

Univerza
v Ljubljani

Fakulteta
*za gradbeništvo
in geodezijo*



Jamova cesta 2
1000 Ljubljana, Slovenija
<http://www3.fgg.uni-lj.si/>

DRUGG – Digitalni repozitorij UL FGG
<http://drugg.fgg.uni-lj.si/>

To je izvirna različica zaključnega dela.

Prosimo, da se pri navajanju sklicujete na bibliografske podatke, kot je navedeno:

Dragoš, M., 2013. Objektna klasifikacija fotogrametrično določenega oblaka točk. Diplomski naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. (mentorica Kosmatin Fras, M., somentor Grigillo, D.): 41 str.

University
of Ljubljana

Faculty of
*Civil and Geodetic
Engineering*



Jamova cesta 2
SI – 1000 Ljubljana, Slovenia
<http://www3.fgg.uni-lj.si/en/>

DRUGG – The Digital Repository
<http://drugg.fgg.uni-lj.si/>

This is original version of final thesis.

When citing, please refer to the publisher's bibliographic information as follows:

Dragoš, M., 2013. Objektna klasifikacija fotogrametrično določenega oblaka točk. B.Sc. Thesis. Ljubljana, University of Ljubljana, Faculty of civil and geodetic engineering. (supervisor Kosmatin Fras, M., co-supervisor Grigillo, D.): 41 pp.

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*

Jamova 2
1000 Ljubljana, Slovenija
telefon (01) 47 68 500
faks (01) 42 50 681
fgg@fgg.uni-lj.si



UNIVERZITETNI ŠTUDIJ
GEODEZIJE
SMER GEODEZIJA

Kandidat:

MATIJA DRAGOŠ

**OBJEKTNA KLASIFIKACIJA FOTOGRAMETRIČNO
DOLOČENEGA OBLAKA TOČK**

Diplomska naloga št.: 932/G

**OBJECT-BASED CLASSIFICATION OF
PHOTOGRAMMETRICALLY ACQUIRED POINT
CLOUD**

Graduation thesis No.: 932/G

Mentorica:

doc. dr. Mojca Kosmatin Fras

Predsednik komisije:

izr. prof. dr. Dušan Kogoj

Somentor:

asist. dr. Dejan Grigillo

Član komisije:

doc. dr. Božo Koler

izr. prof. dr. Tomaž Ambrožič

Ljubljana, 12. 09. 2013

STRAN ZA POPRAVKE, ERRATA

Stran z napako

Vrstica z napako

Namesto

Naj bo

IZJAVA O AVTORSTVU

Podpisani Matija Dragoš izjavljam, da sem avtor diplomske naloge z naslovom: »Objektna klasifikacija fotogrametrično določenega oblaka točk«.

Izjavljam, da je elektronska različica v vsem enaka tiskani različici.

Izjavljam, da dovoljujem objavo elektronske različice v repozitoriju UL FGG.

Ljubljana, 1.8. 2013

Podpis:

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:	528.7(497.12)(043.2)
Avtor:	Matija Dragoš
Mentor:	doc. dr. Mojca Kosmatin Fras
Somentor:	asist. dr. Dejan Grigillo
Naslov:	Objektna klasifikacija fotogrametrično določenega oblaka točk
Tip dokumenta:	Diplomska naloga – univerzitetni študij
Obseg in oprema:	41 str., 4 pregl., 36 sl.
Ključne besede:	kvadrokopter, oblak točk, interpolacija »naravni sosed«, normaliziran digitalni model površja, segmentacija, objektna klasifikacija, SAGA

Izvleček

V diplomski nalogi je predstavljeno brezpilotno plovilo za snemanje iz zraka - kvadrokopter. Predstavljeni so podatki – oblak točk, zajeti s tem plovilom. Naloga obravnava objektno klasifikacijo tega oblaka točk. Opisana je metodologija priprave podatkov v brezplačnem odprtokodnem programu SAGA ter klasifikacija oblaka točk v brezplačnem odprtokodnem programu InterImage. V nalogi smo preizkusili postopek izdelave različnih podatkovnih slojev iz oblaka točk in predstavili vpliv vhodnih podatkov na kakovost segmentacije. Poudarek smo dali iskanju ustreznih parametrov in na podlagi analize histogramov preučili njihov vpliv na rezultate klasifikacije. Ugotovitve glede izbora parametrov na enem oblaku točk smo uporabili na drugem oblaku točk, ki predstavlja podobno območje in ugotovili, da je ponovitev klasifikacije z istimi parametri možna le pri nekaterih objektnih razredih. Za zadovoljivo klasifikacijo vseh objektnih razredov je potrebna ponovna nastavitvev parametrov.

BIBLIOGRAPHIC – DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC: 528.7(497.12)(043.2)
Author: Matija Dragoš
Supervisor: Assist.Prof. Mojca Kosmatin Fras, Ph.D.
Co-supervisor: Assist. Dejan Grigillo, Ph.D.
Title: Object-based classification of photogrammetrically acquired point cloud
Document type: Graduation Thesis – University studies
Scope and tools: 41 p., 4 tab., 36 fig.
Keywords: quadcopter, point cloud, natural neighbour interpolation, normalized digital surface model, segmentation, object based classification, SAGA

Abstract

This graduation thesis addresses unmanned aerial vehicle for aerial data acquisition - quadcopter. Data (point cloud), acquired with the vehicle is presented and object-based classification of this point cloud is performed. The thesis describes methodology of data preparation with free open source software SAGA and classification of point cloud in free open source software InterImage. Protocol of producing different data layers from the point cloud is tested and the influence of input data on the segmentation quality is presented. We focused on finding appropriate parameters for classification and studied their impact on classification results based on histogram analysis. We used the knowledge of parameter selections obtained from one point cloud and applied it to another point cloud that represented similar area. We discovered that the classification with the same parameters can be repeated only for certain object classes. For sufficient classification of all object classes new parameter settings are required.

ZAHVALA

Zahvaljujem se mentorici doc. dr. Mojci Kosmatin Fras ter somentorju asist. dr. Dejanu Grigillu za pomoč in nasvete pri izdelavi diplomske naloge. Prav tako se zahvaljujem svoji družini, prijateljem ter Anni Oslizlo, ki so me podpirali pri študiju.

KAZALO VSEBINE

1	UVOD.....	1
2	SNEMANJE POVRŠJA Z RADIJSKO VODENIM KVADROKOPTERJEM	3
3	METODOLOGIJA OBDELAVE PODATKOV IN UPORABLJENA PROGRAMSKA OPREMA	5
3.1	Metodologija obdelave podatkov	5
3.2	Uporabljena programska oprema	7
4	INTERPOLACIJA OBLAKA TOČK	9
4.1	Interpolacija barvnih kanalov ter izdelava DMP	10
5	PRIPRAVA VHODNIH PODATKOV ZA OBJEKTNO KLASIFIKACIJO V PROGRAMU INTERIMAGE	14
5.1	Izdelava normaliziranega digitalnega modela površja (nDMP).....	14
5.2	Pridobitev sloja kvazi vegetacijskega indeksa	16
5.3	Izdelava podobe s petimi kanali	17
6	OBJEKTNA KLASIFIKACIJA	19
6.1	Segmentacija.....	19
6.2	Klasifikacija.....	23
6.3	Izdelava in analiza histogramov	25
6.3.1	Izdelava histogramov	26
6.3.2	Analiza histogramov	27
6.4	Uporaba znanja na drugi podobi	33
6.4.1	Klasifikacija druge podobe.....	34
7	REZULTATI IN KOMENTAR.....	36
8	ZAKLJUČEK.....	39
	VIRI	40

KAZALO PREGLEDNIC

Preglednica 1: Tehnične specifikacije kvadrokopterja md4-1000	4
Preglednica 2: Primer vhodnih podatkov (prvi oblak točk)	5
Preglednica 3: Uporabljeni ukazi programa SAGA	8
Preglednica 4: Rezultati različnih vrst interpolacij	9

KAZALO SLIK

Slika 1: Kvadrokopter md4-1000.....	3
Slika 2: Prvo območje snemanja, Stari trg pri Ložu	5
Slika 3: Shema postopka.....	6
Slika 4: Drugo območje snemanja, Hrašenski Vrh	7
Slika 5: Voronijeva teselacija z grafično predstavljenimi utežmi	10
Slika 6: Oblak točk, prikazan v programu SAGA.....	11
Slika 7: Nastavitveno okno za interpolacijo programa Saga	11
Slika 8: Prikaz območja v ukazu RGB overlay.....	12
Slika 9: Pravilne nastavitve ukaza RGB Composite.....	13
Slika 10: Ukaz GridCalculus	14
Slika 11: DMP obravnavanega območja - Stari trg	15
Slika 12: nDMP obravnavanega območja - Stari trg	15
Slika 13: RGB kanali po interpolaciji.....	17
Slika 14: Proces klasifikacije.....	19
Slika 15: Okno NodeEditor programa InterImage	20
Slika 16: Segmentacija RGB sloja.....	21
Slika 17: Segmentacija RGB in nDMP sloja.....	21
Slika 18: Segmentacija RGB, nDMP in KVI sloja	22
Slika 19: Odločitveno drevo	23
Slika 20: Parametri za razred Nizka vegetacija.....	24
Slika 21: Rezultat iskanja parametrov	24
Slika 22: Rezultat klasifikacije prve podobe	25
Slika 23: Export .SHP	26
Slika 24: Objektni razred Ceste, po obdelavi v programu PhotoShop	27
Slika 26: KVI histogram <i>Cest</i> in <i>Nizke vegetacije</i>	28
Slika 27: Značilna vrsta objektov objektnega razreda <i>Nizki objekti</i>	29
Slika 28: RGB histogrami <i>Stavb</i> in <i>Visoke vegetacije</i>	30
Slika 29: KVI Histogram <i>Stavb</i> in <i>Visoke vegetacije</i>	31
Slika 30: Ugotovitve analize histogramov.....	32
Slika 31: Drugo obravnavano območje, Hrašenski Vrh	33
Slika 32 : Parametri klasifikacije druge podobe.....	34
Slika 33: Klasifikaciji z istimi parametri ter dodanim pogojem	35
Slika 34: Klasifikacija 5C podobe prvega območja.....	36
Slika 35: Eden izmed neupeljih poizkusov klasifikacije druge podobe	37
Slika 36: Klasifikacija podobe drugega območja z novim pogojem za klasifikacijo <i>Visokih objektov</i>	38

1 UVOD

Z razvojem tehnologije se tudi v aero-fotogrametriji pojavlja nova oprema za zajem slik. Ena izmed teh je fotografiranje površja z brezpilotnimi zračnimi plovili (angl. unmanned aerial vehicle - UAV). Na tržišču so dostopna različna takšna plovila, eden izmed teh je večrotorski radijsko vodeni helikopter, kvadrokopter, s katerim je bil pridobljen oblak točk, ki smo ga uporabili v diplomski nalogi. Oblaku točk je bila iz zračnih posnetkov dodana vrednost za rdečo (R), zeleno (G) in modro (B) barvo.

V diplomski nalogi smo izvedli postopek interpolacije oblaka točk, ki je diskretna množica točk, za potrebe izdelave rastrske podobe z realnimi barvnimi vrednostmi (RGB) ter izdelali digitalni model površja (DMP).

Soočili smo se z nalogo ustvarjanja novih podatkovnih slojev iz danih podatkov. Za izvedbo klasifikacije je bilo potrebno DMP-ju, z absolutnimi vrednostmi višin, odšteti digitalni model reliefa (DMR), da smo pridobili normaliziran digitalni model površja (nDMP), z relativnimi vrednostmi višin. Prav tako smo za potrebe boljšega ločevanja med vegetacijo in ostalimi površinami izdelali kvazi vegetacijski indeks (KVI) iz podobe z realnimi barvnimi vrednostmi.

Sledila je izvedba objektne klasifikacije, ki je sestavljena iz segmentacije vhodnih slojev in klasifikacije segmentov. V postopku segmentacije smo preverili, kako dodajanje različnih podatkov o površju vpliva na kakovost segmentacije.

Po segmentaciji smo izvedli klasifikacijo po metodi odločitvenih dreves. Rezultat je klasificirana podoba s štirimi objektnimi razredi. Soočili smo se s problemom določitve parametrov za klasifikacijo. Po končani klasifikaciji smo izvedli analizo histogramov po posameznih vhodnih slojih za boljše razumevanje razporeditev vrednosti znotraj posameznih objektnih razredov. Rezultat analize histogramov ter znanje, pridobljeno pri klasifikaciji enega oblaka točk, smo vključili v klasifikacijo drugega oblaka točk, ki je bil zajet na podobnem območju.

Naloga obsega osem glavnih poglavij. V prvem, uvodnem poglavju je predstavljena tema diplomske naloge. V 2. poglavju je opisano plovilo za zajem posnetkov iz zraka – kvadrokopter, s katerim sta bila zajeta oblaka točk, ki sta bila uporabljena v diplomskem delu. V 3. poglavju je opisana uporabljena metodologija klasifikacije, ki je razdeljena na metodologijo obdelave podatkov in na predstavitev programske opreme, ki smo jo uporabljali v tem delu. V 4. poglavju je predstavljen postopek interpolacije. V 5. poglavju je predstavljena obdelava podatkov za objektno klasifikacijo. V 6. poglavju je opisana klasifikacija v programu InterImage in izdelava histogramov. Prav tako so predstavljeni rezultati analize histogramov. V zadnjem delu tega poglavja je opisan prenos znanja iz

enega oblaka točk na klasifikacijo drugega oblaka točk. V 7. poglavju so predstavljeni rezultati in njihov komentar . V zadnjem, 8. poglavju so strnjene zaključne ugotovitve.

2 SNEMANJE POVRŠJA Z RADIJSKO VODENIM KVADROKOPTERJEM

Kvadrokopterji predstavljajo novo vrsto radijsko vodenih brezpilotnih plovil (UAV). Poznamo vrsto različnih več-rotorskih UAV, od takšnih s tremi rotorji, do takšnih z šestimi ali osmimi, med katerimi je najbolj običajen štiri rotorski, kvadrokopter. Delovanje in sestava je pri vseh podobna.

Kvadrokopter je sestavljen iz nosilca, elektronike, baterije ter štirih rotorjev, ki so postavljeni na nosilcu v obliki križa. Dva rotorja se vrtita sournjo, dva protiurno. S kontroliranjem hitrosti vrtenja rotorjev je omogočeno različno gibanje tega plovila: lebdenje, dviganje, spuščanje, vrtenja okoli osi ter premika naprej in nazaj (Rchelicopterfun, 2013).

Po svoji mehanski zgradbi so kvadrokopterji dokaj enostavni. Z razvojem zmogljive elektronske opreme je postalo upravljanje s to vrsto plovil UAV preprosto. Neizkušen »pilot« se lahko nauči upravljanja v eni uri. Ker so plovila UAV cenovno ugodna ter omogočajo pritrnitev kamere na telo, se uporabljajo za vse vrste dejavnosti, kjer je potrebno snemanje iz zraka: proti teroristične operacije, preprečevanje tihotapljenja drog, kontroliranje zgodovinsko pomembnih objektov, zračna fotogrametrija, preprečevanje ter spremljanje nesreč, opazovanje mejnih prehodov,... Povezava z GPS-om in njegov notranji kompas omogočata snemanje predhodno načrtovanega območja (Microdrones, 2013). V primerjavi s klasičnimi sistemi zračnega snemanja so plovila UAV cenejša, hitreje pripravljena na snemanje ter imajo nižje stroške vzdrževanja.



Slika 1: Kvadrokopter md4-1000. (<http://microdrones.com/products/md4-1000/md4-1000-key-information.php>, 2013)

Podatke, ki smo jih obdelali v okviru diplomske naloge, smo pridobili od podjetja MODRI PLANET. Za snemanje uporabljajo fotoaparatus Olympus Pen-EP1 s senzorjem z geometrično ločljivostjo 12,3MP. Za snemanje so uporabili vrsto kvadrokopterja, ki je prikazan na sliki 1. Nekaj tehničnih specifikacij kvadrokopterja, s katerim so zajeli podatke, ki smo jih obravnavali v diplomski nalogi, je predstavljenih v preglednici 1.

Preglednica 1: Tehnične specifikacije kvadrokopterja md4-1000. (Jung, A., elektronsko sporočilo za Dragoš, M.)

Cena	20.000 €, s sistemom za navigacijo
Čas leta	Do 88 minut (odv. od obtežitve, vetra, baterije)
Propelerji	4x 60 cm
Teža	2650 g
Vertikalna hitrost	7.5 m/s , 27 km/h
Horizontalna hitrost	15.0 m/s, 54 km/h
Maksimalna teža tovora	550 g
Pogon	Baterije
Odpornost	Na dež in prah

3 METODOLOGIJA OBDELAVE PODATKOV IN UPORABLJENA PROGRAMSKA OPREMA

3.1 Metodologija obdelave podatkov

Prvo območje, ki smo ga v diplomskem delu obravnavali, se nahaja v vasi Stari trg pri Ložu. Del vasi, ki je bil posnet, je predstavljen na sliki 2.



Slika 2: Prvo območje snemanja, Stari trg pri Ložu

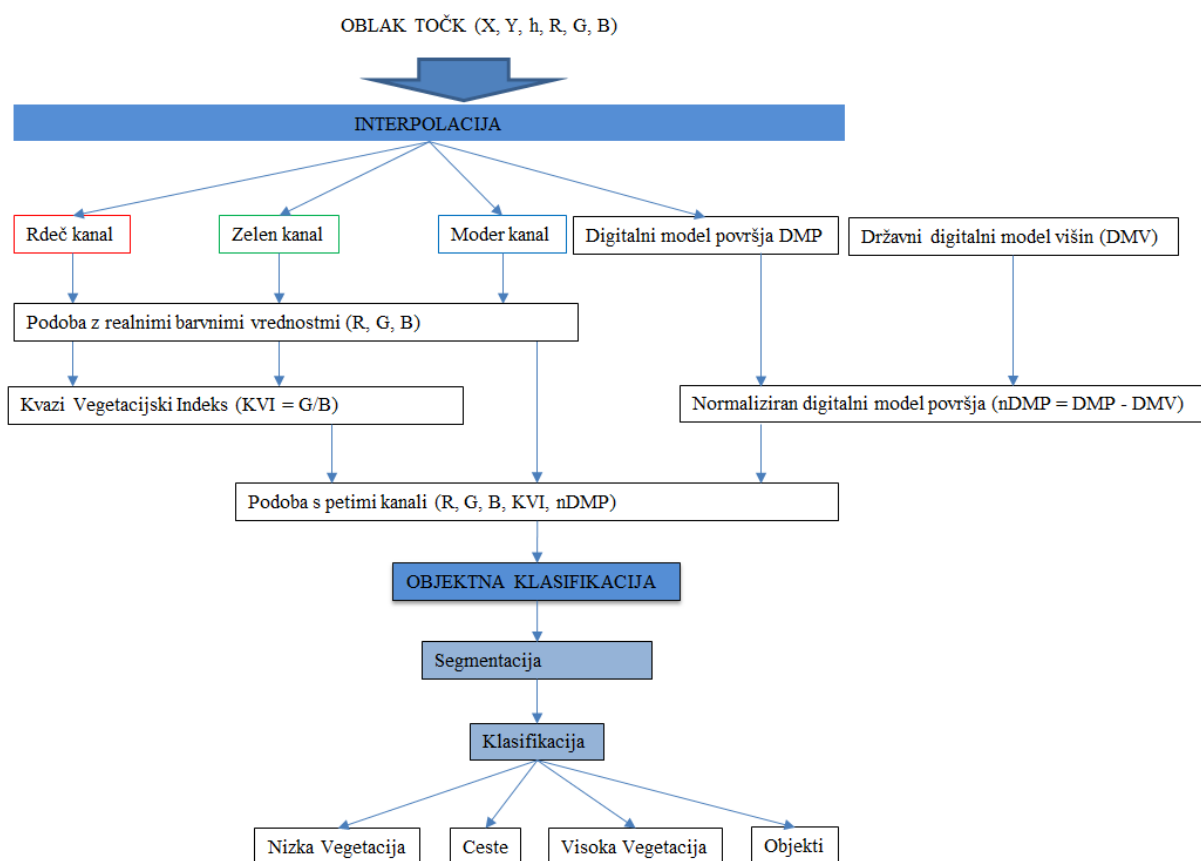
Izhodiščni podatkovni vir za našo nalogo je bil oblak točk, ki je bil rezultat obdelave posnetkov, zajetih s kvadrokopterjem.

Oblak točk (912.632 točk) je bil podan v D48/GK koordinatnem sistemu s tremi koordinatami za vsako točko. Vsaki točki je bila pripisana tudi vrednost rdeče, zelene in modre barve v 8 bitnem razponu vrednosti, ki je bila določena iz posnetkov. Kot primer strukture zapisa podatkov sta v preglednici 2 predstavljeni dve točki.

Preglednica 2: Primer vhodnih podatkov (prvi oblak točk).

Št. točke	Y	X	h	R	G	B
1	459012,1971	63402,0167	606,3326	152	144	119
2	459012,3788	63402,0325	606,2864	162	157	135

Postopek dela je grafično prikazan na sliki 3. Najprej smo opravili interpolacijo posameznih barvnih vrednosti ter tri pridobljene podobe (R, G in B) združili v eno podobo z RGB kanali. Potem smo izvedli interpolacijo višin, katere rezultat je DMP. Potem smo z odštetjem DMP in državnega DMR pridobili nDMP. Nato smo RGB podobo in nDMP združili v podobo s štirimi kanali, kjer je četrti kanal predstavljal višine iz nDMP. Sprva smo mislili, da sta ti dve podobi zadostni za uspešno segmentacijo. Po številnih poizkusih smo ugotovili, da obstajajo nekatera območja, na katerih ostaja nekaj slabo združenih segmentov. Zato smo se odločili, da izdelamo dodatni sloj iz barvnih vrednosti, ki bo izboljšal našo segmentacijo in sicer »kvazi vegetacijski indeks«, ki predstavlja razmerje zelenega in modrega sloja. Potem smo segmentacijo in klasifikacijo izvedli na podobi, ki je poleg vrednosti RGB in višin nDMP vsebovala še vrednost kvazi vegetacijskega indeksa s čimer smo nadomestili infrardeči kanal (poglavje 5.2) in izboljšali segmentacijo. Nato smo izvedli klasifikacijo po metodi odločitvenih dreves.



Slika 3: Shema postopka

Po klasifikaciji smo naredili histograme posameznih objektnih razredov z namenom, da bi videli razporeditve vrednosti v nekaterih slojih. Znanje iz analize histogramov smo uporabili za klasifikacijo drugega oblaka točk (prav tako predstavlja del vasi ob podobni osvetljenosti), ki se nahaja na

območju, označenem na sliki 4, ter vizualno ocenili rezultate. Postopek obdelave tega oblaka točk je podoben postopku obdelave prvega oblaka točk.



Slika 4: Drugo območje snemanja, Hrašenski Vrh

3.2 Uporabljena programska oprema

Za izvedbo interpolacije je bil uporabljen program SAGA (angl. System for Automated Geoscientific Analyses), ki je brezplačni odprtokodni program in služi za upravljanje prostorskih podatkov (SAGA Wiki, 2013). Za potrebe diplomske naloge so bili uporabljeni ukazi, ki so vgrajeni v program in jih najdemo pod menijem moduli. Ukazi, ki smo jih uporabljali v postopku, so predstavljeni v preglednici 3. Ukaze najdemo v modulih, ki vsebujejo te ukaze. Npr: modul Import/Export – Tables vsebuje ukaza: Export Text Table ter Import Text Table.

Program SAGA uporablja izraz mreža (angl. grid) za vsak nabor vrednosti, urejen v pravilno celično mrežo, ki se nahaja v enem izmed sistemov mrež (angl. grid system), ki je definiran z: velikostjo celice, vertikalnim in horizontalnim številom celic ter z vogalnima koordinatama mreže (koordinati leve spodnje celice).

Preglednica 3: Uporabljeni ukazi programa SAGA (Sourceforge, 2013)

Ime ukaza	Modul	Izvede
Import Text Table	Import/Export - Tables	Uvozi izbrano tabelo
Convert Table to Points	Shapes - Points	Spremeni format zapisa točk v tabeli iz tekstovnega v zapis shape
Natural Neighbour	Grid - Gridding	Interpolira izbrano mrežo točk po metodi naravni sosed (angl. Natural neighbour)
RGB Composite	Grid - Visualization	Ustvari RGB (true Color) mrežo iz treh izbranih mrež.
Close Gaps with Spline	Grid - Tools	Zapolni praznine v izbrani mreži z uporabo Spline interpolacije
Grid Division	Grid - Calculus	Deli izbrani mreži med sabo
Reclassify Grid Values	Grid - Tools	Spremeni izbrane vrednosti mreže na podlagi podanega pogoja
Grid Masking	Grid - Tools	Izreže izbrano mrežo z območjem izbrane mreže
Grid Calculator	Grid - Calculus	Izvede nastavljeno matematično opracijo med izbranimi mrežami istega ali različnih sistemov mrež
Grid Normalisation	Grid - Calculus	Izvede razteg ali skrček vrednosti znotraj izbranega ranga vrednosti na mreži
Fit Color Palette to Grid Values	Grid - Visualisation	Spremeni barvni prikaz glede na vrednosti mreže
Export True Color Bitmap	Import/Export Grids	Izvozi izbrano mrežo v podobo z bmp zapisom
Export Image	Import/Export Grids	Izvozi izbrano mrežo v podobo s poljubnim zapisom

Za izvedbo segmentacije in klasifikacije je bil uporabljen program InterImage, ki je brezplačni odprtokodni program, namenjen avtomatski interpretaciji posnetkov. Za potrebe diplomske naloge smo uporabili funkcije, ki so vgrajene v program. Podroben opis delovanja programa je opisan v diplomskem delu »Uporaba odprtokodnih programov za objektno usmerjeno analizo visoko ločljivega posnetka daljinskega zaznavanja« (Štefan, 2012).

4 INTERPOLACIJA OBLAKA TOČK

Naša prva naloga je bila interpolacija ter rasterizacija oblaka točk. Želeli smo pridobiti rastersko sliko z realnimi (RGB) vrednostmi ter digitalni model površja (DMP). Oblak točk je diskretna množica točk v 3D koordinatnem sistemu, ki predstavlja zunanjo površino objekta (Pointcloud Wiki, 2013). V matematičnem smislu je interpolacija ustvarjanje novih podatkov znotraj ranga znanih diskretnih podatkov (Interpolation Wiki, 2013).

V programu SAGA je na voljo več vrst interpolacij. Christopher W. Bater in Nicholas C. Copps sta primerjala sedem različnih algoritmov za interpolacijo ploskve reliefa iz talnih odbojev (Preglednica 4). Ugotovila sta, da je metoda naravnega soseda (angl. Natural Neighbour) najbolj učinkovita, ker je računalniško in časovno manj zahtevna in preprosta za uporabo, saj je potrebno podati le velikost celice. Rezultat je gladka in vizualno »lepa« ploskev, ki je konsistentne točnosti (W. Bater in sod., 2008).

Preglednica 4: Rezultati različnih vrst interpolacij, prostorske ločljivost podatkov 0,5 m. (Prirejeno po preglednici iz vira: W. Bater in sod., 2008).


Interpolation method (weight or power)	Mean error (m)	Mean absolute error (m)
Linear	0,0014	0,11
Quintic	0,0015	0,10
Natural neighbour	0,00059	0,11
IDW (inverse distance...)	-0,0045	0,11
Spline with tension (2)	-0,00030	0,10
Regularized spline (0)	-0,00022	0,10

Zaradi zgornjih ugotovitev smo se odločili, da v naši nalogi uporabimo interpolacijo »naravni sosed«. Interpolacija »naravni sosed« je metoda prostorske interpolacije, ki jo je razvil Robin Sibson. Metoda temelji na Voronijevi teselaciji (angl. Voronoi tessellation) diskretne množice prostorskih točk (Natural neighbour Wiki, 2013). J-D Boissonnat in sod. ugotavljajo, da je v množici nepravilno urejenih točk definiranje sosednjih točk lahko težavno. Za konstrukcijo površine je potrebno povezati vsako točko x z danimi točkami, tako da so blizu točke x in hkrati razporejene okoli točke x . Preproste metode, kot so »točke znotraj razdalje« ali » n najbližjih točk« ne zagotavljajo takšnega pogoja (Boissonnat in sod., 2001).

Enačba 1 podaja 2D izračun za metodo naravnega sosedaja:

$$G(x,y) = \sum_{i=1}^n w_i f(x_i, y_i) \quad (1)$$

$G(x,y)$ je rezultat v točki (x,y) . w_i je utež v točki $f(x_i, y_i)$, ki je izračunana glede na delež »ukradenega« območja, ko se točka (x,y) vstavi v teselacijo.




Slika 5: Voronijeva teselacija z grafično predstavljenimi utežmi

Na sliki 5 obarvani krogi predstavljajo uteži, ki so izračunane na podlagi unije novo vstavljene točke (modro) z Voronijevo celico dane točke (Natural neighbour Wiki, 2013).

4.1 Interpolacija barvnih kanalov ter izdelava DMP

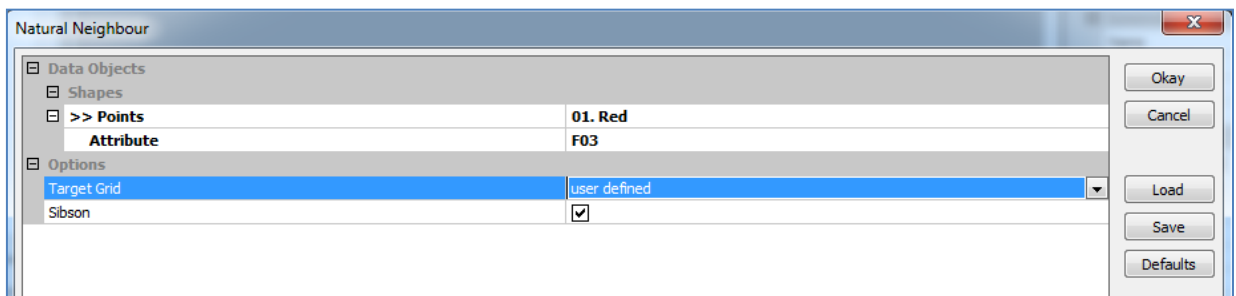
Iz oblaka točk smo ustvarili štiri tekstovne datoteke. Za interpolacijo barvnih kanalov smo naredili tri tekstovne datoteke, v kateri sta bili koordinati X in Y točke podani v prvih dveh stolpcih, vrednost enega izmed barvnih kanalov pa v tretjem stolpcu. Za izdelavo DMP je bilo potrebno narediti tekstovno datoteko, ki je imela vrednosti višin v tretjem stolpcu. Stolpci so bili ločeni s tabulatorjem. Za vse štiri tekstovne datoteke je postopek interpolacije podoben. Vse vrednosti v datotekah smo interpolirali na prostorsko ločljivost 0,5 m, saj bi v primeru večje ločljivosti izvedba interpolacije trajala znatno dlje. V primeru izbire manjše ločljivosti pomembni objekti na podobi po interpolaciji ne bi bili razločno vidni.

Za interpolacijo je bil uporabljen program SAGA. Z ukazom Import/Export - Tables => Import Text Table smo uvozili tabelo. Z ukazom Shapes - Points => Convert Table to Points smo točkam v tabeli spremenil format zapisa iz .txt v .shp, ki ga program uporablja za nadaljnjo obdelavo. Po izvedbi ukaza se podatek pokaže v oknu Workspace pod zavihkom Data. Desni klik na ta podatek omogoča, da ga grafično prikažemo z ukazom Add to Map (slika 6).



Slika 6: Oblak točk, prikazan v programu SAGA

Z ukazom Grid - Gridding => Natural Neighbour začnemo interpolacijo. Pojavi se okno z nastavitvami (slika 7), kjer v vrstici Points izberemo prej ustvarjene točke. V vrstici Attribute izberemo tretji stolpec (F03), ki predstavlja vrednosti atributa. V vrstici Target Grid izberemo možnost »user defined«, če želimo sami nastaviti robne koordinate ter velikost celice mreže, ki jo ustvarjamo. Nastavitev Sibson nam omogoča, da izvedemo interpolacijo samo znotraj meja podatkov. V nasprotnem primeru se interpolacija izvede po območju celotne mreže, ki jo ustvarjamo. Če smo izbrali možnost »user defined«, sledi nastavitev robnih koordinat ter velikost celice mreže.

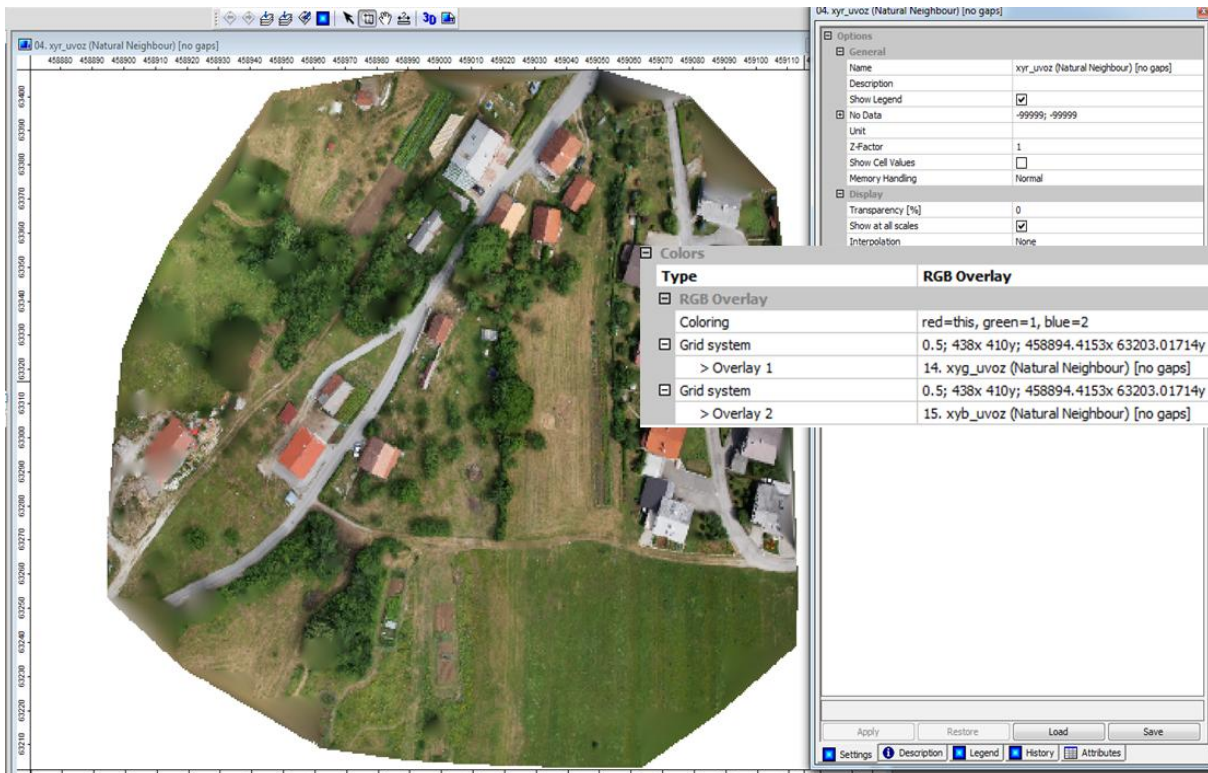


Slika 7: Nastavitveno okno za interpolacijo programa Saga

Po izvedeni interpolaciji po metodi »naravni sosed« lahko pride do lukenj (angl. gaps) v mreži. V našem primeru so vse interpolirane mreže vsebovale luknje, ki smo jih »popravili« z ukazom Grid - Tools => Close Gaps with Spline. V nastavitvah tega ukaza nastavimo minimalno in maksimalno število celic v luknji, ki jih bo ukaz še popravil. Spline je sicer dobra interpolacija, vendar časovno bolj potratna od natural neighbour, zato jo uporabimo samo za luknje. (W. Bater in sod., 2008).

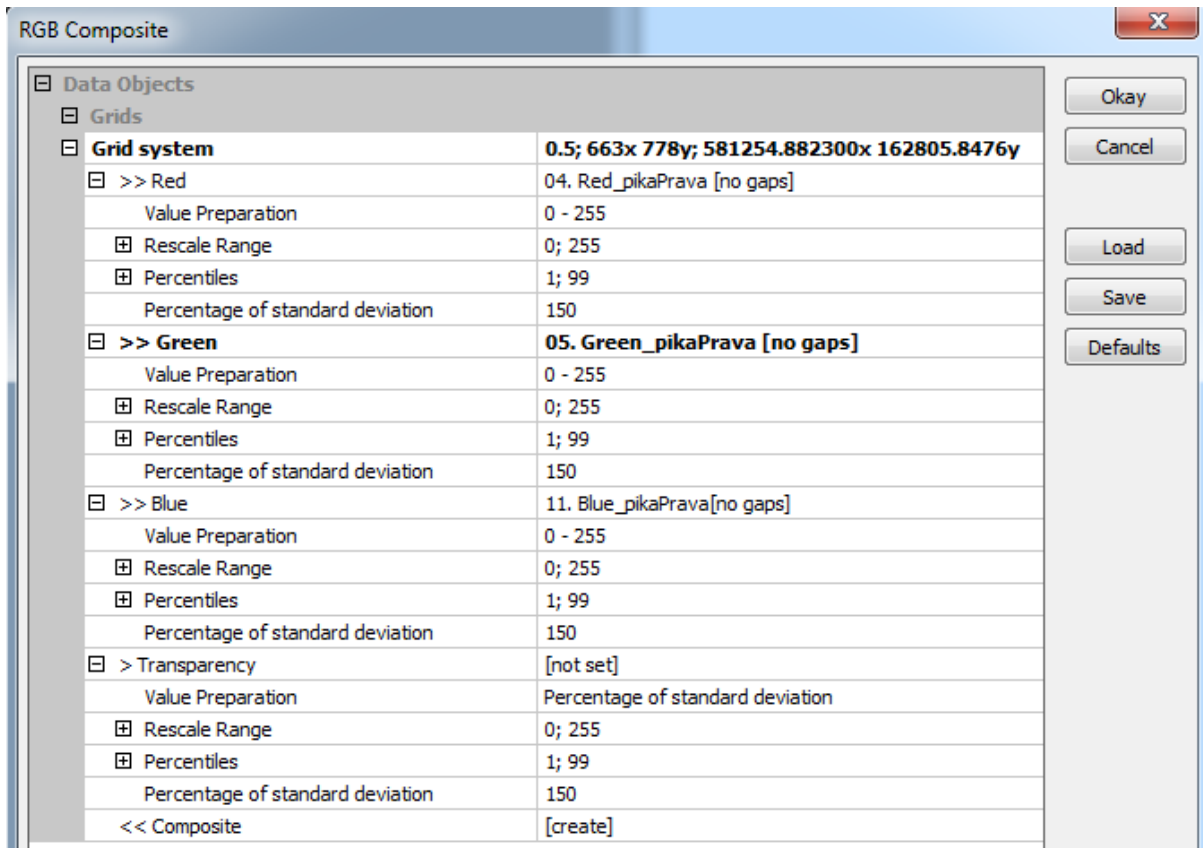
Program privzeto za grafični prikaz uporablja lažno barvno lestvico (angl. false colours), ki rezultatov ne pokaže vedno najbolje. Za pravi prikaz barvnih kanalov je potrebno uporabiti ukaz Grid -

Visualisation => Fit Color Palette to Grid Values, kjer v nastavitvah nastavimo 256 stopenjsko barvno lestvico in izberemo »grayscale« način prikaza. Predogled podobe z RGB kanali (RGB podoba) je možen, če v oknu »Object Properties« pod zavihkom »Settings« v vrstici Colors izberemo možnost RGB Overlay (slika 8). Tukaj moramo pravilno izbrati vrstni red interpoliranih barvnih kanalov.



Slika 8: Prikaz območja v ukazu RGB overlay

Sledila je združitev interpoliranih barvnih kanalov v RGB podobo. Za to smo uporabili ukaz Grid - Visualization => RGB Composite. V nastavitvah tega ukaza izberemo mreže za R, G in B kanal. Pozorni moramo biti, da v vrstici Value Preparation izberemo možnost 0-255 (Slika 9).



Slika 9: Pravilne nastavitve ukaza RGB Composite

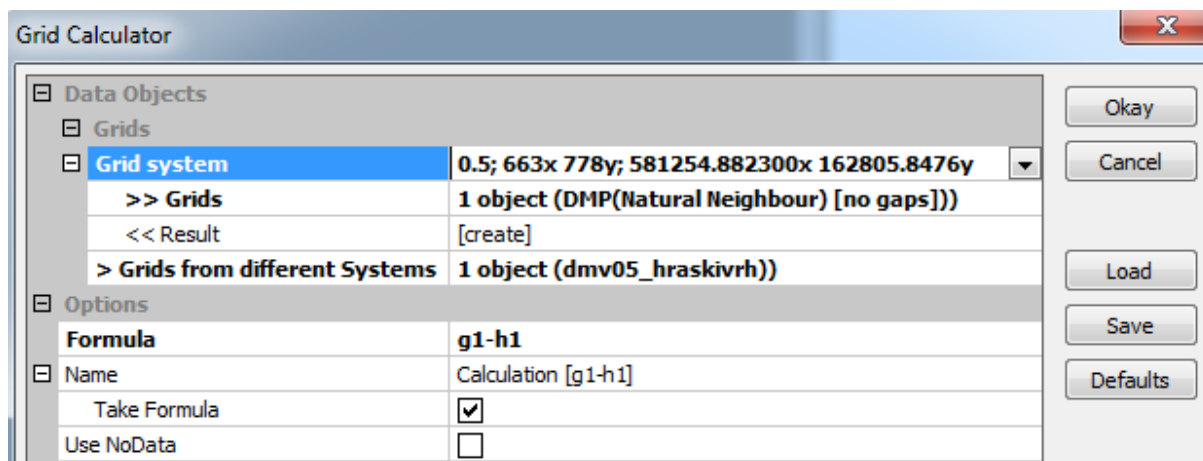
Tako pridobljena RGB podoba bo služila kot osnovni sloj v postopku objektne klasifikacije. Mreža, ki je rezultat interpolacije po višinah (DMP), pa bo služila za izdelavo dodatnega sloja objektne klasifikacije in sicer nDMP (poglavje 6.1).

5 PRIPRAVA VHODNIH PODATKOV ZA OBJEKTNO KLASIFIKACIJO V PROGRAMU INTERIMAGE

5.1 Izdelava normaliziranega digitalnega modela površja (nDMP)


V postopku interpolacije pridobljeni DMP (slika 11) vsebuje absolutne višine, za potrebe klasifikacije pa potrebujemo model z relativnimi višinami, zato je bilo potrebno izdelati nDMP (slika 12). Pridobimo ga tako, da DMP-ju odštejemo digitalni model višin (DMV). DMP smo izdelali v postopku interpolacije oblaka točk. DMV smo pridobili iz državnega DMV 5, interpoliranega na prostorsko ločljivost 0,5 m. Državni DMV je razdeljen na liste TTN 5. List, ki zajema naše območje, je »Sodražica 22«.

Za izračun razlike smo uporabili ukaz Grid - Calculus => Grid Calculator, kjer lahko delamo preračune med različnimi sistemi mrež. Ta ukaz je potreben, saj je DMP v enem, DMV pa v drugem sistemu mrež. DMP je v istem sistemu mrež, kot oblak točk in iz njega pridobljeni podatki. DMV je v drugem sistemu mrež, saj je pridobljen iz državnega DMV 5. Zaradi tega se sistema mrež razlikujeta po robnih koordinatah in številu pikslov. Slika 10 prikazuje nastavitve za potrebe izračuna razlike med dvema sistemoma mrež. Rezultat bo v sistemu mrež, ki je nastavljen v vrstici Grid Calculus. Pri zapisu enačbe je potrebno vedeti, da so mreže v prvem sistemu mrež označene z g1, g2,..., medtem ko so mreže drugega sistema mrež označene z h1, h2,...




Slika 10: Ukaz GridCalculus

Če DMP in DMV nista čisto skladna, po odštetju nekatere celice dobijo negativno vrednost. To smo odpravili z ukazom Grid - Tools => Reclassify Grid Values, kjer smo nastavili pogoj, da se vrednostim z negativnim predznakom spremeni vrednost v 0. Tako ustvarjen nDMP smo uporabili kot prvi dodatni sloj v objektni klasifikaciji.



Slika 11: DMP obravnavanega območja - Stari trg



Slika 12: nDMP obravnavanega območja - Stari trg

5.2 Pridobitev sloja kvazi vegetacijskega indeksa


Za razpoznavanje vegetacije se velikokrat uporablja bližnji infrardeči (angl. near infrared, NIR) kanal, zajet s senzorjem, občutljivim na valovne dolžine bližnje infrardeče svetlobe, saj vegetacija bolj kot ostali objekti odbija to vrsto svetlobe – je svetla v NIR (NDVI Wiki, 2013). Ker vegetacija za fotosintezo uporablja rdečo svetlobo, je na rdečem kanalu temnejša od ostalih objektov. Vegetacijski indeks (VI) se v tem primeru izračuna po enačbi 2 (Oštir, 2006).

$$VI = \frac{NIR}{R} \quad (2)$$

V enačbi 2 je NIR vrednost bližnjega infrardečega kanala, R pa vrednost rdečega kanala posnetka. Ker so bili naši podatki zajeti s fotoaparatom s senzorjem RGB, nismo imeli NIR kanala. Da bi lažje ločili med vegetacijo in ostalim površjem, smo se odločili za izračun kvazi vegetacijskega indeksa (KVI) po istem »modelu«. Vizualno smo preverili, na katerih kanalih ima vegetacija najvišjo in na katerih najnižjo vrednost. V našem primeru je vegetacija imela najvišjo vrednost na zelenem kanalu, najnižjo pa na modrem (slika 13), zato smo se odločili, da izračunamo KVI po enačbi 3:

$$KVI = \frac{G}{B} \quad (3)$$

V enačbi 3 vrednosti G predstavljajo interpolirane vrednosti zelenega, vrednosti B pa interpolirane vrednosti modrega kanala.



Slika 13: RGB kanali po interpolaciji. Levo: rdeči kanal, desno: zelen kanal, spodaj: moder kanal

V programu SAGA smo za izračun KVI uporabili ukaz `Grid -Calculus => Grid Division`, kjer je za izračun kvocienta potrebno izbrati mrežo zelenega in mrežo modrega kanala. Tako izračunan KVI smo uporabili kot drugi dodatni sloj v postopku objektne klasifikacije.

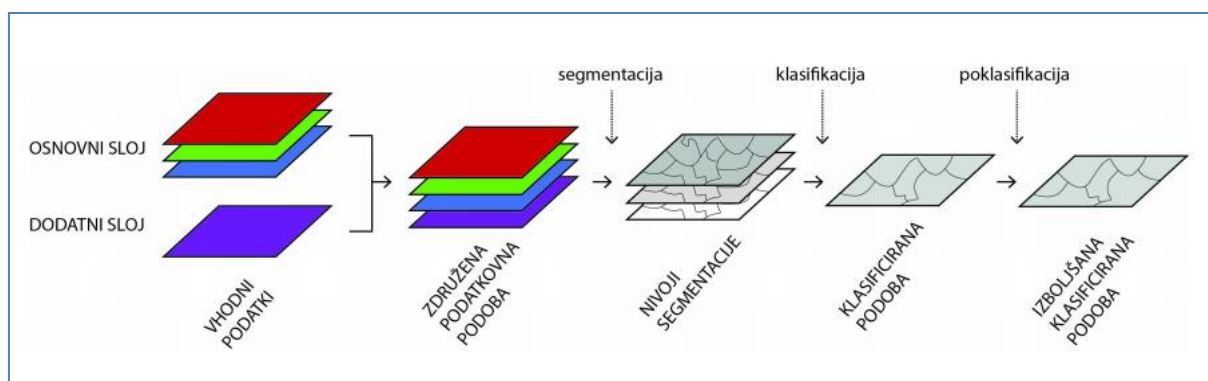
5.3 Izdelava podobe s petimi kanali

Osnovni sloj (RGB podoba) in dodatna sloja (nDMP in KVI) je za potrebe objektne klasifikacije v programu InterImage potrebno združiti v podobo s petimi kanali (5C podoba) (slika 14). Da bi bili združitev in klasifikacija lažji, smo vrednosti dodatnih slojev linearno »raztegnili« na isto zalogo vrednosti, kot jo ima osnovni sloj (8 bitov, vrednosti 0-255). Za to smo uporabili ukaz `Grid - Calculus => Grid Normalisation`, kjer smo namesto privzete zaloge vrednosti 0-1, nastavili zalogo vrednosti osnovnega sloja, ki je 0-255. Osnovni sloj iz programa SAGA z ukazom `Import/Export Grids => Export Image` izvozimo v format .tif, dodatna sloja pa z ukazom `Import/Export Grids => Export True Color Bitmap` v format .bmp. SAGA z ukazom `Export Image` izdelava tri-kanalne podobe. Dodatna sloja, ki sta enokanalna, je potrebno izvoziti z ukazom `Export True Color Bitmap`, saj se v tem primeru vrednosti zapišejo v prvi (od treh) kanal bmp podobe in je tako nadaljnja obdelava preprostejša.

Zaradi večje preglednosti in lažjega postopka smo združitev slojev v 5C podobo opravili v programu Photoshop. Osnovnemu sloju (RGB podoba), ki je sestavljen iz treh kanalov, je potrebno dodati dva nova kanala. To storimo tako, da prvi kanal (kanal z vrednostmi nDMP in KVI) bmp podob dodatnih slojev kopiramo v RGB podobo. Ta dva kanala se prevzeto v Photoshopu imenujeta Alfa1 in Alfa2. Tako smo pridobili 5C podobo, ki je na prvih treh kanalih imela R, G in B. Četrty sloj (Alfa1) je vseboval vrednosti nDMP, peti (Alfa2) pa vrednosti KVI. Tako dobljeno 5C podobo shranimo v format .tif.

6 OBJEKTNA KLASIFIKACIJA

Glavni namen klasifikacije je razpoznavanje in poimenovanje elementov (geografskih objektov in pojavov) na zemeljskem površju iz posnetka. Danes je objektno usmerjena analiza na prostorskih podatkih že dozorela in velja splošno soglasje, da objektna analiza podob temelji na konceptih segmentacije, odkrivanja robov, prepoznavanja in razvrščanja objektov (klasifikacije) (slika 14), ki so se v obdelavi podob daljinskega zaznavanja uporabljali že desetletja (Veljanovski in sod., 2011). Slaba stran objektno klasifikacije je, da je težko določiti »najboljše« attribute za razvrstitev v razrede, saj se ti lahko zelo razlikujejo od posnetka do posnetka. Ponavadi je za to potrebna kombinacija poizkusov, napak ter izkušenj (Gronemeyer, 2013).



Slika 14: Proces klasifikacije (Veljanovski in sod., 2011, str. 649)

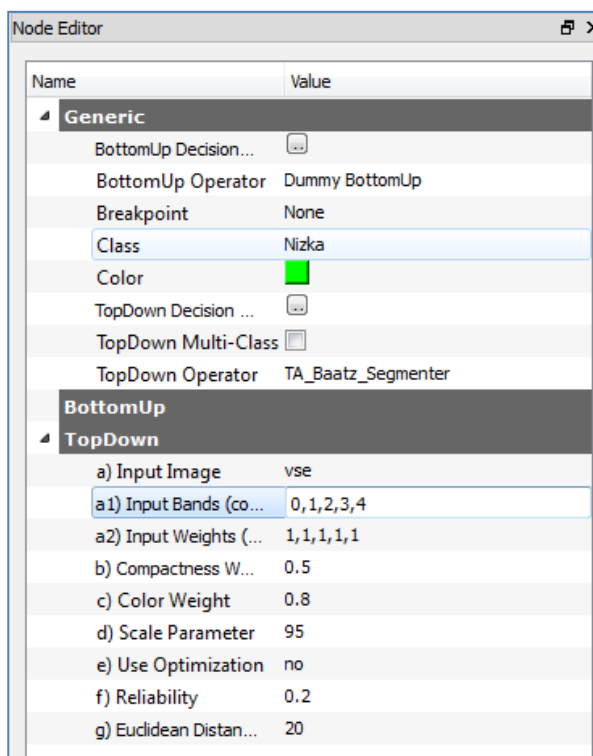
6.1 Segmentacija

Segmentacija je sestavni del objektno klasifikacije. Pri segmentaciji gre za združevanje sosednjih pikslov s podobnimi atributi na podlagi več kriterijev homogenosti. V objektno usmerjenih analizah je najtežja naloga zadovoljivo izvesti segmentacijo – z enim postopkom doseči pravo raven predstavitve po velikosti in lastnosti različnih prostorskih enot. Tako ustvarjeni segmenti predstavljajo realne objekte na posnetku ali njihove dele, ki jih nato v procesu objektno klasifikacije na podlagi različnih parametrov razporedimo v pripadajoči objektni razred (Veljanovski in sod., 2011).


V programu InterImage smo najprej izvedli segmentacijo združene podobe, sestavljene iz RGB podobe, z dodatnim slojem nDMP. Izkazalo se je, da so nekatera območja, kjer je visoka vegetacija blizu stavb, slabo segmentirana. Za ločitev med vegetacijo in ostalimi objekti se ponavadi uporablja infra-rdeči kanal, iz katerega je možno izračunati vegetacijski indeks. Naši podatki niso vsebovali tega kanala, zato smo se odločili, da izračunamo kvazi vegetacijski indeks iz modrega in zelenega kanala. Ta sloj smo dodali prejšnji združeni podobi in kakovost segmentacije se je izboljšala. Zaradi raziskovalnega namena smo izvedli še segmentacijo RGB podobe brez dodatnih slojev, da preverimo ali se kvaliteta segmentacije z vključitvijo sloja nDMP izboljša.

V programu InterImage imamo na izbiro več algoritmov za segmentacijo. Za vse naše poizkuse segmentacije smo uporabili algoritem TA Baatz Segmenter. Ta segmentacija je objektno usmerjena multispektralna segmentacija, v kateri je vsaka odločitev za združitev pikslov v segment odvisna od atributov predhodno združenih segmentov na obravnavani podobi (Baatz in sod., 2013).


Sam postopek segmentacije je takšen, kot je opisan v diplomski nalogi Štefan, 2012. V oknu Node Editor je potrebno spremeniti nekaj nastavitev. Spreminjamo jih glede na število kanalov, ki jih ima podoba ter pričakovano stopnjo segmentacije, ki je določena preko Scale Parametra (slika 15).




Slika 15: Okno NodeEditor programa InterImage (primer nastavitev za segmentacijo podobe s petimi kanali)



Slika 16: Segmentacija RGB sloja. ScaleParameter=80, 179 segmentov



Slika 17: Segmentacija RGB in nDMP sloja. ScaleParameter=110, 182 segmentov



Slika 18: Segmentacija RGB, nDMP in KVI sloja. ScaleParameter=120, 173 segmentov

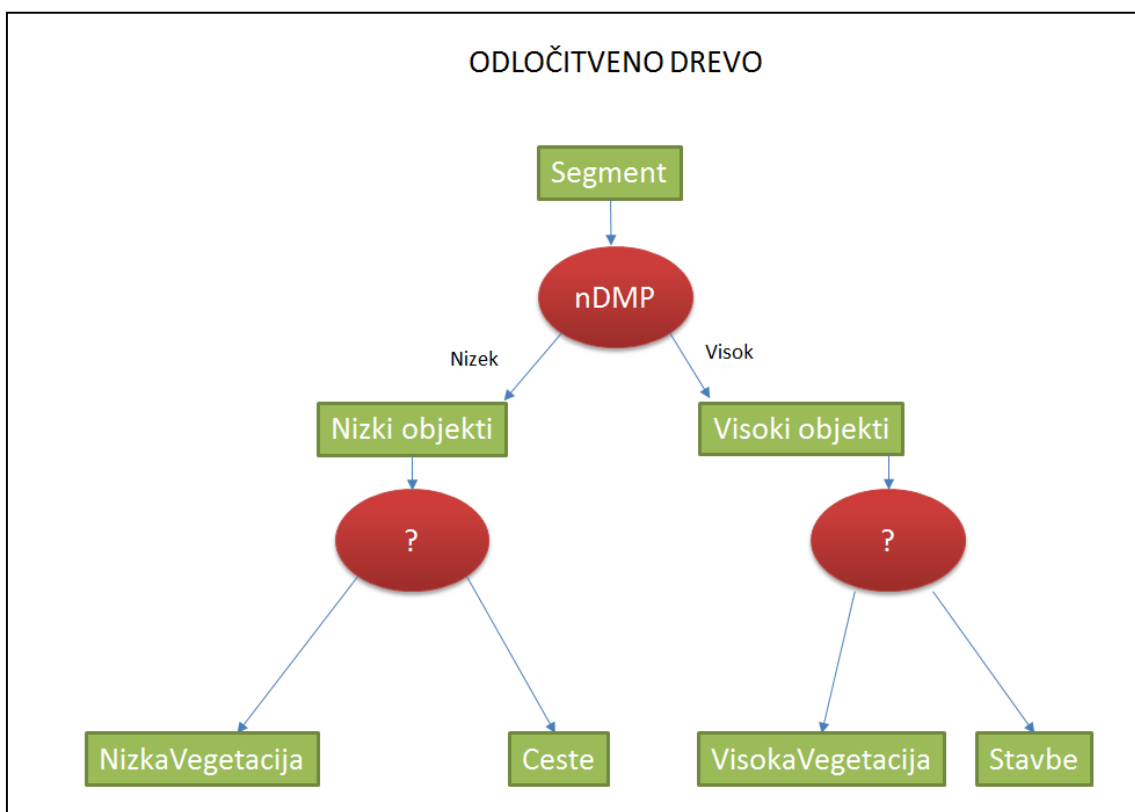
Scale parameter je nastavitev, ki določa stopnjo segmentacije – manjši kot je ScaleParameter, manjši bodo segmenti, vendar to ne pomeni, da bo segmentacija kvalitetnejša, saj lahko hitro pride do prekomerne segmentacije (Veljanovski in sod., 2011). Cilj je izvesti segmentacijo tako, da je v vsakem segmentu en ali več objektov „istega”objektnega razreda. ScaleParameter smo izbirali tako, da je bilo število segmentov pri vseh treh segmentacijah približno enako. Zgornji in spodnji pravokotnik na slikah 16-18 predstavljata dve „kritični” območji pri naši klasifikaciji. Zgornje kritično območje zajema visoko vegetacijo, ki nekoliko prekriva streho hiše. Spodnje kritično območje pa zajema hišo z dvoriščem.

Po izvedbi prve segmentacije (slika 16) sta kritični območji napačno segmentirani, saj imajo piksli preveč podobne lastnosti pri tej stopnji segmentacije. Druga segmentacija (slika 17) reši kritično območje spodnjega pravokotnika. Ker imamo podatke o višinah, ta segmentacija dobro loči dvorišče od stavbe, čeprav sta ta dva segmenta barvno podobna. Še vedno imamo nerešeno zgornje kritično območje, saj sta visoka vegetacija in streha stavbe isto visoka ter imata podobno barvo. Tretja segmentacija (slika 18), ki vsebuje KVI, reši problem zgornjega kritičnega območja, saj vključitev tega dodatnega sloja omogoča boljšo ločitev vegetacije od ostalih objektov.

Te tri vrste segmentacije kažejo, da je izbira vhodnih podatkov za segmentacijo pomembna. Ker je tretja segmentacija najbolj kvalitetna, smo ta rezultat uporabili za klasifikacijo.

6.2 Klasifikacija

Po končani segmentaciji smo izvedli klasifikacijo teh segmentov (klasifikacija) po postopku odločitvenih dreves. Postopek odločitvenih dreves temelji na opredelitvi pravil na podlagi reprezentativnih mejnih vrednosti (Veljanovski in sod., 2011). Odločili smo se, da na podlagi višin, ki so signifikanten parameter, segmente klasificiramo v dva nadrazreda in sicer *Nizki objekti* ter *Visoki objekti*. *Nizki objekti* se nato razdelijo na *Nizko vegetacijo* in *Ceste*, *Visoki objekti* pa na *Visoko vegetacijo* in *Stavbe*. Objektni razred *Nizka vegetacija* zajema objekte nizke vegetacije (travniki, njive in nizko grmičevje). Objektni razred *Ceste* zajema nizke zidane površine (ceste, dvorišča,..). Objektni razred *Visoka vegetacija* zajema objekte visoke vegetacije (drevesa in visoke grme). Objektni razred *Stavbe* zajema stavbe. Ostali parametri in njihove vrednosti so bili določeni z vrsto poizkusov. Sestava odločitvenega drevesa je prikazana na sliki 19.



Slika 19: Odločitveno drevo

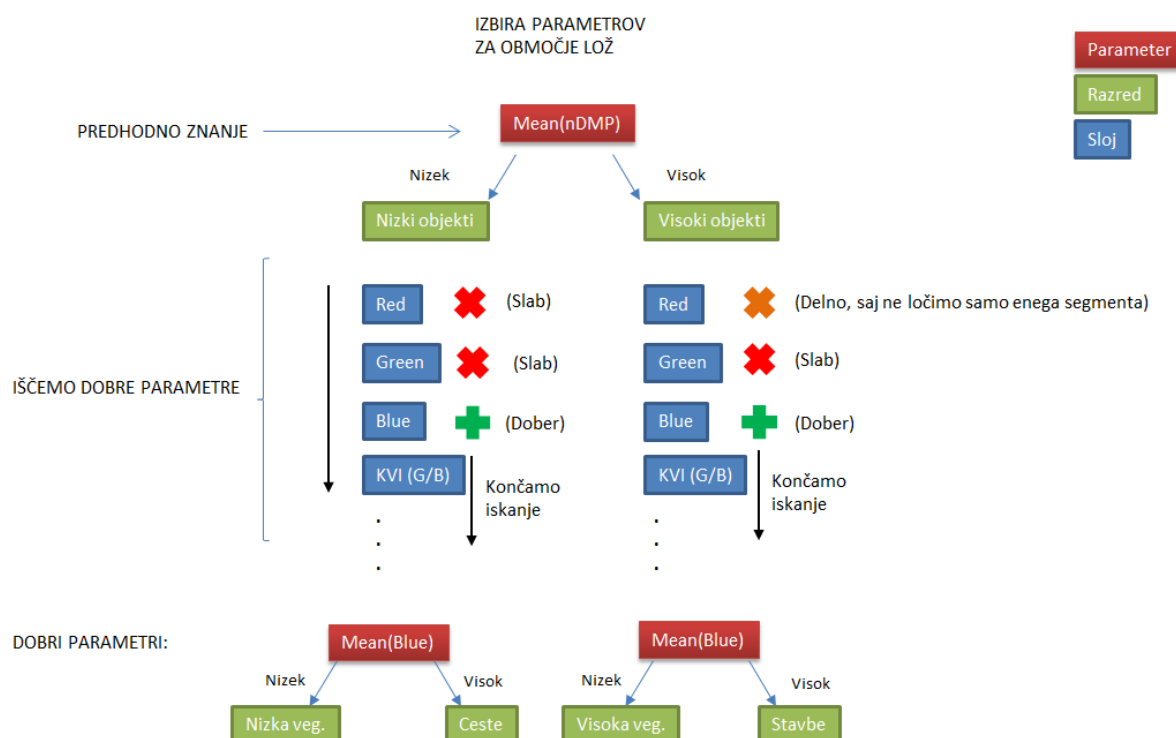
Postopek klasifikacije je podoben postopku, ki je opisan v diplomski nalogi Štefana D. (Štefan, 2012). Pri izbiri neznanih parametrov smo poizkušali najprej izbrati najbolj očitne parametre (srednje vrednosti petih slojev posnetka) in določiti robne vrednosti. Ko smo našli dober parameter, smo z iskanjem končali. Ker je bila segmentacija dobro narejena, je bila izbira parametrov in njihovih

vrednosti dokaj enostavna. Primer vrednosti parametrov za klasifikacijo objektnega razreda *Nizka vegetacija* prikazuje slika 20:



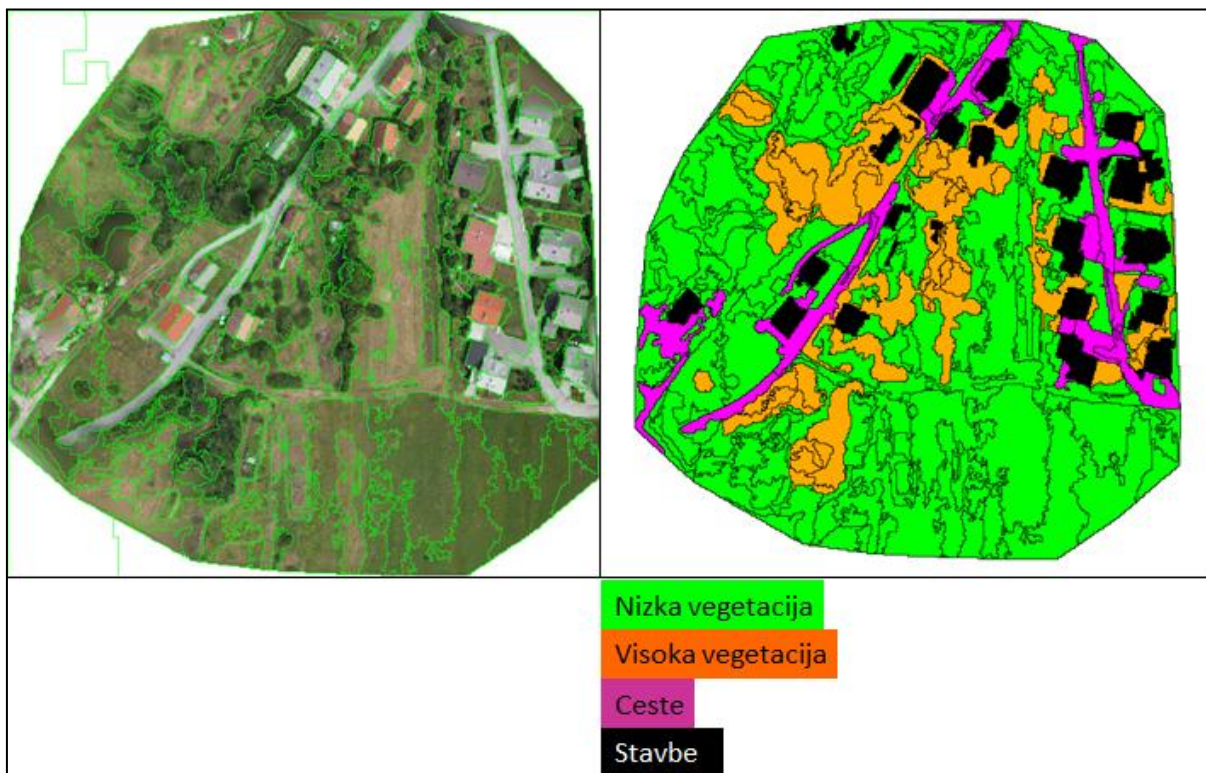
Slika 20: Parametri za razred Nizka vegetacija

Postopek iskanja parametrov in rezultati so predstavljeni na sliki 21.



Slika 21: Rezultat iskanja parametrov

Vizualna ocenitev klasifikacije pove, da je bila klasifikacija uspešna, kot je prikazano na sliki 22.



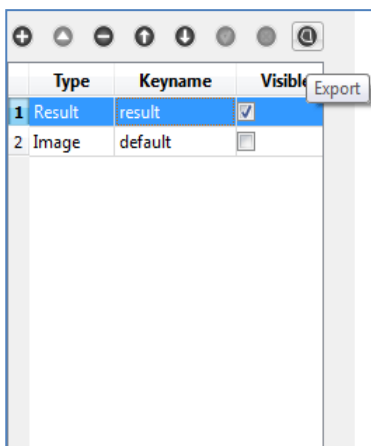
Slika 22: Rezultat klasifikacije prve podobe. Levo segmentirana podoba, desno klasificirana podoba. Uporabljena parametra sta Mean(nDMP) ter Mean(Blue)

6.3 Izdelava in analiza histogramov

Histogrami so bili zaradi boljše predstavitve in preučitve razporeditve vrednosti posameznih objektnih razredov izdelani po štirih kanalih. Kanal nDMP smo izpustili, saj so na podlagi vrednosti nDMP segmenti ločeni na *Nizke* ter na *Visoke objekte*. Hoteli smo vedeti ali je razporeditev vrednosti R, G, B in KVI takšna, da omogoča enolično klasifikacijo. Predvsem smo se osredotočili na iskanje specifične razporeditve vrednosti in lastnosti razporeditev, ki bi nam pomagale pri ločitvi objektnih razredov drugega oblaka točk.

6.3.1 Izdelava histogramov

Ko je klasifikacija v programu InterImage končana, lahko oblike posameznih objektnih razredov izvozimo v datoteko z zapisom .shp. To storimo tako, da kliknemo na ustvarjeni sloj result in izberemo ukaz export (slika 23). Pokaže se nam okno za izvoz shapefile datoteke, kjer v vrstici Class izberemo objektni razred, ki ga hočemo izvoziti.



Slika 23: Export .SHP

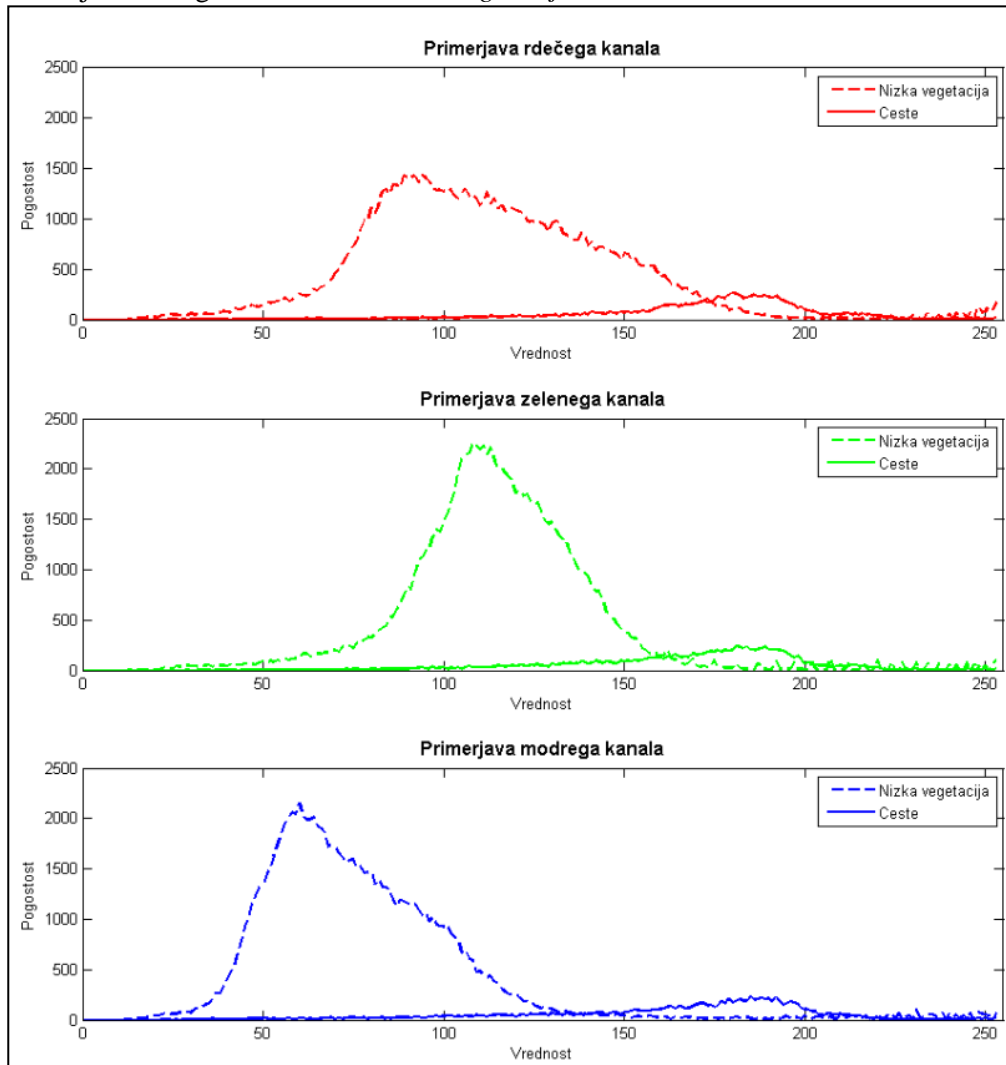

Zaradi večje preglednosti in lažjega postopka smo postopek nadaljevali v programu PhotoShop. Ker PhotoShop ne podpira .shp zapisa smo pred tem morali spremeniti shape v raster istih dimenzij, kot je 5C podoba (za to smo uporabili program SAGA). V programu Photoshop iz poligonov objektnega razreda naredimo »masko«, s katero prekrijemo vse razen izbranega objektnega razreda. Pomagali smo si z ukazom Select Color Range (izbrali smo vse razen poligona objektnega razreda). To masko kopiramo kot nov sloj v okno 5C podobe. Sedaj na tem novem sloju uporabimo ukaz Create Clipping Mask, in na sloju 5C podobe ukaz Merge Clipping Mask. Primer podobe po ukazu Merge Clipping Mask za objektni razred ceste je prikazan na sliki 24. Ukaz Merge Clipping Mask se izvede samo za RGB kanale. Za kanala nDMP in KVI, ki sta v Photoshopu prevzeta poimenovana Alfa1 in Alfa2 (četrti in peti sloj), moramo masko kopirati iz enega izmed kanalov sloja poligona objektnega razreda. Pozorni moramo biti, da je maska « čiste» bele barve [255, 255, 255], saj jo bomo tako pozneje lažje izločili iz histogramov.



Slika 24: Objektni razred Ceste, po obdelavi v programu PhotoShop

6.3.2 Analiza histogramov

Primerjavo histogramov smo razdelili v dve skupini. V prvi skupini smo primerjali histograme med *Cestami* in *Nizko vegetacijo*. V drugi skupini pa smo primerjali histograme med *Stavbami* ter *Visoko vegetacijo*. Potrebno je omeniti, da so bili histogrami narejeni iz pikselov posameznega objektnega razreda, parametri za ločitev med posameznimi segmenti (poglavja 6.1 in 6.2) pa veljajo za določen segment, ki je sestavljen iz teh pikselov.

Primerjava histogramov *Cest* in *Nizke vegetacije*.Slika 25: RGB histogrami *Cest* in *Nizke vegetacije*Slika 26: KVI histogram *Cest* in *Nizke vegetacije*

Iz vizualne ocene RGB histogramov *Ceste* (sliki 25 in 26) vidimo, da imajo piksli zalogo vrednosti med 125 in 220 za vse tri barvne vrednosti. Histogrami so podobni, zato lahko sklepamo, da gre večinoma za sivo barvo. Histogram ima približno zvonasto razporeditev, saj gre za piksele, ki predstavljajo eno vrsto objektov. Raporeditev KVI histograma prav tako kaže na to, da gre za eno vrsto objektov.

Iz vizualne ocene RGB histogramov *Nizka vegetacija* vidimo, da ima nizka vegetacije najvišje vrednosti v zelenem kanalu, najnižje pa v modrem kanalu. Ima zvonasto razporeditev, saj gre za piksele, ki predstavljajo eno vrsto objektov. Iz vizualne ocene KVI histograma vidimo, da je bimodalno razporejena, kar kaže da gre za dve značilni vrsti objektov znotraja objektov nizke vegetacije.

Iz slike 26, kjer je prikazan histogram KVI za objektni razred *Nizka vegetacija*, lahko razberemo, da je mejna vrednost parametra med značilnima vrstama objektov znotraj objektnega razreda *Nizka vegetacija* približno 60. To smo preizkusili v programu InterImage, kjer smo za osnovni sloj uporabili podobo, ki predstavlja samo nizko vegetacijo. Opazimo, da značilna vrsta objektov, ki ima nizek KVI (manjši od 60), predstavlja nizko vegetacijo z malo zelenja (slika 27). Vrsta objektov, ki ima velik KVI (večji od 60), pa predstavlja nizko vegetacijo z veliko zelenja.

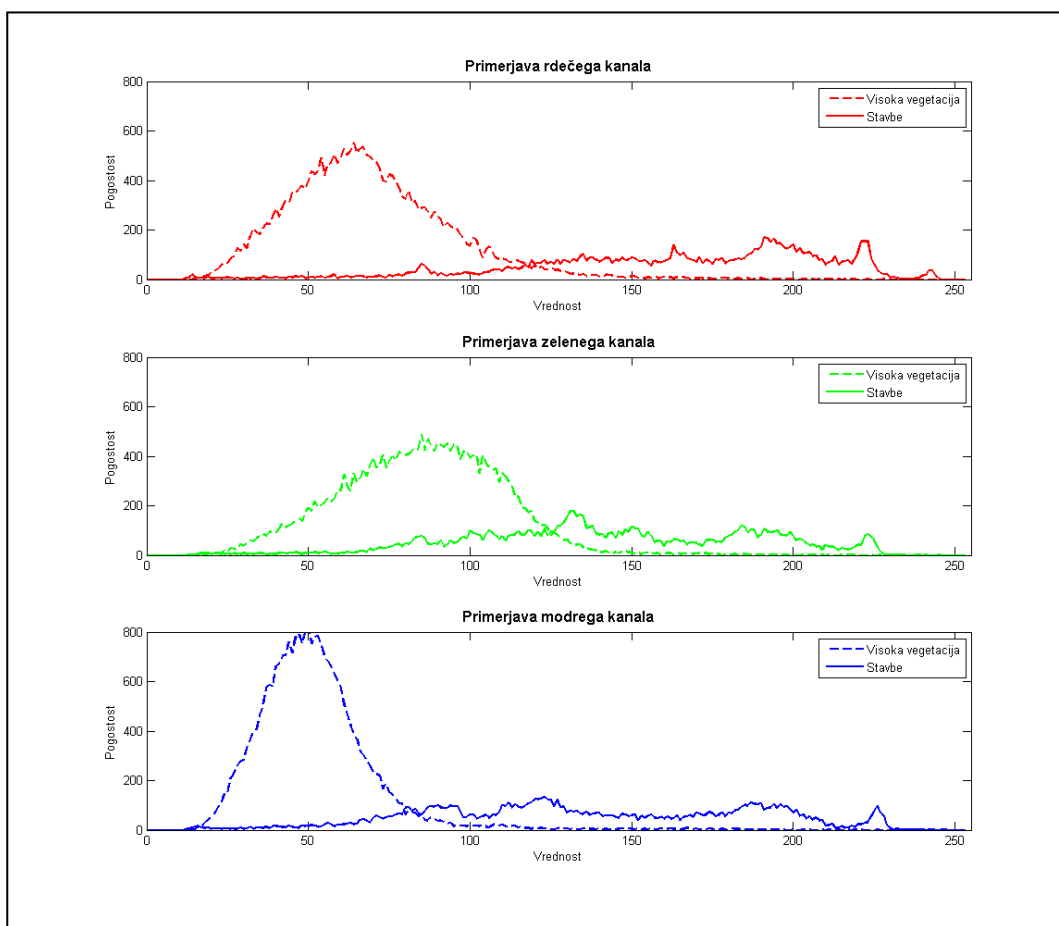


Slika 27: Značilna vrsta objektov objektnega razreda *Nizki objekti*. Objekti, ki imajo parameter KVI manjši od 60, so prikazani s svetlo zeleno barvo


Ugotovitve:

Iz površine histogramov RGB sklepamo, da je število pikslov *Nizke vegetacije* večje od števila pikslov *Ceste* na obravnavani podobi. Iz zaloge vrednosti sklepamo, da so ceste na posnetku svetlejšje od nizke vegetacije. Objektne razreda v vrednosti modrega kanala zavzemata specifične vrednosti iz česar sklepamo, da sta med sabo ločljiva po tej vrednosti, kar smo potrdili v klasifikaciji. Histogram KVI prav tako kaže, da je ločitev teh dveh objektnih razredov med sabo možna po vrednosti KVI, saj zavzemata specifične vrednosti.

Primerjava histogramov *Stavb* in *Visoke vegetacije*.



Slika 28: RGB histogrami *Stavb* in *Visoke vegetacije*



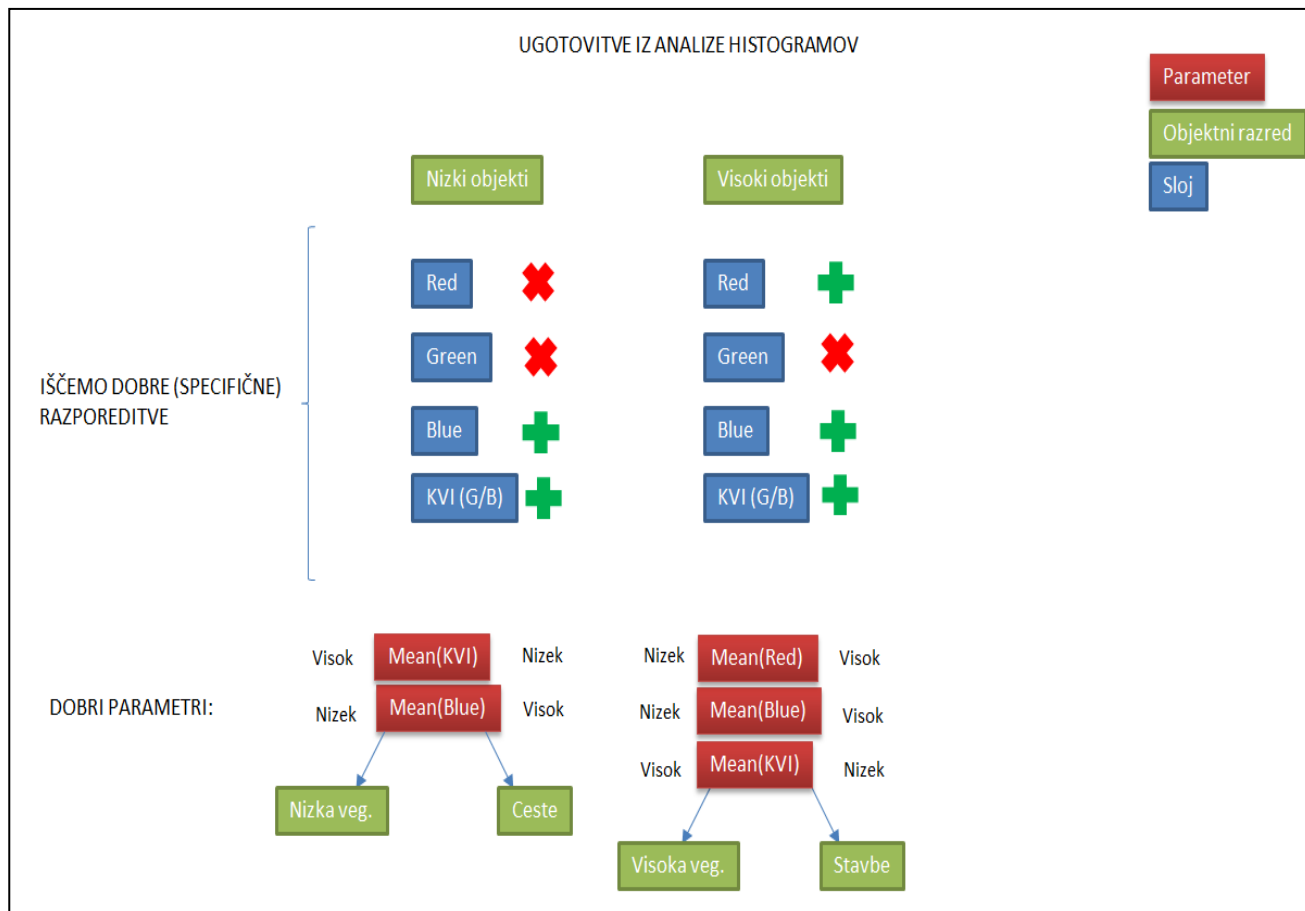
Slika 29: KVI Histogram *Stavb* in *Visoke vegetacije*

Iz vizualne ocene RGB histogramov *Visoke vegetacije* (sliki 28 in 29) vidimo, da ima visoka vegetacije najvišje vrednosti v zelenem kanalu, najnižje pa v modrem kanalu. Ima približno zvonasto razporeditev, saj gre za piksele, ki predstavljajo eno vrsto objektov. Razporeditev KVI histograma prav tako kaže na to, da gre za eno vrsto objektov.

Iz vizualne ocene RGB histogramov *Stavbe* vidimo, da ni prevladujoče vrste objektov tega objektnega razreda. Lahko opazimo nekaj vrhov, vendar je vzorec podatkov premajhen, da bi bil statistični opis teh podatkov možen. Piksli objektnega razreda *Stavbe* so barve streh stavb in imajo široko zalogo vrednosti.

Ugotovitve:

Iz površine histogramov RGB sklepamo, da je število pikslov visoke vegetacije večje od števila pikslov stavb na obravnavani podobi. Iz zaloge vrednosti sklepamo, da so stavbe na našem posnetku svetlejše od visoke vegetacije. Objektne razreda v vrednosti rdečega in modrega kanala zavzemata specifične vrednosti iz česar sklepamo, da sta med sabo ločljiva po tej vrednosti, kar smo delno potrdili v klasifikaciji. Histogram KVI prav tako kaže, da je ločitev teh dveh objektnih razredov med sabo možna po vrednosti KVI, saj zavzemata specifične vrednosti.



Slika 30: Ugotovitve analize histogramov

Iz analize histogramov za sloje R, G, B in KVI smo ugotovili, da poleg parametrov, ki smo jih uporabili v klasifikaciji, obstaja še najmanj en parameter, s katerim je klasifikacija možna (slika 30). To je parameter mean(KVI) , ki je izračunan kot povprečje segmenta v sloju KVI. Ker smo KVI uporabili že pri segmentaciji za izboljšanje kvalitete segmentacije, je ta izsledek pričakovan. Parameter je dober za klasifikacijo znotraj *Nizkih* ter znotraj *Visokih objektov*. Opazili smo tudi, da parameter Mean(Red) dobro loči med sabo objektna razreda *Visoka vegetacija* in *Stavbe* (pri klasifikaciji je bil s tem parametrom napačno klasificiran le en segment).

6.4 Uporaba znanja na drugi podobi

Za raziskovalne namene smo se odločili shemo odločitvenega drevesa ter parametre, ki so bili ugotovljeni kot »dobri« pri analizi histogramov, preizkusiti na drugi podobi (slika 31). Oblak točk druge podobe je bil prav tako pridobljen od podjetja MODRI PLANET. Postopek izdelave podobe s petimi kanali tega območja je podoben postopku izdelavi podobe s petimi kanali prejšnjega območja.

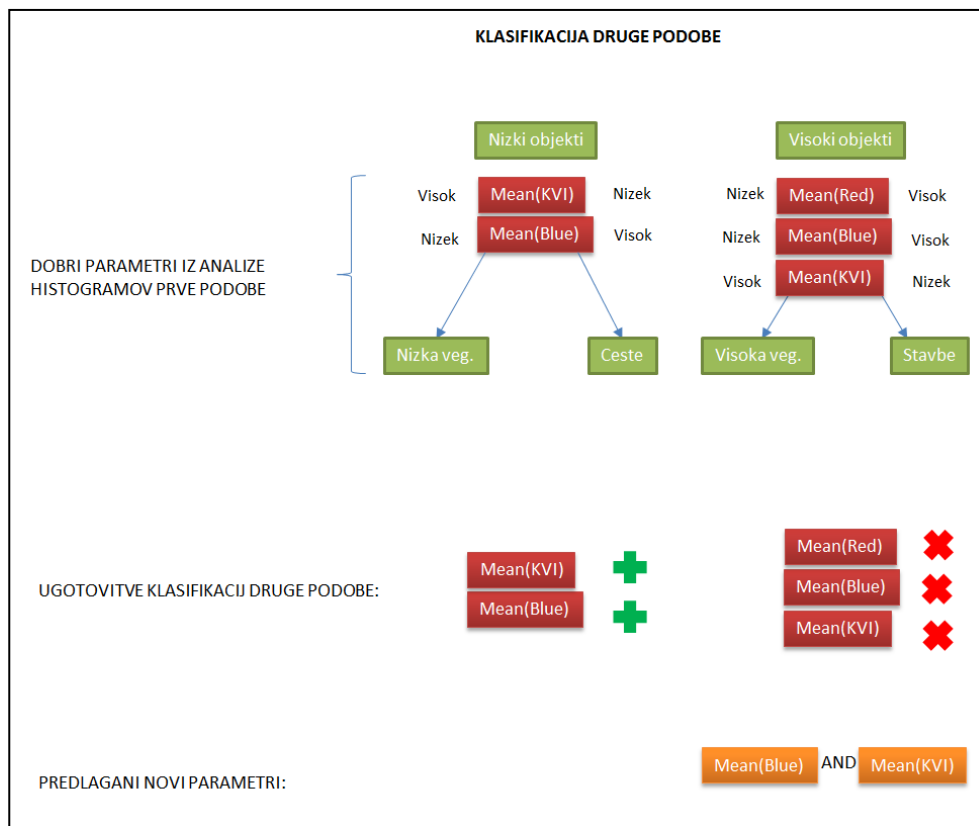


Slika 31: Drugo obravnavano območje, Hrašenski Vrh

6.4.1 Klasifikacija druge podobe

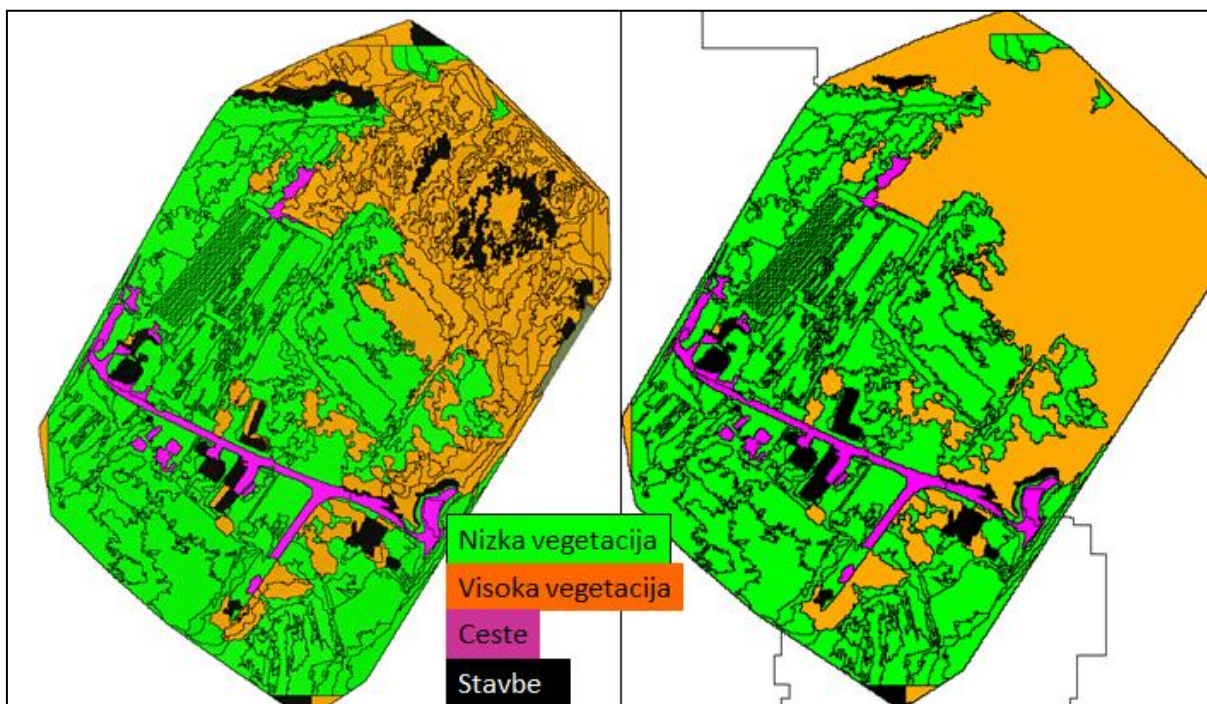
Klasifikacijo smo najprej izvedli tako, da smo uporabljali isto odločitveno drevo ter iste parametre, kot so bili ugotovljeni iz analize histogramov prve podobe. Pozorni moramo biti pri izbiri vrednosti sloja nDMP, saj ne moremo vzeti iste vrednosti parametra kot pri 5C podobi prvega oblaka točk. Vrednosti sloja nDMP v 5C posnetku so pridobljene tako, da smo zalogo vrednosti nDMP sloja raztegnili na polno zalogo vrednosti 8-bitnih podob [0,255]. Ker ima nDMP drugega oblaka točk zaradi različno visokih objektov drugačno zalogo vrednosti kot nDMP prvega oblaka točk, je rezultat »raztezka« tudi drugačen. Pri 5C podobi prvega oblaka točk je bila mejna vrednost nDMP sloja za ločitev med *Nizkimi* in *Visokimi objekti* 20, medtem ko je pri drugem oblaku točk ta vrednost 15. Obe vrednosti predstavljata vrednost 1,5 m v realnih višinah.

Nato smo preizkusili parametre za ločevanje med *Visokimi* in *Nizkimi objekti*. Ugotovili smo, da je klasifikacija *Nizkih objektov* z istimi parametri možna. Pri klasifikaciji *Visokih Objektov* smo odkrili, da klasifikacija z nobenim od parametrov, ki so bili v prvi podobi ocenjeni kot dobri, ni možna v celoti. Za konec smo predlagali in izvedli klasifikacijo z novim pogojem, kakor je predstavljeno na sliki 32.



Slika 32 : Parametri klasifikacije druge podobe

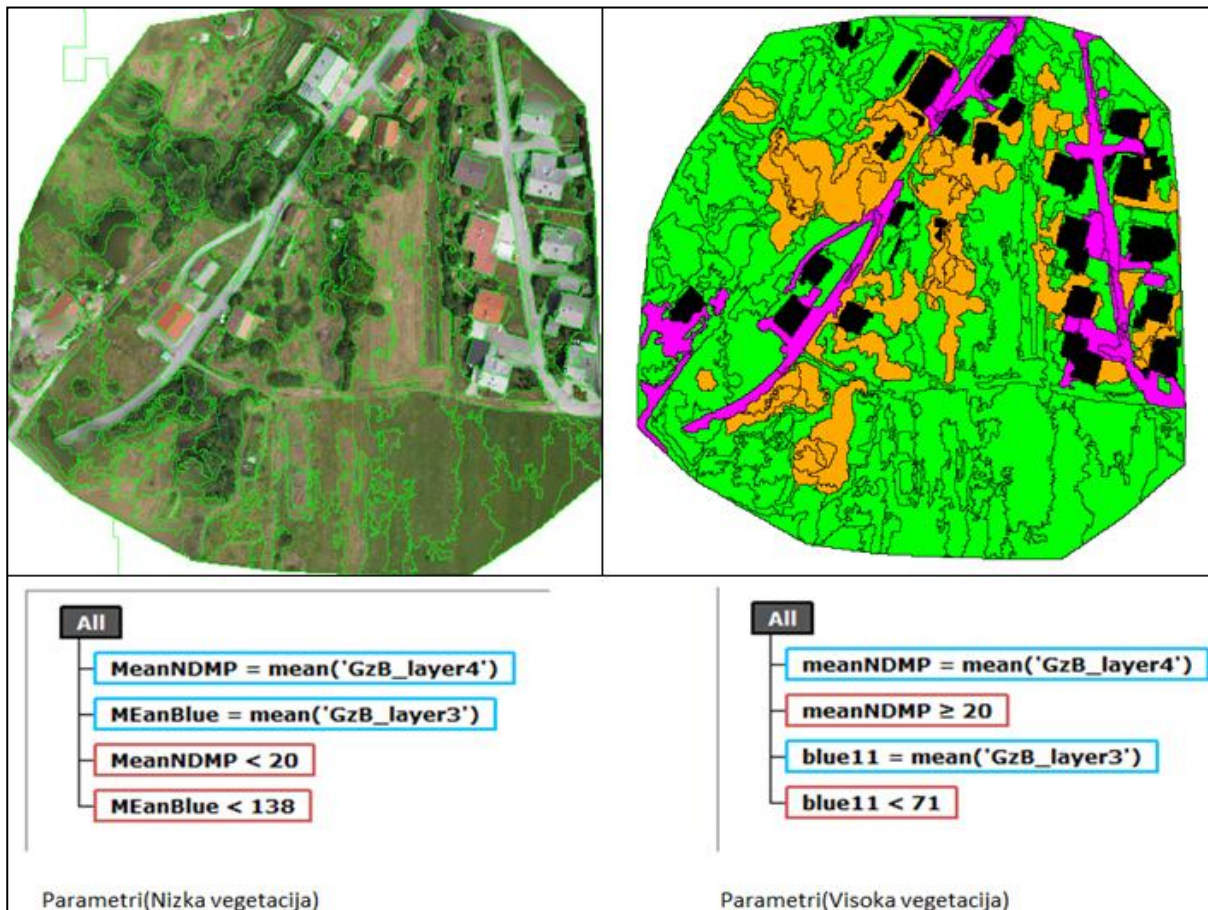
Na sliki 33 (levo) je predstavljena klasifikacija druge podobe z uporabo parametrov, ki so bili ugotovljeni kot dobri pri analizi histogramov prve podobe. Nato smo za *Visoke objekte* spremenili parametre in tako dobili boljše rezultate klasifikacije (slika 33, desno).



Slika 33: Klasifikaciji z istimi parametri ter dodanim pogojem. Levo: isti parametri, desno dodan pogoj

7 REZULTATI IN KOMENTAR


Rezultati naloge so klasificirane podobe prvega in drugega območja ter izpis parametrov, s katerimi so bile podobe klasificirane.



Slika 34: Klasifikacija 5C podobe prvega območja, Stari trg pri Ložu

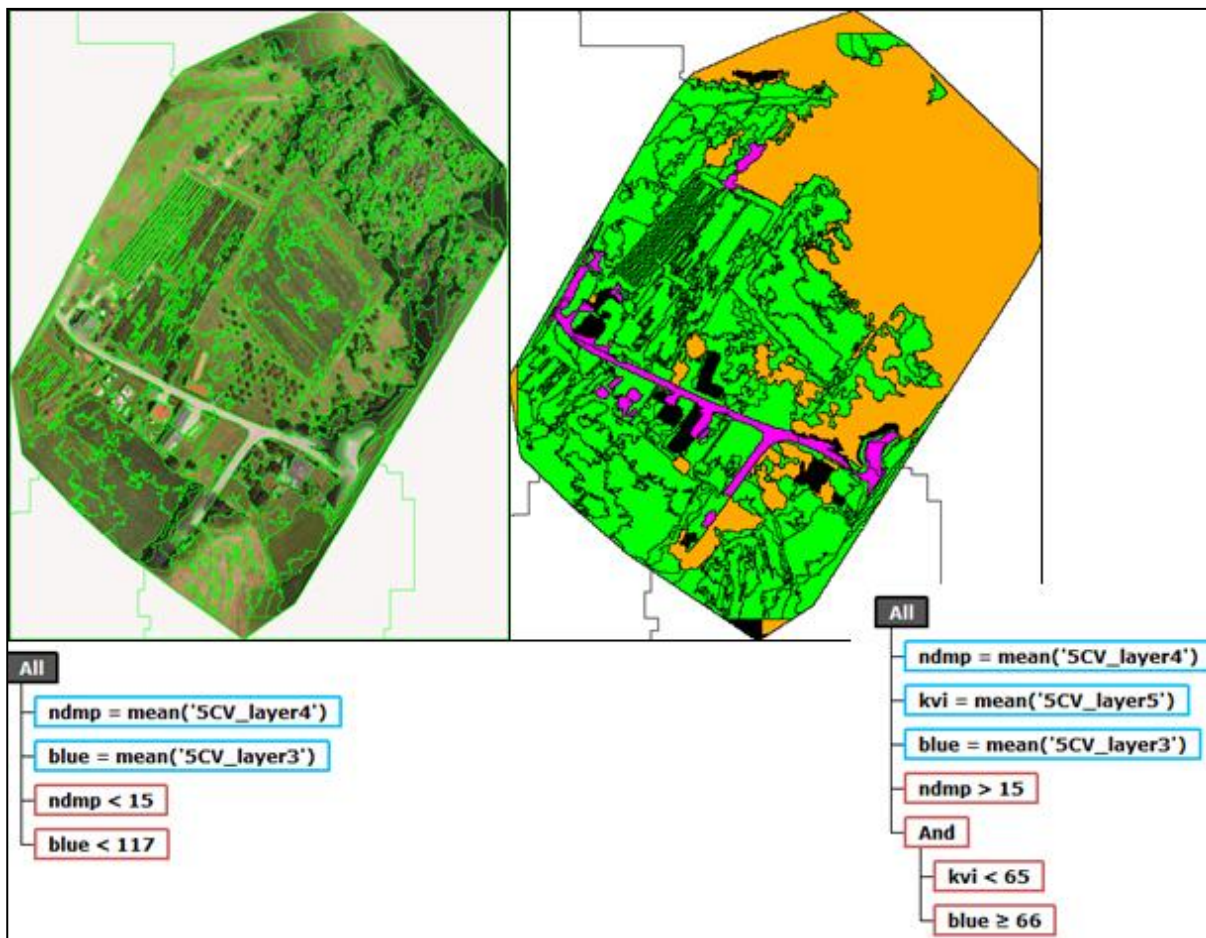
Izpisani so parametri za objektna razreda (slika 34) *Nizka vegetacija* (levo) ter *Visoka vegetacija* (desno). Za ostala dva objektna razreda uporabimo obratne vrednosti (obrnemo neenačaje). Uporabljeni parametri: Mean(nDMP), Mean(Blue). Rezultat je bila popolna klasifikacija vseh segmentov, saj z vizualno oceno ni bilo mogoče odkriti napak pri klasifikaciji.

Po uspešni klasifikaciji prve podobe smo naredili analizo histogramov ter uporabili parametre, ki so bili ugotovljeni kot dobri, v klasifikaciji podobe drugega območja.



Slika 35: Eden izmed neupelih poizkusov klasifikacije druge podobe. Segmentirana podoba (levo) ter klasificirana podoba (desno)

Vidimo, da je klasifikacija med *Nizkimi objekti* bila uspešna, medtem ko je pri klasifikaciji *Visokih objektov* prišlo do opaznih napak (slika 35). Nato smo izvedli klasifikacijo tako, da smo uvedli nov pogoj parametrov za klasifikacijo *Visokih objektov* z namenom izboljšanja kakovosti klasifikacije (slika 36).



Slika 36: Klasifikacija podobe drugega območja z novim pogojem za klasifikacijo *Visokih objektov*.

Novi pogoj je And, ki zahteva, da morajo biti izpolnjeni vsi podpogoji, ki se nahajajo pod tem pogojem. Vidimo, da je klasifikacija *Visokih objektov* z novim pogojem bolj uspešna. Na desni strani so parametri za *Stavbe*. V tem primeru za *Visoko vegetacijo* ne moremo dati obratnih parametrov, saj bi tako pridobili neklasificirane segmente. Uporabimo lahko operator, ki neklasificiranem segmentom pove, da spadajo v izbrani razred. V NodeEditorju izberemo TopDownOperator - dummy top down.

8 ZAKLJUČEK

V diplomski nalogi smo izvedli postopek interpolacije fotogrametrično določenega oblaka točk po barvnih kanalih (RGB) in izdelali DMP. Nato smo izdelali dva dodatna sloja iz teh interpoliranih podatkov, in sicer nDMP (DMP minus DMR) ter kvazi vegetacijski indeks ($KVI = G/B$). Iz teh slojev smo izdelali podobo s petimi kanali (R, G, B, nDMP, KVI). S preizkusi smo preverili, kako se spreminja kakovost segmentacije z dodajanjem teh dveh dodatnih slojev in spoznali, da se je z dodanim nDMP segmentacija na območjih istih barv ter različnih višin izboljšala. Ko smo dodali še sloj KVI, se je segmentacija izboljšala na območjih istih višin ter barv.

Na najbolj kakovostni segmentaciji, ki je bila ocenjena vizualno, smo izvedli klasifikacijo, kjer smo za ločitev med *Visokimi* in *Nizkimi objekti* uporabili vrednost nDMP kanala. Pokazali smo postopek iskanje dobrih parametrov za ločitev med *Nizko vegetacijo* in *Cestami* znotraj nadrazreda *Nizki objekti* ter ločitev med *Vegetacijo* in *Stavbami* znotraj nadrazreda *Visoki objekti*. Poizkusili smo zaporedno iskanje robnih parametrov po kanalih iz katerih je sestavljena podoba. Najprej smo poizkusili poiskati ustrezen robni parameter v kanalu z rdečo radiometrično vrednostjo, nato v kanalu z zeleno, itd... Pokazali smo, da je takšno iskanje robnih parametrov možno.

Ko smo s klasifikacijo končali, smo izdelali histograme z namenom preučitve razporeda vrednosti znotraj nadrazreda *Visoki objekti* ter znotraj nadrazreda *Nizki objekti*. Opazili smo, da so vrednosti za *Ceste* in *Nizko vegetacijo* v kanalih B in KVI specifične (histogrami se ne prekrivajo). Zaključili smo, da *Ceste* zavzemajo visoke vrednosti v kanalu B ter nizke v kanalu KVI. Obratno velja za *Nizko vegetacijo*. Prav tako smo opazili, da so vrednosti za *Stavbe* in *Visoko vegetacijo* specifične v kanalih R, B in KVI. Tako smo pridobili še en dober parameter Mean(KVI) ter en delno dober parameter Mean(Red). Zaključili smo, da *Visoka vegetacija* zavzema nizke vrednosti v kanalih R in B ter visoke v kanalu KVI. Obratno velja za *Stavbe*. Mean(Red) je delno dober parameter, saj pride do nekaj prekrivanja.

Pridobljeno znanje iz analize histogramov smo preizkusili na drugem oblaku točk s podobno osvetlitvijo. Izkazalo se je, da parametri, ki so v prvem oblaku točk veljali kot dobri, veljajo samo za razred *Nizki objekti*. V klasifikaciji *Visokih objektov* pa se je izkazalo, da ti parametri niso dobri ter da je potreben nov pogoj, s katerim lahko z uporabo »starih« parametrov kakovostno klasificiramo drugo podobo. Razlog za to je v tem, da so radiometrične vrednosti cest, nizke in visoke vegetacije na vseh posnetkih »podobne«, medtem ko radiometrične vrednosti stavb zavzemajo preveč širok spekter, da bi bila klasifikacija iz enega oblaka točk ponovljiva na drugem oblaku točk.

VIRI

Baatz, M., Schäpe, A. 2013. Multiresolution Segmentation. An optimization approach for high quality multi-scale image segmentation. (Samozaložba Baatz, M., Schäpe, A.): 12 str.

Boissonnat, J.-D., Cazals, F. 2001. Smooth surface reconstruction via natural neighbour interpolation of distance functions. Computational Geometry 22: 158-203

Interpolation Wiki. 2013.

<http://en.wikipedia.org/wiki/Interpolation> (Pridobljeno 1. 5. 2013.)

Microdrones. 2013.

<http://www.microdrones.com/index.php> (Pridobljeno 1. 5. 2013.)

Modri planet. 2013.

<http://www.modriplanet.si/si> (Pridobljeno 1. 5. 2013)

Natural neighbour Wiki. 2013.

http://en.wikipedia.org/wiki/Natural_neighbour (Pridobljeno 1. 5. 2013.)

NDVI Wiki. 2013.

<http://en.wikipedia.org/wiki/NDVI> (Pridobljeno 1. 5. 2013.)

Oštir, K. 2006. Daljinsko zaznavanje. Ljubljana, Založba ZRC: 250 str.

Point cloud Wiki. 2013.

http://en.wikipedia.org/wiki/Point_cloud (Pridobljeno 1. 5. 2013.)

Rchelicoptfun. 2013.

<http://www.rchelicoptfun.com/> (Pridobljeno 1. 6. 2013.)

SAGA. 2013.

<http://www.saga-gis.org> (Pridobljeno 1. 5. 2013)

Sourceforge. 2013.

<http://sourceforge.net/apps/trac/saga-gis/wiki/Module%20Descriptions> (Pridobljeno 1. 5. 2013.)

Štefan, D. 2012. Uporaba odprtokodnih programov za objektno usmerjeno analizo visoko ločljivega posnetka daljinskega zaznavanja. Diplomski naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. (samozaložba D. Štefan): 37 str.

The LandscapeToolbox. 2013.

http://wiki.landscapetoolbox.org/doku.php/remote_sensing_methods:object-based_classification
(Pridobljeno 1. 5. 2013)

Veljanovski, T., Kanjir, U., Oštir, K. 2011. Objektno usmerjena analiza podatkov daljinskega zaznavanja. Geodetski vestnik 55, 4: 641-664.

W. Bater, C., C. Coops, N. 2009. Evaluating error associated with lidar-derived DEM interpolation. Computers and Geoscience 35: 289-300

<http://www.sciencedirect.com/science/article/pii/S0098300408002537> (Pridobljeno 1. 5. 2013.)