	0.701	<b>80.8</b>	<b>0.734</b>	80.0	0.726	79.6	0.720
	просторна регуларизација	81.5	0.745	<b>83.7</b>	<b>0.773</b>	83.2	0.768	82.9	0.764
	облак тачака	78.4	0.708	<b>81.5</b>	<b>0.750</b>	80.0	0.731	80.0	0.730
$D_2R_{1.5}$	растерска предикција	80.8	0.736	<b>82.2</b>	<b>0.755</b>	81.9	0.751	81.9	0.752
	просторна регуларизација	84.2	0.782	<b>85.4</b>	<b>0.797</b>	85.0	0.793	85.0	0.793
	облак тачака	80.3	0.734	<b>82.1</b>	<b>0.757</b>	81.1	0.745	81.3	0.748
$D_2R_2$	растерска предикција	58.6	0.453	<b>78.3</b>	<b>0.703</b>	78.0	0.700	67.2	0.560
	просторна регуларизација	57.9	0.443	<b>81.0</b>	<b>0.739</b>	80.9	0.738	67.9	0.569
	облак тачака	57.7	0.437	<b>77.4</b>	<b>0.696</b>	77.6	0.699	67.2	0.561
$D_2R_3$	растерска предикција	<b>82.9</b>	<b>0.766</b>	75.5	0.665	62.9	0.501	<b>83.4</b>	<b>0.774</b>
	просторна регуларизација	<b>85.3</b>	<b>0.798</b>	77.9	0.696	63.2	0.505	<b>85.4</b>	<b>0.800</b>

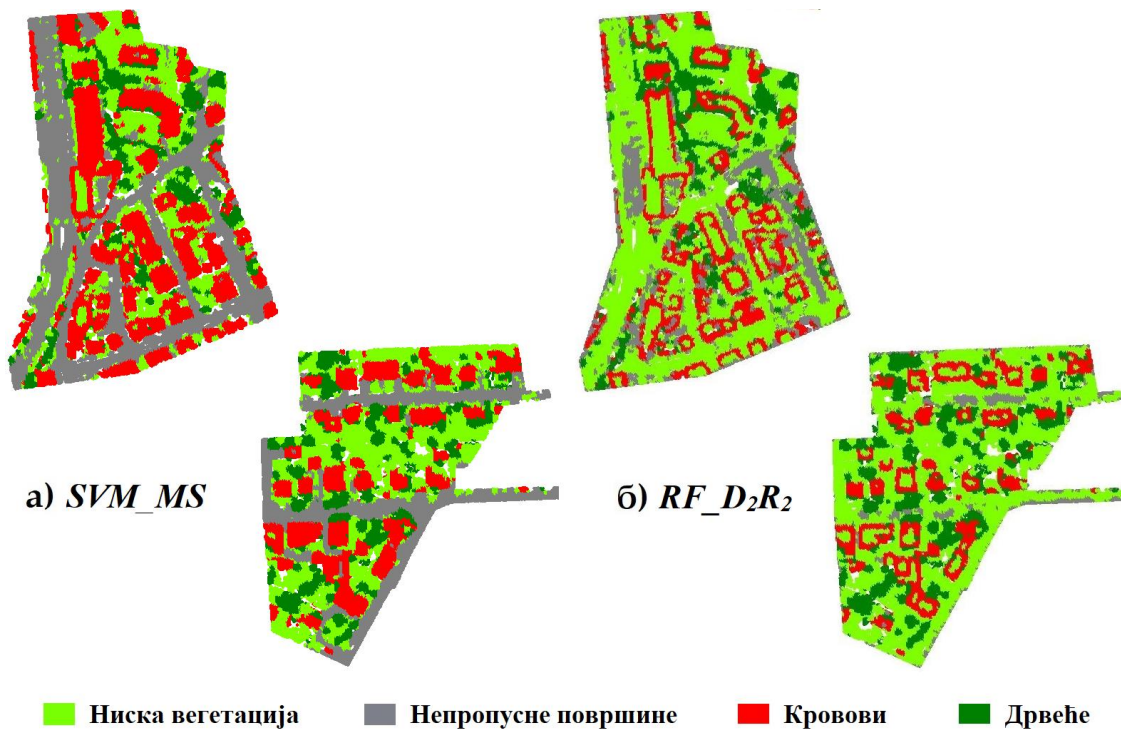


	облак тачака	<b>81.2</b>	<b>0.748</b>	78.8	0.714	69.9	0.594	<b>81.6</b>	<b>0.753</b>
$D_3R_2$	растерска предикција	77.4	0.691	<b>78.1</b>	<b>0.699</b>	77.2	0.688	77.7	0.696
	просторна регуларизација	81.0	0.739	<b>81.9</b>	<b>0.750</b>	81.1	0.740	81.1	0.740
	облак тачака	77.9	0.703	<b>79.1</b>	<b>0.718</b>	78.2	0.707	77.9	0.703
$D_3R_3$	растерска предикција	79.8	0.724	80.0	0.726	<b>80.4</b>	<b>0.731</b>	79.9	0.725
	просторна регуларизација	82.7	0.763	83.4	0.771	<b>84.0</b>	<b>0.779</b>	82.6	0.761
	облак тачака	79.4	0.723	80.4	0.735	<b>80.6</b>	<b>0.739</b>	79.5	0.725
<i>MultiScale</i>	растерска предикција	<b>83.9</b>	<b>0.780</b>	<b>84.9</b>	<b>0.792</b>	<b>82.4</b>	<b>0.760</b>	<b>84.2</b>	<b>0.783</b>
	просторна регуларизација	<b>86.3</b>	<b>0.811</b>	<b>87.4</b>	<b>0.826</b>	<b>85.5</b>	<b>0.801</b>	<b>86.2</b>	<b>0.810</b>
	облак тачака	<b>82.1</b>	<b>0.759</b>	<b>83.5</b>	<b>0.777</b>	<b>82.2</b>	<b>0.759</b>	<b>82.4</b>	<b>0.762</b>

Најбољи резултати у погледу укупне тачности семантичке сегментације добијају се вишеразмерном комбинацијом атрибута (*MultiScale*) код које је сваки од коришћених класификатора дао боље резултате од других комбинација атрибута. Треба само нагласити да је за *ANN* модел и ову комбинацију атрибута било потребно користити податке са извршеном екстремном елиминацијом атрибута, будући да се коришћењем свих атрибута није могао истренирати наведени модел. У случају кад су коришћени сви расположиви атрибути за тренирање *ANN* модела, долазило би до прекида процеса због недовољне количине меморијског простора.

Друга по перформансама у погледу тачности показала се  $D_2R_3$  комбинација атрибута генерисаних цилиндром претраге полупречника 3 m, када се користе *RF* и *XGB* као алгоритми за класификацију. Резултати који су упоредиви са наведеним добијају се и са  $D_2R_{1.5}$  комбинацијом атрибута добијених цилиндром претраге полупречника 1.5 m, и то када се користи *SVM* метода. У овој комбинацији се такође добијају и стабилнији резултати за сва четири коришћена алгоритма машинског учења гледано у односу на  $D_2R_3$ . Због свега наведеног, у наставку су упоређени резултати семантичке сегментације који се добијају у комбинацијама *MultiScale*,  $D_2R_3$  и  $D_2R_{1.5}$ , али и коришћењем сложенијих модела машинског учења који настају слагањем основних метода машинског учења, као што је описано у поглављу 3.1.6.3.

Може се закључити да је и у овој анализи *SVM* дао најбоље резултате са скоро свим комбинацијама атрибута у односу на друге коришћене класификаторе. Најбољи резултати са *SVM* добијени су коришћењем вишеразмерне комбинације атрибута при чему је укупна тачност износила 83.5%. Најлошије резултате је дала  $D_2R_2$  комбинација приликом коришћења *RF* модела класификације ( $OA = 57.7\%$ ). За ове резултате семантичке сегментације дате су и карте класификације (Слика 5.1).



Слика 5.1: Најбољи резултати семантичке сегментације (*SVM* са вишеразмерном комбинацијом – лево под а) и најлошији (*RF* са  $D_2R_2$  комбинацијом – десно под б) над *ISPRS* тест подацима.

Прилог 1, Табела П.1 садржи бољи преглед по постигнутој осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скору ( $F1$ ) за наведена четири модела машинског учења и за сваку од четири одабране класе *ISPRS* скупа података.

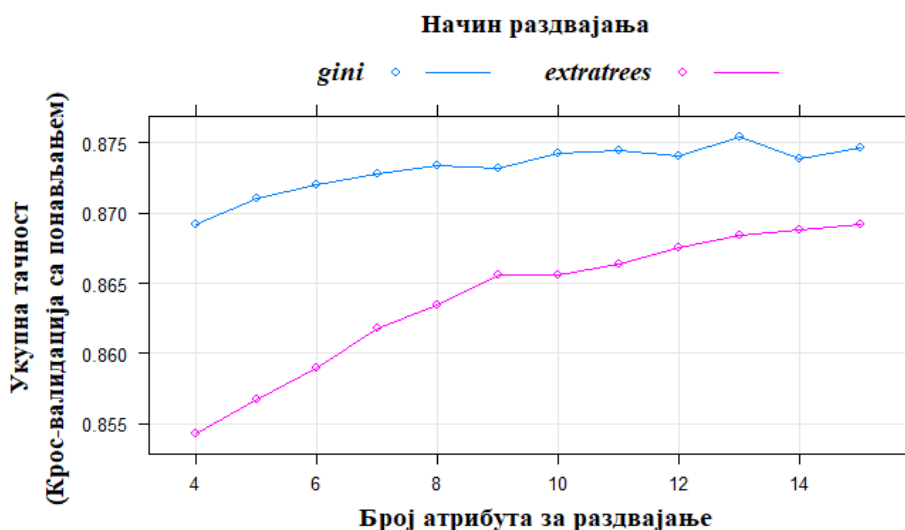
Како би се што боље упоредили добијени резултати, дати су визуелни прикази резултата семантичке сегментације за сваку комбинацију начина и полупречника претраге за наведене класификаторе (Прилог 1:  $D_2R_1$  – Слика П.1,  $D_2R_{1.5}$  – Слика П.2,  $D_2R_2$  – Слика П.3,  $D_2R_3$  – Слика П.4,  $D_3R_2$  – Слика П.5,  $D_3R_3$  – Слика П.6, *MultiScale* – Слика П.7). Такође су за детаљнији преглед и даље анализе формиран графици засебно за наведене квантитативне мере где се по класама може видети који алгоритам је дао боље резултате (Прилог 5: Слика П.8 и Слика П.9).

Прегледом вредности  $F1$  скорa може се исто доћи до закључка да се вишеразмерна комбинација атрибута показала као најбоље решење за све класе (Прилог 1, Табела П.1). Сагледавањем ове мере по класама, *XGB* класификатор је дао најбоље резултате за класу ниске вегетације и непропусних површина, док су се *SVM* класификатором добили најбољи резултати за класе кровова и дрвећа. Такође се може приметити да се значајно бољи резултати класификације добијају за класе непропусних површина и кровова у односу на класе ниске вегетације и дрвећа и то за 10–15% разлике у вредности  $F1$  скорa.

У наставку је вршено поређење резултата класификације свих објашњених метода машинског учења (поглавље 3.1), али само за комбинације  $D_2R_{1.5}$ ,  $D_2R_3$  и *MultiScale*. Овом приликом су анализирани и ефекти који настају смањењем података селекцијом најрепрезентативнијих атрибута и балансирањем података према класама.

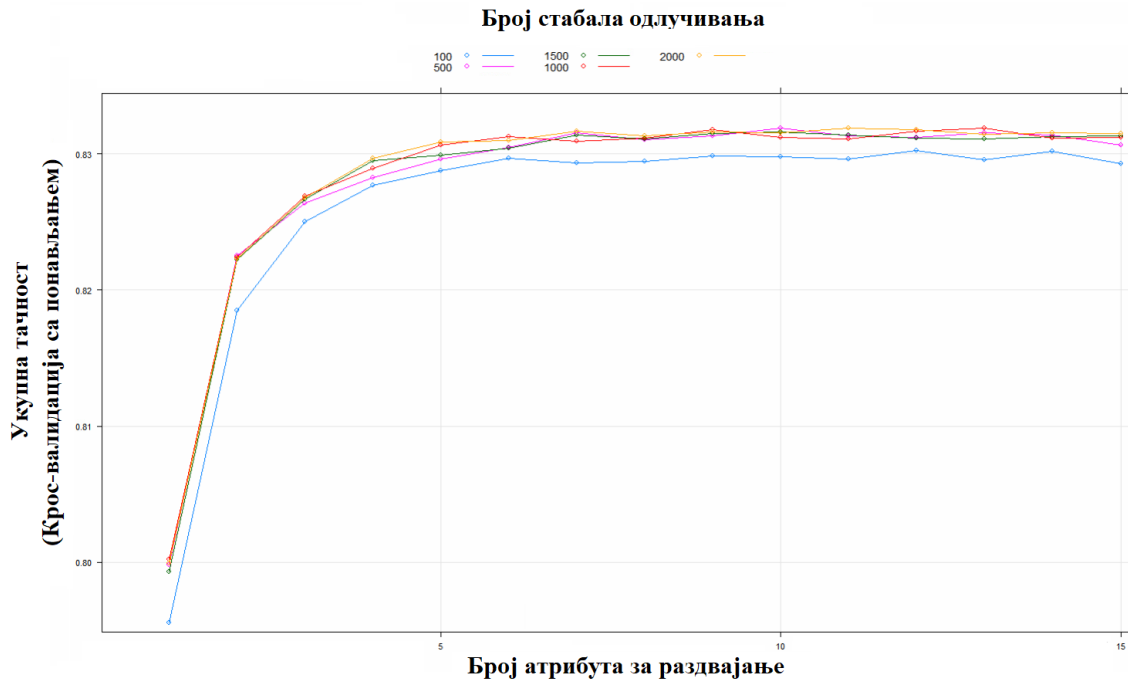
### 5.2.1 Одређивање хиперпараметара модела машинског учења

Одређивање хиперпараметара модела машинског учења врши се петоструком унакрсном валидацијом са понављањем при чему се укупна тачност користи као мера перформанси модела. За неке од модела није било могуће одредити хиперпараметре модела због меморијских могућности рачунара или због времена потребног за тренирање модела (*SVM* и *XGB*). У овом делу вршена је оптимизација параметара за методу случајне шуме у две фазе будући да је за одређивање оптималног броја стабала одлучивања било потребно формирати посебан алгоритам. Стога је у првом кораку вариран број атрибута за раздвајање у сваком чвору (у распону од 4 до 15) са различитим начином раздвајања атрибута (*gini* са Џинијевом мером или *extratrees* са *ERT* методом објашњеном у поглављу 3.1.6.1). Овде се *gini* показао као боље решење од *extratrees*, док је 13 био оптималан број атрибута за раздвајање (Слика 5.2).



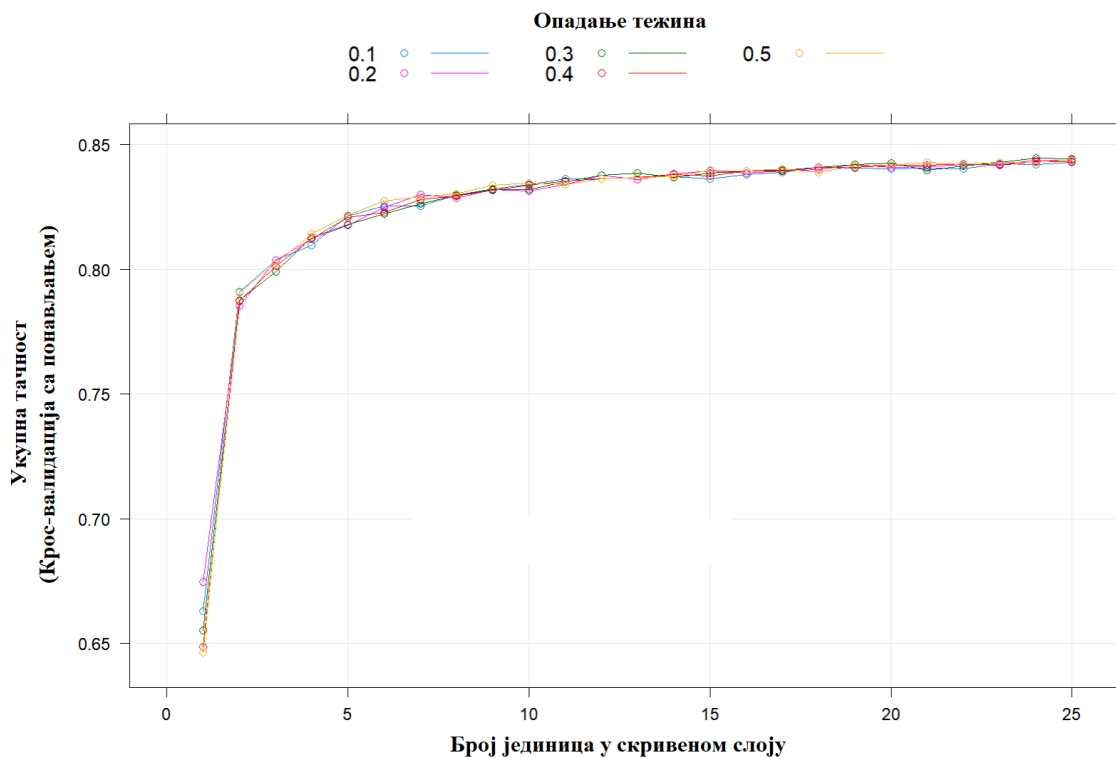
Слика 5.2: Одређивање хиперпараметара избором начина раздвајања (*gini* или *extratrees*) и броја атрибута за раздвајање приликом тренирања *RF* модела.

У другом кораку је вариран број стабала одлучивања (100, 500, 1 000, 1 500, 2 000 – Слика 5.3), и број атрибута за раздвајање (у распону од 1 до 15). Приликом ове оптимизације највиша укупна тачност ( $OA = 83.2\%$  и  $\kappa = 0.783$ ) добија се са 1 000 стабала и 13 атрибута за раздвајање, што се слаже са претходном фазом у погледу броја атрибута. Такође се може закључити да се и са 500 и више стабала одлучивања добијају добри резултати, као и да нема знатног побољшања у погледу тачности ако се користи више од седам атрибута за раздвајање (Слика 5.3).



Слика 5.3: Оптимизација хиперпараметара методе случајне шуме са варирањем броја стабала одлучивања и атрибута за раздвајање приликом тренирања *RF* модела.

Код методе вештачких неуронских мрежа вршена је оптимизација параметара опадање тежина (у распону од 0.1 до 0.5) и броја јединица (чворова) у скривеном слоју (у распону од 1 до 25). Добијено је да се највиша укупна тачност модела добија са 24 јединице у скривеном слоју и вредности опадања тежина од 0.3 ( $OA = 84.4\%$  и  $\kappa = 0.799$  – Слика 5.4). На основу графика, може се доћи до закључка да се укупна тачност незнатно побољшава уколико је број скривених јединица већи од 12. Уколико је број скривених јединица мањи, време процесирања је знатно краће, па је зато било потребно наћи баланс између постигнуте укупне тачности модела и времена процесирања. На основу графика се може закључити да би вредност опадања тежина од 0.3 и број скривених јединица од 13 дало компромис у виду постигнуте укупне тачности и оптималног времена процесирања.

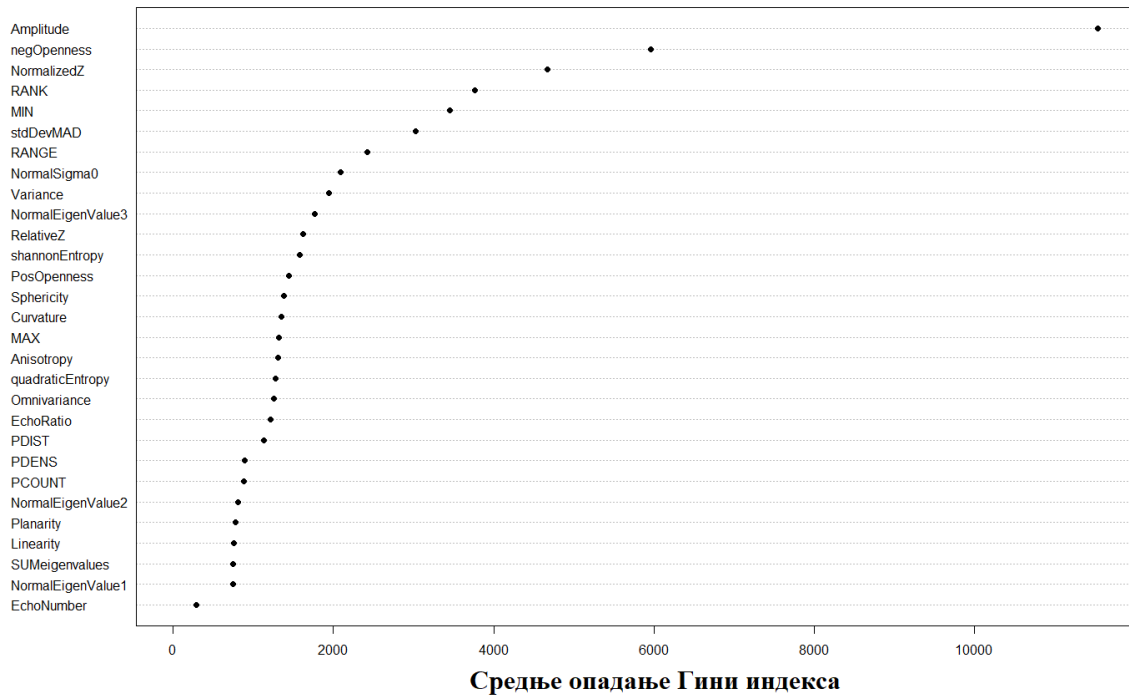


Слика 5.4: Оптимизација хиперпараметара опадања тежина и броја јединица у скривеном слоју вештачке неуронске мреже.

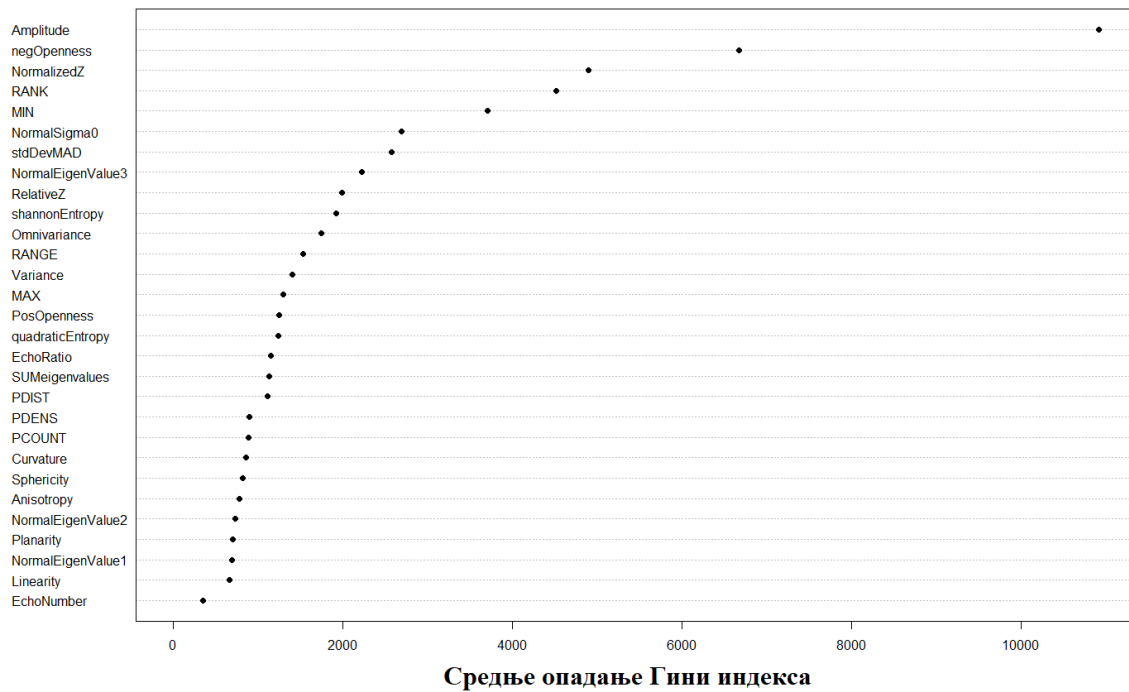
## 5.2.2 Важност атрибута

Атрибути који се користе за тренирање и формирање модела машинског учења имају различит утицај на резултате семантичке сегментације. Појединачни утицај атрибута на резултате семантичке сегментације се дефинише као важност атрибута (енгл. *feature importance*). У случају када се користи *RF* као класификатор, могуће је добити важност атрибута по основу параметра средњег опадања Џини индекса (енгл. *Mean Decrease Gini – MDG*) и вршити сортирање по важности атрибута (Chehata и др., 2009). Управо је ова опција и искоришћена приликом селекције најважнијих атрибута са *RF* моделом када је одређена и мера важности атрибута.

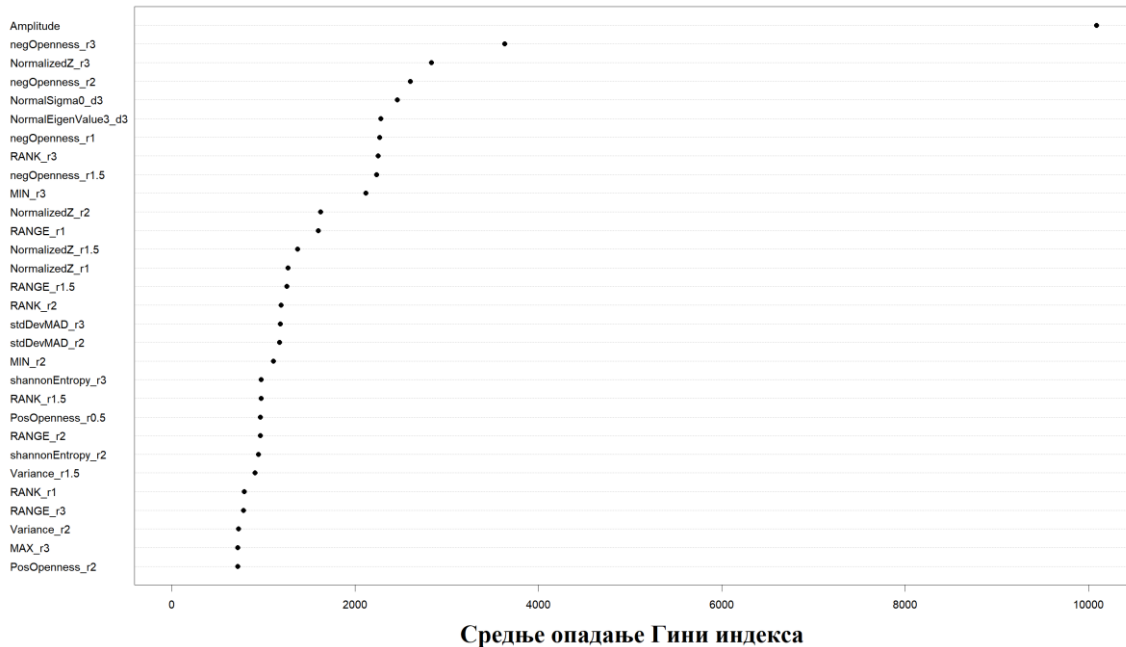
Графици важности атрибута су генерисани за  $D_2R_{1.5}$ ,  $D_2R_3$  и вишеразмерну комбинацију (Слика 5.5 за  $D_2R_{1.5}$ , Слика 5.6 за  $D_2R_3$  и Слика 5.7 за вишеразмерну), јер је само за ове комбинације вршена рекурзивна елиминација атрибута.



Слика 5.5: Важност атрибута код *RF* класификације сортиран по *MDG* за  $D_2R_{1.5}$  комбинацију.



Слика 5.6: Важност атрибута код *RF* класификације сортиран по *MDG* за  $D_2R_3$  комбинацију.



Слика 5.7: Важност атрибута код *RF* класификације сортиран по *MDG* за вишеразмерну комбинацију добијену са рекурзивном елиминацијом атрибута.

Код свих графика важности атрибута може се видети да вредност интензитета одбијања ласерског сигнала (*Amplitude*) има највећи утицај на резултате семантичке сегментације. Уколико наведени атрибут не би био коришћен међу подацима, укупна тачност би опала чак за 8% када се као класификатор користи *SVM*, или чак за 10% када се као класификатор користи *RF*.

Следећи битан атрибут био би негативна отвореност (*negOpenness*) којом се описује степен затворености локације у односу на околину на неправилној површини (*Doneus, 2013; Yokoyama, 2002*). Када се наведени атрибут не би користио за тренирање модела *RF* методом, укупна тачност класификације би опала за око 1%.

Затим се види да одређена група атрибута везана за вертикалну дистрибуцију тачака (*NormalizedZ, MIN, RANK*) има велики утицај на коначну семантичку сегментацију. Када наведени атрибути нису укључени у тренирање *RF* модела и каснију семантичку сегментацију тест података, укупна тачност би била мања за око 5%.


### 5.2.3 Селекција најважнијих атрибута

Селекција најважнијих атрибута вршена је рекурзивном елиминацијом атрибута применом петоструке унакрсне валидације са пет понављања коришћењем *RF* класификатора и укупном тачношћу као оценом перформанси модела. *RF* метода је коришћена јер се коришћењем ове методе аутоматски рачуна и мера важности атрибута (*MDG*) на основу које се уклањају одређени атрибути и касније врши сортирање атрибута по важности, што ће бити обрађено у поглављу 5.2.2. *RF* метода такође може дати релативно добре резултате и са мањим бројем стабала

одлучивања, а алгоритам има релативно кратко време извршавања што посебно значи код вишеструког понављања тренирања модела применом унакрсне валидације.

Селекцијом најважнијих атрибута одређује се комбинација атрибута којом се добијају најбоље перформансе модела семантичке сегментације без коришћења атрибута који имају високу међусобну корелацију. Селекција најважнијих атрибута вршена је само за  $D_2R_{1.5}$ ,  $D_2R_3$  и вишеразмерну комбинацију које су дале најбоље перформансе у погледу укупне тачности кад су коришћене четири традиционалне методе класификације ( $RF$ ,  $SVM$ ,  $ANN$  и  $XGB$ ).

Код комбинације  $D_2R_{1.5}$  селекција најважнијих атрибута изведена је рекурзивном елиминацијом атрибута  $RF$  методом са најбољом оценом укупне тачности модела добијеном петоструком унакрсном валидацијом. На овај начин је добијена комбинација од 19 атрибута којом се постиже средња укупна тачност класификације од  $85.0\% \pm 0.3\%$  и капа коефицијент од  $0.806 \pm 0.004$  (Слика 5.8). Најзначајнији атрибути добијени рекурзивном селекцијом су *Amplitude*, *negOpenness*, *RANK*, *NormalizedZ*, *RANGE*, *EchoRatio*, *MAX*, *MIN*, *NormalEigenValue2*, *NormalSigma0*, *PCOUNT*, *PDENS*, *PDIST*, *PosOpenness*, *quadraticEntropy*, *RelativeZ*, *shannonEntropy*, *stdDevMAD* и *Variance*.

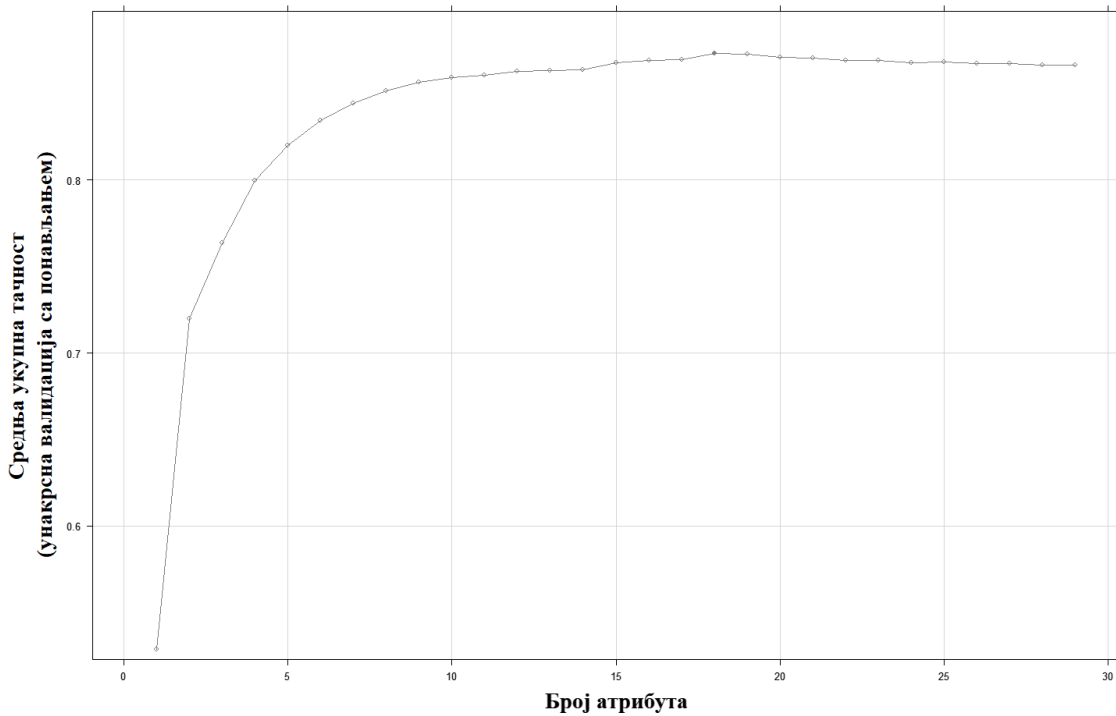


Слика 5.8: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута.

Код комбинације  $D_2R_3$  селекција најзначајнијих атрибута извршена је рекурзивном методом елиминације атрибута методом случајне шуме са најбољом оценом тачности модела добијеном петоструком унакрсном валидацијом. Овим начином добијена је комбинација од 18 атрибута којом се постиже средња укупна тачност класификације од  $87.3\% \pm 0.3\%$  и капа коефицијент од  $0.836 \pm 0.004$  (Слика 5.9). Најзначајнији атрибути добијени рекурзивном елиминацијом атрибута су:




*Amplitude, negOpenness, NormalizedZ, RANK, EchoRatio, MAX, MIN, NormalSigma0, PCOUNT, PDENS, PDIST, PosOpenness, quadraticEntropy, RANGE, RelativeZ, shannonEntropy, stdDevMAD* и *Variance*.




Слика 5.9: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом  $D_2R_3$  комбинације атрибута.

Код вишеразмерне комбинације, селекција најзначајнијих атрибута извршена је рекурзивном методом елиминације атрибута методом случајне шуме са најбољом оценом тачности модела добијеном петоструком унакрсном валидацијом. На овај начин је добијена комбинација од 44 атрибута којом се постиже средња укупна тачност класификације од  $87.1\% \pm 0.2\%$  и капа коефицијент од  $0.833 \pm 0.003$  (Слика 5.10). Најзначајнији атрибути добијени рекурзивном елиминацијом атрибута су: *Amplitude, NormalizedZ\_r3, RANK\_r3, negOpenness\_r3, MIN\_r3, RANGE\_r3, shannonEntropy\_r3, RANK\_r1, RANK\_r2, RANK\_r1.5, negOpenness\_r1.5, negOpenness\_r2, negOpenness\_r1, MAX\_r3, RANGE\_r2, NormalizedZ\_r2, Variance\_r3, PosOpenness\_r3, stdDevMAD\_r3, PDIST\_r3, quadraticEntropy\_r3, NormalizedZ\_r1.5, RANGE\_r1.5, PosOpenness\_r0.5, RANGE\_r1, shannonEntropy\_r2, NormalSigma0\_d3, PDIST\_r2, MAX\_r2, Variance\_r2, PosOpenness\_r2, PDENS\_r3, NormalizedZ\_r1, NormalEigenValue3\_d3, PDIST\_r1.5, PCOUNT\_r3, PDIST\_r1, stdDevMAD\_r2, PosOpenness\_r1.5, Variance\_r1.5, PCOUNT\_r2, MIN\_r2, quadraticEntropy\_r2* и *RANK\_r0.5*.



Слика 5.10: Средња укупна тачност класификације добијена за различит број атрибута одређених рекурзивном елиминацијом вишеразмерне комбинације атрибута.

Вишеразмерна комбинација има 100 генерисаних атрибута што представља велики обим података за рекурзивну елиминацију атрибута, поготово кад се врши унакрсном валидацијом са понављањем. Стога су прво уклоњени високо међусобно корелирани атрибути (од 0.8 до 1), после чега је остало 38 атрибута који међусобно имају нижи степен корелације (од 0 до 0.8). Након тога је извршена рекурзивна метода елиминације атрибута и добијена је коначна комбинација од 25 атрибута којом се постиже средња укупна тачност класификације од  $85.3\% \pm 0.5\%$  и капа коефицијент од  $0.811 \pm 0.006$  (Слика 5.11). Најзначајнији атрибути добијени на наведени начин, такођећи екстремном рекурзивном елиминацијом атрибута, су: *Amplitude*, *negOpenness\_r3*, *NormalizedZ\_r3*, *RANK\_r1*, *MAX\_r3*, *MIN\_r3*, *Variance\_r3*, *PDENS\_r3*, *NormalEigenValue3\_d3*, *MAX\_r2*, *RelativeZ*, *MAX\_r1.5*, *RANGE\_r0.5*, *MIN\_r1*, *PosOpenness\_r0.5*, *stdDevMAD\_r0.5*, *RANK\_r0.5*, *PosOpenness\_r1*, *PDIST\_r0.5*, *PCOUNT\_r0.5*, *SUMeigenvalues\_d2*, *Omnivariance\_d2*, *NormalEigenValue2\_d3*, *NormalEigenValue2\_d2*, *MAX\_r1*.



Слика 5.11: Средња укупна тачност класификације за различит број атрибута одређених уклањањем високо корелисаних атрибута и рекурзивном елиминацијом вишеразмерне комбинације атрибута.

Добијена редукована вишеразмерна комбинација од 25 атрибута даје за скоро 2% нижу укупну тачност од вишеразмерне комбинације састављене од 44 селектована атрибута која је добијена рекурзивном елиминацијом над целим скупом атрибута. Разлика у времену тренирања модела није превелика када се користи 44 атрибута у односу на комбинацију са 25 атрибута са овим скупом података. Стога је у наставку коришћена вишеразмерна комбинација од 44 селектована атрибута која је добијена само извођењем рекурзивне елиминације атрибута без претходног уклањања високо корелисаних атрибута.

## 5.2.4 Резултати семантичке сегментације за комбинацију $D_2R_{1.5}$

За комбинацију  $D_2R_{1.5}$  најбољи резултати над растерским продуктима добијају се када се користи *ENS\_NB* сложени ансамбл модел (Табела 5.2). Наведени модел је настао слагањем модела првог нивоа (*LR*, *RF* и *GB*), док се као модел другог нивоа (мета–модел) користио наивни Бајес.

Табела 5.2 Резултати семантичке сегментације растерских продуката *ISPRS* облака тачака са различитим класификаторима добијени са  $D_2R_{1.5}$  комбинацијом атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$
<i>RF</i>	81.8	0.751	84.8	0.791
<b><i>SVM</i></b>	<b>82.3</b>	<b>0.755</b>	<b>85.2</b>	<b>0.795</b>
<i>ANN</i>	81.9	0.751	85.0	0.793
<i>XGB</i>	82.1	0.754	85.0	0.793
<i>LR</i>	81.0	0.739	84.0	0.780
<b><i>GB</i></b>	<b>82.3</b>	<b>0.757</b>	<b>85.4</b>	<b>0.798</b>
<i>ENS_RF</i>	82.0	0.753	85.2	0.796
<i>ENS_GB</i>	81.6	0.748	85.2	0.796
<i>ENS_ANN</i>	78.9	0.713	81.3	0.745
<b><i>ENS_NB</i></b>	<b>82.9</b>	<b>0.763</b>	<b>85.7</b>	<b>0.801</b>
<i>AML</i>	81.4	0.745	85.1	0.794

Уколико се изврши просторна регуларизација ознака класа, а затим и конверзија растерске слике у облак тачака, добија се да нешто боље резултате даје *SVM* метода тј. коришћењем овог модела *OA* износи 82.1% (Табела 5.3). Друге методе су такође давале добре резултате (*OA* изнад 80%), сем *ENS\_ANN* модела где је *OA* била 77.6%.

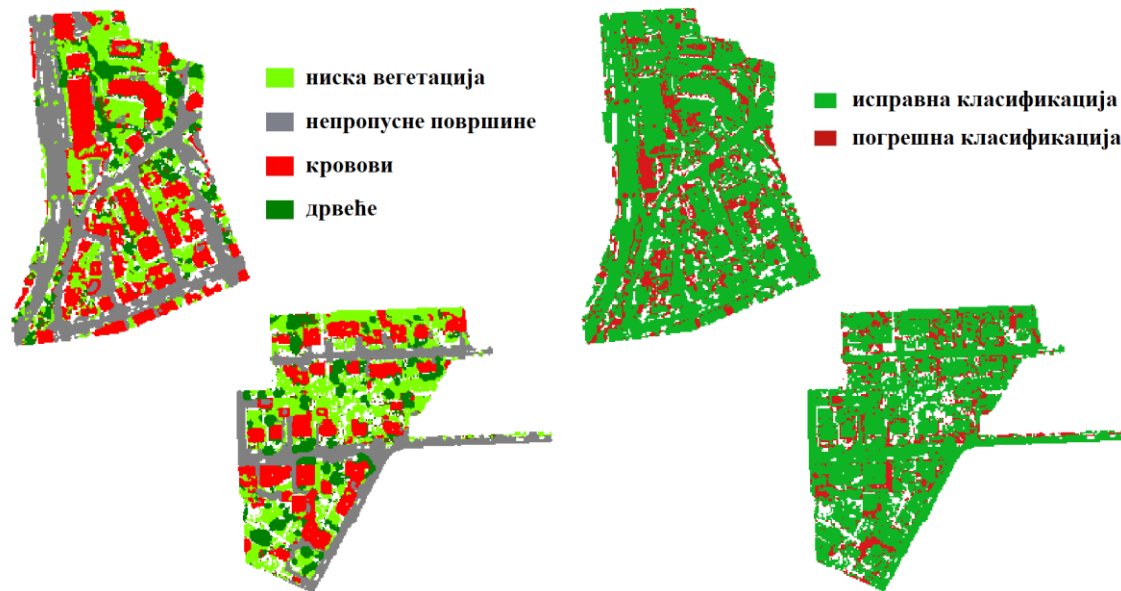
Табела 5.3 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени са  $D_2R_{1.5}$  комбинацијом атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	$\kappa$
<i>RF</i>	80.9	0.743
<b><i>SVM</i></b>	<b>82.1</b>	<b>0.758</b>
<i>ANN</i>	81.3	0.747
<i>XGB</i>	81.3	0.748
<i>LR</i>	80.5	0.737
<b><i>GB</i></b>	<b>81.7</b>	<b>0.754</b>
<b><i>ENS_RF</i></b>	<b>81.6</b>	<b>0.751</b>
<i>ENS_GB</i>	81.4	0.749
<i>ENS_ANN</i>	77.6	0.700
<b><i>ENS_NB</i></b>	<b>81.5</b>	<b>0.750</b>
<i>AML</i>	81.3	0.747

Аутоматска метода машинског учења (*AML*) направљена је у виду ансамбла слаганих модела за једноразмерне комбинације атрибута и заснована је на 20 традиционалних модела машинског учења: десет модела вештачких неуронских мрежа, два модела случајне шуме, седам модела градијентног појачавања и једног

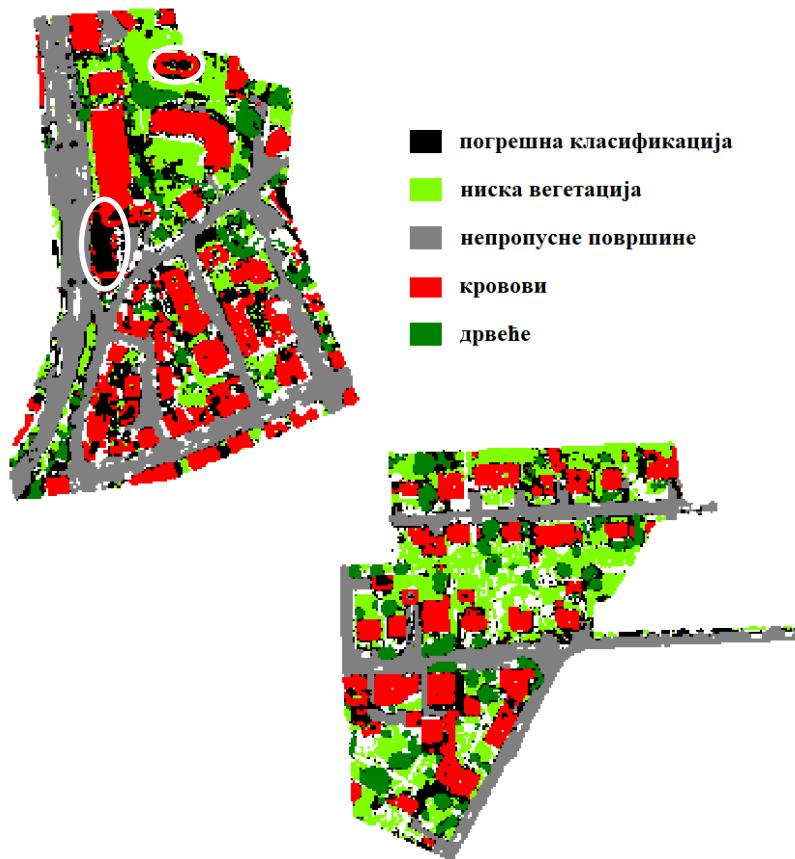
генерализованог линеарног модела. Алгоритам коришћен за слагање модела био је генерализовани линеарни модел, док је оцена тачности модела добијена петоструком унакрсном валидацијом.

Као графички приказ карте класа дати су резултати семантичке сегментације облака тачака када је добијена највиша укупна тачност (*SVM*) и одговарајућа карта грешака семантичке сегментације са овом комбинацијом атрибута (Слика 5.12).



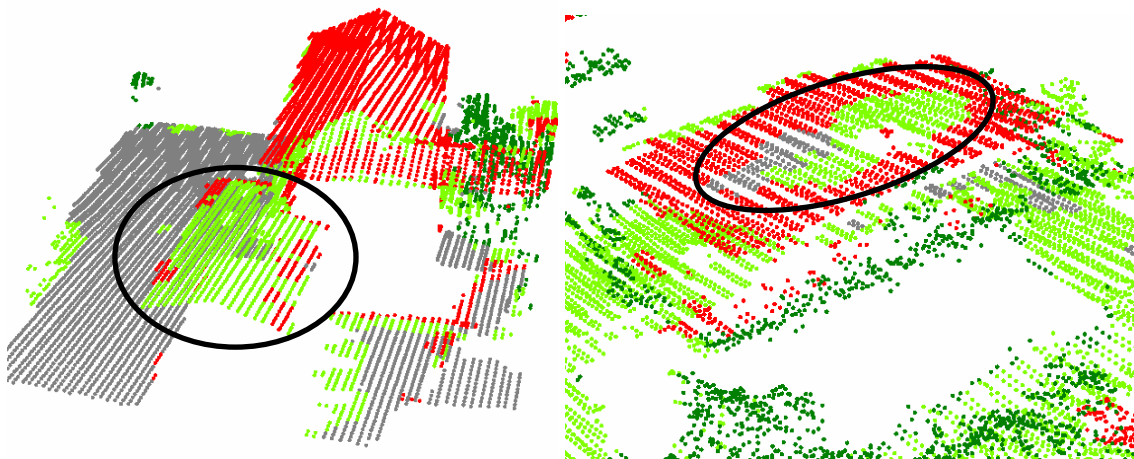
Слика 5.12: Најбољи резултати семантичке сегментације (*SVM* – лево) и карта грешака семантичке сегментације (десно) добијени са  $D_2R_{1.5}$  комбинацијом атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом.

Такође је могуће сагледати у којим деловима подручја је погрешно извршена класификација на карти класа са приказаним грешкама семантичке сегментације добијене *SVM* класификатором (Слика 5.13). Најчешће су то грешке које се јављају на ивицама кровова зграда или на крајевима крошњи стабала где су изражени висински прелази на тачке које припадају класи терена или ниске вегетације.



Слика 5.13: Карта семантичке сегментације са приказаним грешкама на *ISPRS* скупу података. Приказани су резултати *SVM* класификатора над подацима генерисаним са  $D_2R_{1.5}$  комбинацијом. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом.

Уколико се увећа део где су приказане највеће грешке настале семантичком сегментацијом (заокружене белом бојом – Слика 5.13), може се приметити да је у том делу кров једне ниже зграде већим делом класификован у ниску вегетацију (Слика 5.14 – лево), као и да је било грешака семантичке сегментације на крову зграде који је скоро хоризонталан (Слика 5.14 – десно). Уколико су равни крова под већим нагибом, најчешће се неће појављивати овакве грешке.



Слика 5.14: Највеће грешке код семантичке сегментације. Кров ниже зграде (лево) и хоризонталан кров зграде (десно) са додељеном класом ниске вегетације и непропусних површина.

Резултати семантичке сегментације се нису побољшали балансирањем класа приликом тренирања алгоритма и понављањем процедура просторне регуларизације ознака класа (Табела 5.4) и конверзије у класификован облак тачака (Табела 5.6). У овом случају би се опет добили најбољи резултати над растерским продуктима кад се користи *ENS\_NB* сложени ансамбл модел (Табела 5.4).

Табела 5.4 Резултати семантичке сегментације **растерских продуката *ISPRS* облака тачака балансираних класа** са различитим класификаторима добијени са *D<sub>2</sub>R<sub>1.5</sub>* комбинацијом атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	<i>κ</i>	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	80.9	0.739	83.9	0.779
<i>LR</i>	81.0	0.739	84.0	0.780
<i>GB</i>	82.1	0.754	85.2	0.796
<i>ENS_RF</i>	82.0	0.752	85.2	0.795
<i>ENS_GB</i>	81.7	0.749	85.2	0.796
<i>ENS_ANN</i>	81.5	0.746	84.6	0.787
<b><i>ENS_NB</i></b>	<b>82.7</b>	<b>0.761</b>	<b>85.3</b>	<b>0.796</b>
<i>AML</i>	80.5	0.732	84.2	0.782

Овакви резултати са подацима балансираним према класама су и очекивани будући да не постоји велики дисбаланс у заступљености класа *ISPRS* података (Табела 5.5). Може се приметити да једино класа тачака које припадају дрвећу садржи нешто мањи број примерака у укупном уделу, поготово код података за тестирање модела (Табела 5.5).

Табела 5.5 Резултати семантичке сегментације **растерских продуката *ISPRS* облака тачака балансираних класа** са различитим класификаторима добијени са *D<sub>2</sub>R<sub>1.5</sub>* комбинацијом атрибута.

Шифра класе	Опис класе	% заступљености	
		Тренинг подаци	Тест подаци
1	Ниска вегетација	27.3%	27.1%
2	Непропусне површине	29.3%	28.0%
5	Кровови	23.0%	30.0%
8	Дрвеће	20.4%	14.9%
Укупно тачака		100%	100%

Уколико би се предикција применила директно на облак тачака, нешто боље резултате би дали други сложени ансамбл модели који за мета-моделе користе случајну шуму и градијентно појачавање (*ENS\_RF* и *ENS\_GB*), али ови резултати су скоро исти као и када се ради са небалансираним подацима. Битно је напоменути да се балансирање класа није вршило за методе *SVM*, *ANN* и *XGB*, јер би се процес тренирања свих модела знатно продужио, а није примећено да је дошло до неког побољшања у резултатима семантичке сегментације кад се врши балансирање класа и за те методе.

Табела 5.6 Резултати семантичке сегментације *ISPRS* облака тачака балансираних класа са различитим класификаторима добијени са *D<sub>2</sub>R<sub>1.5</sub>* комбинацијом атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	80.5	0.738
<i>LR</i>	80.5	0.737
<i>GB</i>	81.0	0.744
<b><i>ENS_RF</i></b>	<b>81.5</b>	<b>0.751</b>
<b><i>ENS_GB</i></b>	<b>81.5</b>	<b>0.751</b>
<i>ENS_ANN</i>	80.6	0.739
<i>ENS_NB</i>	80.6	0.738
<i>AML</i>	80.8	0.740

Ако би се прво извршила рекурзивна елиминација атрибута, а затим семантичка сегментација са свим класификаторима, била би иста ситуација што се тиче метода које дају најбоље резултате као и кад се не врши рекурзивна селекција атрибута.

Табела 5.7 Резултати семантичке сегментације *растерских продуката ISPRS* облака тачака са различитим класификаторима добијени **рекурзивном елиминацијом *D<sub>2</sub>R<sub>1.5</sub>*** комбинације атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	<i>κ</i>	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	81.7	0.749	84.7	0.789
<b><i>SVM</i></b>	<b>82.1</b>	<b>0.754</b>	<b>85.4</b>	<b>0.797</b>
<i>ANN</i>	81.0	0.740	84.4	0.785
<i>XGB</i>	81.8	0.750	84.6	0.788
<i>LR</i>	80.3	0.729	83.1	0.767
<i>GB</i>	81.9	0.752	85.1	0.794
<i>ENS_RF</i>	81.6	0.748	84.9	0.792
<i>ENS_GB</i>	81.6	0.747	85.1	0.794
<i>ENS_ANN</i>	81.3	0.742	85.2	0.794
<b><i>ENS_NB</i></b>	<b>82.5</b>	<b>0.758</b>	<b>85.2</b>	<b>0.795</b>
<i>AML</i>	81.8	0.748	85.3	0.796

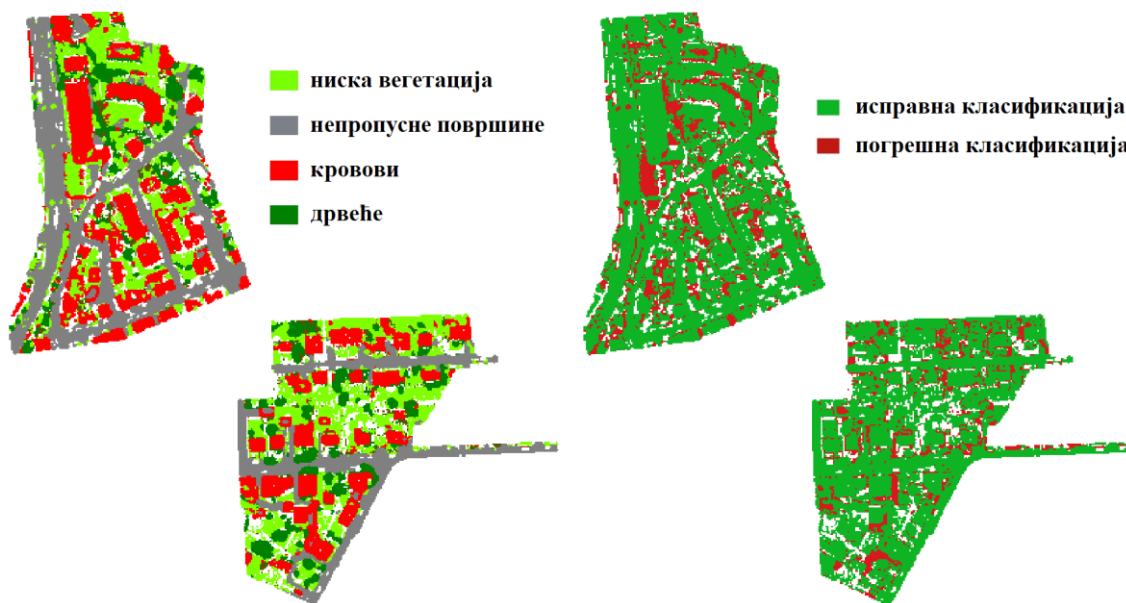
У овом случају, *SVM* такође даје боље резултате над облаком тачака (*OA* = 82%), при чему је укупна тачност за само 0.1% нижа у односу на варијанту кад су коришћени сви атрибути (Табела 5.8). Ово значи да би се са смањеним бројем атрибута значајно скратило време тренирања, а да се не би скоро ништа изгубило на тачности семантичке сегментације. Једино што се променило је то што се са методом логистичке регресије (*LR*) добили нешто лошији резултати са *OA* испод 80% (Табела 5.8).



Табела 5.8 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	80.6	0.738
<i>SVM</i>	<b>82.0</b>	<b>0.756</b>
<i>ANN</i>	80.7	0.740
<i>XGB</i>	80.9	0.742
<i>LR</i>	79.5	0.724
<i>GB</i>	81.4	0.750
<i>ENS_RF</i>	81.3	0.747
<i>ENS_GB</i>	81.2	0.746
<i>ENS_ANN</i>	81.4	0.748
<i>ENS_NB</i>	80.8	0.742
<i>AML</i>	81.2	0.746

Као графички приказ карте класа дати су резултати семантичке сегментације када је добијена највиша укупна тачност (*SVM*) и одговарајућа карта грешака семантичке сегментације добијена рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута (Слика 5.15).



Слика 5.15: Најбољи резултати семантичке сегментације (*SVM* – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом.

Уколико би се и у овом случају извршило балансирање података према класама приликом тренирања алгорита, не би дошло до неких промена у погледу успешности семантичке сегментације. И у овом случају се добило да сложени ансамбл модели машинског учења дају нешто боље резултате (*ENS\_NB* за растерске продукте – Табела 5.9, а *ENS\_RF* и *ENS\_GB* за облак тачака – Табела 5.10).

Табела 5.9 Семантичка сегментација **растерских продуката ISPRS облака тачака балансираних класа** са различитим класификаторима добијени **рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута**.

Класификатор	растерска предикција		просторна регуларизација	
	OA [%]	$\kappa$	OA [%]	$\kappa$
<i>RF</i>	80.8	0.738	83.7	0.777
<i>LR</i>	80.3	0.729	83.1	0.767
<i>GB</i>	81.9	0.752	85.0	0.793
<i>ENS_RF</i>	81.7	0.748	85.0	0.793
<i>ENS_GB</i>	81.6	0.747	85.1	0.794
<i>ENS_ANN</i>	79.3	0.718	82.9	0.766
<b><i>ENS_NB</i></b>	<b>82.5</b>	<b>0.758</b>	<b>85.2</b>	<b>0.795</b>
<i>AML</i>	81.4	0.744	84.8	0.789

Као методе које су дале *OA* мању од 80% опет се издвајају *LR* и *ENS\_ANN* (Табела 5.10).

Табела 5.10 Семантичка сегментација **ISPRS облака тачака балансираних класа** са различитим класификаторима добијени **рекурзивном елиминацијом  $D_2R_{1.5}$  комбинације атрибута**.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	80.3	0.736
<i>LR</i>	79.5	0.724
<i>GB</i>	80.8	0.741
<b><i>ENS_RF</i></b>	<b>81.2</b>	<b>0.747</b>
<b><i>ENS_GB</i></b>	<b>81.2</b>	<b>0.746</b>
<i>ENS_ANN</i>	79.0	0.718
<i>ENS_NB</i>	80.8	0.742
<i>AML</i>	81.0	0.743

Бољи преглед по постигнутој осетљивости (*R*), прецизности (*P*) и Ф1 скору (*F1*) за све моделе машинског учења и четири одабране класе *ISPRS* скупа података за  $D_2R_{1.5}$  комбинације атрибута, дат је у прилозима дисертације (Прилог 1) и то:

- Табела П.2 – када се користе сви атрибути;
- Табела П.3 – када су подаци са свим атрибутима балансирани према класама;
- Табела П.4 – када је извршена рекурзивна елиминација атрибута;
- Табела П.5 – када је извршена рекурзивна елиминација атрибута и подаци балансирани према класама.

За детаљнији преглед и даље анализе формиран су графици засебно за наведене квантитативне мере где се по класама може уочити који алгоритам је дао боље резултате (Прилог 6: Слика П.10).

### 5.2.5 Резултати семантичке сегментације за комбинацију $D_2R_3$

За комбинацију  $D_2R_3$  се исто као и за претходну комбинацију добијају најбољи резултати над растерским продуктима када се користи сложени ансамбл модел базиран на наивном Бајесу који је настао слагањем основних модела – *ENS\_NB* (Табела 5.11). Овде је проблематично што је *SVM* метода дала знатно лошије резултате од већине других ( $OA = 76.2\%$ ), јер је та метода давала најбоље резултате код  $D_2R_{1.5}$  комбинације атрибута. Вештачке неуронске мреже (*ANN*) су дале најлошије резултате семантичке сегментације извршене над растерским продуктима (Табела 5.11).

Табела 5.11 Резултати семантичке сегментације растерских продуката *ISPRS* облака тачака са различитим класификаторима добијени  $D_2R_3$  комбинацијом атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$
<i>RF</i>	83.2	0.771	85.5	0.800
<i>SVM</i>	76.2	0.674	78.9	0.708
<i>ANN</i>	69.0	0.568	69.6	0.576
<i>XGB</i>	83.6	0.775	85.6	0.802
<b><i>LR</i></b>	<b>83.7</b>	<b>0.775</b>	<b>86.3</b>	<b>0.809</b>
<b><i>GB</i></b>	<b>83.7</b>	<b>0.777</b>	<b>85.8</b>	<b>0.805</b>
<i>ENS_RF</i>	83.4	0.773	85.9	0.806
<i>ENS_GB</i>	83.0	0.767	85.4	0.800
<i>ENS_ANN</i>	82.0	0.755	84.3	0.786
<b><i>ENS_NB</i></b>	<b>85.4</b>	<b>0.799</b>	<b>87.6</b>	<b>0.829</b>
<i>AML</i>	82.0	0.754	84.7	0.790

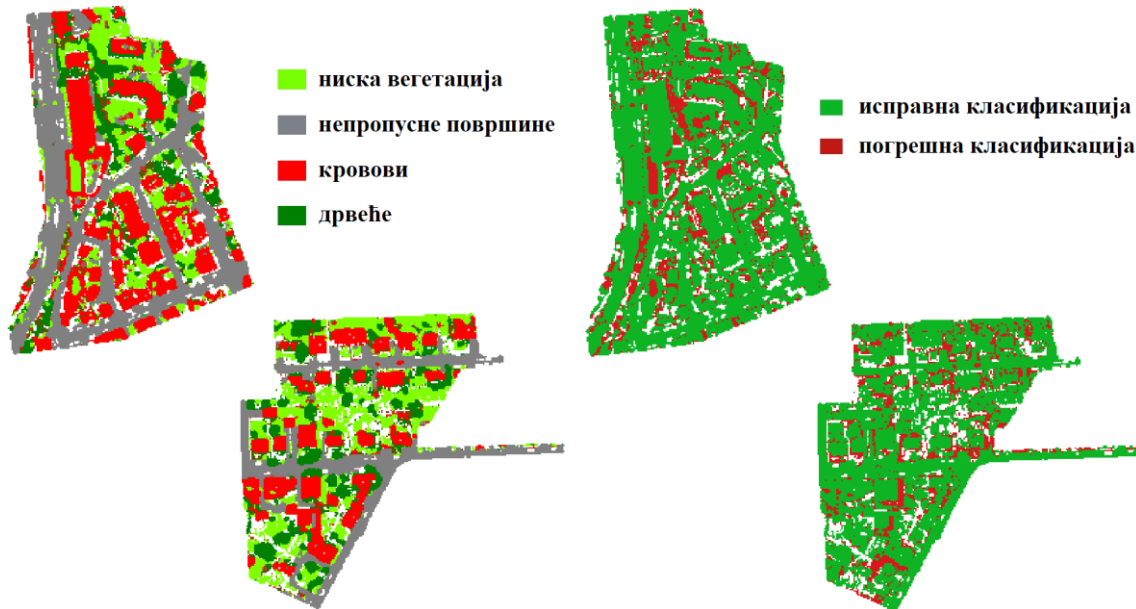
Након извршене просторне регуларизације ознака класа и конверзије растерске слике у облак тачака, иста метода (*ENS\_NB*) је дала највећу укупну тачност од 82.6% (Табела 5.12), што је за 0.5% више од најбољег модела комбинације  $D_2R_{1.5}$  (Табела 5.3).

Табела 5.12 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени  $D_2R_3$  комбинацијом прорачуна атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	$\kappa$
<i>RF</i>	81.4	0.751
<i>SVM</i>	79.8	0.726
<i>ANN</i>	74.7	0.656
<i>XGB</i>	81.9	0.757
<b><i>LR</i></b>	<b>82.3</b>	<b>0.761</b>
<i>GB</i>	82.1	0.759
<i>ENS_RF</i>	81.5	0.752
<i>ENS_GB</i>	80.9	0.744
<i>ENS_ANN</i>	79.6	0.728
<b><i>ENS_NB</i></b>	<b>82.6</b>	<b>0.765</b>
<i>AML</i>	80.8	0.742

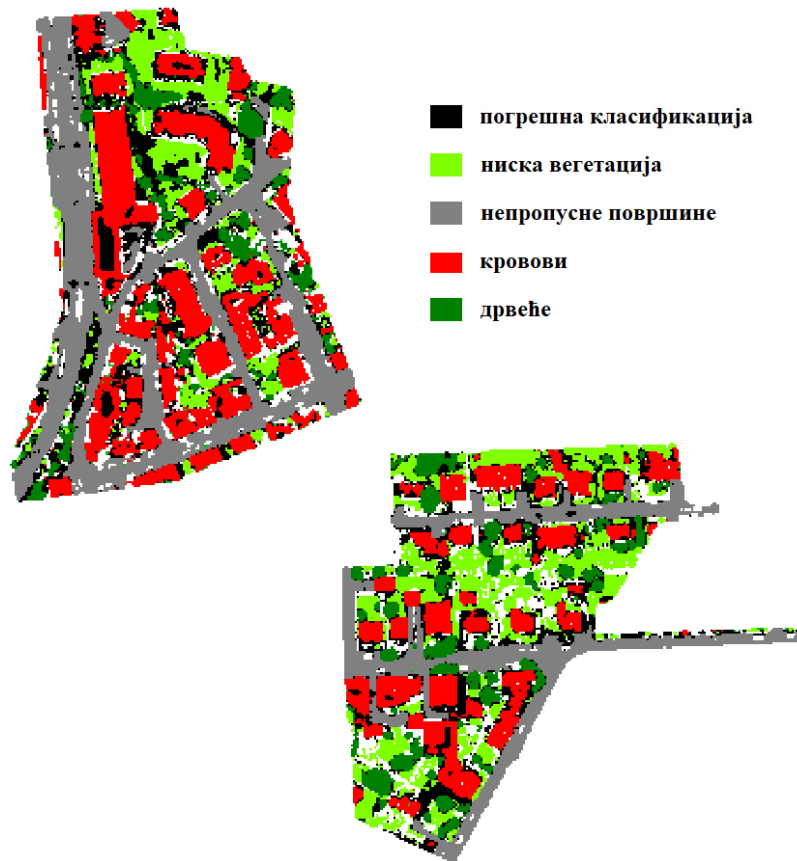
Овде је мало збуњујуће што се и метода логистичке регресије (*LR*) показала као друга по учинку, будући да се са том методом иначе добијали лошији резултати код *D<sub>2</sub>R<sub>1.5</sub>* комбинације. У овом делу експеримента се за *ANN* методу добијају најлошији резултати (*OA* мања од 75%), док методе *ENS\_ANN* и *SVM* имају *OA* мању од 80% (Табела 5.12).

Као графички приказ дата је карта класа као резултат семантичке сегментације када је добијена највиша тачност (*ENS\_NB*) и одговарајућа карта грешака семантичке сегментације добијена са наведеном комбинацијом када су коришћени сви атрибути (Слика 5.16).



Слика 5.16: Најбољи резултати семантичке сегментације (*ENS\_NB* – лево) и карта грешака семантичке сегментације (десно) добијени са *D<sub>2</sub>R<sub>3</sub>* комбинацијом атрибута. Белом бојом су приказане тачке мањинских класа које нису учествовале у семантичкој сегментацији.

Такође је могуће сагледати у којим деловима подручја је погрешно извршена класификација на карти класа са приказаним грешкама семантичке сегментације добијене са *ENS\_NB* класификатором (Слика 5.17).



Слика 5.17: Карта са грешкама семантичке сегментације *ISPRS* скупа података. Приказани су резултати *ENS\_NB* класификатора над подацима генерисаним са  $D_2R_3$  комбинацијом атрибута. Тачке класа које нису учествовале у семантичкој сегментацији приказане су белом бојом.

Као и код претходне комбинације, највише грешака се појављује на ивицама сегмената који припадају једној класи (као што су кровови зграда) где долази до нагле висинске промене између суседних тачака. Понављају се грешке где је скоро цео кров класификован као ниска вегетација због мале висине крова и благог нагиба равни крова, као и код резултата семантичке сегментације  $D_2R_{1.5}$  комбинације (Слика 5.14).

Резултати семантичке сегментације се нису побољшали ни код  $D_2R_3$  комбинације балансирањем класа током тренирања алгоритма (Табела 5.13). У овом случају се опет најбољи резултати добијају наведеним сложеним ансамбл моделом базираном на наивном Бајесу (*ENS\_NB*). Ово важи и у случају кад се семантичка сегментација врши над растерским продуктима (*OA* већа за скоро 1% од следеће рангиране методе) као и када се након побољшања резултата просторном регуларизацијом ознака класа (Табела 5.13).

Табела 5.13 Резултати семантичке сегментације **растерских продуката ISPRS облака тачака балансираних класа** са различитим класификаторима добијени  $D_2R_3$  комбинацијом атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	<i>κ</i>	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	82.6	0.762	84.5	0.788
<i>LR</i>	83.7	0.775	86.3	0.809
<b><i>GB</i></b>	<b>83.8</b>	<b>0.778</b>	<b>86.4</b>	<b>0.810</b>
<i>ENS_RF</i>	83.5	0.775	86.0	0.808
<i>ENS_GB</i>	82.6	0.763	85.3	0.798
<i>ENS_ANN</i>	81.3	0.746	84.1	0.782
<b><i>ENS_NB</i></b>	<b>84.7</b>	<b>0.788</b>	<b>86.7</b>	<b>0.816</b>
<i>AML</i>	81.8	0.751	84.4	0.786

Када се изврши накнадна конверзија у класификован облак тачака, поређењем са референтним тест подацима добија се да *LR* метода даје нешто боље резултате у односу на друге алгоритме. Ови резултати нису бољи од оних добијених семантичком сегментацијом класификатором *ENS\_NB* над подацима који нису балансирани, тј. укупна тачност је мања за 0.3% (Табела 5.14). Може се приметити да су резултати семантичке сегментације добијени са балансираним подацима нешто поузданији јер *OA* прелази 80% за све коришћене методе машинског учења (Табела 5.14).

Табела 5.14 Резултати семантичке сегментације **ISPRS облака тачака балансираних класа** са различитим класификаторима добијени  $D_2R_3$  комбинацијом атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	80.9	0.743
<b><i>LR</i></b>	<b>82.3</b>	<b>0.761</b>
<i>GB</i>	81.8	0.755
<b><i>ENS_RF</i></b>	<b>81.8</b>	<b>0.755</b>
<i>ENS_GB</i>	81.1	0.746
<i>ENS_ANN</i>	80.2	0.735
<i>ENS_NB</i>	81.5	0.750
<i>AML</i>	80.3	0.735

Након извршене рекурзивне елиминације атрибута, добило се да *ENS\_NB* даје најбоље резултате над растерским продуктима (Табела 5.15). Овде се може уочити да су све методе дале добре резултате, тј. ниједна метода није имала значајно нижу *OA* од осталих.

Табела 5.15 Резултати семантичке сегментације *растерских продуката ISPRS облака тачака* са различитим класификаторима добијени *рекурзивном елиминацијом D<sub>2</sub>R<sub>3</sub> комбинацијом* атрибута.

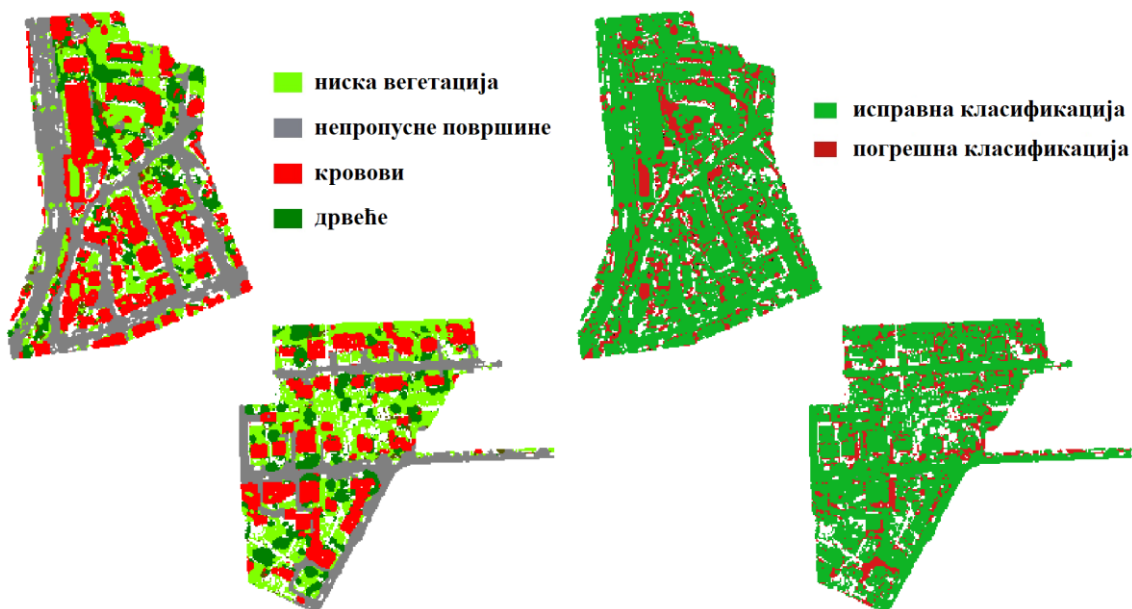
Класификатор	растерска предикција		просторна регуларизација	
	OA [%]	$\kappa$	OA [%]	$\kappa$
<i>RF</i>	84.0	0.781	86.0	0.808
<i>SVM</i>	<b>84.0</b>	<b>0.780</b>	<b>86.4</b>	<b>0.811</b>
<i>ANN</i>	83.8	0.777	86.0	0.806
<i>XGB</i>	83.9	0.779	85.9	0.806
<i>LR</i>	82.3	0.758	84.7	0.789
<i>GB</i>	84.0	0.780	86.2	0.810
<i>ENS_RF</i>	83.9	0.779	86.2	0.810
<i>ENS_GB</i>	83.5	0.774	86.1	0.808
<i>ENS_ANN</i>	83.7	0.777	86.1	0.808
<i>ENS_NB</i>	<b>84.8</b>	<b>0.790</b>	<b>86.9</b>	<b>0.819</b>
<i>AML</i>	83.8	0.777	86.3	0.811

Када се изврши конверзија у класификован облак тачака, добило би се да *SVM* метода даје најбоље резултате ( $OA = 82.4\%$ ), док се *LR* методом добијају најлошији резултати у погледу постигнуте тачности, али ипак са  $OA$  већом од 80% (Табела 5.16).

Табела 5.16 Резултати семантичке сегментације *ISPRS облака тачака* са различитим класификаторима добијени *рекурзивном елиминацијом D<sub>2</sub>R<sub>3</sub> комбинације* атрибута.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	81.6	0.753
<i>SVM</i>	<b>82.4</b>	<b>0.762</b>
<i>ANN</i>	82.1	0.759
<i>XGB</i>	82.0	0.757
<i>LR</i>	80.4	0.736
<i>GB</i>	82.2	0.760
<i>ENS_RF</i>	81.9	0.756
<i>ENS_GB</i>	81.5	0.751
<i>ENS_ANN</i>	81.8	0.754
<i>ENS_NB</i>	81.8	0.754
<i>AML</i>	<b>82.0</b>	<b>0.757</b>

Као графички приказ карте класа дати су резултати семантичке сегментације када је добијена највиша укупна тачност (*SVM*) и одговарајућа карта грешака семантичке сегментације добијена рекурзивном елиминацијом *D<sub>2</sub>R<sub>3</sub> комбинације* атрибута (Слика 5.18).



Слика 5.18: Најбољи резултати семантичке сегментације (*SVM* – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом  $D_2R_3$  комбинације атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији.

Када би се извршило балансирање података према класама приликом тренирања модела машинског учења, метода која даје боље резултате семантичке сегментације растерских продуката у односу на друге јесте ансамбл модел базираном на наивном Бајесу (*ENS\_NB*) (Табела 5.17).

Табела 5.17 Семантичка сегментација растерских продуката *ISPRS* облака тачака балансираних класа са различитим класификаторима добијени рекурзивном елиминацијом  $D_2R_3$  комбинације атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	<i>κ</i>	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	83.2	0.771	85.2	0.797
<i>LR</i>	82.3	0.758	84.7	0.789
<i>GB</i>	83.7	0.777	86.1	0.809
<i>ENS_RF</i>	83.9	0.779	86.2	0.810
<i>ENS_GB</i>	83.5	0.774	86.1	0.808
<i>ENS_ANN</i>	84.0	0.779	86.7	0.816
<b><i>ENS_NB</i></b>	<b>84.8</b>	<b>0.790</b>	<b>86.9</b>	<b>0.819</b>
<i>AML</i>	84.0	0.781	86.8	0.817

У случају кад се изврши конверзија резултата у облак тачака, до изражаја долази аутоматска метода машинског учења (*AML*) са укупном тачношћу од 82.4% (Табела 5.18). Овакве перформансе у погледу укупне тачности имала је и *SVM* метода са небалансираним подацима (Табела 5.16). Балансирањем класа се у овом случају код *AML* методе постигло да је *OA* порасла за 0.4%.



Табела 5.18 Семантичка сегментација *ISPRS* облака тачака балансираних класа са различитим класификаторима добијени  $D_2R_3$  комбинацијом прорачуна рекурзивне елиминације атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	81.3	0.748
<i>LR</i>	80.4	0.736
<b><i>GB</i></b>	<b>81.9</b>	<b>0.756</b>
<i>ENS_RF</i>	81.8	0.756
<i>ENS_GB</i>	81.5	0.751
<i>ENS_ANN</i>	82.0	0.756
<i>ENS_NB</i>	81.7	0.754
<b><i>AML</i></b>	<b>82.4</b>	<b>0.762</b>

Бољи преглед по постигнутој осетљивости (*R*), прецизности (*P*) и Ф1 скору (*F1*) за све моделе машинског учења и четири одабране класе *ISPRS* скупа података за  $D_2R_3$  комбинацију атрибута, дат је у прилозима дисертације (Прилог 3) и то:

- Табела П.6 – када се користе сви атрибути;
- Табела П.7 – када су подаци са свим атрибутима балансирани према класама;
- Табела П.8 – када је извршена рекурзивна елиминација атрибута;
- Табела П.9 – када је извршена рекурзивна елиминација атрибута и подаци балансирани према класама.

За детаљнији преглед и даље анализе формиран су графици засебно за наведене квантитативне мере где се по класама може видети који алгоритам је дао боље резултате (Прилог 6: Слика П.11).

## 5.2.6 Резултати семантичке сегментације за вишеразмерну комбинацију

За вишеразмерну комбинацију добијају се најбољи резултати над растерским продуктима када се користи поменути сложени ансамбл модел базиран на наивном Бајесу – *ENS\_NB* (Табела 5.19). Уколико се изврши просторна регуларизација ознака класа, наведена метода би се по учинку изједначила са *SVM* методом.

Табела 5.19 Резултати семантичке сегментације растерских продуката *ISPRS* облака тачака са различитим класификаторима добијени са вишеразмерном комбинацијом атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$
<i>RF</i>	84.0	0.780	86.3	0.812
<i>SVM</i>	<b>84.9</b>	<b>0.792</b>	<b>87.4</b>	<b>0.826</b>
<i>XGB</i>	84.2	0.783	86.2	0.810
<i>LR</i>	84.0	0.779	86.4	0.811
<i>GB</i>	84.5	0.787	86.6	0.816
<i>ENS_RF</i>	84.4	0.786	86.8	0.818
<i>ENS_GB</i>	84.2	0.783	86.7	0.816
<i>ENS_ANN</i>	84.9	0.792	87.2	0.823
<i>ENS_NB</i>	<b>85.4</b>	<b>0.798</b>	<b>87.4</b>	<b>0.825</b>
<i>AML</i>	83.9	0.780	86.0	0.808

Након конверзије резултата семантичке сегментације у облак тачака, *SVM* метода је дала боље резултате у односу на друге методе (*OA* = 83.5% – Табела 5.20). Ово је уједно и најбољи резултат семантичке сегментације у односу на комбинације атрибута  $D_2R_{1.5}$  и  $D_2R_3$  и то за *OA* већу за скоро 1%.

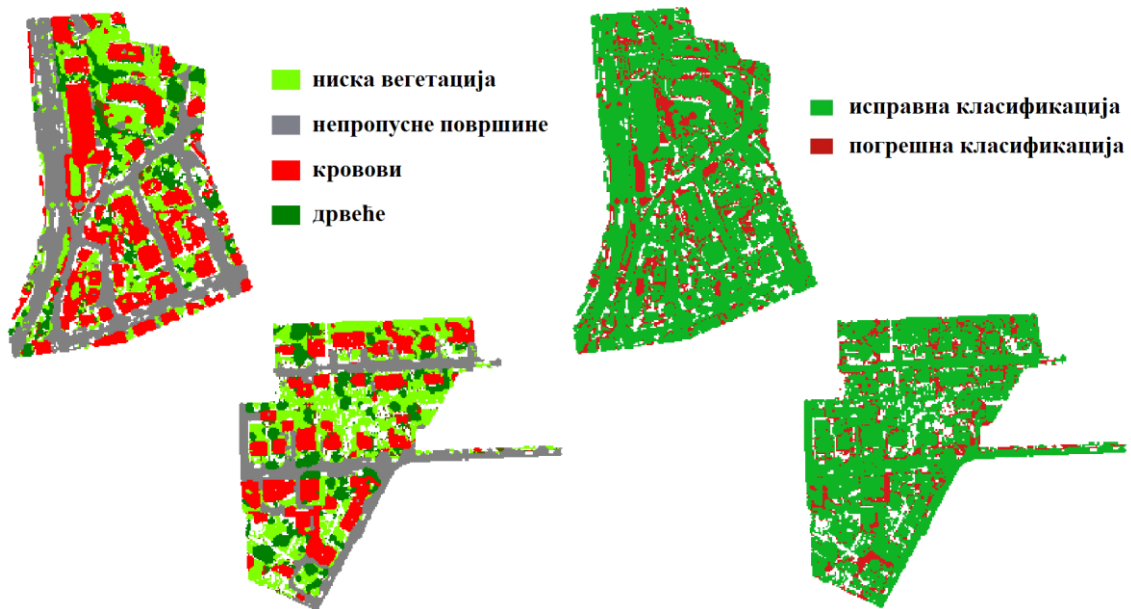
Табела 5.20 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени са вишеразмерном комбинацијом атрибута.

Класификатор	облак тачака	
	<i>OA</i> [%]	$\kappa$
<i>RF</i>	82.1	0.759
<i>SVM</i>	<b>83.5</b>	<b>0.777</b>
<i>XGB</i>	82.4	0.762
<i>LR</i>	82.5	0.764
<i>GB</i>	82.8	0.769
<i>ENS_RF</i>	82.8	0.768
<i>ENS_GB</i>	82.5	0.763
<i>ENS_ANN</i>	<b>83.0</b>	<b>0.770</b>
<i>ENS_NB</i>	82.5	0.764
<i>AML</i>	82.0	0.758

Интересантно је приметити да је већи број атрибута у вишеразмерној комбинацији довео до знатног побољшања резултата семантичке сегментације облака тачака свих коришћених метода, и да су тада резултати *OA* за све коришћене методе већи од 82%.

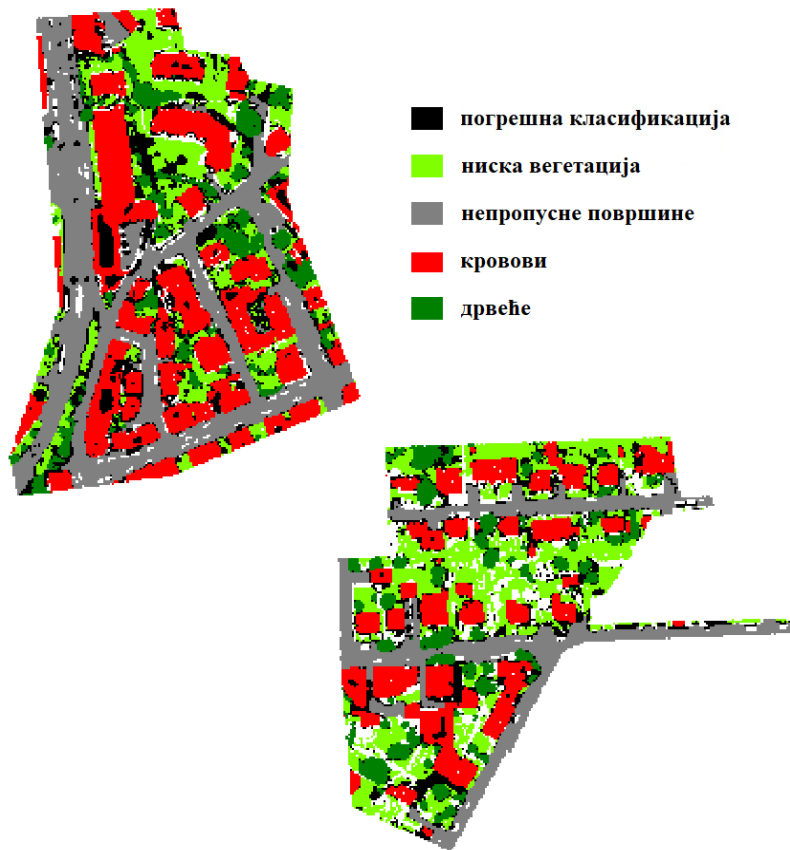
Аутоматска метода машинског учења (*AML*) направљена је у виду ансамбла слаганих модела за вишеразмерну комбинацију атрибута. Ова метода је заснована на 20 основних модела машинског учења: девет модела вештачких неуронских мрежа, два модела случајне шуме, осам модела градијентног појачавања и једног генерализованог линеарног модела. Алгоритам коришћен за слагање модела био је генерализовани линеарни модел, док је оцена тачности модела добијена петоструком унакрсном валидацијом.

Као графички приказ карте класа могу се сагледати резултати семантичке сегментације када је добијена највиша тачност (*SVM*) и одговарајућа карта грешака семантичке сегментације добијена са наведеном комбинацијом када су коришћени сви атрибути (Слика 5.19).



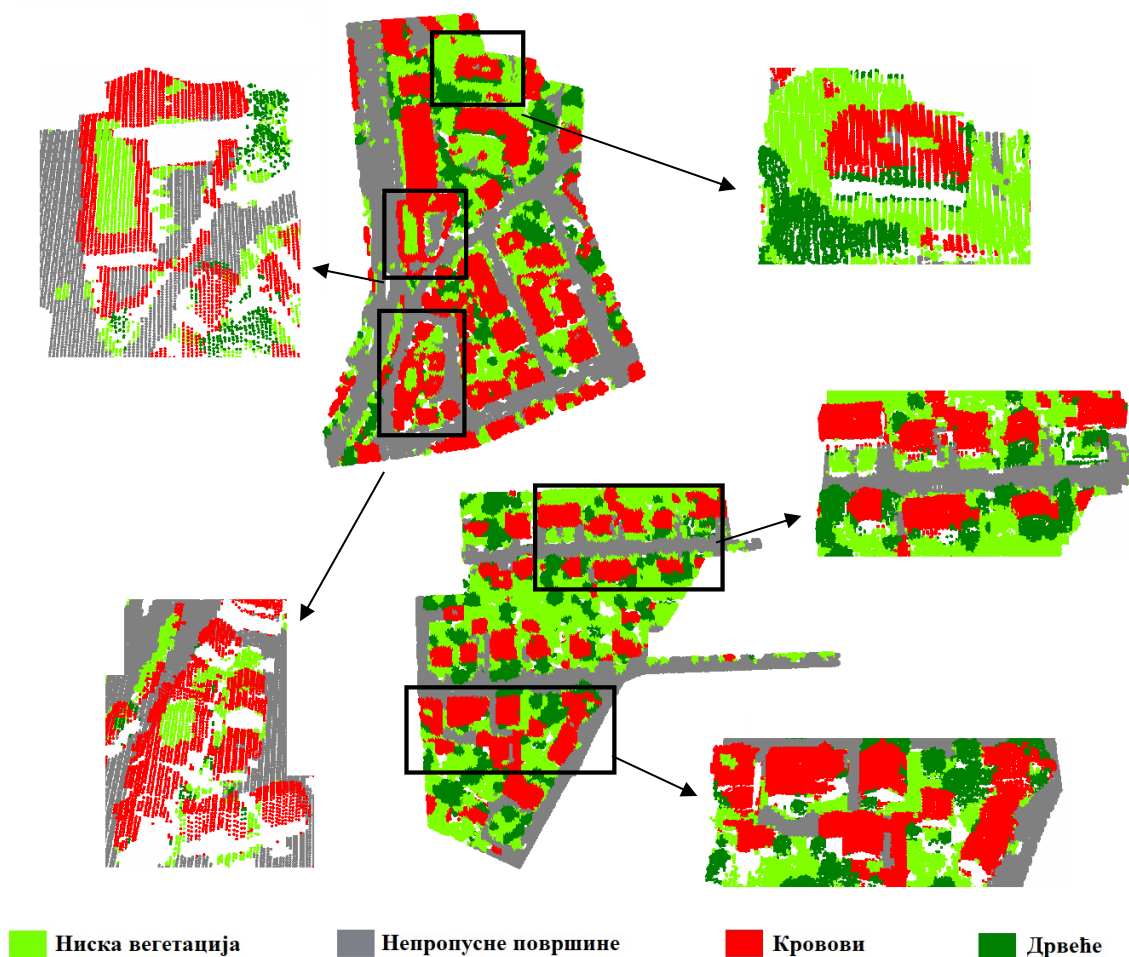
Слика 5.19: Најбољи резултати семантичке сегментације (*SVM* – лево) и карта грешака семантичке сегментације (десно) добијена вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке мањинских класа које нису учествовале у семантичкој сегментацији.

Такође је могуће уочити у којим деловима подручја је погрешно извршена класификација на карти класа са приказаним грешкама семантичке сегментације изведене *SVM* класификатором (Слика 5.20).



Слика 5.20: Карта са грешкама семантичке сегментације *ISPRS* скупа података. Приказани су резултати *SVM* класификатора над подацима генерисаним са вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији.

Када се користи наведена комбинација са различитим варијантама атрибута, најчешће грешке семантичке сегментације се појављују код кровова зграда чији делови буду класификовани као ниска вегетација (Слика 5.21 – лево). Друге типичне грешке семантичке сегментације које се појављују код ових података јесу класификација тачака које се налазе на ивицама кровова у класу дрвећа (Слика 5.21 – десно).



Слика 5.21: Највеће грешке семантичке сегментације *ISPRS* тест података. Кровови зграда (црвено) класификовани у класу ниске вегетације (светло зелено) и дрвеће (тамно зелено).

Резултати семантичке сегментације се нису побољшали балансирањем класа током тренирања алгоритма, побољшањем резултата просторном регуларизацијом ознака класа (Табела 5.21) и конверзијом у класификован облак тачака (Табела 5.22). У овом случају су се најбољи резултати над растерским продуктима добили сложеним ансамбл моделима (*ENS\_ANN* и *ENS\_NB*).

Најбољи резултати семантичке сегментације облака тачака добијени су коришћењем аутоматске методе машинског учења и логистичке регресије (*AML* и *LR* – Табела 5.22). У овом случају су се код *AML* методе побољшали резултати у виду укупне тачности за 0.4% у односу на податке који нису балансирани. Разлог зашто ове методе долазе до изражаја је и у томе што се приликом тренирања *SVM* модела подаци нису могли балансирати и стога ни резултати нису били упоређени.

Табела 5.21 Резултати семантичке сегментације **растерских продуката ISPRS облака тачака балансираних класа** са различитим класификаторима добијени са **вишеразмерном комбинацијом** атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	OA [%]	$\kappa$	OA [%]	$\kappa$
<i>RF</i>	83.3	0.772	85.4	0.800
<i>LR</i>	84.0	0.779	86.4	0.811
<i>GB</i>	84.2	0.784	86.6	0.815
<i>ENS_RF</i>	84.3	0.785	86.7	0.816
<i>ENS_GB</i>	84.2	0.784	86.7	0.817
<i>ENS_ANN</i>	<b>85.2</b>	<b>0.794</b>	<b>87.2</b>	<b>0.822</b>
<i>ENS_NB</i>	<b>84.7</b>	<b>0.789</b>	<b>86.7</b>	<b>0.816</b>
<i>AML</i>	84.1	0.781	86.5	0.813

Табела 5.22 Резултати семантичке сегментације **ISPRS облака тачака балансираних класа** са различитим класификаторима добијени са **вишеразмерном комбинацијом** атрибута.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	81.4	0.749
<i>LR</i>	<b>82.5</b>	<b>0.764</b>
<i>GB</i>	82.3	0.762
<i>ENS_RF</i>	82.2	0.760
<i>ENS_GB</i>	<b>82.3</b>	<b>0.761</b>
<i>ENS_ANN</i>	82.1	0.757
<i>ENS_NB</i>	81.7	0.753
<i>AML</i>	<b>82.4</b>	<b>0.763</b>

У случају извршене рекурзивне елиминације атрибута, добија се да *ENS\_NB* даје најбоље резултате над растерским продуктима (Табела 5.23).

Табела 5.23 Резултати семантичке сегментације **растерских продуката ISPRS облака тачака** са различитим класификаторима добијени **рекурзивном елиминацијом вишеразмерне комбинације** атрибута.

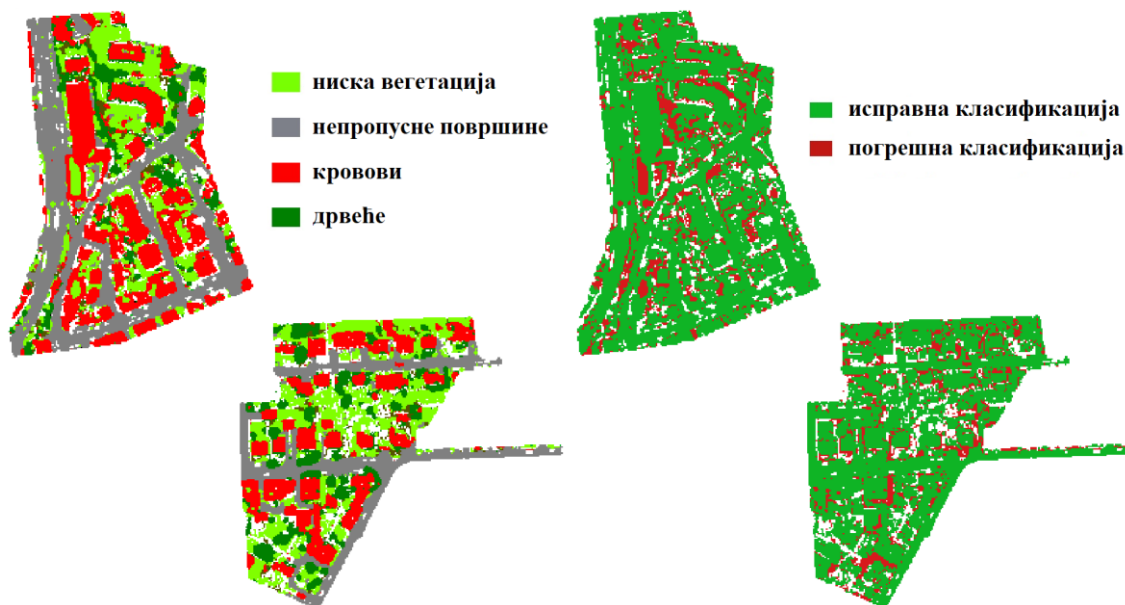
Класификатор	растерска предикција		просторна регуларизација	
	OA [%]	$\kappa$	OA [%]	$\kappa$
<i>RF</i>	83.9	0.780	86.2	0.811
<i>SVM</i>	84.4	0.786	86.8	0.818
<i>ANN</i>	82.4	0.760	85.5	0.801
<i>XGB</i>	84.1	0.782	86.1	0.809
<i>LR</i>	83.3	0.770	85.5	0.800
<i>GB</i>	84.2	0.783	86.4	0.813
<i>ENS_RF</i>	84.1	0.782	86.4	0.813
<i>ENS_GB</i>	83.8	0.778	86.2	0.810
<i>ENS_ANN</i>	84.6	0.788	87.1	0.821
<i>ENS_NB</i>	<b>85.3</b>	<b>0.797</b>	<b>87.2</b>	<b>0.823</b>
<i>AML</i>	83.4	0.773	85.9	0.805

У случају конверзије резултата у облак тачака, до изражаја долази *SVM* метода, али и сложени ансамбл модел базиран на вештачким неуронским мрежама – *ENS\_ANN* (Табела 5.24). Ипак ови резултати нису бољи од резултата семантичке сегментације постигнутих коришћењем свих атрибута за тренирање модела (Табела 5.20).

Табела 5.24 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени рекурзивном елиминацијом вишеразмерне комбинације атрибута.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	82.2	0.760
<i>SVM</i>	<b>82.7</b>	<b>0.766</b>
<i>ANN</i>	82.2	0.759
<i>XGB</i>	82.2	0.761
<i>LR</i>	81.4	0.749
<i>GB</i>	82.5	0.764
<i>ENS_RF</i>	82.2	0.760
<i>ENS_GB</i>	81.8	0.755
<i>ENS_ANN</i>	<b>82.8</b>	<b>0.767</b>
<i>ENS_NB</i>	82.3	0.761
<i>AML</i>	81.7	0.752

Као графички приказ могу се видети резултати семантичке сегментације када је добијена највиша укупна тачност (*ENS\_ANN*) и карта грешака семантичке сегментације са вишеразмерном комбинацијом кад је извршена рекурзивна елиминација атрибута (Слика 5.22).



Слика 5.22: Најбољи резултати семантичке сегментације (*ENS\_ANN* – лево) и карта грешака семантичке сегментације (десно) добијени рекурзивном елиминацијом вишеразмерне комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији.

У случају кад се изврши балансирање података према класама приликом тренирања модела машинског учења, метода која даје нешто боље резултате у односу на друге

била је сложени ансамбл модел базираном на наивном Бајесу (*ENS\_NB*). Ово се односи на резултате растерских продуката добијених пре и после извршене просторне регуларизације класа (Табела 5.25).

Табела 5.25 Резултати семантичке сегментације **растерских продуката ISPRS облака тачака балансираних класа** са различитим класификаторима добијени **рекурзивном елиминацијом вишеразмерне комбинације** атрибута.

Класификатор	растерска предикција		просторна регуларизација	
	ОА [%]	κ	ОА [%]	κ
<i>RF</i>	83.6	0.776	85.5	0.802
<i>LR</i>	83.3	0.770	85.5	0.800
<i>GB</i>	83.8	0.778	86.1	0.809
<i>ENS_RF</i>	84.0	0.781	86.3	0.812
<i>ENS_GB</i>	83.8	0.778	86.2	0.810
<i>ENS_ANN</i>	84.0	0.779	86.4	0.812
<b><i>ENS_NB</i></b>	<b>85.0</b>	<b>0.794</b>	<b>86.8</b>	<b>0.817</b>
<i>AML</i>	84.1	0.782	86.4	0.812

Након конверзије резултата семантичке сегментације у облак тачака, највиша *ОА* која се постиже у случају више сложених модела насталих слагањем је 81.9%, што је за скоро 1% нижа укупна тачност од најбоље методе у ситуацији кад се не врши балансирање података према класама (Табела 5.26).

Табела 5.26 Резултати семантичке сегментације **ISPRS облака тачака балансираних класа** са различитим класификаторима добијени **рекурзивном елиминацијом вишеразмерне комбинације** атрибута.

Класификатор	облак тачака	
	ОА [%]	κ
<i>RF</i>	81.5	0.751
<i>LR</i>	81.4	0.749
<i>GB</i>	82.1	0.759
<b><i>ENS_RF</i></b>	<b>81.9</b>	<b>0.756</b>
<i>ENS_GB</i>	81.7	0.753
<b><i>ENS_ANN</i></b>	<b>81.9</b>	<b>0.755</b>
<b><i>ENS_NB</i></b>	<b>81.9</b>	<b>0.756</b>
<i>AML</i>	81.4	0.749

Бољи преглед по постигнутој осетљивости (*R*), прецизности (*P*) и  $\Phi 1$  скору (*F1*) за све моделе машинског учења и четири одабране класе *ISPRS* скупа података, дат је у прилозима дисертације (Прилог 4) и то:

- Табела П.10 – када се користе сви атрибути;
- Табела П.11 – када су подаци са свим атрибутима балансирани према класама;
- Табела П. 12 – када је извршена рекурзивна елиминација атрибута;
- Табела П.13 – када је извршена рекурзивна елиминација атрибута и подаци балансирани према класама.



За детаљнији преглед и даље анализе формиран су графици засебно за наведене квантитативне мере где се по класама може сагледати који алгоритам је дао боље резултате (Прилог 6: Слика П.12).

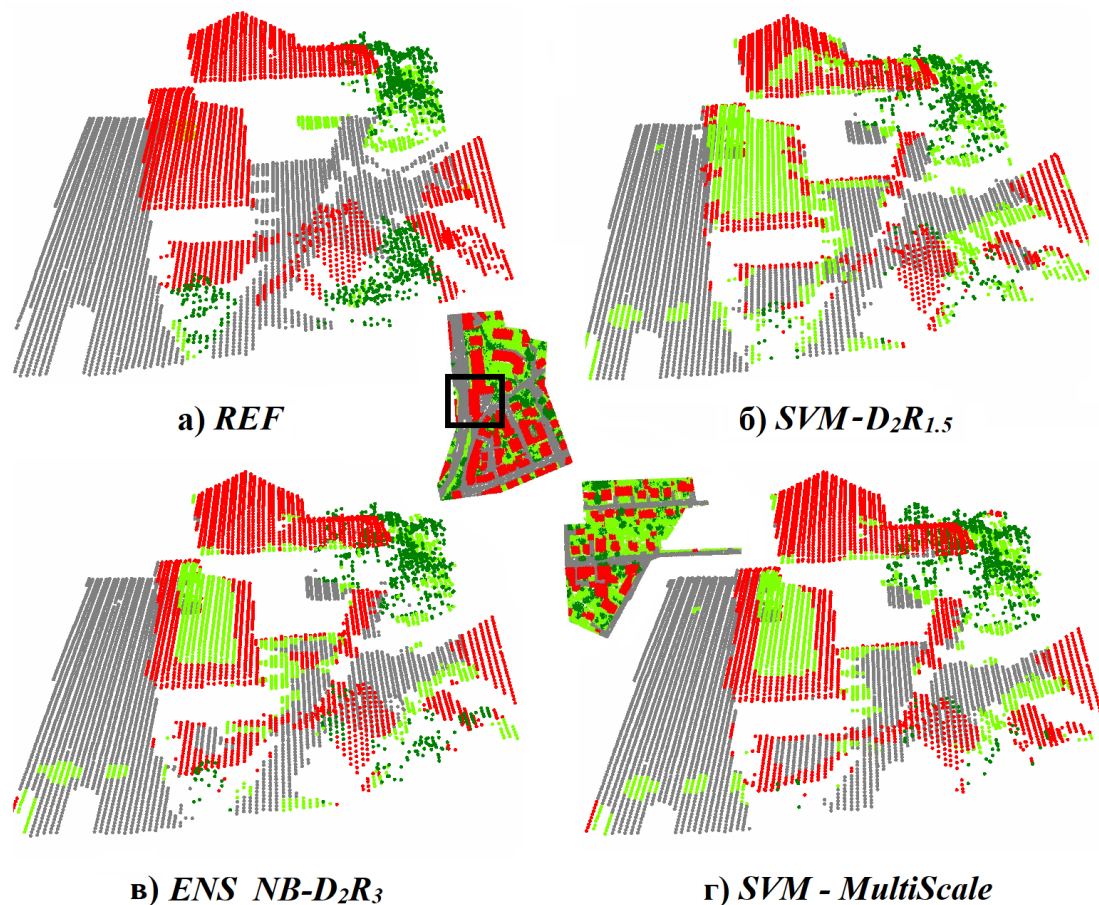
Будући да је вишеразмерна комбинација свеукупно дала најбоље резултате, она је даље коришћена за анализу количине тренинг података потребне да се истренира модел којим се најбоље врши семантичка сегментација. Ово је изведено узорковањем података, при чему се водило рачуна о балансирању класа.

### **5.2.7 Упоредна анализа резултата семантичке сегментације *ISPRS* података коришћењем различитих комбинација атрибута**

У овом поглављу је извршено визуелно поређење резултата семантичке сегментације облака тачака. Дато је поређење референтних података на више локација са најбољим резултатима семантичке сегментације за  $D_2R_{1.5}$ ,  $D_2R_3$  и вишеразмерну комбинацију атрибута.

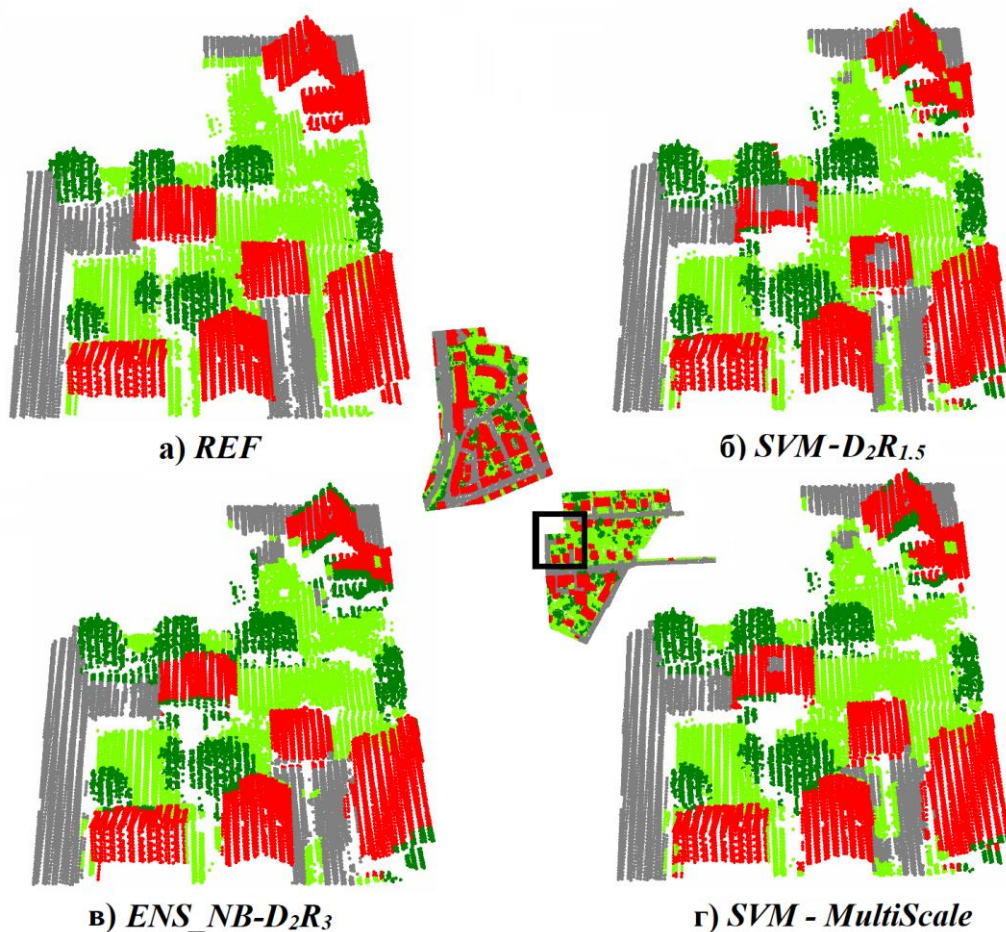
Досадашње анализе са *ISPRS* подацима указују на то да се најбољи резултати семантичке сегментације добијају вишеразмерном комбинацијом атрибута, при чему се користи *SVM* метода машинског учења за семантичку сегментацију облака тачака ( $OA = 83.5\%$ ). Резултати семантичке сегментације  $D_2R_3$  комбинације атрибута најбољи су исто код *SVM* методе ( $OA = 82.1\%$ ), док је за  $D_2R_{1.5}$  комбинацију атрибута најбоље резултате дао *ENS\_NB* сложени ансамбл модел ( $OA = 82.6\%$ ).

Грешке семантичке сегментације које су се појављивале код све три коришћене комбинације атрибута биле су да је део облака тачака који представља кров зграде делимично класификован као ниска вегетација (Слика 5.23). Ово се најчешће дешава код оних кровова који имају мали нагиб, па се такве површине помешају са вештачким површинама или са ниском вегетацијом. У овом случају, лошије резултате дала је  $D_2R_{1.5}$  комбинација у односу на друге две комбинације, док су резултати добијени са  $D_2R_3$  комбинацијом незнатно бољи од вишеразмерне комбинације атрибута. Овде се може видети да је и мањи кров испод поменутог погрешно класификован као непропусне површине. У овој ситуацији  $D_2R_3$  комбинација атрибута дала је најбоље резултате, тј. са овом комбинацијом је најмањи део сегмента крова погрешно класификован као ниска вегетација (Слика 5.23).



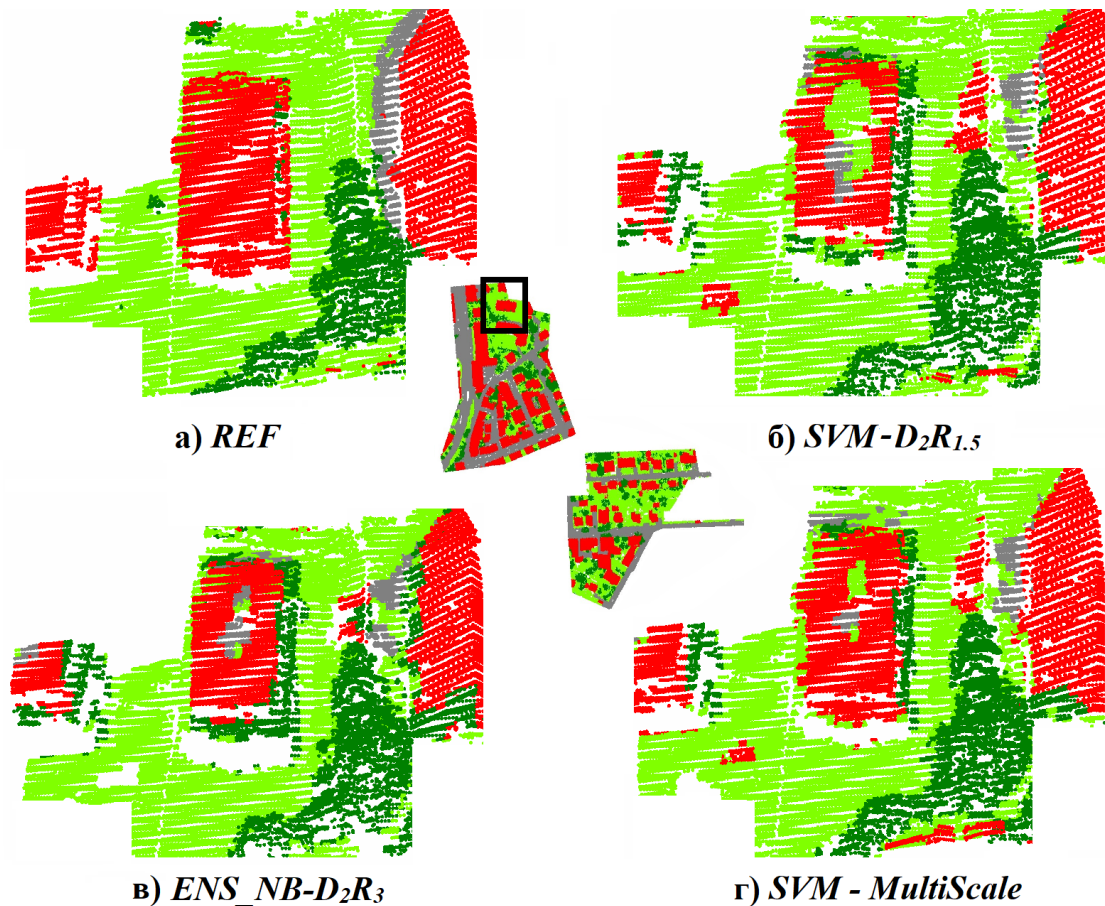
Слика 5.23: Поређење резултата семантичке сегментације благо нагнутог крова: а) референтни подаци, б) *SVM* са  $D_2R_{1.5}$  комбинацијом, в) *ENS\_NB* са  $D_2R_3$  комбинацијом и г) *SVM* са вишеразмерном комбинацијом атрибута. У средини је дата позиција локације на том подручју.

Честе грешке семантичке сегментације појављују се на ивицама кровова, при чему су тачке кровова погрешно класификоване најчешће у дрвеће, што су иначе грешке које настају и код стандардних алгоритама који се користе за класификацију облака тачака (Слика 5.24 – кућа у горњем десном углу). Визуелно, овде делује да најмање таквих грешака има код  $D_2R_{1.5}$  комбинације, али се код ове комбинације јављају и грешке где су тачке кровова малих, ниских објеката погрешно класификоване у непропусне површине (шупе у средини слике). Тих грешака има најмање код  $D_2R_3$  комбинације, док је вишеразмерна комбинација оптимално решење и за један и други тип грешака. Добијени ефекат је донекле сузбијен просторном регуларизацијом ознака класа у којој се отклањају тачке које представљају шум у означавању класа, али се и даље поткраде понека грешка. Грешке семантичке сегментације се јављају и код непропусних површина тј. мањих прилазних путева који су погрешно класификовани као ниска вегетација (Слика 5.24 – доле десно). Оваквих грешака је најмање било код  $D_2R_3$  комбинације.



Слика 5.24: Поређење резултата семантичке сегментације – грешака код ивица кровова: а) референтни подаци, б) *SVM* са  $D_2R_{1.5}$  комбинацијом, в) *ENS\\_NB* са  $D_2R_3$  комбинацији и г) *SVM* са вишеразмерном комбинацијом атрибута. У средини је дата позиција локације на том подручју.

Последња ситуација приказује такође грешке семантичке сегментације на крововима зграда где су тачке погрешно класификоване у ниску вегетацију и непропусне површине (Слика 5.25). Такође су видљиве грешке које се појављују на ивицама кровова где су тачке погрешно класификоване у класу дрвећа. Вишеразмерна комбинација је имала најмање оваквих грешака, и једног и другог типа. У десном делу слике видљив је узак путић који пролази поред зграде и који је посебно компликован за семантичку сегментацију. Само фрагменти овог пута су правилно класификовани у непропусне површине, док је већи део погрешно класификован у ниску вегетацију. Такође, поред пута постоји један део терена са ниском вегетацијом у продужетку групе дрвећа који је погрешно класификован у класу кровова зграда и дрвећа.




Слика 5.25: Поређење резултата семантичке сегментације крова класификованог као непропусне површине и ниска вегетација: а) референтни подаци, б) *SVM* са  $D_2R_{1.5}$  комбинацијом, в) *ENS\_NB* са  $D_2R_3$  комбинацијом и г) *SVM* са вишеразмерном комбинацијом атрибута. У средини слике је дат преглед позиције локације на том подручју.

### 5.3 Експеримент 3: Семантичка сегментација *ISPRS* облака тачака са узоркованим тренинг подацима и вишеразмерном комбинацијом атрибута

У овом поглављу су описани резултати експеримента редукције података потребних за тренирање модела машинског учења са вишеразмерном комбинацијом атрибута. Циљ експеримента је анализирање утицаја редукције количине података за тренирање модела имајући у виду количину тест података над којим треба извршити предикцију. Поглавље 5.3.1 садржи опис процедуре узорковања тренинг података, док је у поглављу 5.3.2 дат опис добијених резултата семантичке сегментације са таквим подацима.

### 5.3.1 Узорковање тренинг података вишеразмерне комбинације атрибута

Узорковање тренинг података извршено је смањењем података тако што се задржава 90%, а одбацује 10% укупне количине података, при чему се одржава балансираност података у погледу класне заступљености примерака. Наведена процедура је извршена коришћењем функције *partition* из *R* пакета *groupdata2* (Olsen, 2022), помоћу које се формирају балансиране партиције података према одређеној варијабли (класи). Након тога је извршено тренирање *RF* модела машинског учења са умањеном количином тренинг података и вршена предикција над тест подацима. Ово је учињено да би се дошло до закључка да ли се редуkcијом података за тренирање модела губи на перформансама семантичке сегментације. Поступак је итеративан, тј. након добијања резултата тачности предикције врши се даље умањивање тренинг података за 10% и понавља цео поступак. Резултати узорковања приказани су у виду графика где је на хоризонталној оси дат је број примерака који учествују у тренирању модела, а на вертикалној оси графика је нанета постигнута укупна тачност модела (Слика 5.26).



Слика 5.26: Утицај смањења количине тренинг података у односу на укупну тачност *RF* модела.

Овде се може видети да се и са смањеним скупом тренинг података добијају задовољавајући резултати, што може да указује и на квалитетну информативност атрибута. Разлике између укупних тачности појединачних модела тренираних са редукованим количинама података су веома мале. Ово је и добро зато што је на овај начин оправдана редуkcија, са обзиром на бенефите које доноси у рачунарским перформансама. Ако се посматра график (Слика 5.26), може се уочити да је модел генерисан са редукованим тренинг подацима од скоро 46 700 примерака дао нешто боље резултате од других у погледу укупне тачности. Стога ће наведени модел бити усвојен за даље анализе како би се проверило да ли смањење количине података за тренинг утиче на појављивање неких других грешака семантичке сегментације. Корисно је знати и да је број примерака у тест подацима који су коришћени за предикцију био незнатно мањи од ове количине података, око 44 000 примерака,

што доводи до могућег закључка да би једнака количина података и у тренинг и у тест делу података довела до најбољих перформанси. Количина података мања од ове даје нешто нижу тачност, док се количином података већом од наведене не добија виша тачност. Даљим повећањем количине података укупна тачност семантичке сегментације се не мења значајно (Слика 5.26).

У следећем поглављу је усвојена количина узоркованих података добијена у овом кораку искоришћена за тренирање свих других модела машинског учења.

### 5.3.2 Резултати семантичке сегментације узоркованих тренинг података вишеразмерне комбинације атрибута

За вишеразмерну комбинацију са узоркованим тренинг подацима такође се добијају најбољи резултати над растерским продуктима када се користи сложени ансамбл модел базиран на наивном Бајесу – *ENS\_NB* (Табела 5.27). Уколико се изврши просторна регуларизација ознака класа, *SVM* метода би се по учинку скоро изједначила са наведеном методом. У овој ситуацији се сложени ансамбл модел базиран на вештачким неуронским мрежама (*ENS\_ANN*) није могао истренирати над узоркованим подацима. Разлог је био у томе што редукована количина података за потребе овог експеримента није била довољна за тренирање *ENS\_ANN* модела.

Табела 5.27 Резултати семантичке сегментације растерских продуката *ISPRS* облака тачака са различитим класификаторима добијени са вишеразмерном комбинацијом атрибута узоркованих тренинг података.

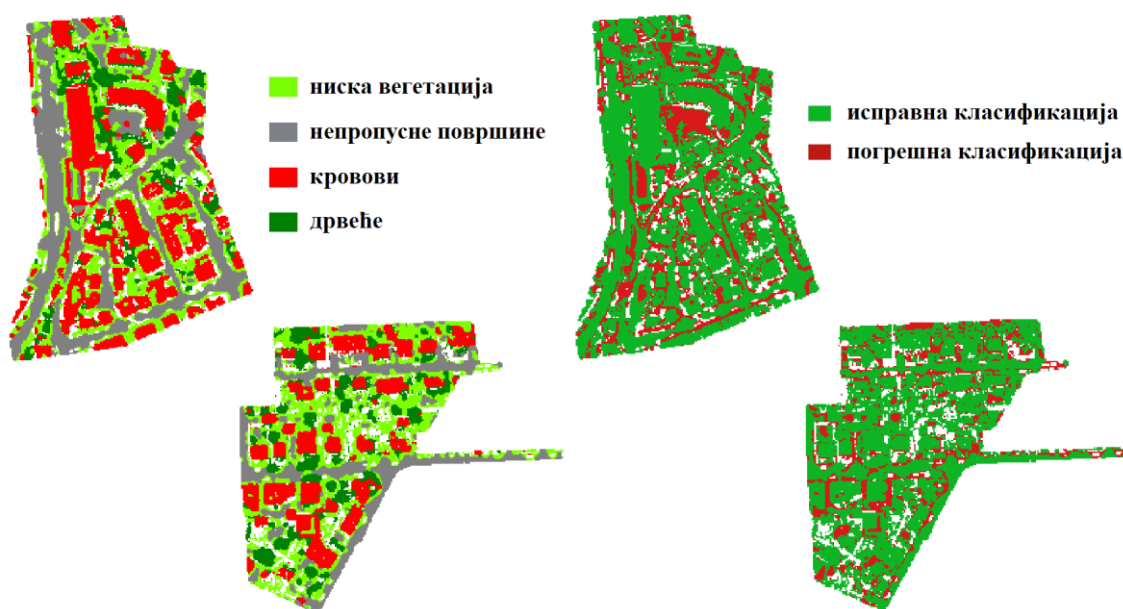
Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	$\kappa$	<i>OA</i> [%]	$\kappa$
<i>RF</i>	84.0	0.781	86.3	0.811
<i>SVM</i>	<b>84.4</b>	<b>0.785</b>	<b>86.8</b>	<b>0.817</b>
<i>XGB</i>	83.9	0.779	86.0	0.808
<i>LR</i>	83.2	0.770	85.6	0.801
<i>GB</i>	84.1	0.782	86.5	0.814
<i>ENS_RF</i>	84.0	0.780	86.4	0.812
<i>ENS_GB</i>	84.0	0.780	86.6	0.815
<i>ENS_NB</i>	<b>85.0</b>	<b>0.792</b>	<b>86.9</b>	<b>0.818</b>
<i>AML</i>	83.5	0.774	85.9	0.806

Након конверзије растерске слике семантичке сегментације у облак тачака, *SVM* метода даје нешто боље резултате од већине метода (*OA* = 82.9% – Табела 5.28). Ово је нешто лошији резултат у односу на вишеразмерну комбинацију кад се користе сви расположиви тренинг подаци (*OA* мања за 0.6%), али опет нешто бољи у односу на најбоље резултате комбинација атрибута *D<sub>2</sub>R<sub>1.5</sub>* и *D<sub>2</sub>R<sub>3</sub>* и то за скоро 0.5% у укупној тачности.

Табела 5.28 Резултати семантичке сегментације *ISPRS* облака тачака са различитим класификаторима добијени са вишеразмерном комбинацијом атрибута узоркованих тренинг података.

Класификатор	облак тачака	
	OA [%]	$\kappa$
<i>RF</i>	82.2	0.760
<i>SVM</i>	<b>82.9</b>	<b>0.769</b>
<i>XGB</i>	82.0	0.758
<i>LR</i>	81.4	0.750
<i>GB</i>	82.6	0.766
<i>ENS_RF</i>	82.2	0.760
<i>ENS_GB</i>	82.4	0.763
<i>ENS_NB</i>	82.0	0.758
<i>AML</i>	82.1	0.758

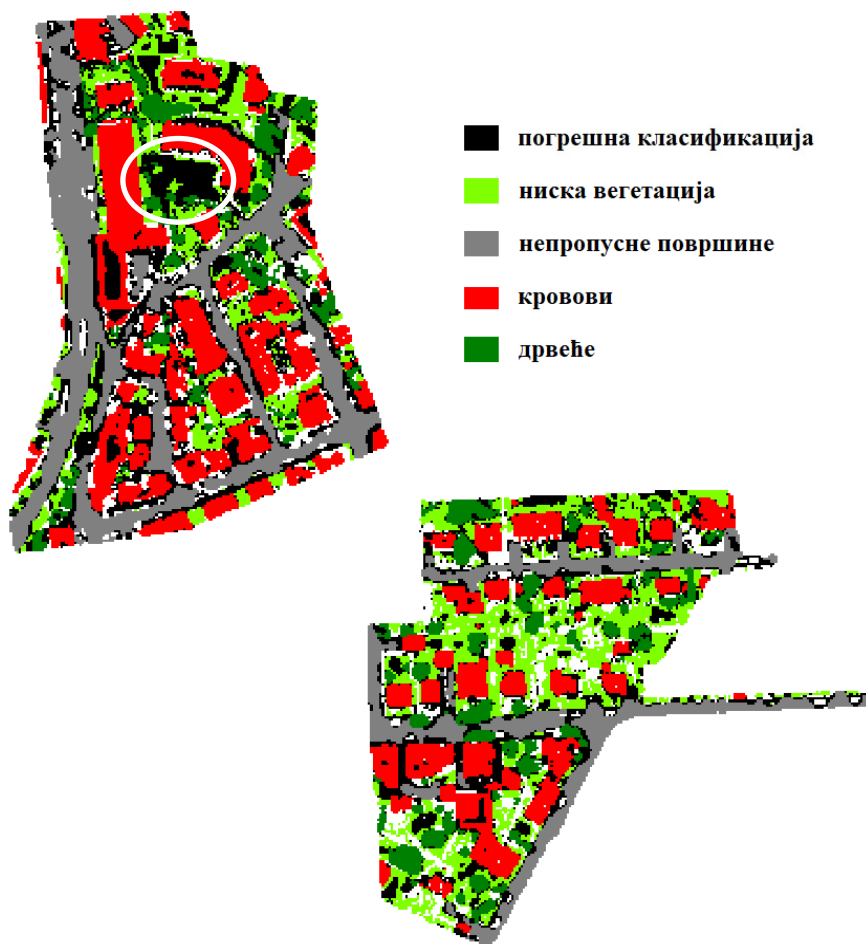
Као графички приказ карте класа дати су резултати семантичке сегментације када је добијена највиша укупна тачност (*SVM*) и карта грешака семантичке сегментације са вишеразмерном комбинацијом кад је извршено узорковање тренинг података (Слика 5.27).



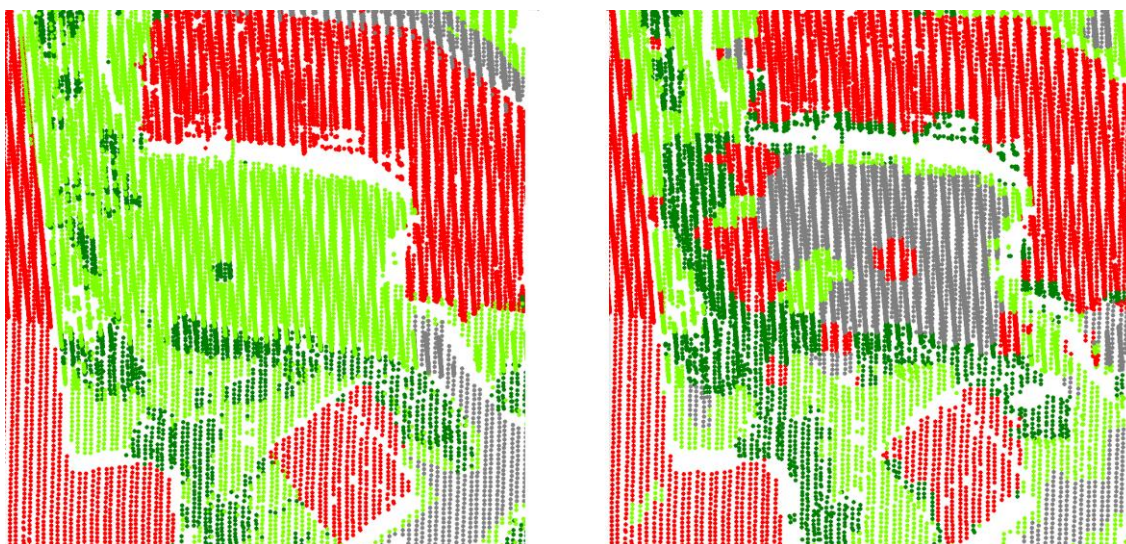
Слика 5.27: Најбољи резултати семантичке сегментације са *SVM* класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута узоркованих података.

Такође је могуће приметити у којим деловима подручја је погрешно извршена класификација на карти класа са приказаним грешкама семантичке сегментације добијених са *SVM* класификатором (Слика 5.28). У односу на претходне резултате семантичке сегментације, може се видети да има више грешака у горњем делу тест подручја (Слика 5.28 – заокружени део).

У том делу су додатно настале грешке семантичке сегментације, тако да су тачке које припадају ниској вегетацији погрешно класификоване у класу непропусних површина, па чак и у класу кровова (Слика 5.29).



Слика 5.28: Карта са грешкама семантичке сегментације *ISPRS* скупа података. Дати су резултати *SVM* класификатора над узоркованим тренинг подацима вишеразмерне комбинације атрибута.



Слика 5.29: Приказ референтних података (лево) и додатних грешака семантичке сегментације облака тачака над узоркованим тренинг подацима вишеразмерне комбинације атрибута (десно).



Резултати семантичке сегментације се нису значајно побољшали уколико би се вршило балансирање класа током тренирања алгорита (Табела 5.29 и Табела 5.30). У случају када се изврши конверзија резултата семантичке сегментације на облак тачака, најбољи резултати добијени су коришћењем сложеног ансамбл модела аутоматске методе машинског учења – *AML* (Табела 5.30). У овом случају је укупна тачност нижа за 0.5% у односу на претходни учинак *SVM* методе.

Табела 5.29 Резултати семантичке сегментације **растерских продуката ISPRS облака тачака** балансираних класа са различитим класификаторима ердобјени **вишеразмерном комбинацијом** прорачуна **рекурзивне елиминације атрибута** узоркованим тренинг података.

Класификатор	растерска предикција		просторна регуларизација	
	<i>OA</i> [%]	<i>κ</i>	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	83.4	0.773	85.5	0.801
<i>LR</i>	83.2	0.770	85.6	0.801
<i>GB</i>	83.6	0.776	86.0	0.808
<i>ENS_RF</i>	84.2	0.783	86.5	0.813
<i>ENS_GB</i>	84.1	0.782	86.5	0.814
<i>ENS_NB</i>	<b>85.2</b>	<b>0.795</b>	<b>86.8</b>	<b>0.817</b>
<i>AML</i>	84.0	0.781	86.5	0.814

Табела 5.30 Резултати семантичке сегментације **ISPRS облака тачака** балансираних класа са различитим класификаторима добијени **вишеразмерном комбинацијом** прорачуна **рекурзивне елиминације атрибута** узоркованих тренинг података.

Класификатор	облак тачака	
	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	81.4	0.750
<i>LR</i>	81.4	0.750
<i>GB</i>	81.7	0.754
<i>ENS_RF</i>	82.0	0.757
<i>ENS_GB</i>	82.1	0.758
<i>ENS_NB</i>	81.6	0.751
<i>AML</i>	<b>82.4</b>	<b>0.763</b>

Бољи преглед по постигнутој осетљивости (*R*), прецизности (*P*) и  $\Phi 1$  скору (*F1*) за све методе машинског учења и четири одабране класе узоркованог *ISPRS* скупа података, дат је у прилозима дисертације (Прилог 4) и то:

- Табела П.14 – када се користе сви атрибути;
- Табела П.15 – када је извршена рекурзивна елиминација атрибута;

За детаљнији преглед и даље анализе формиран су графици засебно за наведене квантитативне мере где се по класама може сагледати који алгоритам је дао боље резултате (Прилог 7: Слика П.13).

## 5.4 Експеримент 4: Семантичка сегментација GRSS облака тачака

Будући да је над *ISPRS* подацима утврђено да се најбољи резултати добијају са вишеразмерној комбинацијом, исти приступ је примењен и за *GRSS* податке тј. атрибути су срачунати за више начина претраге са различитим полупречницима претраге (поглавље 3.2.2). За ове податке је одмах извршена рекурзивна елиминација атрибута, будући да је велика количина података одвојена за тренирање модела и наведена комбинација има велики број атрибута. Атрибути који су коришћени након рекурзивне елиминације били су: *Amplitude*, *EchoRatio*, *MIN*, *NormalizedZ*, *NormalSigma0*, *PosOpenness*, *RANGE*, *Rank*, *RelativeZ*, *stdDevMAD* и *VARIANCE*. Након тога је извршена семантичка сегментација свим већ испробаним методама машинског учења, при чему није вршена просторна регуларизација ознака класа након добијања растерских продуката, јер се тим поступком над овим подацима нису добили бољи резултати и зато нису ни приказани у дисертацији.

Као што се може видети из резултата семантичке сегментације облака тачака, највишу укупну тачност даје сложени ансамбл модел базиран на наивном Бајесу – *ENS\_NB* ( $OA = 93.6\%$ ). Скоро исти учинак има и сложени ансамбл модел базиран на вештачким неуронским мрежама – *ENS\_ANN* (Табела 5.31). Мора се додати и да су све друге методе дале добре резултате семантичке сегментације са  $OA$  већом од  $82.5\%$ .

У наведеној табели су, поред вредности укупне тачности и капа коефицијента слагања, унете и вредности мера перформанси (осетљивост –  $R$ , прецизност –  $P$  и  $F1$  скор –  $FI$ ) за све моделе семантичке сегментације.

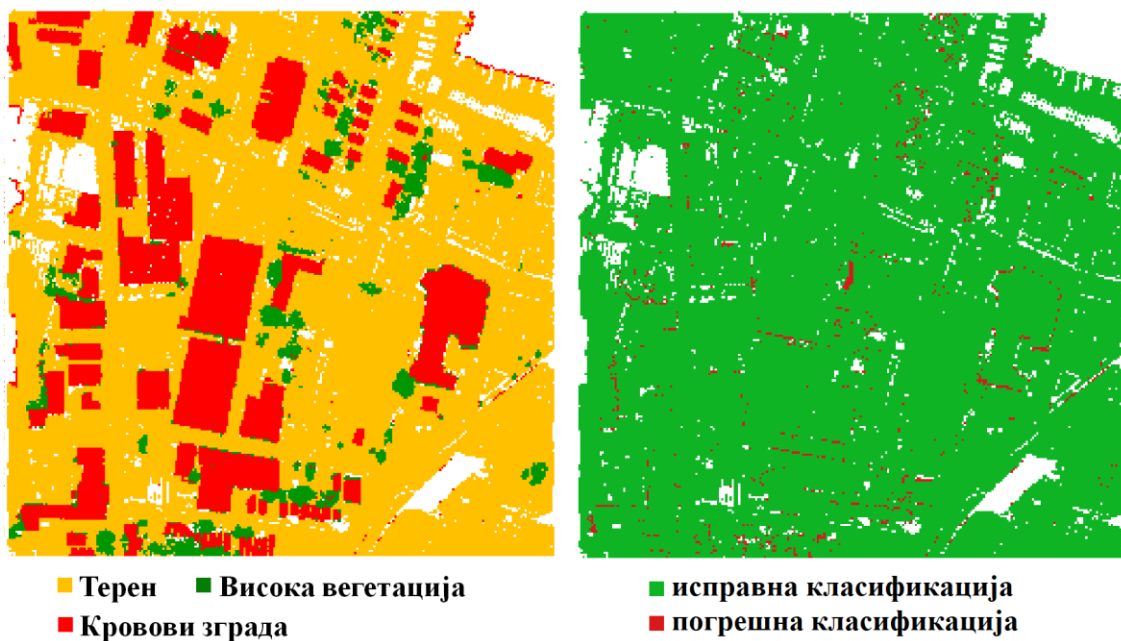
Вредности  $F1$  скорa за класу високе вегетације су знатно ниже од класа терена и кровова зграда. Разлог може бити у томе што је за ове тест податке количина тачака које припадају овој класи знатно мања у односу на друге класе. Заступљеност класа у тренинг подацима за класу високе вегетације је била слична као и за кровове зграда, али у тест подацима је знатно мањи удео тачака које припадају класи високе вегетације јер се само по један тајл користи за Џексонвил и Омаху. Зато и мали број грешака може имати велик утицај на мере перформанси које се одређују засебно по класама, поготово на осетљивост и  $F1$  скор (Табела 5.1).

Табела 5.31 Укупна тачност ( $OA$ ), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост –  $R$ , прецизност –  $P$ ,  $F1$  скор –  $FI$ ) за све моделе семантичке сегментације *GRSS* скупа података за **Џексонвил**. Резултати су добијени коришћењем атрибута задржаних у моделу након рекурзивне елиминације атрибута.

Класификатор	Класа	$OA$ [%]	$\kappa$	$R$ [%]	$P$ [%]	$FI$ [%]
<i>RF</i>	Терен	92.9	0.844	96.8	94.8	95.8
	Висока вегетација			59.7	77.4	67.4
	Кровови зграда			94.3	91.8	93.0
<i>ANN</i>	Терен	92.6	0.836	96.2	94.1	95.1
	Висока вегетација			62.4	79.8	70.0
	Кровови зграда			93.0	91.4	92.2
<i>XGB</i>	Терен	92.6	0.837	96.7	94.4	95.5

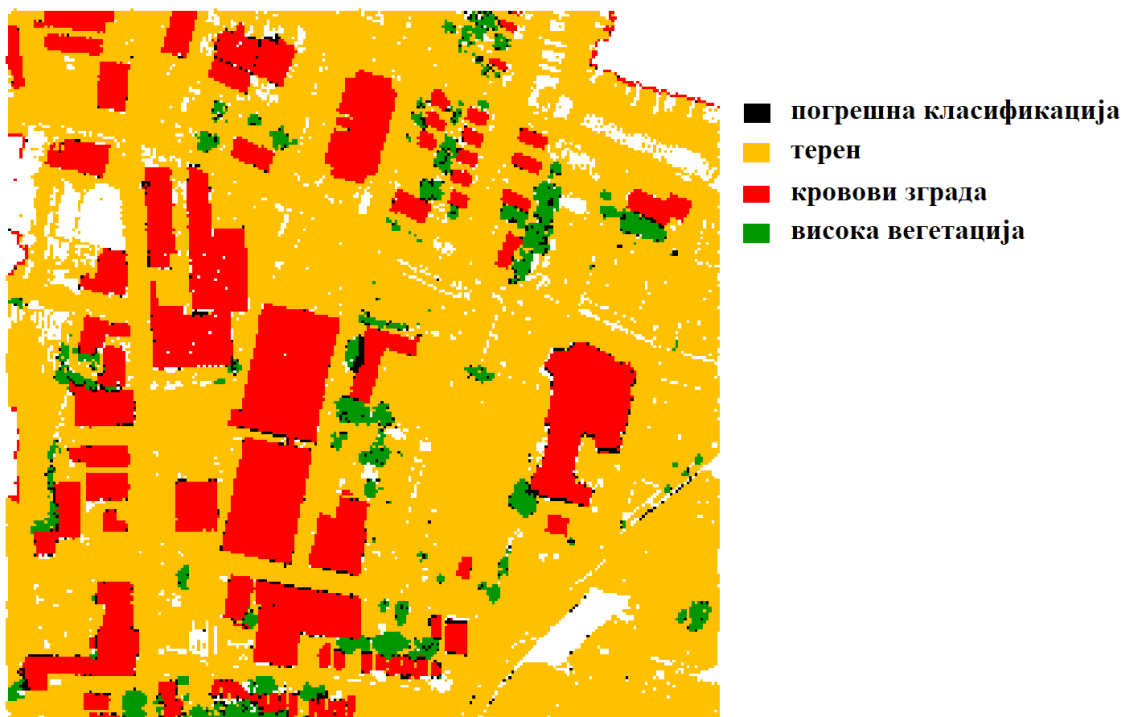
	Висока вегетација			57.9	79.0	66.8
	Кровови зграда			94.2	90.7	92.4
<i>LR</i>	Терен	92.5	0.834	96.3	94.8	95.5
	Висока вегетација			57.5	82.0	67.6
	Кровови зграда			95.8	88.2	91.8
<i>GB</i>	Терен	92.8	0.842	96.7	94.7	95.7
	Висока вегетација			59.1	78.8	67.5
	Кровови зграда			94.4	91.2	92.8
<i>ENS_RF</i>	Терен	93.0	0.844	96.7	94.9	95.8
	Висока вегетација			59.6	77.7	67.5
	Кровови зграда			94.6	91.6	93.1
<i>ENS_GB</i>	Терен	92.9	0.844	96.7	94.8	95.7
	Висока вегетација			59.7	77.3	67.4
	Кровови зграда			94.2	91.8	93.0
<i>ENS_ANN</i>	Терен	<b>93.5</b>	<b>0.856</b>	97.0	95.1	96.0
	Висока вегетација			62.4	76.8	68.9
	Кровови зграда			94.2	93.5	93.8
<i>ENS_NB</i>	Терен	<b>93.6</b>	<b>0.858</b>	98.0	94.7	96.3
	Висока вегетација			59.1	86.0	70.1
	Кровови зграда			95.0	92.5	93.7

Као графички приказ карте класа дати су резултати семантичке сегментације када је добијена највиша укупна тачност, као и карта грешака семантичке сегментације кад је примењен *ENS\_NB* модел над вишеразмерном комбинацијом атрибута (Слика 5.30). Резултати се односе на атрибуте добијене рекурзивном елиминацијом атрибута *GRSS* података једног дела града Џексонвила.



Слика 5.30: Најбољи резултати семантичке сегментације са *ENS\_NB* класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута *GRSS* података за Џексонвил.

Дат је и приказ резултата семантичке сегментације за део *GRSS* података ласерског скенирања града Џексонвила заједно са грешкама семантичке сегментације (Слика 5.31). Резултати су добијени коришћењем *ENS\_NB* методе машинског учења са балансираним подацима. Може се уочити да се грешке класификације најчешће појављују на местима где се дрвеће преклапа са ивицама кровова, као и приликом наглих прелаза са дрвећа на терен или са крова зграде на терен.



Слика 5.31: Карта са грешкама семантичке сегментације *GRSS* скупа података за Џексонвил. Приказани су резултати *ENS\_NB* класификатора над подацима генерисаним са вишеразмерном комбинацијом атрибута. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији.

Када се изврши балансирање података према заступљеним класама приликом тренирања модела машинског учења, може се видети се исти резултати добијају коришћењем *ENS\_NB* методе као и без балансирања података (Табела 5.32). У наведеној табели су, поред вредности укупне тачности и капа коефицијента слагања, унете и вредности мера перформанси (осетљивост – *R*, прецизност – *P* и  $F1$  скор – *FI*) за све моделе семантичке сегментације. Управо су вредности тих мера перформанси и највише за поменути методу машинског учења којом је постигнута највиша укупна тачност.

Табела 5.32 Укупна тачност (*OA*), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – *R*, прецизност – *P*,  $F1$  скор – *FI*) за све моделе семантичке сегментације *GRSS* балансираног скупа података за Џексонвил.

Класификатор	Класа	<i>OA</i> [%]	$\kappa$	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Терен	92.6	0.837	96.2	94.8	95.5
	Висока вегетација			59.9	75.8	66.9
	Кровови зграда			94.0	90.8	92.4
<i>LR</i>	Терен	92.5	0.834	96.3	94.8	95.5
	Висока вегетација			57.5	82.0	67.6

	Кровови зграда			95.8	88.2	91.8
<i>GB</i>	Терен	92.8	0.841	96.7	94.6	95.6
	Висока вегетација			59.2	79.4	67.8
	Кровови зграда			94.3	91.1	92.7
<i>ENS_RF</i>	Терен	92.9	0.843	96.7	94.8	95.7
	Висока вегетација			59.5	77.5	67.3
	Кровови зграда			94.5	91.5	93.0
<i>ENS_GB</i>	Терен	93.0	0.844	96.7	94.9	95.8
	Висока вегетација			59.6	77.5	67.4
	Кровови зграда			94.7	91.6	93.1
<i>ENS_ANN</i>	Терен	92.8	0.838	95.36	88.67	91.9
	Висока вегетација			63.59	98.04	77.1
	Кровови зграда			95.23	97.3	96.3
<i>ENS_NB</i>	Терен	<b>93.6</b>	<b>0.858</b>	98.0	94.6	96.3
	Висока вегетација			59.1	86.4	70.2
	Кровови зграда			94.9	92.6	93.7

Приликом семантичке сегментације *GRSS* података може се приметити да скоро све методе дају прилично добре резултате и да се разлике у тачности модела на основу *OA* крећу се у домену од 92.5% до 93.6%.

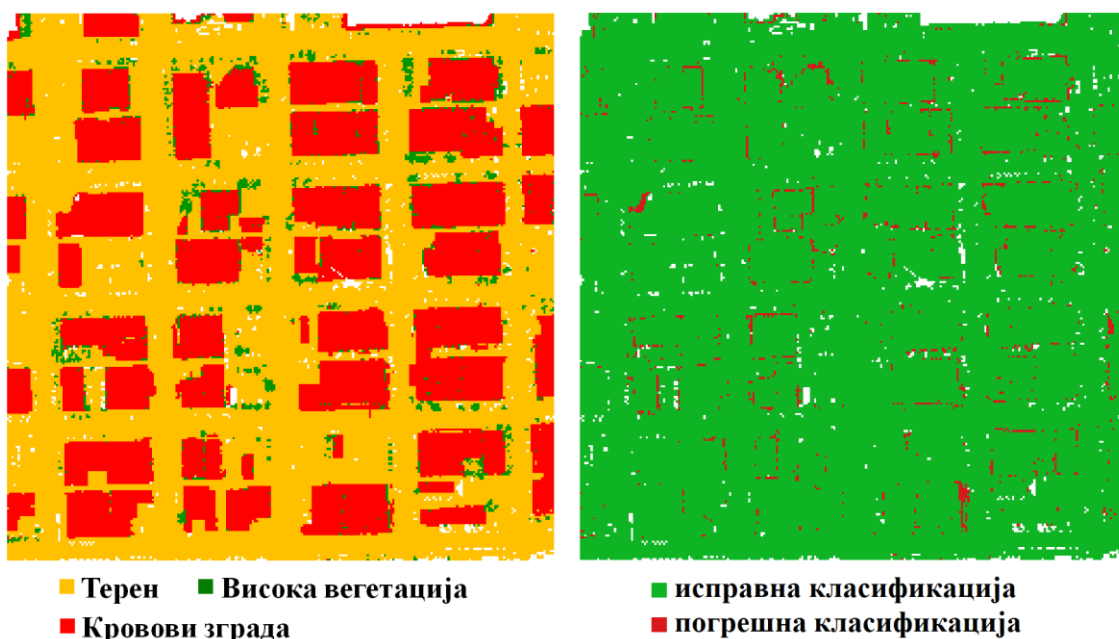
Код резултата семантичке сегментације *GRSS* облака тачака над подацима за Омаху, највишу укупну тачност даје метода случајне шуме – *RF* и сложени ансамбл модел базиран на вештачким неуронским мрежама – *ENS\_ANN* (*OA* = 92.9 – Табела 5.33). Мора се рећи да и други сложени модели настали слагањем постижу скоро исте перформансе (*ENS\_RF*, *ENS\_GB* и *ENS\_NB*), док само метода логистичке регресије даје резултате укупне тачности ниже од 90%.

Табела 5.33 Укупна тачност (*OA*), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – *R*, прецизност – *P*, Ф1 скор – *F1*) за све моделе семантичке сегментације *GRSS* скупа података за Омаху.

Класификатор	Класа	<i>OA</i> [%]	$\kappa$	<i>R</i> [%]	<i>P</i> [%]	<i>F1</i> [%]
<i>RF</i>	Терен	<b>92.9</b>	<b>0.862</b>	95.4	95.1	95.2
	Висока вегетација			40.1	57.8	47.3
	Кровови зграда			96.9	93.0	94.9
<i>ANN</i>	Терен	91.1	0.825	91.9	96.3	94.0
	Висока вегетација			32.9	39.2	35.8
	Кровови зграда			97.4	88.1	92.5
<i>XGB</i>	Терен	91.2	0.831	94.6	95.3	94.9
	Висока вегетација			30.9	56.9	40.1
	Кровови зграда			97.5	88.2	92.6
<i>LR</i>	Терен	89.2	0.791	92.4	96.3	94.3
	Висока вегетација			23.2	46.7	31.0
	Кровови зграда			98.7	82.0	89.6
<i>GB</i>	Терен	91.8	0.841	94.7	95.1	94.9
	Висока вегетација			34.4	57.8	43.1
	Кровови зграда			97.3	89.8	93.4
<i>ENS_RF</i>	Терен	92.7	0.857	95.2	95.0	95.1

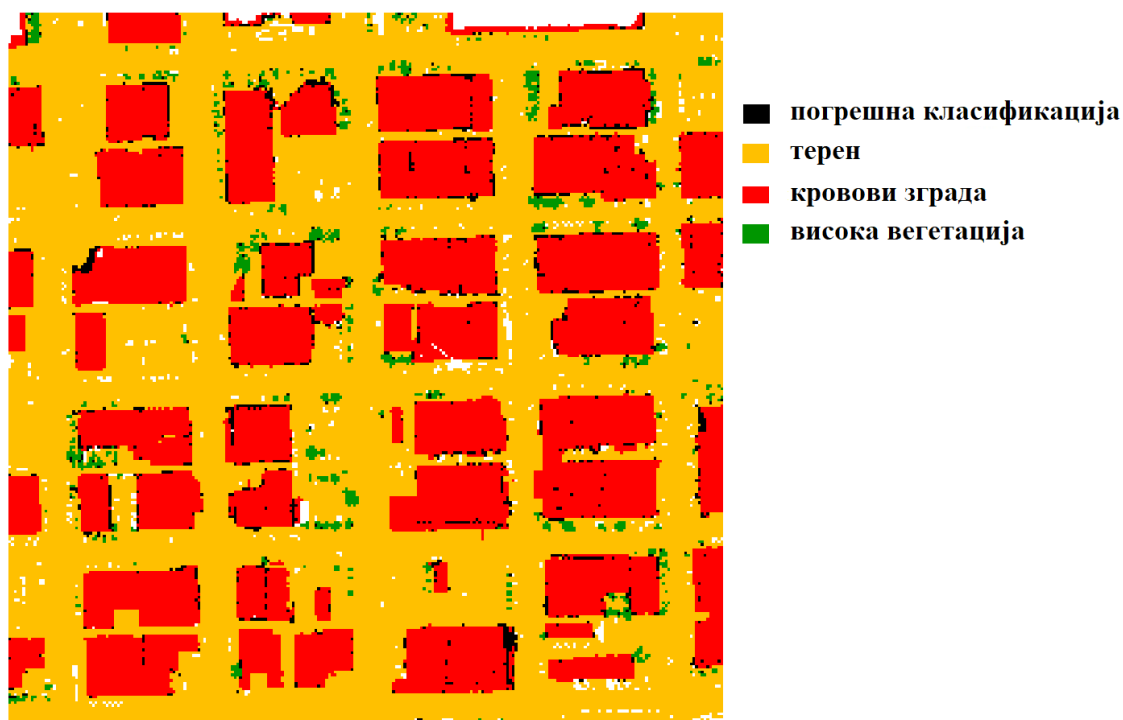
	Висока вегетација			40.0	59.2	47.7
	Кровови зграда			96.8	92.3	94.5
<i>ENS_GB</i>	Терен	92.8	0.860	95.5	94.9	95.2
	Висока вегетација			40.5	59.1	48.1
	Кровови зграда			96.6	92.9	94.7
<i>ENS_ANN</i>	Терен	<b>92.9</b>	<b>0.861</b>	95.6	94.7	95.1
	Висока вегетација			40.8	60.9	48.9
	Кровови зграда			96.2	93.2	94.7
<i>ENS_NB</i>	Терен	92.2	0.847	96.0	95.2	95.6
	Висока вегетација			33.1	62.2	43.2
	Кровови зграда			97.6	90.0	93.6

Као графички приказ карте класа дати су резултати семантичке сегментације када је добијена највиша тачност, заједно са картом грешака семантичке сегментације кад је примењен *ENS\_ANN* модел над вишеразмерном комбинацијом атрибута (Слика 5.32). Резултати се односе на податке добијене рекурзивном елиминацијом атрибута *GRSS* података једног дела града Омахе.



Слика 5.32: Најбољи резултати семантичке сегментације са *ENS\_ANN* класификатором (лево) и карта грешака семантичке сегментације (десно) добијени са вишеразмерном комбинацијом атрибута *GRSS* података за Омаху.

Слика 5.33 садржи приказ резултата семантичке сегментације за део *GRSS* података ласерског скенирања града Омахе заједно са грешкама семантичке сегментације. Резултати су добијени коришћењем *ENS\_ANN* методе машинског учења. И овде је иста ситуација као и за податке града Џексонвила, грешке класификације се највише појављују на ивицама кровова.



Слика 5.33: Карта класа са грешкама семантичке сегментације *GRSS* података за Омаху. Приказани су резултати *ENS\_ANN* класификатора над подацима добијеним са вишеразмерном комбинацијом. Белом бојом су приказане тачке класа које нису учествовале у семантичкој сегментацији.


Балансирањем података према заступљеним класама се не добијају бољи резултати тачности семантичке сегментације. Разлог највероватније лежи у томе јер количина тренинг података је већ уједначена по класама, док је класа података високе вегетације у тест подацима мање заступљена од других. Највишу тачност семантичке сегментације дају методе сложеног ансамбл метода настале слагањем модела – *ENS\_GB*, *ENS\_ANN* и *ENS\_RF* (Табела 5.34), док најлошије резултате опет даје *LR* метода машинског учења.

Табела 5.34 Укупна тачност (*OA*), капа коефицијент слагања ( $\kappa$ ) и мере перформанси (осетљивост – *R*, прецизност – *P*, Ф1 скор – *FI*) за све моделе семантичке сегментације *GRSS* балансираног скупа података за Омаху.

Класификатор	Класа	<i>OA</i> [%]	$\kappa$	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Терен	92.2	0.848	93.9	95.4	94.6
	Висока вегетација			40.0	57.3	47.1
	Кровови зграда			97.3	90.5	93.8
<i>LR</i>	Терен	89.2	0.791	92.4	96.3	94.3
	Висока вегетација			23.2	46.7	31.0
	Кровови зграда			98.7	82.0	89.6
<i>GB</i>	Терен	91.3	0.832	94.2	95.1	94.6
	Висока вегетација			33.9	58.7	43.0
	Кровови зграда			97.2	88.5	92.6
<i>ENS_RF</i>	Терен	<b>92.7</b>	<b>0.857</b>	95.2	95.0	95.1
	Висока вегетација			40.1	59.5	47.9

	Кровови зграда			96.8	92.4	94.5
<i>ENS_GB</i>	Терен	<b>92.8</b>	<b>0.860</b>	95.4	94.9	<b>95.1</b>
	Висока вегетација			40.8	59.5	<b>48.4</b>
	Кровови зграда			96.6	92.9	<b>94.7</b>
<i>ENS_ANN</i>	Терен	<b>92.6</b>	<b>0.855</b>	95.5	94.9	95.2
	Висока вегетација			39.6	59.4	47.5
	Кровови зграда			96.5	92.2	94.3
<i>ENS_NB</i>	Терен	92.1	0.845	96.1	95.1	95.6
	Висока вегетација			33.0	62.6	43.2
	Кровови зграда			97.6	89.9	93.6

Уколико се погледају резултати семантичке сегментације за *GRSS* податке, може се видети у којим ситуацијама се предложеном методологијом греша. Најчешће долази до мешања класа на ивицама зграда са класама терена и вегетације, као и додела класе терена тачкама које се налазе на крајевима крошњи стабала (Слика 5.34). Ово су грешке које настају због конверзије облака тачака у растерске слике које се користе за семантичку сегментацију, зато је и свим тачкама које се налазе на истој вертикали додељена иста класа.



Слика 5.34: Приказ резултата семантичке сегментације *GRSS* облака тачака Џексонвила (лево) и резултата семантичке сегментације *GRSS* облака тачака Омахе (десно).

За детаљнији преглед и даље анализе формиран су графици засебно за наведене квантитативне мере где се по класама може уочити који алгоритам је дао боље резултате (Прилог 8: Слика П.14).

#### 5.4.1 Примена модела истренираног са *GRSS* подацима на *ISPRS* тест податке

У случају када се модел истрениран над *GRSS* подацима примени на *ISPRS* тест податке са истим генерисаном атрибутима, добија се знатно нижа укупна тачност семантичке сегментације облака тачака, поготово код појединих модела машинског учења (Табела 5.35). И овде се најбоље показао сложени ансамбл модел базиран на наивном Бајесу – *ENS\_NB* ( $OA = 72.8\%$ ), док је најнижу укупну тачност семантичке сегментације дала метода вештачких неуронских мрежа – *ANN* (испод 50%).



Табела 5.35 Семантичка сегментација *ISPRS* облака тачака са моделом истренираним са *GRSS* подацима.

Класификатор	OA [%]
<i>RF</i>	65.3
<i>XGB</i>	56.9
<i>ANN</i>	49.5
<i>GB</i>	60.7
<i>ENS_RF</i>	51.2
<i>ENS_GB</i>	51.2
<i>ENS_ANN</i>	50.7
<b><i>ENS_NB</i></b>	<b>72.8</b>

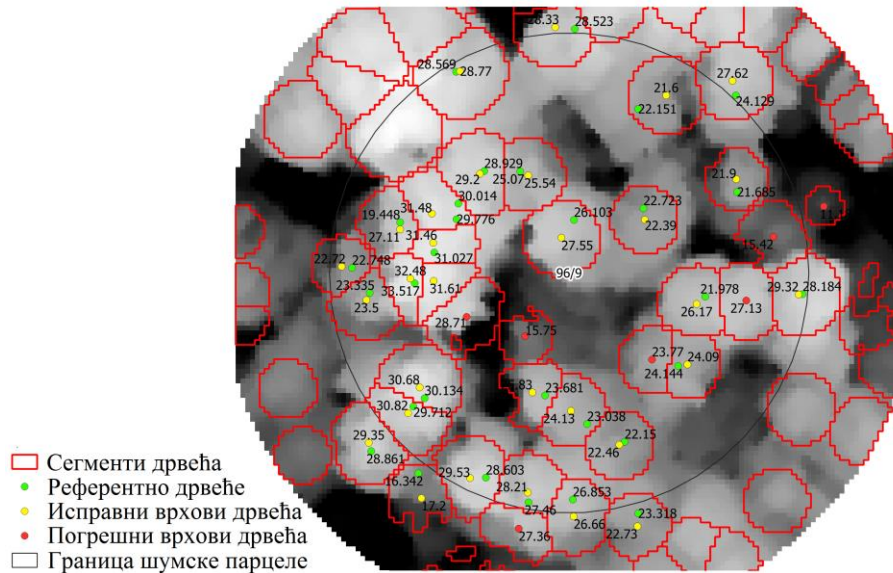
Иако је значајно опала ефикасност свих коришћених метода, *ENS\_NB* модел се опет показао као најбољи избор приликом наведеног трансфера учења (енгл. *transfer learning*). Генерализација *ENS\_NB* модела је прилично добра будући да се моделом предиктује над сасвим другим подацима у односу на оне над којима је трениран.

## 5.5 Експеримент 5: Побољшање резултата детекције појединачних стабала

У овом експерименту описани су резултати постигнути побољшањем детекције појединачних стабала коришћењем *ALS* података. У поглављу 5.5.1 дат је опис припреме података у виду означавања класа за тренинг и тест податке. Поглавље 5.5.2 садржи опис поступка балансирања података и селекцију најважнијих атрибута коришћењем генетских алгоритама, док је у поглављу 5.5.3 приказано сортирање селектованих атрибута по важности. У поглављу 5.5.4 вршено је одређивање оптималних хиперпараметара неколико метода машинског учења, док је у поглављу 5.5.5 извршен избор модела машинског учења којим ће бити вршена коначна класификација. Поглавље 5.5.6 даје опис резултата класификације са изабраним мерама перформанси модела.

### 5.5.1 Припрема података за класификацију врхова стабала


Као што је описано у поглављу 3.3.4, потребно је извршити означавање локалних максимума (*LM*) у исправно и погрешно детектоване врхове стабала за тренинг и тест податке ласерског скенирања коришћених за индивидуалну детекцију стабала. Ознаке које одређују да ли генерисани *LM* представља исправно или погрешно детектован врх стабла, а које су одређене поређењем са референтним стаблима (међусобно растојање и висинска разлика), додељују се кандидату за врх стабла (Слика 5.35). Након ове процедуре, утврђено је да подаци за тренирање модела имају 611 исправних и 343 погрешних врхова стабала, док тест подаци садрже 289 исправних и 139 погрешних врхова стабала, чиме се добија да тачност визуелне детекције класа врхова стабала за тест податке износи 68%.



Слика 5.35: Сегменти крошњи са детектованим врховима стабала.

### 5.5.2 Балансирање и селекција најважнијих атрибута

Као што је објашњено у поглављу 3.3.3, подаци су балансирани коришћењем алгорита *ADASYN*. Алгоритам је имплементиран као функција *ADAS* у *R* пакету *smotefamily* (Siriseriwan, 2019). Број најближих суседа ( $k$ ) узетих из класе са већим појављивањем током процеса прекомерног узорковања био је пет. Након балансирања података, број синтетички генерисаних примерака који су додатно генерисани за мањинску класу (погрешно детектовани врхови стабала) био је 296. Установљено је да је балансирање класа увећало *OA* за скоро 5% код десетоструке унакрсне валидације са десет понављања.




Слика 5.36: Поређење *OA* *RF* модела машинског учења пре и после балансирања података. Медијана је приказана у виду црне тачке у правоугаоник, док први и трећи кватил дефинишу правоугаоник. Граничници дефинишу минимум и максимум података, док су грубе грешке приказане као плави кругови.

Одређена је Пирсонова (енгл. *Pearson*) матрица корелације како би се уклонили високо корелисани атрибути. Високо корелисани атрибути у подацима одређени су коришћењем функције *findCorrelation R* пакета *caret* (Kuhn, 2008) којом се рачуна средња апсолутна корелација за сваки атрибут. Након тога, уклоњени су атрибути из парова које имају корелацију већу од 0.8. После овог корака, 37 атрибута је остало за даље процесирање.

Селекција атрибута базирана на генетским алгоритмима вршена је коришћењем функције *gafs R* пакета *caret* (Kuhn, 2008), који је базиран на *R* пакету *GA* (Scrucca, 2013). У овом истраживању, погодност бинарних секвенци је оцењена преко тачности *RF* класификатора користећи десетоструку унакрсну валидацију понављану пет пута у свакој итерацији. Параметри одабрани за генетске алгоритме били су 100 генерација са 20 популација у генерацији, са вероватноћом укрштања од 0.8 и вероватноћом мутације од 0.1. Циљ селекције подскупа била је максимизација средње укупне тачности интерне валидације, док је најбоља итерација имала највећу укупну тачност екстерне валидације постигнуте *RF* класификатором. На екстерну валидацију се гледа као на предикцију једног подскупа података са којим се не тренира модел код унакрсне валидације, док је интерна валидација показатељ укупне тачности модела над свим другим подскуповима.

Са графика могуће је видети да се укупна тачност интерне валидације повећава са операцијама укрштања и мутације у каснијим итерацијама, као и да је средња укупна тачност већа од 92% после 20–те итерације (Слика 5.37). Укупна тачност екстерне валидације је нешто нижа, будући да је то део скупа података над којим се не тренира модел, али је опет већа од 90%.




Слика 5.37: Селекција атрибута коришћењем *GA* са 100 итерација. Црвене тачке представљају укупну тачност добијену екстерном валидацијом, док су плаве тачке средња укупна тачност интерне валидације сваке итерације.

За коначну селекцију подскупа атрибута одабрана је итерација 76 са којом је екстерном валидацијом добијено 91.6% за  $OA$  и 0.832 за  $k$ . У овој итерацији селектована су 23 атрибута:  $N$ ,  $Hentr$ ,  $Phabhm$ ,  $Phabx$ ,  $Hq1$ ,  $Hq5$ ,  $Hrcum9$ ,  $P2th$ ,  $P3th$ ,  $P5th$ ,  $Hmod$ ,  $Hmadmed$ ,  $HL3$ ,  $HL4$ , и  $Hprofarea$  из групе метрика дрвећа;  $Maxquad$ ,  $Medquad$ ,  $Minrobquad$ ,  $Maxrobquad$ ,  $Medrobquad$  and  $RMSrobquad$  из групе уклапања облика; и  $EccEgn$  и  $Rect$  који припадају групи облика сегмената. Може се приметити да је задржан велики број атрибута из групе метрика дрвећа и да су селектовани скоро сви атрибути уклапања облика. Такође су само два атрибута задржана из групе облика сегмената, док ниједан атрибут није изабран из групе базираних на сопственим вредностима.

### 5.5.3 Важност атрибута

Селекција атрибута се врши у циљу смањења количине података који се користе. Ово смањује време процесирања потребно за класификацију, без значајнијег губитка перформанси модела у погледу постигнуте тачности. Након тога, битно је оценити важност сваког атрибута који учествује у класификацији.

Мером важности атрибута указује се на просечан раст чистоће чвора кад се изврши подела на класе на основу тог атрибута. Нечистоћа чвора је одређена Џинијевом мером. Средње опадање Џини индекса ( $MDG$ ) је мера колико је Џинијева нечистоћа опала са тим атрибутом за сваку класу. У овом случају,  $MDG$  је изабрана као мера важности атрибута, будући да је такође коришћена током селекције атрибута коришћењем генетских алгоритама. Скалирана важност атрибута базираних на  $MDG$  је срачуната и исцртана на графику. Приказане су величине важности за првих 15 атрибута, од укупно 23 атрибута који су изабрани за коначан  $RF$  модел (Слика 5.38).



Слика 5.38: Важност селектованих атрибута изражена преко скалираног средњег опадања Џини индекса.

Као што се може видети са слике, највећа важност атрибута добијена је за број тачака које припадају сваком сегменту ( $N$ ), праћено атрибутима који припадају групи атрибута уклапања облика (*Medquad* и *Medrobquad*), а затим и атрибутима који припадају групи метрика дрвећа (*Hentr*, *Hprofarea*, *Phabx* и *Hrcum9*) измешаних са атрибутима из групе атрибута облика сегмента (*Rect* и *EccEgn*).

#### 5.5.4 Одређивање хиперпараметара модела машинског учења

Одређивање хиперпараметара за сваки од модела машинског учења изведено је над подацима за тренирање користећи грид претрагу засебно за сваку методу класификације. Претрага у виду грида подразумева дефинисање различитих комбинација хиперпараметра са унапред дефинисаним распонима вредности. За тренирање класификационог модела коришћена је десетострука унакрсна валидација са десет понављања, док је *OA* коришћена као мера перформанси модела. Вршено је поређење резултата класификације добијених сваком комбинацијом грида претраге.


Оптимизација класификационих модела изведена је коришћењем *R* пакета *caret* (*Kuhn, 2008*). Табела 5.36 садржи коначне вредности хиперпараметара за сваку од метода, док је објашњење за сваки од коришћених параметара дато у наставку.

Табела 5.36 Оптимални хиперпараметри за сваки коришћени алгоритам машинског учења и одговарајући *R* пакети.

Метода	Оптимални хиперпараметри	Метода/ <i>R</i> пакет
<i>RF</i>	<i>splitrule = extratrees</i> <i>ntree = 2 000</i> <i>min.node.size = 1</i> <i>mtry = 4</i> <i>num.random.splits = 3</i>	екстремно насумична стабла <i>/ranger</i> ( <i>Wright</i> и <i>Ziegler, 2017</i> )
<i>XGB</i>	<i>nrounds = 1 500</i> <i>max_depth = 4</i> <i>eta = 0.1</i> <i>gamma = 0</i>	<i>xgboost</i> ( <i>Chen</i> и др., 2022)
<i>ANN</i>	<i>size = 36</i> <i>decay = 0.2</i>	вештачка неуронска мрежа усмерена напред са једним скривеним слојем/ <i>nnet</i> ( <i>Venables</i> и <i>Ripley, 2002</i> )
<i>SVM</i>	<i>degree = 3</i> <i>scale = 1</i> <i>C = 0.1</i>	полиномски кернел/ <i>kernlab</i> ( <i>Karatzoglou</i> и др., 2022, 2004)
<i>LR</i>	<i>family = binomial</i>	генерализовани линеарни модели/ <i>caret</i> ( <i>Kuhn</i> и др., 2022)

За потребе овог истраживања коришћен је *RF* алгоритам машинског учења који је имплементиран у *R* пакету *ranger* (*Wright* и *Ziegler, 2017*). За наведену методу машинског учења прво је потребно изабрати одговарајући начин раздвајања атрибута (енгл. *splitrule*): *gini* или *extratrees*. Такође, три додатна параметра су морала бити одређена: број стабала одлучивања (*ntree*), број атрибута за раздвајање (*mtry*) и минимална величина чвора (*min.node.size*). Такође, за *extratrees* мора бити


дефинисан начин поделе и број насумичних раздвајања (*num.random.splits*). Закључено је да се најбољи резултати добијају са 2 000 стабала и четири атрибута за раздвајање (Слика 5.39). Мора се додати да су резултати добијени са свим варијантама грида претраге (комбинацијама броја стабала и број атрибута за раздвајање) дали веома сличне резултате класификације у погледу укупне тачности која се кретала од 0.88% до 0.90% (Слика 5.39).



Слика 5.39: Одређивање хиперпараметара *mtry* и *ntree* за *RF*.

У истраживању је коришћен *XGB* алгоритам имплементиран у оквиру *R* пакета *xgboost* (Chen и др., 2022). Најбитнији параметри за ову методу машинског учења били су: број итерација појачавања (*nrounds*), највећа дубина стабла одлучивања (*max\_depth*), скупљеност стабла (*eta*) и минимална редукција губитака (*gamma*).


За овај експеримент коришћен је и *SVM* алгоритам из *R* пакета *kernelab* (Karatzoglou и др., 2004). Од неколико испробаних кернела (*linear*, *radial* и *polynomial*), испоставило се да нелинеарни полиномски кернел даје најбоље резултате за наведени задатак класификације (Слика 5.40).



Слика 5.40: Избор одговарајућег кернела за SVM базиран на укупној тачности.

Када се користи SVM класификатор са полиномским кернелом, три параметра морају бити одређена: степен полинома (*degree*), размера (*scale*) и трошак (*cost*). Степен полинома утиче на глаткоћу хипер-равни којом се раздвајају класе, док се параметром трошка контролишу пенали за грешке.

У овом истраживању је коришћен и алгоритам за вештачке неуронске мреже (ANN) имплементиран у R пакету *nnet* (Venables и Ripley, 2002). Хиперпараметри одређени за наведену неуронску мрежу били су број скривених јединица (*size*) и опадање тежина (*decay*). Број скривених јединица (неурона) у једном скривеном слоју је важан параметар када је реч о степену прилагођавања модела подацима. Опадање тежина је техника регуларизације која је примењена на тежине неурона у неуронској мрежи. У овом случају добијено је да опадање тежина од 0.2 и 36 скривених јединица даје укупну тачност од скоро 89% (Слика 5.41).




Слика 5.41: Одређивање хиперпараметара *size* и *decay* за ANN.

Са графика (Слика 5.41) се може закључити да модели који имају опадање тежина 0.5 дају укупну тачност класификације мању од 88% уколико користе мање од 36 скривених јединица. Све друге варијанте модела имају већу тачност од наведене уколико користе више од 31 скривене јединице.

Имплементација логистичке регресије у *R* пакету *caret* (Kuhn и др., 2022) која је коришћена за потребе овог истраживања, не нуди опције за одређивање хиперпараметара.

### 5.5.5 Селекција метода машинског учења

Поређењем тачности која је постигнута различитим класификаторима над тренинг подацима, може се уочити да су *RF*, *XGB*, *ANN* и *SVM* показали далеко боље резултате у погледу тачности од *LR* (Слика 5.42).



Слика 5.42: Поређење вредности *OA* и *κ* са различитим класификаторима над тренинг подацима.

Исто рангирање класификатора се добија кад се истрениран модел примени над тест подацима (Табела 5.37).

Табела 5.37 Мере перформанси (*OA* и *κ*) сваког класификатора предикцијом над тест подацима.

Класификатор	<i>OA</i> [%]	<i>κ</i>
<i>RF</i>	89.0	0.757
<i>XGB</i>	88.8	0.750
<i>ANN</i>	84.1	0.657
<i>SVM</i>	82.5	0.625
<i>LR</i>	74.1	0.431

Може се приметити да само *RF* метода даје *OA* изнад 90% и *κ* преко 0.8, кад се користи унакрсна валидација над тренинг подацима (Слика 5.42), као и да се добија највиша тачност када је наведени модел примењен на тест податке (Табела 5.37). Стога, наведени класификатор је даље коришћен како би се вршила класификација врхова стабала на оне који су исправно детектовани и на оне који су погрешно детектовани.



### 5.5.6 Резултати класификације

$OA$  и  $\kappa$  за  $RF$  класификатор добијени на основу десетоструке унакрсне валидације над тренинг подацима били су 90.4% и 0.808. Када је истренирани модел примењен над тест подацима, било је могуће постићи  $OA = 89.0\%$  и  $\kappa = 0.757$ . Оптимизовани параметри за  $RF$  модел били су  $splitrule = extratrees$ ,  $ntree = 2\ 000$ ,  $min.node.size = 1$  и  $mtry = 4$ . Матрица конфузије и мере перформанси модела дате су за све шумске парцеле, као и посебно за стабла која припадају четинарским, лишћарским и мешовитим шумским парцелама (Табела 5.38).

Табела 5.38 Матрица конфузије свих шумских парцела и квантитативне мере перформанси модела.

Тип парцеле	Пред./Реф.	исправни	погрешни	$P$ [%]	$R$ [%]	$FI$ [%]	$OA$ [%] / $\kappa$
Све (свих осам парцела)	исправни	257	15	94.5	88.9	91.6	$OA = 89.0$
	погрешни	32	124	79.5	89.2	84.1	$\kappa = 0.757$
Лишћарске (пет парцела)	исправни	113	7	94.2	89.0	91.5	$OA = 88.3$
	погрешни	14	46	76.7	86.8	81.4	$\kappa = 0.730$
Четинарске (две парцеле)	исправни	118	6	95.2	87.4	91.1	$OA = 89.2$
	погрешни	17	71	80.7	92.2	86.1	$\kappa = 0.772$
Мешовито (једна парцела)	исправни	26	2	92.8	96.3	94.5	$OA = 91.7$
	погрешни	1	7	87.5	77.8	82.4	$\kappa = 0.769$

## 6 ДИСКУСИЈА

Дискусија о коришћеним методама и добијеним резултатима биће спроведена редом по поглављима која су дефинисана изведеним експериментима. У поглављу 6.1 биће речи о атрибутима тачака који су екстрактовани, начину њиховог одређивања и размери при којој су срачунати (полупречнику претраге). Овде је дато и поређење са атрибутима коришћеним од стране других аутора при семантичкој сегментацији облака тачака. Поглавље 6.2 покрива експериментални део о резултатима семантичке сегментације *ISPRS* облака тачака, тј. дискусију о томе која комбинација атрибута је дала најбоље резултате са којом методом машинског учења. У овом поглављу биће дато и поређење резултата добијених од других аутора над истим подацима. Након тога, биће речи о важности појединих атрибута у процесу тренирања модела машинског учења. У поглављу 6.3 анализира се ефекат смањења количине тренинг података узорковањем при чему се водило рачуна о томе да подаци остану балансирани у погледу класне заступљености. Дискусија о резултатима семантичке сегментације *GRSS* података представљена је у поглављу 6.4. Овде се неће толико анализирати сви аспекти као код семантичке сегментације *ISPRS* података, већ ће бити дата поређења резултата семантичке сегментације са другим ауторима. Један део овог поглавља односи се на универзалност примене модела истренираног над *GRSS* подацима на *ISPRS* податке. У поглављу 6.5 биће речи о резултатима класификације детектованих појединачних стабала података ласерског скенирања.

### 6.1 Експеримент 1: Екстракција атрибута тачака

Као што је већ наведено у претходним поглављима, укупно 29 геометријских атрибута (Табела 3.1) генерисано је за два начина претраге суседства: цилиндра и сфере претраге са полупречницима од 1 m, 1.5 m, 2 m и 3 m (једноразмерних комбинација). Додатно је формирана вишеразмерна комбинација атрибута генерисаних и са цилиндрима и са сферама претраге са полупречницима претраге од 0.5 m, 1 m, 1.5 m, 2 m и 3 m што је резултовало комбинацијом од укупно 100 атрибута.

Вишеразмерно суседство у овим подацима је разматрано и од стране *Atik* и др., 2021., при чему су се они на крају одлучили за атрибуте добијене сфером претраге полупречника 1.5 m за исте податке. У овој дисертацији коришћене су и сфере, цилиндри претраге и вишеразмерна комбинација са свим обједињеним резултатима.

Када се врши поређење са методама других аутора, може се приметити да је у овој дисертацији генерисан знатно већи број атрибута (29) у односу на неке друге студије (*Blomley* и др., 2016; *Chehata* и др., 2009; *Han* и др., 2020; *Niemeyer* и др., 2014; *Weinmann* и др., 2015a). *Blomley* и *Weinmann*, су 2017. заправо у свом каснијем

раду размотрили додатне типове атрибута и користили више од 60 генерисаних атрибута добијених на основу *ISPRS* података облака тачака.

Највећи допринос у овом делу истраживања остварен је са применом вишеразмерног приступа одређивања атрибута. На овај начин је генерисано 100 атрибута на основу различитог начина претраге у виду сфере и цилиндра претраге, као и различитих полупречника претраге суседства тачке од од 0.5 m, 1 m, 1.5 m, 2 m и 3 m. И други аутори су донели закључке да се коришћењем вишеразмерног приступа добија знатно увећање укупне тачности семантичке сегментације у односу на једноразмерни приступ (*Blomley* и *Weinmann*, 2017).

Потребна су додатна истраживања да би се испитале предности коришћења аутоматских метода одређивања оптималног суседства тачака у виду броја најближих тачака (*Weinmann* и др., 2015a) и то у комбинацији са вишеразмерним приступом, иако је то делимично извршено од стране *Blomley* и др., 2016.

## 6.2 Експеримент 2: Семантичка сегментација *ISPRS* облака тачака

Резултати овог експеримента показују да су начин претраге тачака суседа и величина полупречника претраге најважнији фактори који утичу на тачност семантичке сегментације. Након генерисања атрибута за једноразмерне комбинације са различитим начином и величином претраге суседства, као и за вишеразмерну комбинацију, приступило се тренирању четири традиционална модела машинског учења (*RF*, *SVM*, *ANN* и *XGB*). По добијању прелиминарних резултата уочено је да најбоље резултате семантичке сегментације даје вишеразмерна комбинација са скоро свим класификаторима, при чему се *SVM* најбоље показала са укупном тачношћу од 83.5%. Од једноразмерних комбинација атрибута истицале су се оне са цилиндрима претраге од 1.5 m и 3 m ( $D_2R_{1.5}$  и  $D_2R_3$ ) са појединим класификаторима (*SVM* и *XGB*, тим редом – Табела 5.1).

Даље су подаци добијени са само ове три комбинације коришћени за семантичку сегментацију *ISPRS* облака тачака са већим бројем сложенијих метода машинског учења (*RF*, *SVM*, *ANN*, *XGB*, *LR*, *GB*, *ENS\_RF*, *ENS\_GB*, *ENS\_ANN*, *ENS\_NB* и *AML*). Вршено је балансирање података према класама приликом тренирања модела машинског учења и рекурзивна елиминација атрибута наведених комбинација како би се установило да ли ове операције утичу на коначне резултате. Семантичка сегментација је вршена над растерским продуктима облака тачака, након чега је вршена просторна регуларизација резултата семантичке сегментације уклањањем шума у резултатима. На крају су резултати добијени над побољшаним растерским продуктима пресликани на облак тачака.

Уочено је да најбоље резултате семантичке сегментације најчешће даје сложени ансамбл модел базиран на наивном Бајесу (*ENS\_NB*). У теорији би сложени ансамбл модели настали слагањем и требало да дају за неколико процената вишу тачност предикције од основних модела, јер се тако користе предности сваког појединачног

основног модела (*Sivanandham* и *Gunaseelan*, 2022). Овом методом су се скоро увек добијали најбољи резултати над растерским продуктима (Табела 5.2, Табела 5.4, Табела 5.7, Табела 5.9, Табела 5.11, Табела 5.13, Табела 5.15, Табела 5.17 и Табела 5.19). После би се дешавало да друге методе дођу до изражаја кад би се вршила просторна регуларизација резултата семантичке сегментације (отклањање шума у класној припадности). Ово је био случај и код вишеразмерне комбинације са свим атрибутима, када је прво *ENS\_NB* дала најбоље резултате над растерским продуктима, а затим се *SVM* методом добили бољи резултати са просторном регуларизацијом ознака класа (Табела 5.19). На крају су резултати за 0.5% били бољи код *SVM* методе када је семантичка сегментација директно примењена на облак тачака (Табела 5.20).


Балансирање података према класама у току тренирања модела у већини случајева није донело побољшање у погледу резултата семантичке сегментације. Разлог се вероватно налази у томе што су примерци који припадају појединим класама већ скоро подједнако дистрибуирани, па балансирање не мења значајно однос између количине примерака у свакој класи. Ово би дефинитивно било од велике помоћи да су коришћене све расположиве класе *ISPRS* података, међутим класе далеководна, аутомобила, ограда, фасада и жбуња су изопштене зато што у подацима за тренинг обухватају премало припадајућих тачака. Оно што се могло приметити је да су се поправили резултати класификације неких метода које су имале нешто лошије резултате у погледу семантичке сегментације, као што је *ENS\_ANN* сложени модел настао слагањем модела код  $D_2R_3$  комбинације атрибута *ISPRS* података (Табела 5.14). *Blomley* и др., су 2016. извршили балансирање тренинг података према класама тако да су имали по 10 000 тачака које су припадале свакој од класа. За класе коришћене у тој студији, наведени аутори су морали извести узорковање података класа с већим бројем тачака, док су тачке које припадају мањинским класама дуплициране. Овај приступ је имао ману у томе што се смањује количина података за тренинг узорковање, а и, уместо дуплицирања, синтетизовање тачака мањинских класа је боље вршити неким од устаљених метода, као што је *ADASYN*, или коришћењем неког другог приступа базираног на *SMOTE* методи, као што је извршено у овом експерименту.

Добри резултати су постигнути и са подкупом атрибута код једноразмерних комбинација ( $D_2R_{1.5}$  и  $D_2R_3$ ) добијеним након извршене рекурзивне елиминације атрибута. Овде није дошло до значајног опадања укупне тачности семантичке сегментације. Код вишеразмерне комбинације након рекурзивне елиминације атрибута долази до смањења укупне тачности семантичке сегментације за 0.8% у односу на резултате добијене коришћењем свих расположивих атрибута.

Приликом селекције атрибута за  $D_2R_{1.5}$  и  $D_2R_3$  и вишеразмерну комбинацију (поглавље 5.2.3) и њиховог каснијег сортирања по важности атрибута (поглавље 5.2.2), могло се приметити да је највећу важност имао интензитет одбитка сигнала (*Amplitude*). Даље се издвајала негативна отвореност локације (*negOpeness*), потом атрибути базирани на висини тачака (*NormalizedZ*, *RANK*, *MIN*, *RANGE*, *RelativeZ*), расипању тачака по висини (*stdDevMAD*, *NormalSigma0*, *Variance*) и атрибути генерисани коришћењем сопствених вредности (*NormalEigenValue3*, *OmniVariance*).

Интензитет или јачина одбитка сигнала, у самом почетку често није коришћен за потребе класификације облака тачака, поготово у софтверским решењима који се користе за комерцијалне сврхе (Flood, 2001). Главни разлог за то био је у потреби да се претходно изврши ваљана радиометријска калибрација. Вредност одбијеног интензитета у великој мери зависи од упадног угла ласерског зрака и стога би требало да се претходно изврши радиометријска корекција тако добијених вредности интензитета. Касније студије су показале да се класификација поспешује укључивањем интензитета одбијеног *LiDAR* сигнала (Charaniya и др., 2004) код којих је претходно извршена радиометријска корекција. У овом истраживању је интензитет коришћен највише због тога што је дат као основни атрибут за сваку тачку у улазним подацима. Више вредности интензитета одбитка сигнала могу се наћи на природним површинама (дрвеће и ниска вегетација), док су ниже вредности заступљене код вештачких објеката (непропусне површине и кровови зграда – Слика 6.1 – лево). Niemeyer и др., су 2014. користили интензитет као атрибут приликом класификације облака тачака и нашли да је важан за разликовање између природних и вештачких површина (нпр. путева). Други аутори су такође користили интензитет или амплитуду сигнала као атрибут приликом класификације (Chehata и др., 2009; Guo и др., 2015; Lodha и др., 2007).

Негативна отвореност (*negOpeness*) је релативно нов параметар за потребе класификације облака тачака. Њиме се представља степен заклоњености неке локације на неправилној површи и најчешће служи за визуелизацију топографије терена (Doneus, 2013; Yokoyama, 2002). То је угловна мера односа између рељефа површи и хоризонталне удаљености. Будући да се најчешће користе за визуелизацију, атрибути отворености површи (позитивне и негативне) нису коришћени за класификацију облака тачака. Ниже вредности атрибута *negOpeness* добијају се на комплексним површинама дрвећа или сложених површи кровова, док се код равних, непропусних површина или ниске вегетације добијају више вредности (Слика 6.1 – десно).



Слика 6.1: Приказ интензитетске слике (лево) и слике негативне отворености површи (десно) за  $D_2R_3$  комбинацију атрибута *ISPRS* тренинг података

Неки од атрибута базираних на висинским информацијама о тачкама (*NormalizedZ*, *RANK*, *MIN*, *RANGE*, *RelativeZ*), показали су се као битни приликом семантичке сегментације. Висински базирани атрибути су коришћени у великом броју радова (*Chehata* и др., 2009; *Niemeyer* и др., 2014) и значајни су за процес семантичке сегментације, поготово ако се односе на нормализовану висину тачке изнад терена, као што је атрибут *RelativeZ*. Вредностима тих атрибута се стога могу лако разликовати тачке које су на терену или близу терена (непропусне површине и ниска вегетација) од тачака које су изнад терена (кровови зграда и дрвеће).

Последња група битна за семантичку сегментацију су атрибути базирани на расипању тачака по висини (*stdDevMAD*, *NormalSigma0*, *Variance*). Они су и показатељи храпавости површи неког објекта. Стога се помоћу ових атрибута прави разлика између објеката са равним површинама, као што су непропусне површине, и објеката са храпавим површинама, као што је дрвеће.

Будући да су коришћени јавно доступни *ISPRS* подаци са назначеним референтним класама за сваку тачку, постоји велики број радова са којим се могу упоредити резултати семантичке сегментације (*Anandakumar* и др., 2016; *Atik* и др., 2021; *Blomley* и др., 2016; *Blomley* и *Weinmann*, 2017; *Horvat* и др., 2016; *Niemeyer* и др., 2016, 2014; *Schmidt* и др., 2014; *Vosselman* и др., 2017; *Zhu* и др., 2021). Ово су већином традиционалне методе машинског учења примењене над генерисаним атрибутима, док су неке од наведених метода биле базиране на методама дубоког учења (*Zhu* и др., 2021).

*Atik* и др. (*ITU*) су 2021. развили сличан приступ семантичке сегментације над истим подацима који су коришћени у овој дисертацији. Они су констатовали да се најбољи резултати од 79.7% за *OA* добијају комбинацијом атрибута генерисаним сфером претраге од 1.5 m и коришћењем методе потпорних вектора (*SVM*). У њиховом раду је коришћено 13 атрибута за семантичку сегментацију. У овој дисертацији добијена је већа вредност за *OA* са истим класификатором, односно *SVM* методом за вишеразмерну комбинацију атрибута (83.5%). Такође су за неколико процената добијени бољи резултати коришћењем других метода и комбинација атрибута – 82.6% за *ENS\_NB* кад су коришћени сви атрибути, 82.4% за *SVM* кад је извршена рекурзивна елиминација атрибута и 82.4% за *AML* кад су балансиране класе.

*Vosselman* и др., су 2017. користили методу с условним насумичним пољима (*CRF*) за сегментски базирану семантичку сегментацију *ISPRS* података којом су узимали у обзир суседност означавања класа тачака у облаку тачака. Њихов принцип је био заснован на првобитној детекцији сегмената након чега су применили *CRF* класификатор. У свом раду, они су одредили 19 атрибута за сваки сегмент који су касније коришћени као предиктори за класификацију. Постигли су укупну тачност од 79.6% уколико се одбаце резултати класа тачака које нису коришћене у овој дисертацији. Стога су они имали скоро исти учинак као и аутори са *ITU* приступом.

Будући да су за потребе ове дисертације коришћене само доминантне класе приликом семантичке сегментације, поређење резултата са другим методама није могло бити вршено путем укупне тачности. Стога је поређење резултата вршено коришћењем  $F1$  скорa засебно за сваку коришћену класу (Табела 6.1). Резултати и

скраћенице назива других метода преузети су са *ISPRS* веб-сајта где су публиковани резултати семантичке сегментације<sup>8</sup>.

Табела 6.1 Поређење резултата семантичке сегментације у погледу Ф1 скорa за *ISPRS* скуп података.

Класе/Метода	<i>ITU</i>	<i>KIT</i>	<i>IIS_7</i>	<i>PhD</i>	<i>UM</i>	<i>LUH</i>	<i>RIT_1</i>	<i>NANJ2</i>	<i>WhuY4</i>	<i>CHDJ</i>
Ниска вегетација	/	57.9	65.2	75.7	79.0	77.5	77.9	88.8	<b>82.7</b>	82.5
Непропусне	87.46	80.0	85.0	88.8	89.1	91.1	91.5	91.2	91.4	<b>91.6</b>
Кровови	74.58	81.8	90.9	88.8	92.0	94.2	94.0	93.6	94.3	<b>95.3</b>
Древеће	67.75	70.9	75.6	76.8	77.9	<b>83.1</b>	82.5	82.6	82.8	82.4

*Blomley* и *Weinmann (KIT)* су 2017. користили геометријске атрибуте добијене вишеразмерним приступом над више типова суседства. Као класификатор, користили су *RF* и то над два скупа података од који је један био *ISPRS*. *Anandakumar* и др. (*IIS\_7*) су 2016. користили сегментацију облака тачака базирану на супер-вокселима (енгл. *supervoxel*) и класификовали сегменте користећи различите методе машинског учења над екстрактованим спектралним и геометријским атрибутима. У овом приступу облак тачака је дискретизован преко волуметријских елемената – воксела на основу густине и удаљености између тачака. Супер-воксели су засновани на методи супер-пиксела (енгл. *superpixel*) у компјутерској визији, само што су генерисани у 3Д простору на основу скупа воксела. *Horvat* и др. (*UM*) су 2016. користили генетске алгоритме како би вршили семантичку сегментацију на основу текстуралних карактеристика и геометријских атрибута тачака. *Niemeyer* и др. (*LUH*) су 2016. развили два независна *CRF* приступа за класификацију тачака и сегмената облака тачака.


Код метода *NANJ2 (Zhao* и др., 2018) и *WhuY4 (Yang* и др., 2017), генерисани атрибути су пројектовани на 2Д слике. На тај начин је класификација тачака у 3Д простору пребачена на класификацију одговарајуће атрибутске слике како би се у потпуности искористила моћ дводимензионалних конволуционих неуронских мрежа (енгл. *Convolutional Neural Network – CNN*). Ове методе су имале више вредности Ф1 скорa од традиционалних метода (Табела 6.1). За разлику од тих метода, *RIT\_1 (Yousefhusien* и др., 2018) и *CHDJ (Zhu* и др., 2021) су методе које се извршавају директно над облаком тачака. Код *RIT\_1* коришћена је модификована верзија *PointNet* алгоритма (*Qi* и др., 2017), заснована на вишеразмерном приступу семантичког означавања тачака укључивањем контекстуалних информација. Код *CHDJ* методе коришћене су конволуционе неуронске мреже са новим конволуционим оператором који је служио за екстракцију локалних атрибута директно над облаком тачака. На тај начин су аутори дефинисали нови конволуциони слој као саставни део *CNN* мреже како би научили мрежу да користи вишеслојне карактеристике из облака тачака и одреди ознаку класе сваке тачке.

Генерално гледано, *ITU*, *KIT*, *IIS7*, *UM*, *LUH* и метода развијена у оквиру ове дисертације (*PhD*) су традиционалне методе базиране на машинском учењу које

<sup>8</sup> <https://www.isprs.org/education/benchmarks/UrbanSemLab/results/vaihingen-3d-semantic-labeling.aspx>

користе ручно генерисане атрибуте (енгл. *handcrafted features*), док су методе *NANJ2*, *RIT\_1*, *WhuY4* и *CHDJ* базиране на дубоком учењу.

Из наведене табеле, може се видети да је најбоље резултате семантичке сегментације дала *CHDJ* метода базирана на дубоком учењу. Једино је *WhuY4* имала незнатно виши Ф1 скор за класу ниске вегетације, док је *LUH* метода пружила нешто више вредности Ф1 скор за класу дрвећа. Што се тиче приступа развијеног за потребе ове дисертације, добијени резултати су били бољи од метода код којих се врши семантичка сегментација за сваку тачку (*ITU* и *KIT*), док су нешто лошији резултати добијени у односу на методе којим се укључују контекстуалне информације приликом класификације (*LUH* и *UM*). Резултати Ф1 скор су били бољи од *IIS\_7* методе за скоро све класе, сем за класу кровова. Може се закључити да су укупна тачност и Ф1 скор благо увећани вршењем просторне регуларизације резултата семантичке сегментације. Можда је то био највећи разлог зашто су добијени бољи резултати у смислу укупне тачности од *ITU* и *KIT*. Такође се треба додати да се у *PhD* методи користе растеризовани производи облака тачака, и да би се са поправљањем грешака насталих тим приступом можда и боље позиционирала у поређењу са другим методама које се извршавају директно над облаком тачака. Очигледно је да би увођењем контекстуалних информација у процес семантичке сегментације дошло и до побољшања резултата, јер би се спровела класна регуларизација тачака у простору.



Слика 6.2: Вредност Ф1 скор за сваку класу различитих метода за семантичку сегментацију *ISPRS* података (*PhD* је приступ развијен у оквиру ове дисертације).



### 6.3 Експеримент 3: Семантичка сегментација *ISPRS* облака тачака са узоркованим тренинг подацима и вишеразмерном комбинацијом атрибута

У неким истраживањима се узорковање тренинг података врши насумичним узимањем одређеног броја примерака подједнако за сваку класу (*Blomley* и др., 2016; *Blomley* и *Weinmann*, 2017; *Han* и др., 2020; *Niemeyer* и др., 2014). Балансирање података се изводи ради избегавања померености (енгл. *bias*) које се дешава приликом тренирања модела над небалансираним скупом података (*Chen* и др., 2004). Балансирање скупа података се врши узорковањем или дуплицирањем примерака у зависности од тога да ли је класа којој припадају већинска или мањинска у том скупу података. Редукција количине тренинг података је неопходна такође и уколико је количина тренинг података преобимна (*Atik* и др., 2021).

У циљу смањења количине података без губљења значајнијих перформанси модела, извршено је узорковање тренинг података у овом експерименту. Ово је спроведено на тај начин што су тренинг подаци умањивани за по 10% у свакој итерацији, а затим је проверавано како врше предикцију над тест подацима. Смањивање је вршено тако што се водило рачуна да подаци остану балансирани гледајући класе означавања тачака. Након тога је вршено тренирање појединачних *RF* модела над сваком од умањених итерација тренинг података и предикција над тест подацима са рачунањем укупне тачности предикције. Провера успешности семантичке сегментације узоркованих скупова података вршена је *RF* методом машинског учења. Ова метода је коришћена због кратког времена извршавања и аутоматског рачунања мере важности атрибута која је потребна код каснијег сортирања и рекурзивне елиминације атрибута. После извршеног узорковања података за тренирање, усвојена је количина примерака од 46 700 за даље анализе, док је број примерака коришћених за тестирање семантичке сегментације нешто мало мањи (44 000). Мора се додати да је ова редукована количина података за тренирање модела одабрана иако се и са другим нивоима редукције података добијали јако слични резултати у погледу укупне тачности семантичке сегментације.

Након извршене семантичке сегментације свим методама машинског учења, добило се да најбоље резултате у погледу укупне тачности даје *SVM* метода. Укупна тачност је ипак за 0.6% била мања од тачности добијене вишеразмерном комбинацијом атрибута кад се користе сви расположиви тренинг подаци. Добијени резултат је ипак био бољи за скоро 0.5% у укупној тачности у односу на резултате *D<sub>2</sub>R<sub>1.5</sub>* и *D<sub>2</sub>R<sub>3</sub>* комбинација атрибута. Укупна тачност семантичке сегментације са узоркованим подацима је незнатно мања од поступка кад се користе сви расположиви подаци, али је предност што је на овај начин количина података смањена за више од 40%. Умањење података за тренирање модела је произвело појаву нових грешака приликом семантичке сегментације (Слика 5.28 и Слика 5.29).

## 6.4 Експеримент 4: Семантичка сегментација GRSS облака тачака

Као и код *ISPRS* података, резултати *GRSS* података су јавно доступни заједно са објашњењем алгоритма и оценом тачности (*Le Saux* и др., 2019; *Lian* и др., 2021). Будући да је наведени скуп података публикован доста касније од *ISPRS* података, методе коришћене за семантичку сегментацију су углавном базиране на методама дубоког учења и то *PointSift* алгоритму (*Jiang* и др., 2018; *Lian* и др., 2021). Стога су резултати већине метода веома високе тачности у погледу вредности средњег пресека са унијом – *mIoU* (Табела 6.2), који се користи као главна мера перформанси модела у овом такмичењу<sup>9</sup>.


Табела 6.2 Поређење резултата семантичке сегментације у погледу *IoU* по класама и *mIoU* за *GRSS* скуп података.

Класе/Метода	<i>PhD</i>	<i>liuguang</i>	<i>piter</i>	<i>raomb</i>	<i>rbync</i>	<i>aikin</i>	<i>jinhou</i>	<i>CHDJ</i>
Терен	0.9284	0.9563	0.9606	0.9664	0.9728	0.9680	0.9737	<b>0.9750</b>
Висока вегетација	0.5392	0.9635	0.9541	0.9455	0.9478	0.9568	0.9533	<b>0.9654</b>
Кровови зграда	0.8816	0.8426	0.8627	0.8572	0.8814	0.8832	<b>0.8949</b>	0.8943
<i>mIoU</i>	0.7830	0.9208	0.9258	0.9230	0.9340	0.9360	0.9406	<b>0.9449</b>

Исто као и за *ISPRS* скуп података, метода коју су развили *Zhu* и др. (*CHDJ*) 2021. дала је најбоље резултате за све класе (Табела 6.2). Метода *PhD* развијена у оквиру ове дисертације даје поприлично добре резултате за класу терена, мада нешто нижу у погледу *IoU* од оних заснованих на методама дубоког учења. За класу кровова зграда добијени су резултати којима је позиционирана као четврта најбоље рангирана метода. Најлошији резултати се добијају за класу високе вегетације, тј. дрвећа, где су резултати значајно нижи од других метода (Табела 6.2). Ово се делом дешавало и због знатно мање количине података за тренирање и тестирање која су припадала класи вегетације. Са само малим бројем грешака семантичке сегментације за мањинску класу *IoU* мера би знатно опала, док *OA* вредност остаје висока уколико су тачке које припадају већинској класи добро предиктоване.

---

<sup>9</sup> <https://competitions.codalab.org/competitions/20217>



Слика 6.3: Вредност  $IoU$  за сваку класу различитих метода за семантичку сегментацију  $GRSS$  података ( $PhD$  је приступ развијен у оквиру ове дисертације).

Као што је већ речено, уколико се модели истренирани над  $GRSS$  подацима примене на  $ISPRS$  податке, добија се знатно нижа укупна тачност семантичке сегментације за све методе (Табела 5.35). Као једна од метода која одскаче од других и даје укупну тачност од укупно 72.8% издваја се сложени ансамбл модел базиран на наивном Бајесу –  $ENS\_NB$ . Треба додати да друге методе машинског учења у овом случају нису дале запажене резултате семантичке сегментације јер су  $OA$  од 65.3% и 60.7% имале само  $RF$  и  $GB$ , респективно, док су друге методе имале укупну тачност испод 60%. Методом вештачких неуронских мрежа добијени су најлошији резултати са укупном тачношћу мањом од 50%. Ово се дешава код вештачких неуронских мрежа поготово ако подаци за тренирање не одговарају подацима за тестирање, што се очигледно догодило у овом поступку семантичке сегментације.

Углавном је било тешко ускладити коришћене класе за један и други скуп података, јер су класе непропусних површина и ниске вегетације из  $ISPRS$  података спојене како би биле упоредиве са класом терена у  $GRSS$  подацима. Такође, ако се упореде  $GRSS$  и  $ISPRS$  подаци у погледу класе кровова, може се видети да су  $GRSS$  објекти значајно веће површине и мање нагнутости крова од  $ISPRS$  објеката. Такође, различите густине облака тачака су утицале на различито срачунате атрибуте ова два скупа података.

## 6.5 Експеримент 5: Побољшање резултата детекције појединачних стабала

У овом делу дисертације, дата је дискусија о стратегији детекције појединачних стабала и побољшању резултата у односу на већ устаљене методе (поглавље 6.5.1), избору метода машинског учења најефикаснијег за наведени проблем класификације (поглавље 6.5.2), као и о поређењу резултата класификације са резултатима истраживања других аутора. У последњем делу су дати закључци о важности појединих атрибута коришћених за класификацију.

### 6.5.1 Значај побољшања резултата детекције појединачних стабала у односу на већ устаљене методе

У овом истраживању, прозор коришћен за филтрирање локалних максимума био је за 1 m мањи од оптималне величине за сваку шумску парцелу како би се генерисало што већи број кандидата за врхове стабала. Ово је извршено како би се осигурало да сва стабла унутар парцеле садрже локални максимум и да би се касније могли елиминисати погрешно детектовани врхови стабала коришћењем предложене методе побољшања детекције стабала у шумском подручју. На овај начин се избегава каснија недовољна сегментација која се јавља када нису детектовани неки од потенцијалних кандидата за врхове стабала. Стога ни не постоји потреба да се дефинише још једна класа када локални максимум није детектован, што би иначе проузроковало то да одговарајући сегмент садржи крошње већег броја стабала (недовољна сегментација). Будући да је *ITD* тачност за тест податке била око 68%, предложеном методом побољшања резултата *OA* је повећана за 21%. Међутим, мора се имати у виду да су *ITD* резултати постигнути са параметрима подешеним тако да се генерише већи број кандидата врхова стабала. Када би се користили оптимални параметри, наведена *ITD* метода би засигурно генерисала мањи број кандидата за врхове стабала, што би довело до повећања *OA*. Код *LM* филтрирања то се постиже коришћењем прозора променљиве величине који је зависан од висине стабала унутар парцеле или би се користио прозор са фиксном, оптималном величином. *Persson* и др., су 2002. успели да детектују 71% од укупног броја стабала једном од првих аутоматизованих метода екстракције појединачних стабала користећи *СНМ* генерисан на основу *ALS* података. Тачност детекције стабала била је 70% за доминантна стабла у хетерогеним шумама код истраживања изведеног од стране *Pitkänen* и др., 2004. *Yu* и др., 2011. су постигли *ITD* тачност од око 69% за детекцију стабала која су се налазила у различитим шумским условима (различита густина шуме, старост, типови подручја и врсте дрвећа). *Kaartinen* и др., су 2012. у њиховом истраживању о успешности *ITD* методе коришћењем *ALS* података нашли да се мануелним процесирањем може идентификовати 70% од укупног броја стабала.

## 6.5.2 Селекција метода машинског учења

*XGB*, *ANN* и *SVM* класификатори су се показали инфериорнији у односу на *RF* класификатор, али није било значајнијих разлика између ових метода. Наиме, вредност медијане *OA* за *RF* била је 90.4%, за *XGB* 88.8%, за *ANN* 88.0% и за *SVM* 85.6%, док су вредности медијане за капа коефицијент биле редом 0.808, 0.776, 0.759 и 0.712. Када се врши поређење перформанси поменутих класификатора над тест подацима (Табела 5.37), може се видети да је остао исти редослед класификатора, али са већим раздвајањем између прва два и друга три. *XGB* је показао скоро исте перформансе у погледу постигнуте тачности као и *RF*, али је за *XGB* било потребно много више времена за тренирање модела. Такође је могуће да се *ANN* превише прилагодио подацима због великог броја скривених јединица, тако да би се можда *SVM* показао боље од овог класификатора у неким другим ситуацијама. Интересантно је да је у оквиру овог истраживања добијено да су се *XGB* и *ANN* алгоритми показали конкурентним *RF* алгоритму или чак погоднији алгоритми од *SVM*-а, док су остали истраживачи најчешће налазили да *RF* и *SVM* обезбеђују боље резултате за *ALS* и друге задатке класификације података прикупљеним техникама даљинске детекције (Corte и др., 2020; Dai и др., 2018; Immitzer и др., 2012; Kamińska и др., 2018; Lisiewicz и др., 2022b).

## 6.5.3 Резултати класификације

У оквиру овог истраживања постигнуте су високе вредности *OA* и капа коефицијента кад је као класификатор коришћена случајна шума са екстремно насумичним стаблима (*ERT*). *OA* добијена из десетоструке унакрсне валидације над тренинг подацима била је 90.4%, док је капа коефицијент био 0.808. Предикцијом извршеном над тест подацима постигнута је *OA* од 89.0% и *k* од 0.757.

Постоји неколико студија које су се бавиле класификацијом сегмената крошњи стабала коришћењем *SVM* класификатора (Dai и др., 2018; Lisiewicz и др., 2022b). У оквиру тих истраживања постигнути су резултати који су у погледу тачности класификације слични оним оствареним у оквиру овог истраживања. Стога, резултати добијени у овој студији потврђују да *SVM* остаје добра метода машинског учења за класификацију зато што је у неким случајевима класификације по основу врста дрвећа надмашила *RF* (Ballanti и др., 2016; Dalponte и др., 2012).

Код приступа базираног на *LR* класификатору развијеном од стране Kathuria и др., 2016. дошло се до закључка да *LR* даје веће вредности *OA* у односу на *RF* модел (95% за *RF*, док је било 98% за *LR*). У овој дисертацији се дошло до закључка да *RF* и други алгоритми дају много боље резултате од *LR* класификатора, али је тешко вршити директно поређење резултата између ових студија, будући да је истраживање у овој дисертацији вршено над подацима добијеним снимањем природне и мешовите, углавном лишћарске шуме, док је код истраживања изведеног од стране Kathuria и др., 2016. експеримент вршен над подацима *Pinus radiata* плантаже четинарских стабала. Још један разлог зашто су поменути истраживачи добијали тако добре резултате може бити у томе што је модел

истрениран симулираним стаблима која су заправо појединачна стабла издвојена из података *ALS* облака тачака. Затим, методологије истраживања се разликују у неколико аспеката. У истраживању спроведеном за потребе ове дисертације коришћене су зоналне статистике за рачунање атрибута сваког сегмента крошње стабла које припада сваком локалном максимуму, док су *Kathuria* и др., 2016. користили фокалне статистике са прорачуном атрибута који су зависили од величине полупречника претраге. На тај начин је боље срачунат атрибут на бази тачака које припадају целој крошњи стабла, а не неком суседству врха крошње којим се обухвата део крошње или подручје веће од ње. Поменути корак доста зависи и од самих резултата сегментације крошњи стабала.

*Lisiewicz* и др., су 2022b. испробали неколико метода машинског учења (*RF*, *SVM* и *kNN*) како би коришћењем *ITD* метода базираног на *CHM*–у разликовали исправно детектоване сегменте крошњи стабала од погрешно детектованих. *RF* класификатором су постигли највишу укупну тачност над тренинг подацима (*OA* од 87.0% и *κ* од 0.794) и над тест подацима (*OA* од 85.3% и *κ* од 0.641). Истраживање спроведено за потребе ове дисертације је више било оријентисано на раздвајање исправних од погрешно детектованих врхова стабала користећи информације добијене од кластера тачака које упадају у одговарајуће сегменте крошњи стабала. Са друге стране, поменути истраживачи су у оквиру свог истраживања покушали да разликују грешке на свеобухватнији начин (на исправну, претерану и недовољну сегментацију), како би се идентификовали сви могући сценарији грешака сегментације. У експериментима спроведеним у оквиру израде ове дисертације постигнута је нешто виша тачност над тренинг подацима када је коришћен *RF* базиран на *ERT* (*Geurts* и др., 2006). Тачност постигнута над тест подацима код *Lisiewicz* и др., 2022b. није могуће упоредити са резултатима спроведеним у овом истраживању зато што су ти истраживачи користили унакрсну валидацију над тест подацима, док је у овом истраживању извршена класична подела на тренинг и тест податке и онда је модел који је истрениран над тренинг подацима примењен на тест податке. Тиме је добијена реалнија оцена модела, јер је коришћен независни скуп података за предикцију модела. Подручје истраживања које су поменути истраживачи користили је такође била природна шума, али са већим уделом четинарских у односу на лишћарске врсте дрвећа. *ALS* подаци за потребе истраживања у овој дисертацији су прикупљени за шумско подручје које се састоји већим делом од лишћарских стабала у периоду смањене вегетације, тј. када је опало лишће са дрвећа, што чини детекцију врхова стабала још компликованијом. Такође, за класификацију су коришћени различити атрибути који су базирани на облику сегмената крошњи стабала, сопственим вредностима, атрибутима базираним на уклапању полиномских облика тачкама и метрикама дрвећа генерисаним на основу *LiDAR* облака тачака. За разлику од поменутог истраживања, овде нису коришћени атрибути интензитета одбитка сигнала зато што би требала бити извршена ваљана радиометријска корекција података интензитета пре било какве анализе (*Ahokas* и др., 2006; *Kashani* и др., 2015). Уклањање високо корелираних атрибута је изведено на исти начин, али је у овој дисертацији извршен додатни корак селекције атрибута коришћењем генетских алгоритама. Такође је коришћена метода балансирања класа базирана на *SMOTE* алгоритму којом је укупна тачност увећана за скоро 5%.

Према расположивим сазнањима, *XGB* и *ANN* као методе никад нису биле коришћене за овакав тип проблема класификације, и у овом истраживању је показано да *XGB* даје сличне резултате као и *RF*.

### 6.5.3.1 Резултати класификације у зависности од типа шуме

Табела 5.38 даје преглед да је у скоро свим шумским парцелама са различитим типовима шуме добијена укупна тачност виша од 88%. Вредности  $F1$  скорa су биле значајно више за класу исправно детектованих врхова стабала у односу на класу погрешно детектованих (5–12%). Најбоље перформансе у погледу постигнуте тачности постигнуте су код шумске парцеле која је имала мешовите типове шума (лишћарске и четинарске). Разлог за овакав епилог могао би бити мањи број примерака које садржи шумска парцела (укупно 36 стабала), посебно оних који припадају класи погрешно детектованих врхова стабала. Чак и миграцијом једног примерка из једне класе у другу долази се до велике промене излазне тачности.

Може се приметити да је тачност класификације извршена над лишћарским шумским парцелама била нешто нижа у односу на четинарске (Табела 5.38). Ово се увек дешавало у досадашњим истраживањима зато што је велики број студија показао да је детекција појединачног стабла и делинеација у четинарским шумама много успешнија, будући да, у већини случајева, четинарске врсте имају јасно дефинисан облик крошње (*Eysn* и др., 2015). Међутим, у истраживању спроведеном у оквиру ове дисертације, коришћени поступак детекције појединачних стабала је дао веома сличне резултате за лишћарске и четинарске шуме. Још један важан параметар је да шумске парцеле углавном садрже доминантне лишћарске врсте дрвећа (букве), које је у великој мери добро раздвојено.

### 6.5.4 Важност атрибута

Број тачака у сваком сегменту крошње стабла ( $N$ ) је важан атрибут који указује на величину крошње стабла ако нема великих разлика у густини облака тачака. Ако је локални максимум детектован за одговарајући сегмент крошње стабла и ако је алгоритам за сегментацију добро извршио тај део процесирања, онда ће број тачака за лишћарску врсту дрвећа имати велику значајност као атрибут. Уколико је детектовано неколико локалних максимума за једну крошњу стабла, десиће се да ће тачке које нису врхови стабала такође бити погрешно детектоване као врхови стабала (*Koch* и др., 2006). Када је наведени атрибут изостављен из тренинг података, *OA* добијена из десетоструке унакрсне валидације над тренинг подацима опада за 2%. *Kathuria* и др., су 2016. такође користили број тачака које се налазе на висини већој од два метра изнад терена као атрибут и приказали га као важну, некорелисану варијаблу за тренирање финалног модела.

Један од најважнијих атрибута је ентропија висинске дистрибуције тачака – нормализовани Шенонов индекс вертикалне комплексности (*Hentr*). Ентропија висинске дистрибуције је мера за квантификацију диверзитета и базирана је на

броју и фреквенцији присутних врста (*Shannon, 1948*). Наведена метрика дрвећа је коришћена како би се квантификовала различитост и једнакост висинске дистрибуције *ALS* тачака. У том случају се прави добро разликовање између сегмента који представља део крошње стабла као резултата претеране сегментације и исправног сегмента који покрива целу крошњу стабла. Када би се наведени атрибут изоставио, *OA* добијена из десетоструке унакрсне валидације над тренинг подацима опала би за 1.5%.

Неки атрибути из групе уклапања облика (*Medquad* и *Medrobquad*) показали су се битни за класификацију на основу вредности важности атрибута. Вредности медијане уклапања полиномског облика на облак тачака сегмента крошње стабла (прво без – *Medquad*, а затим са робусном проценом за уклапање грубих грешака – *Medrobquad*), биле су позициониране по важности као други и трећи атрибут. У овом случају, уколико је цело дрво у потпуности добро сегментовано, онда је апсолутна вредност медијане резидуала од уклапања полиномског облика на облак тачака већа од вредности која се добија кад се уклапање врши са сегментом дела крошње стабла добијеним са претераном сегментацијом. Један од могућих разлога би био тај што се полиномски облик боље уклапа са тачкама које припадају само делу крошње дрвета него тачкама које би припадале целој крошњи стабла, због „шиљатог“ облика крошње и стога такве и дистрибуције тачака. Ово је важан закључак зато што претходне студије нису користиле ову групу атрибута за наведени тип класификације. Када се наведени атрибути уклапања облика не би користили у тренинг подацима, *OA* добијена из десетоструке унакрсне валидације над тренинг подацима би се смањила за 0.6%.

Интересантно је приметити да атрибути из групе базираних на сопственим вредностима нису препознати као важни за класификацију врхова стабала, тако да су уклоњени приликом процеса селекције атрибута. Ово је самим тим оправдано будући да наведени тип атрибута нису користили ни други аутори приликом класификације сегмената крошњи стабала (*Dai* и др., 2018; *Kathuria* и др., 2016; *Lisiewicz* и др., 2022b), али јесу коришћени приликом семантичке сегментације облака тачака (*Chehata* и др., 2009; *Weinmann* и др., 2014; *West* и др., 2004).



## 7 ЗАКЉУЧНА РАЗМАТРАЊА

Семантичка сегментација облака тачака је научна област која је и даље предмет интензивног истраживања. Постоје дефинитивни захтеви у погледу коректно класификованих података и балансираних примерака по класама потребних за тренирање, валидацију и класификацију. Проблеми на које се наилази нису тривијални и захтевају дуг процес експериментисања са различитим скуповима података да би се развиле универзалне процедуре класификације за све типове података.

Данас се велика количина података прикупља технологијом ласерског скенирања из ваздуха која захтева обимно процесирање података са доста мануелног рада, поготово код класификације облака тачака. Аутоматизована или полуаутоматизована класификација којима се постижу висока тачност могу знатно уштедети време и ресурсе у односу на мануелну класификацију. Само мали помак у смислу постизања веће тачности или бржег процеса класификације много значи, јер пропорционално смањује велику количину каснијег мануелног посла. У томе се огледа практична примењивост овог приступа и значај саме дисертације из тог угла. Поред свега наведеног, резултати добијени у оквиру овог истраживања могу да укажу на даље правце истраживања у овој области.

Техника ласерског скенирања посебно је важна за шумска подручја, будући да се због природе сигнала могу прикупити подаци о структури дрвећа и терену који се налази испод крошњи стабла. Побољшањем детекције појединачних стабала у шумском подручју унапређује се начин прикупљања података о шумској инвентури што је неопходно ради утврђивања стања шуме за потребе стратешког планирања. Развијен је велики број метода за детекцију појединачних стабала у шумском подручју, али није извршено довољно истраживања која се баве побољшањем добијених резултата коришћењем метода машинског учења, што је обухваћено овом дисертацијом.

### 7.1 Преглед извршених истраживања и добијених резултата

У овом истраживању извршена је семантичка сегментација облака тачака коришћењем метода машинског учења за два скупа података који се користе за потребе јавних такмичења у постизању што бољих перформанси код класификације облака тачака. Извршено је побољшање резултата детекције појединачних стабала у шумском подручју методом базираном на машинском учењу. Анализиран је учинак различитих комбинација атрибута као и ефекат избора атрибута са рекурзивном елиминацијом атрибута или генетским алгоритмима. Вршене су анализе балансирања података и утицај који овај поступак има на тачност семантичке сегментације/класификације.

На основу постигнутих резултата могу се донети одређени закључци који се тичу различитих експеримената изведених у овој дисертацији. Експерименти су извршени над два јавно доступна скупа података ласерског скенирања (*ISPRS* и *GRSS*), као и над подацима добијеним ласерским скенирањем из ваздуха за потребе индивидуалне детекције стабала. У овом делу су донети и важни закључци који се односе на:

- утицај балансирања података по класама ради тренирања модела машинског учења,
- тестирање великог броја метода машинског учења за потребе семантичке сегментације и оцене њихове тачности ради проналаска најприкладније методе,
- одређивање важности појединих атрибута,
- узорковање тренинг података и универзалности тренираног модела за предикцију над другим скуповима података и
- избор оптималне методе машинског учења за побољшање детекције појединачних стабала у шумским подручјима.

Што се тиче врсте атрибута коришћених за предикцију одређених у експерименту 1, може се приметити да је у овом истраживању коришћен далеко већи број атрибута него у другим радовима са сличним тематиком (*Atik* и др., 2021; *Cehata* и др., 2009; *Duran* и др., 2021; *Niemeyer* и др., 2014; *Pauly* и др., 2003; *Schmidt* и др., 2014; *Weinmann* и др., 2015a, 2014, 2013; *West* и др., 2004). Управо из ових разлога дешавало се да са истим подацима предложени модел даје боље резултате у погледу тачности семантичке сегментације (*Atik* и др., 2021).

Вршена је и оптимизација параметара којима се врши избор суседства тачака на основу којих се врши прорачун атрибута. Ту се дошло до закључка да цилиндар претраге даје боље резултате него сфера претраге и да треба одабрати оптималан полупречник претраге који опет зависи од густине облака тачака. У том случају, најбоље резултате даје вертикални цилиндар претраге са полупречницима претраге од 1.5 m и 3 m – комбинације  $D_2R_{1.5}$  и  $D_2R_3$ . *Atik* и др. су 2021. добили најбоље резултате *ISPRS* података управо за полупречник претраге суседства тачака од 1.5 m. У овој дисертацији је испробан приступ којим се истовремено рачунају атрибути из више комбинација начина претраге и величине полупречника претраге суседства. Добијена је нешто већа тачност семантичке сегментације, али је подигнут број коришћених атрибута на 100, што је довело до тога да се са расположивим рачунарским ресурсима поједини модели машинског учења нису могли истренирати над тако великим скупом података.

После тога је примењен приступ уклањања атрибута са високом међусобном корелацијом и извршена рекурзивна елиминација атрибута. Утврђено је да се елиминацијом великог броја атрибута у наведеним комбинацијама није знатно изгубило на перформансама модела класификације, али се драстично смањило време тренирања модела машинског учења и предикције над тест подацима.

Коначни циљ методологије је био генерисање што више атрибута који имају великог значаја за семантичку сегментацију, али и уклањање оних атрибута који су међусобно високо корелисани у циљу скраћења времена тренирања модела.

Закључак је да је најбоље решење користити вишеразмерну комбинацију атрибута, али да при томе треба извршити избор најважнијих атрибута и са њима вршити тренирање модела за семантичку сегментацију облака тачака.

У овој дисертацији је извршена растеризација атрибута облака тачака како би се смањила количина података потребна за тренирање модела, а и издвојили они подаци који су битни за семантичку сегментацију. Наведени приступ конверзије у растерске слике је већ успешно коришћен код аутора који су користили традиционалне методе машинског учења (*Chehata* и др., 2009), али и методе дубоког учења (*Yang* и др., 2017; *Yousefhussein* и др., 2018; *Zhao* и др., 2018), како би у потпуности искористили предности конволуционих неуронских мрежа. Мана овог приступа је у томе што се конверзијом из облака тачака у растерске слике (вредности атрибута тачака) долази до губитка информација. Ово је посебно очигледно у ситуацијама када у једну ћелију слике упада више тачака различитих класа знатно раздвојених по висини као што су тачке које припадају терену и тачке које припадају крововима зграда. У тим случајевима се дешава да све тачке које упадају у ћелију добијају и исту класу као и да не постоји могућност да им се додели различита класа ако су по хоризонталној локацији блиске. Ово је један од главних разлога зашто су се и појављивале грешке семантичке сегментације на ивицама кровова (Слика 5.21 и Слика 5.34). Један од начина на који би се могао превазићи наведени недостатак је генерисање више нивоа растерских слика класа на различитим висинама изнад терена. Све ове слике би биле коришћене као излазне вредности приликом тренирања модела семантичке сегментације за различиту висину одређивања. Тако би се узеле у обзир и ситуације кад на истој локацији има више тачака са различитим висинама које имају другачију класу. Други начин решавања овог проблема био би вокселизација (енгл. *voxelization*) облака тачака са којом се и даље смањује количина података за тренирање, а обухватају се различите класе које се јављају променом висине на истој локацији (*Aljumaily* и др., 2023; *Anandakumar* и др., 2016; *Plaza-Leiva* и др., 2017). Још један начин превазилажења овог проблема јесте коришћење метода којим се ради директно над облаком тачака, узимајући у обзир просторне односе између објеката (*Niemeyer* и др., 2014).

У експерименту 2 утврђено је да се највиша укупна тачност семантичке сегментације *ISPRS* тест података ( $OA = 83.5\%$ ) постиже се коришћењем *SVM* класификатора са вишеразмерном комбинацијом атрибута. Вишеразмерна комбинација се показала бољом од једноразмерних комбинација атрибута, јер је укупна тачност свих метода увећана за око 2% (Табела 5.20). Генерално гледано, резултати свих коришћених метода су задовољавајући и разлике у тачности модела на основу *OA* крећу се у домену од 79% до 83.5%. *Atik* и др., су 2021. такође добијали најбоље резултате коришћењем *SVM* класификатора, али са нешто нижом укупном тачношћу ( $OA = 79.71\%$ ). Кад се гледају резултати  $F1$  скорa семантичке сегментације аутора који су користили ове податке у својим истраживањима (Табела 6.1), наведени приступ је имао боље резултате метода код којих се семантичка сегментација врши засебно за сваку тачку (*Anandakumar* и др., 2016; *Atik* и др., 2021; *Blomley* и *Weinmann*, 2017). Нешто лошији резултати добијени су у односу на методе којим се укључују контекстуалне информације приликом класификације (*Horvat* и др., 2016; *Niemeyer* и др., 2014). Методе примењене над овим подацима, а које су базиране на дубоком учењу (*Yang* и др., 2017; *Yousefhussein* и др., 2018; *Zhao* и др., 2018; *Zhu* и др., 2021), дале су значајно боље

результате у односу на традиционалне методе машинског учења, међу којима је и приступ развијен у оквиру ове дисертације (Слика 6.2).

Просторна регуларизација резултата семантичке сегментације растерских продуката облака тачака вршена је додељивањем класе вредности ћелија пиксела на основу вредности која се најчешће појављивала у суседству  $3 \times 3$ . На тај начин је узета у обзир припадност класама пиксела околине и уклоњени су усамљени пиксели других класа. Овим поступком се постигло повећање укупне тачности семантичке сегментације за 3 до 4%, у зависности од коришћеног модела семантичке сегментације.

Уколико се ради са *ISPRS* подацима, балансирање података према заступљеним класама није довело до значајног побољшања у семантичкој сегментацији, већ је чак и у већини случајева незнатно смањило укупну тачност. Ово је највероватније последица тога што су *ISPRS* подаци у извесној мери већ балансирани према коришћеним класама (ниска вегетација, непропусне површине, кровови и дрвеће). И у случају кад се користе *GRSS* подаци, балансирање података није довело до унапређења резултата семантичке сегментације.

Важност атрибута говори о утицају који сваки од атрибута коришћених за тренирање модела има на тачност предикције. Сви атрибути који учествују у тренирању *RF* модела сортирани су на основу средњег опадања Џини индекса (*MDG*). Утицај појединачних атрибута је квантификован избацавањем појединачних, највише ранжираних атрибута из тренирања модела и одређивањем укупне тачности предикције модела над тест подацима. Смањење би указивало на важност који је атрибут имао у самој предикцији. Овде се дошло до закључка да интензитет одбијања сигнала (*Amplitude*) има највећи утицај на предикцију модела (до 10%) и да се отклањањем негативне отворености (*negOpenness*) смањује укупна тачност предикције *RF* модела за 1%. Када се одређена група атрибута која је везана за вертикалну дистрибуцију тачака (*NormalizedZ*, *MIN*, *RANK*) не би укључила у тренирање *RF* модела и каснију предикцију над тест подацима, укупна тачност би била мања за око 5%.

У циљу смањења количине података без губљења значајнијих перформанси модела, извршено је узорковање тренинг података у експерименту 3. Може се доћи до закључка да је у овом експерименту тренирање модела над тренинг подацима који су количински скоро једнаки тест подацима дало нешто вишу тачност предикције у односу на друге варијанте са различитим количинама података за тренирање модела. У случају када се користи мање или више података од наведене количине, нема велике разлике у укупној тачности семантичке сегментације. Количина података мања од наведене доводи до благог пада у тачности модела, док са количинама изнад ове не би дошло до побољшања у тачност семантичке сегментације. Укупна тачност семантичке сегментације смањена је за 0.6% у односу на случај када нису редуковани тренинг подаци, што је ипак за скоро 0.5% боље од резултата семантичке сегментације добијених у случају једноразмерне комбинације атрибута. Ово је један од разлога зашто би пре овог поступка требало проценити да ли се исплати редукација података јер доводи до смањења перформанси семантичке сегментације и појављивању некарактеристичних

грешака којих није било пре извршене редукције података (Слика 5.28 и Слика 5.29).

У експерименту 4 добијено је да се највиша укупна тачност над *GRSS* подацима за Цексонвил постиже *ENS\_NB* методом машинског учења ( $OA = 93.6\%$ ). Највиша укупна тачност над *GRSS* подацима за Омаху постиже се исто *ENS\_NB* методом ( $OA = 92.9\%$ ). Добијени резултати нису били бољи од већине метода дубоког учења које су примењене над овим подацима (Табела 6.2 и Слика 6.3). Једино су резултати класификације кровова зграда били бољи од више од половине метода у погледу *IoU* за ту класу. Резултати семантичке сегментације класе терена нису били знатно инфериорнији од других метода, док су вредности *IoU* за класу високе вегетације значајно ниже од других метода (Слика 6.3). Закључак је да се методама дубоког учења добијају знатно бољи резултати у односу на традиционалне методе машинског учења, било да се врши конверзија облака тачака у растерске слике или се семантичка сегментација врши директно над облаком тачака. Техникама дубоког учења се можда постиже највиша тачност семантичке сегментације, али велика мана ових метода је веома мала интерпретабилност модела и што је потребна огромна количина података за тренирање модела. Такође је за тренирање неуронских мрежа са великим бројем скривених слојева потребно издвојити пуно времена да се изврши рачунарско процесирање. Додатно постоје и велики захтеви капацитета рачунара у погледу паралелног извршавања послова (напредни процесори и графичке картице) и велике количине расположиве радне меморије. Методама дубоког учења се такође прескаче и део који се тиче генерисања атрибута и избора најважнијих атрибута за потребе семантичке сегментације (енгл. *feature engineering*) будући да се неуронским мрежама аутоматски тражи повезаност између улазних података и циљних класа. На тај начин се избегава процес који би требао да обави стручњак из те конкретне области са великим нивоом искуства. У овом раду је тај део обрађен и указано је који су атрибути, начин њиховог одређивања и величина претраге суседства битни за семантичку сегментацију. У неким применама је можда и боље користити методе базиране на дубоком учењу, уколико нема стручњака из те области и има мало времена да се уради детаљнија и подробнија студија. Приступ који је коришћен у овој дисертацији је у том смислу бољи јер се детаљно анализирају коришћени подаци, генеришу адекватни атрибути и врши одређивање одговарајућих хиперпараметара модела чиме се стиче велико искуство и знање потребно за коришћење традиционалних метода машинског учења.

Универзалност модела се огледа у томе како би се модел истрениран над наведеним подацима показао у предикцији над потпуно другим тест подацима са сличним класама. Ово је био један од циљева докторске дисертације и дошло се до закључка да се најбоље показао модел *ENS\_NB* истрениран над *GRSS* подацима који даје укупну тачност предикције од  $72.8\%$  над *ISPRS* тест подацима (Табела 5.35). Треба додати да друге методе машинског учења у овом случају нису дале запажене резултате семантичке сегментације јер су  $OA$  од  $65.3\%$  и  $60.7\%$  имале само *RF* и *GB*, тим редом, док су друге методе имале укупну тачност испод  $60\%$ . Методом вештачких неуронских мрежа добијени су најлошији резултати са укупном тачношћу мањом од  $50\%$ . Ово се очигледно десило јер подаци за тренирање нису одговарали подацима за тестирање што је посебно проблематично код ових метода. У овом експерименту се дошло до закључка да је и даље тешко постићи

универзалност модела машинског учења истренираног над једним скупом података у циљу предикције над тест подацима другог скупа података. Један од главних проблема био је усклађивање класа између различитих скупова података али и одабир репрезентативних делова скупа података којим се могао истренирати оптималан модел. И овде је показано да сложени ансамбл модел базиран на наивном Бајесу (*ENS\_NB*) даје најбоље резултате семантичке сегментације. Један од начина унапређења овог приступа био би одабир доброг подскупа података и најинформативнијих атрибута којим би се могао истренирати оптималан модел.

У већини експеримената, најбољи резултати семантичке сегментације над растерским продуктима добијени су коришћењем сложеног ансамбл модела базираног на наивном Бајесу – *ENS\_NB*. Наведени модел је конструисан на основу модела случајне шуме, градијентног појачавања и логистичке регресије. Ово је остварено независно од тога да ли су коришћени сви расположиви атрибути одређене комбинације или само део тих атрибута након рекурзивне елиминације. Смањење ефикасности ове методе у односу на друге јавило се у неким случајевима кад би била извршена просторна регуларизација класа и конверзија растерских продуката у облак тачака. *SVM* метода би се тада показала као једна од традиционалних метода машинског учења која даје најбоље резултате, и то за вишеразмерну и  $D_2R_{1.5}$  комбинацију атрибута *ISPRS* података. Код ове методе није вршено балансирање података зато што би се одужио процес тренирања модела без приметних побољшања резултата семантичке сегментације. Метода машинског учења која се често показала као најслабија у погледу остварених резултата била је логистичка регресија – *LR*. У неким случајевима дешавало се да су неуронске мреже и сложени ансамбл модел базиран на вештачким неуронским мрежама дали најлошије резултате, тако да су се ови модели показали као најмање ефикасни. Ефикасност коришћених метода машинског учења варира од величине размере претраге као и балансирања података, те би стога требало користити вишеразмерну комбинацију атрибута и избећи балансирање података уколико нема велике неједнакости између класа.

Мана коришћења сложених ансамбл модела је и у томе што је за тренирање таквог модела потребно много више времена, рачунарског процесирања и ресурса у односу на основне моделе који су служили за конструкцију ансамбл модела. Стога је потребно испробати више стратегија за слагање модела и више комбинација основних модела како би се побољшала ефикасност прорачуна и прилагодљивост модела. У неким случајевима би до изражаја дошли и други класификатори и то најчешће сложени ансамбл модели базирани на вештачким мрежама (*ENS\_ANN*) и градијентном појачавању (*ENS\_GB*). Уколико се радило са великом количином података и великим бројем генерисаних атрибута, понекад би се десило да се коришћени модел није могао истренирати (*SVM*, вештачке неуронске мреже и неки сложени ансамбл модели).

У оквиру експеримента 5 представљена је ефективна метода за разликовање између исправно и погрешно детектованих врхова стабала. Метода је базирана на процесирању информација добијених од одговарајућих сегмената крошњи стабала *ALS* података облака тачака. Метрике дрвећа, атрибути уклапања облика, атрибути базирани на сопственим вредностима и атрибути базирани на облику сегмента одређени су за сваки сегмент крошње како би се користили као подаци за

тренирање модела машинског учења. *ADASYN* алгоритам је коришћен за балансирање података, а генетски алгоритми за селекцију атрибута. Пет метода машинског учења је испробано за наведену класификацију: *RF*, *XGB*, *ANN*, *SVM* и *LR*, при чему су најбољи резултати добијени коришћењем *RF* класификатора. Укупна тачност и капа коефицијент добијени из десетоструке унакрсне валидације над подацима за тренирање модела били су 90.4% и 0.808, респективно. Када се предикција врши над тест подацима било је могуће постићи  $OA = 89.0\%$  и  $\kappa = 0.757$ .

Један од кључних корака за постизање наведене класификације било је балансирање класа података *ADASYN* алгоритмом, што је увећало укупну тачност за скоро 5%. Експеримент је показао да су најважнији атрибути за постизање наведене тачности били број тачака унутар сваког сегмента (изостављање овог атрибута смањује  $OA$  за 2%), ентропија висинске дистрибуције (изостављање наведеног атрибута смањује  $OA$  за 1.5%) и медијане уклапања полиномског облика у облак тачака (изостављање ових атрибута смањује  $OA$  за 0.6%).

Када су резултати класификације оцењени засебно за сваки тип шуме,  $OA$  је била 88.3% за парцеле лишћарске шуме предиктоване за тест податке, 89.2% за парцеле четинарске шуме и 91.7% за шумске парцеле које садрже стабла која припадају мешовитој шуми.

## 7.2 Смернице за даља истраживања

Семантичка сегментација и даље представља велики изазов за истраживање у смислу развоја нових метода машинског учења за ове потребе. Потребно је постићи већу универзалност модела машинског учења, како би се са великом успешношћу могао применити на друге скупове података. Управо овде долазе до изражаја методе засноване на дубоком учењу код којих нема ограничења за количину података за тренирање модела. Показало се да су такве методе дале боље резултате семантичке сегментације од традиционалних и ансамбл метода машинског учења.

Битан корак за даљи развој семантичке сегментације односи се на универзалан начин претраге 3Д суседства облака тачака ради прорачуна значајнијих атрибута. Ово се донекле решава вишеразмерном претрагом суседства облака тачака, али се и даље траже решења у виду начина претраге директно над облаком тачака. Вршењем семантичке сегментације директно над облаком тачака избегли би се проблеми који настају због губитка информација приликом конверзије облака тачака у растерске слике. Други начин превазилажења наведених проблема јесте вокселизација са којом би се и смањила количина података за тренирање модела, а и развој алгоритама би био лакши од оних који се врше директно над облаком тачака.

Такође, потребно је узети у обзир повезаност тачака објекта како би се елиминисале грешке које настају ако се не врши просторна регуларизација класа. То се постиже уношењем локалних контекстуалних информација у класификационе моделе, као што је *CRF* (Han и др., 2020; Landrieu и др., 2017; Niemeyer и др., 2014; Schmidt и

др., 2014; Steinsiek и др., 2017). Овим приступом би се постигло отклањање шума у означавању класа и извршило значајно унапређење резултата семантичке сегментације. Увођењем контекстуалних информација приликом семантичке сегментације *ENS\_NB* моделом би се дефинитивно дошло до бољих резултата за разлику од накнадне просторне регуларизације резултата семантичке сегментације.

Временом се густина облака тачака добијеног ласерским скенирањем драстично повећала, поготово код *LiDAR* система монтираних на беспилотне летелице (енгл. *UAV Laser Scanning – ULS*), те се и овај фактор мора имати у виду приликом даљег развоја методологије семантичке сегментације облака тачака. Са већом густином се генерише већа количина података и виши ниво детаљности површи, па се сходно томе и алгоритми морају оптимизовати. Повећана густина облака тачака има и велики утицај на детекцију појединачних стабала у шумским подручјима на основу података ласерског скенирања. У том случају се генерише знатно више кандидата за врхове стабала због веће детаљности генерисаног *CHM*-а, те је детекција појединачних стабала посебан изазов (*Corte* и др., 2022).

Следећи задатак би био одређивање додатних атрибута из других извора података, као што су мултиспектрални или *ALS* подаци са *FW* реконструкцијом облика сигнала. Фузијом података ласерског скенирања са мултиспектралним подацима би се дефинитивно побољшали резултати семантичке сегментације као што је то извршено у другим студијама (*Haala* и *Brenner*, 1999; *Rottensteiner* и др., 2005; *Secord* и *Zakhor*, 2007). Са *ALS* подацима добијеним *FW* реконструкцијом облика сигнала побољшале би се перформансе издвајања класе вегетације због саме природе података добијених овим системом (*Gross* и др., 2007; *Wagner* и др., 2008).



## 8 ЛИТЕРАТУРА

- Ahokas, E., Kaasalainen, S., Hyypä, J., Suomalainen, J., 2006. Calibration of the Optech ALTM 3100 laser scanner intensity data using brightness targets. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36.
- Aljumaily, H., Laefer, D.F., Cuadra, D., Velasco, M., 2023. Point cloud voxel classification of aerial urban LiDAR using voxel attributes and random forest approach. *International Journal of Applied Earth Observation and Geoinformation* 118, 103208. <https://doi.org/10.1016/j.jag.2023.103208>
- Anandakumar, R., Nidamanuri, R., Krishnan, R., 2016. A supervoxel-based spectro-spatial approach for 3D urban point cloud labelling. *International Journal of Remote Sensing* 37, 4172–4200. <https://doi.org/10.1080/01431161.2016.1211348>
- Atik, M.E., Duran, Z., Seker, D.Z., 2021. Machine Learning-Based Supervised Classification of Point Clouds Using Multiscale Geometric Features. *ISPRS International Journal of Geo-Information* 10, 187. <https://doi.org/10.3390/ijgi10030187>
- Axelsson, P., 2000. Dem Generation From Laser Scanner Data Using Adaptive Tin Models. *International Archives of Photogrammetry and Remote Sensing XXXIII*, 8.
- Babahajiani, P., Fan, L., Kämäräinen, J.-K., Gabbouj, M., 2017. Urban 3D segmentation and modelling from street view images and LiDAR point clouds. *Machine Vision and Applications* 28, 679–694. <https://doi.org/10.1007/s00138-017-0845-3>
- Ballanti, L., Blesius, L., Hines, E., Kruse, B., 2016. Tree Species Classification Using Hyperspectral Imagery: A Comparison of Two Classifiers. *Remote Sensing* 8, 445. <https://doi.org/10.3390/rs8060445>
- Becker, C., Rosinskaya, E., Häni, N., d'Angelo, E., Strecha, C., 2018. Classification of Aerial Photogrammetric 3D Point Clouds. *Photogrammetric Engineering and Remote Sensing* 84, 287–295. <https://doi.org/10.14358/PERS.84.5.287>
- Blomley, R., Jutzi, B., Weinmann, M., 2016. 3D Semantic labeling of ALS point clouds by exploiting multi-scale, multi-type neighborhoods for feature extraction. <https://doi.org/10.3990/2.418>
- Blomley, R., Weinmann, M., 2017. Using Multi-Scale Features For The 3d Semantic Labeling Ofairborne Laser Scanning Data. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci. IV-2/W4*, 43–50. <https://doi.org/10.5194/isprs-annals-IV-2-W4-43-2017>

- Bosch, M., Foster, K., Christie, G., Wang, S., Hager, G.D., Brown, M., 2018. Semantic Stereo for Incidental Satellite Images. <https://doi.org/10.48550/arXiv.1811.08739>
- Breiman, L., 2001. Random Forests. *Machine Learning* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., 1996. Stacked regressions. *Machine Learning* 24, 49–64. <https://doi.org/10.1007/BF00117832>
- Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J., 1984. *Classification And Regression Trees*. Routledge, New York. <https://doi.org/10.1201/9781315139470>
- Brodić, N., Cvijetinović, Ž., Milenković, M., Kovačević, J., Stančić, N., Mitrović, M., Mihajlović, D., 2022. Refinement of Individual Tree Detection Results Obtained from Airborne Laser Scanning Data for a Mixed Natural Forest. *Remote Sensing* 14, 5345. <https://doi.org/10.3390/rs14215345>
- Brodu, N., Lague, D., 2012. 3D terrestrial LiDAR data classification of complex natural scenes using a multi-scale dimensionality criterion: applications in geomorphology. *ISPRS Journal of Photogrammetry and Remote Sensing* 68. <https://doi.org/10.1016/j.isprsjprs.2012.01.006>
- Cabo, C., Ordóñez, C., Sánchez-Lasheras, F., Roca-Pardiñas, J., de Cos-Juez, J., 2019. Multiscale Supervised Classification of Point Clouds with Urban and Forest Applications. *Sensors* 19, 4523. <https://doi.org/10.3390/s19204523>
- Charaniya, A.P., Manduchi, R., Lodha, S.K., 2004. Supervised Parametric Classification of Aerial LiDAR Data, in: 2004 Conference on Computer Vision and Pattern Recognition Workshop. Presented at the 2004 Conference on Computer Vision and Pattern Recognition Workshop, pp. 30–30. <https://doi.org/10.1109/CVPR.2004.446>
- Chawla, N.V., Bowyer, K.W., Hall, L.O., Kegelmeyer, W.P., 2002. SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* 16, 321–357. <https://doi.org/10.1613/jair.953>
- Chehata, N., Guo, L., Mallet, C., 2009. Airborne Lidar Feature Selection for Urban Classification using Random Forests, in: *Laserscanning*. Paris, France.
- Chen, C., Liaw, A., Breiman, L., 2004. Using Random Forest to Learn Imbalanced Data.
- Chen, Q., Baldocchi, D., Gong, P., Kelly, M., 2006. Isolating Individual Trees in a Savanna Woodland Using Small Footprint Lidar Data. *Photogrammetric Engineering & Remote Sensing* 72, 923–932. <https://doi.org/10.14358/PERS.72.8.923>
- Chen, T., Guestrin, C., 2016. XGBoost: A Scalable Tree Boosting System, in: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*. Association for Computing Machinery, New York, NY, USA, pp. 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., Yuan, J., implementation), Xgb. contributors (base Xgb., 2022. *xgboost: Extreme Gradient Boosting*.

- Cohen, J., 1960. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement* 20, 37–46. <https://doi.org/10.1177/001316446002000104>
- Corte, A.P.D., da Cunha Neto, E.M., Rex, F.E., Souza, D., Behling, A., Mohan, M., Sanquetta, M.N.I., Silva, C.A., Klauberg, C., Sanquetta, C.R., Veras, H.F.P., de Almeida, D.R.A., Prata, G., Zambrano, A.M.A., Trautenmüller, J.W., de Moraes, A., Karasinski, M.A., Broadbent, E.N., 2022. High-Density UAV-LiDAR in an Integrated Crop-Livestock-Forest System: Sampling Forest Inventory or Forest Inventory Based on Individual Tree Detection (ITD). *Drones* 6, 48. <https://doi.org/10.3390/drones6020048>
- Corte, A.P.D., Souza, D.V., Rex, F.E., Sanquetta, C.R., Mohan, M., Silva, C.A., Zambrano, A.M.A., Prata, G., Alves de Almeida, D.R., Trautenmüller, J.W., Klauberg, C., de Moraes, A., Sanquetta, M.N., Wilkinson, B., Broadbent, E.N., 2020. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture* 179, 105815. <https://doi.org/10.1016/j.compag.2020.105815>
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Mach Learn* 20, 273–297. <https://doi.org/10.1007/BF00994018>
- Cox, D.R., 1958. The Regression Analysis of Binary Sequences. *Journal of the Royal Statistical Society. Series B (Methodological)* 20, 215–242.
- Cramer, M., 2010. The DGPF-Test on Digital Airborne Camera Evaluation Overview and Test Design. *Photogrammetrie - Fernerkundung - Geoinformation* 73–82. <https://doi.org/10.1127/1432-8364/2010/0041>
- Cramer, M., Haala, N., Laupheimer, D., Mandlbürger, G., Havel, P., 2018. Ultra-High Precision Uav-Based Lidar And Dense Image Matching, in: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the ISPRS TC I Mid-term Symposium <q>Innovative Sensing – From Sensors to Methods and Applications</q> (Volume XLII-1) - 10&ndash;12 October 2018, Karlsruhe, Germany, Copernicus GmbH, pp. 115–120. <https://doi.org/10.5194/isprs-archives-XLII-1-115-2018>
- Criminisi, A., Shotton, J., 2013. Decision Forests for Computer Vision and Medical Image Analysis. pp. 95–107. [https://doi.org/10.1007/978-1-4471-4929-3\\_8](https://doi.org/10.1007/978-1-4471-4929-3_8)
- Dai, Q., Ye, R., Liu, Z., 2017. Considering diversity and accuracy simultaneously for ensemble pruning. *Applied Soft Computing* 58, 75–91. <https://doi.org/10.1016/j.asoc.2017.04.058>
- Dai, W., Yang, B., Dong, Z., Shaker, A., 2018. A new method for 3D individual tree extraction using multispectral airborne LiDAR point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 144, 400–411. <https://doi.org/10.1016/j.isprsjprs.2018.08.010>
- Dalponte, M., Bruzzone, L., Gianelle, D., 2012. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment* 123, 258–270. <https://doi.org/10.1016/j.rse.2012.03.013>

- Dalponte, M., Coomes, D.A., 2016. Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. *Methods in Ecology and Evolution* 7, 1236–1245. <https://doi.org/10.1111/2041-210X.12575>
- Demantké, J., Mallet, C., David, N., Vallet, B., 2011. Dimensionality based scale selection in 3D lidar point clouds. *Proceedings of the ISPRS Workshop Laser Scanning* 38, 97–102. <https://doi.org/10.5194/isprsarchives-XXXVIII-5-W12-97-2011>
- Dey, L., Chakraborty, S., Biswas, A., Bose, B., Tiwari, S., 2016. *International Journal of Information Engineering and Electronic Business(IJIEEB)*. *International Journal of Information Engineering and Electronic Business(IJIEEB)* 8, 54.
- Domingos, P., Pazzani, M., 1997. On the Optimality of the Simple Bayesian Classifier under Zero-One Loss. *Machine Learning - ML* 29, 103–130.
- Doneus, M., 2013. Openness as Visualization Technique for Interpretative Mapping of Airborne Lidar Derived Digital Terrain Models. *Remote Sensing* 5, 6427–6442. <https://doi.org/10.3390/rs5126427>
- Dong, T., Zhou, Q., Gao, S., Shen, Y., 2018. Automatic Detection of Single Trees in Airborne Laser Scanning Data through Gradient Orientation Clustering. *Forests* 9, 291. <https://doi.org/10.3390/f9060291>
- Ducic, V., Hollaus, M., Ullrich, A., Wagner, W., Melzer, T., 2006. 3D Vegetation Mapping and Classification using Full-Waveform Laser Scanning 7.
- Duda, R., Hart, P., G.Stork, D., 2001. *Pattern Classification*, in: Wiley Interscience.
- Duran, Z., Ozcan, K., Atik, M.E., 2021. Classification of Photogrammetric and Airborne LiDAR Point Clouds Using Machine Learning Algorithms. *Drones* 5, 104. <https://doi.org/10.3390/drones5040104>
- Ene, L., Næsset, E., Gobakken, T., 2012. Single tree detection in heterogeneous boreal forests using airborne laser scanning and area-based stem number estimates. *International Journal of Remote Sensing* 33, 5171–5193. <https://doi.org/10.1080/01431161.2012.657363>
- Eysn, L., Hollaus, M., Lindberg, E., Berger, F., Monnet, J.-M., Dalponte, M., Kobal, M., Pellegrini, M., Lingua, E., Mongus, D., Pfeifer, N., 2015. A Benchmark of Lidar-Based Single Tree Detection Methods Using Heterogeneous Forest Data from the Alpine Space. *Forests* 6, 1721–1747. <https://doi.org/10.3390/f6051721>
- Ferraz, A., Saatchi, S., Mallet, C., Meyer, V., 2016. Lidar detection of individual tree size in tropical forests. *Remote Sensing of Environment* 183, 318–333. <https://doi.org/10.1016/j.rse.2016.05.028>
- Filin, S., Pfeifer, N., 2005. Neighborhood Systems for Airborne Laser Data. *photogramm eng remote sensing* 71, 743–755. <https://doi.org/10.14358/PERS.71.6.743>
- Flood, M., 2001. LIDAR activities and research priorities in the commercial sector. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 34.
- Geurts, P., Ernst, D., Wehenkel, L., 2006. Extremely randomized trees. *Mach Learn* 63, 3–42. <https://doi.org/10.1007/s10994-006-6226-1>

- Griffiths, D., Boehm, J., 2019. A Review on Deep Learning Techniques for 3D Sensed Data Classification. *Remote Sensing* 11, 1499. <https://doi.org/10.3390/rs11121499>
- Gross, H., Jutzi, B., Thoennessen, U., 2007. Segmentation of Tree Regions using Data of a Full-Waveform Laser. *Photogrammetric Image Analysis* 6.
- Guo, B., Huang, X., Zhang, F., Sohn, G., 2015. Classification of airborne laser scanning data using JointBoost. *ISPRS Journal of Photogrammetry and Remote Sensing, High-Resolution Earth Imaging for Geospatial Information* 100, 71–83. <https://doi.org/10.1016/j.isprsjprs.2014.04.015>
- Guo, L., Chehata, N., Mallet, C., Boukir, S., 2011. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 56–66. <https://doi.org/10.1016/j.isprsjprs.2010.08.007>
- Gupta, S., Weinacker, H., Koch, B., 2010. Comparative Analysis of Clustering-Based Approaches for 3-D Single Tree Detection Using Airborne Fullwave Lidar Data. *Remote Sensing* 2, 968–989. <https://doi.org/10.3390/rs2040968>
- Haala, N., Brenner, C., 1999. Extraction of buildings and trees in urban environments. *ISPRS Journal of Photogrammetry and Remote Sensing* 54, 130–137. [https://doi.org/10.1016/S0924-2716\(99\)00010-6](https://doi.org/10.1016/S0924-2716(99)00010-6)
- Haala, N., Kölle, M., Cramer, M., Laupheimer, D., Mandlbürger, G., Glira, P., 2020. Hybrid Georeferencing, Enhancement And Classification Of Ultra-High Resolution Uav Lidar And Image Point Clouds For Monitoring Applications, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the XXIV ISPRS Congress, Commission II (Volume V-2-2020) - 2020 edition, Copernicus GmbH, pp. 727–734. <https://doi.org/10.5194/isprs-annals-V-2-2020-727-2020>
- Hamraz, H., Contreras, M.A., Zhang, J., 2016. A robust approach for tree segmentation in deciduous forests using small-footprint airborne LiDAR data. *International Journal of Applied Earth Observation and Geoinformation* 52, 532–541. <https://doi.org/10.1016/j.jag.2016.07.006>
- Han, H., Guo, X., Yu, H., 2016. Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest, in: *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. Presented at the 2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS), pp. 219–224. <https://doi.org/10.1109/ICSESS.2016.7883053>
- Han, W., Wang, R., Huang, D., Xu, C., 2020. Large-Scale ALS Data Semantic Classification Integrating Location-Context-Semantics Cues by Higher-Order CRF. *Sensors* 20, 1700. <https://doi.org/10.3390/s20061700>
- Haralick, R.M., 1974. A Measure for Circularity of Digital Figures. *IEEE Transactions on Systems, Man, and Cybernetics* SMC-4, 394–396. <https://doi.org/10.1109/TSMC.1974.5408463>
- He, H., Bai, Y., Garcia, E.A., Li, S., 2008. ADASYN: Adaptive synthetic sampling approach for imbalanced learning, in: *2008 IEEE International Joint Conference*

- on Neural Networks (IEEE World Congress on Computational Intelligence). Presented at the 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), pp. 1322–1328. <https://doi.org/10.1109/IJCNN.2008.4633969>
- Heinzel, J.N., Weinacker, H., Koch, B., 2011. Prior-knowledge-based single-tree extraction. *International Journal of Remote Sensing* 32, 4999–5020. <https://doi.org/10.1080/01431161.2010.494633>
- Höfle, B., Hollaus, M., 2010. Urban vegetation detection using high density full-waveform airborne LIDAR data - Combination of object-based image and point cloud analysis. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 38.
- Höfle, B., Mücke, W., Dutter, M., Rutzinger, M., Dorninger, P., 2009. Detection of building regions using airborne LiDAR: a new combination of raster and point cloud based GIS methods.
- Holmgren, J., Lindberg, E., 2019. Tree crown segmentation based on a tree crown density model derived from Airborne Laser Scanning. *Remote Sensing Letters* 10, 1143–1152. <https://doi.org/10.1080/2150704X.2019.1658237>
- Hoppe, H., DeRose, T., Duchamp, T., McDonald, J., Stuetzle, W., 1992. Surface reconstruction from unorganized points. *SIGGRAPH Comput. Graph.* 26, 71–78. <https://doi.org/10.1145/142920.134011>
- Horvat, D., Žalik, B., Mongus, D., 2016. Context-dependent detection of non-linearly distributed points for vegetation classification in airborne LiDAR. *ISPRS Journal of Photogrammetry and Remote Sensing* 116, 1–14. <https://doi.org/10.1016/j.isprsjprs.2016.02.011>
- Hyypä, J., Hyypä, H., Litkey, P., Yu, X., Haggrén, H., Rönholm, P., Pyysalo, U., Pitkänen, J., Maltamo, M., 2003. Algorithms and Methods of Airborne Laser Scanning for Forest Measurements. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVI*, 8.
- Hyypä, J., Inkinen, M., 1999a. Detecting and estimating attributes for single trees using laser scanner. *Photogramm J Finland* 16, 27–42.
- Hyypä, J., Inkinen, M., 1999b. Detecting and Estimating Attributes for Single Trees using Laser Scanner. *The photogrammetric journal of Finland* 16, 27–42.
- Hyypä, J., Schardt, M., Haggrén, H., Koch, B., Lohr, U., Scherrer, H.U., Paananen, R., Luukkonen, H., Ziegler, M., Hyypä, H., Pyysalo, U., Friedländer, H., Uuttera, J., Wagner, S., Inkinen, M., Wimmer, A., Kukko, A., Ahokas, E., Karjalainen, M., 2001. HIGH-SCAN: The first European-wide attempt to derive single-tree information from laserscanner data. *Photogrammetric Journal of Finland* 17, 58–68.
- Hyypä, J., Yu, X., Hyypä, H., Vastaranta, M., Holopainen, M., Kukko, A., Kaartinen, H., Jaakkola, A., Vaaja, M., Koskinen, J., Alho, P., 2012. Advances in Forest Inventory Using Airborne Laser Scanning. *Remote Sensing* 4, 1190–1207. <https://doi.org/10.3390/rs4051190>

- Immitzer, M., Atzberger, C., Koukal, T., 2012. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sensing* 4, 2661–2693. <https://doi.org/10.3390/rs4092661>
- Jakubowski, M.K., Li, W., Guo, Q., Kelly, M., 2013. Delineating Individual Trees from Lidar Data: A Comparison of Vector- and Raster-based Segmentation Approaches. *Remote Sensing* 5, 4163–4186. <https://doi.org/10.3390/rs5094163>
- Jiang, M., Wu, Y., Zhao, T., Zhao, Z., Lu, C., 2018. PointSIFT: A SIFT-like Network Module for 3D Point Cloud Semantic Segmentation. <https://doi.org/10.48550/arXiv.1807.00652>
- Jing, L., Hu, B., Li, J., Noland, T., 2012. Automated Delineation of Individual Tree Crowns from Lidar Data by Multi-Scale Analysis and Segmentation. *Photogrammetric Engineering & Remote Sensing* 78, 1275–1284. <https://doi.org/10.14358/PERS.78.11.1275>
- John, G.H., Kohavi, R., Pflieger, K., 1994. Irrelevant Features and the Subset Selection Problem, in: Cohen, W.W., Hirsh, H. (Eds.), *Machine Learning Proceedings 1994*. Morgan Kaufmann, San Francisco (CA), pp. 121–129. <https://doi.org/10.1016/B978-1-55860-335-6.50023-4>
- Kaartinen, H., Hyypä, J., Yu, X., Vastaranta, M., Hyypä, H., Kukko, A., Holopainen, M., Heipke, C., Hirschmugl, M., Morsdorf, F., Næsset, E., Pitkänen, J., Popescu, S., Solberg, S., Wolf, B.M., Wu, J.-C., 2012. An International Comparison of Individual Tree Detection and Extraction Using Airborne Laser Scanning. *Remote Sensing* 4, 950–974. <https://doi.org/10.3390/rs4040950>
- Kamińska, A., Lisiewicz, M., Stereńczak, K., Kraszewski, B., Sadkowski, R., 2018. Species-related single dead tree detection using multi-temporal ALS data and CIR imagery. *Remote Sensing of Environment* 219, 31–43. <https://doi.org/10.1016/j.rse.2018.10.005>
- Karatzoglou, A., Smola, A., Hornik, K., Australia (NICTA), N.I., Maniscalco, M.A., Teo, C.H., 2022. kernlab: Kernel-Based Machine Learning Lab.
- Karatzoglou, A., Smola, A., Hornik, K., Zeileis, A., 2004. kernlab - An S4 Package for Kernel Methods in R. *Journal of Statistical Software* 11, 1–20. <https://doi.org/10.18637/jss.v011.i09>
- Kashani, A.G., Olsen, M.J., Parrish, C.E., Wilson, N., 2015. A Review of LIDAR Radiometric Processing: From Ad Hoc Intensity Correction to Rigorous Radiometric Calibration. *Sensors* 15, 28099–28128. <https://doi.org/10.3390/s151128099>
- Kathuria, A., Turner, R., Stone, C., Duque-Lazo, J., West, R., 2016. Development of an automated individual tree detection model using point cloud LiDAR data for accurate tree counts in a *Pinus radiata* plantation. *Australian Forestry* 79, 126–136. <https://doi.org/10.1080/00049158.2016.1153770>
- Kebede, T.A., Hailu, B.T., Suryabagavan, K.V., 2022. Evaluation of spectral built-up indices for impervious surface extraction using Sentinel-2A MSI imageries: A case of Addis Ababa city, Ethiopia. *Environmental Challenges* 8, 100568. <https://doi.org/10.1016/j.envc.2022.100568>

- Keränen, J., Maltamo, M., Packalen, P., 2016. Effect of flying altitude, scanning angle and scanning mode on the accuracy of ALS based forest inventory. *International Journal of Applied Earth Observation and Geoinformation* 52, 349–360. <https://doi.org/10.1016/j.jag.2016.07.005>
- Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T., Hussin, Y.A., 2014. Generating Pit-free Canopy Height Models from Airborne Lidar. *Photogrammetric Engineering & Remote Sensing* 80, 863–872. <https://doi.org/10.14358/PERS.80.9.863>
- Khosravipour, A., Skidmore, A.K., Wang, T., Isenburg, M., Khoshelham, K., 2015. Effect of slope on treetop detection using a LiDAR Canopy Height Model. *ISPRS Journal of Photogrammetry and Remote Sensing* 104, 44–52. <https://doi.org/10.1016/j.isprsjprs.2015.02.013>
- Kim, H.B., Sohn, G., 2010. 3D Classification of Power-Line Scene from Airborne Laser Scanning Data using Random Forests 7.
- Koch, B., Heyder, U., Weinacker, H., 2006. Detection of Individual Tree Crowns in Airborne Lidar Data. *Photogrammetric Engineering & Remote Sensing* 72, 357–363. <https://doi.org/10.14358/PERS.72.4.357>
- Koch, B., Kattenborn, T., Straub, C., Vauhkonen, J., 2014. Segmentation of Forest to Tree Objects, in: Maltamo, M., Næsset, E., Vauhkonen, J. (Eds.), *Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies, Managing Forest Ecosystems*. Springer Netherlands, Dordrecht, pp. 89–112. [https://doi.org/10.1007/978-94-017-8663-8\\_5](https://doi.org/10.1007/978-94-017-8663-8_5)
- Kovačević, J., 2022. Kartiranje šumske vegetacije na osnovu podataka satelitskog osmatranja Zemlje korišćenjem tehnika mašinskog učenja (doctoralThesis).
- Kraus, K., Pfeifer, N., 1998. Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* 53, 193–203. [https://doi.org/10.1016/S0924-2716\(98\)00009-4](https://doi.org/10.1016/S0924-2716(98)00009-4)
- Krzystek, P., Serebryanyk, A., Schnörr, C., Červenka, J., Heurich, M., 2020. Large-Scale Mapping of Tree Species and Dead Trees in Šumava National Park and Bavarian Forest National Park Using Lidar and Multispectral Imagery. *Remote Sensing* 12, 661. <https://doi.org/10.3390/rs12040661>
- Kuhn, M., 2008. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software* 28, 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., Mayer, Z., Kenkel, B., R Core Team, Benesty, M., Lescarbeau, R., Ziem, A., Scrucca, L., Tang, Y., Candan, C., Hunt, T., 2022. caret: Classification and Regression Training.
- Kuncheva, L.I., Whitaker, C.J., 2003. Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracy. *Machine Learning* 51, 181–207. <https://doi.org/10.1023/A:1022859003006>
- Laefer, D.F., Abuwarda, S., Anh-Vu Vo, Truong-Hong, L., Gharibi, H., 2017. 2015 Aerial Laser and Photogrammetry Datasets for Dublin, Ireland's City Center. <https://doi.org/10.17609/N8MQ0N>



- Landrieu, L., Mallet, C., Weinmann, M., 2017. Comparison of belief propagation and graph-cut approaches for contextual classification of 3D lidar point cloud data, in: 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Presented at the 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), pp. 2768–2771. <https://doi.org/10.1109/IGARSS.2017.8127571>
- Le Saux, B., Yokoya, N., Haensch, R., Brown, M., 2019. 2019 IEEE GRSS Data Fusion Contest: Large-Scale Semantic 3D Reconstruction [Technical Committees]. IEEE Geoscience and Remote Sensing Magazine 7, 33–36. <https://doi.org/10.1109/MGRS.2019.2949679>
- Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., Shreenan, R., 2003. Combined high-density lidar and multispectral imagery for individual tree crown analysis. Canadian Journal of Remote Sensing 29, 633–649. <https://doi.org/10.5589/m03-024>
- LeDell, E., Poirier, S., 2020. H2O AutoML: Scalable Automatic Machine Learning. 7th ICML Workshop on Automated Machine Learning (AutoML).
- Lee, H., Slatton, K.C., Roth, B.E., Cropper, W.P., 2010. Adaptive clustering of airborne LiDAR data to segment individual tree crowns in managed pine forests. International Journal of Remote Sensing 31, 117–139. <https://doi.org/10.1080/01431160902882561>
- Lee, I., Schenk, A., 2002. Perceptual organization of 3D surface points. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 34.
- Li, W., Guo, Q., Jakubowski, M.K., Kelly, M., 2012. A New Method for Segmenting Individual Trees from the Lidar Point Cloud. Photogrammetric Engineering & Remote Sensing 78, 75–84. <https://doi.org/10.14358/PERS.78.1.75>
- Lian, Y., Feng, T., Zhou, J., Jia, M., Li, A., Wu, Z., Jiao, L., Brown, M., Hager, G., Yokoya, N., Hänsch, R., Saux, B.L., 2021. Large-Scale Semantic 3-D Reconstruction: Outcome of the 2019 IEEE GRSS Data Fusion Contest—Part B. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 14, 1158–1170. <https://doi.org/10.1109/JSTARS.2020.3035274>
- Lin, C.-H., Chen, J.-Y., Su, P.-L., Chen, C.-H., 2014. Eigen-feature analysis of weighted covariance matrices for LiDAR point cloud classification. ISPRS Journal of Photogrammetry and Remote Sensing 94, 70–79. <https://doi.org/10.1016/j.isprsjprs.2014.04.016>
- Lindberg, E., Eysn, L., Hollaus, M., Holmgren, J., Pfeifer, N., 2014. Delineation of Tree Crowns and Tree Species Classification From Full-Waveform Airborne Laser Scanning Data Using 3-D Ellipsoidal Clustering. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 7, 3174–3181. <https://doi.org/10.1109/JSTARS.2014.2331276>
- Linsen, L., Prautzsch, H., 2001. Local Versus Global Triangulations. <https://doi.org/10.2312/egs.20011021>

- Lisiewicz, M., Kamińska, A., Kraszewski, B., Stereńczak, K., 2022a. Correcting the Results of CHM-Based Individual Tree Detection Algorithms to Improve Their Accuracy and Reliability. *Remote Sensing* 14, 1822. <https://doi.org/10.3390/rs14081822>
- Lisiewicz, M., Kamińska, A., Stereńczak, K., 2022b. Recognition of specified errors of Individual Tree Detection methods based on Canopy Height Model. *Remote Sensing Applications: Society and Environment* 25, 100690. <https://doi.org/10.1016/j.rsase.2021.100690>
- Liu, J., Skidmore, A.K., Jones, S., Wang, T., Heurich, M., Zhu, X., Shi, Y., 2018. Large off-nadir scan angle of airborne LiDAR can severely affect the estimates of forest structure metrics. *ISPRS Journal of Photogrammetry and Remote Sensing* 136, 13–25. <https://doi.org/10.1016/j.isprsjprs.2017.12.004>
- Liu, T., Im, J., Quackenbush, L.J., 2015. A novel transferable individual tree crown delineation model based on Fishing Net Dragging and boundary classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 110, 34–47. <https://doi.org/10.1016/j.isprsjprs.2015.10.002>
- Lodha, S.K., Fitzpatrick, D.M., Helmbold, D.P., 2007. Aerial Lidar Data Classification using AdaBoost, in: *Sixth International Conference on 3-D Digital Imaging and Modeling (3DIM 2007)*. Presented at the Sixth International Conference on 3-D Digital Imaging and Modeling (3DIM 2007), pp. 435–442. <https://doi.org/10.1109/3DIM.2007.10>
- Lucas, C., Bouten, W., Koma, Z., Kissling, W.D., Seijmonsbergen, A.C., 2019. Identification of Linear Vegetation Elements in a Rural Landscape Using LiDAR Point Clouds. *Remote Sensing* 11, 292. <https://doi.org/10.3390/rs11030292>
- Mallet, C., Soergel, U., Bretar, F., 2008. Analysis of Full-Waveform Lidar Data for Classification of Urban Areas. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVII*, 8.
- Mandlbürger, G., Otepka, J., Karel, W., Wagner, W., Pfeifer, N., 2009. Orientation and Processing of Airborne Laser Scanning Data (OPALS) - Concept and First Results of a Comprehensive ALS Software. *IAPRS XXXVIII*, 6.
- Matikainen, L., Kaartinen, H., 2007. Classification tree based building detection from laser scanner and aerial image data, in: *ISPRS Workshop on Laser Scanning 2007 and SilviLaser 2007*.
- McGaughey, R.J., 2022. FUSION/LDV: Software for LIDAR Data Analysis and Visualization 119.
- Meyer, H., Reudenbach, C., 2019. Unmanned Aerial Vehicle Remote Sensing Tools [R package uavRst version 0.5-2].
- Millard, K., Richardson, M., 2013. Wetland mapping with LiDAR derivatives, SAR polarimetric decompositions, and LiDAR–SAR fusion using a random forest classifier. *Canadian Journal of Remote Sensing* 39, 290–307. <https://doi.org/10.5589/m13-038>
- Mitchell, M., 1996. *An Introduction to Genetic Algorithms, Complex Adaptive Systems*. A Bradford Book, Cambridge, MA, USA.

- Mitra, N.J., Nguyen, A., 2003. Estimating Surface Normals in Noisy Point Cloud Data. *Proceedings of the Annual Symposium on Computational Geometry* 322–328.
- Mongus, D., Žalik, B., 2015. An efficient approach to 3D single tree-crown delineation in LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 108, 219–233. <https://doi.org/10.1016/j.isprsjprs.2015.08.004>
- Munoz, D., Bagnell, J.A., Vandapel, N., Hebert, M., 2009. Contextual classification with functional Max-Margin Markov Networks, in: 2009 IEEE Conference on Computer Vision and Pattern Recognition. Presented at the 2009 IEEE Conference on Computer Vision and Pattern Recognition, pp. 975–982. <https://doi.org/10.1109/CVPR.2009.5206590>
- Niemeyer, J., Rottensteiner, F., Soergel, U., 2014. Contextual classification of lidar data and building object detection in urban areas. *ISPRS Journal of Photogrammetry and Remote Sensing* 87, 152–165. <https://doi.org/10.1016/j.isprsjprs.2013.11.001>
- Niemeyer, J., Rottensteiner, F., Soergel, U., 2012. Conditional Random Fields For Lidar Point Cloud Classification In Complex Urban Areas, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the XXII ISPRS Congress, Technical Commission III (Volume I-3) - 25 August &ndash; 01 September 2012, Melbourne, Australia, Copernicus GmbH, pp. 263–268. <https://doi.org/10.5194/isprsannals-I-3-263-2012>
- Niemeyer, J., Rottensteiner, F., Soergel, U., Heipke, C., 2016. HIERARCHICAL HIGHER ORDER CRF FOR THE CLASSIFICATION OF AIRBORNE LIDAR POINT CLOUDS IN URBAN AREAS. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLI-B3*, 655–662. <https://doi.org/10.5194/isprsarchives-XLI-B3-655-2016>
- Olofsson, P., Foody, G.M., Herold, M., Stehman, S.V., Woodcock, C.E., Wulder, M.A., 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Olsen, L.R., 2022. *groupdata2: Creating Groups from Data*.
- Pauly, M., Keiser, R., Gross, M., 2003. Multi-scale Feature Extraction on Point-Sampled Surfaces. *Computer Graphics Forum* 22, 281–289. <https://doi.org/10.1111/1467-8659.00675>
- Peng, C.-Y.J., Lee, K.L., Ingersoll, G.M., 2002. An Introduction to Logistic Regression Analysis and Reporting. *The Journal of Educational Research* 96, 3–14. <https://doi.org/10.1080/00220670209598786>
- Persson, A., Holmgren, J., Soderman, U., 2002. Detecting and Measuring Individual Trees Using an Airborne Laser Scanner. *Photogrammetric Engineering and Remote Sensing* 68, 925–932.
- Pfeifer, N., Mandlbürger, G., Otepka, J., Karel, W., 2014. OPALS – A framework for Airborne Laser Scanning data analysis. *Computers, Environment and Urban Systems* 45, 125–136. <https://doi.org/10.1016/j.compenvurbsys.2013.11.002>

- Pitkänen, J., Maltamo, M., Hyypä, J., Yu, X., 2004. Adaptive methods for individual tree detection on airborne laser based canopy height model. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36.
- Plaza-Leiva, V., Gomez-Ruiz, J.A., Mandow, A., García-Cerezo, A., 2017. Voxel-Based Neighborhood for Spatial Shape Pattern Classification of Lidar Point Clouds with Supervised Learning. *Sensors* 17, 594. <https://doi.org/10.3390/s17030594>
- Polewski, P., Yao, W., Heurich, M., Krzystek, P., Stilla, U., 2015. Free Shape Context Descriptors Optimized with Genetic Algorithm for the Detection of Dead Tree Trunks in ALS Point Clouds, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the ISPRS Geospatial Week 2015 (Volume II-3/W5) - 28 September&ndash;3 October 2015, La Grande Motte, France, Copernicus GmbH, pp. 41&ndash;48. <https://doi.org/10.5194/isprsannals-II-3-W5-41-2015>
- Popescu, S.C., Wynne, R.H., 2004. Seeing the Trees in the Forest. *Photogrammetric Engineering & Remote Sensing* 70, 589&ndash;604. <https://doi.org/10.14358/PERS.70.5.589>
- Popescu, S.C., Wynne, R.H., Nelson, R.F., 2002. Estimating plot-level tree heights with lidar: local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture* 37, 71&ndash;95. [https://doi.org/10.1016/S0168-1699\(02\)00121-7](https://doi.org/10.1016/S0168-1699(02)00121-7)
- Qi, C.R., Su, H., Mo, K., Guibas, L.J., 2017. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. Presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 652&ndash;660.
- R: The R Project for Statistical Computing [WWW Document], 2022. URL <https://www.r-project.org/> (accessed 6.21.22).
- Reitberger, J., Schnörr, Cl., Krzystek, P., Stilla, U., 2009. 3D segmentation of single trees exploiting full waveform LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 64, 561&ndash;574. <https://doi.org/10.1016/j.isprsjprs.2009.04.002>
- Ripley, B.D., 1996. *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge. <https://doi.org/10.1017/CBO9780511812651>
- Rosin, P.L., 2005. Computing global shape measures, in: *Handbook of Pattern Recognition and Computer Vision*. WORLD SCIENTIFIC, pp. 177&ndash;196. [https://doi.org/10.1142/9789812775320\\_0010](https://doi.org/10.1142/9789812775320_0010)
- Rottensteiner, F., Sohn, G., Jung, J., Gerke, M., Baillard, C., Benitez, S., Breitkopf, U., 2012. THE ISPRS BENCHMARK ON URBAN OBJECT CLASSIFICATION AND 3D BUILDING RECONSTRUCTION, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the XXII ISPRS Congress, Technical Commission III (Volume I-3) - 25 August &ndash; 01 September 2012, Melbourne, Australia, Copernicus GmbH, pp. 293&ndash;298. <https://doi.org/10.5194/isprsannals-I-3-293-2012>
- Rottensteiner, F., Trinder, J., Clode, S., Kubik, K., 2005. Using the Dempster&ndash;Shafer method for the fusion of LIDAR data and multi-spectral images for building

- detection. *Information Fusion, Fusion of Remotely Sensed Data over Urban Areas* 6, 283–300. <https://doi.org/10.1016/j.inffus.2004.06.004>
- Roussel, J.-R., Auty, D., De Boissieu, F., Meador, A.S., Bourdon, J.-F., Demetrios, G., Steinmeier, L., Adaszewski, S., 2022. *lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications*.
- Roussel, J.-R., Caspersen, J., Béland, M., Thomas, S., Achim, A., 2017. Removing bias from LiDAR-based estimates of canopy height: Accounting for the effects of pulse density and footprint size. *Remote Sensing of Environment* 198, 1–16. <https://doi.org/10.1016/j.rse.2017.05.032>
- Rutzinger, M., Höfle, B., Pfeifer, N., 2008. Object detection in airborne laser scanning data - an integrative approach on object-based image and point cloud analysis, in: Blaschke, T., Lang, S., Hay, G.J. (Eds.), *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, Lecture Notes in Geoinformation and Cartography. Springer, Berlin, Heidelberg, pp. 645–662. [https://doi.org/10.1007/978-3-540-77058-9\\_35](https://doi.org/10.1007/978-3-540-77058-9_35)
- Saeys, Y., Inza, I., Larrañaga, P., 2007. A review of feature selection techniques in bioinformatics. *Bioinformatics* 23, 2507–2517. <https://doi.org/10.1093/bioinformatics/btm344>
- Sasaki, Y., 2007. The truth of the F-measure. *Teach Tutor Mater*.
- Schmidhuber, J., 2015. Deep learning in neural networks: An overview. *Neural Networks* 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Schmidt, A., Niemeyer, J., Rottensteiner, F., Soergel, U., 2014. Contextual Classification of Full Waveform Lidar Data in the Wadden Sea. *IEEE Geoscience and Remote Sensing Letters* 11, 1614–1618. <https://doi.org/10.1109/LGRS.2014.2302317>
- Scrucca, L., 2013. GA: A Package for Genetic Algorithms in R. *Journal of Statistical Software* 53, 1–37. <https://doi.org/10.18637/jss.v053.i04>
- Secord, J., Zakhor, A., 2007. Tree Detection in Urban Regions Using Aerial Lidar and Image Data. *IEEE Geoscience and Remote Sensing Letters* 4, 196–200. <https://doi.org/10.1109/LGRS.2006.888107>
- Shannon, C.E., 1948. A Mathematical Theory of Communication. *Bell System Technical Journal* 27, 379–423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shapovalov, R., Velizhev, A., Barinova, O., 2010. Non-associative Markov networks for 3D point cloud classification, *Photogrammetric Computer Vision and Image Analysis*.
- Silva, C.A., Crookston, N.L., Hudak, A.T., Vierling, L.A., Klauberg, C., Cardil, A., (review), C.H. (Maintenance and, 2021. *rLiDAR: LiDAR Data Processing and Visualization*.
- Silva, C.A., Hudak, A.T., Vierling, L.A., Loudermilk, E.L., O'Brien, J.J., Hiers, J.K., Jack, S.B., Gonzalez-Benecke, C., Lee, H., Falkowski, M.J., Khosravipour, A., 2016. Imputation of Individual Longleaf Pine (*Pinus palustris* Mill.) Tree Attributes from Field and LiDAR Data. *Canadian Journal of Remote Sensing* 42, 554–573. <https://doi.org/10.1080/07038992.2016.1196582>

- Siriseriwan, W., 2019. smotefamily: A Collection of Oversampling Techniques for Class Imbalance Problem Based on SMOTE.
- Sivanandham, S., Gunaseelan, D.B., 2022. Development of an Ensembled Meta-Deep Learning Model for Semantic Road-Scene Segmentation in an Unstructured Environment. *Applied Sciences* 12, 12214. <https://doi.org/10.3390/app122312214>
- Solberg, S., Naesset, E., Bollandsas, O.M., 2006. Single Tree Segmentation Using Airborne Laser Scanner Data in a Structurally Heterogeneous Spruce Forest. *Photogrammetric Engineering & Remote Sensing* 72, 1369–1378. <https://doi.org/10.14358/PERS.72.12.1369>
- Steinsiek, M., Polewski, P., Yao, W., Krzystek, P., 2017. Semantische Analyse von ALS- und MLS-Daten in urbanen Gebieten mittels Conditional Random Fields.
- Stereńczak, K., Kraszewski, B., Mielcarek, M., Piasecka, Ż., Lisiewicz, M., Heurich, M., 2020. Mapping individual trees with airborne laser scanning data in an European lowland forest using a self-calibration algorithm. *International Journal of Applied Earth Observation and Geoinformation* 93, 102191. <https://doi.org/10.1016/j.jag.2020.102191>
- Strobl, C., Boulesteix, A.-L., Augustin, T., 2007. Unbiased split selection for classification trees based on the Gini Index. *Computational Statistics & Data Analysis* 52, 483–501. <https://doi.org/10.1016/j.csda.2006.12.030>
- Thome, A.C.G., 2012. SVM Classifiers – Concepts and Applications to Character Recognition, *Advances in Character Recognition*. IntechOpen. <https://doi.org/10.5772/52009>
- Ting, K.M., Witten, I.H., 1999. Issues in Stacked Generalization. *jair* 10, 271–289. <https://doi.org/10.1613/jair.594>
- Tóvári, D., Pfeifer, N., 2012. Segmentation based robust interpolation- A new Approach to laser data filtering. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36.
- Venables, B., Ripley, B., 2002. *Modern Applied Statistics With S*, in: Springer. <https://doi.org/10.1007/b97626>
- Vosselman, G., 2000. Slope based filtering of laser altimetry data. *IAPRS XXXIII*.
- Vosselman, G., Coenen, M., Rottensteiner, F., 2017. Contextual segment-based classification of airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* 128, 354–371. <https://doi.org/10.1016/j.isprsjprs.2017.03.010>
- Wagner, W., Hollaus, M., Briese, C., Ducic, V., 2008. 3D vegetation mapping using small-footprint full-waveform airborne laser scanners. *International Journal of Remote Sensing* 29, 1433–1452. <https://doi.org/10.1080/01431160701736398>
- Wan Mohd Jaafar, W.S., Woodhouse, I.H., Silva, C.A., Omar, H., Abdul Maulud, K.N., Hudak, A.T., Klauberg, C., Cardil, A., Mohan, M., 2018. Improving Individual Tree Crown Delineation and Attributes Estimation of Tropical Forests Using Airborne LiDAR Data. *Forests* 9, 759. <https://doi.org/10.3390/f9120759>

- Wang, X.-H., Zhang, Y.-Z., Xu, M.-M., 2019. A Multi-Threshold Segmentation for Tree-Level Parameter Extraction in a Deciduous Forest Using Small-Footprint Airborne LiDAR Data. *Remote Sensing* 11, 2109. <https://doi.org/10.3390/rs11182109>
- Weinmann, M., Jutzi, B., Hinz, S., Mallet, C., 2015a. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing* 105, 286–304. <https://doi.org/10.1016/j.isprsjprs.2015.01.016>
- Weinmann, M., Jutzi, B., Mallet, C., 2014. Semantic 3D scene interpretation: A framework combining optimal neighborhood size selection with relevant features. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.* II-3, 181–188. <https://doi.org/10.5194/isprsannals-II-3-181-2014>
- Weinmann, M., Jutzi, B., Mallet, C., 2013. Feature relevance assessment for the semantic interpretation of 3D point cloud data, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Presented at the WG V/3, I/2, I/3, III/2, V/2, VII/7, ICWG I/Va </br> ISPRS Workshop Laser Scanning 2013 (Volume II-5/W2) - 11&ndash;13 November 2013, Antalya, Turkey, Copernicus GmbH, pp. 313–318. <https://doi.org/10.5194/isprsannals-II-5-W2-313-2013>
- Weinmann, M., Schmidt, A., Mallet, C., Hinz, S., Rottensteiner, F., Jutzi, B., 2015b. Contextual classification of point cloud data by exploiting individual 3D neighborhoods. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* II-3/W4, 271–278. <https://doi.org/10.5194/isprsannals-II-3-W4-271-2015>
- West, K.F., Webb, B.N., Lersch, J.R., Pothier, S., Triscari, J.M., Iverson, A.E., 2004. Context-driven automated target detection in 3D data, in: *Automatic Target Recognition XIV*. Presented at the Automatic Target Recognition XIV, SPIE, pp. 133–143. <https://doi.org/10.1117/12.542536>
- Wolf (né Straub), B.-M., Heipke, C., 2007. Automatic extraction and delineation of single trees from remote sensing data. *Machine Vision and Applications* 18, 317–330. <https://doi.org/10.1007/s00138-006-0064-9>
- Wolpert, D.H., 1992. Stacked generalization. *Neural Networks* 5, 241–259. [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)
- Woods, M., Lim, K., Treitz, P., 2008. Predicting forest stand variables from LiDAR data in the Great Lakes – St. Lawrence forest of Ontario. *The Forestry Chronicle* 84, 827–839. <https://doi.org/10.5558/tfc84827-6>
- Wright, M.N., Ziegler, A., 2017. ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R. *Journal of Statistical Software* 77, 1–17. <https://doi.org/10.18637/jss.v077.i01>
- Wu, B., Yu, B., Wu, Q., Huang, Y., Chen, Z., Wu, J., 2016. Individual tree crown delineation using localized contour tree method and airborne LiDAR data in coniferous forests. *International Journal of Applied Earth Observation and Geoinformation* 52, 82–94. <https://doi.org/10.1016/j.jag.2016.06.003>

- Wulder, M.A., Coops, N.C., Hudak, A.T., Morsdorf, F., Nelson, R., Newnham, G., Vastaranta, M., 2013. Status and prospects for LiDAR remote sensing of forested ecosystems. *Canadian Journal of Remote Sensing* 39, S1–S5. <https://doi.org/10.5589/m13-051>
- Xie, Y., Tian, J., Zhu, X.X., 2020. Linking Points With Labels in 3D: A Review of Point Cloud Semantic Segmentation. *IEEE Geoscience and Remote Sensing Magazine* 8, 38–59. <https://doi.org/10.1109/MGRS.2019.2937630>
- Yang, B., Dai, W., Dong, Z., Liu, Y., 2016. Automatic Forest Mapping at Individual Tree Levels from Terrestrial Laser Scanning Point Clouds with a Hierarchical Minimum Cut Method. *Remote Sensing* 8, 372. <https://doi.org/10.3390/rs8050372>
- Yang, Z., Jiang, W., Xu, B., Zhu, Q., Jiang, S., Huang, W., 2017. A Convolutional Neural Network-Based 3D Semantic Labeling Method for ALS Point Clouds. *Remote Sensing* 9, 936. <https://doi.org/10.3390/rs9090936>
- Yao, W., Hinz, S., Stilla, U., 2011. Extraction and motion estimation of vehicles in single-pass airborne LiDAR data towards urban traffic analysis. *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 260–271. <https://doi.org/10.1016/j.isprsjprs.2010.10.005>
- Yokoyama, R., 2002. Visualizing Topography by Openness: A New Application of Image Processing to Digital Elevation Models. *PHOTOGRAMMETRIC ENGINEERING*.
- Yousefhusien, M., Kelbe, D.J., Ientilucci, E.J., Salvaggio, C., 2018. A multi-scale fully convolutional network for semantic labeling of 3D point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing, ISPRS Journal of Photogrammetry and Remote Sensing Theme Issue “Point Cloud Processing”* 143, 191–204. <https://doi.org/10.1016/j.isprsjprs.2018.03.018>
- Yu, X., Hyypä, J., Vastaranta, M., Holopainen, M., Viitala, R., 2011. Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 28–37. <https://doi.org/10.1016/j.isprsjprs.2010.08.003>
- Zeybek, M., 2021. Classification of UAV Point Clouds by Random Forest Machine Learning Algorithm. *Turkish Journal of Engineering*. <https://doi.org/10.31127/tuje.669566>
- Zhang, J., Lin, X., Ning, X., 2013. SVM-Based Classification of Segmented Airborne LiDAR Point Clouds in Urban Areas. *Remote Sensing* 5, 3749–3775. <https://doi.org/10.3390/rs5083749>
- Zhang, K., Chen, S.-C., Whitman, D., Shyu, M.-L., Yan, J., Zhang, C., 2003. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing* 41, 872–882. <https://doi.org/10.1109/TGRS.2003.810682>
- Zhao, D., Pang, Y., Li, Z., Sun, G., 2013. Filling invalid values in a lidar-derived canopy height model with morphological crown control. *International Journal of Remote Sensing* 34, 4636–4654. <https://doi.org/10.1080/01431161.2013.779398>



- Zhao, R., Pang, M., Wang, J., 2018. Classifying airborne LiDAR point clouds via deep features learned by a multi-scale convolutional neural network. *International Journal of Geographical Information Science* 32, 960–979. <https://doi.org/10.1080/13658816.2018.1431840>
- Zhen, Z., Quackenbush, L.J., Zhang, L., 2016. Trends in Automatic Individual Tree Crown Detection and Delineation—Evolution of LiDAR Data. *Remote Sensing* 8, 333. <https://doi.org/10.3390/rs8040333>
- Zhu, J., Sui, L., Zang, Y., Zheng, H., Jiang, W., Zhong, M., Ma, F., 2021. Classification of Airborne Laser Scanning Point Cloud Using Point-Based Convolutional Neural Network. *ISPRS International Journal of Geo-Information* 10, 444. <https://doi.org/10.3390/ijgi10070444>
- Zolanvari, I., Ruano, S., Rana, A., Cummins, A., Smolic, A., Da Silva, R., Rahbar, M., 2019. *DublinCity: Annotated LiDAR Point Cloud and its Applications*.

## 9 ПРИЛОЗИ


### Прилог 1: Резултати семантичке сегментације *ISPRS* података

Табела П.1 Мере перформанси модела (осетљивост – *R*, прецизност – *P* и Ф1 скор – *FI*) за изабрану методу семантичке сегментације (*RF*, *SVM*, *ANN* и *XGB*) и комбинацију начина претраге и величине полупречника претраге коришћених класа *ISPRS* скупа података.


Тип и полупречник претраге	Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>D<sub>2</sub>R<sub>1</sub></i>	<i>RF</i>	Ниска вегетација	74.7	74.2	74.4
		Непропусне	86.7	80.2	83.3
		Кровови	83.4	76.6	79.9
		Дрвеће	64.5	86.0	73.7
	<i>SVM</i>	Ниска вегетација	73.4	74.9	74.1
		Непропусне	86.9	89.2	88.0
		Кровови	90.5	80.0	84.9
		Дрвеће	71.0	82.0	76.1
	<i>ANN</i>	Ниска вегетација	74.6	73.6	74.1
		Непропусне	87.2	86.9	87.0
		Кровови	89.1	77.2	82.7
		Дрвеће	64.5	84.4	73.1
	<i>XGB</i>	Ниска вегетација	74.4	74.0	74.2
		Непропусне	88.6	85.9	87.2
		Кровови	88.1	76.9	82.1
		Дрвеће	64.0	85.5	73.2
<i>D<sub>2</sub>R<sub>1.5</sub></i>	<i>RF</i>	Ниска вегетација	77.1	72.8	74.9
		Непропусне	86.8	85.7	86.2
		Кровови	88.4	78.4	83.1
		Дрвеће	63.8	87.2	73.7
	<i>SVM</i>	Ниска вегетација	75.3	73.6	74.4
		Непропусне	87.3	89.5	88.4
		Кровови	89.8	82.5	86.0
		Дрвеће	70.6	82.0	75.9
	<i>ANN</i>	Ниска вегетација	76.3	72.9	74.6
		Непропусне	86.3	89.0	87.6
		Кровови	91.3	79.1	84.8
		Дрвеће	65.2	84.7	73.7
	<i>XGB</i>	Ниска вегетација	77.1	74.2	75.6
		Непропусне	88.4	88.3	88.3
		Кровови	90.3	78.2	83.8
		Дрвеће	64.0	86.6	73.6
<i>D<sub>2</sub>R<sub>2</sub></i>	<i>RF</i>	Ниска вегетација	40.3	81.6	54.0
		Непропусне	89.4	18.7	30.9
		Кровови	91.8	59.7	72.3
		Дрвеће	62.0	87.4	72.5

	<i>SVM</i>	Ниска вегетација	64.7	75.0	69.5
		Непропусне	87.6	88.4	88.0
		Кровови	90.6	65.9	76.3
		Дрвеће	67.0	84.0	74.5
	<i>ANN</i>	Ниска вегетација	67.2	73.4	70.2
		Непропусне	87.8	89.8	88.8
		Кровови	90.9	65.4	76.1
		Дрвеће	63.0	85.8	72.7
	<i>XGB</i>	Ниска вегетација	48.7	82.0	61.1
		Непропусне	94.6	48.2	63.9
		Кровови	91.8	63.0	74.7
		Дрвеће	63.2	86.4	73.0
<i>D<sub>2</sub>R<sub>3</sub></i>	<i>RF</i>	Ниска вегетација	77.8	73.8	75.7
		Непропусне	89.8	88.4	89.1
		Кровови	92.7	77.9	84.7
		Дрвеће	60.0	87.6	71.2
	<i>SVM</i>	Ниска вегетација	74.7	72.8	73.7
		Непропусне	89.7	76.1	82.3
		Кровови	82.7	83.5	83.1
		Дрвеће	64.3	85.1	73.3
	<i>ANN</i>	Ниска вегетација	50.9	79.8	62.2
		Непропусне	90.0	45.7	60.6
		Кровови	90.0	79.8	84.6
		Дрвеће	68.2	78.1	72.8
	<i>XGB</i>	Ниска вегетација	77.3	74.9	76.1
		Непропусне	90.8	88.0	89.4
		Кровови	92.3	78.7	85.0
		Дрвеће	61.3	87.2	72.0
<i>D<sub>3</sub>R<sub>2</sub></i>	<i>RF</i>	Ниска вегетација	72.6	71.8	72.2
		Непропусне	87.8	85.9	86.8
		Кровови	87.0	71.4	78.4
		Дрвеће	60.7	87.0	71.5
	<i>SVM</i>	Ниска вегетација	69.3	72.3	70.8
		Непропусне	87.6	86.7	87.1
		Кровови	87.9	75.9	81.5
		Дрвеће	68.2	83.6	75.1
	<i>ANN</i>	Ниска вегетација	71.4	69.9	70.6
		Непропусне	87.8	87.5	87.6
		Кровови	88.0	73.2	79.9
		Дрвеће	61.6	85.8	71.7
	<i>XGB</i>	Ниска вегетација	72.8	69.8	71.3
		Непропусне	88.9	87.1	88.0
		Кровови	86.2	71.8	78.3
		Дрвеће	59.7	87.4	70.9
<i>D<sub>3</sub>R<sub>3</sub></i>	<i>RF</i>	Ниска вегетација	74.5	70.8	72.6
		Непропусне	87.6	88.6	88.1
		Кровови	89.8	74.6	81.5
		Дрвеће	61.4	87.0	72.0
	<i>SVM</i>	Ниска вегетација	73.0	72.0	72.5


		Непропусне	87.6	87.7	87.6
		Кровови	88.8	79.4	83.8
		Дрвеће	67.3	83.7	74.6
	<i>ANN</i>	Ниска вегетација	75.7	70.2	72.8
		Непропусне	87.3	89.2	88.2
		Кровови	89.6	79.6	84.3
		Дрвеће	64.7	85.4	73.6
	<i>XGB</i>	Ниска вегетација	75.5	70.4	72.9
		Непропусне	88.7	88.2	88.4
		Кровови	88.3	75.8	81.6
		Дрвеће	61.0	86.9	71.7
	<i>MultiScale</i>	<i>RF</i>	Ниска вегетација	78.7	73.2
Непропусне			89.9	88.6	89.2
Кровови			91.2	81.3	86.0
Дрвеће			63.1	87.1	73.2
<i>SVM</i>		Ниска вегетација	78.0	73.6	75.7
		Непропусне	88.6	89.0	88.8
		Кровови	90.8	86.9	88.8
		Дрвеће	70.8	83.8	76.8
<i>XGB</i>		Ниска вегетација	78.9	74.4	76.6
		Непропусне	89.7	89.4	89.5
		Кровови	92.3	80.3	85.9
		Дрвеће	63.0	86.9	73.0




Слика П.1: Резултати семантичке сегментације са свим атрибутима  $D_2R_1$  комбинације са свим коришћеним класификаторима (а–г).



Слика П.2: Резултати семантичке сегментације са свим атрибутима  $D_2R_{1,5}$  комбинације са свим коришћеним класификаторима (а–г).

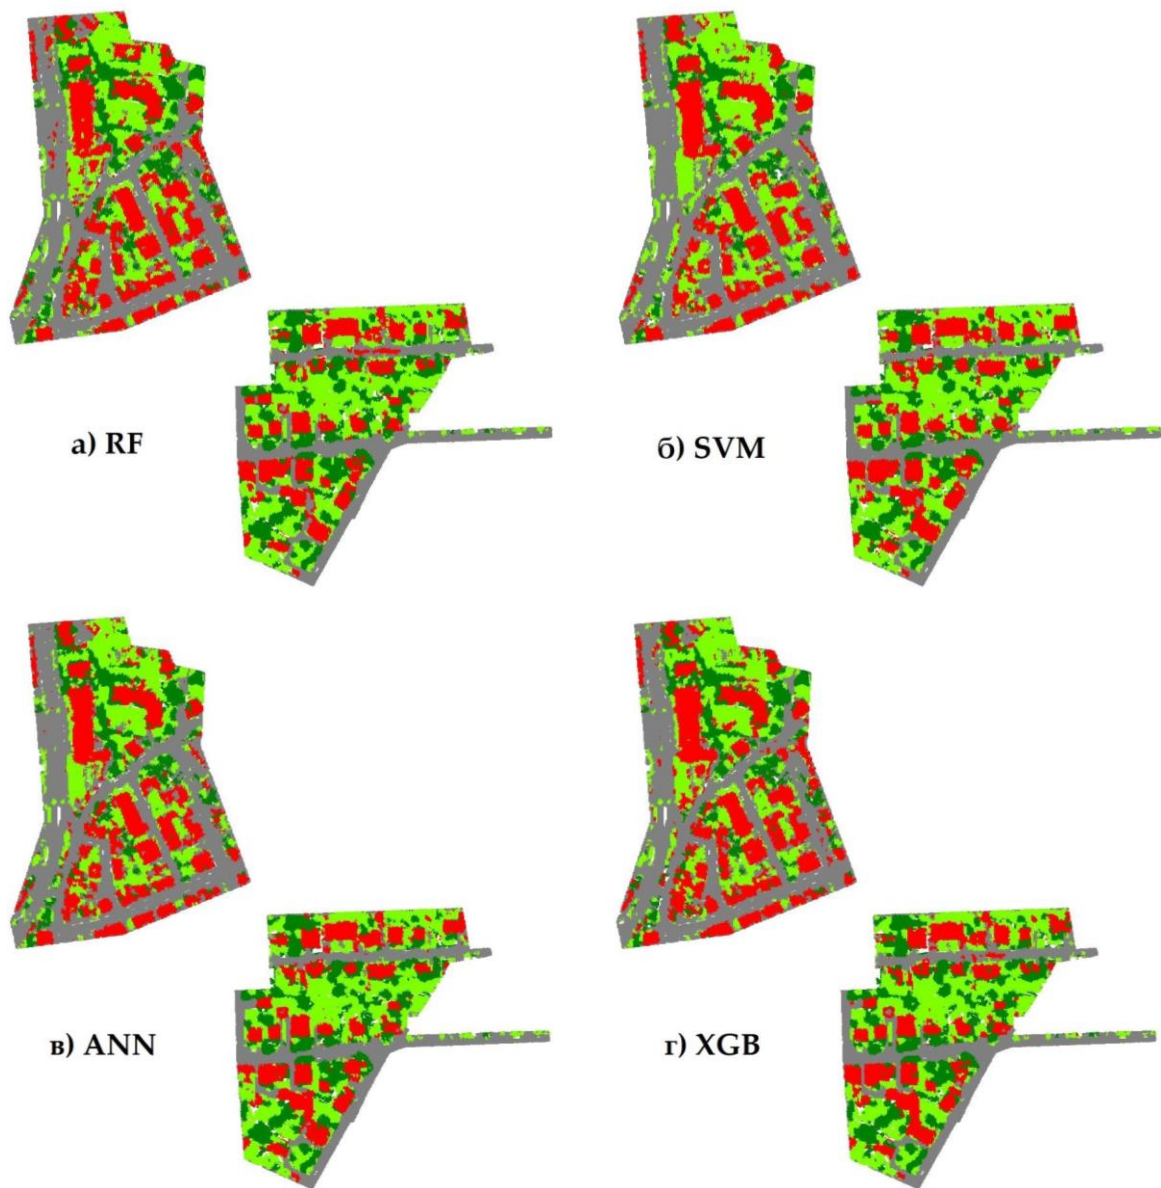


Слика П.3: Резултати семантичке сегментације са свим атрибутима  $D_2R_2$  комбинације са свим коришћеним класификаторима (а–г).




Слика П.4: Резултати семантичке сегментације са свим атрибутима  $D_2R_3$  комбинације са свим коришћеним класификаторима (а–г).






Слика П.5: Резултати семантичке сегментације са свим атрибутима  $D_3R_2$  комбинације са свим коришћеним класификаторима (а–г).



Слика П.6: Резултати семантичке сегментације са свим атрибутима  $D_3R_3$  комбинације са свим коришћеним класификаторима (а–г).



Слика П.7: Резултати семантичке сегментације са свим атрибутима вишеразмерне комбинације са свим коришћеним класификаторима (а–г).

## Прилог 2: Резултати семантичке сегментације *ISPRS* података за $D_2R_{1.5}$ комбинацију атрибута

Табела П.2 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене  $D_2R_{1.5}$  комбинацијом прорачуна атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	76.4	72.8	74.6
	Непропусне	87.3	88.8	88.0
	Кровови	92.2	77.5	84.2
	Дрвеће	63.0	87.3	73.2
<i>SVM</i>	Ниска вегетација	75.0	73.3	74.1
	Непропусне	87.0	89.3	88.1
	Кровови	90.4	82.6	86.3
	Дрвеће	70.8	83.1	76.5
<i>XGB</i>	Ниска вегетација	76.7	74.6	75.6
	Непропусне	88.8	87.9	88.3
	Кровови	90.3	78.4	83.9
	Дрвеће	64.1	86.7	73.7
<i>LR</i>	Ниска вегетација	78.5	69.4	73.7
	Непропусне	84.0	92.0	87.8
	Кровови	90.4	77.2	83.3
	Дрвеће	64.0	84.6	72.9
<i>GB</i>	Ниска вегетација	77.5	74.3	75.9
	Непропусне	87.8	88.4	88.1
	Кровови	91.0	79.8	85.0
	Дрвеће	65.3	86.3	74.3
<i>ENS_RF</i>	Ниска вегетација	77.0	73.8	75.4
	Непропусне	88.0	88.3	88.1
	Кровови	90.6	79.4	84.6
	Дрвеће	65.2	86.6	74.4
<i>ENS_GB</i>	Ниска вегетација	77.2	73.1	75.1
	Непропусне	87.6	88.0	87.8
	Кровови	90.4	80.0	84.9
	Дрвеће	65.0	86.3	74.2
<i>ENS_ANN</i>	Ниска вегетација	76.0	69.5	72.6
	Непропусне	83.2	91.9	87.3
	Кровови	95.3	66.0	78.0
	Дрвеће	55.9	88.0	68.4
<i>ENS_NB</i>	Ниска вегетација	81.3	68.4	74.3
	Непропусне	83.0	92.8	87.6
	Кровови	92.7	78.8	85.2
	Дрвеће	64.6	87.7	74.4
<i>AML</i>	Ниска вегетација	76.4	74.0	75.2
	Непропусне	88.5	85.2	86.8
	Кровови	88.6	81.1	84.7
	Дрвеће	66.3	87.1	75.3

Табела П.3 Мере перформанси модела за све методе семантичке сегментације **ISPRS** балансираних класа скупа података добијене **D<sub>2</sub>R<sub>L5</sub>** комбинацијом прорачуна атрибута.

Класификатор	Класа	R [%]	P [%]	FI [%]
<i>RF</i>	Ниска вегетација	74.5	73.9	74.2
	Непропусне	88.4	88.2	88.3
	Кровови	91.9	76.9	83.7
	Дрвеће	63.0	85.2	72.4
<i>LR</i>	Ниска вегетација	78.5	69.4	73.7
	Непропусне	84.0	92.0	87.8
	Кровови	90.4	77.2	83.3
	Дрвеће	64.0	84.6	72.9
<i>GB</i>	Ниска вегетација	76.9	74.3	75.6
	Непропусне	88.9	87.6	88.2
	Кровови	90.5	78.1	83.8
	Дрвеће	62.3	86.1	72.3
<i>ENS_RF</i>	Ниска вегетација	76.8	73.7	75.2
	Непропусне	88.5	88.3	88.4
	Кровови	90.4	79.6	84.7
	Дрвеће	64.8	86.2	74.0
<i>ENS_GB</i>	Ниска вегетација	77.0	73.4	75.2
	Непропусне	88.3	88.0	88.1
	Кровови	90.3	80.1	84.9
	Дрвеће	65.1	86.5	74.3
<i>ENS_ANN</i>	Ниска вегетација	74.8	75.3	75.0
	Непропусне	87.4	89.4	88.4
	Кровови	92.6	74.8	82.8
	Дрвеће	62.7	85.0	72.2
<i>ENS_NB</i>	Ниска вегетација	82.0	64.7	72.3
	Непропусне	81.7	93.5	87.2
	Кровови	92.7	78.1	84.8
	Дрвеће	62.4	88.3	73.1
<i>AML</i>	Ниска вегетација	73.2	77.8	75.4
	Непропусне	89.7	83.1	86.3
	Кровови	88.4	80.1	84.0
	Дрвеће	67.4	83.1	74.4

Табела П.4 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене *D<sub>2</sub>R<sub>1.5</sub>* комбинацијом рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	76.6	71.9	74.2
	Непропусне	87.2	88.5	87.8
	Кровови	91.3	77.6	83.9
	Дрвеће	62.4	86.9	72.6
<i>SVM</i>	Ниска вегетација	75.2	73.9	74.5
	Непропусне	87.4	88.9	88.1
	Кровови	90.6	82.0	86.1
	Дрвеће	69.2	83.1	75.5
<i>ANN</i>	Ниска вегетација	76.6	73.0	74.8
	Непропусне	87.3	87.7	87.5
	Кровови	90.3	78.0	83.7
	Дрвеће	63.7	86.4	73.3
<i>XGB</i>	Ниска вегетација	76.9	73.8	75.3
	Непропусне	88.4	88.0	88.2
	Кровови	90.3	77.4	83.4
	Дрвеће	62.6	86.7	72.7
<i>LR</i>	Ниска вегетација	77.9	69.0	73.2
	Непропусне	83.1	91.9	87.3
	Кровови	90.2	74.8	81.8
	Дрвеће	61.9	83.7	71.2
<i>GB</i>	Ниска вегетација	77.3	74.8	76.0
	Непропусне	88.2	88.0	88.1
	Кровови	91.3	78.6	84.5
	Дрвеће	63.6	86.2	73.2
<i>ENS_RF</i>	Ниска вегетација	77.0	72.9	74.9
	Непропусне	87.4	88.6	88.0
	Кровови	91.0	79.2	84.7
	Дрвеће	64.3	86.5	73.8
<i>ENS_GB</i>	Ниска вегетација	76.9	72.6	74.7
	Непропусне	87.0	88.2	87.6
	Кровови	90.4	79.7	84.7
	Дрвеће	64.9	85.8	73.9
<i>ENS_ANN</i>	Ниска вегетација	75.9	73.2	74.5
	Непропусне	86.5	87.8	87.1
	Кровови	88.3	83.6	85.9
	Дрвеће	69.3	79.4	74.0
<i>ENS_NB</i>	Ниска вегетација	80.7	67.9	73.7
	Непропусне	82.5	92.6	87.3
	Кровови	92.6	77.7	84.5
	Дрвеће	63.3	87.1	73.3
<i>AML</i>	Ниска вегетација	76.4	73.0	74.7
	Непропусне	86.8	87.8	87.3
	Кровови	90.7	79.9	85.0
	Дрвеће	65.4	85.6	74.1

Табела П.5 Мере перформанси модела за све методе семантичке сегментације **ISPRS** балансираних класа скупа података добијене  $D_2R_{1.5}$  комбинацијом рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	74.5	73.2	73.8
	Непропусне	87.8	87.7	87.7
	Кровови	91.9	77.6	84.1
	Дрвеће	62.9	85.0	72.3
<i>LR</i>	Ниска вегетација	77.9	69.0	73.2
	Непропусне	83.1	91.9	87.3
	Кровови	90.2	74.8	81.8
	Дрвеће	61.9	83.7	71.2
<i>GB</i>	Ниска вегетација	76.6	73.8	75.2
	Непропусне	88.7	87.8	88.2
	Кровови	90.6	77.6	83.6
	Дрвеће	62.1	86.1	72.2
<i>ENS_RF</i>	Ниска вегетација	77.1	72.8	74.9
	Непропусне	87.3	88.5	87.9
	Кровови	90.8	79.3	84.7
	Дрвеће	64.4	86.4	73.8
<i>ENS_GB</i>	Ниска вегетација	76.9	72.6	74.7
	Непропусне	87.0	88.2	87.6
	Кровови	90.4	79.7	84.7
	Дрвеће	64.9	85.8	73.9
<i>ENS_ANN</i>	Ниска вегетација	76.5	69.5	72.8
	Непропусне	89.8	81.5	85.4
	Кровови	85.5	81.2	83.3
	Дрвеће	60.3	87.3	71.3
<i>ENS_NB</i>	Ниска вегетација	80.7	67.9	73.7
	Непропусне	82.5	92.6	87.3
	Кровови	92.6	77.7	84.5
	Дрвеће	63.3	87.1	73.3
<i>AML</i>	Ниска вегетација	76.0	72.4	74.2
	Непропусне	87.3	87.7	87.5
	Кровови	89.9	79.8	84.5
	Дрвеће	65.1	85.6	74.0

### Прилог 3: Резултати семантичке сегментације *ISPRS* података за $D_2R_3$ комбинацију атрибута

Табела П.6 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене  $D_2R_3$  комбинацијом прорачуна атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	78.4	73.2	75.7
	Непропусне	89.6	89.1	89.3
	Кровови	92.3	78.5	84.8
	Дрвеће	60.6	87.5	71.6
<i>SVM</i>	Ниска вегетација	76.6	71.9	74.2
	Непропусне	89.0	78.5	83.4
	Кровови	82.3	86.3	84.3
	Дрвеће	66.7	82.8	73.9
<i>ANN</i>	Ниска вегетација	83.4	63.6	72.2
	Непропусне	86.2	65.5	74.4
	Кровови	67.2	89.5	76.8
	Дрвеће	67.9	81.9	74.2
<i>XGB</i>	Ниска вегетација	77.3	75.1	76.2
	Непропусне	91.0	88.0	89.5
	Кровови	92.4	80.0	85.8
	Дрвеће	62.0	87.1	72.4
<i>LR</i>	Ниска вегетација	80.9	69.8	74.9
	Непропусне	86.5	91.3	88.8
	Кровови	88.6	85.4	87.0
	Дрвеће	66.8	81.1	73.3
<i>GB</i>	Ниска вегетација	78.1	74.4	76.2
	Непропусне	90.5	89.2	89.8
	Кровови	92.4	79.5	85.5
	Дрвеће	61.9	86.8	72.3
<i>ENS_RF</i>	Ниска вегетација	78.2	73.0	75.5
	Непропусне	89.2	89.8	89.5
	Кровови	92.8	78.4	85.0
	Дрвеће	61.2	87.2	71.9
<i>ENS_GB</i>	Ниска вегетација	78.2	70.9	74.4
	Непропусне	87.8	90.1	88.9
	Кровови	92.2	77.9	84.4
	Дрвеће	60.5	87.2	71.4
<i>ENS_ANN</i>	Ниска вегетација	79.0	65.8	71.8
	Непропусне	87.0	90.0	88.5
	Кровови	92.8	77.6	84.5
	Дрвеће	56.8	89.9	69.6
<i>ENS_NB</i>	Ниска вегетација	82.0	69.7	75.4
	Непропусне	86.3	92.5	89.3
	Кровови	93.6	81.7	87.2
	Дрвеће	63.2	87.5	73.4
<i>AML</i>	Ниска вегетација	75.2	72.7	73.9



	Непропусне	90.8	86.2	88.4
	Кровови	91.4	79.3	84.9
	Дрвеће	61.3	88.0	72.3

Табела П.7 Мере перформанси модела за све методе семантичке сегментације **ISPRS** балансираних класа скупа података добијене  $D_2R_3$  комбинацијом прорачуна атрибута.

Класификатор	Класа	$R$ [%]	$P$ [%]	$FI$ [%]
<i>RF</i>	Ниска вегетација	76.2	74.4	75.3
	Непропусне	91.2	87.8	89.5
	Кровови	91.0	78.6	84.3
	Дрвеће	60.6	84.4	70.5
<i>LR</i>	Ниска вегетација	80.9	69.8	74.9
	Непропусне	86.5	91.3	88.8
	Кровови	88.6	85.4	87.0
	Дрвеће	66.8	81.1	73.3
<i>GB</i>	Ниска вегетација	79.3	72.6	75.8
	Непропусне	89.9	90.3	90.1
	Кровови	91.4	79.0	84.7
	Дрвеће	61.1	87.1	71.8
<i>ENS_RF</i>	Ниска вегетација	78.0	73.7	75.8
	Непропусне	89.9	89.7	89.8
	Кровови	92.0	79.0	85.0
	Дрвеће	61.9	86.4	72.1
<i>ENS_GB</i>	Ниска вегетација	77.9	72.8	75.3
	Непропусне	89.3	89.5	89.4
	Кровови	91.8	77.8	84.2
	Дрвеће	60.4	86.3	71.1
<i>ENS_ANN</i>	Ниска вегетација	74.6	72.4	73.5
	Непропусне	90.0	86.9	88.4
	Кровови	93.2	77.4	84.6
	Дрвеће	59.7	87.3	70.9
<i>ENS_NB</i>	Ниска вегетација	82.5	65.5	73.0
	Непропусне	83.1	93.8	88.1
	Кровови	93.1	80.9	86.6
	Дрвеће	62.8	86.9	72.9
<i>AML</i>	Ниска вегетација	78.0	70.6	74.1
	Непропусне	87.3	89.2	88.2
	Кровови	91.0	77.6	83.8
	Дрвеће	59.7	85.8	70.4

Табела П.8 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене *D<sub>2</sub>R<sub>3</sub>* комбинацијом рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	79.3	72.1	75.5
	Непропусне	89.4	89.9	89.6
	Кровови	92.2	79.2	85.2
	Дрвеће	60.6	87.8	71.7
<i>SVM</i>	Ниска вегетација	77.7	73.0	75.3
	Непропусне	89.4	88.3	88.8
	Кровови	88.8	85.3	87.0
	Дрвеће	67.4	82.0	74.0
<i>ANN</i>	Ниска вегетација	79.3	72.0	75.5
	Непропусне	87.9	90.5	89.2
	Кровови	91.6	81.4	86.2
	Дрвеће	63.6	85.3	72.9
<i>XGB</i>	Ниска вегетација	78.9	74.1	76.4
	Непропусне	90.0	90.0	90.0
	Кровови	92.1	79.1	85.1
	Дрвеће	61.6	86.8	72.1
<i>LR</i>	Ниска вегетација	80.5	68.1	73.8
	Непропусне	85.8	91.8	88.7
	Кровови	90.0	78.4	83.8
	Дрвеће	60.0	84.4	70.1
<i>GB</i>	Ниска вегетација	78.5	74.2	76.3
	Непропусне	90.1	90.0	90.0
	Кровови	92.3	79.9	85.7
	Дрвеће	62.3	86.7	72.5
<i>ENS_RF</i>	Ниска вегетација	78.8	72.6	75.6
	Непропусне	89.3	89.9	89.6
	Кровови	91.7	79.8	85.3
	Дрвеће	62.2	87.2	72.6
<i>ENS_GB</i>	Ниска вегетација	78.6	71.3	74.8
	Непропусне	88.0	89.8	88.9
	Кровови	91.2	80.7	85.6
	Дрвеће	62.6	85.6	72.3
<i>ENS_ANN</i>	Ниска вегетација	76.2	74.2	75.2
	Непропусне	91.7	86.5	89.0
	Кровови	89.9	82.7	86.1
	Дрвеће	63.8	84.5	72.7
<i>ENS_NB</i>	Ниска вегетација	82.5	67.6	74.3
	Непропусне	84.7	93.2	88.7
	Кровови	93.4	80.1	86.2
	Дрвеће	61.9	87.3	72.4
<i>AML</i>	Ниска вегетација	77.1	72.4	74.7
	Непропусне	89.6	88.4	89.0
	Кровови	90.8	82.7	86.6
	Дрвеће	64.2	85.3	73.3

Табела П.9 Мере перформанси модела за све методе семантичке сегментације *ISPRS* балансираног скупа података добијене  $D_2R_3$  комбинацијом рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	77.0	73.4	75.2
	Непропусне	90.0	88.6	89.3
	Кровови	90.7	80.3	85.2
	Дрвеће	62.0	83.8	71.3
<i>LR</i>	Ниска вегетација	80.5	68.1	73.8
	Непропусне	85.8	91.8	88.7
	Кровови	90.0	78.4	83.8
	Дрвеће	60.0	84.4	70.1
<i>GB</i>	Ниска вегетација	79.5	73.1	76.2
	Непропусне	90.0	90.1	90.0
	Кровови	91.5	79.2	84.9
	Дрвеће	61.2	87.0	71.9
<i>ENS_RF</i>	Ниска вегетација	78.8	72.6	75.6
	Непропусне	89.3	89.9	89.6
	Кровови	91.7	79.8	85.3
	Дрвеће	62.1	87.2	72.5
<i>ENS_GB</i>	Ниска вегетација	78.6	71.3	74.8
	Непропусне	88.0	89.8	88.9
	Кровови	91.1	80.7	85.6
	Дрвеће	62.6	85.6	72.3
<i>ENS_ANN</i>	Ниска вегетација	75.9	76.0	75.9
	Непропусне	90.0	87.7	88.8
	Кровови	89.6	82.8	86.1
	Дрвеће	65.9	80.0	72.3
<i>ENS_NB</i>	Ниска вегетација	82.5	67.6	74.3
	Непропусне	84.7	93.2	88.7
	Кровови	93.4	80.1	86.2
	Дрвеће	61.9	87.3	72.4
<i>AML</i>	Ниска вегетација	77.8	73.3	75.5
	Непропусне	90.6	88.8	89.7
	Кровови	89.0	83.9	86.4
	Дрвеће	65.7	83.2	73.4

## Прилог 4: Резултати семантичке сегментације *ISPRS* података за вишеразмерну комбинацију атрибута

Табела П.10 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене вишеразмерном комбинацијом прорачуна атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	78.7	73.2	75.9
	Непропусне	89.9	88.6	89.2
	Кровови	91.1	81.3	85.9
	Дрвеће	63.1	87.1	73.2
<i>SVM</i>	Ниска вегетација	78.0	73.6	75.7
	Непропусне	88.6	89.0	88.8
	Кровови	90.8	86.9	88.8
	Дрвеће	70.8	83.8	76.8
<i>ANN</i>	Ниска вегетација	78.6	71.4	74.8
	Непропусне	88.0	89.6	88.8
	Кровови	89.8	84.0	86.8
	Дрвеће	66.0	83.3	73.6
<i>XGB</i>	Ниска вегетација	78.9	74.4	76.6
	Непропусне	89.7	89.4	89.5
	Кровови	92.3	80.3	85.9
	Дрвеће	63.0	86.9	73.0
<i>LR</i>	Ниска вегетација	81.3	69.9	75.2
	Непропусне	86.7	91.8	89.2
	Кровови	90.7	83.0	86.7
	Дрвеће	65.4	85.5	74.1
<i>GB</i>	Ниска вегетација	79.4	74.5	76.9
	Непропусне	89.8	90.1	89.9
	Кровови	92.7	81.0	86.5
	Дрвеће	63.9	87.5	73.9
<i>ENS_RF</i>	Ниска вегетација	79.4	72.3	75.7
	Непропусне	88.7	89.9	89.3
	Кровови	91.7	83.0	87.1
	Дрвеће	65.6	87.6	75.0
<i>ENS_GB</i>	Ниска вегетација	79.0	72.1	75.4
	Непропусне	87.7	89.3	88.5
	Кровови	90.8	83.6	87.1
	Дрвеће	66.3	85.3	74.6
<i>ENS_ANN</i>	Ниска вегетација	77.6	73.4	75.4
	Непропусне	88.1	89.5	88.8
	Кровови	88.9	86.7	87.8
	Дрвеће	71.7	80.5	75.8
<i>ENS_NB</i>	Ниска вегетација	83.2	66.9	74.2
	Непропусне	84.4	93.5	88.7
	Кровови	92.9	82.5	87.4
	Дрвеће	64.8	88.4	74.8
<i>AML</i>	Ниска вегетација	77.9	71.8	74.7

	Непропусне	89.2	88.3	88.7
	Кровови	90.9	82.5	86.5
	Дрвеће	64.6	87.5	74.3

Табела П.11 Мере перформанси модела за све методе семантичке сегментације **ISPRS** балансираног скупа података добијене **вишеразмерном** комбинацијом прорачуна атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	76.0	73.2	74.6
	Непропусне	90.5	87.0	88.7
	Кровови	90.5	81.8	85.9
	Дрвеће	63.2	84.6	72.4
<i>LR</i>	Ниска вегетација	81.3	69.9	75.2
	Непропусне	86.7	91.8	89.2
	Кровови	90.7	83.0	86.7
	Дрвеће	65.4	85.5	74.1
<i>GB</i>	Ниска вегетација	79.1	73.6	76.3
	Непропусне	89.8	90.1	89.9
	Кровови	91.9	80.1	85.6
	Дрвеће	62.9	87.6	73.2
<i>ENS_RF</i>	Ниска вегетација	79.0	71.1	74.8
	Непропусне	88.3	89.6	88.9
	Кровови	90.8	82.5	86.5
	Дрвеће	64.6	86.9	74.1
<i>ENS_GB</i>	Ниска вегетација	79.0	71.0	74.8
	Непропусне	88.3	89.5	88.9
	Кровови	90.0	83.6	86.7
	Дрвеће	65.8	86.0	74.6
<i>ENS_ANN</i>	Ниска вегетација	81.3	66.2	73.0
	Непропусне	83.7	92.4	87.8
	Кровови	87.4	86.8	87.1
	Дрвеће	70.2	80.4	75.0
<i>ENS_NB</i>	Ниска вегетација	83.2	64.8	72.9
	Непропусне	83.4	93.6	88.2
	Кровови	92.5	82.0	86.9
	Дрвеће	63.2	88.0	73.6
<i>AML</i>	Ниска вегетација	78.7	72.2	75.3
	Непропусне	89.6	88.8	89.2
	Кровови	90.0	83.6	86.7
	Дрвеће	65.0	85.6	73.9

Табела П. 12 Мере перформанси модела за све моделе семантичке сегментације *ISPRS* скупа података добијене вишеразмерном комбинацијом прорачуна рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	78.7	73.7	76.1
	Непропусне	89.6	88.9	89.2
	Кровови	91.7	80.9	86.0
	Дрвеће	63.2	87.1	73.2
<i>SVM</i>	Ниска вегетација	77.4	72.8	75.0
	Непропусне	89.1	88.8	88.9
	Кровови	89.7	85.6	87.6
	Дрвеће	68.6	83.0	75.1
<i>XGB</i>	Ниска вегетација	78.9	74.7	76.7
	Непропусне	89.9	89.4	89.6
	Кровови	92.2	79.8	85.6
	Дрвеће	62.6	86.7	72.7
<i>LR</i>	Ниска вегетација	80.6	68.7	74.2
	Непропусне	85.9	92.0	88.8
	Кровови	90.6	80.8	85.4
	Дрвеће	62.7	85.0	72.2
<i>GB</i>	Ниска вегетација	78.8	74.4	76.5
	Непропусне	90.0	89.7	89.8
	Кровови	92.2	80.4	85.9
	Дрвеће	63.2	87.0	73.2
<i>ENS_RF</i>	Ниска вегетација	78.2	72.6	75.3
	Непропусне	89.5	89.3	89.4
	Кровови	91.7	81.6	86.4
	Дрвеће	63.7	87.0	73.5
<i>ENS_GB</i>	Ниска вегетација	77.9	72.1	74.9
	Непропусне	88.8	88.8	88.8
	Кровови	90.9	82.0	86.2
	Дрвеће	63.9	85.8	73.2
<i>ENS_ANN</i>	Ниска вегетација	79.7	71.7	75.5
	Непропусне	88.2	90.5	89.3
	Кровови	89.0	84.9	86.9
	Дрвеће	67.2	82.7	74.1
<i>ENS_NB</i>	Ниска вегетација	82.5	67.8	74.4
	Непропусне	84.8	93.3	88.8
	Кровови	93.2	81.4	86.9
	Дрвеће	63.6	87.6	73.7
<i>AML</i>	Ниска вегетација	76.6	72.4	74.4
	Непропусне	89.5	87.2	88.3
	Кровови	90.2	82.5	86.2
	Дрвеће	64.3	86.0	73.6

Табела П.13 Мере перформанси модела за све методе семантичке сегментације **ISPRS** балансираног скупа података добијене вишеразмерном комбинацијом прорачуна рекурзивне елиминације атрибута.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	76.9	73.6	75.2
	Непропусне	90.5	87.9	89.2
	Кровови	90.7	80.9	85.5
	Дрвеће	62.5	84.7	71.9
<i>LR</i>	Ниска вегетација	80.6	68.7	74.2
	Непропусне	85.9	92.0	88.8
	Кровови	90.6	80.8	85.4
	Дрвеће	62.7	85.0	72.2
<i>GB</i>	Ниска вегетација	79.0	74.5	76.7
	Непропусне	90.5	89.4	89.9
	Кровови	91.2	79.7	85.1
	Дрвеће	61.8	86.0	71.9
<i>ENS_RF</i>	Ниска вегетација	78.6	72.5	75.4
	Непропусне	88.8	89.5	89.1
	Кровови	90.9	80.8	85.6
	Дрвеће	63.4	86.1	73.0
<i>ENS_GB</i>	Ниска вегетација	78.6	71.5	74.9
	Непропусне	88.1	89.5	88.8
	Кровови	90.5	81.6	85.8
	Дрвеће	63.6	85.0	72.8
<i>ENS_ANN</i>	Ниска вегетација	79.1	69.5	74.0
	Непропусне	84.1	92.4	88.1
	Кровови	91.9	81.5	86.4
	Дрвеће	66.6	84.1	74.3
<i>ENS_NB</i>	Ниска вегетација	81.7	69.2	74.9
	Непропусне	85.6	93.1	89.2
	Кровови	93.4	79.8	86.1
	Дрвеће	62.3	87.1	72.6
<i>AML</i>	Ниска вегетација	78.9	68.6	73.4
	Непропусне	86.8	90.8	88.8
	Кровови	90.1	81.8	85.7
	Дрвеће	63.7	85.4	73.0

Табела П.14 Мере перформанси за све моделе семантичке сегментације *ISPRS* скупа података добијене вишеразмерном комбинацијом прорачуна атрибута са узоркованим тренинг подацима.


Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	79.1	73.3	76.1
	Непропусне	89.6	89.2	89.4
	Кровови	91.6	80.8	85.9
	Дрвеће	62.8	87.2	73.0
<i>SVM</i>	Ниска вегетација	77.7	73.2	75.4
	Непропусне	89.0	89.1	89.0
	Кровови	90.0	85.6	87.7
	Дрвеће	68.9	83.2	75.4
<i>XGB</i>	Ниска вегетација	78.9	73.8	76.3
	Непропусне	90.0	89.2	89.6
	Кровови	91.7	80.2	85.6
	Дрвеће	62.5	86.7	72.6
<i>LR</i>	Ниска вегетација	80.6	68.7	74.2
	Непропусне	85.8	92.0	88.8
	Кровови	90.5	80.9	85.4
	Дрвеће	63.2	84.9	72.5
<i>GB</i>	Ниска вегетација	78.8	74.6	76.6
	Непропусне	90.1	89.6	89.8
	Кровови	92.2	81.2	86.4
	Дрвеће	63.6	86.4	73.3
<i>ENS_RF</i>	Ниска вегетација	78.6	72.4	75.4
	Непропусне	89.1	89.7	89.4
	Кровови	91.3	81.6	86.2
	Дрвеће	63.7	86.3	73.3
<i>ENS_GB</i>	Ниска вегетација	78.9	72.2	75.4
	Непропусне	89.1	89.9	89.5
	Кровови	90.8	82.9	86.7
	Дрвеће	64.8	85.4	73.7
<i>ENS_NB</i>	Ниска вегетација	82.6	66.3	73.6
	Непропусне	83.6	93.6	88.3
	Кровови	93.2	81.6	87.0
	Дрвеће	64.0	87.7	74.0
<i>AML</i>	Ниска вегетација	76.5	75.0	75.7
	Непропусне	90.4	88.1	89.2
	Кровови	91.5	81.4	86.2
	Дрвеће	64.2	84.5	73.0



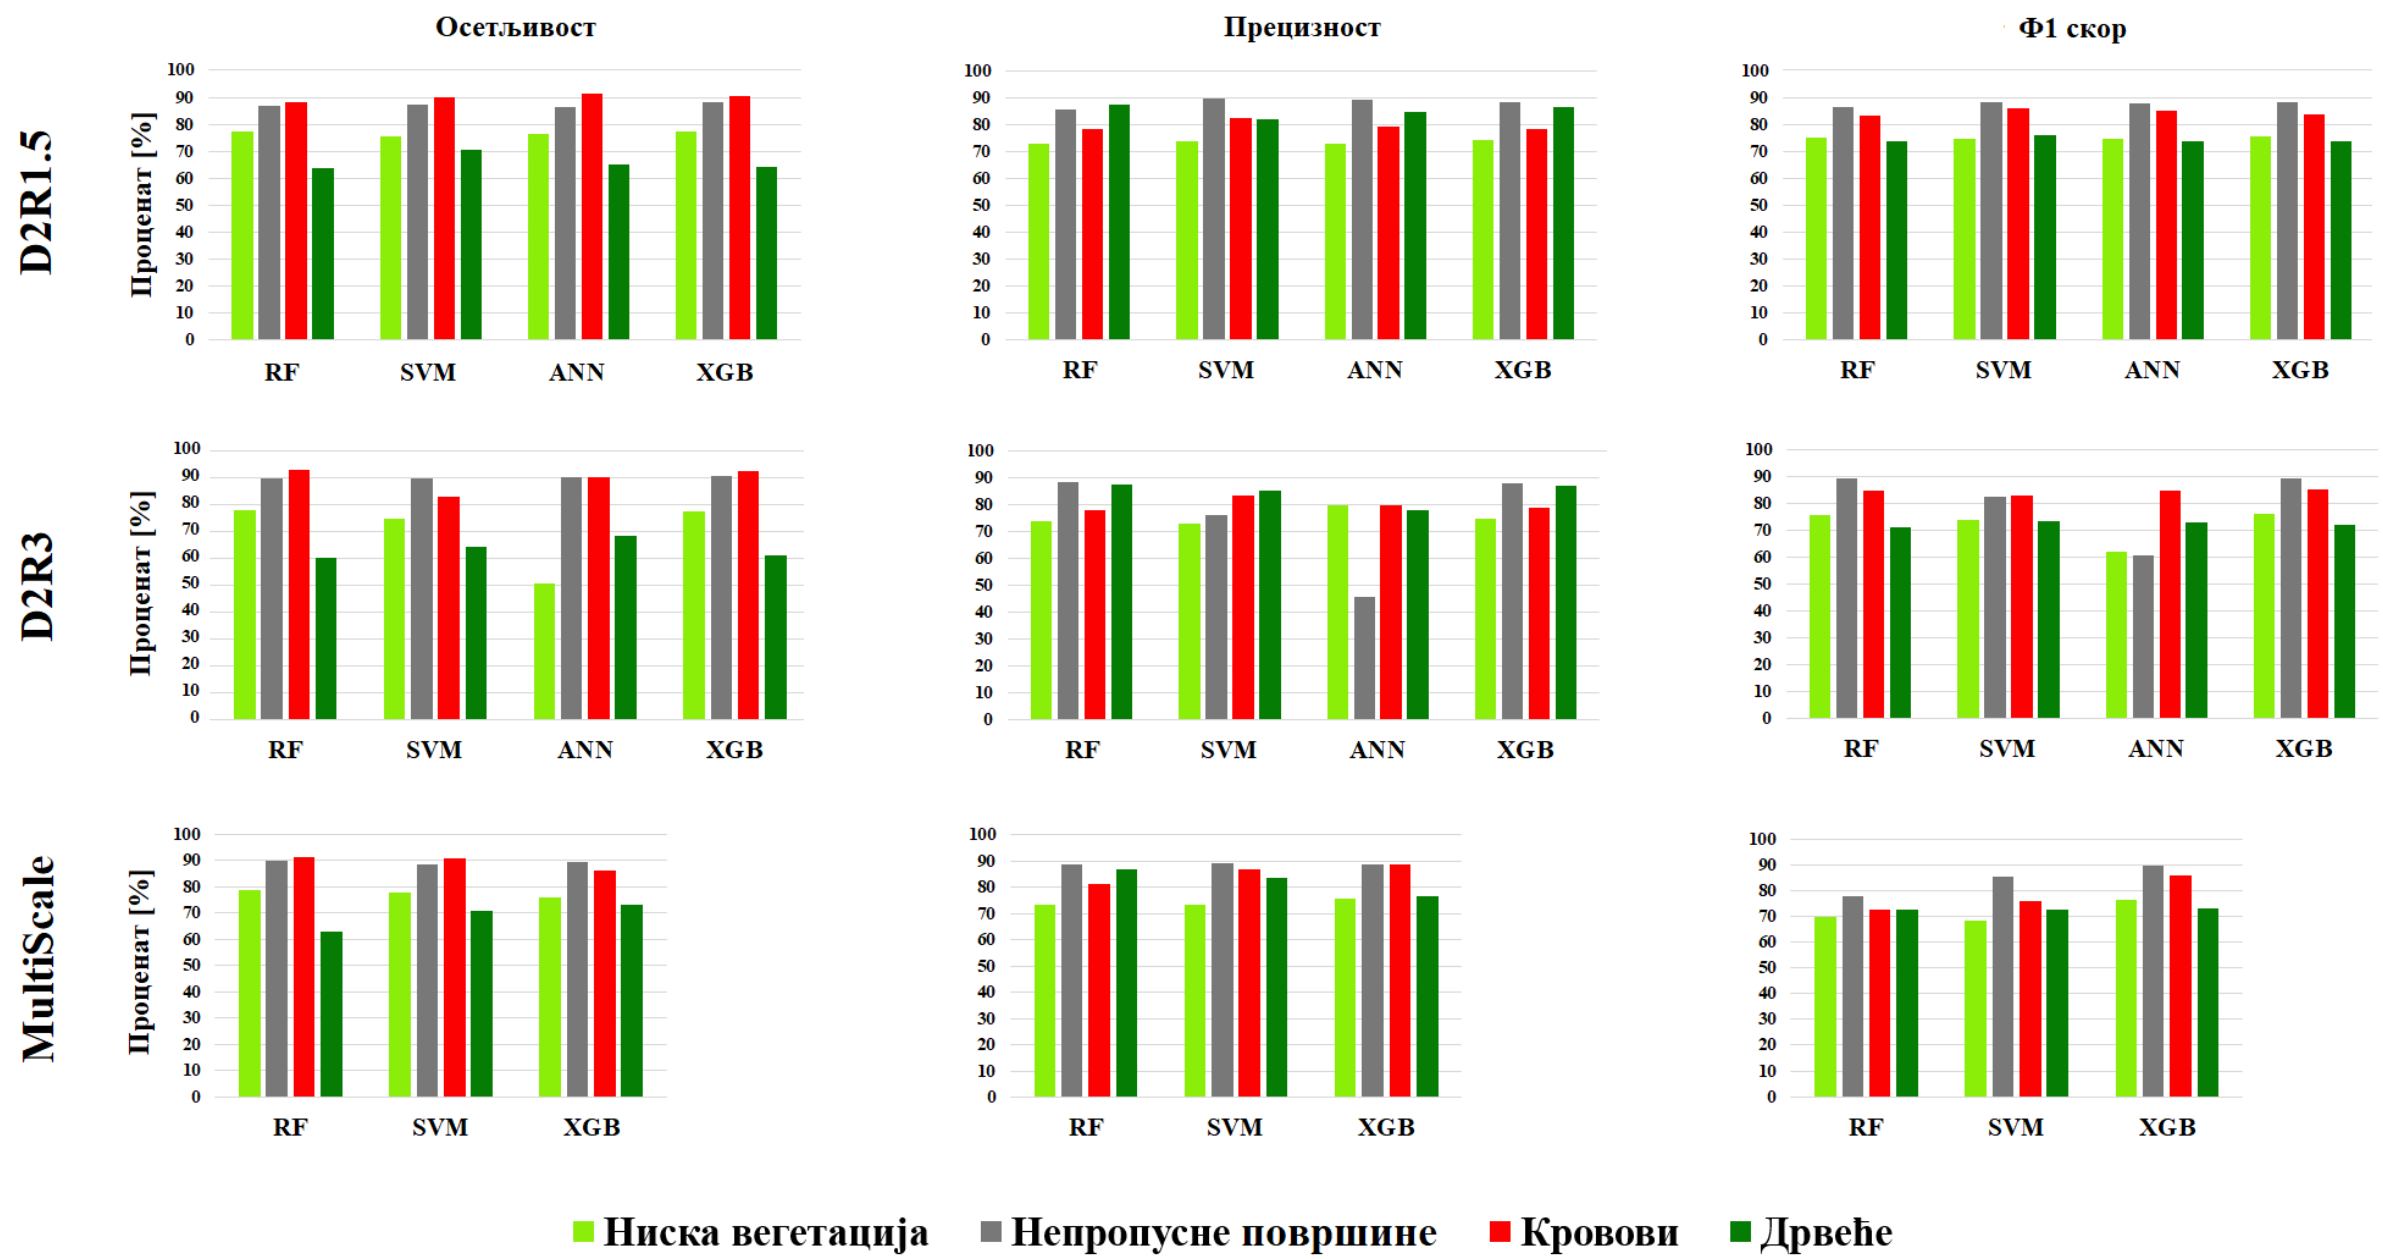
Табела П.15 Мере перформанси модела за све методе семантичке сегментације *ISPRS* скупа података добијене вишеразмерном комбинацијом прорачуна рекурзивне елиминације атрибута са узоркованим тренинг подацима.

Класификатор	Класа	<i>R</i> [%]	<i>P</i> [%]	<i>FI</i> [%]
<i>RF</i>	Ниска вегетација	76.4	73.8	75.1
	Непропусне	90.3	87.8	89.0
	Кровови	90.3	81.4	85.6
	Дрвеће	63.2	83.2	71.8
<i>LR</i>	Ниска вегетација	80.6	68.7	74.2
	Непропусне	85.8	92.0	88.8
	Кровови	90.5	80.9	85.4
	Дрвеће	63.2	84.9	72.5
<i>GB</i>	Ниска вегетација	78.6	73.0	75.7
	Непропусне	89.7	89.7	89.7
	Кровови	91.1	79.5	84.9
	Дрвеће	61.7	85.9	71.8
<i>ENS_RF</i>	Ниска вегетација	78.4	72.2	75.2
	Непропусне	88.7	89.6	89.1
	Кровови	90.9	81.5	85.9
	Дрвеће	64.0	85.9	73.4
<i>ENS_GB</i>	Ниска вегетација	78.4	72.1	75.1
	Непропусне	88.8	89.4	89.1
	Кровови	90.3	82.5	86.2
	Дрвеће	64.7	85.0	73.5
<i>ENS_NB</i>	Ниска вегетација	81.1	67.6	73.7
	Непропусне	83.8	93.7	88.5
	Кровови	93.8	79.7	86.2
	Дрвеће	62.9	86.3	72.8
<i>AML</i>	Ниска вегетација	78.9	71.7	75.1
	Непропусне	89.6	89.5	89.5
	Кровови	90.4	83.8	87.0
	Дрвеће	64.3	85.2	73.3

Прилог 5: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $\Phi 1$  скорa ( $F1$ ) за све комбинације атрибута по класама за *ISPRS* податке




Слика П.8: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $\Phi 1$  скорa ( $F1$ ) за комбинације  $D_2R_1$ ,  $D_2R_2$ ,  $D_3R_2$  и  $D_3R_3$






Слика П.9: Графици осетљивости (R), прецизности (P), и Ф1 скор (F1) за комбинације  $D_2R_{1.5}$ ,  $D_2R_3$  и вишеразмерна (MultiScale)

Прилог 6: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скора ( $F1$ ) за  $D_2R_{1.5}$ ,  $D_2R_3$  и вишеразмерну комбинацију кад су коришћени сви атрибути и рекурзивна елиминација атрибута, са и без балансирања  $ISPRS$  података према класама






Слика П.10: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скора ( $F1$ ) за  $D_2R_{1.5}$  комбинацију са свим класификаторима




Сви атрибуты






Сви атрибуты  
балансиране класе



Рекурзивна  
селекција






Рекурзивна селекција  
балансиране класе





■ Ниска вегетација   ■ Непропусне површине   ■ Кровови   ■ Дрвеће

Слика П.11: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скорa ( $F1$ ) за  $D_2R_3$  комбинацију са свим класификаторима




Сви атрибути






Сви атрибути  
балансиране класе



Рекурзивна  
селекција



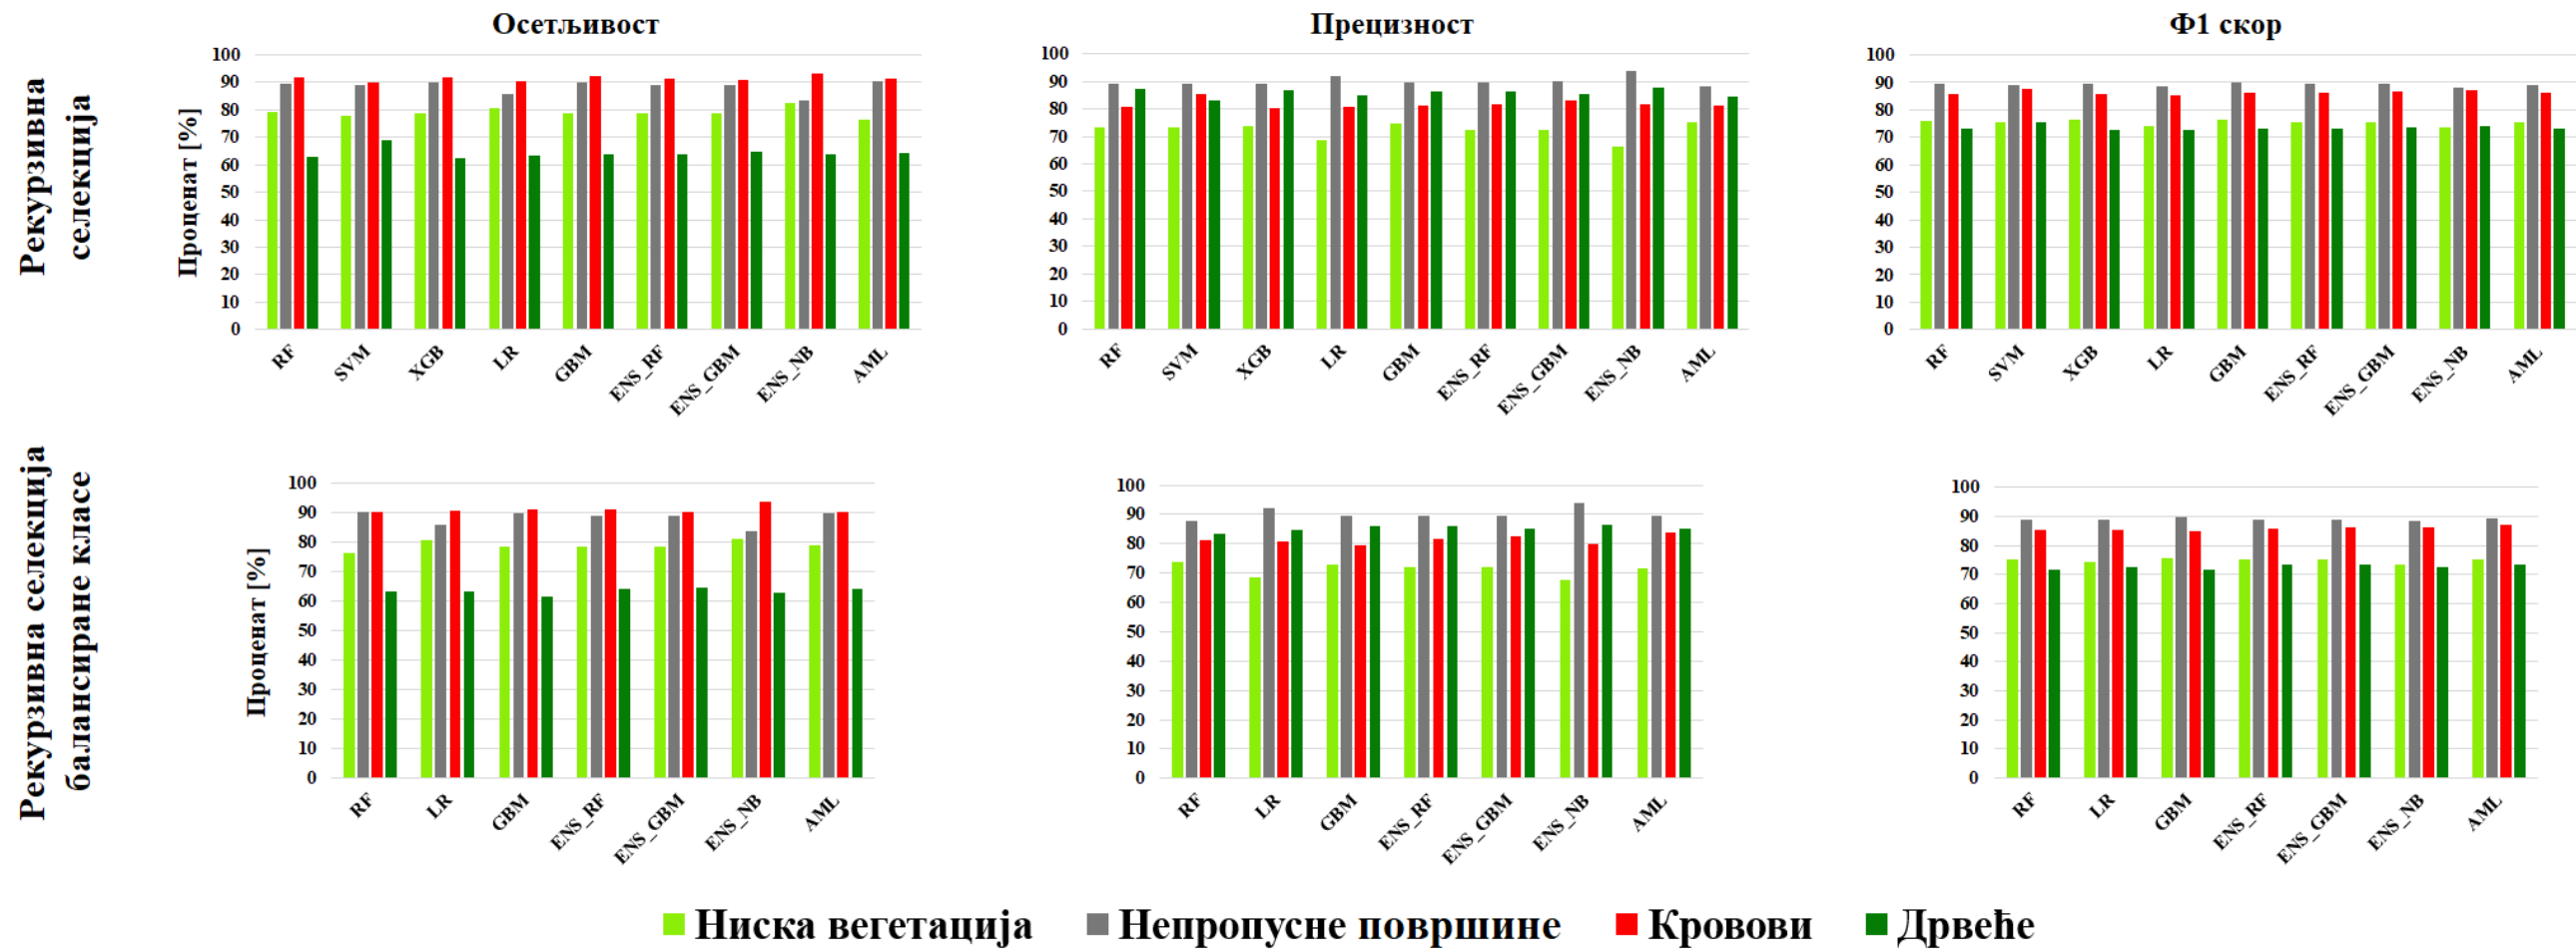
Рекурзивна селекција  
балансиране класе



■ Ниска вегетација ■ Непропусне површине ■ Кровови ■ Дрвеће

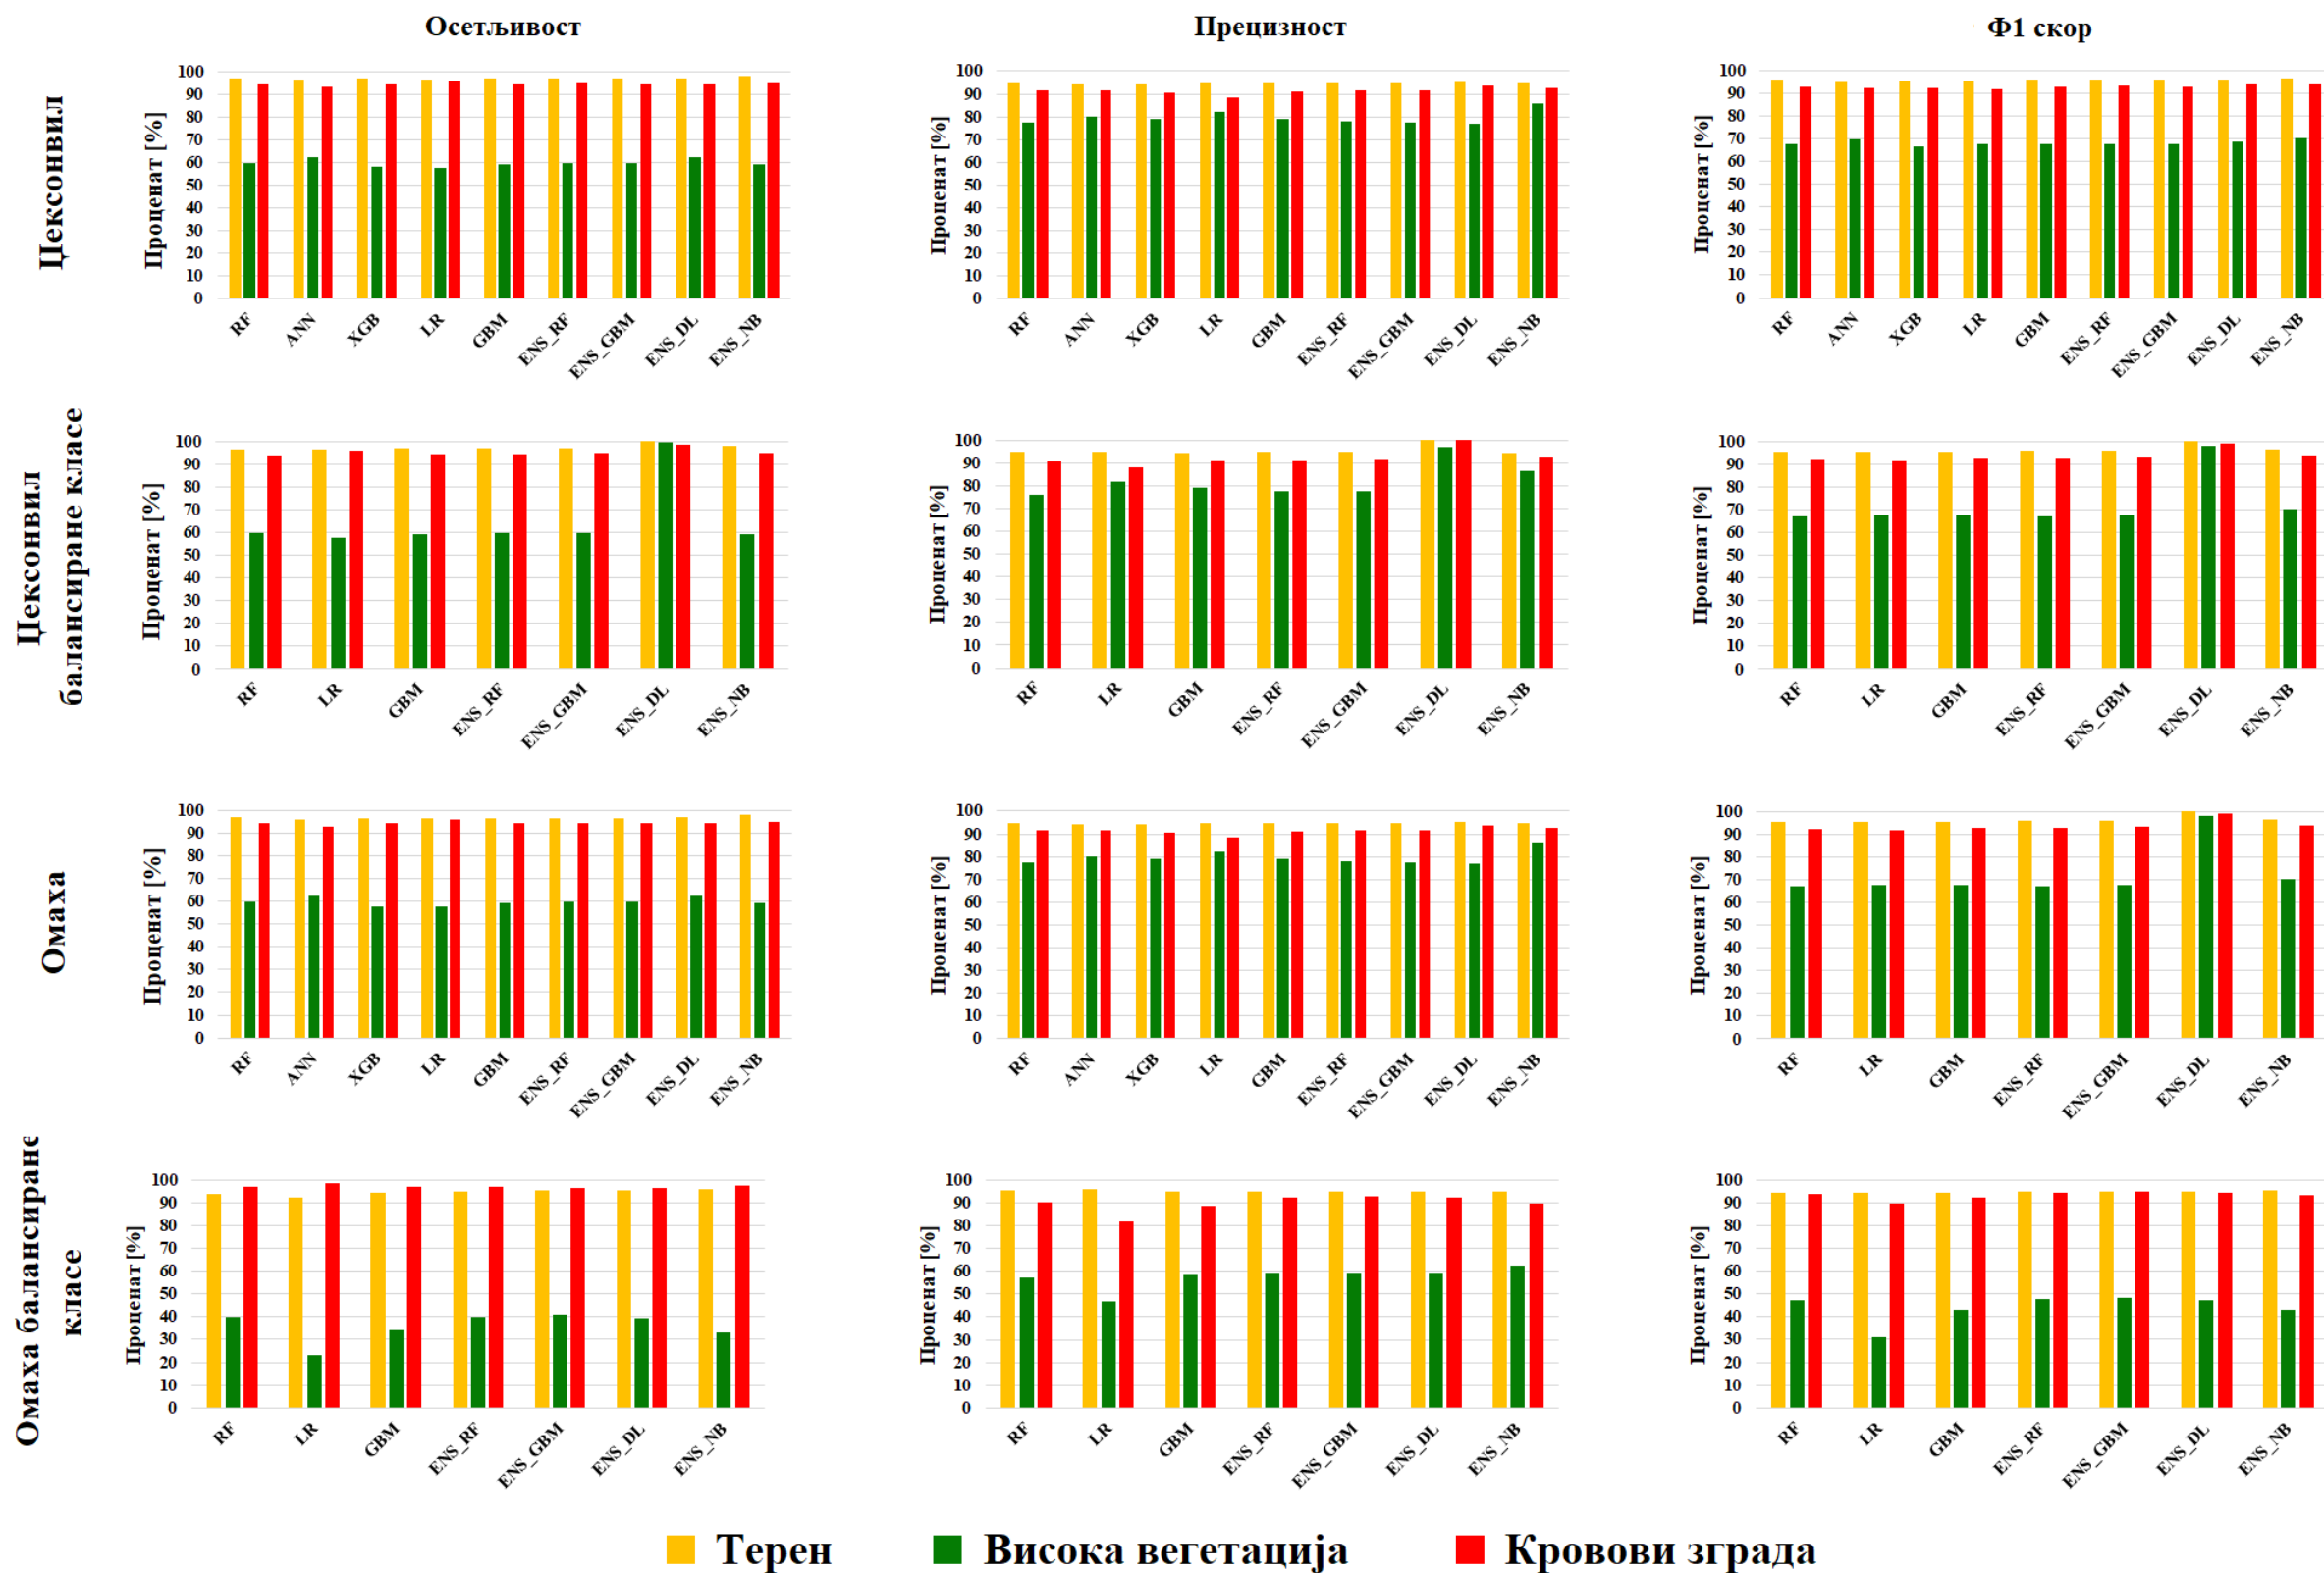
Слика П.12: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и Ф1 скорa ( $F1$ ) за вишеразмерну комбинацију са свим класификаторима

Прилог 7: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скорa ( $F1$ )  $ISPRS$  узоркованих података када је коришћена рекурзивна елиминација атрибута, са и без балансирања података према класама



Слика П.13: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скорa ( $F1$ ) за вишеразмерну комбинацију узоркованих података са свим класификаторима

Прилог 8: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скорa ( $F1$ ) када је коришћена рекурзивна елиминација атрибута, са и без балансирања  $GRSS$  података према класама



Слика П.14: Графици осетљивости ( $R$ ), прецизности ( $P$ ) и  $F1$  скорa ( $F1$ ) када је коришћена рекурзивна елиминација атрибута, са и без балансирања класа за за  $GRSS$  податке



## БИОГРАФИЈА АУТОРА

Ненад Бродић рођен је 19.09.1988. године у Шапцу, Република Србија. Основну школу „Јанко Веселиновић“ у Црној Бари завршио је 2003. године, а затим је похађао Геодетску техничку школу у Београду коју је завршио 2007. године. У току основног и средњег образовања био је одличан ученик и носилац је Вукове дипломе.

Основне академске студије Грађевинског факултета Универзитета у Београду, Одсек за геодезију и геоинформатику, уписао је 2007. године а завршио 2010. године са просечном оценом 9.83. Исте године уписао је дипломске–мастер студије, студијски програм Геоинформатика на Грађевинском факултету Универзитета у Београду. Мастер студије је успешно завршио 2012. године са просечном оценом 10.00. За успехе постигнуте током основних академских студија додељена му је награда „Студент генерације“ Грађевинског факултета Универзитета у Београду за школску 2010/2011. годину.

Школске 2012/2013. године уписао је докторске студије на Грађевинском факултету Универзитета у Београду– студијски програм Геодезија и геоинформатика.

Од 2010. до 2012. био је ангажован као студент демонстратор на Грађевинском факултету, Универзитета у Београду на предметима: Геоинформатика 1, Геоинформатика 2, Фотограмetriја и даљинска детекција 1 и Фотограмetriја и даљинска детекција 2. Од 2013. до 2019. био је запослен на Грађевинском факултету Универзитета у Београду као асистент – студент докторских студија на предметима: Геоинформатика 1 и Геоинформатика 2, Фотограмetriја и даљинска детекција 1 и Фотограмetriја и даљинска детекција 2, Дигитално моделирање терена, Основе дигиталне обраде слике, Инжењерска фотограмetriја, Дигитална фотограмetriја и Даљинска детекција. Активно је учествовао у креирању и унапређењу наставног плана и програма. Од 2015. био је ангажован у организацији два Еразмус+ програма за подизање капацитета у високом образовању: „*Modernising geodesy education in Western Balkan with focus on competences and learning outcomes (GEOWEB)*“ и „*Business driven problem-based learning for academic excellence in geoinformatics (GEOBIZ)*“. Један је од коаутора Практикума из геоинформатике за студенте основних академских студија геодезије и геоинформатике.

Од 2019. године ангажован је као истраживач на пројекту Министарства науке, просвете и технолошког развоја ев. бр. ТР36009: „*Примена GNSS и LiDAR технологије у мониторингу стабилности инфраструктурних објеката и терена*“.

До сада је, као аутор или коаутор, објавио бројне стручне и научноистраживачке радове у страним и домаћим научним часописима и међународним научним конференцијама из области ГИС–а, фотограмetriје и даљинске детекције. Носилац је бројних награда и добитник је великог броја стипендија током свог школовања. Присуствовао је бројним радионицама, курсевима и летњим школама које су се бавиле тематиком корисном за његову област истраживања.

Поседује одлично знање енглеског и основно знање немачког језика. Ожењен је и отац двоје деце.



## ИЗЈАВА О АУТОРСТВУ

Име и презиме аутора      Ненад Бродић

Број индекса                      915/12

### Изјављујем

да је докторска дисертација под насловом

СЕМАНТИЧКА СЕГМЕНТАЦИЈА ОБЛАКА ТАЧАКА ДОБИЈЕНОГ ЛАСЕРСКИМ  
СКЕНИРАЊЕМ ИЗ ВАЗДУХА КОРИШЋЕЊЕМ МЕТОДА МАШИНСКОГ УЧЕЊА

SEMANTIC SEGMENTATION OF AIRBORNE LASER SCANNING POINT CLOUDS  
USING MACHINE LEARNING METHODS

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршио ауторска права и користио интелектуалну својину других лица.

**Потпис аутора**

У Београду, \_\_\_\_\_

\_\_\_\_\_



## ИЗЈАВА О ИСТОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ ДОКТОРСКОГ РАДА

Име и презиме аутора	Ненад Бродић
Број индекса	915/12
Студијски програм	Геодезија
Наслов рада	СЕМАНТИЧКА СЕГМЕНТАЦИЈА ОБЛАКА ТАЧАКА ДОБИЈЕНОГ ЛАСЕРСКИМ СКЕНИРАЊЕМ ИЗ ВАЗДУХА КОРИШЋЕЊЕМ МЕТОДА МАШИНСКОГ УЧЕЊА  SEMANTIC SEGMENTATION OF AIRBORNE LASER SCANNING POINT CLOUDS USING MACHINE LEARNING METHODS
Ментор	В. проф. др Жељко Цвијетиновић, дипл. инж. геод.

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао ради похрањивања у **Дигиталном репозиторијуму Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

**Потпис аутора**

У Београду, \_\_\_\_\_

\_\_\_\_\_



## ИЗЈАВА О КОРИШЋЕЊУ

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

СЕМАНТИЧКА СЕГМЕНТАЦИЈА ОБЛАКА ТАЧАКА ДОБИЈЕНОГ ЛАСЕРСКИМ СКЕНИРАЊЕМ ИЗ ВАЗДУХА КОРИШЋЕЊЕМ МЕТОДА МАШИНСКОГ УЧЕЊА

SEMANTIC SEGMENTATION OF AIRBORNE LASER SCANNING POINT CLOUDS USING MACHINE LEARNING METHODS

која је моје ауторско дело.

Дисертацију са свим прилозима предао сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
- 3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)**
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци. Кратак опис лиценци је саставни део ове изјаве).

**Потпис аутора**

У Београду, \_\_\_\_\_

\_\_\_\_\_

1. **Ауторство.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. **Ауторство – некомерцијално.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. **Ауторство – некомерцијално – без прерада.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. **Ауторство – некомерцијално – делити под истим условима.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. **Ауторство – без прерада.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. **Ауторство – делити под истим условима.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.