

Univerza
v Ljubljani
Fakulteta
*za gradbeništvo
in geodezijo*

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



Univerzitetni program Geodezija,
smer Geodezija

Kandidatka:

Urška Kanjir

Objektna klasifikacija rabe tal iz podatkov daljinskega zaznavanja

Diplomska naloga št.: 808

Mentor:

izr. prof. dr. Krištof Oštir

Somentor:

Aleš Marsetič

Ljubljana, 29. 9. 2009

ERRATA

Stran z napako	Vrstica z napako	Namesto	Naj bo
-----------------------	-------------------------	----------------	---------------

IZJAVA O AVTORSTVU

Podpisana **URŠKA KANJIR** izjavljam, da je diplomska naloga z naslovom »**OBJEKTNA KLASIFIKACIJA RABE TAL IZ PODATKOV DALJINSKEGA ZAZNAVANJA**« v celoti moje avtorsko delo.

Ljubljana, 24.9.2009

(podpis)

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK: 528.8:711.14(043.2)
Avtor: Urška Kanjir
Mentor: izr. prof. dr. Krištof Oštir
Naslov: Objektna klasifikacija rabe tal iz podatkov daljinskega zaznavanja
Obseg in oprema: 72 str., 10 pregl., 26 sl., 12 en., 3 pril.
Ključne besede: daljinsko zaznavanje, objektna klasifikacija, segmentacija, analiza podob, raba tal

Izvleček

Daljinsko zaznavanje je stroškovno učinkovit način za velika območja kartiranja pokrovnosti/rabe tal. Ker je razpoložljivost in zanesljivost teh kart zelo pomembna za številne znanosti o zemeljskem površju, je razvoj (pol)samodejnih klasifikacijskih postopkov bistvenega pomena. Za klasifikacijo podob, kjer so piksli večji ali v najboljšem primeru podobni (geografskim) objektom na podobi, prevladuje uporaba pikselske klasifikacije. S povečevanjem prostorske ločljivosti, delno pa tudi z izboljševanjem spektralnih značilnosti, pa so te »tradicionalne« klasifikacijske metode postale manj učinkovite, zato se vedno bolj uveljavlja objektno usmerjena klasifikacija. Objektna klasifikacija združuje kontekstno segmentacijo, ki je temeljna faza tovrstne klasifikacije, in samo klasifikacijo. Segmentacija razdeli podobo na relativno homogene in semantično značilne skupine pikslov (segmente) na podlagi enega ali več meril homogenosti. Pri postopku klasifikacije se poleg njihovih spektralnih lastnosti (barve) za razvrščanje upoštevajo tudi oblika in povezava med segmenti. V diplomski nalogi je objektna klasifikacija uporabljena kot orodje za določevanje rabe tal/pokrovnosti na primeru dveh študijskih območij v Sloveniji (Kobarid, Gornja Radgona) z različno prevladujočimi razredi pokrovnosti.

BIBLIOGRAPHIC – DOKUMENTACIJSKA STRAN AND ABSTRACT

UDC: 528.8:711.14(043.2)
Author: Urška Kanjir
Supervisor: assoc. prof. dr. Krištof Oštir
Title: Object oriented land use classification from remote sensing data
Notes: 72 p., 10 tab., 26 fig., 12 eq., 3 ann.
Key words: remote sensing, object based classification, segmentation, image analysis, land use

Abstract

Remote sensing is a cost-effective way for large area land cover/land use mapping availability. The reliability of these maps is very important for many of the Earth sciences and the development of (semi) automatic classification procedures is therefore essential. As long as pixel size remains coarser than, or at the best similar, in size to the (geographical) objects, pixel classification is the most appropriate approach. With increasing spatial resolution, and also improving spectral characteristics, of satellite images “traditional” classification methods become less effective. Therefore, object-oriented classification is being used more and more frequently. Object based classification combines contextual segmentation, which is a fundamental phase of the approach, and classification itself. Segmentation divides satellite image into a relatively homogeneous and semantically significant pixel groups (segments) based on one or more criteria of homogeneity. Beside their spectral features (colour) also shape and connection between the segments are considered in the process of the classification. Object oriented classification is used in the thesis as a tool for the identification of land use/cover in the case of two study areas in Slovenia (Kobarid, Gornja Radgona) with a different dominant cover classes.

ZAHVALA

Za pomoč pri nastajanju diplomske naloge se najlepše zahvaljujem mentorju Krištofu Oštirju in somentorju Alešu Marsetiču za njuno strokovno pomoč in kup uporabnih napotkov. Prav tako gre zahvala Tatjani, ki je bila s svojimi idejami in skrbnim pregledom še en neuradni somentor, Žigu za raznorazne pomembne mini nasvete in Petru za podloge in tehnično pomoč, ko je bila potrebna. Vsem skupaj iz Inštituta za antropološke in prostorske vede, ZRC SAZU, hvala za toplo in kreativno okolje.

Posebno zahvalo namenjam mojima staršema, Majdi in Juretu, za njuno finančno in pa predvsem moralno podporo tekom študija. Hvala, ker mi pustita biti to kar sem.

Prav tako pa hvala Nejcju za olepšavo; tako diplome s slikami kot mojega vsakdana.

KAZALO

1	UVOD	1
2	OSNOVNA NAČELA DALJINSKO ZAZNANIH PODATKOV	4
2.1	Pridobivanje informacij o površju	4
2.1.1	Spektralni podpis	5
2.2	Posnetki.....	6
2.2.1	Letalski posnetki	6
2.2.2	Satelitski posnetki	6
2.3	Predstavitev informacij na podobah	8
3	POKROVNOST/RABA TAL.....	10
4	KLASIFIKACIJA PODOB.....	12
4.1	Načini klasifikacije.....	12
4.2	Razdelitev v razrede	13
4.3	Vrste klasifikacij glede na način razdelitve v razrede.....	14
4.3.1	Nenadzorovana klasifikacija.....	14
4.3.2	Nadzorovana klasifikacija.....	15
4.4	Primerjava med pikselo in objektno klasifikacijo	17
4.5	Pikselna klasifikacija.....	19
5	OBJEKTNA KLASIFIKACIJA	21
5.1	Postopek objektno usmerjene klasifikacije	21
5.1.1	Prednosti in slabosti objektno usmerjene klasifikacije	22
5.1.2	Uporaba objektno usmerjene klasifikacije.....	23
5.2	Segmentacija.....	24
5.2.1	Lastnosti (atributi) objektov	25
5.2.2	Vrste segmentacijskih algoritmov	28

5.2.3	Prekomerna in prešibka segmentacija	32
5.3	Semantična klasifikacija	33
6	POKLASIFIKACIJA	34
7	NATANČNOST KLASIFIKACIJE	36
7.1	Koeficient kappa.....	37
7.2	Natančnost proizvajalca in natančnost uporabnika.....	38
7.3	Skupna natančnost	38
8	PROGRAMSKA ORODJA ZA OBJEKTNO KLASIFIKACIJO	39
8.1	Definiens Developer.....	39
8.2	Feature Analyst in LIDAR Analyst	39
8.3	ENVI Feature Extraction	40
9	UPORABA OBJEKTNE KLASIFIKACIJE V DIPLOMSKI NALOGI.....	41
9.1	Študijski območji.....	41
9.2	Uporabljeni podatki	42
9.3	Uporabljena programska oprema	44
10	POSTOPEK OBDELAVE PODOB	45
10.1	Segmentacija	47
10.2	Klasifikacija	51
10.2.1	Klasifikacija Gornje Radgone/Bad Radkersburg-a in Kobarida	52
	Opis razredov.....	53
10.2.2	Podrobna klasifikacija kmetijskih površin Gornje Radgone.....	56
10.3	Merilo ločljivosti razredov.....	56
10.4	Poklasifikacija.....	58
10.4.1	Vektorska obdelava rezultatov klasifikacije.....	59
10.4.2	Preklasifikacija in generalizacija	60

11	OVREDNOTENJE DOBLJENIH REZULTATOV	61
11.1	Matrika napak.....	61
11.2	Ovrednotenje rezultatov pokrovnosti/rabe tal za območje Gornje Radgone. ...	62
11.3	Ovrednotenje rezultatov pokrovnosti/rabe tal za območje Kobarida	64
11.4	Ovrednotenje rezultatov kmetijskih zemljišč za območje Gornje Radgone	65
12	PRIKAZ REZULTATOV	67
13	ZAKLJUČEK.....	70

VIRI

PRILOGE

KAZALO PREGLEDNIC

Preglednica 1: Prostorski atributi objektov	26
Preglednica 2: Spektralni atributi objektov	27
Preglednica 3: Teksturni atributi objektov	27
Preglednica 4: Razmerje kanalov in barvni prostor	27
Preglednica 5: Izbrani parametri pri poteku segmentacije v programski opremi ENVI za posamezno obravnavano območje.....	48
Preglednica 6: Spektralna ločljivost med razredi na primeru Gornje Radgone.	57
Preglednica 7: Združeni razredi podrobne analize kmetijskih zemljišč na referenčni in klasificirani podobi.....	61
Preglednica 8: Matrika napak pokrovnosti/rabe tal za območje Gornje Radgone v odstotkih.	62
Preglednica 9: Matrika napak pokrovnosti/rabe tal za območje Kobarida v odstotkih.....	64
Preglednica 10: Matrika napak podrobnejše klasifikacije kmetijskih zemljišč na območju Gornje Radgone v odstotkih.....	66

KAZALO SLIK

Slika 1: Spektralni podpis različnih predmetov na zemeljski površini.....	5
Slika 2: Vektorji pikslov na primeru multispektralne satelitske podobe s štirimi kanali	9
Slika 3: Različni pristopi klasifikacije na primeru vegetacije	13
Slika 4: Princip delovanja nadzorovane klasifikacije.	15
Slika 5: Različni algoritmi nadzorovane klasifikacije. Metoda najmanjše razdalje, paralepipedna metoda in metoda največje verjetnosti	16
Slika 6: Primerjava pikselske in objektno usmerjene klasifikacije.....	18
Slika 7: Spektralno obnašanje pikslov v primerjavi z objekti na primeru naselja in gozda	19
Slika 8: Splošni postopek objektno usmerjene klasifikacije.....	22
Slika 9: Skupek podobjektov (segmentov) ustvari realen objekt.....	24
Slika 10: Hierarhična mreža posameznih ravni segmentacije	25
Slika 11: Določanje segmentov v okolici z načinom štirih oziroma osmih sosedov.....	31
Slika 12: Primer prekomerne in prešibke segmentacije.....	32
Slika 13: Analiza "združi in presej". Primer prikazuje stanje pred in po obdelavi.....	35
Slika 14: Programski paket ENVI Zoom, kjer je integriran modul za objektno klasifikacijo ENVI Feature Extraction.	40
Slika 15: Delovni proces.....	41
Slika 16: Študijski območji.....	42
Slika 17: Potek postopka izločanja objektov iz podobe.....	46
Slika 18: Originalna vhodna podoba.....	48
Slika 19: Segmentirana podoba.	49
Slika 20: Podoba, kjer so segmenti še dodatno združeni.	49
Slika 21: Določevanje vrednosti praga.	50
Slika 22: Atributi, ki se računajo segmentom v programu ENVI.....	50
Slika 23: Primer zajemanja učnih vzorcev.....	52

Slika 24: Osenčene površine na posnetku zaradi velikih naklonov na površju.....	55
Slika 25: Postopek poklasifikacije. Obdelavo s funkcijo »presej« in »združi«.....	58
Slika 26: Obdelava klasificiranih rezultatov v programskem okolju ArcGIS.....	59

1 UVOD

Daljinsko zaznavanje je trenutno najbolj učinkovita tehnologija za redno opazovanje zemeljske površine. Pri tem multispektralni senzori iz večjih razdalj nad Zemljo zaznavajo in zapisujejo elektromagnetno valovanje pri vidnih, infrardečih in radarskih mikrovalovnih dolžinah elektromagnetnega spektra, ki ga odbijajo ali sevajo različni predmeti na zemeljskih tleh. Informacije o površju se pretvorijo v digitalno obliko, da se lahko obdelajo, analizirajo in uporabijo v različnih aplikacijah. Postopek obdelave rastrske (digitalne) podobe v obliko razumljivo uporabniku imenujemo klasifikacija.

Klasifikacija podob predstavlja pomemben del v daljinskem zaznavanju, saj lahko s pomočjo razvrščanja vsebine podobe pridobimo zemljevidu podobno sliko, kar pa je tudi končni proizvod analize (Campbell, 1996). Kljub temu da je prikladno opazovati posnetke iz vesolja ali zraka, pa so vendarle šele tematske karte tiste, ki dajo podobam pomen (Oštir, 2006).

Vsebino podobe se lahko določi z vizualno fotointerpretacijo oziroma z digitalno klasifikacijo. Vizualna interpretacija posnetkov je lahko zaradi velikega števila podatkov na podobi zelo zamudna, saj mora operater prečesati celotno podobo, medtem ko digitalna klasifikacija prepozna predmete na zemeljski površini samodejno z upoštevanjem spektralnih informacij na posnetkih (Oštir, 2006). Uporaba avtomatske klasifikacije podob zmanjšuje neskladnosti in napake, ki se pojavljajo pri vizualni fotointerpretaciji posnetkov. Prav tako pa so se samodejne metode izkazale finančno ugodnejše v primerjavi z vizualnim opisovanjem in klasifikacijo (Thomson et al., 2003).

Zaradi dostopnosti tehnologije, ki ponuja visoko ločljivostne satelitske podatke (prostorska ločljivost okoli enega metra) in s tem veliko število podrobnosti na podobah, so se razvile potrebe po novih metodah klasifikacije. Že dobro razvite, »tradicionalne« pikselno usmerjene analitične tehnike in algoritmi ne morejo v polni meri izkoristiti povečano prostorsko skladnost visoke ločljivosti posnetkov, saj je velikost piksla na teh podobah bistveno manjša od povprečne velikosti opazovanega predmeta.

Nove perspektive v disciplini daljinskega zaznavanja prinaša objektna klasifikacija podob, ki je učinkovita metoda za združevanje velikih detajlov na podobah, še posebej za odkrivanje in razvrščanje umetnih objektov (Nussbaum in Menz, 2008). Ključni metodološki element pri objektno usmerjenem postopku predstavlja segmentacija. To je postopek, ki deli podobo na regije (objekte na podobi oziroma segmente), ki imajo skupne lastnosti.

Objektna klasifikacija torej združuje piksele s podobnimi spektralnimi in prostorskimi značilnostmi in zmanjšuje probleme klasifikacije na nekaj objektov namesto na tisoče in tisoče pikslov. Ta pristop omogoča, da se uporabi prava moč daljinskega zaznavanja z izkoriščanjem vseh dimenzij te discipline, vključno s spektralnimi, prostorskimi, kontekstnimi, morfološkimi ter časovnimi vidiki pri postopku izločanja objektov (Navulur, 2007). Na primer, pri kmetijskih površinah je učinkoviteje, če določimo pridelek na njivi s pomočjo njegove fizične vegetacijske meje kot pa vsak piksel znotraj njive posebej. Prostorske in spektralne razlike na njivi zaradi gostote vegetacije, namakanja ter jarkov, ki potekajo preko njiv, pri pikseli klasifikaciji pogosto predstavljajo velik problem.

Vodilno načelo objektno usmerjene klasifikacije je torej jasno: zapletena vsebina površja na podobah se mora najbolje opisati, vsaka opisana vsebina pa mora biti čimbolj razumljiva uporabnikom (Blasche et al., 2008).

V diplomski nalogi bom skušala razčleniti in analizirati nekatere pojme, poteke in algoritme objektne klasifikacije in pokazati njeno uporabnost na konkretnih primerih. Temu namenu ustreza razdelitev na posamezna poglavja, ki so razdrobljena – nekatera bolj in nekatera manj – na posamezne razdelke. Naloga do vključno osmega poglavja teoretično utemeljuje osnove izbrane teme, medtem ko so v drugem delu naloge praktično uporabljena temeljna teoretična izhodišča na konkretnem primeru Gornje Radgone in Kobarida.

Pričujočemu Uvodu sledi poglavje Osnovna načela daljinsko zaznanih podatkov, kjer so predstavljene podobe in razumevanje informacij na njih. V tretjem poglavju sem opisala definicijo pokrovnosti oziroma rabe tal, v nadaljevanju pa predstavila načine klasifikacije, kjer sem med drugim primerjala pikselo in objektno klasifikacijo. Osrednje poglavje je Objektna klasifikacija, kjer so opisani glavni koraki te klasifikacije, velik poudarek sloni na

segmentaciji, saj le ta pri omenjeni klasifikaciji predstavlja ključen pomen. V šestem poglavju se seznanimo s postopkom naknadne obdelave dobljenih rezultatov, ki ga imenujemo poklasifikacija, v sedmem poglavju pa s postopkom ovrednotenja klasifikacije opišem parametre, s katerimi se vrednoti natančnost klasifikacije. V nadaljevanju so našteje komercialno dostopne programske opreme, ki imajo implementirane metode objektne klasifikacije.

Sledi praktični del naloge, začenši z uporabo objektne klasifikacije v diplomski nalogi. V tem poglavju so opisani uporabljeni podatki in programska oprema ter območja na katerih se je izvajala klasifikacija. Poglavje kasneje je opisan celoten postopek obdelave podob in pridobitev končnih rezultatov na izbranih območjih. V enajstem poglavju pa sem opisala natančnost dobljenih rezultatov v primerjavi z referenčnimi podatki. Predzadnje poglavje diplomske naloge nam ponudi dobljene rezultate klasifikacije v kartografski obliki.

V zaključku so podani rezultati, prav tako pa je na kratko povzet postopek diplomske naloge, dodano je tudi časovno ovrednotenje postopka. Predstavljene so tudi težave in bodoče delo. Tisti, ki bi jih pa utegnili snov podrobneje zanimati, bodo našli na koncu diplomskega dela seznam dosegljive domače in tuje literature, ki se ukvarja s podrobnimi problemi. Kot zadnje pa so dodane še priloge, podatki o natančnostih klasifikacije, ki so bili za vključitev v delo preveč obsežni in natančni.

2 OSNOVNA NAČELA DALJINSKO ZAZNANIH PODATKOV

Daljinsko zaznavanje je znanost in umetnost pridobivanja informacij o objektih na površju Zemlje, ne da bi prišli v neposreden stik z njimi. Prenos podatkov se doseže z uporabo elektromagnetnega valovanja, ki vpliva in interaktira z opazovanimi objekti. Zajete informacije so v obliki digitalnih matrik prikazane uporabniku kot daljinsko zaznane podobe, katere je mogoče nadaljnje obdelovati in analizirati.

2.1 Pridobivanje informacij o površju

Elektromagnetno valovanje je nihanje električnega in magnetnega polja v prostoru. Elektromagnetni (EM) spekter se razteza od radijskih valov z dolgo valovno dolžino do gamma žarkov kratkih valovnih dolžin. Največ energije nosijo valovi z najkrajšo valovno dolžino in obratno, najmanj energije nosijo valovi z najdaljšo valovno dolžino. Vsa materialna telesa v vesolju, ki imajo temperaturo nad absolutno ničlo, sevajo EM valovanje v EM spektru, čigar intenziteta in valovna dolžina sta odvisni od absolutne temperature.


»Z zapisovanjem izsevanega in odbitega elektromagnetnega valovanja ter upoštevanjem njegovih lastnosti pri poti skozi atmosfero in načina njegove interakcije s predmeti na površini lahko določimo opazovane predmete na njej (vegetacija, zgradbe, gola prst, odprte površine, vodne površine...)« (Oštir, 2006, str. 21). Predmetom na zemeljskem površju torej merimo njihov spektralni podpis oziroma energijo, ki se odbije ali seva od njih pri različnih valovnih dolžinah.

Ker sistemi za opazovanje ne zaznavajo celoten spektralni prostor ponavadi nimamo na voljo celotnega spektralnega podpisa predmeta, ki ga opazujemo. Zaznajo se le množice diskretnih vrednosti, ki predstavljajo odboje v različnih kanalih uporabljenega senzorja. Spektralni odziv lahko opazujemo skoraj zvezno s pomočjo hiperspektralnih senzorjev, ki imajo več sto ali celo tisoč kanalov, večinoma pa imamo na voljo le nekaj vrednosti. V splošnem velja, da večje število kanalov olajša ločevanje predmetov in s tem klasifikacijo, ni pa nujno, da se

rezultati na ta način vedno izboljšajo. Vsekakor pa se precej poveča količina redundantnih podatkov (Oštir, 2006).

2.1.1 Spektralni podpis

Pri večspektralnih sistemih se zajemajo posnetki istočasno v različnih spektralnih območjih, kar omogočajo nameščeni sistemi z več senzorji. Ker ima vsaka pokrovnost/raba tal različne spektralne odzive oziroma različen spektralni podpis (odvisnost odboja od valovne dolžine) lahko pri več valovnih dolžinah tako bolje ločimo in prepoznamo predmete na površju (slika 1). Tako imata na primer voda in zelena vegetacija približno enako odbojnost v vidnem delu spektra, medtem ko ju v infrardečem vedno ločimo med seboj.



Slika 1: Spektralni podpis različnih predmetov na zemeljski površini.

2.2 Posnetki

Posnetki nam dajejo razne informacije o površju, njegovih lastnostih in so vir pridobivanja posodobljenih, spremenjenih informacij (Blasche et al., 2008). Na posnetkih se zapisujejo odbojnosti v obliki digitalnih vrednosti, ki so praviloma predstavljene v obliki matrik pikselov.

S (pol)samodejno obdelavo posnetkov lahko dosežemo relativno poceni ter hitro pridobivanje semantičnih informacij o površju. Podatki zajeti z daljinskim zaznavanjem se nenehno izboljšujejo, kar se odraža v boljši spektralni, prostorski in radimetrični ločljivosti.

Daljinsko zaznani podatki, ki so na voljo danes, so večinoma zajeti z uporabo multispektralnih senzorjev, ki so nameščeni bodisi na letalih ali na satelitih.

2.2.1 Letalski posnetki

Kot primarno sredstvo za pridobivanje ustreznih informacij o površju za večja merila (večja od 1:10.000) že desetletja služijo letalski posnetki, ki so kot medij za zajem Zemlje prvenstveno uporabljali fotografski film. Za pridobitev digitalnih podob se negativni filmovi kasneje skenirajo. V zadnjih letih, ko smo priča skokovitemu tehnološkemu razvoju, se poleg senzorjev na film pri klasičnih kamerah uporabljajo tudi digitalne kamere oziroma digitalni senzorji.

2.2.2 Satelitski posnetki

Pri razvoju satelitov za opazovanje kopnih površin pomemben korak predstavlja izstrelitev civilnega satelita ERTS-1 (*Earth Resources Technology Satellite*, oziroma kasneje preimenovan v Landsat-1) v začetku sedemdesetih let. Prostorska ločljivost (80 m), ki jo je nudil multispektralni skener s štirimi kanali na krovu tega satelita, navkljub tehnološkemu mejniku ni omogočala razločevanje nekaterih ponavljajočih se elementov na površju, ki karakterizirajo skupno pokrovnost/rabo tal (drevesa, zgradbe, ceste...) (Blasche et al., 2008).

Dokaj kmalu so satelitu Landsat-1 sledili še številni drugi sistemi s srednjo ločljivostjo za opazovanje Zemlje, vendar ga po priljubljenosti niso presegli vse do leta 1999 oziroma dokler niso na trg prišli visokoločljivi satelitski sistemi.

Še prej, natančno leta 1991, je daljinsko zaznavanje doživelo še en korak v razvoju. Takrat je Evropska Satelitska Agencija (ESA) izstrelila satelit ERS, ki je ponudil možnost snemanja z radarjem. Radar (*ang. Radio Detection And Ranging*) pri svojem delovanju uporablja relativno dolge valovne dolžine v mikrovalovnem območju, zaradi katerih je možno opazovanje zemeljske površine tudi skozi oblake, dim in določeno vegetacijo. Pozitivna lastnost so prav tako njegovi aktivni senzorji, ki omogočajo snemanje tudi ponoči.

Z izstrelitvijo satelita IKONOS leta 1999, ki je postregel z 1 m pankromatsko in 4 m večspektralno prostorsko ločljivostjo, se je postavil naslednji mejnik v razvoju vede - prevladala je uporaba visokoločljivih satelitskih sistemov. Kmalu za satelitom IKONOS so sledili še SPOT5, IRS, QuickBird, OrbView3 in ostali visokoločljivi satelitski sistemi, s katerimi lahko zaznamo veliko podrobnosti (Navulur, 2007). Novi senzorji in nove vrste podatkov ponujajo bogastvo informacij o površju, njihov končni cilj pa je razumljivost s strani uporabnikov. Napredne metode zahtevajo tako sinhronizacijo tehnologije kot tudi usklajenost pristopov obdelave. Prva je povezana s pridobitvijo in predobdelavo večločljivostnih podatkov, druga pa se ukvarja z integracijo tehnik o prostorski analizi med postopki obdelave (Blasche et al., 2008). Visokoločljivi satelitski posnetki so sedaj na voljo v veliki meri in so široko razširjeni tako na različnih področjih raziskav kot tudi za domačo rabo. Produkti visokoločljivih satelitskih sistemov so zlahka dostopni vsakomur preko spletnih virtualnih globusov, kot so Google Earth, NASA World Wind, Microsoft Virtual Earth in podobnih (Blasche et al., 2008).

Visokoločljivim podobam se je na prelomu tisočletja pridružila še tehnologija lidar (*ang. Light Detection And Ranging*), ki trenutno predstavlja najbolj natančno tehniko za izdelavo digitalnih modelov višin. Lidar je enako kot radar aktivni senzor, ki deluje v vidnem in infrardečem delu spektra in proti opazovanim predmetom pošilja kratke laserske pulze in opazuje njihov odboj (Oštir, 2006). Čeprav lidar in radar temeljita na podobnih načelih delovanja, obstajajo zaradi drugačnih fizikalnih procesov velike razlike med njima.

2.3 Predstavitev informacij na podobah

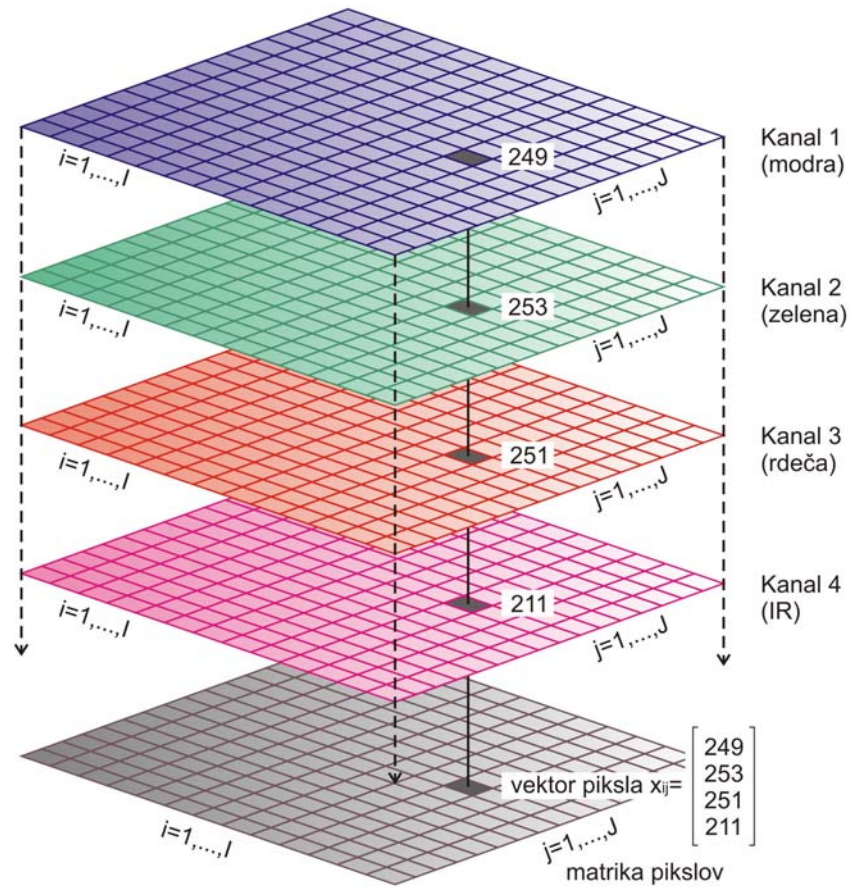
Podatki na daljinsko zaznanih podobah so izraženi v obliki matrike, ki je sestavljena iz I vrstic in J stolpcev na podobi, pri čemer je piksel¹ s položajem (i, j) definiran glede na njegovo odbojno vrednost v vseh pasovih posnetka kot vektor piksla x_{ij} .

$$x_{ij} = \begin{bmatrix} b_{1ij} \\ b_{2ij} \\ b_{3ij} \\ \dots \\ b_{nij} \end{bmatrix}$$

Ta vektor x_{ij} predstavlja sive vrednosti (0, 1..., 255 za 8-bitne podatke oziroma 0, 1..., 2048 za 11-bitne podatke) pikslov v posameznih pasovih. Potemtakem je 0 = črna (brez odboja, maksimalna absorpcija) in 255 oziroma 2048 = bela (maksimalni odboj, brez absorpcije).

Slika 2 shematično prikazuje vektorsko naravo pikslov na primeru multispektralnega posnetka z več pasovi (Nussbaum in Menz, 2008).

¹ Piksel oziroma slikovni element (*ang. picture element*) je najmanjša (praviloma kvadratna) naslovljiva enota na sliki, ki se jo lahko prebere. Piksel nima določene velikosti ima le informacijo o barvi in intenziteti slike.



Slika 2: Vektorji pikslov na primeru multispektralne satelitske podobe s štirimi kanali. (Nussbaum in Menz, 2008)

3 POKROVNOST/RABA TAL

Poznavanje stanja pokrovnosti oziroma rabe tal v povezavi z znanjem o njihovih spremembah igra pomembno vlogo na mnogih področjih politike in uprave. Ti podatki se uporabljajo zlasti na področju javne uprave ter pri prostorskem načrtovanju, gozdarstvu, kmetijstvu, varstvu narave, hidrologiji, itd. Tudi v GIS analizah je pokrovnost oziroma raba tal eden najpomembnejših slojev.

Raba tal je zastopanost in razširjenost zemljiških kategorij, ki najbolj prepoznavno zaznamujejo pokrajino. Odraža zapletena razmerja med naravnimi in družbenogospodarskimi dejavniki. Med prvimi je posebej pomembna izoblikovanost površja, t.j. nadmorska višina, nagib in osončenost pobočij, med družbenogospodarskimi in zgodovinskimi pa značilnosti kolonizacije, gospodarske razmere v preteklosti in sedanjosti ter zemljiškoposestniški odnosi (Kladnik et al., 1998). Raba tal je zato dinamičen proces, kar se kaže v stalnem spreminjanju površine posameznih kategorij oziroma njihovih medsebojnih razmerij (Gabrovec in Kladnik, 1997).

Ker se v literaturi pogosto pojavljata oba izraza - pokrovnost oziroma raba tal - je potrebno tukaj zapisati nekaj osnovnih razlik med rabo tal in pokrovnostjo. Raba tal (*ang. land use*) lahko definiramo kot namen za katerega ljudje izkoriščajo nek kos zemljišča, s poudarkom na funkcijski vlogi zemljišča v ekonomskih aktivnostih. Raba tal je abstraktna in je včasih ne moremo določiti niti s podrobnim ogledom (Campbell, 1996). Pokrovnost (*ang. land cover*) na drugi strani pa je konkretna saj nam pove, kaj (kateri material oziroma kakšen »pokrov«) pokriva posamezen del zemeljskega površja in jo lahko kot tako neposredno opazujemo s tehnikami daljinskega zaznavanja. Na primer, betonska ploščad predstavlja kategorijo pokrovnosti tal, ki pa je glede na rabo lahko na primer športno igrišče, skladišče na prostem, parkirišče itd. (Krevs, 2004).

Vsaka karta pokrovnosti/rabe tal je poenostavljen prikaz določenega izseka zemeljskega površja. Informacije o pokrovnosti/rabi tal morajo biti čimbolj ažurne, popolne in objektivne, saj služijo kot podlaga za gospodarjenje s prostorom, okoljem in naravnimi viri v različnih

prostorskih vedah. Kot osnova spremljanja pokrovnosti/rabe tal se je uveljavilo daljinsko zaznavanje, saj so predvsem satelitski posnetki v večini primerov postali osnova za zabeleženje pokrovnosti. Poleg njih se največkrat uporablja še digitalne ortofoto posnetke, dodatne podatke pa pridobivamo iz topografskih podlag ter drugih razpoložljivih podatkov. Kot način preverjanja pa je še vedno najbolj verodostojen terenski ogled (Rikanovič, 2003).

4 KLASIFIKACIJA PODOB

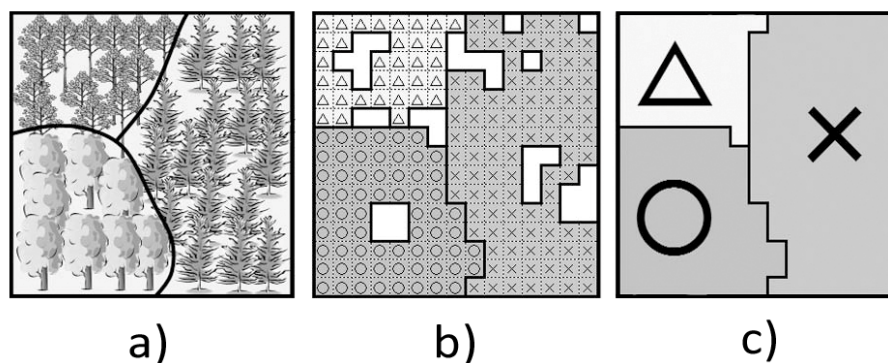
»Klasifikacija podob je eden najpomembnejših postopkov pri obdelavi daljinsko zaznanih podob, saj predstavlja povezavo med daljinskim zaznavanjem in geografskimi informacijskimi sistemi (GIS). Z njo namreč iz rastrske podobe, ki je primerna kot ozadje pri različno prikazanih in vizualnih analizah, dobimo kvantitativni sloj, ki ga kasneje lahko uporabimo v analizah s sistemi GIS.« (Oštir, 2006, str.175). To pomeni, da pri postopku klasifikacije posamezne piksele oziroma segmente na podobi dodelimo v pripadajoči razred, ki ustreza informativni kategoriji, ki so v interesu operaterja. Ti razredi oblikujejo regije na zemljevidu oziroma podobi, zato je po klasifikaciji digitalna podoba predstavljena kot mozaik.

Klasifikacijo delimo glede na način razdelitve v razrede na nadzorovano in nenadzorovano klasifikacijo, glede na metodo razvrščanja pikselov pa klasifikacijo satelitskih in letalskih podob delimo tudi na pikselo in objektno klasifikacijo.

4.1 Načini klasifikacije

V letih razvoja daljinskega zaznavanja so znanstveniki razvili številne metode klasifikacije. Od vseh alternativ, ki obstajajo, je bistveno, da analitik izbere klasifikacijo, ki najbolj ustreza analizirani podobi in želenemu namenu. Vsaka klasifikacija ni najboljša za vse situacije, saj se značilnosti in okoliščine podob med seboj precej spreminjajo (Campbell, 1996).

Najpreprostejša oblika klasifikacije podob je postopek, kjer obravnavamo vsak piksel kot posamezno enoto, ki je sestavljena iz vrednosti več spektralnih pasov. Z operacijami klasifikacije in analize podob digitalno prepoznamo in razdelimo piksele na posnetku v razrede. Medtem ko se pri »tradicionalni« pikseli klasifikaciji razvršča vsak piksel glede na določene statistične značilnosti v razrede, se pri objektno usmerjeni klasifikaciji najprej piksli v fazi segmentacije združijo v segmente (objekte), nato pa se vsak segment dodeli nekemu razredu.



Slika 3: Različni pristopi klasifikacije na primeru vegetacije (Blaschke et al., 2008)
a) vizualna interpretacija, b) pikselska klasifikacija in c) objektna klasifikacija.

4.2 Razdelitev v razrede

Pri klasifikaciji, ki jo po navadi izvajamo z večspektralnimi podatki, vsakemu pikslu ali objektu na podobi priredimo določen razred oziroma temo glede na njegovo sivo vrednost in druge statistične značilnosti. Razred sestavljajo elementi, ki imajo v okviru dane razdelitve podobne značilnosti.

»Kadar govorimo o razredih, moramo ločevati med informacijskimi razredi in spektralnimi razredi. Informacijski razredi so tiste kategorije, ki jih skušamo na podobah prepoznati, na primer različne vrste poljščin, vrste gozdov, geološke strukture in podobno. Spektralni razredi pa so skupine podobnih pikslov, glede na njihove sive vrednosti v posameznih kanalih. Glavni namen pri klasifikaciji je iskanje povezave med spektralnimi in informacijskimi razredi. Pri tem je le redko mogoče dobiti povezavo enega spektralnega razreda z enim informacijskim.« (Oštir, 2006, str. 178).

Obstaja veliko načinov, kako razdelitev v razrede opravimo, v splošnem pa klasifikacijo razdelimo na nadzorovano in nenadzorovano. Glavna razlika med obema je način, kako ustvarimo spektralne podpise oziroma učne vzorce.

4.3 Vrste klasifikacij glede na način razdelitve v razrede

4.3.1 Nenadzorovana klasifikacija

Pri nenadzorovani klasifikaciji postopek išče »naravne« skupine (*ang. clusters*), ki se pojavljajo v populaciji glede na izbrane spremenljivke. Klasifikacija je nenadzorovana, ker razen z izborom števila skupin, ne moremo vplivati na razvrščanje. Algoritem klasifikacije sam izvede združevanje podatkov glede na njihovo podobnost. Osnovna predpostavka je, da so spektralne vrednosti določene vrste pokrovnosti/rabe tal blizu skupaj, medtem ko naj bi bili različni razredi sorazmerno dobro ločeni (Lillesand et al., 2004). Klasifikacija je prostorsko neodvisna in sosednje enote ne vplivajo druge na drugo (Campbell, 1996).

Za oblikovanje spektralnih razredov obstaja veliko algoritmov nenadzorovane klasifikacije. Eden najpogosteje uporabljenih algoritmov je ISODATA (*ang. iterative self-organizing data analysis technique algorithm*), ki izračuna povprečje enakomerno porazdeljenega razreda v prostoru in nato združi v gruče preostale piksele s pomočjo metode najmanjše razdalje. ISODATA deluje dinamično, kar pomeni, da lahko združuje centre sorodnih razredov, briše majhne gruče in velike razrede razdeli na več delov (Oštir, 2006). Računsko preprostejši je algoritem K-povprečje (*ang. K-means*), ki z enako metodo kot algoritem ISODATA razvršča piksele v gruče, vendar ne deluje dinamično.

Po Cambell-u (1996) so prednosti te klasifikacije v primerjavi z nadzorovano klasifikacijo sledeče:

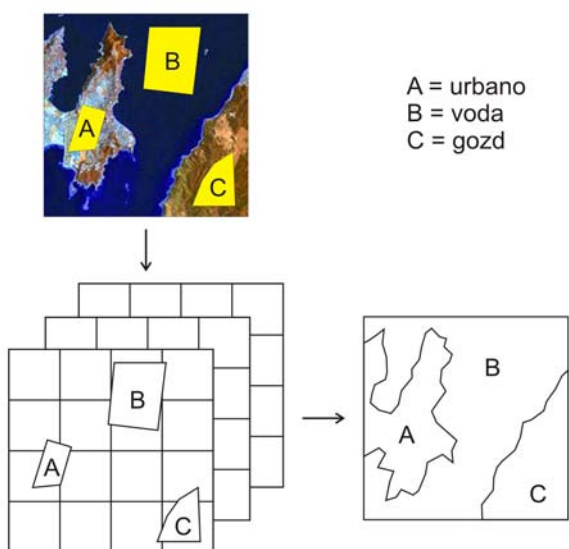
- uporabnik ne potrebuje predhodnega poznavanja obravnavanega površja,
- možnosti človeških napak so minimalne, saj operater označi samo število kategorij razredov, ki jih želi pridobiti s klasifikacijo,
- razredi, ki se na posnetku pojavljajo redko oziroma imajo majhno površino ostajajo pri tej klasifikaciji identificirani kot ločene enote. Takšni razredi lahko pri nadzorovani klasifikaciji ostanejo neprepoznani oziroma so lahko nenamerno vključeni v ostale prevladujoče razrede. To prinaša netočnosti v celotni razvrstitvi.

Slabosti in omejitve te klasifikacije pa izhajajo predvsem iz zanašanja na »naravno« zduževanje v skupine in iz težav usklajevanja teh skupin z informacijskimi razredi, ki so v interesu uporabnika. Podrobneje so slabosti opisane spodaj (Cambell, 1996):

- pari informacijskih in spektralnih razredov se le redko ujemajo, zato se uporabniki soočajo s problemom prilagajanja spektralnih razredov, ki jih ustvarja klasifikacija z informacijskimi razredi, ki jih zahteva končni uporabnik,
- analitik ima omejen nadzor nad potekom klasifikacije,
- spektralne lastnosti informativnih razredov se sčasoma (v sezoni ter čez leta) spremenijo. Razmerja med informacijskimi in spektralnim razredi zato niso stalna in se lahko le redko prenesejo iz ene podobe na druge.

4.3.2 Nadzorovana klasifikacija

Kot že pove samo ime, je nadzorovana klasifikacija v večji meri kontrolirana (nadzorovana) s strani uporabnika, saj skušamo enote uvrstiti v enega izmed znanih razredov – to je razredom, ki smo jih določili sami. Klasifikacija je sestavljena iz učne faze in faze razvrščanja v razrede. V učni fazi uporabnik določi reprezentativna območja za določen razred (učne vzorce). Izbira ustreznih učnih vzorcev temelji na uporabnikovem poznavanju geografskega območja.

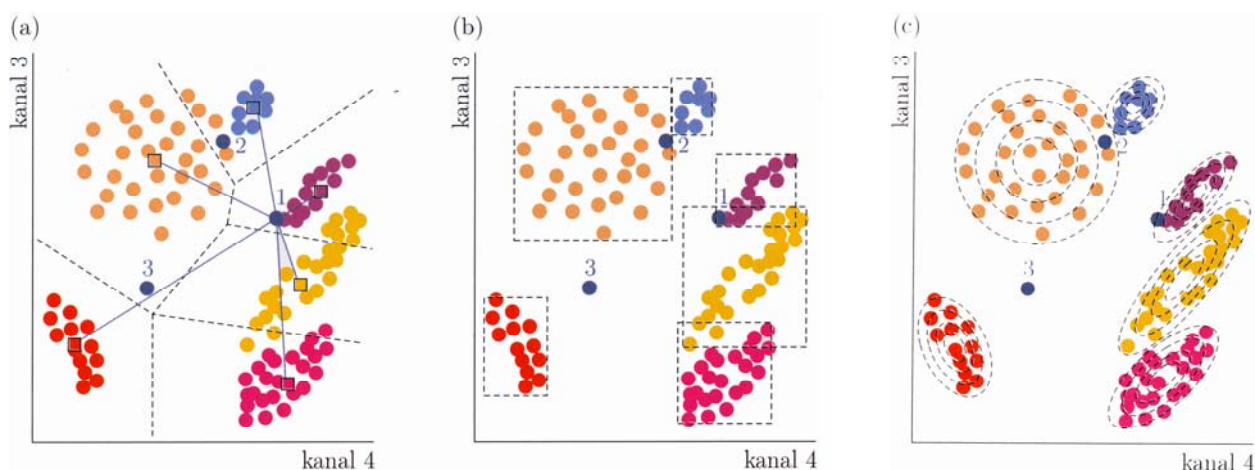


Številčne informacije izvzete iz vseh spektralnih pasovih znotraj učnega vzorca »naučijo« računalnik, da prepozna spektralno podobna območja za vsak razred. Računalnik glede na izbran algoritem izračuna spektralni podpis za vsak učni vzorec. Ko so le ti definirani v fazi razvrščanja vsak piksel na podlagi podobnosti spektralnega vzorca uvrsti v ustrezni razred, v primeru, da je podobnost pod določenim pragom, pa piksel ni uvrščen (Campbell, 1996). Slika 4 prikazuje princip delovanja nadzorovane klasifikacije.

Slika 4: Princip delovanja nadzorovane klasifikacije.

Obstaja več različnih algoritmov in metod za razdelitev pikslov v razrede (slika 5), na primer:

- metoda najmanjše razdalje (piksli so razdeljeni v tisti razred, od katerega so v povprečju najmanj oddaljeni),
- paralelepipedna metoda (piksel se uvrsti v tisti razred v katerega padejo njegove sive vrednosti),
- metoda največje verjetnosti (pri razvrščanju se ustvarijo ploskve enake verjetnosti, kjer se upoštevajo statistične lastnosti pikslov in njihovih povezav. Predvideva se, da so vsi piksli razporejeni normalno) (Oštir, 2006),
- k-najbližji sosed (pri tem algoritmu se za vsak segment računa najmanjša oddaljenost od števila učnih vzorcev, ki jih definiramo s parametrom k. Segmentu je dodeljen razredu, ki je med temi najpogostejši. Če je $k = 1$, potem je segment preprosto dodeljen razredu njegovega najbližjega soseda) (ENVI User's guide, 2008)). Ta algoritem je uporabljen v praktičnem delu naloge.



Slika 5: Različni algoritmi nadzorovane klasifikacije. a) Metoda najmanjše razdalje, b) paralelepipedna metoda in c) metoda največje verjetnosti. (Oštir, 2006)

Prednost nadzorovane klasifikacije je predvsem v direktni vpletenosti operaterja pri procesu ustvarjanja in urejanja vzorcev. Prav tako predstavlja prednost operaterjeva sposobnost zaznavanja večjih napak, ki lahko nastanejo pri klasifikaciji.

Netočna razvrstitev reprezentativnih območij vodi do velikih napak pri klasifikaciji, čeprav njihova pravilna razvrstitev tudi ne kaže vedno dobrih razvrstitev v primerjavi z drugimi podobnimi podatki. Optimalna razporeditev reprezentativnih območij je zato zelo pomembna,

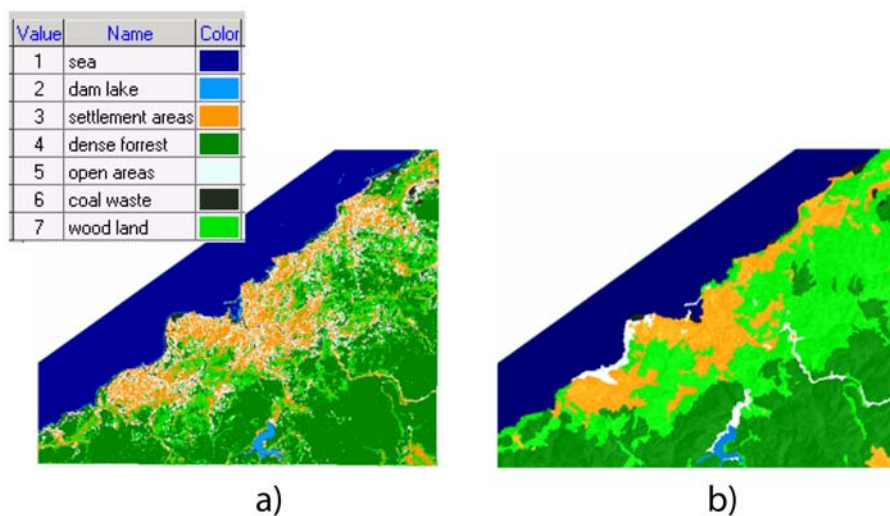
ker se zaradi nepravilnega zajemanja testnih primerov lahko znatno kvarijo rezultati. Natančnost klasifikacije se slabša tudi kadar testni primeri niso enako reprezentativni čez celotno podobo, saj se njihov spektralni podpis spreminja prostorsko. Slabost te klasifikacije pa je prav tako dolgotrajen ter drag postopek zajemanja reprezentativnih območij.

4.4 Primerjava med pikselo in objektno klasifikacijo

Od izstrelitve prvega satelita za opazovanje Zemlje in s tem od začetka razvoja analiz daljinsko zaznanih podob ter klasifikacijskih metod so piksli predstavljali osnovno enoto analiz. Na podlagi pikselnega pristopa so bile razvite digitalne klasifikacijske metode (npr. metoda največje verjetnosti), ki so kmalu zatem postale zgled za ostale analize daljinsko zaznanih podob. Dejstvo, da piksli niso izolirani ampak spleteni skupaj v podobo polno prostorskih vzorcev, je bilo zanemarjeno tudi zaradi omejitev strojne in programske opreme. Klub tej pomanjkljivosti je pikselna klasifikacija ostala nesporna skoraj tri desetletja. Šele Blaschke in Strobl izpostavila problem osredotočenosti statistične analize izključno na posamezne piksele, namesto na prostorske vzorce, ki jih le ti skupaj ustvarjajo (Blaschke et al., 2008).

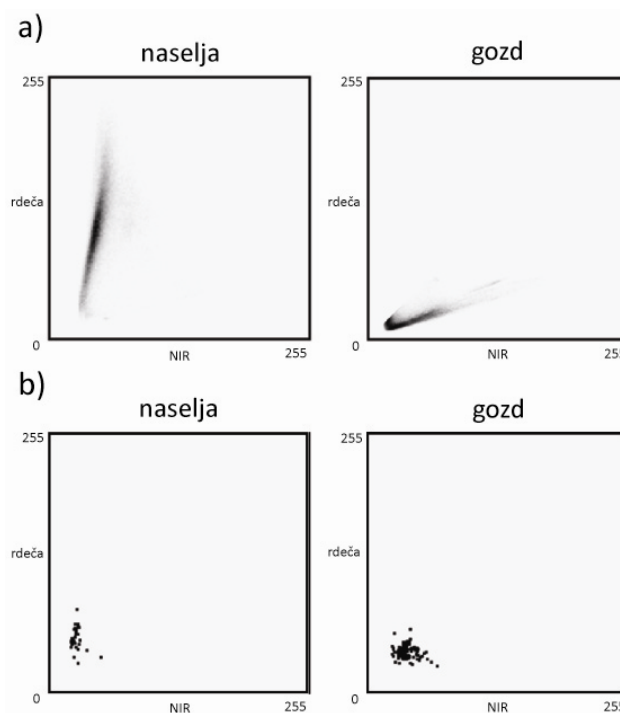
Novo metodo razvrščanja so sprožili napredni visoko ločljivostni satelitski sistemi (VHRS) z izredno detajlnimi podobami, na katerih pa so piksli premajhni, da bi predstavljali razred določene pokrovnosti/rabe tal. Ker ima uporaba objektne usmerjenega pristopa smisel le, če zagotavlja prednosti v primerjavi z ostalimi metodami, je bilo zato do danes opravljenih že mnogo študij o primerjavi pikselne in objektne klasifikacije. Številne publikacije, ki so predstavile primerjavo obeh klasifikacij, kažejo na to, da se na podobah s srednjo in relativno visoko prostorsko ločljivostjo, kot so Landsat-7 ETM+ in SPOT-5, da z objektno usmerjeno metodo pridobiti boljše rezultate (Baatz in Schäpe 2000, Willhauck et al. 2000, Hay et al. 2005, Kamagata et al. 2005, Manakos et al. 2000, Whiteside et al. 2005, Yan et al. 2006...). Obratno pa so študije pokazale, da na podobah z grobo ločljivostjo (100 do 250 m) objektna klasifikacija ni dosegla boljše natančnosti v primerjavi s pikselo.

Objektno usmerjena klasifikacija domneva, da so lahko objekti na podobah povezani in dodeljeni ustreznemu realnemu predmetu na površju Zemlje, medtem ko en sam piksel pri podobah visokih ločljivosti ne more predstavljati en sam realen predmet (slika 6). Zato tudi večina parametrov značilnih za objektni pristop klasifikacije ne more biti uporabljenih pri pikselni klasifikaciji. Objekti imajo veliko število lastnosti, npr. obliko, velikost, spektralni odboj, teksturo in ostale, ki se uporabljajo pri razvrščanju predmetov. Objektna klasifikacija ponuja več možnosti pri obdelavi podob in lahko izkorišča prednosti, ki jih ponujajo analize geografskih informacijskih sistemov (GIS) (Navulur, 2007).



Slika 6: Primerjava pikselne (a) in objektno usmerjene (b) klasifikacije. (Oruc et al., 2004)

Spektralno obnašanje objektov na podobi je podobno tipičnemu spektralnemu obnašanju pikslov. Na primer, gozdne površine so zastopane v zelenem kanalu s temnimi piksli/segmenti, medtem ko so naselja zastopana s svetlimi piksli/segmenti. Takšno obnašanje je mogoče opaziti tudi na sliki 7. Diagrami prikazujejo porazdelitev a) sivih vrednosti pikslov naselij in gozdnih površin v primerjavi z b) srednjo vrednostjo objektov naselij in gozdov v rdečem in bližnjem infrardečem (NIR) kanalu.



Slika 7: Spektralno obnašanje pikselov (a) v primerjavi z objekti (b) na primeru naselja in gozda. (Walter, 2004)

Čeprav so rezultati pri objektno usmerjenem pristopu videti precej čistejši, pa lahko podobne rezultate dobimo tudi s pikselno metodo klasifikacije. To se lahko doseže z uporabo tehnik kot so razbijanje gruč (*ang. cluster bursting*), maskiranje (recimo velikih območij golih tal) in ostalimi GIS analizami, ki omogočajo pridobitev rezultatov podobnih objektnemu pristopu.

4.5 Pikselna klasifikacija

Pikselna klasifikacija je tradicionalna tehnika klasificiranja v daljinskem zaznavanju. Za razvrstitev celotne podobe se klasificira spektralna informacija vsakega piksla. Večina metod pikselne klasifikacije temelji na klusterskih analizah (gručenju). V tem primeru se individualni n-razsežni vektorji pikselov v n-razsežnem prostoru analizirajo, razred pa se pikslu dodeli na enega od načinov, na primer, s pomočjo statističnih metod, s tehniko mehke logike (*ang. fuzzy-logic*) ali z metodo nevronske mreže (*ang. neural networks*). Cilj vseh pikselnih metod je zunanje ločevanje notranje homogenih razredov. To pomeni da morajo biti vse spektralne vrednosti dodeljene razredu čimbolj podobne med seboj oziroma morajo

biti razlike spektralnih vrednosti različnih razredov čim večje. Pikselska klasifikacija je lahko nenadzorovana ali nadzorovana s pomočjo referenčnih podatkov in učnih vzorcev.

Pikselsko usmerjene metode so doslej najpogosteje uporabljene vrste klasifikacij v daljinskem zaznavanju. Posledica tega je dejstvo, da so te metode do danes že podrobno preučene in detajlno matematično izpeljane. Predstavljene so v številnih publikacijah, kot na primer: Albertz (2001), Canty (1999), Lillesand et al. (2003) ter Richards in Jia (1999) (Nussbaum in Menz, 2008).

Ker se diplomska naloga osredotoča na objektno usmerjeno klasifikacijo pikselske metode v tem delu ne bodo podrobneje predstavljene.

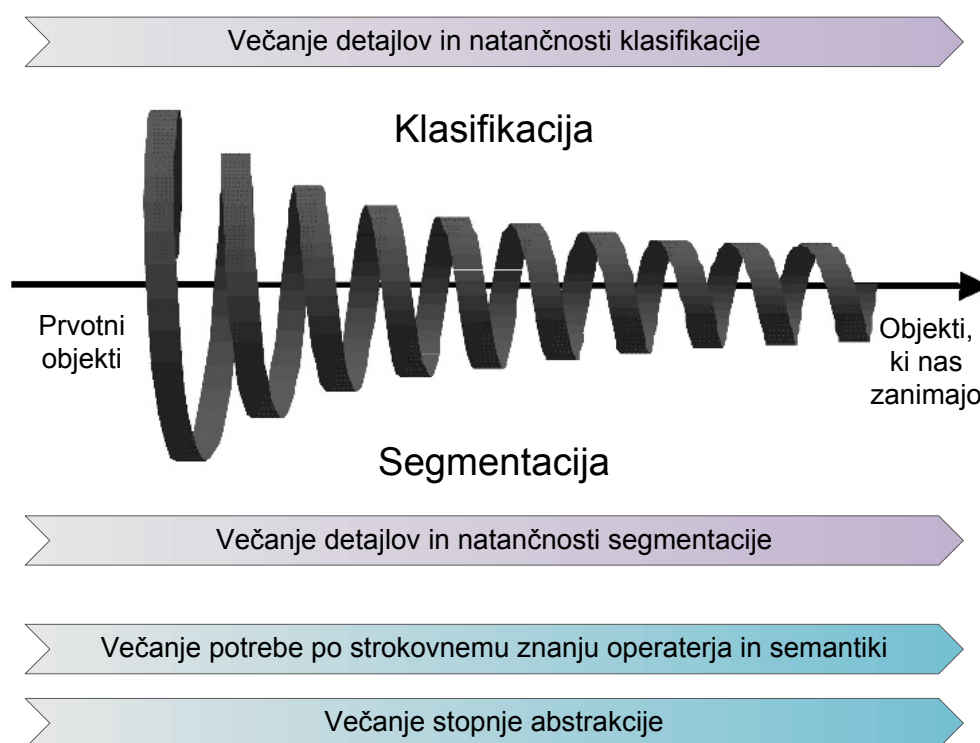
5 OBJEKTNA KLASIFIKACIJA

Objektno usmerjena klasifikacija predstavlja novo podvejo znanosti geografsko informacijskih sistemov (GIS), ki kot osnovno enoto uporablja regije, pridobljene iz daljinsko zaznanih posnetkov, v nadaljnjem besedilu imenovane objekti na podobi ali segmenti. Objekt na podobi je območje z določeno prostorsko, spektralno (svetlost in barva) ter teksturno karakteristiko.

Pri objektni metodi razvrščanja imamo opravka z dvema pojmom objektov – objekti na podobi (segment) ter geografski objekti. Objekti na podobi so diskretne regije na digitalnem posnetku ustvarjene pri procesu segmentacije, ki so notranjo skladne in se razlikujejo od njegove okolice, geografski objekti pa so resnični objekti na zemeljski površini. Objekti na podobah (sami ali v skupku) so boljši ali slabši prikaz geografskih objektov v resničnosti.

5.1 Postopek objektno usmerjene klasifikacije

Objektno usmerjena klasifikacija temelji na dveh fazah; v prvem koraku se piksli združujejo v objekte (segmentacija), ki so v drugem koraku analizirani in razvrščeni (klasifikacija). To pomeni da v prvem koraku ustvarjeni objekti vplivajo na končni rezultat klasifikacije, čeprav morda med potekom analize še ne predstavljajo končnega objekta, ki nas zanima (npr. ena zgradba, drevo, itd.) (Blaschke et al., 2008). Segmentacija in klasifikacija sta torej v vzajemni odvisnosti, saj se podrobnosti in natančnosti prve prenašajo na drugo. Tako so lastnosti in kakovosti atributov, uporabljenih za ocenjevanje in razvrščanje objektov, neposredno odvisni od načina kako so bili objekti tvorjeni prej. Postopek obdelave se prične s preprostimi koraki segmentacije, kjer skoraj ni potrebno imeti nobenega znanja za obvladovanje poteka, vendar pa strokovno znanje pride še kako prav v kasnejših fazah analize. Bolj kot se proces približuje končnemu ciljnemu objektu, bolj se večja potreba po strokovnem znanju, prav tako pa se pridobiva več informacij iz izvorne podobe (Blaschke et al., 2008). V spirali, ki predstavlja objektno usmerjen pristop (slika 8), vsak korak temelji na rezultatih prejšnjih korakov.



Slika 8: Splošni postopek objektno usmerjene klasifikacije. (Blaschke et al., 2008)

5.1.1 Prednosti in slabosti objektno usmerjene klasifikacije

Prednosti objektno usmerjene klasifikacije so, povzeto po Blaschke et al. (2008), naslednje:

- Ločevanje podob na objekte je soroden način človeškemu konceptualnemu razumevanju okolja.
- Uporaba objektov kot osnovnih enot na podobah zmanjšuje zahtevnost računskih algoritmov in hkrati omogoča uporabnikom, da izkoristijo računsko bolj zapletene tehnike.
- Objektno usmerjena klasifikacija uporablja uporabne funkcije objektov za njihovo razvrščanje (oblika, tekstura, odnose z drugimi objekti...).
- Objekti se lažje pretvorijo v vektorje kot rezultati pikselske klasifikacije.
- Število prosto dostopnih programskih oprem za potrebe objektno usmerjene klasifikacije neprekinjeno narašča.

Slabosti objektno usmerjene klasifikacije pa so:

- Pri obdelavi velikih podatkovnih baz je potrebna velika procesorska moč, saj se pri segmentaciji multispektralnih podob obdeluje zelo velika količina pikslov.
- Segmentacija nima enotne rešitve, saj lahko na primer že z majhno spremembo bitne globine dobimo drugačne rezultate. Ampak je v tem primeru podatkov mnogo manj.
- Objektni način klasifikacije je nova metoda daljinskega zaznavanja, zato na tem področju še vedno ne obstaja dovolj soglasij in raziskav pri odnosu med objektom ustvarjenim pri postopku segmentacije in realnim geografskim objektom.
- Obstaja slabo razumevanje stopenj in hierarhičnih odnosov med objekti pridobljenimi pri različnih ločljivostih.

5.1.2 Uporaba objektno klasifikacije

Kot že omenjeno, je uporaba objektno klasifikacije primernejša za visoko ločljive daljinsko zaznane podobe. V osnovi je uporaba objektno klasifikacije enaka uporabi ostalim analizam daljinskega zaznavanja, kjer se prostorske informacije uporabljajo za pomoč pri načrtovanju in usklajevanju globalnih sprememb preko obdelave podatkov in analitičnih postopkov.

Če opišemo bolj natančno pa lahko objektno klasifikacijo na interpretiranih podobah uporabljamo za na primer:


- Ugotavljanje sprememb na površju Zemlje med različnimi časovnimi obdobji. Za ta postopek se potrebuje dva v različnem času pridobljena daljinsko zaznana posnetka, ki ju primerjamo med seboj. Vsak objekt na prvi podobi se primerja z ustreznim objektom na drugem posnetku, kar privede do stopnje sprememb med obema podobama. Za digitalno ugotavljanje sprememb med posnetki je razvitih kar nekaj različnih tehnik (Blaschke et al., 2008). Objektna klasifikacija je za ta postopek pri visoko ločljivostnih podobah bolj uporabna kot pikselska klasifikacija, saj se pri slednji zazna preveč detajlov. Preveč detajlov privede do problema, imenovanega »sol in poper« učinek, ki je posledica naključne razlike odboja senzorja in samih bistvenih značilnosti pokrovnosti/rabe tal (Lobo, 1997).

- Za načrtovanje in upravljanje z zemljišči. Preiskave, ki dajejo vpogled v spremembe na zemeljskem površju, npr. v mestni krajini, so izjemno pomembne za načrtovanje in upravljanje z zemljišči. Nenadzorovana širjenja, ki so se zgodila v večjih mestih v državah v razvoju, predstavljajo oviro za urbano upravljanje (Blaschke et al., 2008).
- Izdelavo kart majhnih meril.


5.2 Segmentacija

Pri izvajanju objektno usmerjene klasifikacije zahteva proces segmentacije posebno pozornost. Pri tem postopku gre za razmejevanje podobe v homogene segmente z združevanjem sosednjih pikslov s podobnimi funkcijskimi vrednostmi (svetlost, tekstura, barva, itd.). Skupek ustvarjenih segmentov pri segmentaciji praviloma še ne predstavlja realnih objektov na podobi ampak le njihove dele. Ti deli oziroma segmenti predstavljajo podobjke geografskih objektov na podobi (slika 9). Šele z njihovim združevanjem v kasnejših fazah dobimo realne objekte tipične pokrovnosti/rabe tal.

S pomočjo mrežne strukture se za vsak segment na podobi pozna skladnost, njegove sosedske odnose ter njegove nadrejene in podrejene objekte na podobi. Slika 10 shematično prikazuje načela hierarhične mreže na posameznih ravneh segmentacije (Nussbaum in Menz, 2008).



Slika 9: Skupek podobjektov (segmentov) ustvari realen objekt.



Slika 10: Hierarhična mreža posameznih ravni segmentacije. (Nussbaum in Menz, 2008)

Izraz segmentacija je torej uporabljen kot povzetek vseh postopkov, ki gradijo, spreminjajo, spojijo, režejo, krčijo ali kakorkoli spreminjajo objekte na podobi (Blaschke et al., 2008). Segmentacija zmanjšuje stopnjo podrobnosti in zapletenosti na podobi ter ji daje skopost. Glavna skrb pri segmentaciji je izbira parametrov segmentacije, ki pa po navadi temeljijo na preizkušanju in napakah. Pri izbiri teh parametrov se predvsem pričakuje, da se podoba razdeli na semantično pomembne segmente, ki bodo lahko prepoznavni v naslednjih korakih obdelave.

5.2.1 Lastnosti (atributi) objektov

Skupek segmentov, ki tvorijo podobo, ima določene lastnosti. Lastnosti oziroma atributi so izrazita posebnost objektov na podobi, na katere se nanaša objektna klasifikacija, saj omogočajo kasnejšo klasifikacijo objektov na podobi v razrede. Vrednosti atributov so odvisne od izbrane metode izračuna, v splošnem pa jih delimo na (Navulur, 2007):

- prostorske (oblika, velikost, dolžina...),
- spektralne (lastnosti multispektralnih pasov kot npr. povprečje, standardna deviacija...),
- morfološke (parametri oblike, tekstura...),
- kontekstualne (bližina sosednjih pikslov, analiza bližine...),
- časovne (časovna obdobja...), itd.

V programski opremi ENVI Zoom, ki je bila uporabljena v diplomski nalogi, lahko določimo katere lastnosti program računa za vsak segment. V sledečih razpredelnicah so navedeni atributi in njihovi opisi, ki se uporabljajo v tem programu za razvrščanje objektov.

Preglednica 1: Prostorski atributi objektov. (ENVI User's guide, 2008)

Atribut	Opis
Površina	Skupna površina poligona minus površina lukenj.
Dolžina	Skupna dolžina vseh mej poligona vključno z mejami lukenj.
Jedrnost (kompaktnost)	Mera za kompaktno obliko poligona. Krog ima najbolj kompaktno obliko z vrednostjo $\frac{1}{\pi}$.
Konveksnost	Mera konveksnosti poligona. Vrednost konveksnega poligona je 1,0, konkavnega pa manj kot 1,0.
Trdnost (zgoščenost)	Mera, ki primerja površino poligona s površino konveksnega okvirja poligona. Vrednost konveksnega poligona je 1,0, konkavnega pa manj kot 1,0.
Okroglost	Mera, ki primerja površino poligona s kvadratom največjega polmera v poligonu (dolžina glavne osi okvirja, ki obdaja poligon). Vrednost okroglosti za krog je 1,0, za kvadrat pa $\frac{4}{\pi}$.
Faktor oblike	Mera, ki primerja površino poligona s kvadratom obsega poligona. Vrednost faktorja oblike kroga je 1,0, kvadrata pa $\frac{\pi}{4}$.
Podaljšanost	Razmerje med glavno in najmanjšo osjo v poligonu. Kvadrat ima vrednost podaljšanosti 1,0, pravokotnik pa več kot 1,0.
Pravokotnost	Mera, ki pokaže kako dobro je oblika poligona opisana s pravokotnikom. Primerja se površina poligona z orientiranim okvirjem okoli poligona. Pravokotnik ima vrednost 1,0, nepravokotne oblike pa manj kot 1,0.
Kot med glavno in osjo x	Kot, ki leži nasproti glavne osi poligona ter osi x. Vrednost glavne smeri se giblje med 0° in 180°, kjer je 90° smer sever/jug, 0° in 180° pa vzhod/zahod.
Dolžina glavne osi	Dolžina glavne osi orientiranega okvirja, ki obdaja poligon.
Dolžina najmanjše osi	Dolžina najmanjše osi orientiranega okvirja, ki obdaja poligon.
Število lukenj v poligonu	Število lukenj, ki se nahajajo znotraj poligona.
Razmerje med površino poligona in lukenj	Razmerje med skupno površino poligona s površino zunanega obrisa poligona. Poligoni brez lukenj imajo to vrednost enako 1,0.

Naslednji štiri spektralni atributi so izračunani za vsak kanal izvorne podobe posebej.

Preglednica 2: Spektralni atributi objektov. (ENVI User's Guide, 2008)

Atribut	Opis
Minimalna vrednost pikslov	Minimalna vrednost pikslov, ki sestavljajo regijo v posameznem kanalu.
Maksimalna vrednost pikslov	Maksimalna vrednost pikslov, ki sestavljajo regijo v posameznem kanalu.
Povprečna vrednost pikslov	Povprečna vrednost pikslov, ki sestavljajo regijo v posameznem kanalu.
Standardna deviacija	Standardna deviacija pikslov, ki sestavljajo regijo v posameznem kanalu.

Preglednica 3: Teksturni atributi objektov. (ENVI User's guide, 2008)

Atribut	Opis
Povprečen razpon pikslov	Povprečen razpon pikslov, ki sestavljajo regijo znotraj jedra.
Povprečna vrednost pikslov	Povprečna vrednost pikslov, ki sestavljajo regijo znotraj jedra.
Povprečna varianca pikslov	Povprečna varianca pikslov, ki sestavljajo regijo znotraj jedra.
Povprečna entropija pikslov	Povprečna entropija pikslov, ki sestavljajo regijo znotraj jedra.

Tekstura je podana v obliki digitalnih vrednosti, ki je prikazana v sivih tonih.

Preglednica 4: Razmerje kanalov in barvni prostor. (ENVI User's guide, 2008)

Atribut	Opis
Razmerje kanalov	Vrednosti v razponu od -1,0 do 1,0
Odtenek	Odtenek je pogosto uporabljen kot barvni filter in se meri od 0° do 360°. Vrednost 0 je rdeča, 120 zelena in 240 modra barva.
Nasičenost	Nasičenost je pogosto uporabljena kot barvni filter, vrednosti se merijo od 0 do 1,0.
Intenziteta	Intenziteta pogosto zagotavlja boljše merjenje svetlosti kot povprečna vrednost pikslov. Vrednosti se merijo od 0 do 1,0.

Za izračun atributov barvnega prostora (odtenek, nasičenost, intenziteta) je potrebna multispektralna podoba z najmanj tremi kanali. Razmerje kanalov pa se računa po naslednji formuli:

$$\frac{B_2 - B_1}{B_2 + B_1} \quad (1)$$

Kot že omenjeno je razmerje kanalov v razponu med -1,0 in 1,0. Če dodelimo B_1 rdečemu kanalu in B_2 infrardečemu kanalu dobimo atribut, ki predstavlja normirani diferencialni vegetacijski indeks (NDVI). NDVI zavzema vrednosti med -1 in 1 in ima velik pomen pri opazovanju vegetacije. Zelena, zdrava vegetacija ima visoko vrednost NDVI (klorofil absorbira rdečo svetlobo in močno odbija svetlobo v bližnjem infrardečem delu elektromagnetnega spektra), medtem ko ima nezdrava vegetacija in druge površine (voda, prst...) enak odboj v rdečem in infrardečem spektralnemu območju in s tem nizko vrednost NDVI (Oštir, 2006).

5.2.2 Vrste segmentacijskih algoritmov

Objekti niso nujno vedno pridobljeni samo iz podatkov na podobah, ampak so lahko pridobljeni iz katerekoli prostorsko porazdeljene spremenljivke (npr. nadmorska višina, nagib in lega terena, gostota poseljenosti...). Natančno oblikovani objekti na podobi, ki so opredeljeni kot regije z oblikovno in spektralno homogenostjo, zagotavljajo osnovo za kasnejši postopek klasifikacije.

Ker se proces segmentacije uporablja tudi na drugih področjih raziskav (v medicini, neuroinformatiki, telekomunikacijah...), so na voljo številne metode segmentiranja. Žal pa večina teh algoritmov ne vključuje spektralnih in prostorskih informacij in le redko kateri od teh so bili dejansko uporabljeni pri klasifikaciji daljinsko zaznanih podob.

V splošnem se segmentacijski algoritmi lahko razdelijo v dva razreda:

- algoritmi na osnovi večanja regij (*ang. region growing*) in
- algoritmi na osnovi robov (*ang. edge-based*).

Pri metodi na osnovi večanja regij se segmenti oblikujejo tako, da se primerni začetni piksli (semena) večajo v regije z njihovimi sosednjimi piksli, ki izpolnjujejo izbrane kriterije homogenosti (Gao et al., 2007). Ta postopek se ponavlja vse dokler ni dosežena neka predpisana meja, ki temelji bodisi na podobnosti ali velikosti teh regij oziroma dokler niso vsi piksli razdeljeni v objekte.

Metoda na osnovi robov pa začne segmentiranje z iskanjem močnih gradientov na podobi, saj se predpostavlja, da prav te prekinitve oziroma spremembe določajo meje segmentov. Robovi segmentov se sestavljajo in skupaj tvorijo skupek mej segmentov (Nussbaum in Menz, 2008).

Obstajajo trije glavni kriteriji, po katerih različni algoritmi segmentacije kombinirajo posamezne piksele v objekte na podobah in sicer: homogenost znotraj segmenta, ločenost (drugačnost) od sosednjih elementov in homogenost oblike. Ker merila v celoti ne morejo biti izpolnjena sočasno, saj se delno izključujejo med seboj, veliko algoritmov segmentacije poudarja samo nekatera od njih (Nussbaum in Menz, 2008).

Enega izmed najbolj obetajočih pristopov za segmentacijo daljinsko zaznanih podob, ki je uporabljen v programski opremi *Definiens*, sta razvila Baatz in Schäpe (2000). Segmentacija v tem pristopu vključuje preučitev vrednot posameznih pikselov in njihovih sosedov (Definiens, 2008) na podlagi primerjave digitalne vrednosti (avtorji navajajo *color criterion*) (h_{barva}) ter oblikovnega in prostorskega merila (avtorji navajajo *shape or spatial criterion*) (h_{oblika}). Ti dve merili sta uporabljene za določevanje objektov na podobah z uporabo splošne segmentacijske funkcije (S_f):

$$S_f = w_{barva} \cdot h_{barva} + (1 - w_{barva}) \cdot h_{oblika}, \quad (2)$$

kjer je w_{barva} utež spektralne barve v razmerju z obliko, določena s strani operaterja. Utež zavzema vrednosti med 0 in 1. Če operater želi, da se daje večji poudarek spektralni (barvni) karakteristiki pri ustvarjanju homogenih objektov v bazi podatkov, je utež w_{barva} močnejša (npr. 0.8). V nasprotnem primeru, torej če so prostorske značilnosti bolj pomembne pri nastajanju objektov, pa je važnejša utež oblike segmentov.

Spektralna heterogenost (h_{barva}) objekta na podobi je izračunana kot vsota standardnih odklonov spektralnih vrednosti vsakega kanala σ_k , pomnožene z utežjo vsakega kanala (w_k).

$$h_{barva} = \sum_{k=1}^m w_k \cdot \sigma_k, \quad (3)$$

Merilo oblike se izračuna s pomočjo dveh parametrov: kompaktnosti in gladkosti. Kompaktna oblika (cpt) je opisana z razmerjem med dolžino piksla l in kvadratnim korenem števila pikslov n , ki tvorijo objekt na podobi.

$$cpt = \frac{l}{\sqrt{n}} \quad (4)$$

Gladkost pa je razmerje med dolžino piksla l in najkrajšo dolžino meje b od okvirja, ki omejuje objekt na podobi:

$$smooth = \frac{l}{b}, \quad (5)$$

Merilo oblike vključuje ti dve meritvi z uporabo enačbe (Definiens, 2003):

$$h_{oblika} = w_{cpt} \cdot h_{cpt} + (1 - w_{cpt}) \cdot h_{smooth}, \quad (6)$$

kjer w_{cpt} predstavlja merilo kompaktnosti.

Merilo je definirano v mejah $0 \leq w_{cpt} \leq 1$, nastavljen pa je ročno s strani operaterja.

Sprememba heterogenosti oblike, ki jo povzroča vsaka združitev segmentov se ocenjuje z izračunom razlike med začetkom in koncem postopka združitve objektov na podobi (ob). To se kaže v naslednjih algoritmihi za izračun hrapavosti in gladkosti (Definiens, 2008):

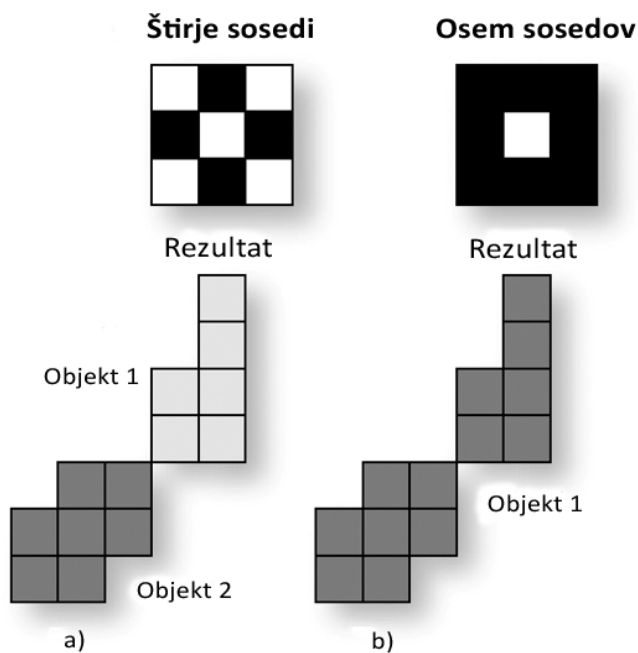
$$h_{cpt} = n_{mg} \cdot \frac{l_{mg}}{\sqrt{n_{mg}}} - \left(n_{ob1} \cdot \frac{l_{ob1}}{\sqrt{n_{ob1}}} + n_{ob2} \cdot \frac{l_{ob2}}{\sqrt{n_{ob2}}} \right), \quad (7)$$

$$h_{smooth} = n_{mg} \cdot \frac{l_{mg}}{b_{mg}} - \left(n_{ob1} \cdot \frac{l_{ob1}}{\sqrt{n_{ob1}}} + n_{ob2} \cdot \frac{l_{ob2}}{\sqrt{n_{ob2}}} \right), \quad (8)$$

kjer n predstavlja velikost objekta v pikslih.

Eno od meril za segmentacijo daljinsko zaznanih podatkov je računanje vrednosti pikslov v njihovi okolici (*ang. pixel neighborhood*). S tem algoritmom se primerja objekte na podobi s sosednjimi piksli in se določi ali naj se sosednji piksel združi z obstoječim objektom na podobi ali pa naj bo del novega objekta. Da se lahko objekti in piksli združijo imamo na razpolago dve vrsti algoritmov:

- a) Če izberemo funkcijo združevanja s štirimi sosedi (*ang. plane four neighbourhood*) se ustvarita dva objekta na podobi, saj se piksli pri tem postopku ne priključijo vedno na drug, sosednji objekt (primer slika 11 a).
- b) Piksli in objekti so pri funkciji z osmimi sosedi (*ang. diagonal eight neighborhood*) opredeljeni kot sosedi, če se z objektom dotikajo po robu ali samo z robno točko. Objekt 1 se v primeru b) slike 11 na podobi razširi, saj sta segmenta povezana drug z drugim z robno diagonalno točko. Posledica tega so večji objekti na podobi.




Slika 11: Določanje segmentov v okolici z načinom štirih oziroma osmih sosedov.

5.2.3 Prekomerna in prešibka segmentacija

Segmentacija podob se sooča z dvostranskim problemom. Prvič, s prekomerno segmentacijo (*ang. oversegmentation*), ki je posledica nezadostnega kontrasta med nekaterimi sosednjimi segmenti, zaradi česar dobimo namesto enega večjega več manjših segmentov. In drugič, s prešibko segmentacijo (*ang. undersegmentation*), kjer pa so segmenti preveliki in zato izgubijo svojo spektralno homogenost. V tem primeru bi jih bilo potrebno razdeliti v več ločenih objektov. Slika 12 prikazuje primera prevelike in prešibke segmentacije.

Na splošno predstavlja prekomerna segmentacija manjši problem kot prešibka segmentacija, saj je v kasnejših fazah analize vseeno lažje združevati segmente kot jih razdruževati. Dobra segmentacija pa je vseeno tista, kjer ne prevladuje nobena od skrajnosti. Primerni segmentacijski algoritmi so tisti, ki zagotavljajo uporabniku dobro segmentacijo brez zamudnih in natančnih nastavitev vhodnih parametrov (Blaschke et al., 2008).



Slika 12: Primer prekomerne (a) in prešibke (b) segmentacije.

5.3 Semantična klasifikacija

Semantična klasifikacija določi ali objekti na podlagi njihovih značilnosti spadajo ali ne spadajo v določen objektni razred. S stopnjo zaupanja se primerja posamezne značilnosti oziroma attribute segmenta. Ta stopnja zaupanja podaja informacijo o tem ali objekt spada v določen razred ali ne oziroma ali so segmenti »pripadniki« (*ang. membership*) nekega razreda ali ne (Nussbaum in Menz, 2008). Pripadništvo se lahko določi objektom s pomočjo različnih pristopov. Homogeni objekti na podobah so po postopku segmentacije lahko klasificirani:

- s tradicionalnimi algoritmi klasifikacij (npr. metoda najmanjše razdalje, metoda največje verjetnosti, paralelepipedna metoda),
- na osnovi definiranih pravil (*ang. knowledge-based approach*) ali
- s klasifikacijo mehke logike.

Točnost in pomen končnih meritev klasifikacije so neposredno odvisne od kakovosti segmentacije.

6 POKLASIFIKACIJA

Klasificirane podobe zahtevajo obdelavo, modeliranje ter generalizacijo dobljenih razredov za izvoz v vektorske GIS-e in s tem pridobitev razumljivega končnega produkta – kartografske podlage.


Zaradi enostavnejših kasnejših obdelav se dobljene klasificirane vektorske podatke v koraku poklasifikacije pogostoma rastrira, saj so razne rastrske operacije po navadi hitrejše. V vektorsko obliko sem za lažje nadaljnje delo pretvorila rezultate klasifikacije v diplomski nalogi.

Za doseg boljših končnih produktov je na voljo veliko orodij, ki izpolnjujejo te zahteve. Primer sta v nalogi uporabljeni operaciji »združi in presej« (*ang. clump and sieve*), ki se uporabljata za generalizacijo podob pridobljenih s postopkom klasifikacije. Funkcija »presej«, ki se običajno izvede v prvi fazi, predstavlja sito, saj odstranjuje izolirane segmente na klasificirani podobi glede na velikost, ki jo definira uporabnik. Ta metoda pri izračunu upošteva sosednje piksele (štiri ali osem) in na ta način določi, če je piksel dodan nekemu razredu ali ne. Pikseli, ki so manjši od definirane vrednosti velikosti, so iz podobe odstranjeni.

Klasificirane podobe pogostokrat trpijo zaradi pomanjkanja prostorske koherentnosti (luknje na podobi), kar pa rešujemo z operacijo »združi«. Izbranim obstoječim razredom ustvarimo skladnost z združevanjem sosednjih podobnih klasificiranih območij. Razredi so združeni tako, da se na klasificirani podobi prvo izvede operacija razširitve razredov (*ang. dilate filter*), kjer se zapolnijo luknje segmentov, ki so manjši od izbrane vrednosti. V naslednjem koraku se velikosti razredov zmanjšajo na določeno vrednost, npr. 3×3 (*ang. erode filter*). To sta dva morfološka filtra, ki jih uporablja funkcija »združi«, katere parametre nastavi uporabnik v dialogu aplikacije.

Čeprav sta funkciji enostavni, je potrebno pred izbiro vhodnih parametrov dobro preučiti katere segmente želimo združiti in katere obdržati.

Desna podoba na sliki 13 prikazuje rezultate obdelave z operacijama »združi in presej«. Majhni segmenti, ki so še videni na neobdelani klasificirani podobi so združeni s prevladujočimi razredi v okolici, prav tako pa je oblika segmentov generalizirana.



Slika 13: Analiza "združi in presej". Primer a) prikazuje stanje pred obdelavo, stanje b) pa po obdelavi.

7 NATANČNOST KLASIFIKACIJE

Ko je podoba klasifikacije pridobljena, nas zanima natančnost razdelitve segmentov v razrede. Pri objektno usmerjeni klasifikaciji uporabljamo skoraj identične postopke ovrednotenja klasifikacije kot pri pikselni klasifikaciji. Za ovrednotenje natančnosti potrebujemo poleg klasificirane podobe še referenčno podobo ali podatke pridobljene s terenskim ogledom.

Natančnost klasifikacije je stopnja do katere se podoba pridobljena s klasifikacijo ujema z resničnostjo (Campbell, 1996), torej je napaka klasifikacije razlika med tematsko karto in resničnostjo. Eden od najpogosteje uporabljenih prikazov natančnosti klasifikacije je klasifikacijska matrika napak (*ang. confusion matrix*). S pomočjo matrike v obliki preproste navzkrižne tabele se ugotavlja odnos med referenčnimi »resničnimi« podatki in rezultati klasifikacije v odstotkih pravilno razvrščenih razredov. Matrika je kvadratna, število stolpcev in vrstic ustreza številu razredov. Vsak stolpec v matriki napak predstavlja razred referenčnih podatkov, vrstice pa predstavljajo klasificirane rezultate. Točnost klasifikacije posameznih razredov je izražena kot delež pravilno razvrščenih segmentov glede na celotno število segmentov tega razreda. Vrednosti v diagonalnih poljih podajajo število pravilno klasificiranih pikselov, števila v ostalih poljih pa so napake.

»V primeru uporabe klasifikacijske matrike napak na učnih vzorcih bi se pričakovalo, da bodo vsi piksli, izbrani kot učni za določen razred, vanj tudi uvrščeni. Vendar vedno temu ni tako, saj so izbrani piksli na učnih območjih uporabljeni zgolj za določitev statistik posameznega razreda. Redko so tako homogeni, da so vsi uvrščeni v pripadajoči razred.« (Janža, 2005).

V splošnem velja, da je pri klasifikaciji natančnost nad 90% dobra, nad 80% pa zadovoljiva (Oštir, 2006). Kvantitativne ocene natančnosti se uporablja za ocenjevanje verjetnosti pravilnih razvrstitev razredov ter splošno kakovost ali zanesljivost rezultata klasifikacije.

Tudi natančnost je zaradi rastriranja klasificiranih rezultatov izračunana na podlagi pikselov in ne segmentov.

Na osnovi podatkov matrike napak se lahko izračuna naslednje parametre, s katerimi se vrednoti natančnost klasifikacije:

- koeficient kappa,
- natančnost proizvajalca in natančnost uporabnika ter
- skupna natančnost.

7.1 Koeficient kappa

S koeficientom kappa (κ) se meri razlika med preučevano in naključno klasifikacijo in je torej drugo merilo za izračun natančnosti klasifikacije. Koeficient je definiran v razponu med 0 in 1, kjer vrednost 0 pomeni, da se z uporabljenimi klasifikacijami ni doseglo boljših rezultatov, kot bi se jih z naključno. Obratno pa vrednost 1 pomeni, da je uporabljena klasifikacija brez napake. Vrednost 0,5 pa pomeni, da je uporabljena klasifikacija za 50% boljša od naključne (Janža, 2005).

Konceptualno je koeficient kappa (κ) definiran kot (Lillesand et al., 2004):

$$\kappa = \frac{\textit{klasifikac.nat.} - \textit{naklj.nat.}}{1 - \textit{naklj.nat.}} \quad (9)$$

Izračunamo pa ga z izrazom:

$$\kappa = \frac{N \sum_{n=1}^r x_{nn} - \sum_{n=1}^r (x_{n+} \cdot x_{+n})}{N^2 - \sum_{n=1}^r (x_{n+} \cdot x_{+n})} \quad (10)$$

Kjer so:

- r število vrstic v matriki napak,
- N število vseh pikslov v matriki,
- x_{nn} vsota diagonale matrike napak,
- x_{n+} vsota vrednosti n-te vrstice,
- x_{+n} vsota vrednosti n-tega stolpca.

7.2 Natančnost proizvajalca in natančnost uporabnika

Natančnost proizvajalca (NP) je namenjena analitiku, ki je izdelal klasifikacijo. Je merilo, ki označuje verjetnost pravilno klasificiranih pikslov glede na referenčne piksele.

$$NP = \frac{\text{pravil.klasif.piksli razreda } n}{\text{vso število referen.pikslov v razredu } n} \quad (11)$$

Natančnost uporabnika (NU) služi kot vodnik za zanesljivost rezultata kot sredstva za napovedovanje in je podana kot delež pravilno klasificiranih pikslov glede na celotno število pikslov v posamezni kategoriji (Oštir, 2006).

$$NU = \frac{\text{pravil.klasif.piksli razreda } n}{\text{vso število klasif.pikslov v razredu } n} \quad (12)$$

7.3 Skupna natančnost

Skupna natančnost se izračuna kot razmerje med seštevkom vseh pravilno razvrščenih referenčnih točk in številom vseh teh točk skupaj. Pravilno razvrščene referenčne točke so izpisane diagonalno v matriki napak, skupno število referenčnih točk pa je seštevek vseh pikslov na referenčni podobi.

8 PROGRAMSKA ORODJA ZA OBJEKTNO KLASIFIKACIJO

V nadaljevanju sledi pregled pomembnejših programskih orodij, ki imajo implementirane metode objektne klasifikacije in so komercialno dostopni oziroma so dostopni samo v demo verzijah (GEOBIA Wiki, 2008). Prva programska oprema za objektno klasifikacijo *eCognition* se je na tržišču pojavila leta 2000.

8.1 Definiens Developer

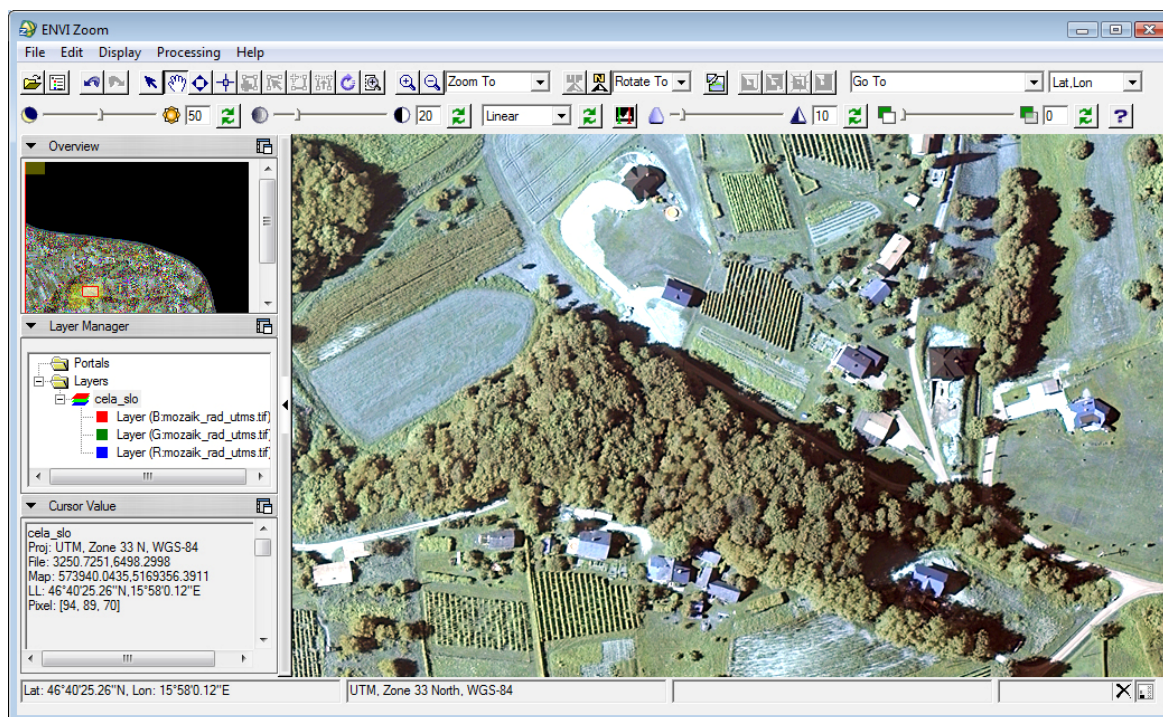
Ta program izhaja iz razvoja programa *eCognition* in je programska oprema za objektno usmerjeno analizo podob. Vsebuje različne algoritme, ki omogočajo uporabnikom, da ustvarijo mrežo objektne hierarhije. Objekti so lahko klasificirani bodisi po metodi z upoštevanjem pravil (*ang. rule-based*) ali po metodi določanja vzorcev (*ang. sample-based*). Definiens Developer je del skupine Definiens Enterprise Image Intelligence Suite, ki je sestavljena iz uporabniške in strežniške programske opreme in ustreza potrebam katerekoli obdelave podob.

8.2 Feature Analyst in LIDAR Analyst

Programski opremi Feature Analyst in LIDAR Analyst sta na voljo na različnih računalniških orodjih (ArcGIS, ERDAS IMAGINE, SOCET SET, GeoMedia...). Feature Analyst je zaokrožen sistem za avtomatiziran postopek izločanja objektov, LIDAR Analyst pa je njegov dvojnik za izločanje objektov pri lidarskih podatkih. Delovni proces objektne klasifikacije in segmentacije podob poteka preprosto in intuitivno, končni produkt obeh sistemov pa so vektorski podatki. Obe programski okolji omogočata postopek izločanja objektov, segmentacijo podob, orodje za čiščenje (*ang. cleanup tools*), avtomatsko orodje za določanje objektnih atributov (*ang. automated attribution tools*), obravnavata različne vrste podob, stereo zmogljivosti, hiperspektralne delovne procese, posodabljanje podatkovne baze ter številne druge možnosti.

8.3 ENVI Feature Extraction


ENVI Feature Extraction je del programskega paketa za daljinsko zaznavanje ENVI Zoom in omogoča izločanje objektov iz visoko ločljivostnih pankromatskih oziroma multispektralnih podob. Temelji na objektni klasifikaciji analize podob za postopek izločanja večih objektov hkrati, ki jih samodejno vektorizira v vektorski format *Shapefile*. Modul ENVI Feature Extraction uporablja kombiniran proces segmentacije podob v regije pikslov, izračun atributov posameznih regij za oblikovanje objektov in klasifikacijo teh objektov z metodo nadzorovane klasifikacije ali z metodo klasifikacije z upoštevanjem pravil. Ena izmed bolj inovativnih vidikov ENVI Feature Extraction pa je sposobnost predogleda rezultatov pri vsaki spremembi nastavitvev parametrov.



Slika 14: Programski paket ENVI Zoom, kjer je integriran modul za objektno klasifikacijo ENVI Feature Extraction.

9 UPORABA OBJEKTNE KLASIFIKACIJE V DIPLOMSKI NALOGI

Glavni cilj praktičnega dela diplomske naloge je bila pridobitev optimalne karte pokrovnosti/rabe tal z uporabo objektno usmerjene klasifikacije s poudarkom na avtomatizaciji. Slika 15 prikazuje potek delovnega procesa. Iz vseh podatkov, ki so bili na razpolago, sem izbrala najbolj primerne in jih integrirala v eno podobo. Na tej podobi sem potem izvedla segmentacijo, sledila je klasifikacija, na koncu pa sem pridobljene rezultate še primerno popravila (poklasifikacija) in ovrednotila.




Slika 15: Delovni proces

9.1 Študijski območji

V diplomski nalogi sta bili obravnavani dve študijski območji z različnimi razredi pokrovnosti tal, in sicer intenzivno kmetijsko območje Gornje Radgone in mesta Bad Radkersburg v Avstriji ter pretežno hribovito območje Kobarida z okolico na zahodnem delu Slovenije. Na obeh območjih se je določala celotna pokrovnost/raba tal, kasneje pa je bila narejena tudi podrobna analiza posnetkov za pridobitev kmetijskih zemljišč na čezmejnem območju Gornje Radgone, kjer je približno 56% celotnega območja kmetijske rabe. Kmetijske površine so bile iz celotnega posnetka izvzete z masko. Na tak način sem pridobila posnetek z ločenimi kmetijskimi zemljišči, na katerem je potekala objektna klasifikacija. Ta podrobna analiza na

regionalni integraciji (avstrijska Štajerska – severna Slovenija) je bila opravljena tudi zaradi potreb tekočega mednarodnega projekta imenovanega GMES-DSL (Servis raba tal/pokrovnost) Avstrija – Slovenija – Andaluzija : Koncept meddržavne harmonizacija informacijskega sistema rabe tal/pokrovnosti. Projekt je delno potekal v času nastajanja diplomske naloge na Inštitutu za antropološke in prostorske študije, na Znanstvenoraziskovalnem centru (ZRC) SAZU.



Slika 16: Študijski območji

9.2 Uporabljeni podatki

Vsi podatki uporabljeni v nalogi so bili pridobljeni na Inštitutu za antropološke in prostorske študije ZRC SAZU.

Osnovni vir podatkov je digitalni ortofoto (DOF). DOF je aerofotografija, ki je z upoštevanjem podatkov o reliefu in absolutne orientacije aerofotografij pretvorjena v

ortogonalno projekcijo in je v metričnem smislu enaka linijskem načrtu ali karti (Prostorski portal, 2009). Barvni DOF podobi uporabljeni v nalogi sta bili posneti iz zraka poleti leta 2006, s prostorsko ločljivostjo pol metra ter zapisani v formatu RGB z osembitno barvno globino.

Objektna klasifikacija v nalogi je bila prvotno opravljena na posnetku DOF. Ker je ta posnetek omejen samo na tri spektralne pasove (RGB), sem posnetku kasneje dodala še četrti (bližnje infrardeči) kanal posnetka SPOT, saj je le ta zelo uporaben pri klasifikaciji vegetacije. Posnetek SPOT je bil posnet 19. julija 2007 z 10 metrsko prostorsko ločljivostjo. Četrti kanal SPOT-a sem preden sem ga dodala DOF-u tudi prevzorčila na prostorsko ločljivost slednjega, to je 0,5 metra, ter uporabila še Gaussov filter, ki podobo zgladi. Gaussov filter je dvorazsežen konvolucijski filter², ki podobi odstrani podrobnosti in šum.

Dobljena kombinirana (3+1) podoba se je izkazala kot najboljša izbira za klasifikacijo. Posnetki SPOT se v celoti niso uporabili zaradi njihove slabše ločljivosti v primerjavi z letalskimi posnetki, bili bi pa uporabni za kartiranje v malem in srednjem merilu.

Poleg že omenjenih podatkov, ki sem jih pridobila pred potekom naloge so bile na voljo še podobe IRS in CORINE, vendar zaradi njihove premajhne ločljivosti v nalogi podobe niso bile uporabljene.

Za določitev učnih vzorcev ter za ocenitev rezultatov klasifikacije je bila uporabljena Karta dejanske rabe zemljišč Ministrstva za kmetijstvo, gozdarstvo in prehrano, MKGP, narejena leta 2008. Ta karta dejanske rabe je bila vzpostavljena na osnovi interpretacije letalskih posnetkov (DOF) skupaj z znatnimi raziskavami na terenu za namene administrativnih kontrol in izdelave katastra trajnih nasadov (vinogradi, sadovnjaki, hmeljišča in oljčniki). Gre za tipološko delitev vrste rabe glede na stanje dejanske rabe ob zajemu, ki skupaj ločuje 25 kategorij rabe tal v Sloveniji (PISO, 2009). Karta je narejena v merilu 1:5.000 in ima najmanjšo enoto kartiranja (*ang. minimum mapping unit, MMU*) v razponu od 10 m² (za urbane površine) do 5000 m² (za vodo). Karta kot taka zahteva veliko količino časa in dela,

² Konvolucijski filter je preprosta metoda za glajenje slik, ki omogoča zmanjšanje velikih razlik med piksli. Zelo pogosto se uporablja za izločevanje šuma v slikah.

poleg tega pa se njena točnost in natančnost spreminja glede na znanje in izkušnje izdelovalca.

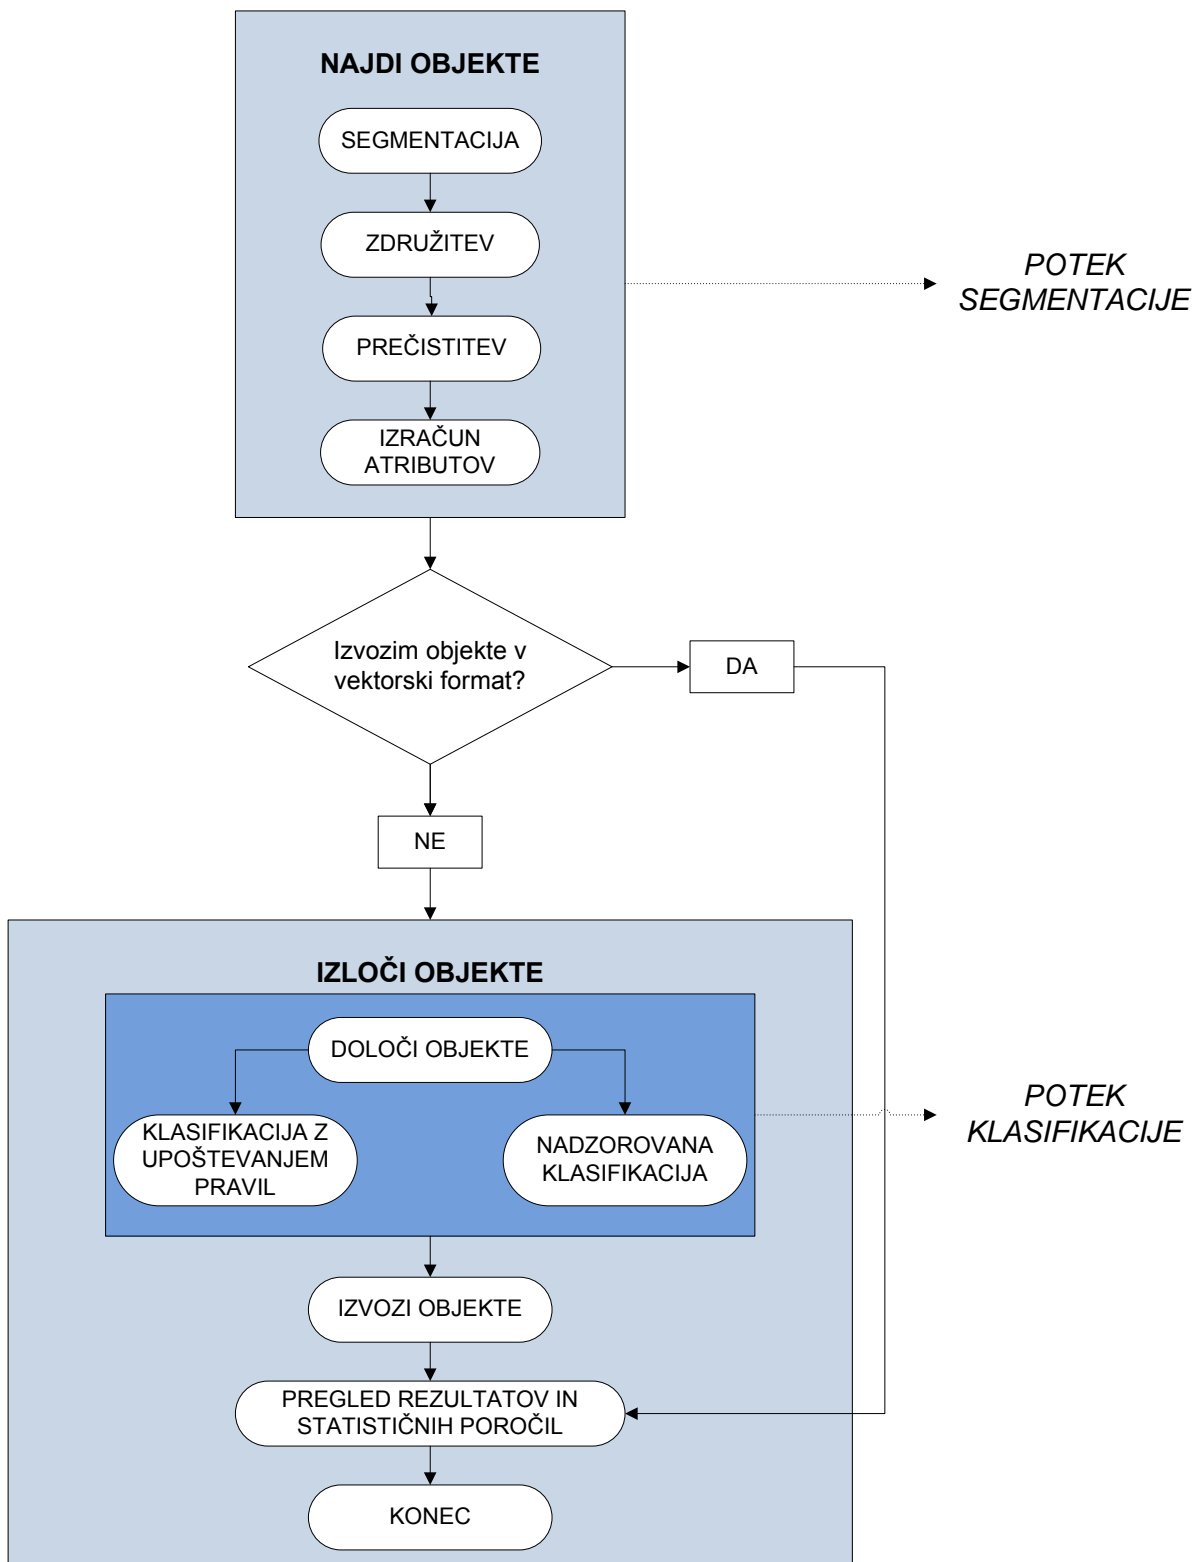
9.3 Uporabljena programska oprema

Tehnologija in metodologija uporabljena v tej diplomski nalogi je bila izdelana z naslednjimi programskimi orodji za daljinsko zaznavanje in GIS:

- ENVI Zoom, modul Feature Extraction, za segmentacijo in objektno usmerjeno klasifikacijo,
- ENVI, za maskiranje podob, poklasifikacijo in primerjalno analizo,
- ESRI ArcGIS, za obdelavo končnih vektorskih rezultatov in kartiranje.

10 POSTOPEK OBDELAVE PODOB

S pomočjo uporabljene aplikacije ENVI Zoom, modula Feature Extraction, pridemo do končnega rezultata v dveh fazah (slika 17). V prvem koraku se iz spektralnih podpisov podob kreirajo segmenti (postopek segmentacije), potem pa sledi postopek določanja teh segmentov (klasifikacija). Prvi del je nadalje še sestavljen iz štirih korakov: segmentacija, združitev, prečistitev ter izračun atributov novo nastalih objektov na podobi. Drugi del pa se sestoji iz nadzorovane klasifikacije ali klasifikacije z upoštevanjem pravil ter kasnejšim izvozom rezultatov v vektorskem formatu ali v obliki rastrske slike.



Slika 17: Potek postopka izločanja objektov iz podobe. (ENVI User's Guide, 2008)

10.1 Segmentacija

Opravljenih je bilo več poskusov segmentacije z različno definiranimi parametri. Segmenti so bili primerjani med seboj z originalnim posnetkom in orisano geografskimi objekti na njem. Postopek se je ponavljal, dokler ni bila dosežena zadovoljiva segmentacija podobe.

Kot že omenjeno poteka segmentacija v programskem okolju ENVI Feature Extraction na več nivojih. V prvem koraku je obdelana vhodna podoba z analizo segmentacije, katere cilj je ustvariti homogene objekte na podlagi štirih spektralnih pasov. ENVI Feature Extraction uporablja pri segmentaciji algoritem na osnovi robov (*ang. edge-based*). V primerjavi z ostalimi algoritmi računa ta algoritem rezultate zelo hitro in zahteva samo en vhodni parameter - stopnjo segmentacije (*ang. scale level*). S stopnjo segmentacije kontroliramo povprečno velikost objekta na podobi. Ta parameter je definiran v vrednostih od 0 do 100 (večja izbrana vrednost ustvari manj segmentov, manjša pa več).

Segmentacijski parameter je bil vedno izbran tako, da je bil prilagojen ločevanju spektralno najbližjih segmentov, čeprav je to pomenilo, da so bili drugi segmenti delno prekomerno segmentirani (presegmentirani). Na obeh študijskih območjih so to predstavljali razredi zeleni pridelki (njive) in travniki, razlog je njuna podobna vegetacijska struktura, ter razreda stavbe in ceste. Tukaj je potrebno še enkrat poudariti, da dobra segmentacija zagotavlja natančnejšo klasifikacijo.

Naslednji korak v fazi segmentacije je združitev (*ang. merge*). Združitev je dodaten, neobvezen korak, ki se uporablja z namenom, da se izboljšajo opisi mej segmentov in predvsem da se manjši objekti združijo v večje objekte. To pride prav na območjih, kjer lahko prevelika segmentacij predstavlja problem, na primer v gozdovih, vinogradih, intenzivnih sadovnjakih...

Tudi združitev se nadzoruje s parametrom, ki ga predstavlja vrednost lambda. Algoritem uporabljen pri tem procesu je Full Lambda-Schedule, ki iterativno združuje sosednje segmente glede na kombinacijo prostorskih in spektralnih lastnosti. Parameter je definiran

med vrednostma 0 in 100, kjer 0 pomeni da se segmenti sploh ne spojijo, medtem ko parameter 100 združi vse objekte v enega.

Omenjeni parameter je bil izbran na vrednost, kjer smo lahko združena območja še povezali s specifičnimi tematskimi razredi iz posnetka. Na primer, dokaj enostavno je bilo mogoče razlikovati segmente na območju vinogradov s segmenti na območju zelenih pridelkov.

Preglednica 5: Izbrani parametri pri poteku segmentacije v programski opremi ENVI za posamezno obravnavano območje.


	Parameter segmentacije	Parameter združitve
Gornja Radgona in Radkersburg	65	80
Kobarid	40	65
Gornja Radgona in Radkersburg (klasifikacija samo kmetijskih površin)	65	96



Slika 18: Originalna vhodna podoba.




Slika 19: Segmentirana podoba.



Slika 20: Podoba, kjer so segmenti še dodatno združeni.

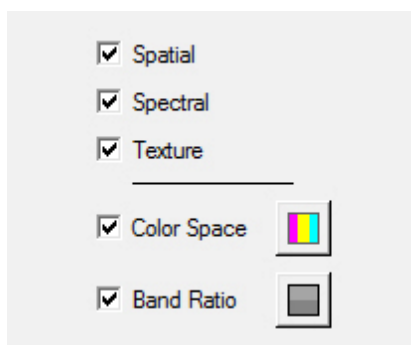
Dodatna izboljšava oziroma t.i. prečistitev rezultatov segmentacije je mogoča tudi z metodo definiranja praga (*ang. thresholding*). Ta metoda je koristna predvsem za pridobivanje značilnosti točkastih objektov (zgradb, letal...) v primeru prevelike segmentacije. Prag je rastrska operacija, ki deluje na prvem spektralnem pasu podobe in razvršča sosednje segmente glede na njihovo vrednost svetlosti. Operacija dobro deluje kadar so objekti na podobah v velikem kontrastu z njihovim ozadjem (na primer svetlo letalo na temnem asfaltu).



Slika 21: Določevanje vrednosti praga.

Nastavljene meje praga definirajo spodnje in zgornje vrednosti, kar pomeni, da se v bistvu definirajo nove meje za segmente, ki nas zanimajo (segmentom, ki so pod in nad pragom je dodeljena vrednost 0). V diplomski nalogi nisem spreminjala nastavitve na histogramu, torej se meje praga niso premikale.

Sledila je še zadnja stopnja pri segmentacijskem postopku, ki je predstavljena na spodnji sliki, to je izračun atributov (glej poglavje 5.2.1. Lastnosti (atributi) objektov).



Slika 22: Atributi, ki se računajo segmentom v programu ENVI.

Pri tem koraku se določi katere attribute naj aplikacija izračuna za vsak objekt. Atributi pomagajo določiti vrsto razreda objektu pri nadzorovani klasifikaciji oziroma klasifikaciji z upoštevanjem pravil. V primeru diplomske naloge sem izbrala vse attribute, saj se je izkazalo,

da se tako pridobijo boljši rezultati. Pri barvnem prostoru (*ang. color space*) sem pri poteku vedno izbrala kanale 2, 3 in 4 (zeleni, modri in infrardeči kanal), pri razmerju med kanali (*ang. band ratio*) pa sem izbrala rdeč in infrardeč kanal. Kot že omenjeno se s pomočjo rdečega in infrardečega lahko izračuna normirani diferencialni vegetacijski indeks.

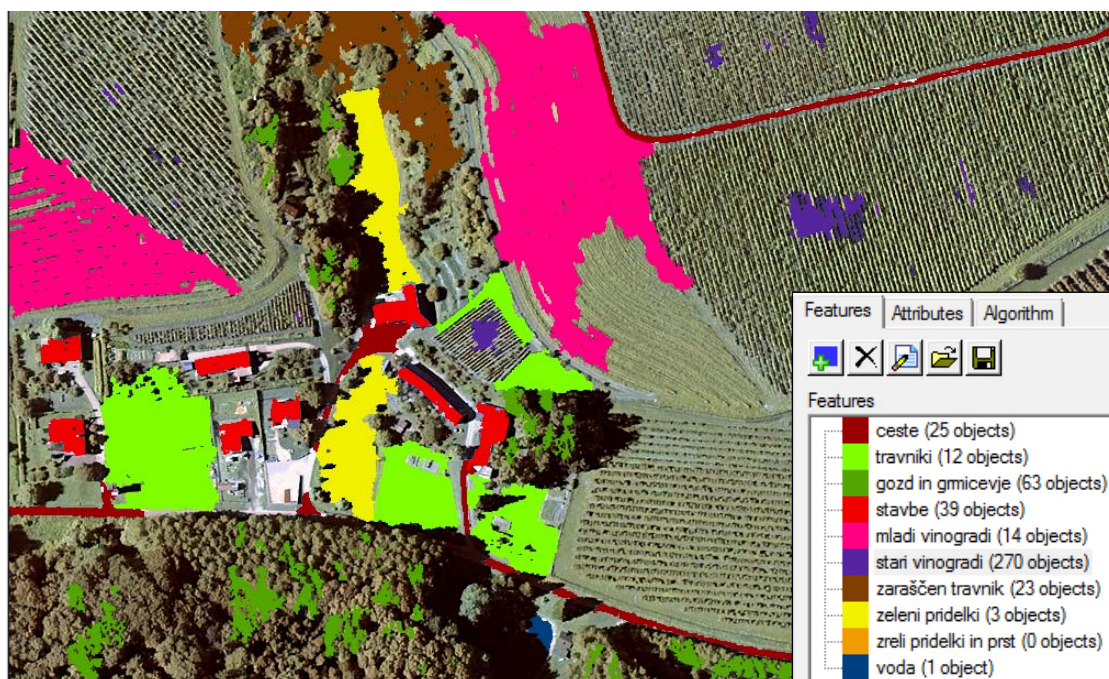
10.2 Klasifikacija

Postopek sem nadaljevala z nadzorovano klasifikacijo, ki je v večji meri kontrolirana s strani uporabnika. Za to vrsto klasifikacije sem se odločila, ker je digitalni ortofoto zaradi manjšega števila kanalov bolje klasificirati z nadzorovano klasifikacijo (večje število kanalov pomeni lažje in boljše ločevanje predmetov v nenadzorovani klasifikaciji). V fazi izbiranja vzorcev sem označila segmente (informacijske razrede), kjer sem vedela, da se nahaja določen tip površja. Ko so bili učni vzorci izbrani je program razvrstil segmente po celi podobi v izbrane razrede po algoritmu k-najbližji sosed, kjer je bil koeficient k nastavljen na vrednost 1. Algoritem k-najbližji sosed je podrobneje opisan v tej diplomski nalogi na strani 16. Pri tem so dobili segmenti različne prostorske, spektralne in teksturne attribute.

Uporabljena programska oprema ENVI Zoom omogoča tudi klasifikacijo z upoštevanjem pravil. Taka klasifikacija je običajno zelo uspešna pri tipičnih antropogenih značilnostih na površju, kot so na primer ceste, poti, stavbe, saj so zgrajene v skladu z določenimi standardi in so zato razmeroma enostavne za model (Lang in Blaschke, 2003). Do izjem pride, kadar so ti antropogeni objekti obdani z vegetacijo in so na posnetku delno ali v celoti skriti. Prav tako pa lahko do napak pride kadar imajo nekatera naravna območja morfologijo in vrednosti svetlosti podobno potem, cestam itd. V mojem primeru se ta klasifikacija ni izkazala kot dobra za vse vrste pokrovnosti/rabe tal, zato ta zvrst klasifikacije ni bila uporabljena.

Na segmentiranem posnetku, ki predstavlja vhodni podatek pri klasifikaciji, sem, kot že omenjeno, vsakemu izbranemu razredu izbrala učne vzorce, ki predstavljajo reprezentativne vzorce pokrovnosti/rabe tal. Več kot je učnih vzorcev, boljši je končni rezultat klasifikacije. Prav tako je priporočeno, da se pri določevanju učnih vzorcev označi po celotnem posnetku približno enako število reprezentativnih vzorcev za vse razrede. To je v praksi pogostoma

težko, saj se izbrani tipi pokrovnosti/rabe tal praviloma ne nahajajo na posnetkih v enaki meri (npr. v gozdnatem območju Kobarida je veliko več gozda kot kmetijskih površin).



Slika 23: Primer zajemanja učnih vzorcev.

Pri določevanju učnih vzorcev sem si pomagala s slojema dejanske rabe zemljišč MKGP in DOF, ki sta predstavljal referenčni podobi pri izbiri reprezentativnih objektov.

10.2.1 Klasifikacija Gornje Radgone/Bad Radkersburg-a in Kobarida

V primeru klasifikacije pokrovnosti/rabe tal na območju Gornje Radgone/Bad Radkersburga sem razdelila objekte na podobi v deset informacijskih razredov pokrovnosti/rabe tal, v primeru Kobarida pa zaradi drugačne pokritosti površja v osem razredov. Šest razredov je skupnih obema območjema, na vsakem posameznem območju pa najdemo še razrede, ki so specifični za del, kjer se le ta nahaja (na primer razred »nerodovitno območje – skala« je specifično za hribovito območje Kobarida, kmetijski razredi kot na primer »zeleni pridelki« pa za pretežno ravninsko območje Gornje Radgone). Tukaj so naštetni vsi razredi za oba območja:

Gornja Radgona/Bad Ratkersburg

- ceste,
- stavbe,
- travnik,
- zaraščeni travnik,
- gozd in grmičevje,
- voda,
- mladi vinogradi,
- stari vinogradi,
- zeleni pridelki ter
- zreli pridelki in prst.

Kobarid

- ceste,
- stavbe,
- travnik,
- zaraščeni travnik,
- gozd in grmičevje,
- voda,
- sadovnjak ter
- nerodovitno območje – skala.

Opis razredov

V razred »ceste« so bile zajete tako asfaltirane kot tudi tlakovane urbane površine, v razred »stavbe« pa objekti visoke gradnje (od bivanjskih stavb do industrijskih objektov).

Razred »gozd in grmičevje« v obeh obravnavanih območjih predstavljajo iglasti, listnati in mešani gozdovi ter grmičevje, čeprav je treba tukaj poudariti, da je struktura gozda zaradi različne lege in podnebnih drugačnosti med območjema različna. Gozdna vegetacija v območju Kobarida je značilno alpska (prevladuje alpski bukov gozd, nad njim alpsko ruševje, na skrajnih rastiščih pa gozd gabrovca in malega jesena), medtem ko v območju Gornje Radgone prevladuje mešani gozd (ZGS, 2009).

Razred »travnik« predstavlja površine travnikov oziroma pašnikov, ki so prisotni predvsem na kobariškem posnetku, pod »zaraščeni travnik« pa so bile zajete površine, ki se zaraščajo, bodisi z grmičevjem bodisi z gozdnim drevjem.

Na območju Gornje Radgone/Bad Radkersburga sem namesto enega izbrala dva razreda kategorije plodne zemlje oziroma njiv, saj so območja kmetijskih površin zaradi različnih stadijev vegetacije spremenljiva (od njiv z zelenimi pridelki do zoranih njiv). Obdelane, neporaščene njive ter vegetacijo v stadiju, ko ne izvaja fotosinteze, sem združila v razred

»zreli pridelki in prst«, zeleno, fotosintetično vegetacijo pa v razred »zeleni pridelki«. Ker sem en splošen razred delila na dve podskupini, sem se izognila spektralni spremenljivosti znotraj iste kategorije in tako zagotovila boljšo končno natančnost klasifikacije.

Zreli pridelki in prst so združeni pod en razred, saj imata obe kategoriji podoben odbojni spekter v vidnem ter bližnjem IR območju (400 - 1900 nm). Zaradi posebnih kemičnih značilnosti absorpcije pa se jih da dobro ločiti v srednjem območju IR spektra (1900 – 2500 nm), kjer lahko izračunamo njun celulozni absorpcijski indeks CAI (*ang. cellulose absorption index*). Zaradi mineralov, ki se nahajajo v zemlji ima le ta v tem delu spektra vrednost CAI manj kot 0,5, medtem ko imajo zreli pridelki/ostanki pridelkov CAI vedno nad 0,5 (Serbin et al., 2009). Ker v nalogi nisem operirala s posnetki, ki bi bili zajeti v srednjem IR spektru³, indeksa CAI nisem mogla izračunati in sem zato obe kategoriji priključila v isti razred.

Na podobi Kobarida kmetijske površine zaradi strmega naklona skoraj niso bile prisotne.

Prav tako kot v primeru poljske vegetacije sem idejo o delitvi v podskupine prenesla na primer vinogradov; boljši rezultati so bili dobljeni, ko sem izbrala dva razreda – mladi in stari vinogradi. Območja vinogradov so sestavljena iz vinogradov ter iz prostora med vrstami trt. Stari vinogradi imajo za razliko od mladih vinogradov na posnetku med vrstami trt vidno zemljo, predvsem pa se od matičnjaka ločijo po tem, da vsebujejo mnogo več senc med vrstami, saj so trte v tem primeru zrele in zato višje. Zaradi različne geometrije vinogradov ter azimuta sonca in zenitnega kota glede na usmeritev vrste prihaja na posnetku pri vinogradih do velikih razlik v senci.


Hall et al. (2003) navajajo, da je priporočeno, da se podobe vinorodnih območij zajemajo blizu sončnega poldneva, saj se tako lahko delno izognemo problemom, ki jih predstavljajo sence med vrstami trt. Zanimivi rezultati bi se lahko dobili tudi s spreminjanjem raznih geometrijskih parametrov osvetlitve, zenita in azimutalnega kota na celotnem posnetku, kar pa presega zastavljen cilj te diplomske naloge.

³ To bi lahko dosegli na primer z uporabo sedmega kanala Landsat TM, ki opazuje v srednjem IR spektru (2080 – 2350 μm).

Sence so predstavljale zanimiv problem tudi v drugem, visokogorskem študijskem območju, kjer le te predstavljajo kar dobre 3% površine posnetka. Čeprav mesto Kobarid leži v Soški dolini, pa se v okolici mesta relief strmo vzpenja (vzhodno od mesta Kobarid se vzdiga gora Krn z 2244 metri nadmorske višine). Osenčenost je posledica velike relativne višinske razlike na sorazmerno kratkih razdaljah in »neprimerne« položaja sonca v času snemanja. Sence predstavljajo na posnetkih na splošno velik problem, katere se da sicer delno eliminirati s topografsko normalizacijo.

Sama sem pristopila k problemu malo drugače. Med prvotno klasifikacijo Kobarida sem vsem osmim že omenjenim razredom dodala še enega – sence. Ta razred sem po opravljeni klasifikaciji izločila od ostalih razredov in z njimi naredila masko na kombinirani podobi. Še enkrat sem postopek segmentacije in klasifikacije ponovila, vendar tokrat le z maskirano podobo senc. Na senčni strani so bili prisotni trije informacijski razredi: travnik, gozd in nerodovitno zemljišče – skala. Zadovoljive rezultate sem kasneje delno ročno popravila in dodala celotnemu klasificiranemu območju.

Opisan postopek je bil opravljen zato, da bi se zaradi različnih spektralnih vrednosti znotraj istih razredov izognila napačno klasificiranim segmentom celotnega območja oziroma da odstopanja vrednosti istega razreda ne bi kvarile skupne natančnosti.



Slika 24: Osenčene površine na posnetku zaradi velikih naklonov na površju.

10.2.2 Podrobna klasifikacija kmetijskih površin Gornje Radgone

V tem primeru so bili objekti na podobi razdeljeni v devet razredov pokrovnosti/rabe tal:

- star vinograd,
- mlad vinograd,
- zreli pridelki in prst,
- zeleni pridelki,
- travniki,
- zaraščeni travniki,
- drevesa in grmičevje,
- rastlinjak ter
- ceste.

Čeprav razreda rastlinjak in ceste (tu so mišljene ceste, ki vodijo med oziroma do njiv) ne spadata med obdelovalne površine, sta bila vseeno vključena v klasifikacijo kmetijskih površin, saj sta bila kljub skrbni stratifikaciji ponekod prisotna na maski. Oba razreda imata specifične spektralne lastnosti, drugačne od drugih kmetijskih razredov. V kasnejših fazah obdelave sta bila razreda združena v prevladujoče sosednje kmetijske razrede.

10.3 Merilo ločljivosti razredov

Po izbiri učnih vzorcev sem s programom ENVI izračunala spektralno ločljivost med izbranimi pari razredov. Z merilom ločljivosti razredov (*ang. separability*) se računa razdalja med dvema spektralnima podpisoma (izračuna se za vsako kombinacijo kanalov) in nam pove kako dobro so izbrani pari med seboj statistično ločeni. Merilo oziroma razdalje se izračunajo po algoritmu Jeffries-Matusita oziroma po transformirani divergenci, vrednosti pa so definirane v razponu od 0 do 2. Običajno vrednosti nad 1,9 nakazujejo na pare, ki so dobro spektralno ločljivi med seboj, medtem ko pari z zelo nizko ločljivostjo (manj kot 1) zastopajo isti razred glede na njihove spektralne lastnosti. Pare, ki imajo ločljivost manjšo od 1,8 je v klasifikacijskem procesu težko ločiti, kar pa se tudi odraža v slabši natančnosti klasifikacije.

To merilo je zato lahko upoštevano kot parameter, ki omogoča izključitev razredov, ki niso primerni za ločevanje in jih v rezultatih ne bomo dobili z zadovoljivo natančnostjo.

Rezultati ločljivosti razredov na podobi DOF + četrti kanal SPOT na primeru Gornje Radgone so vidni v preglednici 6. Dobre ločljivosti so obarvane zeleno, zadovoljive rumeno, slabe (pod 1,5) pa oranžno. Rezultati kažejo, da so med seboj slabše ločljivi razredi travnik, zaraščen travnik, mladi vinograd, star vinograd ter ceste in stavbe. To so tudi razredi, ki sem jih pri definiranju parametrov segmentacije (oziroma pri definiranju velikosti segmentov) morala upoštevati, da ni prišlo do prekomerne segmentacije oziroma da različni realni geografski objekti niso bili na podobi združeni v skupne segmente. Dobro ločljivost (nad 1,9) pa ima kar 24 kombinacij razredov, še posebej dobro ločljivost v primerjavi z ostalimi razredi ima razred voda.

Preglednica 6: Spektralna ločljivost med razredi na primeru Gornje Radgone.


		1. razred								
		Ceste	Stavbe	Travnik	Zaraščen travnik	Gozd in grmičevje	Voda	Mlad vinograd	Star vinograd	Zeleni pridelki
2. razred	Stavbe	1,22								
	Travnik	1,87	1,98							
	Zaraščen travnik	1,63	1,81	1,96						
	Gozd in grmičevje	1,90	1,78	1,92	2,00					
	Voda	1,99	1,97	1,99	2,00	1,99				
	Mladi vinograd	1,50	1,80	1,03	1,60	1,97	1,99			
	Star vinograd	1,26	1,61	1,68	1,45	1,95	2,00	1,37		
	Zeleni pridelki	1,85	1,90	1,73	1,78	1,91	1,99	1,87	1,69	
	Zreli pridelki in prst	1,83	1,75	1,99	1,99	1,99	1,99	1,97	1,99	1,99

Na koncu klasifikacijskega procesa je treba poudariti, da je za klasifikacijo kmetijskih razredov priporočena uporaba veččasovnih (*ang. multitemporal*) podatkov. Z njimi primerjamo podatke na istem območju vendar zajete ob različnih časovnih obdobjih, saj je le tako možno vključiti v izračun fenološke faze poljščin.

10.4 Poklasifikacija

Pogosto je zaželeno, da se dobljeni klasificirani vektorski rezultati »zgladijo« in da se prikažejo le dominantni klasificirani poligoni. Da bi pridobila takšen rezultat sem klasificirano podobo v programski opremi ENVI obdelala z dvema poklasifikacijskima postopkoma - filtroma; združi in presej (*ang. clump and sieve*). Najprej sem vhodno klasificirano podobo obdelala s funkcijo »presej« in jo nato še popravila s funkcijo »združi«. Po navedbah ENVI User's Guide (2008) naj bi funkcija »združi« združevala podobna sosednja območja klasifikacije z uporabo morfoloških operatorjev. Po podrobnem pregledu rezultatov, ki jih je opravila funkcija »združi« je bilo ugotovljeno, da program ne ustvari najboljših rezultatov, saj v nekaterih primerih odstrani izolirane piksele in primerno generalizira meje segmentov, v drugih primerih pa se generalizacija ni opravila po pričakovanjih, oziroma so izolirani pikseli ostali nespremenjeni (slika 25).

Ker je bilo to ugotovljeno šele na koncu izdelave diplomske naloge je bila funkcija »združi« vseeno vključena v poklasifikacijski postopek, vendar pa jo za nadaljnjo uporabo odsvetujem oziroma priporočam dodatne analize.



Slika 25: Postopek poklasifikacije. V primeru a) gre za obdelavo s funkcijo »presej«, v primeru b) pa obdelavo s funkcijo »združi«. S črno so obrobjeni segmenti, ki nimajo logične razlage pri analizi »združi«.

10.4.1 Vektorska obdelava rezultatov klasifikacije

Ker lahko v GIS vključimo vsak podatek z geografsko komponento, lahko vključimo tudi rezultate klasifikacije. Obdelano poklasificirano podobo sem izvozila v obliki gladkih vektorjev v program ArcGIS, ter jih popravila in prečistila.

Pri kartiranju sem upoštevala najmanjšo enoto kartiranja (*ang. minimum mapping unit, MMU*), ki je odvisna od posameznih tematskih kategorij. Ker je bilo izbrano merilo v nalogi za državno oziroma regionalno raven 1 : 25.000, je velikost najmanjšega objekta za urbane površine (razreda ceste in stavbe) predstavljala površina 100 m², za vse ostale kategorije pa površina 0,25 ha. Poligoni manjši od te vrednosti so bili združeni s sosednjimi segmenti, s katerimi si delijo največjo skupno mejo ali največjo površino (funkcija »Eliminate« v ArcMap). Novo nastali objekti so podedovali attribute največjega elementa v območju združevanja. Prav tako pa so bili ročno odstranjeni poligoni vseh kategorij razen urbanih, ki so bili ožji od 20 metrov (*ang. minimum feature width*).



Slika 26: Obdelava klasificiranih rezultatov v programskem okolju ArcGIS.

Pri klasifikaciji celotne pokrovnosti/rabe tal na obeh obravnavanih območjih sem na tej stopnji zaključila poobdelavo klasificiranih rezultatov, na primeru kmetijskih površin na

območju Gornje Radgone in Bad Radkersburga pa sem dodatno opravila še preklasifikacijo in generalizacijo.

10.4.2 Preklasifikacija in generalizacija

Nazadnje je bil opravljen še postopek, kjer sem ročno odpravila napačno klasificirane segmente. Dobljeni rezultati samodejne klasifikacije kmetijskih zemljišč so namreč še vedno vsebovali območja s premajhnimi ali napačno klasificiranimi segmenti, ki jih je bilo potrebno še dodatno popraviti (preklasificirati oziroma generalizirati). To pomeni, da sem nekaterim poligonom poenostavila obliko ter nekatere od njih združila s pravilno pripadajočim razredom ali jih ločila v primernejše oblike.

V tem koraku sem razreda rastlinjak in ceste spojila z ostalimi kmetijskimi razredi, ročno pa sem dodelila tudi nov razred, »ekstenzivni sadovnjak«. Ta razred je spektralno zelo podoben razredu drevesa in grmičevje, zato v fazi izbiranja razredov ni bil vključen, saj so predhodne analize pokazale, da slabša končni rezultat klasifikacije.

Dobljeni razredi klasifikacije kmetijskih zemljišč (zeleni pridelki, zreli pridelki in prst, stari vinogradi, mladi vinogradi, travnik, zaraščen travnik, drevesa in grmičevje ter ekstenzivni sadovnjak) na območju Gornje Radgone/ Bad Radkersburg predstavljajo osnovne kategorije rabe tal oziroma tiste, ki so na obravnavanem območju najbolj zastopane.

Omeniti pa je tudi potrebno, da sem pri pregledu dobljenih klasificiranih rezultatov opazila, da na robovih med objekti prihaja do napak klasificiranja. Mešani piksli so na območju z določeno velikostjo pogosto uvrščeni v objekte, ki so kasneje klasificirani v napačen razred. Večje kot je območje, več objektov je klasificiranih narobe. Predvidevam, da se to dogaja zaradi neustreznosti algoritmov segmentacije in klasifikacije na robnih delih podobe.

Da bi se izognila napakam na robovih sem robne objekte pred ovrednotenjem natančnosti ročno popravila, to se pravi zbrisala ali po potrebi preklasificirala. Zaradi omenjene napake programske opreme priporočam pri klasifikaciji nekega območja uporabo nekaj metrskih vplivnih con (*ang. buffer*).

11 OVREDNOTENJE DOBLJENIH REZULTATOV

Ocena natančnosti klasifikacije z uporabo dejanskih podatkov na terenu ni bila izvedena, saj je bilo obdobje, ko sta bili zajeti satelitska in letalska podoba, časovno preveč oddaljeno, da bi se lahko primerjalo s stanjem v času nastajanja naloge. Iz navedenih razlogov je bila opravljena zgolj ocena natančnosti klasifikacije dobljenih rezultatov v primerjavi s slojem Dejanske rabe zemljišč (MKGP 2008), saj ta sloj predstavlja najbolj natančen vir rabe tal v Sloveniji. Zaradi neobstoječih referenčnih virov na območju Avstrije, na tem delu klasifikacija žal ni bila ovrednotena.

11.1 Matrika napak

Ovrednotenje rezultatov klasifikacije je bilo izračunano z matriko napak. Zaradi različne vsebine kategorij pokrovnosti/rabe tal med Dejansko rabo zemljišč in klasificirano podobo neposredne primerjave med obema slojema ni bilo mogoče izvesti. Ker za izračun matrike napak potrebujemo enako število razredov na obeh vhodnih podobah, sem pri vseh primerih nekatere razrede med seboj razumno združila.

Preglednica 7: Združeni razredi podrobne analize kmetijskih zemljišč na referenčni in klasificirani podobi.

Karta rabe tal MKGP (Gornja Radgona)	Združeni razredi	Rezultati klasifikacije
Njive in vrtovi Rastlinjak Ostali trajni nasadi Neobdelano kmetijsko zemljišče	Obdelana zemlja	Zeleni pridelki Zreli pridelki in prst
Vinograd	Vinograd	Star vinograd Mlad vinograd
Trajni travnik	Travnik	Travnik
Kmetijsko zemljišče v zaraščanju	Zaraščen travnik	Zaraščen travnik
Drevesa in grmičevje Kmetijsko zemljišče, poraslo z gozdnim drevjem Gozd	Drevesa in grmičevje	Drevesa in grmičevje
Intenzivni sadovnjak Ekstenzivni sadovnjaki	Ekstenzivni sadovnjak	Ekstenzivni sadovnjak

Skupna natančnost = 77,0 %

Kappa koeficient = 0,71

Analiza natančnosti klasifikacije rabe tal/pokritosti na območju Gornje Radgone je dosegla 77,0 % v primerjavi z referenčno Dejansko rabo zemljišč MKGP. Slabši dobljen rezultat lahko pripišemo popolni avtomatski pridobitvi rezultatov (to se pravi, da poligoni niso bili pri postopku ročno obdelani oziroma popravljeni), delno pa lahko ta rezultat opravičimo kot posledico velike pestrosti in s tem detajlnosti pokrovnosti/rabe tal na tem območju in zato težjega ločevanja pri postopku klasifikacije. Do razlik med obema primerjanima slojema pride tudi zaradi njune različne ločljivosti. Pri avtomatskem izločevanju se zato ne orišejo celoviti geografski objekti, medtem ko v primeru ročnega zajemanja po navadi se, prav tako pa se pri vektorskih rezultatih klasifikacije, zaradi posledice pridobivanja rezultatov iz rastra, opazijo zobate oblike poligonov. Referenčni podatki pa so osnovani ročno in zato tudi definirani z ravnimi črtami. Slednje ugotovitve lahko uporabimo pri vseh razlagah natančnosti dobljenih klasifikacij v diplomski nalogi.

Za primerjavo sem del območja ročno zajela in uporabila te podatke kot referenčno podlago v primerjavi s klasificirano, vendar pa tudi v tem primeru natančnost klasifikacije ni dosegla boljših rezultatov.

Če pogledamo preglednico 8 splošno natančnost najbolj kvari razred travnik (47,2 %), ki je v manj kot četrtini primerov klasificiran kot gozd, oziroma več kot v 10% klasificiran v urbane površine. Tega razreda je na podobi najmanj, zato lahko posledično predvidevamo da so slabši rezultati posledica manjšega števila zajetih učnih vzorcev ter podobnega spektralnega odziva s prej omenjenima razredoma (gozd in urbane površine).

Z dobrimi 71% sta klasificirana razreda urbane površine in njive, predvsem zaradi napačnega klasificiranja razreda travnik in gozd.

Dobro pa so klasificirani razredi gozd (91,9 %), vinograd (88,0 %) ter voda (89,3 %). Prva dva omenjena razreda predvsem zaradi njunega večinskega zastopanja na posnetku, razred voda pa zaradi specifičnih spektralnih lastnosti v primerjavi z ostalimi razredi. Med

postopkom klasifikacije je bilo opaziti, da so se segmenti senc dreves v bližini vode (reke Mure) kasneje klasificirali kot razred voda, iz česar predvidevamo, da bi lahko dosegli pri klasifikaciji še boljše rezultate, če bi lahko eliminirali vpliv senc zaradi krošenj dreves.

11.3 Ovrednotenje rezultatov pokrovnosti/rabe tal za območje Kobarida

Preglednica 9: Matrika napak pokrovnosti/rabe tal za območje Kobarida v odstotkih.

		Dejanska raba kmetijskih zemljišč [%]						
		Sadovnjak	Travnik	Urbane površine	Nerodovitno zemljišče - skala	Gozd	Voda	Skupaj
Klasifikacija	Sadovnjak	82,0	0,0	0,0	0,0	0,0	0,0	0,1
	Travnik	11,2	81,2	15,2	2,5	2,0	8,3	23,3
	Urbane površine	0,0	0,7	59,9	0,2	0,3	1,3	2,2
	Nerodovitno zemljišče - skala	0,0	2,5	1,5	92,3	0,6	0,3	5,8
	Gozd	6,8	15,6	23,1	5,0	97,0	24,8	68,2
	Voda	0,0	0,0	0,3	0,0	0,1	65,3	0,4
	Skupaj	100,0	100,0	100,0	100,00	100,0	100,0	100,0

Skupna natančnost: 91,3 %

Koeficient Kappa: 0,71

Analiza natančnosti na območju Kobarida je pokazala na 91% natančnost, kar je za skupno natančnost zelo dober rezultat, glede na to, da razen nekaj očitno narobe klasificiranih segmentov, dobljeni vektorski rezultati niso bili ročno popravljani pri postopku poklasifikacije. Iz tega rezultata sledi dejstvo, da so bili parametri segmentacije optimalno izbrani.

Urbane površine so na območju Kobarida glede na celoten posnetek zastopane v manjšem obsegu (2,2 %), njihova klasifikacija pa je dosegla 60% natančnost. Glede na to, da je za referenčno karto značilen relativno dosleden in podroben zajem za območja izven naselij, poseljena območja in prometnice pa so združene v eno samo kategorijo, bi za primerjavo klasifikacije urbanih površin mogoče potrebovali drug referenčni vir.

Pri razredu vode pa prav tako kot v že omenjenem primeru Gornje Radgone prihaja do združevanj med segmenti, ki v realnosti predstavljajo sence krošenj dreves v gozdu ob reki, kar v splošnem slabša natančnost.

Dobro pa se je izkazal način klasificiranja senc v goratem območju, glede na to da so razredi, ki jih je prekrivala senca dosegli zadovoljive oziroma dobre natančnosti klasifikacije (travnik, nerodovitno območje – skala ter gozd).

11.4 Ovrednotenje rezultatov kmetijskih zemljišč za območje Gornje Radgone

Preglednica 10 prikazuje izračunano matriko napak podrobnejše analize kmetijskih zemljišč na območju Gornje Radgone, kjer stolpci predstavljajo rezultate Dejanske rabe zemljišč, vrstice pa razrede pridobljene z objektno klasifikacijo. Kot že omenjeno klasifikacijo sosednjega Bad Radkersburga nismo ovrednotili, saj ne obstaja nobena referenčna karta rabe tal za to območje.

Zelo dobri rezultati so dobljeni pri razredih »obdelana zemlja« in »vinograd«. Ker oba razreda prevladujeta na posnetku lahko predvidevamo, da so dobri rezultati posledica velikega števila zajetih učnih vzorcev v fazi določevanja reprezentativnih segmentov vsakega razreda.

Natančnost klasifikacije razreda »travnik« je dosegla skoraj 75%. Ta malo slabši rezultat lahko opravičimo kot posledico spektralne podobnosti z razredom »zeleni pridelki«.

»Zaraščen travnik« je razred, ki je na posnetku prisoten le v manjši meri (predstavlja samo 1,3% celotne podobe). Vizualno se lahko primerja tako z razredom »drevesa in grmičevje« kot tudi z razredom »travnik«, odvisno od tega v kateri stopnji zaraščenosti je obravnavano območje. Ta razred je bil po procesu klasifikacije delno ročno dodan oziroma spremenjen.

»Ekstenzivni sadovnjak« je bil zajet izključno ročno v končnih fazah nastajanja karte, saj ga je, kot že omenjeno, nemogoče samodejno ločiti od razreda »drevesa in grmičevje«. Ta

slednji razred pa predstavljajo območja, ki naj bi bila dodana gozdovom oziroma so le večji skupki dreves med ostalimi kmetijskimi zemljišči.

Kot je razvidno, imajo najslabše rezultate razredi, ki so zastopani na podobi v manjšem obsegu (zaraščeni travnik, drevesa in grmičevje ter ekstenzivni sadovnjak) in obratno, najboljše rezultate so dosegli razredi, ki so na podobi zastopani večinsko (obdelana zemlja, vinograd in travnik).

Preglednica 10: Matrika napak podrobnejše klasifikacije kmetijskih zemljišč na območju Gornje Radgone v odstotkih.

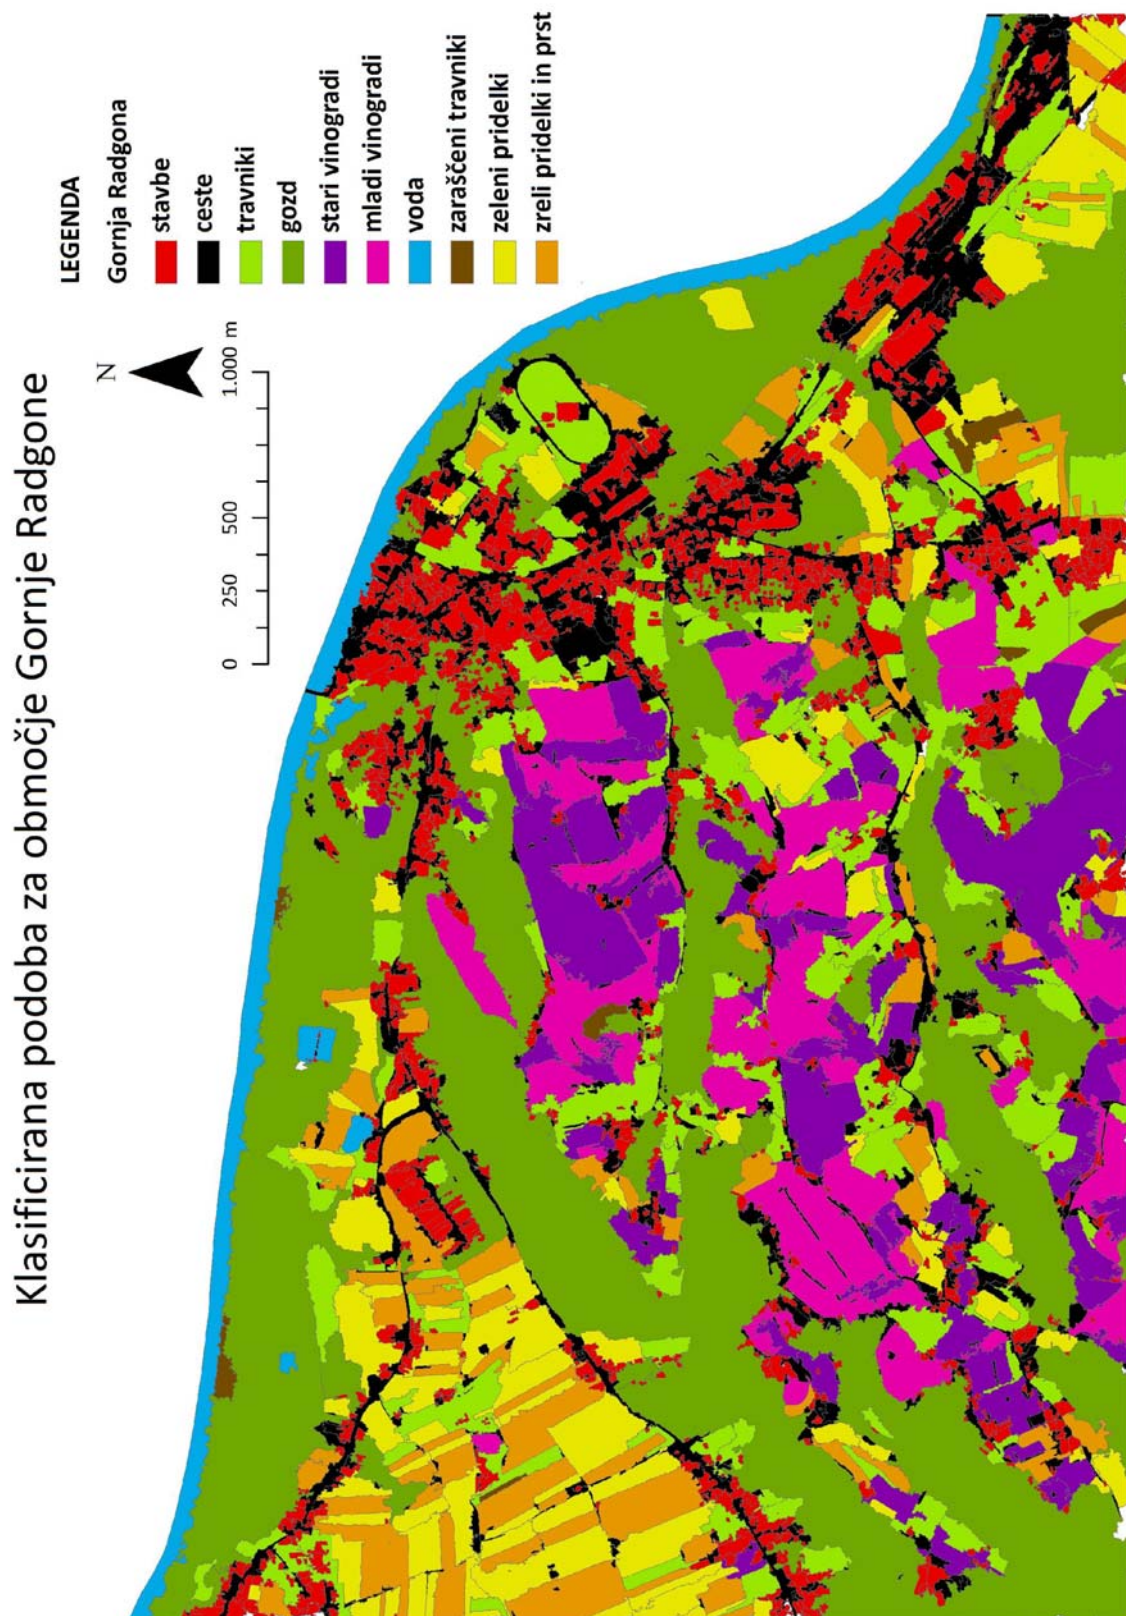
		Dejanska raba kmetijskih zemljišč [%]						
		Obdelana zemlja	Vinograd	Travnik	Zaraščen travnik	Drevesa in grmičevje	Ekstenzivni sadovnjak	Skupaj
Klasifikacija	Obdelana zemlja	95,5	2,1	18,4	8,8	15,2	9,2	41,7
	Vinograd	0,3	96,1	4,5	3,5	5,2	7,3	32,5
	Travnik	3,9	1,6	74,8	31,9	25,7	44,5	21,0
	Zaraščen travnik	0,0	0,0	0,9	55,0	3,3	0,0	1,3
	Drevesa in grmičevje	0,2	0,0	1,0	0,8	48,3	0,0	2,2
	Ekstenzivni sadovnjak	0,1	0,2	0,4	0,0	2,3	39,0	1,3
	Skupaj	100,0	100,0	100,0	100,0	100,0	100,0	100,0

Skupna natančnost = 87,1 %

Koeficient Kappa= 0,81

Kakovost klasifikacije bi lahko na območjih senc znatno izboljšali z uporabo digitalnega modela višin, saj lahko z njim zmanjšamo vpliv naklonov, senc in nadmorske višine, vendar pa bi potek tega postopka presegal cilje zadane naloge.








12 PRIKAZ REZULTATOV



Klasificirana podoba za območje Kobarida

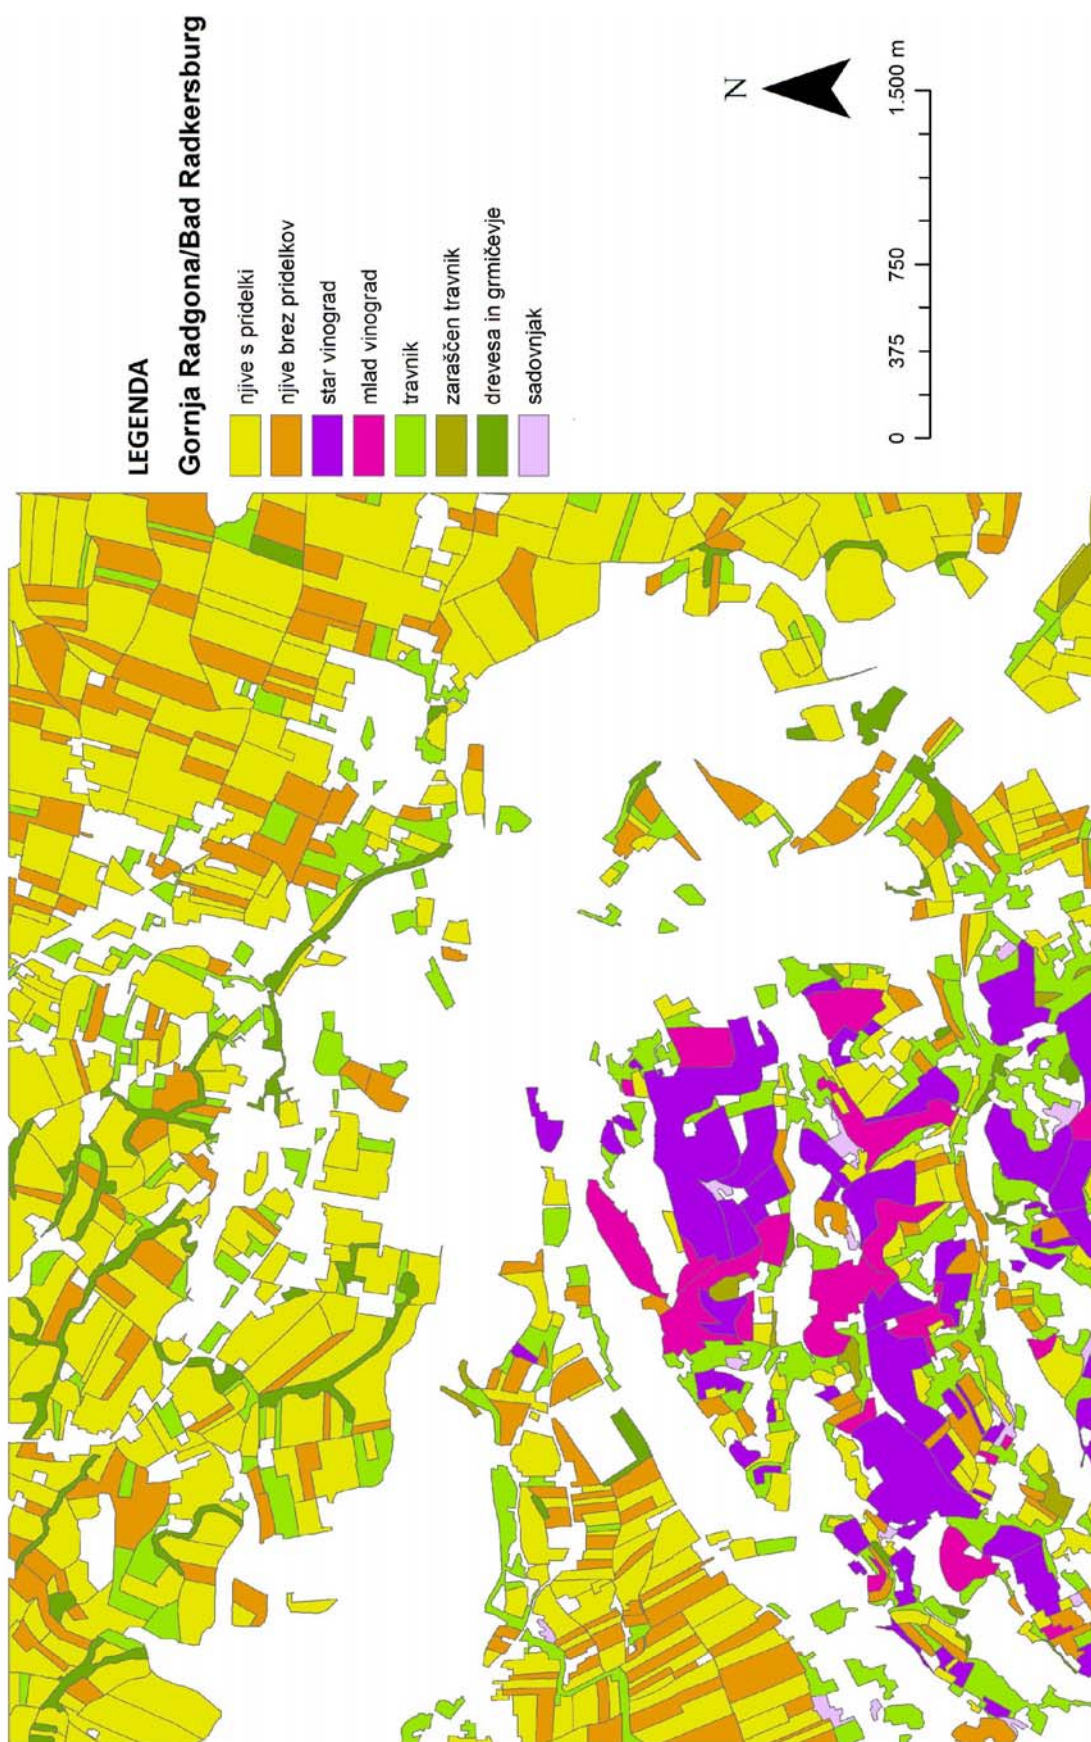
LEGENDA

Kobarid

	gozd
	travnik
	ceste
	stavbe
	voda
	sadovnjak
	nerodovitno območje - skala



Klasificirana podoba kmetijskih površin za območje Gornje Radgone/Bad Radkersburg



13 ZAKLJUČEK

V diplomski nalogi je bila uporabljena tehnika kombiniranega pristopa, t.j. uravnotežena kombinacija metod samodejne objektne klasifikacije podprta z vizualno interpretacijo s pomočjo pomožnih podatkov. Večina obdelave podatkov je potekala v modulu ENVI Zoom (Feature Extraction), ki je sestavni del programa ENVI in ima implementirano metodo objektne klasifikacije. Temeljna faza tovrstne klasifikacije je segmentacija, kjer se vhodna podoba razdeli na relativno homogene skupine pikselov (segmente), ki se jih kasneje v fazi klasifikacije razvrsti v prevladujoče razrede. Ko je bila klasificirana podoba pridobljena, so bili rezultati delno ročno popravljeni v programski opremi ArcGIS, njihova natančnost pa je bila dobljena v primerjavi z referenčnimi podatki Dejanske rabe površin MKGP v obliki matrike napak.

Segmentacija predstavlja ključno fazo pri objektni klasifikaciji, saj dobra izbira segmentacijskih parametrov zagotavlja natančnejšo klasifikacijo. V diplomski nalogi je bila segmentacija izračunana z algoritmom na osnovi robov. Optimalni rezultati oziroma oblike segmentov so bili pridobljeni šele po več poskusih. Iz ugotovitev je mogoče povzeti to, da je izbira segmentacijskih parametrov močno odvisna od spektralno najbližjih razredov (v primeru te naloge so bili to razredi zeleni pridelki v kombinaciji s travniki ter ceste v kombinaciji s stavbami). Potrebno je torej izbrati parametre, kjer se omenjeni razredi še ločijo med seboj, pa čeprav to pomeni, da bodo ostali razredi presegmentirani. Dobra izbira segmentacijskih parametrov pa je ključnega pomena za dobro natančnost klasifikacije.

V diplomskem delu je bila uporabljena nadzorovana klasifikacija, kjer pomembno fazo predstavlja izbira učnih vzorcev. Več kot je bilo izbranih reprezentativnih učnih vzorcev, boljši so bili rezultati klasifikacije. Iz izkušenj in iz prebrane literature je mogoče trditi, da je potrebno pri določevanju učnih vzorcev označiti po celotnem posnetku približno enako število reprezentativnih segmentov za vse razrede, kar pa je pogostoma težko, glede na to da se izbrani tipi pokrovnosti/rabe tal praviloma ne nahajajo na posnetkih v enaki meri.

Končni rezultati pridobljeni z objektno klasifikacijo so bili dobri in nekateri celo presegli pričakovanja. Presenečajo predvsem rezultati klasifikacije na primeru Kobarida, kjer je natančnost dosegla brez naknadne ročne obdelave kar 91,3%. Prav tako pa so zadovoljivi rezultati klasifikacije kmetijskih površin na primeru Gornje Radgone, ki so bili naknadno ročno popravljani in predstavljajo dokaj natančno pokritost kmetijskega površja na tem območju. Rezultati bi lahko bili kot taki uporabni za razne nadaljnje raziskave, saj so dober približek realnega stanja na zemeljskem površju. Rezultate še boljših natančnosti bi dobili tudi, če bi rezultate klasifikacije celotne pokrovnosti/rabe tal na območju Gornje Radgone ročno obdelali po fazi klasifikacije in poklasifikacije.

V vseh treh dobljenih primerih obdelave je bilo mogoče opaziti, da so rezultati klasifikacije pridobljeni s pomočjo uporabljene programske opreme na robovih kvarili skupno natančnost klasifikacije. Da sem se temu izognila sem robne segmente po vsej podobi ročno popravila oziroma jih preklasificirala.

Predvidevam, da bi operater, ki bi že bil seznanjen s postopkom in programsko opremo, za pridobitev informacij iz satelitskega posnetka s pomočjo objektne klasifikacije potreboval okoli enega do dva tedna, odvisno od obsežnosti zahtevane naloge. V postopek dela je v tem časovnem izračunu vključen avtomatski in ročni del.

Zaradi velike količine podatkov, ki jih nosijo visokoločljivostne podobe poteka avtomatski proces objektne klasifikacije v programu ENVI Zoom dokaj počasi. Segmentacija in združitev sta narejeni v nekaj desetih minutah, časovno dlje poteka postopek pripisovanja atributov segmentom. To lahko traja za satelitski posnetek 3×3 kilometre tudi do eno uro, enako dolgo traja tudi faza nadzorovane klasifikacije. Seveda je vse odvisno od uporabljene strojne opreme; z dobro izbiro lahko opazno zmanjšamo čas obdelave. Vseeno pa je zamudna izbira učnih vzorcev, ki lahko za tako veliko območje operaterju vzame tri ure ali celo več.

Sam potek poklasifikacije ne zahteva veliko časa, je pa odvisen od izbranih operacij. Prav tako ne zahteva veliko časa izračun natančnosti klasifikacije. Časovno daleč najbolj obsežen pa je ročni del, kjer si je za generalizacijo in preklasifikacijo potrebno vzeti kar nekaj dni. Seveda je to zopet odvisno od velikosti posnetka in natančnosti, ki jo hočemo doseči.

Ker so algoritmi objektno usmerjene klasifikacije zmožni vključiti tudi ostale prostorske informacije in attribute, bi lahko z dodajanjem dodatnih podatkov zvišali obseg informacij, s tem pa bi se verjetno izboljšala tudi natančnost pridobivanja objektov iz podob. Kot dodatni podatek bi lahko uporabili čas z uporabo multitemporalnih posnetkov, višino geografskih objektov s pomočjo lidarja, toploto na termalnih posnetkih, itd. S pomočjo laserskih podatkov lahko zelo dobro ločimo razreda gozd in stavbe od drugih razredov zaradi njihovih odstopajočih višin, prav tako lahko z multispektralnimi podatki dobro ločimo vegetacijske razrede od antropogenih zaradi močnega odstopanja v klorofilu.

Nekatere težave napačne klasifikacije vseeno ostajajo tudi pri objektni klasifikaciji, vendar pa skupni rezultati kažejo, da je uporaba te klasifikacije na posnetkih visokih ločljivosti z uporabo dodatnih funkcij zelo praktično orodje za kartiranje pokrovnosti/rabe tal. Pristopu objektno usmerjene klasifikacije je zato potrebno posvetiti poseben pomen, saj je njegovo izboljšanje nujno glede na poplavo podatkov, ki bodo dostopni iz številnih visoko ločljivostnih satelitskih sistemov izstreljenih v naslednjih nekaj letih.

VIRI

Baatz, M., Schape, A., 2000, Multi-resolution segmentation – an optimization approach for high quality multi-scale segmentation. V: Strobl, J., et al. (Ur): Angewandte Geographische Informationsverarbeitung XII, 12-23. Beiträge zum AGIT Symposium Salzburg 2000, Karlsruhe, Herbert Wichmann Verlag.

Blaschke, T. (Ur), Lang, S. (Ur), Hay, G.J. (Ur), 2008, Object-Based Image Analysis. Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Berlin, Springer – Verlag Berlin Heidelberg: 817 str.

Blaschke, T., Strobl, J., 2001, What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GIS-Zeitschrift für Geoinformationssysteme 14, 6:12-17.

Campbell, J.B., 1996, Introduction to Remote Sensing. 2. izdaja. New York, The Guilford Press: 622 str.

Definiens, 2008, Definiens Solutions.

<http://www.definiens.com/> (avgust 2009)

Gabrovec, M., Kladnik, D., 1997, Nekaj novih vidikov rabe tal v Sloveniji. Geografski zbornik 37, 35 str.

Gao, Y., Kerle, N., Mas, J. F., Navarrete, A., Niemeyer, I., 2007, Optimized image segmentation and its effect on classification accuracy. Poster session on 5th international Symposium on Spatial Data Quality, Enschede, The Netherlands.

GEOBIA Wiki: GEO Object Based Image Analysis Wikipedia, 2008, Universtiy of Calgary.

<http://wiki.ucalgary.ca/page/GEOBIA> (april 2009)

Hall, A., Louis, J., Lamb, D., 2003, Characterising and mapping vineyard canopy using high-spatial-resolution aerial multispectral images. Computers & Geosciences 29, 7: 813 – 822.

Hay, G.J., Blaschke, T., Marceau, D.J., Bouchard, A., 2003, A comparison of three image-object methods for the multiscale analysis of landscape structure. *ISPRS Journal of Photogrammetry & Remote Sensing* 57, 5-6: 327 – 345.

ITT Visual Information Solutions, 2008, ENVI User's guide.

<http://www.ittvis.com/> (avgust 2009)

Janža, M., 2005, Določitev rabe tal s klasifikacijo satelitske podobe za namene hidrološkega modeliranja na območju zaledja izvira Rižane. *Geologija* 48, 1: 153 – 159.

Kladnik, D., et al., 1998, Geografski atlas Slovenije. Ljubljana, DZS: 360 str.

Krevs, M., 2004, Spreminjanje urbane rabe tal v Ljubljani. *Dela* 22, 55 – 65.

Lang, R., et al., 2008, Optimizing unsupervised classification of remotely sensed imagery with a data-assisted labeling approach. *Computers and Geosciences* 34, 12: 1877 – 1885.

Lang, S., Blaschke, T., 2003, Hierarchical object representation – comparative multiscale mapping of anthropogenic and natural features. *ISPRS Archives* 34, Part 3/W8: 17 – 19.

Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2004, *Remote Sensing and Image Interpretation*. 5. Izdaja. New York, John Wiley and Sons, Inc.: 763 str.

Lobo, A., 1997, Image segmentation and discriminant analysis for the identification of land cover units in ecology. *IEEE Transactions on Geoscience and Remote Sensing* 35, 5: 1136-1145.

Navulur, K., 2007, *Multispectral image analysis using the object-oriented paradigm*. Boca Raton, Taylor & Francis Group: 165 str.

Nussbaum, S., Menz, G., 2008, Object-Based Image Analysis and Treaty Verification. New Approaches in Remote Sensing – Applied to Nuclear Facilities in Iran. Springer Science + Business Media B.V.: 170 str.

Oruc, M., Marangoz, A. M., Buyuksalih, G., 2004, Comparison of pixel-based and object-oriented classification approaches using Landsat-7 ETM spectral bands, Članek predstavljen na 20. ISPRS Kongresu, Istanbul, Turčija

Oštir, K., 2006, Daljinsko zaznavanje. Ljubljana, Inštitut za antropološke in prostorske študije Založba ZRC SAZU: 250 str.

PISO: Prostorski Informacijski Sistem Občin, 2009.

http://www.geoprostor.net/PisoPortal/vsebine_dejanska.aspx (junij 2009)

Prostorski portal, Geodetska uprava Republike Slovenije, 2009, Ministrstvo za okolje in prostor.

<http://prostor.gov.si/vstop/index.php?id=181> (junij 2009)

Rikanovič, R., 2003, Digitalne podatkovne zbirke pokrovnosti/rabe tal Slovenije. Geologija 47, 2: 283 – 290.

Schiewe, J., Tufte, L., Ehlers, M., 2001, Potential and problems of multi-scale segmentation methods in remote sensing. Geographische Informationssysteme 6: 34-39.

Serbin, G., Daughtry, C. S. T., Hunt Jr, E. R., Reeves III, J. B., Brown, D. J., 2009, Effects of soil composition and mineralogy on remote sensing of crop residue cover. Remote Sensing of Environment 113, 1: 224 – 238.

Thomson, A. G., Fueller, R. M., Yates, M. G., Brown, S. L., Cox, R., Wadsworth, R. A., 2003, The use of airborne remote sensing for extensive mapping of intertidal sediments and saltmarshes in eastern England. International Journal of Remote Sensing 24, 13:2717 – 2737.

Walter, V., 2004, Object-based classification of remote sensing data for change detection. ISPRS Journal of Photogrammetry & Remote Sensing 58, 3-4: 225 – 238.

Wikipedia, 2009, Wiki.

<http://sl.wikipedia.org> (avgust 2009)

ZGS: Zavod za Gozdove Slovenije, 2009.

<http://www.zgs.gov.si/> (maj 2009)

PRILOGA A: OVREDNOTENJE NATANČNOSTI KLASIFIKACIJ

Priloga A1: Klasifikacija rabe tal/pokrovnosti za celotno območje Gornje Radgone

Overall Accuracy = (42579691/55306102) 76,9891%

Kappa Coefficient = 0,7103

Class	Ground Truth (Pixels)				
	urbano	travni ki	gozd	vi nograd	voda
EVF: urbano	8171398	972965	422118	374092	14309
EVF: travni k	1067985	3571053	234184	374183	9209
EVF: gozd	1382588	1772691	14132518	233624	121508
EVF: vi nograd	442793	531546	232186	7838621	158
EVF: voda	53739	20274	179930	0	1453466
EVF: nj i ve	348896	695792	172810	89433	29622
Total	11467399	7564321	15373746	8909953	1628272

Class	Ground Truth (Pixels)	
	nj i ve	Total
EVF: urbano	674489	10629371
EVF: travni k	1385497	6642111
EVF: gozd	604019	18246948
EVF: vi nograd	285484	9330788
EVF: voda	287	1707696
EVF: nj i ve	7412635	8749188
Total	10362411	55306102

Class	Ground Truth (Percent)				
	urbano	travni ki	gozd	vi nograd	voda
EVF: urbano	71,26	12,86	2,75	4,20	0,88
EVF: travni k	9,31	47,21	1,52	4,20	0,57
EVF: gozd	12,06	23,43	91,93	2,62	7,46
EVF: vi nograd	3,86	7,03	1,51	87,98	0,01
EVF: voda	0,47	0,27	1,17	0,00	89,26
EVF: nj i ve	3,04	9,20	1,12	1,00	1,82
Total	100,00	100,00	100,00	100,00	100,00

Class	Ground Truth (Percent)	
	nj i ve	Total
EVF: urbano	6,51	19,22
EVF: travni k	13,37	12,01
EVF: gozd	5,83	32,99
EVF: vi nograd	2,75	16,87
EVF: voda	0,00	3,09
EVF: nj i ve	71,53	15,82
Total	100,00	100,00

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
EVF: urbano	23, 12	28, 74	2457973/10629371	3296001/11467399
EVF: travnik	46, 24	52, 79	3071058/6642111	3993268/7564321
EVF: gozd	22, 55	8, 07	4114430/18246948	1241228/15373746
EVF: vinograd	15, 99	12, 02	1492167/9330788	1071332/8909953
EVF: voda	14, 89	10, 74	254230/1707696	174806/1628272
EVF: njive	15, 28	28, 47	1336553/8749188	2949776/10362411

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
EVF: urbano	71, 26	76, 88	8171398/11467399	8171398/10629371
EVF: travnik	47, 21	53, 76	3571053/7564321	3571053/6642111
EVF: gozd	91, 93	77, 45	14132518/15373746	14132518/18246948
EVF: vinograd	87, 98	84, 01	7838621/8909953	7838621/9330788
EVF: voda	89, 26	85, 11	1453466/1628272	1453466/1707696
EVF: njive	71, 53	84, 72	7412635/10362411	7412635/8749188

Priloga A2: Klasifikacija rabe tal/pokrovnosti za celotno območje Kobarida

Overall Accuracy = (90348620/98910236) 91,3441%

Kappa Coefficient = 0,8241

Class	Ground Truth (Pixels)		
	sadovnjak	travnik	urbano
EVF: sadovnjak	1703	532	0
EVF: travnik	21138424	449792	129454
EVF: urbano	187534	1773977	10801
EVF: skala	652416	43727	4707133
EVF: gozd	4053320	685958	253231
EVF: voda	0	7575	37
Total	26033435	2961563	5100656

Class	Ground Truth (Pixels)		
	gozd	voda	Total
EVF: sadovnjak	14609	0	95695
EVF: travnik	1318112	41095	23087703
EVF: urbano	164813	6290	2143415
EVF: skala	367478	1586	5772340
EVF: gozd	62327249	122852	67449142
EVF: voda	31280	322986	361878
Total	64223557	494816	98910236

Class	Ground Truth (Percent)			
	sadovnjak	travnik	urbano	skala
EVF: sadovnjak	81, 96	0, 01	0, 02	0, 00
EVF: travnik	11, 25	81, 20	15, 19	2, 54
EVF: urbano	0, 00	0, 72	59, 90	0, 21

EVF: skal a	0,00	2,51	1,48	92,28
EVF: gozd	6,79	15,57	23,16	4,96
EVF: voda	0,00	0,00	0,26	0,00
Total	100,00	100,00	100,00	100,00

Cl ass	Ground Truth (Percent)		
	gozd	voda	Total
EVF: sadovnj a	0,02	0,00	0,10
EVF: travni k	2,05	8,31	23,34
EVF: urbano	0,26	1,27	2,17
EVF: skal a	0,57	0,32	5,84
EVF: gozd	97,05	24,83	68,19
EVF: voda	0,05	65,27	0,37
Total	100,00	100,00	100,00

Cl ass	Commi ssi on (Percent)	Omi ssi on (Percent)	Commi ssi on (Pi xel s)	Omi ssi on (Pi xel s)
EVF: sadovnj a	17,60	18,04	16844/95695	17358/96209
EVF: travni k	8,44	18,80	1949279/23087703	4895011/26033435
EVF: urbano	17,24	40,10	369438/2143415	1187586/2961563
EVF: skal a	18,45	7,72	1065207/5772340	393523/5100656
EVF: gozd	7,59	2,95	5121893/67449142	1896308/64223557
EVF: voda	10,75	34,73	38892/361878	171830/494816

Cl ass	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pi xel s)	User Acc. (Pi xel s)
EVF: sadovnj a	81,96	82,40	78851/96209	78851/95695
EVF: travni k	81,20	91,56	21138424/26033435	21138424/23087703
EVF: urbano	59,90	82,76	1773977/2961563	1773977/2143415
EVF: skal a	92,28	81,55	4707133/5100656	4707133/5772340
EVF: gozd	97,05	92,41	62327249/64223557	62327249/67449142
EVF: voda	65,27	89,25	322986/494816	322986/361878

Priloga A3: Klasifikacija kmetijskih zemljišč za območje Gornje Radgone

Overall Accuracy = (20790804/23872038) 87,0927%

Kappa Coeffi ci ent = 0,8133

Cl ass	Ground Truth (Pi xel s)				
	nj i ve	vi nogradi	travni k	zarascen tr	drevesa i n gr
Nj i ve	8595668	163743	955988	36120	144397
Vi nograd	29247	7382053	231254	14304	49374
Travni k	349405	125606	3878053	131581	244468
zarascen trav	2669	777	47290	226511	31452
drevesa i n gr	14123	1049	52835	3379	459735
sadovnj ak	5903	11722	22473	0	22409
Total	8997015	7684950	5187893	411895	951835

Class	Ground Truth (Pixel s)	
	sadovnjak	Total
Njive	58644	9954560
Vinograd	46928	7753160
Travnik	284094	5013207
zarascen trav	0	308699
drevesa in gr	0	531121
sadovnjak	248784	311291
Total	638450	23872038

Class	Ground Truth (Percent)				
	njive	vinogradi	travnik	zarascen tr	drevesa in gr
njive_klas [Y	95,54	2,13	18,43	8,77	15,17
vinograd_klas	0,33	96,06	4,46	3,47	5,19
travnik_klas	3,88	1,63	74,75	31,95	25,68
zarascen trav	0,03	0,01	0,91	54,99	3,30
drevesa in gr	0,16	0,01	1,02	0,82	48,30
sadovnjak_kla	0,07	0,15	0,43	0,00	2,35
Total	100,00	100,00	100,00	100,00	100,00

Class	Ground Truth (Percent)	
	sadovnjak	Total
Njive	9,19	41,70
vinograd	7,35	32,48
travnik	44,50	21,00
zarascen trav	0,00	1,29
drevesa in gr	0,00	2,22
sadovnjak	38,97	1,30
Total	100,00	100,00

Class	Commi ssi on	Omi ssi on	Commi ssi on	Omi ssi on
	(Percent)	(Percent)	(Pixel s)	(Pixel s)
Njive	13,65	4,46	1358892/9954560	401347/8997015
Vinograd	4,79	3,94	371107/7753160	302897/7684950
Travnik	22,64	25,25	1135154/5013207	1309840/5187893
zarascen trav	26,62	45,01	82188/308699	185384/411895
drevesa in gr	13,44	51,70	71386/531121	492100/951835
sadovnjak	20,08	61,03	62507/311291	389666/638450

Class	Prod. Acc.	User Acc.	Prod. Acc.	User Acc.
	(Percent)	(Percent)	(Pixel s)	(Pixel s)
Njive	95,54	86,35	8595668/8997015	8595668/9954560
Vinograd	96,06	95,21	7382053/7684950	7382053/7753160
Travnik	74,75	77,36	3878053/5187893	3878053/5013207
zarascen trav	54,99	73,38	226511/411895	226511/308699
drevesa in gr	48,30	86,56	459735/951835	459735/531121
sadovnjak	38,97	79,92	248784/638450	248784/311291