

Univerza
v Ljubljani

Fakulteta
*za gradbeništvo
in geodezijo*



ANDREJA ŠVAB LENARČIČ

**VEČČASOVNA KLASIFIKACIJA POKROVNOSTI
Z OPTIČNIMI SATELITSKIMI POSNETKI**

DOKTORSKA DISERTACIJA

Ljubljana, 2018

Univerza
v Ljubljani

Fakulteta
*za gradbeništvo
in geodezijo*

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



DOKTORSKI ŠTUDIJSKI
PROGRAM III. STOPNJE
GRAJENO OKOLJE

Doktorandka:

ANDREJA ŠVAB LENARČIČ

**VEČČASOVNA KLASIFIKACIJA POKROVNOSTI
Z OPTIČNIMI SATELITSKIMI POSNETKI**

**MULTITEMPORAL LAND COVER
CLASSIFICATION OF OPTICAL SATELLITE
IMAGERY**

2018

Univerza
v Ljubljani

Fakulteta
*za gradbeništvo
in geodezijo*



Mentor: prof. dr. Krištof Oštir, UL FGG

Poročevalci za oceno doktorske disertacije:

- doc. dr. Mojca Kosmatin Fras, UL FGG
- znan. sod. dr. Tatjana Veljanovski, ZRC SAZU
- pridr. prof. dr. Marko Komac, habilitiran na UNG

ERRATA

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

»Ta stran je namenoma prazna.«

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:	528.7(497.12)(043.3)
Avtor:	mag. Andreja Švab Lenarčič, univ. dipl. inž. geod.
Mentor:	prof. dr. Krištof Oštir
Naslov:	Veččasovna klasifikacija pokrovnosti z optičnimi satelitskimi posnetki
Tip dokumenta:	Doktorska disertacija
Obseg in oprema:	175 str., 63 pregl., 77 sl., 6 en., 0 pril.
Ključne besede:	optični satelitski posnetki, objektno usmerjena klasifikacija, segmentacija, klasifikacija pokrovnosti, časovna vrsta satelitskih posnetkov, veččasovna klasifikacija

Izvleček

Dostopnost časovnih vrst visoko prostorsko in časovno ločljivih satelitskih posnetkov je omogočila razvoj metod veččasovne klasifikacije pokrovnosti, ki naj bi – zaradi časovne informacije – izboljšale kakovost klasifikacije. V disertaciji sta obravnavani dve veččasovni klasifikaciji: kvazi veččasovna klasifikacija in klasifikacija na osnovi časovnih vrst. Pri prvi posnetke časovne vrste uporabimo kot attribute enočasovne klasifikacije, pri drugi pa primerjamo razvoj določenih spektralnih karakteristik v času. Klasifikacije petih osnovnih razredov pokrovnosti (gozd, travnik, njiva, voda, urbano) in šestih osnovnih poljščin (koruza, pšenica, ječmen, buča, oljna ogrščica, tritikala) so bile izvedene z različnimi vhodnimi podobami, atributi, osnovnimi enotami ter posnetki različnih senzorjev. Velik poudarek je na preučitvi postopkov segmentacije, saj izkušnje o uporabnosti segmentov kot osnovnih enot veččasovne klasifikacije v svetovnem merilu skoraj ni. Poleg same učinkovitosti omenjenih metod je podrobno analiziranih več možnih vplivov na rezultat klasifikacije. Namen je izboljšati trenutno zelo skromne usmeritve za pridobitev visoke natančnosti pri kratkem času procesiranja. Dobljeni rezultati kažejo, da je – poleg spektralnih vrednosti – čas zajema satelitskega posnetka najpomembnejši atribut pri klasifikaciji. Kvazi veččasovna klasifikacija povprečno omogoča pridobitev mnogo višje skupne natančnosti kakor enočasovna klasifikacija (+8 % osnovni razredi, +16 % poljščine), s čimer se s povprečno skupno natančnostjo 90 % (osnovni razredi) in 88 % (poljščine) dotika uporabne operative vrednosti. Rezultati klasifikacije na osnovi časovnih vrst so od rezultatov kvazi veččasovne klasifikacije slabši (-1 % osnovni razredi, -25 % poljščine), pri čemer je čas izvajanja izredno dolg, kar metodo uvršča med trenutno nesprejemljivo za praktično uporabo. Pomembna ugotovitev naloge je, da za veččasovno klasifikacijo segmenti niso najustreznejše osnovne enote. Ne glede na postopek pridobitve namreč prinašajo slabšo natančnost klasifikacije od referenčnih poligonov (-5 % osnovni razredi, -18 % poljščine) in pikslov (-5 % osnovni razredi, -16 % poljščine).

»Ta stran je namenoma prazna.«

BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC : 528.7(497.12)(043.3)
Author: Andreja Švab Lenarčič, M.Sc.
Supervisor: Prof. Krištof Oštir, Ph.D.
Title: Multitemporal land cover classification of optical satellite imagery
Document type : Doctoral Dissertation
Notes : 175 p., 63 tab., 77 fig., 6 eq., 0 app.
Keywords: optical satellite images, object-based classification, segmentation, land cover classification, satellite image time series, multitemporal classification

Abstract

The accessibility of high spatial and high temporal satellite imagery time series has enabled the development of methods of multitemporal land cover classification, which should improve the quality of classification due to time information. The dissertation examines two multitemporal classifications: quasi-multitemporal classification and time series based classification. In the first one, image time series are used as the attributes of single-date classification, while the second one compares the development of certain spectral characteristics over time. The classifications of five basic land cover classes (forest, grass, arable land, water, build-up) and six basic crops (maize, wheat, barley, pumpkin, rapeseed, triticale) are performed using various input images, attributes, mapping units and images of different sensors. Emphasis is given to segmentation processes since the segments as basic units of multitemporal classification are not well researched globally. In addition, several possible effects on the classification result are analysed in detail to provide guidelines for obtaining high precision in short processing time. The results show that satellite image acquisition time, besides spectral values, is the most important attribute in the classification. The quasi-multitemporal classification returns a much higher overall accuracy (+8% basic classes, +16% crops), with an average total accuracy of 90% (basic classes) and 88% (crops) giving the useful operational value. The results of the time series based classification are worse (-1% basic classes, -25% crops), the processing time being extremely long, which makes the method as currently unacceptable for practical use. An important finding of this dissertation is that segments are not the most suitable mapping units for the multitemporal classification. Regardless of the production process, segments give worse classification accuracy than reference polygons (-5% basic classes, -18% crops) and pixels (-5% basic classes, -16% crops).

»Ta stran je namenoma prazna.«

ZAHVALA

V prvi vrsti se zahvaljujem mentorju prof. dr. Krištofu Oštirju, brez katerega ta disertacija zagotovo ne bi ugledala belega dne. Iskrena hvala za prepoznavo raziskovalnega duha v meni, seznanitvijo z meni takrat neobičajno, a navdušujočo vedo, daljinskim zaznavanjem, ter za vse spodbude pri odločitvi za podajo na to pot. Hvala za nesebično pomoč in usmerjanje pri pisanju disertacije same. Za konkretne napotke ter hitre in jasne odločitve.

Hvala Evropski vesoljski agenciji¹ ter Javni agenciji za raziskovalno dejavnost Republike Slovenije², ker sta finančno podprli projekta, na katerih je disertacija osnovana. Hvala Centru odličnosti veselje, znanost in tehnologije ter Znanstvenoraziskovalnemu centru Slovenske akademije znanosti in umetnosti, Inštitutu za antropološke in prostorske študije, za možnost dela na projektih ter strojno in programsko opremo.

Hvala vsem sodelavcem za večno pozitivno naravnost, pripravljenost k skupnemu razmišljanju, vedno dobre nasvete in občasno konkretno pomoč. Posebna hvala Klemnu Č. za pomoč pri prebijanju skozi programske kode ter Nataši Đ. za svoj odlično opravljen prispevek k projektoma.

Hvala Ministrstvu za kmetijstvo, gozdarstvo in prehrano, Agenciji RS za kmetijske trge in razvoj podeželja ter Panviti d.d. za uporabo svojih podatkov v raziskovalne namene.

Hvala mojim staršem, da so mi omogočili šolanje brez odvečnih skrbi.

Nenazadnje hvala možu za vsestransko podporo in razumevanje ter sinovoma za prepotrebno vmesno razvedrilo.

1 Projekt Application of Sentinel-2 time series data for crop identification and crop stress monitoring – Sentinel2Agri4Slovenia (številka 4000112100/14/NL/NDe) je sofinancirala Evropska vesoljska agencija.

2 Projekt Samodejna objektno usmerjena klasifikacija pokrovnosti podatkov optičnega daljinskega zaznavanja (J2-6777) je sofinancirala Javna agencija za raziskovalno dejavnost Republike Slovenije iz državnega proračuna.

»Ta stran je namenoma prazna.«

KAZALO VSEBINE

Eratta	I
Bibliografsko-dokumentacijska stran in izvleček	III
Bibliographic-documental information and abstract	V
Zahvala	VII
Kazalo vsebine	IX
Kazalo preglednic	XII
Kazalo slik	XVIII
List of Tables	XXIII
List of Figures	XXIX
Okrajšave in simboli	XXXV
Slovar strokovnih besed in tujk	XXXVII
1 UVOD	1
1.1 Cilji doktorske disertacije	3
1.2 Raziskovalne hipoteze	4
1.2.1 Hipoteza H1	4
1.2.2 Hipoteza H2	5
1.2.3 Hipoteza H3	5
1.2.4 Hipoteza H4	6
1.3 Struktura poglavij	6
2 OSNOVE KLASIFIKACIJE POKROVNOSTI	7
2.1 Objektno usmerjena klasifikacija	7
2.1.1 Segmentacija	8
2.1.2 Osnovna enota kartiranja	8
2.1.3 Vhodna podoba	8
2.2 Veččasovna klasifikacija	9
2.2.1 Kvazi veččasovna klasifikacija	12
2.2.2 Klasifikacija na osnovi časovnih vrst	13
2.2.3 Pregled obstoječih raziskav na področju veččasovne klasifikacije pokrovnosti	14
3 METODE DELA	17
3.1 Metode ocenjevanja kakovosti klasifikacije	17
3.2 Metode ocenjevanja kakovosti segmentacije	21
3.3 Zanesljivost ocene segmentacije za napoved ocene klasifikacije	23
3.4 Način izbire najboljših rezultatov posameznega sklopa	27
4 UPORABLJENI PODATKI	29
4.1 Študijsko območje	29
4.2 Satelitski posnetki	30
4.2.1 RapidEye	30
4.2.2 SPOT5 Take5	31
4.2.3 Sentinel-2	32
4.2.4 Predobdelava satelitskih posnetkov	35
4.3 Referenčni podatki	36
4.3.1 Dejanska raba kmetijskih in gozdnih zemljišč	36
4.3.2 Grafična enota rabe kmetijskega gospodarstva	37
4.3.3 Podatki Panvita	38
4.3.4 Priprava referenčnih slojev	39
5 PROGRAMSKA OPREMA IN OSNOVNI PRINCIPI DELOVANJA UPORABLJENIH ALGORITMOV	44
5.1 Segmentacija	44

5.2	Enočasovna in kvazi veččasovna klasifikacija	44
5.2.1	Atributi, osnovna enota in določitev učnih vzorcev	44
5.2.2	Klasifikator	45
5.3	Klasifikacija na osnovi časovnih vrst	46
6	PREUČITEV POSTOPKOV SEGMENTACIJE	47
6.1	Primerjava algoritmov in programske opreme za segmentacijo	47
6.1.1	Primerjava algoritmov	47
6.1.2	Primerjava programske opreme	48
6.1.2.1	Vhodni in izhodni podatki	51
6.1.2.2	Segmentacija	51
6.1.2.3	Uporabniški vidik	51
6.1.2.4	Dobljene smernice glede algoritmov in programske opreme	51
6.2	Preučitev algoritma ENVI FX ter vpliva njegovih spremenljivk na segmentacijo	52
6.2.1	Delovanje algoritma razvodij	53
6.2.2	Vpliv metode vpeljave algoritma razvodij na vhodno podobo	54
6.2.3	Vpliv vhodne podobe na segmentacijo	54
6.2.4	Vpliv parametrov na segmentacijo	57
6.2.5	Vpliv parametrov na klasifikacijo	60
7	ANALIZA UPORABNOSTI ENO-KANALNIH VHODNIH PODOB	63
7.1	Izdelava eno-kanalne podobe iz kombinacije spektralnih lastnosti	64
7.2	Izdelava eno-kanalne podobe iz kombinacije teksturnih lastnosti	68
8	DOLOČITEV NAJZNAČILNEJŠIH ATRIBUTOV	71
8.1	Določitev najznačilnejših spektralnih atributov	72
8.1.1	Vizualna primerjava	72
8.1.2	Časovna korelacija	75
8.1.2.1	Korelacija neodvisna od razreda pokrovnosti	75
8.1.2.2	Korelacija na osnovnih razredih pokrovnosti	77
8.1.2.3	Korelacija na osnovnih poljščinah	80
8.1.2.4	Atributi, izbrani s časovno korelacijo	84
8.1.3	Algoritem ReliefF	86
8.1.4	Klasifikacija	91
8.1.4.1	Enočasovna klasifikacija	91
8.1.4.2	Kvazi veččasovna klasifikacija	96
8.1.5	Končna določitev najznačilnejših spektralnih atributov	102
8.2	Določitev najznačilnejših statističnih kazalnikov in teksturnih atributov	103
8.2.1	Enočasovna klasifikacija	104
8.2.2	Kvazi veččasovna klasifikacija	107
8.2.3	Končna določitev najznačilnejših statističnih kazalnikov in teksturnih atributov	109
9	DOLOČITEV OPTIMALNE OSNOVNE ENOTE KARTIRANJA	110
9.1	Opis osnovnih enot	110
9.2	Izbor segmentacij	112
9.3	Analiza optimalnih enot pri enočasovni klasifikaciji	114
9.3.1	Enočasovna klasifikacija osnovnih razredov	114
9.3.2	Enočasovna klasifikacija osnovnih poljščin	122
9.4	Analiza optimalnih enot pri veččasovni klasifikaciji	125
9.4.1	Veččasovna klasifikacija osnovnih razredov	126
9.4.2	Veččasovna klasifikacija osnovnih poljščin	128
9.5	Določitev optimalne osnovne enote kartiranja	130
10	VPELJAVA NAJSODOBNEJŠIH METOD V POSTOPEK SEGMENTACIJE	131

10.1	Vpeljava različnih metod zaznave robov v postopek segmentacije	131
10.2	Vpeljava teksture v postopek segmentacije	136
10.3	Večnivojska segmentacija	141
10.4	Veččasovna segmentacija	144
11	PRIMERJAVA ENOČASOVNE IN VEČČASOVNE KLASIFIKACIJE	151
11.1	Osnovni razredi pokrovnosti	151
11.1.1	RapidEye	152
11.1.2	SPOT5 Take5	153
11.1.3	Sentinel-2	154
11.2	Osnovni tipi poljščin	155
11.2.1	RapidEye	155
11.2.2	SPOT5 Take5	156
11.2.3	Sentinel-2	157
11.3	Primerjava rezultatov enočasovne in veččasovne klasifikacije	157
12	ZAKLJUČEK	159
13	POVZETEK	164
14	SUMMARY	166
	VIRI	168

KAZALO PREGLEDNIC

Preglednica 1: Primer matrike napak, dobljene po klasifikaciji pokrovnosti Krasa. Vrstice predstavljajo piksele klasificiranega sloja, stolpci predstavljajo piksele referenčnega sloja. Skupno število referenčnih in klasificiranih pikslov mora biti enako (v tem primeru 800).	18
Preglednica 2: Ocena natančnosti klasifikacije, dobljena na osnovi matrike napak v preglednici 1.20	
Preglednica 3: Rezultati stopnje kakovosti segmentacije (SQR) za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (od merila 0, združitev 0 do merila 90, združitev 90), os y predstavlja vrednost ocene segmentacije. Razpon obeh osi je enak pri vseh razredih.	26
Preglednica 4: Rezultati stopnje kakovosti klasifikacije (CQR) za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (od merila 0, združevanje 0 do merila 90, združevanje 90), os y predstavlja vrednost ocene klasifikacije. Razpon obeh osi je enak pri vseh razredih.	27
Preglednica 5: Valovne dolžine, ki jih zajemajo kanali RapidEye (Satellite Image Corporation, 2016a)	30
Preglednica 6: Valovne dolžine, ki jih zajemajo kanali SPOT5 (Satellite Image Corporation, 2016b)	31
Preglednica 7: Valovne dolžine, ki jih zajemajo kanali Sentinel-2a (Satellite Image Corporation, 2016c)	33
Preglednica 8: Šifrant razvrstitve razredov dejanske rabe v osnovne razrede pokrovnosti za klasifikacijo	40
Preglednica 9: Šifrant razvrstitve vrst kmetijskih rastlin (KMRS) v razrede poljščin za klasifikacijo	42
Preglednica 10: Seznam izdelanih eno-kanalnih spektralnih slojev s kraticami, ki so uporabljene v nadaljevanju	65
Preglednica 11: Deset najbolj pozitivno, najbolj negativno in najbolj nekoreliranih atributov glede na korelacijo z atributom NDVI, neodvisno od razreda pokrovnosti.	76
Preglednica 12: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano neodvisno od razreda pokrovnosti	77
Preglednica 13: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano za posamezen osnovni razred pokrovnosti.	80
Preglednica 14: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano za šest osnovnih poljščin.	84
Preglednica 15: Najznačilnejši spektralni atributi glede na moč časovne korelacije. Osnovni razredi, označeni od 1 do 5 so: njiva, trava, gozd, urbano, voda. Poljščine, označene od 1 do 6 so: koruza, pšenica, ječmen, buča, ogrščica in tritikala. Izbrani najznačilnejši atributi so obarvani modro. Atributi, ki bodo kot vhodni podatek šli v aplikacijo ReliefF in klasifikacijo, so poudarjeni.	85
Preglednica 16: Trideset najznačilnejših atributov po izračunu algoritma ReliefF, izbranih izmed 80 atributov posnetka RapidEye 29.7.2013, računanih kot mediana vrednosti na poligonih referenčnega sloja. S »S« je označena stopnja značilnosti.	86
Preglednica 17: Rezultati klasifikacije osnovnih razredov pokrovnosti na posnetku RapidEye 29.7.2013, osnovni enoti GERK in različnih atributih (mediana na OE): na devetih	

atributih, izbranih s korelacijo, na trideset najznačilnejših atributih po izboru algoritma ReliefF in osnovnih štirih spektralnih kanalih.	87
Preglednica 18: Kratek opis devetih izbranih spektralnih atributov	88
Preglednica 19: Stopnje značilnosti devetih atributov (mediana na OE), določene na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih razredov na posnetku RapidEye in študijskem območju Pomurja. Stopnja pri treh različnih datumih, seštevek posameznih stopenj ter skupna stopnja značilnosti. Nižji seštevek pomeni višjo značilnost atributa.	89
Preglednica 20: Stopnje značilnosti devetih atributov (mediana na OE), določene na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih poljščin na posnetku RapidEye in študijskem območju Pomurja. Stopnja pri treh različnih datumih, seštevek posameznih stopenj ter skupna stopnja značilnosti. Nižji seštevek pomeni višjo značilnost atributa.	89
Preglednica 21: Stopnja značilnosti atributov (mediana na OE), določena na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih razredov in osnovnih poljščin na posnetku RapidEye, študijsko območje Pomurja.	90
Preglednica 22: Število pojavitev posameznega spektralnega atributa med trideset najznačilnejšimi atributi (ne glede na datum). Dobljeno iz preglednice 21.	91
Preglednica 23: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 18.5.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.	92
Preglednica 24: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.	92
Preglednica 25: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 14.9.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.	92
Preglednica 26: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z najboljšim, potem pa postopoma dodajamo naslednje najboljše glede na osebno presojo kakovosti klasifikacij s posameznimi atributi (preglednica 24).	93
Preglednica 27: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z najboljšim, potem pa postopoma dodajamo naslednje najboljše glede na vrstni red, kot ga predlaga ReliefF (preglednica 20).	94
Preglednica 28: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. V praksi najpogosteje uporabljane kombinacije atributov.	94
Preglednica 29: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Kombinacije najboljših in najslabših atributov glede na predlog algoritma ReliefF ter kombinacije z izključevanjem posameznih atributov.	95
Preglednica 30: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. V praksi najpogosteje uporabljane kombinacije atributov, uspešna kombinacija pri klasifikaciji osnovnih razredov ter kombinacija vseh devetih atributov.	96

- Preglednica 31: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje. Vsi časi za en sloj, vsak sloj posebej. 97
- Preglednica 32: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z vsemi datumi najboljšega spektralnega sloja, potem pa postopoma dodajamo naslednje najboljše glede na osebno presojo kakovosti klasifikacij s posameznimi atributi (izhajajo iz preglednice 31). 97
- Preglednica 33: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov (N) se iz koraka v korak povečuje. Začnemo z vsemi datumi najboljšega spektralnega sloja, potem pa postopoma dodajamo naslednje najboljše glede na izbiro atributov z algoritmom ReliefF (preglednica 21). Krepko so označeni atributi najboljših rezultatov. 98
- Preglednica 34: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Rezultati klasifikacij z dvema kombinacijama osnovnih spektralnih kanalov ter njima dodanim atributom NDVI. Število atributov je označeno z N. 99
- Preglednica 35: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje, glede na število najznačilnejših atributov po izboru algoritma ReliefF. Rezultati klasifikacij s kombinacijo osnovnih spektralnih kanalov ter njim dodanim atributom NDVI. Število atributov je označeno z N. 99
- Preglednica 36: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti vseh spektralnih slojev na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje, glede na število najznačilnejših atributov po izboru algoritma ReliefF. 100
- Preglednica 37: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje. Rezultati klasifikacij z dvema kombinacijama osnovnih spektralnih kanalov ter njima dodanim atributom NDVI. Število atributov je označeno z N. 100
- Preglednica 38: Pogostost pojavitve datuma med najboljših 30 atributov po presoji algoritma ReliefF 101
- Preglednica 39: Opis analiziranih statističnih kazalnikov in teksturnih atributov 104
- Preglednica 40: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Statistični kazalniki in teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 105
- Preglednica 41: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Vse kombinacije statističnega kazalnika in teksturnih

- atributov so bile izračunane za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 105
- Preglednica 42: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 106
- Preglednica 43: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Vse kombinacije statističnega kazalnika in teksturnih atributov so izračunane za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 106
- Preglednica 44: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov vseh testnih posnetkov RapidEye leta 2013. Teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 107
- Preglednica 45: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov vseh testnih posnetkov RapidEye leta 2013. Statistični kazalnik in teksturni atributi so bili izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 108
- Preglednica 46: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin vseh testnih posnetkov RapidEye leta 2013. Statistični kazalnik in teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje. 108
- Preglednica 47: Rezultati stopnje kakovosti klasifikacije za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (zgornja vrsta merilo, spodnja vrsta združevanje), os y predstavlja vrednost ocene klasifikacije. Razpon obeh osi je enak pri vseh razredih. 112
- Preglednica 48: Rezultati stopnje kakovosti klasifikacije, dobljeni pri različnih parametrih segmentacij. Klasifikacija je bila izvedena za osnovne razrede pokrovnosti, s klasifikatorjem k-NN, na segmentacijah v intervalu merilo_združitvev od 00_00 do 40_90. V prvem delu tabele je za vsak razred pokrovnosti prikazana najnižja in najvišja kakovost klasifikacije ter pripadajoče segmentacije. V drugem delu tabele so navedene tri (po cenilki stopnje kakovosti segmentacije sodeč) najbolj kakovostne segmentacije ter pripadajoče stopnje kakovosti klasifikacije. Parametri segmentacij pri najboljših stopnjah kakovosti klasifikacije (zgornjih 25 % vrednosti intervala min-max) so odebeljeni. 113
- Preglednica 49: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije. Klasifikator ANN. Vse segmentacije so narejene na RGBNir s Sobelovo metodo zaznave robov. 114
- Preglednica 50: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije. Klasifikator ANN. Vse segmentacije so narejene na RGBNir s Sobelovo metodo zaznave robov. 123
- Preglednica 51: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye datumov od 9.4.2013 do 26.10.2013. Študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije mediana RGBNir. Klasifikator ANN. Segmentacije so bile izvedene na posnetku RapidEye 29.7.2013, na slojih RGBNir s Sobelovo metodo zaznave robov. 126
- Preglednica 52: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetkih RapidEye datumov od 9.4.2013 do 26.10.2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije RGBNir.

Klasifikator ANN. Segmentacije so bile izvedene na posnetku RapidEye 29.7.2013, na slojih RGBNir s Sobelovo metodo zaznave robov.	128
Preglednica 53: Opis uporabljenih metod zaznave robov	132
Preglednica 54: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na segmentih, osnovanih s podobami gradienta različnih metod zaznave robov. Osnova podob gradienta je bil posnetek RapidEye 29.7.2013. Na segmentih se računa mediana vrednosti spektralnih slojev R, G, B in NIR. Študijsko območje Murska Sobota.	134
Preglednica 55: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na segmentih, osnovanih na različnih teksturnih vhodnih podobah. Osnova analize je bil posnetek RapidEye 29.7.2013. Na segmentih se za klasifikacijo računa mediana vrednosti spektralnih slojev R, G, B in NIR. Študijsko območje Murska Sobota. Za vsako vhodno podobo sem vzela takšne parametre velikosti in združitve, ki so se iz med vseh možnih vizualno zdeli najbolj podobni poligonu referenčnega sloja. Parametra sta za vsak posamezen primer zapisana v oklepajih (velikost_združitev).	138
Preglednica 56: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetkih RapidEye datumov od 9.4.2013 do 8.10.2013, študijsko območje Murska Sobota. Klasifikacije na dveh nesegmentiranih osnovnih enotah, različnih enočasovno določenih segmentih ter različnih veččasovno določenih segmentih. Atributi klasifikacije mediana RGBNir, klasifikator ANN.	149
Preglednica 57: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetkih RapidEye od 9.4.2013 do 8.10.2013., študijsko območje Murska Sobota. Klasifikacije na dveh nesegmentiranih osnovnih enotah, različnih enočasovno določenih segmentih ter različnih veččasovno določenih segmentih. Atributi klasifikacije RGBNir, klasifikator ANN.	149
Preglednica 58: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih RapidEye študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGBNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 29.7.2013, pri veččasovnih klasifikacijah pa naslednji posnetki RapidEye za leto 2013: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. in 26.10. 2013. V času računanja sta sešteta čas učenja in čas klasifikacije.	152
Preglednica 59: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih SPOT5 Take5 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGBNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 1.8.2015, pri veččasovnih klasifikacijah pa naslednji posnetki SPOT5 Take5 za leto 2015: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. in 10.9.2015. V času računanja sta sešteta čas učenja in čas klasifikacije.	153
Preglednica 60: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih Sentinel-2 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGBNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek	

6.8.2016, pri veččasovnih klasifikacijah pa naslednji posnetki Sentinel-2 za leto 2016: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. in 3.9.2016. V času računanja sta sešteta čas učenja in čas klasifikacije. 154

Preglednica 61: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih RapidEye študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 29.7.2013, pri veččasovnih klasifikacijah pa naslednji posnetki RapidEye za leto 2013: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. in 26.10. 2013. V času računanja sta sešteta čas učenja in čas klasifikacije. 155

Preglednica 62: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih SPOT5 Take5 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 1.8.2015, pri veččasovnih klasifikacijah pa naslednji posnetki SPOT5 Take5 za leto 2015: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. in 10.9.2015. V času računanja sta sešteta čas učenja in čas klasifikacije. 156

Preglednica 63: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih Sentinel-2 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 6.8.2016, pri veččasovnih klasifikacijah pa naslednji posnetki Sentinel-2 za leto 2016: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. in 3.9.2016. V času računanja sta sešteta čas učenja in čas klasifikacije. 157

KAZALO SLIK

Slika 1: Postopek objektno usmerjene klasifikacije: predobdelava daljinsko zaznanega posnetka (a), segmentacija (b) in klasifikacija (vektorski sloj pokrovnosti) (c)	7
Slika 2: Primeri osnovne enote kartiranja: PIKSEL (a), SEGMENT (b) in GERK (c)	8
Slika 3: Barvni prikazi primerov vhodnih podob. Kot rdeča, zelena in modra barva so prikazane sledeče podobe posnetkov RapidEye: podoba rdečega, zelenega in modrega kanala posnetka 29.7.2013 (a); podoba rdečega in zelenega kanala ter podoba ndvi posnetka 29.7.2013 (b); podoba ndvi posnetka 18.5.2013, podoba ndvi posnetka datuma 29.7.2013 in podoba ndvi posnetka 14.9.2013 (c).	9
Slika 4: Fotografije različnih fenoloških faz macesnovega gozda Fujihokuroku. Vir: Center for Global Environmental Research, National Institute for Environmental Studies, Japan (po Simonetti et al., 2014).	10
Slika 5: Mesečni satelitski posnetki RapidEye občine Stara Nova vas	11
Slika 6: Posnetek julija (a); septembra (b); graf povprečnih vrednosti NDVI na izbranih njivah skozi čas (c)	11
Slika 7: Graf časovnega spreminjanja povprečne vrednosti indeksa NDVI za izbrane poljščine	12
Slika 8: Podobe različnih datumov (D1 do D4) s štirimi kanali (levo) in podoba, v kateri so združeni kanali vseh posameznih štirih posnetkov (desno)	13
Slika 9: Klasični fenološki razvoj rastlinskega razreda pokrovnosti, prikazan v obliki razvoja indeksa NDVI (Aurdal et al., 2005)	14
Slika 10: Primeri pogreškov: resnični pozitivni (TP), resnični negativni (TN), lažni pozitivni (FP) in lažni negativni (FN)	19
Slika 11: Referenčni objekt razreda (CRO): unija vseh referenčnih objektov določenega razreda; unija segmentov razreda (CSU): unija vseh segmentov, ki se več kot 50 % prekrivajo s CRO; resnično pozitivni piksli (TP); lažno negativni piksli (FN); lažno pozitivni piksli (FP) in meje segmentov (S).	23
Slika 12: Rezultat segmentacije na naslednjih posnetkih: SPOT 5 (a), RapidEye (b), WorldView-2 (c) in ortofoto (d). Modra črta predstavlja izbran referenčni poligon gozda. Poudarjena rumena črta predstavlja unije segmentov izbranega poligona gozda. Vektorski sloj segmentacije je prikazan v svetlo rumeni barvi.	24
Slika 13: Rezultat klasifikacije segmentov, dobljenih pri enakih parametrih na naslednjih posnetkih: SPOT 5 (a), RapidEye (b), WorldView-2 (c) in ortofoto (d). Modra črta predstavlja izbran referenčni poligon gozda. Rdeča črta predstavlja mejo unije segmentov izbranega poligona gozda. Segmenti, klasificirani kot gozd, so združeni in obarvani zeleno. Segmenti, ki niso bili klasificirani kot gozd, so združeni in obarvani svetlo sivo.	25
Slika 14: Prikaz oznak parametrov segmentacije na grafih disertacije. V zgornji vrsti so navedeni parametri merila, v spodnji vrsti parametri združitev.	26
Slika 15: Študijsko območje Pomurje (polna rdeča črta) in študijsko območje Murska Sobota (črtkana rdeča črta)	29
Slika 16: Predogledi posnetkov RapidEye za študijsko območje Pomurje	31
Slika 17: Predogledi posnetkov SPOT5 Take5 za študijsko območje Pomurja. Kanali GREEN, RED, NIR	32
Slika 18: Predogledi posnetkov Sentinel-2 za študijsko območje Pomurja	34
Slika 19: Sloj RABA z legendo na študijskem območju Murska Sobota	37

Slika 20: Sloj GERK z legendo na študijskem območju Murska Sobota	38
Slika 21: Sloj PANVITA z legendo na študijskem območju Murska Sobota	39
Slika 22: Koledar dogodkov na šestih glavnih poljščinah Panvite za leto 2013	39
Slika 23: Referenčni sloji osnovnih razredov za leta 2013 (a), 2015 (b) in 2016 (c). Študijsko območje Murska Sobota.	41
Slika 24: Referenčni sloji poljščin za leta 2013 (a), 2015 (b) in 2016 (c). Študijsko območje Murska Sobota.	43
Slika 25: Primeri segmentacij posnetka RapidEye, izvedenih s podobnimi nastavitvami in z različno programsko opremo: eCognition (a), ENVI FX (b), InterIMAGE (c) in OrfeoToolbox (d).	50
Slika 26: Relief jakosti gradienta (a), podoba jakosti gradienta (b), podoba razvodij gradienta (c) in relief razvodij gradienta (d) (Cousty, 2007)	53
Slika 27: Območje, prikazano z vrednostmi bližnje-infrardečega kanala (a); območje, prikazano z vrednostmi bližnje-infrardečega kanala, obdelanega z operacijo morfološkega zapiranja z velikostjo okna 5 x 5 pikslov (b); segmentacija posnetka (a) s parametri merilo 30 in združitev 70 (c); segmentacija posnetka (b) s parametri merilo 30 in združitev 70 (d).	56
Slika 28: Območje, prikazano z vrednostmi rdečega kanala R (a); območje, prikazano z vrednostmi bližnje-infrardečega kanala Nir (b); območje, prikazano z vrednostmi R in Nir kanala v kombinaciji RGB = RNirR (c); segmentacija posnetka (a) s parametri merilo 30 in združitev 70 (d); segmentacija posnetka (b) s parametri merilo 30 in združitev 70 (e); segmentacija posnetka (c) s parametri merilo 30 in združitev 70 (f);	57
Slika 29: Segmentacija spektralnih kanalov R, G, B in NIR s stopnjo združevanja 50 ter stopnjami merila 00 (a), 30 (b) in 50 (c)	59
Slika 30: Segmentacija spektralnih kanalov R, G, B in NIR s stopnjo merila 00 ter stopnjami združevanja 00 (a), 30 (b) in 60 (c). Združevanje je bilo izvedeno z metodo FLS in spektralnimi kanali R, G, B in NIR.	59
Slika 31: Referenčni sloj (a) ter klasifikacija osnovnih razredov pokrovnosti, izvedena s klasifikatorjem k-Nearest Neighbour, vhodnimi podobami R, G, B in NIR ter parametri segmentacije merilo_združitev = 00_00 (b), 30_50 (c) in 50_50 (d).	61
Slika 32: Rezultati skupne natančnosti klasifikacije vseh osnovnih razredov pokrovnosti. Os x predstavlja parametre segmentacije. V zgornji vrsti so navedeni parametri merila (od 00 do 90), v spodnji vrsti parametri združitev (od 0 do 90). Os y predstavlja vrednost ocene klasifikacije.	62
Slika 33: Vegetacijski indeksi: normiran diferencialni vegetacijski indeks (NDVI) (a), prvi indeks odbojnosti antocianinov (ARI-1) (b) in transformiran indeks vpojnosti klorofila (TCARI) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.	67
Slika 34: Barvne transformacije: intenziteta podobe NirGB (NIR_GREEN_BLUE_VAL) (a), nasičenost podobe NirRdgR (NIR_REDEGE_RED_SAT) (b) in barva podobe RGB (RED_GREEN_BLUE_HUE) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.	67
Slika 35: Analiza posameznih komponent originalnih kanalov posnetka RE: druga komponenta (ICA-FORWARD-2) (a), četrta komponenta (ICA-FORWARD-4) (b) in peta komponenta (ICA-FORWARD-5) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.	68

- Slika 36: Metoda »kape s cofom«: svetlost (BRIGHTNESS) (a), zelenost (GREENNESS) (b) in rumenost (YELLOWNESS) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota. 68
- Slika 37: Podobe matrike sopojavljanja, narejene z oknom velikosti 3 x 3 s podobo rdečega kanala: povprečje (a), varianca (b), kontrast (c), homogenost (d), drugačnost (e) in entropija (f). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota. 70
- Slika 38: Podobe konvolucijskih filtrov: smerni filter kota 0° (a); smerni filter kota 135° (b) in visokopasovni filter rdečega kanala (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota. 70
- Slika 39: Podobnost podob indeksov NDVI (a) in TDVI (b) 72
- Slika 40: Podobnost podob indeksov ARI-1 (a) in CVI (b). 73
- Slika 41: Primeri podob z veliko šuma: CCCI (a), NDVI_GREEN_BLUE_HUE (b), PSRI_NIR_REDEDGE_HUE (c) in SR_GREEN_BLUE_HUE (d) 73
- Slika 42: Primeri podob atributov, izbranih na osnovi vizualne primerjave: ARI-1 (a), BAI (b), BLUE (c), CHLREDEDGE (d), GREEN (e), NDVI (f), NDVI-GREEN (g), NIR (h), PSRI-NIR (i), RED (j) in REDEDGE (k) 74
- Slika 43: Spremenljivost nekaterih izračunanih korelacij v odnosu z NDVI skozi vso rastno sezono 76
- Slika 44: Toplotna karta korelacij atributa NDVI z vsemi ostalimi atributi pri osnovnih razredih pokrovnosti. Daljša imena atributov so zapisana v preglednici 10. 78
- Slika 45: Toplotna karta vseh korelacij vseh atributov pri osnovnih razredih pokrovnosti: njiva (a), trava (b), gozd (c), urbano (d) in voda (e). Atributi so prikazani v enakem vrstnem redu kot na sliki 44 (začenši s SUMBANDS od leve proti desni in od spodaj navzgor). 79
- Slika 46: Toplotna karta korelacij atributa NDVI z vsemi ostalimi atributi pri osnovnih poljščinah pokrovnosti. Daljša imena atributov so zapisana v preglednici 10. 82
- Slika 47: Toplotna karta vseh korelacij vseh atributov pri razredih osnovnih poljščin: koruza (a), pšenica (b), ječmen (c), oljna buča (d), oljna ogrščica (e) in tritikala (f). Atributi so prikazani v enakem vrstnem redu kot na sliki 44 (začenši s SUMBANDS od leve proti desni in od spodaj navzgor). 83
- Slika 48: Čas izbiranja najznačilnejših atributov z ReliefF, čas učenja, čas same klasifikacije, skupni čas brez izbire atributov z ReliefF ter skupni čas z izbiro atributov z ReliefF pri določenem številu atributov na osnovni enoti GERK. 102
- Slika 49: Primeri različnih osnovnih enot: PIKSEL (a), MREŽA 3 x 3 (b), SEGMENT (c) in GERK (d). V ozadju je posnetek RapidEye, prikazan z vidnimi kanali. 111
- Slika 50: Referenčni sloj petih osnovnih razredov z masko (območja ne klasificiramo). Študijsko območje Murska Sobota. 117
- Slika 51: Rezultat klasifikacije z OE piksel (a) in OE GERK (b). Študijsko območje Murska Sobota. 117
- Slika 52: Rezultat klasifikacije z OE 3 x 3 (a) in OE SEGMENT 20_40 (b). Študijsko območje Murska Sobota. 118
- Slika 53: Rezultat klasifikacije z OE SEGMENT 30_70 (a) in OE SEGMENT 40_90 (b). Študijsko območje Murska Sobota. 119
- Slika 54: Rezultat klasifikacije z OE SEGMENT 50_90 (a) in OE SEGMENT 60_90 (b). Študijsko območje Murska Sobota. 119

- Slika 55: OE GERK (a), OE SEGMENT 20_40 (b), OE SEGMENT 30_70 (c) in OE SEGMENT 40_90 (d) na posnetku RapidEye 29.7.2013. Izsek študijskega območja Murska Sobota. 120
- Slika 56: OE GERK (a), OE SEGMENT 20_40 (b), OE SEGMENT 30_70 (c) in OE SEGMENT 40_90 (d) na referenčnem sloju osnovnih razredov za leto 2013. Izsek študijskega območja Murska Sobota. 121
- Slika 57: OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in SEGMENT 30_70 (d) na referenčnem sloju. Izsek študijskega območja Murska Sobota. 124
- Slika 58: Klasifikacija, dobljena z OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in OE SEGMENT 30_70 (d). Izsek študijskega območja Murska Sobota. 125
- Slika 59: Rezultat kvazi veččasovne klasifikacije osnovnih razredov z OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in OE SEGMENT 30_70 (d). Študijsko območje Murska Sobota. 127
- Slika 60: Rezultat kvazi veččasovne klasifikacije osnovnih poljščin z OE piksel (a), OE GERK (b), OE SEGMENT 10_20 (c) in OE SEGMENT 20_40 (d). Študijsko območje Murska Sobota. 129
- Slika 61: Izhodne podobe metod zaznave robov: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Robovi so bili narejeni na spektralnih pasovih R, G, B in NIR vhodne podobe RapidEye 29.7.2013. Študijsko območje Murska Sobota. 132
- Slika 62: Segmentacije, narejene z metodo intenzitete s podobami gradienta slike 61: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Vse segmentacije so bile izvedene z istimi parametri: segmentacija sama je bila narejena na vhodni podobi gradienta s stopnjo merila 30. Segmenti so bili nato združeni na osnovi kanalov R, G, B, Nir ter stopnjo združevanja 70. Na sliki je prikazan manjši izsek študijskega območja Murska Sobota. 133
- Slika 63: Podoba gradientov, pridobljena s Sobelovo metodo zaznave robov na posnetku RapidEye 29.7.2013 (transparenten sivi raster) ter segmenti, kot jih vrne algoritem razvodij pri parametrih 30_70 (modre linije). Izsek študijskega območja Murska Sobota. 135
- Slika 64: OE GERK v obliki, kot gre v postopek klasifikacije (a), ter OE SEGMENT 30_70, pridobljen s Sobelovo metodo zaznave robov (b). Oboje prikazano na RapidEye posnetku 29.7.2013 v pravih barvah. Izsek študijskega območja Murska Sobota. 136
- Slika 65: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) osnovnih enot GERK (a) in OE SEGMENT, dobljenih na osnovi podobe RGBNir (b). Vsi podatki klasifikacije so navedeni v preglednici 55. 139
- Slika 66: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) OE SEGMENT, dobljenih na osnovi morfologije RGBNir: odpiranje (a) in zapiranje (b). Vsi podatki klasifikacije so navedeni v preglednici 55. 139
- Slika 67: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) OE SEGMENT, dobljenih na osnovi podob matrik sopojavljanja RGBNir: povprečje (a), varianca (b), homogenost (c) in entropija (d). Vsi podatki klasifikacije so navedeni v preglednici 55. 140
- Slika 68: Izsek sloja segmentacije gozda, dobljenega na osnovi vhodnih slojev R in G ter parametrov 30_80 141
- Slika 69: Izsek klasifikacije gozda kot prvega razreda večnivojske klasifikacije 142

- Slika 70: Izsek sloja segmentacije razreda urbano, dobljenega na osnovi vhodne podobe NDVI ter parametrov 40_80. Območje gozda, klasificiranega v prejšnjem koraku, je maskirano, zato se segmentacija na tem območju ne izvaja. 142
- Slika 71: Rezultat večnivojske klasifikacije osnovnih razredov po prvi fazi (vsak razred je bil klasificiran le enkrat). Vso območje v beli barvi je ostalo neklasificirano in mora ponovno v postopek klasifikacije. 143
- Slika 72: Nemaskirana vhodna podoba NDVI posnetka RapidEye 15.6.2013 (a) in nemaskirana vhodna podoba NDVI posnetka RapidEye 19.5.2013 (b). Manjše študijsko območje. 145
- Slika 73: Maskirana vhodna podoba NDVI posnetka RapidEye 15.6.2013 (a) in maskirana vhodna podoba NDVI posnetka RapidEye 19.5.2013 (b). Manjše študijsko območje. 146
- Slika 74: Segmentacija združenih nemaskiranih vhodnih podob NDVI posnetkov RapidEye 15.6.2013 in 19.5.2013 (a) in segmentacija združenih maskiranih vhodnih podob NDVI istih dveh posnetkov (b). Manjše študijsko območje. Vektorska sloja segmentov sta prikazana na lažnem barvnem prikazu združenih nemaskiranih posnetkov. 146
- Slika 75: Segmentacija združenih nemaskiranih vhodnih podob NDVI posnetkov RapidEye 15.6.2013 in 19.5.2013 (a) in segmentacija združenih maskiranih vhodnih podob NDVI istih dveh posnetkov (b). Manjše študijsko območje. Vektorski sloj segmentov je prikazan na maskirani vhodni podobi NDVI posnetka RapidEye 15.6.2013. 147
- Slika 76: Segmentacija kanalov RGBNir podob RapidEye datumov 19.5.2013 (a), 15.6.2013 (b) in 8.10.2013 (c) na pripadajočih RGB posnetkih. 148
- Slika 77: Segmentacije narejene veččasovno na kanalih RGBNir in kombinacijah podob RapidEye datumov: 19.5.2013 in 29.7.2013 (a); 19.5.2013, 15.6.2013, 29.7.2013 in 8.10.2013 (b); 9.4.2013, 19.5.2013, 15.6.2013, 29.7.2013, 18.8.2013 in 8.10.2013 (c). Segmentacije so prikazane na posnetku RapidEye RGB 29.7.2013. 148

LIST OF TABLES

Table 1: Example of an error matrix, calculated after land cover classification of Kras. The rows represent pixels of classification layer, the columns represent pixels of reference layer. The total number of reference and classified pixels must be the same (800 in this case).	18
Table 2: Classification accuracy, calculated from error matrix in Table 1.	20
Table 3: Results of segmentation quality rate (SQR) for five land cover classes. X axis represents the segmentation parameters (from scale 0, merge 0 to scale 90, merge 90), Y axis represents the value of segmentation quality evaluation. The range of each axis is the same for all classes.	26
Table 4: Results of classification quality rate (CQR) for five land cover classes. X axis represents the segmentation parameters (from scale 0, merge 0 to scale 90, merge 90), Y axis represents the value of classification quality evaluation. The range of each axis is the same for all classes.	27
Table 5: Wavelengths of RapidEye bands (Satellite Image Corporation, 2016a)	30
Table 6: Wavelengths of SPOT5 bands (Satellite Image Corporation, 2016b)	31
Table 7: Wavelengths of Sentinel-2a bands (Satellite Image Corporation, 2016c)	33
Table 8: The coding system for linking actual land use and land cover classification class	40
Table 9: The coding system for linking gerk crop types (KMRS) and classification crop type classes	42
Table 10: List of obtained one-band spectral layers with acronyms, used in further chapters	65
Table 11: Ten most positively, most negatively and most non-correlated attributes according to correlation with NDVI attribute, irrespective of the land cover class.	76
Table 12: The most characteristic spectral attributes according to correlation strength among attributes, calculated irrespective of land cover class	77
Table 13: The most significant spectral attributes according to the correlation strength between the attributes, calculated for each basic land cover class.	80
Table 14: The most significant spectral attributes according to the correlation strength between the attributes, calculated for each basic croptype.	84
Table 15: The most significant spectral attributes according to the correlation strength. Basic land cover classes, labelled from 1 to 5 are: arable land, grass, forest, build-up and water. Croptypes, labelled from 1 to 6 are: maize, wheat, barley, oil pumpkin, rapeseed and triticale. The selected most significant spectral attributes are coloured in blue. Attributes that will be used as input data in ReliefF application and classification, are printed in bold.	85
Table 16: Thirty most significant attributes according to results of ReliefF algorithm, chosen among 80 attributes of RapidEye image 29.7.2013. The attributes were calculated as median of attribute values of reference layer polygon values. »S« indicates the significance level.	86
Table 17: Results of basic land cover class classification of RapidEye image 29.7.2013, mapping unit GERK and different attributes (median on mapping unit): on nine attributes, selected with a correlation, on thirty attributes, selected with ReliefF algorithm and on four basic spectral channels.	87
Table 18: Short description of nine selected spectral attributes	88
Table 19: Significance level of nine attributes (median on mapping unit), defined by ReliefF algorithm, used for basic land cover classification of RapidEye image and	

Pomurje study area. Significance level at three different dates, sum of individual levels and total level of significance. A lower sum means higher significance of attribute.	89
Table 20: Significance level of nine attributes (median on mapping unit), defined by ReliefF algorithm, used for croptype classification of RapidEye image and Pomurje study area. Significance level at three different dates, sum of individual levels and total level of significance. A lower sum means higher significance of attribute.	89
Table 21: Significance level of attributes (median on mapping unit), defined by ReliefF algorithm, used for basic land cover and croptype classification of RapidEye image on Pomurje study area.	90
Table 22: Number of occurrences of specific spectral attribute among thirty most specific attributes (irrespective of the capture date). Obtained from Table 21.	91
Table 23: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 18.5.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.	92
Table 24: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.	92
Table 25: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 14.9.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.	92
Table 26: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to personal classification quality evaluation of individual attributes (Table 24).	93
Table 27: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to ReliefF classification quality evaluation of individual attributes (Table 20).	94
Table 28: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The most often used attribute combinations in practice.	94
Table 29: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. Combinations of the best and the worst attributes according to ReliefF algorithm and combinations with excluding specific attributes.	95
Table 30: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The most often used attribute combinations in practice, successful combination at basic land cover class classification and combination of all nine attributes.	96
Table 31: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates).	

Median of spectral layer values of GERK mapping unit. Pomurje study area. All dates for one layer, each layer separately.	97
Table 32: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to personal estimation of classification quality of individual attributes (based on Table 31).	97
Table 33: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to ReliefF selection of best classification attributes (Table 21). Attributes of the best results are marked bold.	98
Table 34: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. Classification evaluation results of two combinations of spectral channels and them added attribute NDVI. Number of attributes is marked with N.	99
Table 35: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step, according to best attribute definition of ReliefF algorithm. Classification evaluation results of combinations of spectral channels and them added attribute NDVI. Number of attributes is marked with N.	99
Table 36: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step, according to best attribute definition of ReliefF algorithm.	100
Table 37: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The classification evaluation results of two combinations of basic spectral channels and them added attribute NDVI. The number of attributes is marked with N.	100
Table 38: The frequency of occurrence of individual dates in the top 30 attributes at the discretion of the algorithm ReliefF	101
Table 39: Description of analysed statistical indicators and textural attributes	104
Table 40: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Statistical indicators and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	105
Table 41: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	105
Table 42: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Statistical indicators and textural attributes were	

calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	106
Table 43: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	106
Table 44: F-score and overall accuracy (OA) of classification of basic land cover classes on all RapidEye images of year 2013. Statistical indicators and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	107
Table 45: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye images captured in year 2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	108
Table 46: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye images captured in year 2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.	108
Table 47: Results of classification quality rate (CQR) for five land cover classes. X axis represents the segmentation parameters (upper row scale, lower row merge), Y axis represents the value of classification quality evaluation. The range of each axis is the same for all classes.	112
Table 48: Results of classification quality rate obtained at different segmentation parameters. Classification was performed for basic land cover classes, with k-NN classifier and segmentations in the scale_merge interval from 00_00 to 40_90. In the first part of the table the minimum and maximum classification quality is shown for each land cover class, together with corresponding segmentations. In the second part of the table three (according to segmentation quality rate) most qualitative segmentations with corresponding classification quality rate are shown. Segmentation parameters at the best classification quality rates (upper 25 % values of the min-max interval) are printed in bold.	113
Table 49: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Pomurje study area. Classifications performed on different mapping units and classification attributes. ANN classifier. All segmentations were performed on RGBNir combination of images and with Sobel edge detection method.	114
Table 50: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Pomurje study area. Classifications performed on different mapping units and classification attributes. ANN classifier. All segmentations were performed on RGBNir combination of images and with Sobel edge detection method.	123
Table 51: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on all RapidEye images from date 9.4.2013 to 26.10 2013. Murska Sobota study area. Classifications on different mapping units with classification attributes median of RGBNir. ANN classifier. All segmentations were performed on RapidEye image 29.7.2013, on RGBNir layers and with Sobel edge detection method.	126
Table 52: F-score and overall accuracy (OA) of multitemporal classification of basic crop type classes on all RapidEye images from date 9.4.2013 to 26.10 2013. Murska Sobota study area. Classifications on different mapping units with classification attributes	

median of RGBNir. ANN classifier. All segmentations were performed on RapidEye image 29.7.2013, on RGBNir layers and with Sobel edge detection method.	128
Table 53: Description of used edge detection methods	132
Table 54: F-score and overall accuracy (OA) of classification of basic land cover classes, based on gradient images of different edge detection methods. Input for gradient images was RapidEye image 29.7.2013. Attributes on segments are calculated as median of RGBNir spectral bands. Murska Sobota study area.	134
Table 55: F-score and overall accuracy (OA) of classification of basic land cover classes on segments, based on different texture images. The basis was a RapidEye image 29.7.2013. Attributes were calculated as median of spectral values R, G, B and NIR. Pomurje study area. For each input image such segmentation parameters were used that visually seemed the most similar to polygons of reference layer. Parameters for each case are put into brackets in the form (scale_merge).	138
Table 56: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured on dates from 9.4.2013 to 8.10.2013. Murska Sobota study area. Classifications on two nonsegmented mapping units, different single-date obtained segments and different multitemporally obtained segments. Classification attributes: median of RGBNir bands. Classifier: ANN.	149
Table 57: F-score and overall accuracy (OA) of multitemporal classification of basic crop type classes on RapidEye images captured on dates from 9.4.2013 to 8.10.2013. Murska Sobota study area. Classifications on two nonsegmented mapping units, different single-date obtained segments and different multitemporally obtained segments. Classification attributes: median of RGBNir bands. Classifier: ANN.	149
Table 58: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on RapidEye imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 29.7.2013 was used. In the case of multitemporal classifications the following RapidEye images for the year 2013 were used: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. and 26.10. 2013. Processing time includes the sum of training time and classification time.	152
Table 59: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on SPOT5 Take5 imagery of Pomurje study area. All classifications used attribute of median RGNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 1.8.2015 was used. In the case of multitemporal classifications the following SPOT5 Take5 images for the year 2015 were used: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. and 10.9.2015. Processing time includes the sum of training time and classification time.	153
Table 60: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on Sentinel-2 imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN	

classifier. In the case of single-date classification, Sentinel-2 image 6.8.2016 was used. In the case of multitemporal classifications the following Sentinel-2 images for the year 2016 were used: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. and 3.9.2016. Processing time includes the sum of training time and classification time.

154

Table 61: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on RapidEye imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 29.7.2013 was used. In the case of multitemporal classifications the following RapidEye images for the year 2013 were used: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. and 26.10. 2013. Processing time includes the sum of training time and classification time.

155

Table 62: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on SPOT5 Take5 imagery of Pomurje study area. All classifications used attribute of median RGNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 1.8.2015 was used. In the case of multitemporal classifications the following SPOT5 Take5 images for the year 2015 were used: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. and 10.9.2015. Processing time includes the sum of training time and classification time.

156

Table 63: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on Sentinel-2 imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, Sentinel-2 image 6.8.2016 was used. In the case of multitemporal classifications the following Sentinel-2 images for the year 2016 were used: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. and 3.9.2016. Processing time includes the sum of training time and classification time.

157

LIST OF FIGURES

Figure 1: Process of object-based classification: preprocessing of remotely sensed image (a), segmentation (b) and classification (vector land cover layer) (c)	7
Figure 2: Examples of basic mapping unit: PIXEL (a), SEGMENT (b) and GERK (c)	8
Figure 3: RGB colour presentations of three examples of input images. The following RapidEye images are used as red, green and blue colour: image of red, green and blue channel of satellite image 29.7.2013 (a); image of red and green channel and ndvi image of satellite image 29.7.2013 (b); ndvi image of satellite image 18.5.2013, ndvi image of satellite image 29.7.2013 and ndvi image of satellite image 14.9.2013 (c).	9
Figure 4: Photos of different phenological phases of larch forest Fujihokuroku. Source: Center for Global Environmental Research, National Institute for Environmental Studies, Japan (after Simonetti et al., 2014).	10
Figure 5: Monthly RapidEye satellite images of Stara Nova vas municipality	11
Figure 6: Satellite image captured in July (a); in September (b); graph of mean NDVI values of selected fields over time (c)	11
Figure 7: Graph of time variation of mean values of NDVI index of selected crops	12
Figure 8: Images of different dates (D1 to D4) with four channels (left) and image with merged channels of all four individual satellite images (right)	13
Figure 9: Standard phenological development of a vegetation ground cover class when observed in the form of NDVI (Aurdal et al., 2005)	14
Figure 10: Error types: true positive (TP), true negative (TN), false positive (FP) and false negative (FN)	19
Figure 11: Class reference object (CRO): union of all reference objects of specific class; class segment union (CSU): union of all segments, which are more than 50 % covered with CRO; true positive pixels (TP); false negative pixels (FN); false positive pixels (FP) and segment borders (S).	23
Figure 12: The result of segmentation on the following images: SPOT 5 (a), RapidEye (b), World-View-2 (c) and orthophoto (d). Blue line represents the selected reference polygon of forest. Bolded yellow line represents unions of segments of selected polygon of forest. Vector segmentation layer is represented in a light yellow colour.	24
Figure 13: The result of classification of segments, obtained with the same parameters on the following images: SPOT 5 (a), RapidEye (b), World-View-2 (c) and orthophoto (d). Blue line represents the selected reference polygon of forest. Red line represents unions of segments of selected polygon of forest. Segments, classified as forest, are merged and coloured in green. Segments, not classified as forest, are merged and coloured light gray.	25
Figure 14: Displaying segmentation parameter labels on graphs of the thesis. In the top row, the scale parameters are listed, in the lower row, the merge parameters are listed.	26
Figure 15: Study area Pomurje (full red line) and study area Murska Sobota (hatched red line)	29
Figure 16: Previews of RapidEye satellite imagery for Pomurje study area	31
Figure 17: Previews of SPOT5 Take5 satellite imagery for Pomurje study area. Channels GREEN, RED, NIR	32
Figure 18: Previews of Sentinel-2 imagery of Pomurje study area	34
Figure 19: Layer RABA and its legend on Murska Sobota study area	37

Figure 20: Layer GERK with its legend on Murska Sobota study area	38
Figure 21: Layer PANVITA with its legend on Murska Sobota study area	39
Figure 22: Calendar of events of six major Panvita crops for year 2013	39
Figure 23: Reference layers of basic land cover classes for years 2013 (a), 2015 (b) and 2016 (c). Murska Sobota study area.	41
Figure 24: Reference layers of basic crop type classes for years 2013 (a), 2015 (b) and 2016 (c). Murska Sobota study area.	43
Figure 25: Examples of segmentation of RapidEye image, obtained by similar settings and different software: eCognition (a), ENVI FX (b), InterIMAGE (c) and OrfeoToolbox (d).	50
Figure 26: Relief of the gradient magnitude (a), Gradient magnitude image (b), Watershed of the gradient (c) and Watershed of the gradient (relief) (d) (Cousty, 2007)	53
Figure 27: Area shown in near infrared channel (a), area shown in near infrared channel, processed with morphological closing with a 5 x 5 pixel window (b); segmentation of image (a) with parameters scale 30 and merge 70 (c); segmentation of image (b) with parameters scale 30 and merge 70.	56
Figure 28: Area shown in red channel R (a), area shown in near infrared channel Nir (b); area shown with an RGB combination of channel RnirR (c); segmentation of image (a) with parameters scale 30 and merge 70 (d); segmentation of image (b) with parameters scale 30 and merge 70 (e) ; segmentation of image (c) with parameters scale 30 and merge 70 (f).	57
Figure 29: Segmentation of spectral channels R, G, B and NIR with merge level 50 and scale levels 00 (a), 30 (b) and 50 (c)	59
Figure 30: Segmentation of spectral channels R, G, B and NIR with scale level 00 and merge levels 00 (a), 30 (b) and 60 (c). Merging was performed by Full Lambda Schedule and spectral channels R, G, B and NIR.	59
Figure 31: Reference layer (a) and final classification image of basic land cover classes, obtained by classifier k-Nearest Neighbour, input images R, G, B and NIR and segmentation parameters scale_merge = 00_00 (b), 30_50 (c) in 50_50 (d).	61
Figure 32: Results of overall classification accuracy of all basic land cover classes. X axis represents segmentation parameters. Upper row represents scale parameter (from 00 to 90), lower row represents merge parameter (from 00 to 90). Y axis represents the value of classification evaluation.	62
Figure 33: Vegetation indices: Normalized difference Vegetation Index (NDVI) (a), Anthocyanin Reflectance Index 1 (ARI-1) (b) and Transformed Chlorophyll Absorption Reflectance Index (TCARI) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	67
Figure 34: Colour transformations: intensity of image NirGB (NIR_GREEN_BLUE_VAL) (a), saturation of image NirRdgR (NIR_REDEGE_RED_SAT) (b) and hue of image RGB (RED_GREEN_BLUE_HUE) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	67
Figure 35: Principal component analysis of original RapidEye image channels: second component (ICA-FORWARD-2) (a), fourth component (ICA-FORWARD-4) (b) and fifth component (ICA-FORWARD-5) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	68

Figure 36: Tasseled cup method: brightness (BRIGHTNESS) (a), greenness (GREENNESS) (b) and yellowness (YELLOWNESS) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	68
Figure 37: Images of co-occurrence matrix, obtained by 3 x 3 moving window on the red channel image: mean (a), variance (b), contrast (c), homogeneity (d), dissimilarity (e) and entropy (f). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	70
Figure 38: Images of convolution filters: directional filter of angle 0° (a); directional filter of angle 135° (b) and high pass filter of red channel (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.	70
Figure 39: Similarity of images of indices NDVI (a) and TDVI (b)	72
Figure 40: Similarity of images of indices ARI-1 (a) and CVI (b)	73
Figure 41: Examples of images with a lot of noise: CCCI (a), NDVI_GREEN_BLUE_HUE (b), PSRI_NIR_REDEGE_HUE (c) and SR_GREEN_BLUE_HUE (d)	73
Figure 42: Examples of images of attributes, selected on the basis of visual comparison: ARI-1 (a), BAI (b), BLUE (c), CHLREDEGE (d), GREEN (e), NDVI (f), NDVI-GREEN (g), NIR (h), PSRI-NIR (i), RED (j) and REDEGE (k)	74
Figure 43: Variability of some calculated correlations in relation to NDVI through the whole growing season	76
Figure 44: Heatmap of correlations of attribute NDVI with all other attributes for basic land cover classes. Entire names of attributes are written in Table 10.	78
Figure 45: Heatmap of all correlations and all attributes for basic land cover classes: arable land (a), grass (b), forest (c), build-up (d) and water (e). Attributes are shown in the same order as on image 44 (starting with SUMBANDS from left to right and from bottom to top).	79
Figure 46: Heatmap of correlations of attribute NDVI with all other attributes for basic crops. Entire names of attributes are written in Table 10.	82
Figure 47: Heatmap of all correlations and all attributes for basic crops: maize (a), wheat (b), barley (c), oil pumpkin (d), rapeseed (e) and triticale (f). Attributes are shown in the same order as on image 44 (starting with SUMBANDS from left to right and from bottom to top).	83
Figure 48: Time of selecting significant attributes with ReliefF algorithm, training time, classification time, total time without selecting attributes with ReliefF algorithm and total time with selecting attributes with ReliefF algorithm at specific number of attributes and at GERK mapping unit.	102
Figure 49: Examples of different mapping units: PIXEL (a), 3 x 3 GRID (b), SEGMENT (c) and GERK (d). Background is true colour RapidEye image.	111
Figure 50: Reference layer of five basic land cover classes with a classification mask (areas under mask are not classified). Murska Sobota study area.	117
Figure 51: Classification result of mapping unit pixel (a) and mapping unit GERK (b). Murska Sobota study area.	117
Figure 52: Classification result of mapping unit 3 x 3 GRID (a) and mapping unit segment 20_40 (b). Murska Sobota study area.	118
Figure 53: Classification result of mapping unit SEGMENT 30_70 (a) and mapping unit SEGMENT 40_90 (b). Murska Sobota study area.	119

Figure 54: Classification result of mapping unit SEGMENT 50_90 (a) and mapping unit SEGMENT 60_90 (b). Murska Sobota study area.	119
Figure 55: Mapping unit GERK (a), mapping unit SEGMENT 20_40 (b), mapping unit SEGMENT 30_70 (c) and mapping unit SEGMENT 40_90 (d) on RapidEye image 29.7.2013. A section of Murska Sobota study area.	120
Figure 56: Mapping unit GERK (a), mapping unit SEGMENT 20_40 (b), mapping unit SEGMENT 30_70 (c) and mapping unit SEGMENT 40_90 (d) on reference layer for year 2013. A section of Murska Sobota study area.	121
Figure 57: Mapping unit PIKSEL (a), mapping unit GERK (b), mapping unit SEGMENT 20_40 (c) and SEGMENT 30_70 (d) on reference layer. A section of Murska Sobota study area.	124
Figure 58: Classification results, obtained with mapping units PIKSEL (a), GERK (b), SEGMENT 20_40 (c) and SEGMENT 30_70 (d). A section of Murska Sobota study area.	125
Figure 59: The result of quasi-multitemporal classification of basic land cover classes with mapping unit PIXEL (a), GERK (b), SEGMENT 20_40 (c) and SEGMENT 30_70 (d). Murska Sobota study area.	127
Figure 60: The result of quasi-multitemporal classification of basic crop type classes with mapping unit PIXEL (a), GERK (b), SEGMENT 10_20 (c) and SEGMENT 20_40 (d). Murska Sobota study area.	129
Figure 61: Output images of edge detection methods: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Edges were obtained on spectral bands R, G, B and NIR of input image RapidEye 29.7.2013. Murska Sobota study area.	132
Figure 62: Segmentations, obtained with intensity method on gradient images, shown in Figure 61: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). All segmentations were performed with the same parameters: scale level 30 on gradient image, merge level 70 on channels R, G, B and Nir. Figure shows small part of Murska sobota study area.	133
Figure 63: Gradient image, obtained by Sobel edge detection method on RapidEye image 29.7.2013 (transparent gray raster) and segments, as result of watershed algorithm at parameters 30_70 (blue lines). Part of Murska Sobota study area.	135
Figure 64: GERK mapping unit, in a form as input to classification process (a), and mapping unit SEGMENT 30_70, obtained with Sobel edge detection method (b). Both mapping units are shown on tru colour RapidEye umege 29.7.2013. Part of Murska Sobota study area.	136
Figure 65: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of mapping unit GERK (a) and of mapping unit SEGMENT, obtained on RapidEye bands RGBNir (b). All classification information can be seen in Table 55.	139
Figure 66: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of segments, obtained by morphology filters of RapidEye bands RGBNir: opening (a) and closing (b). All classification information can be seen in Table 55.	139
Figure 67: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of segments, obtained byco-occurence filters of RapidEye bands RGBNir: mean (a), variance (b), homogeneity (c) and entropy (d). All classification information can be seen in Table 55.	140

Figure 68: Part of forest segmentation layer, obtained on the basis of input layers R and G with parameters 30_80	141
Figure 69: Part of forest classification as the first class of multilevel classification	142
Figure 70: Part of build-up class segmentation, obtained on the basis of NDVI input image and parameters 40_80. The forest area, classified in the previous step, is masked out, therefore segmentation in this area is not performed.	142
Figure 71: Result of multilevel classification of basic land cover classes after first phase (each class was classified only once). The whole area in white colour remained unclassified and must be once again used in the classification procedure.	143
Figure 72: Unmasked NDVI input image of RapidEye image 15.6.2013 (a) and unmasked NDVI input image of RapidEye image 19.5.2013 (b). Small study area.	145
Figure 73: Masked NDVI input image of RapidEye image 15.6.2013 (a) and masked NDVI input image of RapidEye image 19.5.2013 (b). Small study area.	146
Figure 74: Segmentation of combined unmasked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (a) and segmentation of combined masked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (b). Small study area. Segmentation vector layers are shown on false colour image of two combined unmasked RapidEye input images.	146
Figure 75: Segmentation of combined unmasked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (a) and segmentation of combined masked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (b). Small study area. Segmentation vector layers are shown on masked NDVI input image of RapidEye image 15.6.2013.	147
Figure 76: Segmentation of RGBNir bands of RapidEye images captured on 19.5.2013 (a), 15.6.2013 (b) and 8.10.2013 (c) on corresponding true colour images.	148
Figure 77: Segmentations obtained by multitemporal segmentation on spectral bands RGBNir and combinations of RapidEye images of dates: 19.5.2013 and 29.7.2013 (a); 19.5.2013, 15.6.2013, 29.7.2013 and 8.10.2013 (b); 9.4.2013, 19.5.2013, 15.6.2013, 29.7.2013, 18.8.2013 and 8.10.2013 (c). Segmentations are shown on true colour RapidEye images 29.7.2013.	148

»Ta stran je namenoma prazna.«

OKRAJŠAVE IN SIMBOLI

ANN	Artificial Neural Network (umetna nevronska mreža)
ARI-1	Anthocyanin Reflectance Index 1 (prvi indeks odbojnosti antocianinov)
ARSKTRP	Agencija Republike Slovenije za kmetijske trge in razvoj podeželja
ARSO	Agencija Republike Slovenije za okolje
BAI	Burn Area Index (indeks pogorelosti območja)
BLUE	spektralni kanal modre svetlobe
CONTR	contrast (kontrast)
CQR	classification quality rate (stopnja kakovosti klasifikacije)
DISS	dissimilarity (različnost)
DN	Digital Number (digitalna vrednost)
dtwSat	Time-Weighted Dynamic Time Warping for Satellite Image Time Series Analysis
ENERG	energy (energija)
ENTRO	entropy (entropija)
ENVI	ENvironment for Visualizing Images (programska oprema)
ENVI FX	ENVI Feature Extraction (algoritem za segmentacijo)
ESA	European Space Agency (Evropska vesoljska agencija)
GERK	grafična enota rabe kmetijskega gospodarstva
GIS	geografski informacijski sistem (geographic information system)
GREEN	spektralni kanal zelene svetlobe
HOMO	homogeneity (homogenost)
HSI	Hue Saturation Intensity (barvni prostor barve, nasičenosti in intenzitete)
IR	InfraRed (infrardeča svetloba)
KMRS	vrsta kmetijske rastline
kNN	k-Nearest neighbour (k-najbližji sosed)
MEAN	mean (povprečje)
MED	median (mediana)
MKGP	Ministrstvo za kmetijstvo, gozdarstvo in prehrano
MODIS	MODerate resolution Imaging Spectroradiometer (senzor)
NDVI	Normalized Difference Vegetation Index (normiran diferencialni vegetacijski indeks)
NDVI-GREEN	Green band multiplied by NDVI (interno določen vegetacijski indeks)
NIR	Near InfraRed (spektralni kanal bližnje-infrardeče svetlobe)
OA	Overall Accuracy (skupna natančnost)

PA	Producers Accuracy (izdelovalčeva natančnost)
PANVITA	sloj s kmetijskimi podatki podjetja Panvita
PCA	Principal Component Analysis (analiza osnovnih komponent)
PSRI	Plant Senescence Reflectance Index (indeks odbojnosti staranja rastlin)
PSRI-NIR	Plant Senescence Reflectance Index with NIR band (variacija indeksa PSRI)
R	odprtokodni programski jezik za statistične izračune in grafiko
RABA	enota dejanske rabe kmetijskih in gozdnih zemljišč
RED	spektralni kanal rdeče svetlobe
REDEDGE	spektralni kanal robno-rdeče svetlobe
ReliefF	algoritem za izbiro značilnih atributov
RGB	Red Green Blue (barvni prostor rdeča, zelena in modra)
Rtree	Random Tree classifier (metoda naključnega drevesa)
SPOT	Satellite Pour l'Observation de la Terre (satelit)
SQR	segmentation quality rate (stopnja kakovosti segmentacije)
STDEV	standard deviation (standardni odklon)
SVM	Support Vector Machine (metoda podpornih vektorjev)
TOA	Top Of the Atmosphere (odbojnost na vrhu atmosfere)
TWDTW	Time-Weighted Dynamic Time Warping (algoritem za časovne analize)
UA	Users Accuracy (uporabnikova natančnost)
VAR	variance (varianca)
VESOLJE-SI	Center odličnosti Vesolje, znanost in tehnologije
WEKA	Waikato Environment for Knowledge Analysis (programska oprema)
ZRC SAZU	Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti

SLOVAR MANJ ZNANIH BESED IN TUJK

Algoritem razvodij – angl. **watershed algorithm** je algoritem za segmentacijo, ki temelji na konceptu hidroloških razvodij.

Barvni prostor HSI – angl. **HSI colour space** je koordinatni sistem, ki barvne odtenke podaja z intenziteto, barvo in nasičenostjo (Oštir, 2016).

Barvni prostor RGB – angl. **RGB colour space** je koordinatni sistem, ki barvne odtenke podaja z osnovnimi barvami, to je rdečo, zeleno in modro (red, green, blue) (Oštir, 2016).

Časovna ločljivost – angl. **temporal resolution** pove, kako pogosto lahko snemamo iste dele Zemlje oziroma koliko časa preteče med dvema zaporednima snemanjema (Oštir, 2016).

Časovna vrsta satelitskih posnetkov – angl. **satellite image time series** je niz istoležečih posnetkov, posnetih ob zaporednih časih.

Dejanska raba kmetijskih in gozdnih zemljišč – angl. **actual agricultural and forestal land use** je javni vektorski sloj, ki ga vodi Ministrstvo za kmetijstvo, gozdarstvo in prehrano. Dejanska raba je bila vzpostavljena na osnovi interpretacije letalskih posnetkov za namene ugotavljanja izpolnjevanja pogojev za ukrepe kmetijske politike. Gre za tipološko delitev vrst rabe glede na stanje dejanske rabe ob zajemu in poleg podrobnejših vrst kmetijske rabe ločuje kategorije rabe, kot so pozidana in sorodna zemljišča, gozdovi, vode ipd. (Pravilnik o evidenci dejanske rabe kmetijskih in gozdnih zemljišč, 2008).

Enočasovna klasifikacija – angl. **single-date classification** je klasifikacija posnetka enega datuma.

F-mera – angl. **F-measure or F-score** je uteženo povprečje izdelovalčeve in uporabnikove natančnosti.

Georeferenciranje – angl. **georeferencing**, tudi geokodiranje ali georegistracija je postopek izvajanja geometrijskih popravkov in vpenjanja daljinsko zaznanih podob v koordinatni sistem. Način določanja prostorskih koordinat objektov in pojavov v prostoru, ki predstavlja obstoj ustreznega koordinatnega sistema.

Grafična enota rabe kmetijskega gospodarstva – angl. **graphic unit of the agriculture holdings** je strnjena površina kmetijskega zemljišča z enako dejansko rabo in enako vrsto kmetijske rastline, ki je v uporabi enega kmetijskega gospodarstva.

Intenziteta – angl. **intensity** je količina, ki v barvnem sistemu HSI podaja svetlost (Oštir, 2016).

Interpolacija – angl. **interpolation** je približna vrednost funkcije znotraj obsega znanih nepovezanih vrednosti neodvisne spremenljivke.

Izdelovalčeva natančnost – angl. producers accuracy, recall je delež pravilno klasificiranih pikslov razreda glede na število vseh referenčnih pikslov razreda.

Kanal – angl. band, tudi pas, je območje valovnih dolžin v elektromagnetnem spektru, ki ga opazuje posamezni detektor. Sodobni senzorji daljinskega zaznavanja praviloma snemajo v več kanalih in ustvarjajo večspektralne podobe (Oštir, 2016).

Klasifikacija – angl. classification je eden najpomembnejših korakov pri obdelavi daljinsko zaznanih podob, ki predstavlja povezavo med daljinskim zaznavanjem in geografskimi informacijskimi sistemi. S klasifikacijo iz rastrske podobe dobimo kvantitativen sloj, ki ga lahko uporabimo v analizah. Pri klasifikaciji gre za prepoznavanje predmetov na zemeljski površini na osnovi njihovih – praviloma spektralnih – lastnosti (Oštir, 2016).

Klasifikacija na osnovi časovnih vrst – angl. time series based classification je klasifikacija, osnovana na analizi časovnih vrst oz. primerjavi grafov časovnega razvoja določenih spektralnih karakteristik različnih tipov pokrovnosti (Aurdal et al., 2005).

Kvazi veččasovna klasifikacija – angl. quasy-multitemporal classification je navadna enočasovna klasifikacija, kjer kot vhodni podatek uporabimo podobe različnih časov.

Lažno barvna podoba – angl. false colour image je barvna podoba oziroma prikaz, pri katerem so nevidni deli elektromagnetnega spektra podani z eno ali več osnovnih barv (modro, zeleno ali rdečo). Tako dobimo posnetek, ki ne odseva stanja v naravi. Pogosta kombinacija prikazuje bližnjo infrardečo svetlobo v rdeči, rdečo v zeleni in zeleno v modri barvi (Oštir, 2016).

Ločljivost – angl. resolution je sposobnost sistema za ločevanje pojavov ali lastnosti. V daljinskem zaznavanju poznamo prostorsko, radiometrično, spektralno in časovno ločljivost (Oštir, 2016).

Matrika napak – angl. error matrix, confusion matrix, confusion table, contingency matrix je tabela, ki primerja rezultat klasifikacije z referenčnim/kontrolnim podatkom in za vsak razred podaja vrsto in število pravilno oz. napačno klasificiranih pikslov (Oštir, 2016).

Multispektralni satelitski posnetek – angl. multispectral satellite image, tudi večspektralni satelitski posnetek, je posnetek, kjer senzorji na satelitih zaznavajo več različnih, med seboj ločenih delov spektra svetlobe.

Nadzorovana klasifikacija – angl. supervised classification je oblika klasifikacije posnetkov, pri kateri operater določi učne vzorce, program (algoritem) pa ustvari njihove spektralne podpise. Piksle na podobi nato z uporabo različnih tehnik razdeli glede na podane vzorce, pri čemer lahko nekateri piksli ostanejo neklasificirani (Oštir, 2016).

Nenadzorovana klasifikacija – angl. unsupervised classification je oblika klasifikacije, pri kateri piksele razporedimo v razrede glede na njihovo »naravno« zduževanje v spektralnem prostoru. Pri nenadzorovani klasifikaciji v prvem koraku ne potrebujemo informacij o opazovanem površju, v drugem koraku pa moramo razrede prepoznati (Oštir, 2016).

Normiran diferencialni vegetacijski indeks – angl. normalized difference vegetation index je razmerje razlike med odbojem v infrardečem in rdečem delu spektra in njuno vsoto. Določa stanje vegetacije (Oštir, 2016).

Objektno usmerjena klasifikacija – angl. object-based classification je klasifikacija, kjer vhodno podobo najprej segmentiramo (razdelimo na homogene skupine pikslov, segmente) nato pa dobljene segmente razvrstimo v razrede na podlagi njihovih spektralnih, geometričnih, teksturnih in drugih lastnosti (Blaschke, 2010).

Oblika – angl. shape je zgradba oziroma oris posameznih predmetov. Pogosto je najpomembnejši element interpertacije podob (Oštir, 2016).

Optični satelitski posnetek – angl. optical satellite image je posnetek, posnet z optičnim senzorjem satelita. Optični ali pasivni senzori daljinskega zaznavanja zapisujejo v naravi obstoječo elektromagnetno energijo. To je energija, ki iz Sonca pride na Zemljo, se deloma odbije, deloma absorbira in nato znova izseva od površja skozi atmosfero. Za odbito Sončevo svetlobo to pomeni, da lahko snemamo samo podnevi, pogoj za lastno termično infrardeče sevanje pa je, da je sevanja dovolj za zaznavo z merilnimi instrumenti (Oštir, 2016).

Optimalna segmentacija – angl. optimal–segmentation je segmentacija, kjer zunanja meja unije segmentov istega objekta ustreza meji objekta in vsebuje samo enega ali zgolj nekaj segmentov.

Ortorektifikacija – angl. ortorectification je postopek, v katerem iz surovega posnetka na podlagi rezultatov triangulacije (orientacije) in digitalnega modela reliefa pridobimo ortorektificiran posnetek, prost položajnih geometričnih deformacij, ki na izvornem posnetku nastanejo kot posledica vpliva razgibanosti površja. Z izvedbo ortorektifikacije pridobimo zanesljivo položajno natančnost vseh slikovnih elementov na celotnem ortorektificiranem posnetku (Dežman Kete et al., 2008).

Osnovna enota kartiranja– angl. basic mapping unit je element klasifikacije z določeno obliko in velikostjo.

Podoba – angl. image je digitalna predstavitev podatkov daljinskega zaznavanja v obliki matrike slikovnih elementov oziroma pikslov. Podoba lahko predstavlja odbojnost ali lastno sevanje površja in je, odvisno od števila kanalov, eno ali večrazsežna. Izraz poleg tega zajema tudi vse rezultate obdelav, od predobdelave prek izboljšanja in transformacij do klasifikacije, modeliranja in

simulacij. V najožjem pomenu je podoba vsaka slika v rastrski obliki. Pojem je širši od posnetka, ki je predstavitev resničnosti, kot jo je zajel senzor (Oštir, 2016).

Podoba gradienta – angl. gradient image je podoba, ki vsebuje značilne robove (Harris Geospatial Solutions, 2016), velikost sprememb barvne intenzitete med sosednjimi piksli.

Pokrovnost – angl. land cover je konkretna stvarnost, ki pokriva površje Zemlje, in jo lahko neposredno opazujemo, na primer gozd, travnik... (Oštir, 2016).

Poudarjanje robov – angl. edge enhancement je postopek obdelave podob, ki poudari robove in linije na podobi (Oštir, 2016).

Predobdelava – angl. preprocessing so postopki, s katerimi iz daljinsko zaznanih podob odstranimo nepravilnosti, npr. radiometrične in geometrijske, jih vpnemo v izbrani koordinatni sistem in pripravimo za analize (Oštir, 2016).

Prekomerna segmentacija – angl. over-segmentation je segmentacija, kjer zunanja meja unije segmentov istega objekta sicer ustreza meji objekta, a je število segmentov znotraj objekta veliko.

Prešibka segmentacija – angl. under-segmentation je segmentacija, kjer segment obsega območje dveh ali več geografskih objektov, pripadajočim različnim objektnim razredom. Takšnih območij (segmentov) v fazi klasifikacije ne moremo več razdeliti.

Prostorska ločljivost – angl. spatial resolution je razdalja, pri kateri sosednja predmeta na podobi še lahko ločimo med seboj. Prostorska ločljivost predstavlja velikost najmanjšega predmeta, ki ga na podobi zaznamo (Oštir, 2016).

Raba tal – angl. land use je namen, za katerega ljudje izkoriščajo neko zemljišče, s poudarkom na njegovi funkcijski vlogi v ekonomskih aktivnostih, na primer industrija, rekreativne površine idr. Je abstraktna in je včasih ne moremo objektivno določiti niti s podrobnim ogledom (Oštir, 2016).

Redundanca – angl. redundancy, tudi presežek, je informacija na podobi, ki je bodisi ne potrebujemo za interpretacijo ali pa je ne vidimo. Presežek pri podobah daljinskega zaznavanja je lahko prostorski, spektralni ali časovni. Pri spektralnem presežku na večspektralnih podobah zaradi velike korelacije sosednji kanali ne vsebujejo različnih informacij in zato le otežujejo interpretacijo (Oštir, 2016).

Referenčni podatki – angl. reference data or ground-truth data so »resnični talni podatki«, ki nudijo informacijo o tem kaj je resnično na določeni lokaciji (geolocirani točki ali poligonu).

Rob – angl. edge je hitra sprememba sivih vrednosti, ki je praviloma povezana z antropogenimi dejavniki, na primer cestami, mejami med zemljišči, posekami... (Oštir, 2016).

Segmentacija – angl. segmentation je postopek delitve podobe na homogena območja (množice sosednjih pikslov). Segmentacija je praviloma prvi korak objektno usmerjene klasifikacije (Oštir, 2016).

Skoraj realni čas – angl. near-real-time je krajši časovni zamik, ki nastane pri samodejni obdelavi podatkov med zajemom izvirnega podatka in dostavo izdelanega produkta.

Skupna natančnost – angl. overall accuracy je delež vsote pravilno klasificiranih pikslov vseh razredov glede na število vseh testnih pikslov.

Spektralna ločljivost – angl. spectral resolution, tudi valovna ločljivost, je natančnost sistema pri opazovanju elektromagnetnega valovanja različnih valovnih dolžin. Spektralna ločljivost je boljša, če sistem predmete opazuje v več ozkih kanalih (večspektralno ali celo hiperspektralno) (Oštir, 2016).

Tekstura – angl. texture je značilna razporeditev in frekvenčno spreminjanje tona na posameznih območjih podobe. Tekstura je eden najpomembnejših elementov za prepoznavanje predmetov na podobah (Oštir, 2016).

Učni vzorec – angl. training sample, tudi učno območje, je območje na površju s poznanimi lastnostmi. Učna območja uporabljamo pri nadzorovani klasifikaciji podob, zato da določimo spektralne lastnosti opazovanih predmetov (Oštir, 2016).

Uporabnikova natančnost – angl. users accuracy, also reliability or precision je delež pravilno klasificiranih pikslov razreda glede na število vseh pikslov, klasificiranih v določen razred.

Varianca – angl. variance je merilo za razpršenost vrednosti, ki je določeno kot povprečna vrednost kvadratov odklonov spremenljivk od aritmetične sredine (Oštir, 2016).

Veččasovna klasifikacija – angl. multitemporal classification je klasifikacija, kjer uporabimo satelitske posnetke več datumov. Pri tem imamo poleg spektralnih informacij o objektu na površju na voljo tudi informacijo o časovnem spreminjanju spektra tega objekta.

Veččasovna segmentacija – angl. multitemporal segmentation je segmentacija, pri kateri kot vhodni podatek uporabimo posnetke različnih časov.

Večivojska klasifikacija – angl. multi level classification je klasifikacija, ki jo izvajamo po nivojih, za vsak razred posebej. Tudi hierarhična segmentacija.

Večrazredna klasifikacija – angl. multiclass classification je klasifikacija, kjer hkrati klasificiramo več razredov.

Vegetacijski indeks – angl. vegetation index je indeks, ki opredeljuje stanje vegetacije. Podan je kot razmerje med odbojem v infrardečem in rdečem delu elektromagnetnega spektra. Vegetacija

(oziroma klorofil v njej) zelo močno odbija infrardečo svetlobo, rdečo pa slabo. Vegetacijski indeks za vegetacijo je torej zelo visok, medtem ko je za nevegetacijo ali poškodovano vegetacijo nizek (Oštir, 2016).

Vhodna podoba – angl. input image je podoba, ki je vhodni podatek v določen postopek obdelave, npr. v postopek segmentacije ali klasifikacije. Ima splošne lastnosti podobe in je kot takšna lahko eno-kanalna ali več-kanalna, sestavljena iz osnovnih spektralnih kanalov ali raznih izpeljank, kot so npr. vegetacijski indeksi.

1 UVOD

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 različnih prikazih in vizualnih analizah, dobimo kvantitativni sloj, ki ga kasneje lahko uporabimo v analizah s sistemi GIS. Kljub temu da je prikladno opazovati posnetke iz vesolja ali zraka, pa so vendarle šele tematske karte tiste, ki dajo podobam pomen (Oštir, 2006).

Najpogosteje izdelane tematske karte, osnovane na optičnih satelitskih posnetkih, so karte pokrovnosti. Razlog je velik pomen teh kart za številne znanosti o zemeljskem površju, saj omogočajo temeljni vpogled v stanje okolja. Karte pokrovnosti so bile prepoznane kot ključna podnebna spremenljivka (Mason et al., 2003), so najpomembnejši element za opis in študijo okolja (Herold et al., 2006) in ključni vhodni podatek modelom ekosistemskih storitev (Andrew et al., 2014). Kartiranje pokrovnosti je nujno za načrtovanje in kartiranje naravnih virov, modeliranje okoljskih spremenljivk in za razumevanje razporeditve habitatov (Gomez et al., 2016). Identifikacija vrst pokrovnosti omogoča osnovne informacije za izdelavo drugih tematskih kart in vzpostavlja osnovo za dejavnosti spremljanja (Gomez et al., 2016). Karte pokrovnosti so tudi osnova za spremljanje, upravljanje in načrtovanje kmetijstva, spremljanje okoljskih sprememb, opazovanje suše v kmetijstvu, urbanistično planiranje in modeliranje poplav. Karte pokrovnosti imajo velik pomen za številne znanosti o zemeljskem površju.

Več avtorjev, npr. Townshend et al. (1991), je že pred več desetletji v svojih študijah pokazalo velik potencial satelitskega daljinskega zaznavanja za izdelavo kart pokrovnosti. Z leti so se metodologije še izboljševale, na voljo je tudi več posnetkov s še boljšimi lastnostmi. Satelitski posnetki so dokazan vir za pregledno, pravočasno in dosledno informacijo o pokrovnosti površja na svetovni in regionalni ravni. S tem omogočajo temeljni vpogled v stanje okolja in kot take so ključni podatek za uporabnike, ki potrebujejo ažurne in večkrat posodobljene informacije o površju. Daljinsko zaznavanje in digitalna obdelava podob omogočata opazovanje, identifikacijo, kartiranje, ocenjevanje in spremljanje pokrovnosti v različnem prostorskem, časovnem in tematskem obsegu (Rogan in Chen, 2004).

V svetu, v zadnjem času pa tudi v Sloveniji, se vse bolj množično uporabljajo satelitski posnetki, ki omogočajo pogostejše (tudi vsesezonsko) pridobivanje podatkov na večjih območjih. Govorimo o t. i. časovni vrsti satelitskih posnetkov (angl. satellite image time series). To je niz istoležečih posnetkov, posnetih ob različnih časih. Z analizo časovne vrste posnetkov lahko spremljamo spektralne ali izpeljane vrednosti celotnega posnetka oz. posamezne osnovne enote kartiranja skozi čas. Gostejši kot je niz, več informacij dobimo.

Prve časovne vrste za globalne produkte so leta 1972 začeli nuditi sateliti Landsat-1 (Belward in Skoien, 2015). Kmalu za tem so se pridružili drugi sateliti, kot so AVHRR, SPOT VEGETATION, MODIS in

MERIS. Goste časovne vrste optičnih satelitskih posnetkov so bile dolgo v domeni senzorjev z nizko prostorsko ločljivostjo (npr. 1 km). Takšni sistemi so dosegli pokrovnost celotne Zemlje na skoraj dnevni bazi (Hostert et al., 2015).

Zadnje čase je bil narejen velik napredek pri uporabi satelitskih posnetkov, ki omogočajo analize pokrovnosti tudi na regionalnih merilih, recimo Landsat TM, Landsat ETM+ in OLI. V splošnem je dostopnost do optičnih satelitskih posnetkov izredno narasla. To je bilo doseženo s številnimi novimi senzorji v vesolju, vendar se je velika sprememba zgodila predvsem zaradi politike odprtega dostopa do podatkov. Medtem ko so bili nizko prostorsko ločljivi posnetki prosto in brezplačno dostopni že v osnovi, za visoko ločljive posnetke to ni veljalo. V letu 2004 je bila Brazilska vesoljska agencija INPE prva, ki je omogočila brezplačen in prost dostop do srednje prostorsko ločljivih satelitskih posnetkov Landsat.

Danes je na voljo že veliko število časovnih vrst satelitskih posnetkov srednje, visoke ali celo zelo visoke prostorske ločljivosti: SPOT, IKONOS, Proba, IRS, SCISAT, DMC, ERS, METOP, Landsat, Sentinel, GeoEye, Pleiades, Quickbird, WorldView in mnoge druge. Kategorizacija posnetkov glede na prostorsko ločljivost je dinamična in se spreminja glede na leto obdelave (senzorji z leti napredujejo; pred tridesetimi leti je npr. velikost piksla 60 m pomenila visoko prostorsko ločljivost), glede na območje obdelave (npr. ločljivost 60 m je še danes zelo visoka ločljivost, če opazujemo območje celotne Zemlje) in glede na uporabnika, vsebino analize ter način obdelave podatkov. Zato v literaturi zasledimo različne razdelitve posnetkov glede na njihovo prostorsko ločljivost.

Ciljni posnetki te disertacije so posnetki dveh satelitov Sentinel-2, saj njuna izstrelitev predstavlja še posebej revolucionaren premik v smislu količine in kakovosti časovnih vrst posnetkov, ki so brezplačno dostopni. Prostorska ločljivost teh posnetkov je 10 m, kar glede na različne vire spada med bodisi srednje ločljive posnetke (Navulur, 2007) bodisi med visoko ločljive posnetke (Lefebvre et al., 2016; ESA, 2016). Ker jih Evropska vesoljska agencija in posledično v praksi zelo razširjen program Copernicus propagirata kot visoko prostorsko ločljive posnetke, jih kot takšne opredeljujem tudi sama v tej disertaciji.

Medtem ko so se prve študije osredotočale na meteorologijo in spremljanje globalnih ekosistemov, so študije zadnjih let precej bolj kompleksne in podrobne. V ospredje najbolj prihaja dinamika kmetijskih sistemov, kjer je časovna komponenta še posebej dobrodošla in aktualna. Podatki o fenoloških spremembah znotraj enega cikla rasti vegetacije se po prvih testiranjih kažejo kot pomembna dodana informacija h klasifikaciji.

Tudi v Sloveniji obstaja veliko zanimanje in močna potreba po samodejni klasifikaciji osnovnih razredov pokrovnosti in poljščin. To je bilo pokazano s strani Ministrstva za kmetijstvo in okolje (MKO), Agencije Republike Slovenije za okolje (ARSO) in Agencije za kmetijske trge in razvoj podeželja (ARSKTRP).

Tematiko prav tako močno podpira Evropska vesoljska agencija (ESA). Zato je Centru odličnosti VESOLJE-SI, v katerem sem bila zaposlena, v okviru programa PECS odobrila financiranje projekta Uporaba časovne vrste posnetkov Sentinel-2 za določitev vrste poljščin in spremljanje njihovega stanja (angl. Application of Sentinel-2 Time Series Data for Crop Identification and Crop Stress Monitoring), v nadaljevanju Sentinel2Agri4Slovenia. Precejšen del disertacije sem opravila v sklopu tega projekta.

1.1 Cilji doktorske disertacije

Pomembni dejavniki, ki spodbujajo pospešeno rabo podatkov satelitskih sistemov, so poleg brezplačne dostopnosti gostih časovnih vrst srednje in visokoločljivih posnetkov tudi izboljšanje računskih zmognosti, tehnoloških kapacitet, kapacitet shranjevanja in pristopov obdelave podatkov. Dodatno uporabnost prinašajo samodejni postopki za geometrično in radiometrično predobdelavo posnetkov ter orodja za maskiranje oblakov in njihovih senc (Hostert et al., 2015). Naraščajoče in dobro določene potrebe uporabnikov motivirajo razvoj raziskav in prizadevanj za operativno izdelavo časovno, prostorsko in tematsko izboljšanih baz pokrovnosti (Gomez et al., 2016).

Veččasovna klasifikacija – klasifikacija časovne vrste satelitskih posnetkov – je zato postala zelo aktualna. Število strokovnih člankov se hitro povečuje. Vendar pa tehnologija senzorjev in satelitov prehiteva algoritme za razpoznavanje in razvrščanje objektov. Goste časovne vrste posnetkov in posledično ogromno število posnetkov silijo razvijalce algoritmov k vse bolj samodejnim postopkom klasifikacije. Pri tem žal trpi kakovost končnih kart pokrovnosti.

Pri veliki večini raziskav, opisanih v strokovnih člankih, je veččasovna klasifikacija osnovana na pikslu, upoštevajo pa se zgolj spektralne lastnosti posnetka, najpogosteje je to vrednost indeksa NDVI skozi čas. Izkušenim izvajalcem klasifikacij se v primeru veččasovne klasifikacije visoko prostorsko ločljivih posnetkov zagotovo pojavi mnogo vprašanj, kot so:

- Je res časovna komponenta tako zelo pomembna, da lahko uporabimo samo en indeks in osnovno enoto piksel?
- Ali lahko primere dobre prakse iz enočasovne klasifikacije kar prenesemo na veččasovno klasifikacijo?
- Je kvazi veččasovna klasifikacija zadovoljiva ali pa je veliko bolje uporabiti klasifikacijo na osnovi časovnih vrst?
- Lahko metode na osnovi časovnih vrst, ki so se izkazale kot primerne na drugih področjih obdelave podatkov, kar prenesemo na področje klasifikacije rastrskih multispektralnih posnetkov?

Odgovori na takšna in mnoga druga vprašanja so se v strokovni literaturi začeli pojavljati zadnje leto ali dve. Pri prijavi teme doktorske disertacije takšnih odgovorov praktično ni bilo, tematika je bila povsem

na začetku razvoja. Usmeritve za dobro prakso so še danes zelo skromne, zato sem jih pridobivala v sklopu te disertacije.

Naslov disertacije (veččasovna klasifikacija podob z optičnimi satelitskimi posnetki) je namenoma zelo splošen, saj sem iskala odgovore na mnoga vprašanja. Glavni cilj je bil na osnovi optičnih satelitskih posnetkov določiti lokacijo in razred pokrovnosti, pri čemer sem upoštevala spektralne, teksturne in časovne lastnosti posnetkov. Klasificirala sem pet splošnih osnovnih razredov pokrovnosti (gozd, travnik, njiva, voda, urbano) ter šest poljščin. Pet od teh je v Sloveniji najpogostejše zastopanih (koruza, pšenica, ječmen, oljna ogrščica, tritikala), ena poljščina pa je med šestimi najpogostejše zastopanimi na študijskem območju (oljna buča). Z željo po pridobitvi odgovorov na gornja vprašanja, trditve hipotez in mnoga druga vprašanja, sem si zadala naslednje cilje:

- izvedba enočasnih klasifikacij;
- izvedba kvazi veččasnih klasifikacij;
- izvedba veččasnih klasifikacij na osnovi časovnih vrst;
- primerjava vseh izvedb in rezultatov navedenih treh vrst klasifikacij.

Omenjene klasifikacije sem izvajala za osnovne razrede pokrovnosti in osnovne poljščine, z različnimi vhodnimi podobami, različnimi atributi, različnimi osnovnimi enotami, posnetki različnih senzorjev, različnimi metodami klasifikacij, velik poudarek pa sem dala preučitvi postopkov segmentacije, saj so izkušnje o uporabnosti objektno usmerjene veččasovne klasifikacije v svetovnem merilu zelo skromne.

1.2 Raziskovalne hipoteze

V uvodu opredeljujem problematiko, na katero se nanaša doktorska disertacija, ter navajam cilje, ki jih z disertacijo želim doseči. Za usmerjeno doseganje cilja postavljam štiri hipoteze, ki jih po raziskavah bodisi potrdim bodisi ovržem. V nadaljevanju na kratko opisujem pomen vsake postavljene hipoteze ter način njenega preverjanja.

1.2.1 Hipoteza H1

Hipoteza H1 se glasi: upoštevanje teksture v postopku segmentacije izboljša kakovost segmentacije in s tem končne klasifikacije.

Na področju objektno usmerjene klasifikacije je splošno uveljavljeno, da ima segmentacija ključen in neposreden vpliv na kakovost končne klasifikacije, saj z njo fiksiramo lokacijo, velikost in obliko objektov. Uporabnikova želja je zato pridobiti čim bolj optimalne segmente. Predvidoma so to segmenti, kjer velja: en objekt je en segment.

Glede na pregledano literaturo se v postopku segmentacije kot vhodne podobe uporabljajo izključno osnovni spektralni kanali ali (redko) določena kombinacija spektralnih kanalov. Zato so razredi

pokrovnosti z zelo močno izraženo strukturo (npr. gozd v bližnje-infrardečem kanalu) v primeru uporabe algoritma razvodij prekomerno segmentirani. V praksi to pomeni, da je na območju objekta veliko malih segmentov oz. poligonov. Prekomerna segmentacija pa predvidoma vodi v slabšo kakovost klasifikacije.

Predpostavljam, da bi se prekomerni segmentaciji lahko izognili, in sicer na naslednji način: na določeni spektralni podobi bi uporabili teksturni filter, nato pa območja z visoko variabilnostjo označili kot en homogen objekt, ki bi ga posledično segmentirali v en segment.

Hipotezo H1 preverjam v poglavju 10.2. Za potrditev hipoteze morajo biti rezultati klasifikacije z upoštevanjem teksture boljši od rezultatov klasifikacije z neupoštevanjem teksture.

1.2.2 Hipoteza H2

Hipoteza H2 se glasi: veččasovna objektno usmerjena klasifikacija zahteva veččasovno segmentacijo.

V primeru objektno usmerjene klasifikacije je osnovna enota segment. Segmentacija je vezana na posnetek, ki ga segmentiramo. Ker se spektralne lastnosti pokrovnosti iz posnetka v posnetek spreminjajo (še posebej je to značilno za različne poljščine na njivah), se število, oblika in lokacija segmentov med posameznimi posnetki razlikuje. Pri enočasovni klasifikaciji to ne povzroča težav, saj tudi klasificiramo samo z vrednostmi enega posnetka. V primeru veččasovne klasifikacije pa na posamezen segment vezemo attribute več posnetkov, zato predvidevam, da uporaba segmentov, narejenih na zgolj enem posnetku, ni primerna za veččasovno klasifikacijo. Predvidevam, da pri veččasovni klasifikaciji potrebujemo veččasovno narejene segmente, prilagojene vsem uporabljenim posnetkom.

Hipotezo H2 preverjam v poglavju 10.4, kjer primerjam kakovost veččasovne klasifikacije na enočasovno in veččasovno določenih segmentih. Za potrditev hipoteze morajo biti rezultati klasifikacije veččasovno določenih segmentov boljši od rezultatov klasifikacije enočasovno določenih segmentov.

1.2.3 Hipoteza H3

Hipoteza H3 se glasi: večnivojska objektno usmerjena klasifikacija pokrovnosti daje boljše rezultate kakor enonivojska.

Hipotezo postavljam na predpostavki, da bi bila segmentacija in kasnejša klasifikacija veliko boljša in učinkovitejša, če bi jo prilagodili vsakemu razredu posebej. Če bi jo izvajali t. i. večnivojsko. V prvem nivoju bi uporabili določene vhodne podobe in parametre z željo po optimalni segmentaciji prvega razreda. Po klasifikaciji prvega razreda bi prvi razred maskirali, nato pa s poljubnimi drugimi vhodnimi podobami in parametri segmentirali in klasificirali drugi razred. Tako bi postopek ponavljali za vse razrede. S takšnim postopkom ne bi bili obremenjeni z izdelovanjem segmentacije, ki bi morala ustrezati vsem razredom pokrovnosti, ampak bi se lahko prilagodili posameznemu.

Hipotezo H3 preverjam v poglavju 10.3, kjer primerjam kakovost večnivojske klasifikacije s kakovostjo enonivojske klasifikacije. Za potrditev hipoteze morajo biti rezultati večnivojske klasifikacije boljši od rezultatov enonivojske klasifikacije.

1.2.4 Hipoteza H4

Hipoteza H4 se glasi: veččasovna klasifikacija daje boljše rezultate kakor enočasovna klasifikacija.

Hipotezo postavljam na predpostavki, da lahko s hkratno uporabo posnetkov več različnih časov dosežemo boljše rezultate klasifikacije kakor z uporabo zgolj enega posnetka enega časa. V primeru veččasovne klasifikacije imamo namreč poleg spektralnih lastnosti na voljo še pomembno dodatno komponento – čas.

Kljub temu, da rezultate enočasovne in veččasovne klasifikacije preverjam v več vmesnih poglavjih, glavni del hipoteze H4 preverjam v poglavju 11, kjer pri različnih klasifikacijah lahko uporabim že znane najprimernejše attribute in osnovne enote. Tri vrste klasifikacij: enočasovno, kvazi veččasovno in klasifikacijo na osnovi časovnih vrst izvajam na treh vrstah posnetkov: RapidEye, SPOT5 Take5 in Sentinel-2. Za potrditev hipoteze morajo biti rezultati veččasovne klasifikacije večinoma boljši od rezultatov enočasovne klasifikacije.

1.3 Struktura poglavij

Doktorska disertacija je razdeljena na dvanajst poglavij. Prvo poglavje je uvodno in opisuje cilje ter raziskovalne hipoteze disertacije. V drugem poglavju so najprej na kratko podani osnovni teoretični pojmi, nanašajoči se na različne vrste klasifikacij pokrovnosti. Poglavje se konča s pregledom obstoječih raziskav na področju veččasovne klasifikacije. V naslednjem poglavju so opisane metode ocenjevanja kakovosti klasifikacije in segmentacije, zanesljivost ocene segmentacije za napoved ocene klasifikacije ter način izbire najboljših rezultatov. Čeprav že tretje poglavje vsebuje praktične primere, se pravi praktični del disertacije začne s četrtem poglavjem, namenjenim opisu uporabljenih podatkov, ter nadaljuje s petim poglavjem, kjer je opisana uporabljena programska oprema in osnovni principi delovanja uporabljenih postopkov. V šestem poglavju preučim postopke segmentacije, ki jih želim v naslednjih poglavjih izboljšati in s tem pridobiti višjo kakovost končne klasifikacije. Tako v sedmem poglavju opišem razvoj različnih vhodnih podob, v osmem določitev najznačilnejših atributov ter v devetem določitev optimalne osnovne enote kartiranja. Disertacijo nadaljujem z vpeljavo najsodobnejših metod v postopek segmentacije ter jo sklenem s primerjavo enočasovne in veččasovne klasifikacije. Z dvanajstim poglavjem disertacijo zaključim s sprejetjem oz. zavrnitvijo raziskovalnih hipotez. Sledi povzetek v slovenskem in angleškem jeziku.


2 OSNOVE KLASIFIKACIJE POKROVNOSTI

S klasifikacijo pokrovnosti iz rastrskega daljinsko zaznanega (letalskega ali satelitskega) posnetka dobimo kvantitativni sloj pokrovnosti, ki ga kasneje lahko uporabimo v analizah z geografskimi informacijskimi sistemi (GIS) (Oštir, 2006). Glavni namen klasifikacije pokrovnosti je razdelitev predmetov na zemeljski površini v t. i. razrede pokrovnosti. Običajno se klasifikacija izvaja z vizualno interpretacijo posnetka. Zaradi izboljševanja postopkov pa v prakso vse bolj prihaja digitalna klasifikacija, kjer so razredi določeni z upoštevanjem spektralnih informacij na večspektralnih posnetkih. Tovrstno klasifikacijo imenujemo tudi spektralno prepoznavanje vzorcev (angl. spectral pattern recognition).

Klasifikacija pokrovnosti ni novost in o njej je bilo napisane že precej literature, tudi v Sloveniji. Osnovne pojme klasifikacije je npr. v svoji diplomski nalogi lepo opisala Urška Kanjir (Kanjir, 2009). Zato v tem poglavju ne podajam splošnih opisov in razlag klasifikacije, temveč za lažje razumevanje zgolj na kratko opisujem osnovne pojme, ki se bodo pojavljali v nalogi. Obširneje opisujem le veččasovno klasifikacijo, ki je glavna tema disertacije in tudi v svetovnem merilu novost. Zato osnovnemu opisu postopkov dodajam tudi pregled obstoječih raziskav na področju veččasovne klasifikacije.

2.1 Objektno usmerjena klasifikacija

Zaradi izjemnega povečanja prostorske in delno tudi spektralne ločljivosti satelitskih posnetkov je v zadnjem desetletju tradicionalne pikselske klasifikacijske metode izpodrinila objektno usmerjena klasifikacija (angl. object-based classification). Ta združuje segmentacijo, ki je temeljna faza za razmejevanje elementov geografskih objektov, in klasifikacijo, ki je semantično (kontekstualno) podprta (Veljanovski et al, 2011). Segmentacija razdeli podobo na homogene skupine pikslov (segmente), semantična klasifikacija pa jih nato razvršča v razrede na podlagi njihovih spektralnih, geometričnih, teksturnih in drugih lastnosti (Navulur, 2007) (slika 1).



Slika 1: Postopek objektno usmerjene klasifikacije: predobdelava daljinsko zaznanega posnetka (a), segmentacija (b) in klasifikacija (vektorski sloj pokrovnosti) (c)

Figure 1: Process of object-based classification: preprocessing of remotely sensed image (a), segmentation (b) and classification (vector land cover layer) (c)


V disertaciji uporabljam zgolj nadzorovano objektno usmerjeno klasifikacijo pokrovnosti, tako enočasovno kot veččasovno, pri čemer menjavam osnovne enote kartiranja ter vhodne podobe.

2.1.1 Segmentacija

Kot rečeno, je objektno usmerjena klasifikacija postopek razpoznavanja mej objektov (segmentacija) in razvrščanja segmentov v izbrane objektne razrede (klasifikacija). Ker s segmentacijo fiksiramo lokacijo, velikost in obliko objektov, ima segmentacija ključen in neposreden vpliv na kakovost končne klasifikacije. Zato se bo pojem segmentacije v disertaciji zelo pogosto pojavljal in bo tudi podrobneje razložen in preučen.

2.1.2 Osnovna enota kartiranja

V disertaciji je pod pojmom osnovna enota kartiranja mišljena oblika in velikost objekta klasifikacije. Pri objektno usmerjeni klasifikaciji je to segment, lahko pa kot vhodni podatek v postopek klasifikacije vpeljemo tudi poljubno drugo osnovno enoto kartiranja. Ker veččasovna klasifikacija zahteva fiksno osnovno enoto skozi čas, v disertaciji definiram in primerjam zgolj takšne enote. Te so: PIKSEL, MREŽA 3 x 3, SEGMENT ter GERK. Nekaj primerov je prikazanih na sliki 2. Izbiri optimalne osnovne enote kartiranja je namenjeno celotno poglavje 9, kjer so osnovne enote tudi podrobneje obrazložene.



Slika 2: Primeri osnovne enote kartiranja: PIKSEL (a), SEGMENT (b) in GERK (c)


Figure 2: Examples of basic mapping unit: PIXEL (a), SEGMENT (b) and GERK (c)

2.1.3 Vhodna podoba

Podoba (angl. image) je digitalna predstavitev podatkov daljinskega zaznavanja v obliki matrike slikovnih elementov oziroma pikslov (Oštir, 2006). Podoba lahko predstavlja odbojnost ali lastno sevanje površja in je – odvisno od števila kanalov – eno- ali več-razsežna. Izraz poleg tega zajema tudi vse rezultate obdelav, od preobdelave prek izboljšanja in transformacij do klasifikacije, modeliranja in simulacij. V najširšem pomenu je podoba vsaka slika v rastrski obliki. Pojem je širši od posnetka, ki je predstavitev resničnosti, kot jo je zajel senzor (Oštir, 2006).

Pod pojmom vhodna podoba je v disertaciji mišljena podoba, ki je vhodni podatek bodisi v postopek segmentacije bodisi v postopek klasifikacije. Ima splošne lastnosti podobe in je kot takšna lahko eno-kanalna ali več-kanalna, sestavljena iz osnovnih spektralnih kanalov ali raznih izpeljank, kot so npr. vegetacijski indeksi. Podrobneje so vhodne podobe opisane v poglavju 7, na sliki 3 pa so prikazani trije primeri podob v različnih barvnih kombinacijah.

Lažno barvna podoba (angl. false colour image) oz. lažno barvni prikaz je prikaz podobe, pri katerem so poljubni kanali podobe podani z eno ali več osnovnih barv (modro, zeleno ali rdečo). Kot rečeno, so lahko kanali nevidni deli elektromagnetnega dela spektra ali poljubne izpeljanke osnovnih kanalov. Tako dobimo posnetek, ki človeku na razumljiv način predstavi informacije, ki jih sicer v naravi ne vidi.



Slika 3: Barvni prikazi primerov vhodnih podob. Kot rdeča, zelena in modra barva so prikazane sledeče podobe posnetkov RapidEye: podoba rdečega, zelenega in modrega kanala posnetka 29.7.2013 (a); podoba rdečega in zelenega kanala ter podoba ndvi posnetka 29.7.2013 (b); podoba ndvi posnetka 18.5.2013, podoba ndvi posnetka datuma 29.7.2013 in podoba ndvi posnetka 14.9.2013 (c).

Figure 3: RGB colour presentations of three examples of input images. The following RapidEye images are used as red, green and blue colour: image of red, green and blue channel of satellite image 29.7.2013 (a); image of red and green channel and ndvi image of satellite image 29.7.2013 (b); ndvi image of satellite image 18.5.2013, ndvi image of satellite image 29.7.2013 and ndvi image of satellite image 14.9.2013 (c).

2.2 Veččasovna klasifikacija


Klasifikacija pokrovnosti je še do nedavnega temeljila na enočasovni metodi, kjer smo klasificirali en sam posnetek. Odprtje številnih velikih arhivov časovnih vrst satelitskih posnetkov, kot so Landsat, MODIS in Sentinel, je omogočilo dostop do raznovrstnih podatkov, ki omogočajo boljšo oceno in razumevanje lokalnih in globalnih sprememb. Želja po časovni analizi takšnih podatkov je med drugim vodila tudi do razvoja metod veččasovne klasifikacije pokrovnosti.

Veččasovna klasifikacija pokrovnosti je klasifikacija s posnetki različnih časov. Pri tem imamo poleg spektralnih informacij o objektu na površju na voljo tudi informacijo o časovnem spreminjanju spektra tega objekta. Kadar je govora o rastlinskem pokrovu, časovno spreminjanje imenujemo fenologija. Ob upoštevanju, da je večina kopnega na našem planetu pokrita z rastlinstvom, lahko sklepamo, da

upoštevanje fenologije pri klasifikaciji pokrovnosti vodi do bolj kakovostnih kart pokrovnosti (Simonetti et al., 2014).

Beseda fenologija izvira iz grških besed “phainesthai”, kar pomeni pojaviti se, ter “logos”, razlog. Fenologi preučujejo vpliv vremenskih razmer na periodične pojave oz. fenofaze v razvoju rastlin tako, da zapisujejo datume pojava določenih fenofaz v razvoju rastlin, kot je na primer olistanje, cvetenje in podobno (Žust, 2015). Izraz fenologija je torej precej širok. Čeravno lahko s časovno vrsto satelitskih posnetkov ugotavljamo tudi razloge in vpliv na različne fenofaze rastlin, se pri veččasovni klasifikaciji osredotočamo zgolj na določanje časa posameznih fenofaz in njihove primerjave med različnimi rastlinami oz. območji.


Fenološke faze določenih rastlinskih vrst so se včasih določale zgolj lokalno. Na sliki 4 so prikazane fotografije macesnovega gozda v različnih časovnih trenutkih.



Slika 4: Fotografije različnih fenoloških faz macesnovega gozda Fujihokuroku. Vir: Center for Global Environmental Research, National Institute for Environmental Studies, Japan (po Simonetti et al., 2014).

Figure 4: Photos of different phenological phases of larch forest Fujihokuroku. Source: Center for Global Environmental Research, National Institute for Environmental Studies, Japan (after Simonetti et al., 2014).


S povečano dostopnostjo do veččasovnih opazovanj je uporaba časovnih vrst in iz časovnih vrst izpeljanih fenoloških indikatorjev postala aktualna tudi za regionalna in nacionalna kartiranja (Simonetti et al., 2014). Primer spreminjanja rastlinskega pokrova na območju občine je prikazan na sliki 5.



Slika 5: Mesečni satelitski posnetki RapidEye občine Stara Nova vas

Figure 5: Monthly RapidEye satellite images of Stara Nova vas municipality


Za prikazovanje sprememb rastlinstva skozi čas se največkrat uporablja prikaz vrednosti izbranega vegetacijskega indeksa. V veliki večini je to normiran diferencialni vegetacijski indeks NDVI. Spremembe nas lahko zanimajo na splošno (celoten posnetek) ali pa za točno določeno območje. Na sliki 6 je prikazano časovno spreminjanje indeksa NDVI na štirih njivah, kjer je bila v drugi polovici leta posejana koruza. Časovni potek indeksa je v drugi polovici res zelo podoben, saj gre za isto poljščino. Iz primerjave posnetkov in grafa lahko z gotovostjo rečemo, da sta bili njivi 3 in 4 septembra požeti. Iz tega lahko sklepamo, da je koruza na teh dveh njivah silažna, saj se le-ta žanje prej kot koruza za zrnje. Dodatno je opaziti, da je na njivi 3 rastla neka pomladna poljščina.



Slika 6: Posnetek julija (a); septembra (b); graf povprečnih vrednosti NDVI na izbranih njivah skozi čas (c)

Figure 6: Satellite image captured in July (a); in September (b); graph of mean NDVI values of selected fields over time (c)

Če grafe časovnega spreminjanja prikažemo za različne poljščine, lahko v primeru zadostne razlike med grafi poljščine med seboj ločimo. Na sliki 7 so prikazani grafi časovnega spreminjanja povprečne vrednosti indeksa NDVI na petih različnih poljščinah. Opaziti je, da bi lahko nekatere poljščine na osnovi takšnih grafov enostavno razločili, nekatere pa bi predstavljale večji izziv.



Slika 7: Graf časovnega spreminjanja povprečne vrednosti indeksa NDVI za izbrane poljščine


Figure 7: Graph of time variation of mean values of NDVI index of selected crops

Časovne vrste satelitskih posnetkov omogočajo boljši pogled na fenološki status poljščine in sezonski cikel rasti in tako pomenijo pomembno orodje za razlikovanje posameznih tipov poljščin in njihovega stanja. Tehnike obdelave podatkov in interpretacija, ki vključujejo časovno dimenzijo, ostajajo področje intenzivnih raziskav in razvoja. Izboljšave trenutnih pristopov, kot tudi vključitev novih tehnik je pomembna, da dobimo kar največ iz podatkov, ki jih imamo na voljo in da lahko proizvajamo letne karte pokrovnosti, ki služijo različnim potrebam.

V nadaljevanju poglavja opisujem dva načina veččasovne klasifikacije ter podajam pregled obstoječih raziskav na področju veččasovne klasifikacije pokrovnosti.

2.2.1 Kvazi veččasovna klasifikacija

Pojav velike količine časovnih vrst satelitskih posnetkov je nekako »prehitel« razvoj metod za veččasovno klasifikacijo. Preden so razvili prve algoritme klasifikacije, ki vključujejo kompleksne časovne podatke, so se za klasifikacijo veččasovnih posnetkov uporabljala enaka pravila kot za klasifikacijo posnetkov enega časa (Gomez et al., 2016). Tako v literaturi v glavnem zasledimo kvazi veččasovno klasifikacijo. Gre za običajno enočasovno spektralno klasifikacijo, le da kot vhodni podatek ne uporabimo zgolj kanalov posnetka enega časa, temveč podobo, v kateri smo združili kanale posnetkov različnih časov (slika 8). S tem posnetku, v matematičnem smislu, povečamo spektralno ločljivost (Singh in Glenn, 2009).



Slika 8: Podobe različnih datumov (D1 do D4) s štirimi kanali (levo) in podoba, v kateri so združeni kanali vseh posameznih štirih posnetkov (desno)


Figure 8: Images of different dates (D1 to D4) with four channels (left) and image with merged channels of all four individual satellite images (right)

Čeprav gre za kvazi veččasovno klasifikacijo, je bilo ugotovljeno, da lahko ima vključitev posnetkov več različnih časov v klasifikacijo bolj pozitiven vpliv na rezultate kakor izbira klasifikatorja (Jia et al., 2014). Kljub temu pa ni vseeno kateri klasifikator izberemo. Izkušnje nekaterih avtorjev (Glanz et al., 2014) kažejo, da parametrične nadzorovane klasifikatorje (npr. klasifikator največje verjetnosti (angl. maximum likelihood), najmanjše razdalje (angl. minimum distance) ali razločevalne analize (angl. discriminant analysis)) težko uporabimo z veččasovnimi podatki in veliko spektralnimi atributi, saj niso tako prilagodljivi pri določitvi meja med razredi. Njihove slabosti še posebej pridejo do izraza pri velikih območjih in kompleksnih okoljih. Po drugi strani neparametrični klasifikatorji (npr. k-bližnji sosed (angl. k-nearest neighbour), odločitvena drevesa (angl. decision trees), nevronske mreže (angl. neural networks) in metode podpornih vektorjev (angl. support vector machines)) določajo meje poljubnih geometrij, s čimer so bolj prilagodljivi in zato primernejši za veččasovno klasifikacijo. Tudi zato sem, kot opisano v poglavju 5.2.2, za kvazi veččasovno klasifikacijo uporabila enega izmed neparametričnih klasifikatorjev.

2.2.2 Klasifikacija na osnovi časovnih vrst

Časovna vrsta je niz istovrstnih podatkov, ki se nanašajo na zaporedne časovne razmike ali trenutke in dajejo sliko dinamike pojava (Chen et al., 2015). Analiza časovnih vrst se uporablja v različnih aplikacijah. Gručenje, klasifikacija in podatkovno rudarjenje časovnih vrst je bilo preučeno v številnih aplikacijah, kot so prepoznavanje znakovnega jezika, zdravniške diagnoze osnovane na elektrokardiografiji, trgovanje z delnicami... Za potrebe veččasovne klasifikacije podatkov daljinskega zaznavanja pa se časovne vrste uporabljajo relativno kratek čas.

Osnova klasifikacije na osnovi časovnih vrst je torej analiza časovnih vrst oz. konkretnije, primerjava grafov časovnega razvoja določenih spektralnih karakteristik različnih tipov pokrovnosti. Osnovna ideja je, da za posamezne razrede pokrovnosti izdelamo modele časovnega razvoja, nato pa časovne razvoje neznanih razredov pripišemo tistemu znanemu izdelanemu modelu, ki mu je najbolj podoben (Aurdal et al., 2005). Na sliki 9 je prikazan klasični model (fenološki razvoj) rastlinskega razreda pokrovnosti.



Slika 9: Klasični fenološki razvoj rastlinskega razreda pokrovnosti, prikazan v obliki razvoja indeksa NDVI (Aurdal et al., 2005)

Figure 9: Standard phenological development of a vegetation ground cover class when observed in the form of NDVI (Aurdal et al., 2005)

Čeprav zveni precej enostavno, je definicija modela običajno problematična. Kljub temu, da obstaja veliko literature na temo fenologije različnih vrst rastlin, se ta običajno nanaša na posamezno rastlino (in ne določen rastlinski razred pokrovnosti) in opisuje zelo specifične samostojne dogodke (npr. začetek poganjkov ali cvetenja) in ne sezonskega razvoja. Za izgradnjo fenološkega modela tako obstajata dve možnosti: samodejna izgradnja iz satelitskih podatkov in ročna izgradnja, osnovana na botaničnem znanju v kombinaciji s satelitskimi podatki (Aurdal et al., 2005).

Ko imamo model, lahko klasifikacijo na osnovi časovnih vrst izvedemo na dva načina: časovni razvoj razgradimo v posamezne elemente trenda, sezon in večjih sprememb in uporabimo analizo komponent ali pa uporabimo celoten časovni razvoj in uporabimo enostavno analizo trenda (Gomez et al., 2016).

2.2.3 Pregled obstoječih raziskav na področju veččasovne klasifikacije pokrovnosti

Zaradi pojava velikega števila časovnih vrst satelitskih posnetkov je v zadnjih letih zaslediti dramatično povečanje zanimanja za analizo in klasifikacijo tovrstnih podatkov (Gorecki, 2014).

Večinoma je v literaturi za klasifikacijo časovnih vrst posnetkov zaslediti izvedbo kvazi veččasovnih klasifikacij. Pri teh uporabljamo standardne klasifikatorje. Kot že opisano, so parametrični nadzorovani

klasifikatorji neprimerni za klasifikacijo časovnih vrst. Od neparametričnih prevladujejo odločitveno drevo (DT), nevronska mreža (NN) in metoda podpornih vektorjev (SVM).

Klasifikatorji DT so privlačni za klasifikacijo velikih območij, saj so enostavni za izvedbo in interpretacijo, hitro jih naučimo in izvedemo. Sposobni so obdelati podatke različnih meril ter nelinearno povezane podatke in niso zelo občutljivi na manjkajoče podatke. Vendar pa so rezultati klasifikatorjev DT slabši kakor s klasifikatorji SVM in NN, če je podatkov veliko. Dodatno so občutljivi na šum ter prekomerno prilagajanje (angl. over-fitting). Nadgradnja klasifikatorjev DT so klasifikatorji RF, ki imajo višjo kakovost klasifikacije kot DT in nimajo problema s prekomernim prilagajanjem. So pa računsko zahtevnejši in delujejo kot črna skrinja za odločitvena pravila. Klasifikatorji SVM se dobro izvajajo v primeru majhnega števila referenčnih podatkov. Klasifikatorji NN so natančni, ampak imajo težnjo po prekomernem prilagajanju podatkov in ostajajo črna skrinja za interpretacijo. Oboji, klasifikatorji NN in SVM, so računsko zahtevni in zahtevajo nastavitve večjega števila parametrov (Gomez et al., 2016).

Ključno pri klasifikaciji na osnovi časovnih vrst je izračun razdalje oz. podobnosti/različnosti med posameznimi časovnimi vrstami (Gorecki, 2014). Najbolj priljubljena mera različnosti (angl. dissimilarity measure) pri podatkovnem rudarjenju je evklidska razdalja (angl. Euclidean distance), saj je enostavna in učinkovita. Vendar pa zahteva, da sta obe vhodni časovni vrsti enakih dolžin, poleg tega pa je občutljiva na popačenje in spreminjanje vzdolž časovne osi (Gorecki, 2014). Časovno prilagajanje je splošen pojav pri časovnih vrstah in ustvarja velike izzive za samodejno veččasovno klasifikacijo. Problem lahko rešujemo s prožnimi merami različnosti, kot so dinamično časovno prilagajanje (angl. Dynamic Time Warping – DTW) in najdaljša skupna podsekvenca (angl. Longest Common SubSequence – LCSS) (Gorecki, 2014). V primerjavi z evklidsko razdaljo sta metodi DTW in LCSS bolj prožni, podpirata lokalne časovne premike in razlike dolžin med pari časovnih vrst. Nekatere nove metode ju še nadgrajujejo, s čimer rešujejo pretirano izkrivljanje (Vlachos et al., 2003), višajo robustnost proti šumu in časovnemu popačenju (Chen et al., 2005), upoštevajo sezonske spremembe različnih tipov pokrovnosti (Maus et al., 2016) idr. So pa metode DTW in LCSS ter njune izpeljanke računsko zahtevnejše in časovno potratne (Chen et al., 2015; Prekopcsak in Lemire, 2012).

Metode veččasovne klasifikacije iz dneva v dan napredujejo, manj razlik med članki pa je opaziti glede vhodnih podatkov. Osnovna enota kartiranja je v veliki večini piksel. Objekti (skupki več pikslov) bi morda pomagali rešiti problem ali dva (zamik pikslov med posnetki, velika razlika vrednosti pikslov v objektu, hitrost računanja). Osnovni atribut, katerega časovni razvoj primerjamo, je skoraj izključno vrednost indeksa NDVI. Tudi tukaj so raziskave še odprte. Tudi lastnosti vhodnih posnetkov so kljub vsemu za metode veččasovnih klasifikacij še vedno neoptimalne in predstavljajo problem pri gradnji modelov. Nezadostna je bodisi nizka časovna ločljivost visoko prostorsko ločljivih posnetkov (npr. Landsat) ali nizka prostorska ločljivost sicer zadostno časovno ločljivih posnetkov (npr. MODIS in

NOAA) (Aurdal et al., 2005). Dodaten problem predstavljajo oblaki, predvsem meglice, ki jih je težko izločiti.

3 METODE DELA

Doktorska disertacija poleg izvedbe veččasovne klasifikacije pokrovnosti z optičnimi satelitskimi posnetki vsebuje precej podnalog. Poleg preverjanja raziskovalnih hipotez pod drobnogled vzamem mnoge druge podrobnosti postopka klasifikacije. Struktura disertacije je posledično zelo razvejana, pri čemer večina nalog temelji na svoji, specifični metodi dela. Zaradi lažjega razumevanja so metode reševanja posamezne naloge opisane v njihovem pripadajočem poglavju.

Skupna lastnost vseh nalog pa je, da v njih iščem najboljši rezultat, pri čemer je to lahko najustreznejša vhodna podoba, metoda, algoritem, osnovna enota idr. Ker je cilj izvesti klasifikacijo čim višje kakovosti, bo tudi izbira najboljših rezultatov vedno temeljila na primerjavi kakovosti klasifikacije. Zato v podpoglavju 3.1 opisujem metode za oceno klasifikacije.

Ker je velik del disertacije posvečen segmentaciji, kot prvemu koraku objektno usmerjenega postopka klasifikacije, se pri nekaterih nalogah zdi smiselna uporaba ocen kakovosti segmentacije. V tem primeru za določitev nekaterih najboljših metod, podob idr. ne bi bilo potrebno izvajati celotnega postopka klasifikacije. Zato v podpoglavju 3.2 opisujem metode za oceno segmentacije.

Ker oceno kakovosti klasifikacije za izbiro najboljših rezultatov določam kot oceno prvobitnega pomena, moram biti prepričana ali dobra ocena segmentacije res pomeni tudi dobro oceno klasifikacije, zato to preverim z analizo in rezultate opišem v podpoglavju 3.3.

Na osnovi analiz ocen klasifikacije, segmentacije ter njune korelacije se odločim glede končnega načina izbire najboljših rezultatov posameznega sklopa. Način opisujem v podpoglavju 3.4.

3.1 Metode ocenjevanja kakovosti klasifikacije

Tematika kakovosti klasifikacije je zelo široka. Ocenjujemo lahko kakovost rezultata klasifikacije ali celotnega postopka klasifikacije. Prvobitno pravilo je, da moramo pri ovrednotenju klasifikacije vključiti želje in pričakovanja končnega uporabnika. Smits s sodelavci (1999) navaja, da pri nekaterih člankih s področja daljinskega zaznavanja to sicer lahko zasledimo, toda pogosto je tema razprave zgolj kako bi končni uporabniki želeli imeti prikazane rezultate ocene klasifikacije namesto da bi se neposredno ukvarjali z uporabnikovimi dejanskimi željami.

Ocenjevanje kakovosti samih metod klasifikacij (klasifikatorjev) presega temo te disertacije. Pri oceni klasifikatorjev moramo upoštevati natančnost, kompleksnost izračuna (angl. computational complexity) in kompleksnost opisa (angl. descriptional complexity) dobljenih rezultatov (Smits et al., 1999).

Za potrebe primerjave rezultatov klasifikacij v vseh primerih uporabljam enak klasifikator. Prav tako v posameznem testu ohranjam lokacijo in število učnih in testnih točk.

Tudi sama obravnava kakovosti rezultata klasifikacije presega temo te disertacije. Poleg natančnosti je v pojmu kakovosti rezultata zajeta tudi gotovost (angl. certainty) in/oz. prostorska kakovost rezultata klasifikacije (tematske karte). Poleg števila napačno klasificiranih objektov je torej potrebno upoštevati še razporeditev napak v prostoru. Pri oceni razporeditve pa zopet potrebujemo mnenje/zahteve uporabnika: ima prednost več razpršenih manjših napak ali manj zgoščenih napačno določenih območij; ima natančnost določitve določenega razreda pokrovnosti prednost pred natančnostjo določitve drugih razredov; morajo biti meje objektov zelo natančno določene ipd.

Ker disertacija ni namensko usmerjena na konkretnega uporabnika, kakovost ocenjujem na najbolj pogost način določanja kakovosti klasifikacije pokrovnosti, ki ga zasledimo v literaturi, kjer avtorji večinoma ocenjujejo zgolj natančnost klasifikacije. Smits s sodelavci (1999) po pregledu literature ugotavlja, da večina raziskav temelji na matriki napak (angl. error matrix, tudi confusion matrix, confusion table, contingency matrix).

Matrika napak je tabela, ki primerja rezultat klasifikacije z referenčnim/kontrolnim podatkom in za vsak razred podaja vrsto in število pravilno oz. napačno klasificiranih pikslov. Primer matrike napak je prikazan v preglednici 1 (povzeto po Oštirju (2006)). Matrika je nastala pri klasifikaciji pokrovnosti območja Krasa.

Preglednica 1: Primer matrike napak, dobljene po klasifikaciji pokrovnosti Krasa. Vrstice predstavljajo piksele klasificiranega sloja, stolpci predstavljajo piksele referenčnega sloja. Skupno število referenčnih in klasificiranih pikslov mora biti enako (v tem primeru 800).

Table 1: Example of an error matrix, calculated after land cover classification of Kras. The rows represent pixels of classification layer, the columns represent pixels of reference layer. The total number of reference and classified pixels must be the same (800 in this case).

Klasifikacija	Referenca								
	Razred	1	2	3	4	5	6	7	Vsota
	1 Gozd	312	1	2	1	0	0	0	316
	2 Grmičevje	6	67	2	6	0	0	0	81
	3 Travniki	4	4	94	5	0	0	0	107
	4 Kmetijsko	3	10	1	128	5	0	0	147
	5 Pozidano	3	0	0	5	59	0	1	68
	6 Voda	0	0	0	0	1	19	0	20
	7 Odprto	1	2	0	0	0	0	58	61
	Vsota	329	84	99	145	65	19	59	800

Ko imamo matriko napak, je na voljo veliko metod in koeficientov za njeno analizo. Matrika napak omogoča izračun več statističnih pokazateljev oz. mer natančnosti. Izračun vedno temelji na določeni kombinaciji primerov pogoška.

Vrednosti v matriki pripadajo eni izmed naslednjih štirih primerov pogreška (slika 10):

- resnični pozitivni (angl. true positive (TP)): klasificirani in referenčni piksli pripadajo istemu razredu pokrovnosti,
- resnični negativni (angl. true negative (TN)): niti klasificirani niti referenčni piksli ne pripadajo določenemu razredu pokrovnosti,
- lažni pozitivni (angl. false positive (FP)): samo klasificirani piksli pripadajo določenemu razredu pokrovnosti,
- lažni negativni (angl. false negative (FN)): samo referenčni piksli pripadajo določenemu razredu pokrovnosti.

		sloj klasifikacije	
		T	F
kontrolni sloj	T	TP	FN
	F	FP	TN

Slika 10: Primeri pogreškov: resnični pozitivni (TP), resnični negativni (TN), lažni pozitivni (FP) in lažni negativni (FN)

Figure 10: Error types: true positive (TP), true negative (TN), false positive (FP) and false negative (FN)

Najbolj običajni meri sta izdelovalčeva natančnost in uporabnikova natančnost.

Izdelovalčeva natančnost (angl. producers accuracy (PA), tudi recall) je namenjena analitiku, ki je izdelal klasifikacijo, in jo izračunamo kot delež pravilno klasificiranih pikslov razreda glede na število vseh referenčnih pikslov razreda (enačba (1)):

$$PA = \frac{TP}{TP+FN} . \quad (1)$$

Uporabnikova natančnost (angl. users accuracy (UA), tudi reliability ali precision) služi kot vodnik za zanesljivost rezultata kot sredstva za napovedovanje in je podana kot delež pravilno klasificiranih pikslov razreda glede na število vseh pikslov, klasificiranih v določen razred (enačba (2)):

$$UA = \frac{TP}{TP+FP} . \quad (2)$$

Preglednica 2, povzeta po Oštirju (2006) podaja izdelovalčevo ter uporabnikovo natančnost za matriko napak v preglednici 1. Podane so vrednosti za posamezen razred ter za povprečje vseh razredov.

Preglednica 2: Ocena natančnosti klasifikacije, dobljena na osnovi matrike napak v preglednici 1.

Table 2: Classification accuracy, calculated from error matrix in Table 1.

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	329	316	312	94,8	98,7
Grmičevje	84	81	67	79,8	82,7
Travniki	99	107	94	95,0	87,9
Kmetijsko	145	147	128	88,3	87,1
Pozidano	65	68	59	90,8	86,8
Voda	19	20	19	100,0	95,0
Odprto	59	61	58	98,3	95,1
Skupaj	800	800	737		
Povprečje				92,43	90,47

Izdelovalčeva in uporabnikova natančnost temeljita zgolj na lažno negativnih oz. lažno pozitivnih piksljih, zato sta lahko zavajajoči, če ju ne uporabimo skupaj. Če želimo za oceno kakovosti uporabiti samo eno mero natančnosti, je dobro, če ta mera vsebuje tako lažno pozitivne kot lažno negativne piksele. Običajno se v tem primeru uporabi F-mera (angl. F-measure ali F-score), ki je uteženo povprečje izdelovalčeve in uporabnikove natančnosti. Najpogostejše imata izdelovalčeva in uporabnikova natančnost enako težo, v tem primeru F-mera predstavlja njuno harmonično povprečje.

Najbolj znana mera natančnosti, ki vključuje obe vrsti napak in se računa za vse razrede skupaj, je skupna natančnost (angl. overall accuracy (OA)). Izračuna se kot delež vsote pravilno klasificiranih pikslov vseh razredov glede na število vseh testnih pikslov (enačba (3)):

$$OA = \frac{\sum_{i=1}^n TP}{N}, \quad (3)$$

kjer je n število razredov in N število vseh testnih pikslov. Skupna natančnost matrike napak v preglednici 1 tako znaša 92,13 %.

Za oceno natančnosti klasifikacije lahko uporabimo še vrsto drugih mer natančnosti. Mere so občutljive na različne značilnosti, ocenjujejo različne komponente natančnosti in dajejo različne predpostavke o podatkih (Dorren et al., 2003). Za potrebe analize, opisane v Švab Lenarčič et al. (2016), sem izračunala in primerjala sedem mer kakovosti, pri čemer sem iz vsakega primera pogreškov (slika 10) uporabila vsaj eno mero natančnosti.

Za potrebe projekta Sentinel2Agri4Slovenia sem uporabila drugih pet mer kakovosti, vendar se njihov izračun ne razlikuje bistveno od mer, uporabljenih v članku Švab Lenarčič et al. (2016). Med temi merami sta bili tudi izdelovalčeva in uporabnikova natančnost.

Pri primerjavi vseh uporabljenih mer ugotavljam, da se mere, ki temeljijo na enakem primeru pogreška, obnašajo zelo podobno. Nekatere mere so med seboj inverzne. Zato sklepam (Švab Lenarčič et al.,

2016), da ni potrebe po uporabi velikega števila različnih mer natančnosti klasifikacije. Najbolje je, če imamo eno mero iz skupine FP, eno iz skupine FN ter eno mero, ki vključuje tako FP kot tudi FN.

Kakovost v vseh primerih, tudi ko osnovna enota ni piksel, ocenjujem pikselsko. Da je takšen postopek ocenjevanja ustrezen, dokazuje v svojem članku Myint s sodelavci (2011).

Kakovost ocenjujem samo znotraj Slovenije, na območjih, kjer ni razreda drugo, ter samo na pikslih, ki niso bili učni.

3.2 Metode ocenjevanja kakovosti segmentacije

Ocena rezultatov segmentacije je zelo pomembna za nadaljno analizo kakor tudi za izbiro primerne pristopa segmentacije (Neubert et al., 2008). Uporabimo jo lahko za odločitev o uporabnosti segmentov glede na namen uporabe objektno usmerjene analize, za izbiro optimalnega algoritma segmentacije izbrane podobe ter za izbiro optimalnih nastavitev parametrov izbranega algoritma (Zhang et al., 2008).

Kakor moramo za dobro izvedeno segmentacijo dobro poznati postopek segmentacije in namen segmentacije, tako moramo tudi za dobro oceno kakovosti segmentacije razumeti postopek ocene kakovosti (metoda, prednosti in slabosti) ter namen ocene kakovosti segmentacije. Le tako bo ocena kakovosti predstavljala koristno informacijo.

Ustreznost in kakovost izvedene segmentacije lahko ocenimo na podlagi različnih metod, katerih pregled je podan v nadaljevanju (Zhang et al., 2008):

- subjektivna ocena,
- objektivna ocena,
 - indirektna ocena (analitične metode),
 - direktna ocena (empirične metode),
 - nadzorovane metode,
 - nenadzorovane metode.

Subjektivna ocena temelji na vizualnem pregledu rezultatov s strani operaterja. Ocena segmentacije se lahko od operaterja do operaterja zelo razlikuje, zato bi moralo pri subjektivni metodi ocenjevanja sodelovati večje število ocenjevalcev, njihova ocena pa bi morala biti v skladu z natančno opredeljenimi navodili za ocenjevanje.

Pri objektivnem ocenjevanju ločimo indirektno in direktno ocenjevanje. Pri indirektnem ocenjevanju se ocenjuje vpliv različnih metod segmentacije na celoten sistem, neodvisno od rezultatov. Pri tem se uporabljajo analitične metode, kjer se ocena pridobi na podlagi določenih lastnosti algoritmov segmentacije kot je strategija obdelave, kompleksnost obdelave, učinkovitost virov in ločljivost segmentacije.

V nasprotju z indirektno oceno in analitičnimi metodami, pri direktni oceni in empiričnimi metodami ocenjujemo segmentacijo na podlagi rezultatov izvedene segmentacije. V okviru empiričnih metod ločimo nenadzorovane in nadzorovane metode.


Z nenadzorovanimi metodami ocenjujemo kakovost segmentacije zgolj na podlagi rezultatov segmentacije, kar omogoča hitro in neodvisno oceno rezultatov segmentacije, saj ni potrebno pridobivati podatkov o referenčnem sloju segmentacije. Ocena temelji na skladnosti rezultatov segmentacije z nizom lastnosti segmentirane podobe, tako kot jo prepoznajo človeški možgani (Zhang et al., 2008).

Z nadzorovanimi metodami ocenjujemo kakovost segmentacije na podlagi primerjave rezultatov segmentacije z referenčnim slojem podatkov. Prednost teh metod je predvsem direktna primerjava rezultatov segmentacije z referenčnim slojem podatkov, kar omogoča oceno rezultatov na podlagi odstopanj med obema slojema. Bistvena slabost nadzorovanih metod je priprava referenčnega sloja podatkov, saj je le-ta zelo zamudna in subjektivna.

V literaturi obstaja množica zelo različnih pristopov ocene segmentacije, od katerih noben ni uveljavljen kot standardni (Neubert et al., 2008). Najpogosteje uveljavljena metoda je še vedno subjektivna ocena kakovosti segmentacije. Od objektivnih metod ji sledi množica nadzorovanih metod, zadnja leta pa je veliko truda bilo vložnega tudi v nenadzorovane metode, saj te predstavljajo en korak proti samodejnemu postopku objektivne klasifikacije.

Za potrebe raziskave kakovosti segmentacije (Švab Lenarčič et al., 2016) sem uporabila dvajset cenilk – mer kakovosti segmentacije. Glede na razdelitev, ki jo je predlagal Zhang (1996), so vse izbrane cenilke osnovane na empiričnih metodah, trinajst na nadzorovanih in sedem na nenadzorovanih. Izračun nenadzorovanih cenilk je bil izveden neodvisno od referenčnega sloja. Pri izračunu nadzorovanih cenilk je bil sloj segmentacije primerjan z referenčnim slojem. Pri tem sta bila za vsak razred pokrovnosti definirana dva objekta (slika 11):

- referenčni objekt razreda (class reference object (CRO)), ki je unija vseh referenčnih objektov določenega razreda,
- unija segmentov razreda (class segment union (CSU)), ki je unija vseh segmentov, ki se več kot 50 % prekrivajo s CRO.



Slika 11: Referenčni objekt razreda (CRO): unija vseh referenčnih objektov določenega razreda; unija segmentov razreda (CSU): unija vseh segmentov, ki se več kot 50 % prekrivajo s CRO; resnično pozitivni piksli (TP); lažno negativni piksli (FN); lažno pozitivni piksli (FP) in meje segmentov (S).

Figure 11: Class reference object (CRO): union of all reference objects of specific class; class segment union (CSU): union of all segments, which are more than 50 % covered with CRO; true positive pixels (TP); false negative pixels (FN); false positive pixels (FP) and segment borders (S).


Podrobnosti o posameznih uporabljenih cenilkah so zapisane v članku Švab Lenarčič et al. (2016). Ker preučevanje cenilk segmentacije ni primarni namen te disertacije, naj zgolj omenim, da so bile pri analizi uporabljene cenilke iz šestih skupin, glede na glavno spremenljivko izračuna. Cenilke so temeljile na:

- številu segmentov (N),
- geometričnih lastnosti segmentov (G),
- številu resnično pozitivnih pikslov (TP),
- številu lažno negativnih pikslov (FN),
- številu lažno pozitivnih pikslov (FP),
- številu lažno pozitivnih in lažno negativnih pikslov (FPN).

3.3 Zanesljivost ocene segmentacije za napoved ocene klasifikacije


Satelitski posnetki z visoko časovno ločljivostjo omogočajo pogosto pridobivanje informacij o pokrovnosti. Postopke, ki jih pogosto ponavljamo, je smiselno avtomatizirati. V primeru visoko in zelo visoko prostorsko ločljivih posnetkov, karte pokrovnosti najpogosteje pridobivamo z objektno usmerjeno klasifikacijo. Korak klasifikacije navadno lahko izvedemo samodejno. Po drugi strani segmentacija (v vseh sodobnih programskih algoritmih za segmentacijo) še vedno zahteva izkustven pristop za izbiro najboljše vrednosti parametrov. Glavni razlog za to je splošno uveljavljeno prepričanje, da rezultat segmentacije občutno vpliva na posledično kakovost klasifikacije posnetka (Dorren et al., 2003; Blaschke et al., 2004; Meinel in Neubert, 2004; Widner, 2008; Zhang et al., 2014; Kim et al., 2009; Blaschke, 2010; Clinton et al., 2010; Marpu et al., 2010; Kim et al., 2011; Myint et al., 2011; Cheng et al., 2014; Mesner in Oštir, 2014). Zato moramo izbrati optimalne parametre segmentacije (Witharana et al., 2014; Yin et al., 2013; Schouten et al., 1994), ne glede na metodo segmentacije.

Pri svojem delu sem opazala, da kljub dobri segmentaciji še nimamo zagotovila za dobro končno klasifikacijo. Rezultati končne klasifikacije so namreč poleg kakovosti segmentacije odvisni od številnih dejavnikov: klasifikacijske sheme, podatkov, ki so na voljo, izbire učnih vzorcev, klasifikacijskega algoritma, po-klasifikacije, testnih vzorcev in potrditvenih metod (Gong in Howarth, 1990). Segmenti znotraj določenega objekta se ne klasificirajo nujno v ustrezni objekt (ne glede na prostorsko ločljivost posnetka), čeprav je segmentacija zelo dobra (Švab Lenarčič et al., 2015). Primer je prikazan na slikah 12 in 13, kjer na štirih posnetkih z različno prostorsko ločljivostjo primerjamo klasifikacijo gozda.



Slika 12: Rezultat segmentacije na naslednjih posnetkih: SPOT 5 (a), RapidEye (b), WorldView-2 (c) in ortofoto (d). Modra črta predstavlja izbran referenčni poligon gozda. Poudarjena rumena črta predstavlja unije segmentov izbranega poligona gozda. Vektorski sloj segmentacije je prikazan v svetlo rumeni barvi.

Figure 12: The result of segmentation on the following images: SPOT 5 (a), RapidEye (b), World-View-2 (c) and orthophoto (d). Blue line represents the selected reference polygon of forest. Bolded yellow line represents unions of segments of selected polygon of forest. Vector segmentation layer is represented in a light yellow colour.



Slika 13: Rezultat klasifikacije segmentov, dobljenih pri enakih parametrih na naslednjih posnetkih: SPOT 5 (a), RapidEye (b), WorldView-2 (c) in ortofoto (d). Modra črta predstavlja izbran referenčni poligon gozda. Rdeča črta predstavlja mejo unije segmentov izbranega poligona gozda. Segmenti, klasificirani kot gozd, so združeni in obarvani zeleno. Segmenti, ki niso bili klasificirani kot gozd, so združeni in obarvani svetlo sivo.

Figure 13: The result of classification of segments, obtained with the same parameters on the following images: SPOT 5 (a), RapidEye (b), World-View-2 (c) and orthophoto (d). Blue line represents the selected reference polygon of forest. Red line represents unions of segments of selected polygon of forest. Segments, classified as forest, are merged and coloured in green. Segments, not classified as forest, are merged and coloured light gray.

Ocena korelacije med kakovostjo segmentacije in kakovostjo klasifikacije bi bila zelo pomembna za vsakogar, ki bi imel namen avtomatizirati postopek objektno usmerjene klasifikacije, saj bi zmanjšala količino uporabnikovega posredovanja, potrebnega za natančno nastavitev parametrov segmentacije. Kljub temu dejanska korelacija med oceno segmentacije ter oceno klasifikacije doslej še ni bila ocenjena. Zato sem naredila študijo, kjer sem ugotavljala, ali katera od cenilk kakovosti segmentacije omogoča določitev takšnih parametrov segmentacije, ki pripeljejo do najboljše možne kakovosti klasifikacije opazovanih razredov pokrovnosti. V študiji so bile narejene segmentacije s sto kombinacijami parametrov segmentacije (deset vrednosti parametrov merila in deset vrednosti parametra združitve). Kakovost segmentacije je bila ocenjena z dvajsetimi cenilkami. Na vseh segmentacijah je bilo s tremi klasifikatorji klasificiranih pet razredov pokrovnosti. Kakovost klasifikacije je bila ocenjena s sedmimi merili kakovosti. Korelacija med oceno kakovosti segmentacije in klasifikacije za vse kombinacije cenilk in mer je bila računana na dveh intervalih. Podrobnosti študije so opisane v članku Švab Lenarčič et al. (2016). V nadaljevanju tega poglavja povzemam bistvene ugotovitve.


Za numerično določitev linearne korelacije med cenilkami kakovosti segmentacije ter merami kakovosti klasifikacije je bil iz njihovih rezultatov izračunan Pearsonov koeficient korelacije (enačba (4)):

$$r_{X,Y} = \frac{\text{kovarianca}(X,Y)}{\sigma_X \sigma_Y}, \quad (4)$$

kjer je σ standardni odklon opazovanih mer, X mera kakovosti klasifikacije ter Y cenilka kakovosti klasifikacije. Ker nas zanimajo zgolj rezultati segmentacije, ki ni prešibka³, so bile dokončne ugotovitve postavljene zgolj na polovičnem intervalu, in sicer od parametra merilo 0 do 40.

Ocene segmentacije so bile dobljene za vse cenilke segmentacije, vse kombinacije parametrov ter vse razrede pokrovnosti. V preglednici 3 so prikazani zgolj rezultati cenilke stopnja kakovosti segmentacije⁴ (angl. segmentation quality rate (SQR)), saj ta vsebuje tako lažno pozitivne kot lažno negativne piksele.

V preglednicah 3 in 4 so zaradi boljše preglednosti grafi brez oznak. Pri vseh grafih os x predstavlja parametre segmentacije, kot je prikazano na sliki 14.



Slika 14: Prikaz oznak parametrov segmentacije na grafih disertacije. V zgornji vrsti so navedeni parametri merila, v spodnji vrsti parametri združitev.

Figure 14: Displaying segmentation parameter labels on graphs of the thesis. In the top row, the scale parameters are listed, in the lower row, the merge parameters are listed.

Preglednica 3: Rezultati stopnje kakovosti segmentacije (SQR) za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (od merila 0, združitev 0 do merila 90, združitev 90), os y predstavlja vrednost ocene segmentacije. Razpon obeh osi je enak pri vseh razredih.

Table 3: Results of segmentation quality rate (SQR) for five land cover classes. X axis represents the segmentation parameters (from scale 0, merge 0 to scale 90, merge 90), Y axis represents the value of segmentation quality evaluation. The range of each axis is the same for all classes.

Cenilka segmentacije SQR	Razred pokrovnosti				
	njiva	trava	gozd	urbano	voda

Ocene klasifikacije so bile dobljene za vse mere kakovosti klasifikacije, vse kombinacije parametrov, vse tri klasifikatorje ter vse razrede pokrovnosti. V preglednici 4 so prikazani zgolj rezultati stopnje


³ O prešibki segmentaciji govorimo, ko segment obsega območje dveh ali več geografskih objektov, pripadajočim različnim objektnim razredom. Takšnih območij (segmentov) v fazi klasifikacije ne moremo več razdeliti.

⁴ Stopnja kakovosti segmentacije (angl. segmentation quality rate) je razmereje med površino lažno negativnih (FN) in lažno pozitivnih (FP) pikselov in površino unije območij CSU in CRO. Zaželeno so vrednosti blizu 1.

kakovosti klasifikacije⁵ (classification quality rate CQR) klasifikatorja kNN, saj ta mera vsebuje tako lažno pozitivne kot lažno negativne piksele, izračun je primerljiv z izračunom cenilke stopnje kakovosti segmentacije, klasifikator kNN pa je dal najboljše rezultate.

Preglednica 4: Rezultati stopnje kakovosti klasifikacije (CQR) za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (od merila 0, združevanje 0 do merila 90, združevanje 90), os y predstavlja vrednost ocene klasifikacije. Razpon obeh osi je enak pri vseh razredih.

Table 4: Results of classification quality rate (CQR) for five land cover classes. X axis represents the segmentation parameters (from scale 0, merge 0 to scale 90, merge 90), Y axis represents the value of classification quality evaluation. The range of each axis is the same for all classes.



Zanesljivost ocene segmentacije za napoved ocene klasifikacije je bila osnovana na njuni korelaciji. V primeru močne korelacije bi morali parametri, uporabljeni pri segmentaciji z najboljšo oceno, omogočiti izvedbo najboljše ocenjene klasifikacije. Na osnovi primerjave rezultatov vseh segmentacij, vseh klasifikacij ter vseh njunih korelacij sem ta sklep potrdila. Omeniti moram, da zelo dobra segmentacija (glede na naše cenilke) ne prinaša nujno klasifikacije z zelo dobro kakovostjo. Primer je npr. klasifikacija trave (glej preglednici 3 in 4), kjer v primeru močne korelacije in dobre segmentacije dobimo sicer najboljši rezultat klasifikacije, ki pa je še vedno slab (stopnja kakovosti klasifikacije je le 29 %).

V primeru močne korelacije so torej cenilke segmentacije dobri indikatorji (relativne) kakovosti klasifikacije. Večina cenilk je lahko zelo zanesljiva pri določitvi meje za prešibko segmentacijo. Ko pa govorimo o zanesljivosti cenilk za najboljšo oceno kakovosti klasifikacije, se lahko zaradi velike spremenljivosti in nepredvidljivosti korelacij zanesemo le na nekaj nenadzorovanih cenilk segmentacije.

3.4 Način izbire najboljših rezultatov posameznega sklopa

Upoštevajoč dejstva in ugotovitve, zapisana v podpoglavjih 3.1 - 3.3, je odločitev o najustrežnejšem postopku (metodi, vhodni podobi, algoritmu, osnovni enoti idr.) osnovana na šestih merah kakovosti rezultata, ki ga določen postopek omogoča. Štiri od tega so mere natančnosti klasifikacije: izdelovalčeva in uporabnikova natančnost, F-mera ter skupna natančnost. Tem meram dodajam čas računanja klasifikacije, vendar bo ta na odločitev o najboljšem postopku vplival le v primeru občutne razlike med rezultati. Ker je običajno čas računanja same klasifikacije veliko krajši v primerjavi s časom priprave

⁵ Stopnja kakovosti klasifikacije (angl. classification quality rate (CQR)) je razmerje med številom resnično pozitivnih (TP) pikslov in vsoto resnično pozitivnih (TP), lažno negativnih (FN) in lažno pozitivnih (FP) pikslov. Zaželeno so čim višje vrednosti, najvišja je 100 %.

podatkov, v primeru različnega postopka priprave podatkov pri odločitvi o najustreznejšem rezultatu opisno upoštevamo tudi kompleksnost postopka.

Rezultate primerjam na osnovi primerjalnih tabel, ki so prilagojene posameznemu testu. Običajno v tabelah niso vsebovane vse mere kakovosti, večinoma zadoščata F-mera in skupna natančnost klasifikacije.


4 UPORABLJENI PODATKI

Cilj doktorske disertacije je na osnovi časovne vrste satelitskih posnetkov klasificirati pokrovnost študijskega območja. V prvi vrsti to zahteva izbiro študijskega območja, satelitskih posnetkov in referenčnih podatkov.

4.1 Študijsko območje

Kot študijsko območje sem izbrala večje območje severovzhodne Slovenije za končne izračune ter manjše podobmočje za hitra testiranja določenih metod.

Študijsko območje Pomurje je glavno študijsko območje in zajema večji del Pomurja, enega glavnih poljedeljskih območij Slovenije (slika 15, polna rdeča črta). Območje veliko 625 km² (25 km x 25 km) pokriva Panonsko nižino in okoliško hribovje. Osnovni tipi pokrovnosti so njive, travniki in vinogradi (analiza podatkov RABA). Glavne značilnosti kmetijskih zemljišč so njihova majhnost in razdrobljenost. Povprečna velikost kmetijskega zemljišča na desnem bregu reke Mure je približno 1 ha, na levem celo 0,4 ha, najdemo pa tudi manjše od 0,1 ha, pri čemer so njive dolge in ozke (analiza podatkov GERK). Povprečna letna količina padavin v zadnjih štirideset letih je manj kot 900 mm, kar je najmanj v Sloveniji (ARSO, 2016). Namakalna infrastruktura je potrebna, a žal ni pogosta. Najpogostejše poljščine so koruza, pšenica, ječmen, oljna ogrščica, tritikala in oljna buča (analiza podatkov GERK).



Slika 15: Študijsko območje Pomurje (polna rdeča črta) in študijsko območje Murska Sobota (črtkana rdeča črta)

Figure 15: Study area Pomurje (full red line) and study area Murska Sobota (hatched red line)

Podrobnejše analize in hitra testiranja določenih metod izvajam na študijskem območju Murska Sobota (slika 15, črtkana rdeča črta). Območje zajema vse osnovne tipe pokrovnosti, ki jih obravnavam v disertaciji: pet osnovnih razredov ter šest tipov poljščin.

4.2 Satelitski posnetki

Uspešno spremljanje pokrovnosti iz vesolja zahteva tako visoko časovno kot tudi visoko prostorsko ločljivost satelitskih posnetkov. Posnetki Sentinel-2, ki so ciljni podatki te disertacije, tem zahtevam zadostijo s pet-dnevnim časom ponovnega snemanja in prostorsko ločljivostjo od 10 do 20 m. Ker so posnetki Sentinel-2 na voljo šele od konca leta 2015, kot primarne posnetke za podrobnejše analize uporabim njim podobne posnetke, in sicer RapidEye ter SPOT5 Take5. Končni postopek klasifikacije na koncu izvedem tudi z obstoječimi posnetki Sentinel-2. Za uporabo vseh satelitskih posnetkov sem dobila vsa potrebna dovoljenja.

4.2.1 RapidEye


Sateliti RapidEye so del konstalacije petih satelitov, izstreljenih avgusta 2008. Vsi sateliti so opremljeni z identičnimi senzorji in umeščeni v isto orbitalno ravnino. Vključujejo sledeče spektralne kanale: modrega, zelenega, rdečega, robno-rdečega (angl. red edge) in bližnje-infrardečega (preglednica 5). Vsi kanali imajo prostorsko ločljivost 6,5 m, vendar so bili zaradi lažje primerjave s posnetki Sentinel-2 prevzorčeni na 10 m.

Preglednica 5: Valovne dolžine, ki jih zajemajo kanali RapidEye (Satellite Image Corporation, 2016a)

Table 5: Wavelengths of RapidEye bands (Satellite Image Corporation, 2016a)

Spektralni kanal	Valovna dolžina (nm)
BLUE	440 – 510
GREEN	520 – 590
RED	630 – 685
RED EDGE	690 – 730
NIR	760 – 850

Posnetki RapidEye so sicer plačljivi, vendar sem v sklopu sheme Third Party Mission Evropske vesoljske agencije (angl. European Space Agency (ESA)) za potrebe izvajanja tekočih projektov uspela brezplačno dobiti 67 posnetkov za leta 2010-2014. Tako sem imela na voljo vsaj en posnetek na mesec v času rastne sezone (med aprilom in oktobrom). V sklopu disertacije obdelujem zgolj posnetek RapidEye leta 2013, saj so za to leto posnetki najmanj oblačni. Predogledi so prikazani na sliki 16.



Slika 16: Predogledi posnetkov RapidEye za študijsko območje Pomurje

Figure 16: Previews of RapidEye satellite imagery for Pomurje study area

V nalogi uporabljam vseh pet spektralnih kanalov satelita RapidEye: modrega, zelenega, rdečega, robno-rdečega in bližnje-infrardečega.

4.2.2 SPOT5 Take5


Satelit SPOT5 je bil uspešno umeščen v orbito leta 2002. Do marca 2015 je na Zemljo pošiljal posnetke s časovno ločljivostjo 2-3 dni. Senzorji so imeli 4 spektralne kanale (zelenega, rdečega in bližnje-infrardečega s prostorsko ločljivostjo 10 m in kratko-valovnega infrardečega s prostorsko ločljivostjo 20 m) ter en pankromatski kanal s prostorsko ločljivostjo 5 m. Valovne dolžine posameznih kanalov so prikazane v preglednici 6. Uporabljeni kanali so označeni krepko.

Preglednica 6: Valovne dolžine, ki jih zajemajo kanali SPOT5 (Satellite Image Corporation, 2016b)

Table 6: Wavelengths of SPOT5 bands (Satellite Image Corporation, 2016b)

Spektralni kanal	Valovna dolžina (nm)
GREEN	500 – 590
RED	610 – 680
NIR	780 – 890
SWIR	1580 – 1750

SPOT5 Take5 je bila eksperimentalna faza snemanja s satelitom SPOT5. Satelit SPOT5 so pred koncem njegove življenske dobe locirali v takšno orbito, ki je zagotavljala pet-dnevno časovno ločljivost posnetkov. Posnetki so bili namenjeni predpripravi na prihajajoče posnetke Sentinel-2. Na javnem razpisu za izbiro območij snemanja je bilo izbrano tudi območje Pomurja. Tako sem imela za študijsko območje na voljo posnetke SPOT5 Take5 za večino aktivne dobe vegetacije, in sicer od konca aprila do začetka septembra 2015. Večina posnetkov je brezoblačnih (slika 17).



Slika 17: Predogledi posnetkov SPOT5 Take5 za študijsko območje Pomurja. Kanali GREEN, RED, NIR

Figure 17: Previews of SPOT5 Take5 satellite imagery for Pomurje study area. Channels GREEN, RED, NIR

Za potrebe disertacije uporabljam samo tri spektralne kanale SPOT5 Take5 in sicer: zelenega, rdečega in bližnje-infrardečega s prostorsko ločljivostjo 10 m. Izbrani trije kanali se ujemajo z izbranimi kanali posnetkov RapidEye in Sentinel-2, modrega kanala pa posnetki SPOT5 Take5 ne vključujejo.

4.2.3 Sentinel-2


Sentinel-2 je ena izmed petih misij, ki jih Evropska vesoljska agencija razvija v okviru evropskega programa Copernicus. Ta misija za spremljanje površine Zemlje vključuje dva satelita, ki vsebujeta optični tovor z vidnimi, bližnje-infrardečimi in kratko-valovnimi infrardečimi senzorji. Senzorji imajo 13 spektralnih kanalov (4 kanale s prostorsko ločljivostjo 10 m, 6 kanalov z 20 m in 3 kanale s 60 m) s širino pasu snemanja 290 km. Valovne dolžine obravnavanih kanalov so prikazane v preglednici 7). Uporabljeni kanali so označeni krepko. Sedaj, ko sta delujoča oba satelita, Sentinel-2 dosega časovno ločljivost pet dni na ekvatorju in dva do tri dni na srednjih geografskih širinah. Prvi izmed satelitov, Sentinel-2A, je bil izstreljen 23.6.2015, drugi, Sentinel-2B, 7.3.2017. Trenutno sta oba že polno operativna.

Preglednica 7: Valovne dolžine, ki jih zajemajo kanali Sentinel-2a (Satellite Image Corporation, 2016c)

Table 7: Wavelengths of Sentinel-2a bands (Satellite Image Corporation, 2016c)

Spektralni kanal	Valovna dolžina (nm)	Prostorska ločljivost
BLUE	458 - 523	10
GREEN	543 - 578	10
RED	650 - 680	10
NIR	785 - 900	10
RED EDGE 1	698 - 713	20
RED EDGE 2	733 - 748	20
RED EDGE 3	773 - 793	20
NIR 2	855 - 876	20
SWIR 2	1565 - 1655	20
SWIR 3	2100 - 2280	20
AEROSOL	433 - 453	60
WATER	935 - 955	60
SWIR 1	1365 - 1385	60

V nalogi uporabljam podatke Sentinel-2 za leto 2016 (od januarja do vključno začetka septembra). Časovna ločljivost posnetkov je med dva do največ deset dni, povprečno okoli pet dni. Praktično uporabna časovna vrsta posnetkov je redkejša, saj je nemalo posnetkov popolnoma ali delno oblačnih (slika 18).



Slika 18: Predogledi posnetkov Sentinel-2 za študijsko območje Pomurja

Figure 18: Previews of Sentinel-2 imagery of Pomurje study area

Ker vse predhodne analize za klasifikacijo pokrovnosti izvajam na podatkih s prostorsko ločljivostjo 10 m, pri podatkih Sentinel-2 uporabljam zgolj spektralne kanale z najvišjo ločljivostjo, tj. 10 m. To so rdeč (RED), zelen (GREEN), moder (BLUE) in bližnje-infrardeč (NIR) kanal.

4.2.4 Predobdelava satelitskih posnetkov

Analiza časovne vrste posnetkov zahteva natančno georeferencirane in radiometrično enotne posnetke.

Geometrični popravki vključujejo odstranjevanje popačenja zaradi geometrije snemanja (satelit, Zemlja) in zaradi njenega spreminjanja (stabilnost tirnice, zasuk senzorja, vrtenje Zemlje...) (Oštir, 2006). V Centru odličnosti Vesolje, znanost in tehnologije (VESOLJE-SI) so razvili samodejno procesno verigo, ki na satelitskih posnetkih opravlja geometrične popravke (Pehani et al., 2016). Omenjena procesna veriga je bila za položajno uskladitev vseh uporabljenih posnetkov uporabljena tudi v tej disertaciji.

Med radiometrične popravke prištevamo popravke senzorja, atmosferske popravke ter topografsko normalizacijo.

Z atmosferskimi popravki skušamo odstraniti vpliv ozračja, predvsem sipanja in absorpcije, na valovanje. Atmosfera lahko zmanjša ali zaduši del energije, ki osvetljuje površje, valovanje pa dodatno oslabi pot nazaj proti senzorju. Signal, ki ga slednji zazna, ni enak tistemu, ki se odbije ali ga seva opazovani del zemeljskega površja. Atmosferska korekcija še zdaleč ni enostavno rešljiv problem. Zanj sicer obstaja veliko metod, od natančnega modeliranja atmosferskih pogojev med zajemom podatkov do preprostih izračunov na osnovi podatkov v sami podobi. Kljub temu je v praksi težko določiti realne atmosferske popravke. Za potrebe disertacije in projekta Sentinel2Agri4Slovenia so bili atmosferski popravki izvedeni s programsko opremo ATCOR, ki spada med zapletene in po izkušnjah dobre modele. Naj zaradi teme disertacije še omenim ugotovitev iz pregleda literature, da so atmosferski popravki v postopku klasifikacije nepotrebni, če učne podatke pridobivamo iz posnetka, ki ga klasificiramo (Song et al., 2001; Lin et al., 2015).

V procesu topografske normalizacije z digitalnim modelom reliefa odpravljamo psevdo-geomorfološke napake, ki so inherentna posledica oblike terena ter kota in časa opazovanja (Oštir, 2006). S tem popravkom dosežemo učinek izenačitve odboja prisojnih in osojnih leg ter »izravnave« naklona. Topografsko normaliziran posnetek pridobi videz sploščenega, dvorazsežnega, enakomenrno obsijanega površja (Oštir et al., 2014). Na testnih podatkih topografska normalizacija ni bila izvedena, saj na ravnem področju Prekmurja ni bilo zaznati motečih senc reliefa, sam algoritem topografske normalizacije pa bi vrednosti nekaterih pikslov na posnetku morda popačil.

Ker geometrično in radiometrično popravljeni posnetki še vedno vključujejo oblake, ti pa so v postopku klasifikacije zelo moteči, je bilo z oblaki pokritim pikslom dodeljeno neštevilo NaN (angl. not a number). Takšno število se v postopku klasifikacije ne obravnava. Lokacije oblačnih pikslov so bile določene z že omenjenim programom ATCOR.

Na koncu so bili posnetki prevzorčeni na prostorsko ločljivost 10 m z uporabo metode najbližjega soseda.

4.3 Referenčni podatki


Na področju daljinskega zaznavanja so referenčni podatki »resnični talni podatki« (angl. ground-truth data). Ti podatki nudijo informacijo o tem kaj (v našem primeru kakšna pokrovnost) je na določeni lokaciji – geolocirani točki ali poligonu. Piksli s takšno referenčno informacijo lahko služijo kot učni (angl. train data) podatki pri nadzorovani klasifikaciji in kot kontrolni podatki (angl. validation data) pri določanju kakovosti segmentacije in klasifikacije. V nalogi so referenčni podatki uporabljeni kot učni in kot kontrolni. Pri postopku učenja je uporabljenih 30 % referenčnih podatkov, pri postopku validacije pa preostalih 70 %.

Referenčne podatke o pokrovnosti lahko pridobimo na različne načine (terenski ogled, terenske fotografije, vizualna interpretacija letalskih ali satelitskih posnetkov, ustna ali pisna zagotovila lastnikov idr.) in v različnih oblikah (tabele, baze, karte, vektorski sloj). Ne glede na način, je njihovo pridobivanje dolgotrajno in drago. Zato so za potrebe disertacije uporabljeni že obstoječi referenčni podatki⁶. K tej odločitvi dodatno primore dejstvo, da so podatki o pokrovnosti v Sloveniji sistematično pridobljeni in večinoma pravilni. Morebitna t. i. grobo pogrešena opazovanja (angl. outliers) je možno sistematično odstraniti, dodatno je možno uporabiti takšne algoritme za klasifikacijo, ki so na grobo pogrešena opazovanja čim manj občutljivi.

4.3.1 Dejanska raba kmetijskih in gozdnih zemljišč

Dejanska raba kmetijskih in gozdnih zemljišč (v nadaljevanju RABA) je vektorski sloj, namenjen predvsem za administrativne kontrole in izdelavo katastra trajnih nasadov (vinogradi, sadovnjaki, hmeljišča in oljčniki). Gre za tipološko delitev vrste rabe glede na stanje dejanske rabe ob zajemu, ki ločuje kategorije rabe kot so pozidana in sorodna zemljišča, kmetijska zemljišča, gozdovi, vode ipd. Sloj je dobljen z vizualno interpretacijo digitalnih ortofoto posnetkov in izdelan ciklično, po vsakem novem letalskem snemanju (zadnja dva sloja sta bila izdelana leta 2012 in 2015). Pripravo sloja vodi Ministrstvo za kmetijstvo, gozdarstvo in prehrano (MKGP). Podatki so v javni lasti in so prosto dostopni na spletnih straneh MKGP. Primer sloja RABA je prikazan na študijskem območju Murska Sobota (slika 19).

⁶ Za uporabo vseh referenčnih podatkov so bila pridobljena vsa potrebna dovoljenja.



Slika 19: Sloj RABA z legendo na študijskem območju Murska Sobota

Figure 19: Layer RABA and its legend on Murska Sobota study area

4.3.2 Grafična enota rabe kmetijskega gospodarstva

GERK (grafična enota rabe zemljišča kmetijskega gospodarstva) je strnjena površina kmetijskega zemljišča z enako dejansko rabo in enako vrsto kmetijske rastline, ki je v uporabi enega kmetijskega gospodarstva. Na GERK se vodijo številni atributni podatki, za potrebe klasifikacije najpomembnejši je vrsta kmetijske rastline. Posamezni poligoni GERK so združeni v skupnem sloju, ki sem ga poimenovala sloj GERK. Podatke zbira in vodi Agencija Republike Slovenije za kmetijske trge in razvoj podeželja (ARSKTRP) v okviru subvencioniranja kmetijskih površin. Zaradi subvencioniranja je sloj deležen močnih kontrol, zato je skoraj popolnoma pravilen in kot takšen zelo primeren kot referenčni in kontrolni podatek za klasifikacijo pokrovnosti.

Primer sloja GERK je prikazan na študijskem območju Murska Sobota (slika 20).



Slika 20: Sloj GERK z legendo na študijskem območju Murska Sobota

Figure 20: Layer GERK with its legend on Murska Sobota study area

4.3.3 Podatki Panvita

Panvita je zasebno podjetje s sedežem v Rakičanu (znotraj študijskega območja), osredotočeno na kmetijsko in živilsko proizvodnjo. Obdelujejo več kot 3500 ha kmetijskih površin, večinoma za pridelavo koruze, pšenice, ječmena in oljne ogrščice. Za lastne potrebe vodijo podatke o opravilih na svojih njivah. Na osnovni enoti GERK vodijo zelo podrobne podatke, kot so: podatki o oranju, sajenju (datum, vrsta poljščine), gnojenju, škropljenju, namakanju, žetvi idr. Poleg množice koristnih informacij so njihovi podatki točni, saj jih vodijo zase. Zato so kot takšni zelo primerni kot referenčni sloj klasifikacije, še posebej za klasifikacijo vrst poljščin.


Primer sloja GERK je prikazan na študijskem območju Murska Sobota (slika 21).



Slika 21: Sloj PANVITA z legendo na študijskem območju Murska Sobota

Figure 21: Layer PANVITA with its legend on Murska Sobota study area

Poleg vrste poljščine so podatki PANVITA edini v disertaciji uporabljen referenčni sloj, ki vključuje tudi datume setve in žetve določene poljščine na posameznih enotah GERK. Ti datumi so namreč pomembni za uspešno izvedbo veččasovne klasifikacije. Koledar dejavnosti na slojih GERK Panvite za glavne prijavljene poljščine 2013 je prikazan na sliki 22.



Slika 22: Koledar dogodkov na šestih glavnih poljščinah Panvite za leto 2013

Figure 22: Calendar of events of six major Panvita crops for year 2013

4.3.4 Priprava referenčnih slojev

Namen priprave referenčnih slojev je za vsako leto in vsako vrsto klasifikacije imeti en sam sloj, ki vključuje vse potrebne referenčne attribute za klasifikacijo. Za vsako obravnavano leto (2013, 2015 in 2016) sem pripravila dva referenčna sloja: referenčni sloj osnovnih razredov in referenčni sloj poljščin. Sloji so pripravljeni s kombinacijo treh zgoraj opisanih referenčnih podatkov: RABA, GERK in

PANVITA. Vsak sloj pokriva celotno študijsko območje Pomurja. Postopek pridobitve sloja je bil v splošnem sledeč:

- kjer obstaja sloj GERK, uporabimo sloj GERK,
- kjer ni sloja GERK, uporabimo sloj RABA,
- na gerke, ki obstajajo v sloju PANVITA, zapišemo attribute Panvite.

Dodatno sem za sloje določila potrebne attribute in jih zapolnila s predhodno definiranimi šiframi.

Referenčne sloje osnovnih razredov sem razdelila na pet osnovnih razredov in en razred drugo, pri čemer sem za namen disertacije izdelala in upoštevala šifrant razvrstitve razredov dejanske rabe v osnovne razrede pokrovnosti (preglednica 8).


Preglednica 8: Šifrant razvrstitve razredov dejanske rabe v osnovne razrede pokrovnosti za klasifikacijo

Table 8: The coding system for linking actual land use and land cover classification class

Šifra	Ime dejanske rabe	Razred
1100	njiva ali vrt	njiva
1150	njiva za rejo polžev	
1170	jagode na njivi	
1180	trajne rastline na njivskih površinah	
1212	matičnjak	
1240	ostali trajni nasadi	
1300	trajni travnik	trava
1320	travinje z razpršenimi neupravičenimi značilnostmi	
1420	plantaža gozdnega drevja	gozd
1500	drevesa in grmičevje	
1800	kmetijsko zemljišče, poraslo z gozdnim drevjem	
2000	gozd	
1190	rastlinjak	urbano
3000	pozidano in sorodno zemljišče	
7000	voda	voda
1211	vinograd	drugo
1221	intenzivni sadovnjak	
1222	ekstenzivni sadovnjak	
1410	kmetijsko zemljišče v zaraščanju	
1600	neobdelano kmetijsko zemljišče	
1610	kmetijsko zemljišče v pripravi	
4210	trstičje	
4220	ostalo zamočvirjeno zemljišče	
5000	suho, odprto zemljišče s posebnim rastlinskim pokrovom	
6000	odprto zemljišče brez ali z nepomembnim rastlinskim pokrovom	

Pri izdelavi šifranta je upoštevano, da se pri klasifikaciji pokrovnosti v prvi vrsti upoštevajo spektralne vrednosti kanalov. To pomeni, da se npr. park v središču mesta klasificira kot gozd in ne kot park. Prav

tako sadovnjaka ne moremo klasificirati kot sadovnjak, temveč kot ločena drevesa in travo med njimi. Ker so napačni vzorci zelo moteč faktor pri klasifikaciji, je dodan razred drugo, kamor so pripisane dejanske rabe, ki jih ne moremo enolično določiti. Dodatno so v razred drugo dodana tista območja razreda urbano, ki so na poletnem posnetku imela visoke vrednosti normiranega diferencialnega vegetacijskega indeksa (NDVI nad 0,6). V praksi to pomeni, da je iz razreda urbano izločeno visoko zeleneče drevje, travniki pred hišami ipd. Končni referenčni sloji za osnovne razrede za vsa tri testna leta in študijsko območje Murske Sobote so prikazani na sliki 23.



Slika 23: Referenčni sloji osnovnih razredov za leta 2013 (a), 2015 (b) in 2016 (c). Študijsko območje Murska Sobota.

Figure 23: Reference layers of basic land cover classes for years 2013 (a), 2015 (b) and 2016 (c). Murska Sobota study area.


Referenčni sloji poljščin so razdeljeni na šest glavnih razredov poljščin, razred druge poljščine, razred ni poljščina ter razred neznana poljščina. Pri postopku klasifikacije obravnavam zgolj glavne razrede poljščin, vse ostalo označujem kot drugo. Pri razdelitvi je za namen disertacije izdelan in upoštevan šifrant razvrstitve vrst kmetijskih rastlin (KMRS), zapisanih v sloju GERK, v razrede poljščin (preglednica 9). Glavni razredi poljščin so izbrani glede na seznam glavnih poljščin na tem območju, ki sem ga dobila od ARSKTRP.

Preglednica 9: Šifrant razvrstitve vrst kmetijskih rastlin (KMRS) v razrede poljščin za klasifikacijo

Table 9: The coding system for linking gerk crop types (KMRS) and classification crop type classes

	Šifra	Ime rabe	KMRS	Ime KMRS	Poljščina
Obravnavano	1100	njiva ali vrt	005	koruza za zrnje	koruza
			006	koruza za silažo	
			049	sladka koruza	
			001	pšenica (jara)	pšenica
			025	trda pšenica (jara)	
			801	pšenica (ozimna)	
			825	trda pšenica (ozimna)	
			009	ječmen (jari)	ječmen
			809	ječmen (ozimni)	
			013	oljna buča	oljna buča
			042	navadna buča	
			014	oljna ogrščica (jara)	oljna ogrščica
			103	oljna repica	
			104	krmna repica (jara)	
			112	krmna ogrščica (jara)	
			812	krmna ogrščica (ozimna)	
			814	oljna ogrščica (ozimna)	
			007	tritikala (jara)	tritikala
			807	tritikala (ozimna)	
Drugo	1100	njiva ali vrt	večina ostalih poljščin		druga poljščina
			1150	njiva za rejo polžev	
			1160	hmeljišče	
			1170	jagode na njivi	
			1180	trajne rastline na njivskih površinah	
	1190	rastlinjak			ni poljščina
			1192	rastlinjak s sadnimi rastlinami	
			1211	vinograd	
			1212	matičnjak	
			1221	intenzivni sadovnjak	
			1222	ekstenzivni sadovnjak	
			1230	oljčnik	
			1240	ostali trajni nasadi	
			1300	trajni travnik	
			1320	travinje z razpršenimi neuprav. znač.	
			1610	kmetijsko zemljišče v pripravi	
	vse rabe	000	ni v uporabi	neznana poljščina	
		333	tehnično ali drugo sredstvo		
		555	zahtevak ni bil oddan		
777		površina v odstopu			

Končni referenčni sloji za razrede poljščin za vsa tri testna leta in študijsko območje Murske Sobote so prikazani na sliki 24.



Slika 24: Referenčni sloji poljščin za leta 2013 (a), 2015 (b) in 2016 (c). Študijsko območje Murska Sobota.

Figure 24: Reference layers of basic crop type classes for years 2013 (a), 2015 (b) and 2016 (c). Murska Sobota study area.

5 PROGRAMSKA OPREMA IN OSNOVNI PRINCIPI DELOVANJA UPORABLJENIH ALGORITMOV

Pri delu je bila uporabljena programska oprema ENVI, WEKA in R. V nadaljevanju opisujem namen uporabe posamezne opreme ter kratek osnovni princip delovanja uporabljenih algoritmov.

5.1 Segmentacija

Segmentacija je bila izvedena s programsko opremo ENVI (ENVironment for Visualizing Images), ki je celovito programsko orodje za obdelavo in analizo daljinsko zaznanih posnetkov. Vsebuje številne postopke in algoritme: od geometričnih in radiometričnih popravkov posnetkov do segmentacije, klasifikacije, poklasifikacije, nadaljnje uporabe klasificiranih podatkov ter mnogih drugih obdelav in analiz. Algoritmi delujejo večinoma na pristopu, ki vodi uporabnika korak za korakom skozi kompleksne naloge (tako imenovani »čarovnik«).

Bistvena pomanjkljivost je razpoložljivost različnih algoritmov za segmentacijo. Vgrajen je zgolj algoritem razvodij (watershed), ki sicer v splošnem nudi visoko kakovost segmentacije. Nagnjenost k prekomerni segmentaciji je možno izboljšati z algoritmom za združevanje segmentov. V sam algoritem segmentacije sicer ne moremo posegati, lahko pa v programskem jeziku IDL (v katerem je ENVI razvit in ga lahko dokupimo) prilagajamo postopek segmentacije in ga vključimo v druge postopke obdelave. Uporabniki z več znanja programiranja lahko v IDL sami napišejo poljuben algoritem segmentacije in ga vključijo v ENVI.

Podrobneje je programska oprema ENVI FX obravnavana v poglavju 6.

5.2 Enočasovna in kvazi veččasovna klasifikacija

Kvazi veččasovna klasifikacija je enočasovna klasifikacija, kjer kot vhodni podatek uporabimo podobe različnih časov. Postopek enočasovne in kvazi veččasovne klasifikacije je bil posledično povsem enak, zato ga opisujem skupaj.

5.2.1 Atributi, osnovna enota in določitev učnih vzorcev

Določanje optimalnih atributov (tako spektralnih kot teksturnih) je ena izmed glavnih nalog disertacije. Zato sem postopke klasifikacije izvajala z najrazličnejšimi atributi, opisanimi in izbranimi v naslednjih poglavjih. Atributi so preračunani in vezani na izbrano osnovno enoto kartiranja. Tudi osnovno enoto kartiranja sem izbirala v sklopu disertacije.

Učni vzorci so bili zaradi primerljivosti rezultatov vedno izbrani na enak način, in sicer:

- referenčni sloj: za posamezno leto vedno enak,
- količina: 30 % vseh osnovnih enot,

- način izbire: pikselsko osnovan. Samo enkrat (prvič) sem naključno izbrala 30 % pikslov/točk. Te točke sem uporabila pri vseh nadaljnjih klasifikacijah. Izbira učnih osnovnih enot se je izvajala s preprostim presekom izbranih točk in sloja osnovnih enot.
- čistost: vsaj 80 % učne osnovne enote mora biti pokrite z istim referenčnim razredom.

5.2.2 Klasifikator

Klasifikator je algoritem, ki iz niza značilnosti množice objektov pripisuje neznane objekte v njihove pripadajoče razrede. Za klasifikacijo pokrovnosti so na voljo številni klasifikatorji. Vsak ima svoje prednosti in slabosti. Namen naloge sicer ni preučevanje posameznih klasifikatorjev in njihova primerjava, vendar sem kljub temu s standardnimi nastavitvami primerjala rezultate štirih klasifikatorjev, vgrajenih v programsko opremo WEKA 3.7: podatkovno rudarjenje k-najbližji sosed (angl. k-Nearest neighbour data mining classifier (kNN)), umetna nevronska mreža (angl. Artificial Neural Network classifier (ANN)), naključno drevo (angl. Random Tree classifier (Rtree)) in metoda podpornih vektorjev (angl. Support Vector Machine classifier (SVM)). Najboljše in najzanesljivejše rezultate sem dobila s klasifikatorjem ANN. Primernost tega klasifikatorja za klasifikacijo (tudi veččasovno) so potrdili tudi nekateri avtorji. Cetin (2004) npr. ugotavlja, da s klasifikatorjem ANN pridobimo bolj točne rezultate v primerjavi z drugimi klasifikatorji, pri čemer je celoten postopek tudi bolj robusten. Ker v sklopu disertacije analiziram široko množico vhodnih podatkov in parametrov, in ker želim, da so ti čim bolj primerljivi, sem se odločila klasifikacijo izvajati zgolj s klasifikatorjem ANN.

Kot rečeno, je uporabljen klasifikator vgrajen v programsko opremo WEKA (Waikato Environment for Knowledge Analysis). WEKA je priljubljen sestav programske opreme za strojno učenje, napisan v Javi (Rakhman et al., 2009). Vsebuje zbirko orodij za vizualizacijo in algoritme za analizo podatkov in napovedno modeliranje, pri čemer je vse enostavno dostopno preko grafičnih vmesnikov. Glavna prednost programa WEKA je prosta dostopnost pod splošnim dovoljenjem GNU (GNU General Public Licence). WEKA podpira več standardnih nalog podatkovnega rudarjenja, natančneje: predobdelavo podatkov, gručenje, klasifikacijo, regresijo, vizualizacijo in izbiro atributov.

Pri procesu gradnje umetnih nevronske mreže (algoritem ANN) se v programu WEKA uporablja funkcija večslojnega perceptrona (angl. Multilayer Perceptron (MLP) function). Ta funkcija uporablja algoritem učenja z vzratnim razširjanjem (angl. backpropagation). To zagotavlja močno učno bazo s prednostmi, kot so nelinearno kartiranje in toleranca šuma.

Kot velika večina klasifikatorjev, ima tudi klasifikator ANN na voljo številne parametre, ki vplivajo na proces učenja. Uporabnik bi moral poznati osnove klasifikatorja in vrednosti parametrov nastaviti glede na svoje potrebe. Ker sem s privzetimi parametri (angl. default) dobila dobre rezultate, se globlje v optimizacijo parametrov nisem spuščala. Zelo verjetno je, da bi z optimizacijo rezultate vsaj rahlo izboljšala, vendar je bil cilj primerjava različnih klasifikacij. In pri primerjavi je pomembno, da so

uporabljeni enaki parametri, četudi privzeti. Poleg tega je analiza in primerjava klasifikatorjev primerna kot samostojna tema kakšne večje raziskave.

5.3 Klasifikacija na osnovi časovnih vrst

Za klasifikacijo na osnovi časovnih vrst sem uporabila odprtokodni programski paket dtwSat, osnovan na algoritmu TWDTW, ki je po mnenju številnih avtorjev (Dohare in Devi, 2011; Prekopcsak in Lemire, 2012) trenutno najprimernejši algoritem za ta namen.

Programski paket dtwSat je napisan v programskih jezikih R in Fortran. Podpira celoten postopek klasifikacije pokrovnosti z upoštevanjem časovne vrste, od izbire časovnih vzorcev do prikaza in ocene rezultatov. Za klasifikacijo je v paketu vgrajena metoda časovno uteženega dinamičnega časovnega prilagajanja (angl. Time-Weighted Dynamic Time Warping (TWDTW)), ki uporablja niz več-kanalnih satelitskih posnetkov. Programski paket so sprogramirali Maus in sodelavci (2016). V nadaljevanju povzemam opis programskega paketa po Maus et al. (2017).

Paket dtwSat je osredotočen na specifični primer časovnih analiz, in sicer na analize časovnega niza satelitskih posnetkov. Njegova metoda TWDTW je osnovana na standardni metodi DTW, ki primerja časovni podpis znanega dogodka (npr. človeškega govora) z neznanim časovnim podpisom. TWDTW metodo DTW nadgrajuje, tako da upošteva sezonske spremembe različnih tipov pokrovnosti. Npr. cikel rasti soje in koruze ima razpon med 90 do 120 dni, medtem ko ima cikel rasti sladkornega trsa razpon med 360 do 720 dni. Časovna vrsta s ciklom daljšim od 180 dni zelo verjetno ne pripada soji ali koruzi. Dodatno se upošteva čas, ko je določena vegetacija aktivna (npr. maja ali julija). TWDTW pri klasifikaciji pokrovnosti tako upošteva amplitudo in fazo časovne krivulje, s čimer je klasifikacija zelo uspešna (Maus et al., 2016). Žal pa je takšna analiza časovno potratna, kar potrjujeta npr. Chen et al. (2012) in Prekopcsak in Lemire (2012).

Za cikel rasti osnovnih razredov sem določila kar celo obravnavano leto. Ker poljščine ne rastejo celotno leto, sem njihove cikle omejila glede na podatke Panvita (slika 22) od sajenja do žetve. Za vsako poljščino je bil določen svoj cikel.

6 PREUČITEV POSTOPKOV SEGMENTACIJE

Vodilna metoda za klasifikacijo optičnih posnetkov z visoko prostorsko ločljivostjo je objektno usmerjena klasifikacija. Gre za zahteven postopek razpoznavanja mej objektov (segmentacija) in razvrščanja segmentov v izbrane objektne razrede (klasifikacija). Ker s segmentacijo fiksiramo lokacijo, velikost in obliko objektov, ima segmentacija ključen in neposreden vpliv na kakovost končne klasifikacije (Coillie et al., 2008; Marpu et al., 2010). Zato je nikakor ne smemo vzeti kot trivialen postopek in zasluži več raziskovalne pozornosti.

V tem poglavju teoretično preučujem različne postopke segmentacije. V prvem delu je opisana primerjava algoritmov in programske opreme za segmentacijo. Glede na dobljene smernice sledi drugo podpoglavje, kjer podrobno preučim algoritem segmentacije ENVI FX ter vpliv njegovih spremenljivk na segmentacijo. Ugotovitve služijo kot osnova za izboljšavo postopka segmentacije in jih praktično uporabim v nadaljevalnih poglavjih.

6.1 Primerjava algoritmov in programske opreme za segmentacijo

Za segmentacijo daljinsko zaznanih podob so razviti številni algoritmi, ki so – odvisno od namena analize – različno uspešni. Za kakovostno segmentacijo je ključnega pomena poznavanje algoritmov in primernosti njihove uporabe v specifičnih primerih.

V nadaljevanju je na kratko predstavljen izbor algoritmov za segmentacijo optičnih posnetkov daljinskega zaznavanja in možnosti njihove uporabe. Prav tako je podan pregled programske opreme za objektno klasifikacijo, s poudarkom na postopku segmentacije. Podrobnejše informacije o izvedeni analizi lahko bralec najde v (Švab Lenarčič et al., 2015).

6.1.1 Primerjava algoritmov

Segmentacija se uporablja tako v daljinskem zaznavanju kot tudi v številnih drugih vedah (npr. v medicini, strojnemu vidu, prepoznavanju oseb in predmetov). Zato so poznane številne tehnike segmentiranja, pogosto prilagojene posebnemu namenu. Žal večina algoritmov ne upošteva večspektralnih in prostorskih informacij, zato za segmentacijo daljinsko zaznanih posnetkov niso vselej primerni. Razvoj algoritmov segmentacije daljinsko zaznanih podob se je začel z začetkom dostopnosti prostorsko visokoločljivih posnetkov (Schiewe, 2002; Blaschke, 2010), saj pikselno usmerjene metode za tovrstne posnetke niso nujno najprimernejše. Pikselno usmerjene metode so bile namreč prvotno razvite za klasifikacijo satelitskih posnetkov srednje in nizke ločljivosti. Če te metode uporabljamo za klasifikacijo visokoločljivih posnetkov (prostorske ločljivosti manj kot 10 m), so geografski objekti prikazani z množico pikslov in nemalokrat preštevilnimi podrobnostmi (Gao in Mas, 2008). Vzrok je v razmerju med velikostjo piksla in geografskim objektom, ki je na visokoločljivih posnetkih bistveno manjše kot na srednje ali nizkoločljivih posnetkih (Blaschke, 2010). K revolucionarnemu premiku v

razvoju segmentacije daljinsko zaznanih posnetkov je leta 2000 pripomogla programska oprema eCognition (Baatz in Schape, 2000; Blaschke, 2010). Pred tem letom v strokovni literaturi praktično ni zaznati uporabe tovrstnih segmentacij. Po tem se je razvoj drastično povečal in število algoritmov še vedno narašča.

S hitrim razvojem segmentacije daljinsko zaznanih podob je postala pomembna tudi kategorizacija in pregled obstoječih algoritmov segmentacij. Dey s sodelavci (2010) v preglednem članku navaja, da so v prvotnih kategorizacijah algoritmov segmentacije daljinsko zaznanih posnetkov (Reed, 1993; Pal in Pal, 1991; Schiewe, 2002; Shankar, 2007) algoritme delili na osnovi robov (angl. edge based), točk/pikslov (angl. point/pixel based), regij (angl. region based) ali njihove kombinacije, t. i. hibridni pristop (angl. hybrid approach). Guo in njegovi sodelavci (2005) so algoritme kategorizirali na osnovi barve (angl. colour based) in teksture (angl. texture based). Najnovejšo kategorizacijo, uporabljeno zgolj za metode analiz podatkov optičnega daljinskega zaznavanja, so predlagali Dey in sodelavci (2010). Od starejših kategorizacij se razlikuje v tem, da jasno razlikuje metode segmentacije glede na tehnike tvorjenja segmentov. Kategorizacijo so razčlenili na tri skupine:

- kategorizacija glede na pristop k analizi posnetka,
- kategorizacija glede na merilo homogenosti in
- kategorizacija glede na postopek tvorjenja segmentov.

Skupine so medsebojno odvisne, zato lahko posamezen algoritem spada v več različnih skupin.

6.1.2 Primerjava programske opreme

Uporabnikom je na voljo širok nabor komercialne programske opreme za segmentacijo, vendar je ta programska oprema avtorsko zaščitena in se praviloma lahko uporablja le kot črna skrinjica. Poleg tega predstavlja nakup komercialnega programa velik finančni zalogaj, saj se cene licenc za uporabo programov gibljejo od nekaj tisoč pa do več kot deset tisoč evrov. Odlično alternativo komercialnim programom predstavljajo prosti in odprtokodni programi, ki so brezplačni in uporabnikom omogočajo svoboden razvoj programa, saj prosto razpolagajo z izvorno kodo in vso dokumentacijo. Zaradi transparentnosti algoritmov, možnosti lastnega razvoja in brezplačnosti so takšni programi zelo priljubljeni predvsem pri raziskovalcih pa tudi pri podjetnikih.


Poleg vidika lastništva se programi za segmentacijo med seboj razlikujejo po izvedbi postopka segmentacije (nabor algoritmov, dodatne funkcije za izboljšavo segmentacije, trajanje obdelave, največja velikost območja...), možnosti predobdelave posnetkov in urejanja rezultatov klasifikacije ter po uporabniški izkušnji. Izbira najprimernejšega programa za segmentacijo je odvisna predvsem od namena analize, ki jo uporabnik izvaja. V nadaljevanju so naštet programi za objektno klasifikacijo, ki sem jih izbrala za analizo, pri čemer je bil poudarek dan na implementaciji postopka segmentacije. V izbor so bili uvrščeni programi za segmentacijo daljinsko zaznanih podob, ki jih najpogosteje zasledimo

v strokovni literaturi, spletnih iskalnikih in posebnih iskalnikih prostih in odprtokodnih programov. Programska oprema je bila kategorizirana glede na možnosti dostopa:

- komercialna programska oprema:
 - eCognition,
 - ENVI – Feature Extraction,
 - drugi komercialni programi (BerkleyImgseg, ERDAS IMAGINE Objective, IDRISI (TerrSet) in InfoPACK);
- odprtokodna programska oprema:
 - InterIMAGE,
 - OrfeoToolbox,
 - drugi prosti in odprtokodni programi (SPRING, EDISON, PARBAT, SAGA in MSEG);
- lastniška programska oprema (EWS, RHSEG, SCRM in SegSAR) .

Neubert s sodelavci (2006) je opravil obširno raziskavo programske opreme za segmentacijo, v katero je vključil kar 21 programov. Njegovi izsledki so, da so zaradi raznolikosti vgrajenih algoritmov rezultati segmentacije izredno različni. Primernost posameznega programa je zelo odvisna od namena segmentacije. Kljub tehnološkemu napredku v zadnjih desetih letih ostajajo najbolj pereč problem programov za segmentacijo tehnične težave, kot so pomanjkanje procesne stabilnosti in robustnost uvoznih rutin, ki so odvisne od velikosti in formata podobe, radiometrične ločljivosti, podatkovne strukture in parametrov projekcije.

Na primeru posnetka RapidEye izbranega območja v Sloveniji sem preizkusila delovanje vseh programov za segmentacijo, do katerih sem imela možnost dostopa (glej Švab Lenarčič et al, 2015). Preizkusila sem vseh 17 zgoraj navedenih programov. Večina programov je za namen objektno usmerjene klasifikacije neprimernih, saj se pri njihovi uporabi kaj hitro srečamo z nevšečnostmi, kot so: izhodni format segmentacije je raster, vhodni posnetek lahko ima zelo omejeno velikost in format, za segmentacijo je na voljo zgolj koda, brez uporabniškega vmesnika, programi so nestabilni, v nam neznanem jeziku, npr. kitajščini, potrebni so vzorčni primeri razredov idr. V nadaljevanju zato povzemam delovanje štirih programov, ki so se izkazali kot najboljši in sem jih izbrala za podrobnejšo analizo. To sta dva komercialna – eCognition in ENVI FX – in dva odprtokodna programa – InterIMAGE in OrfeoToolBox. Primere segmentacij teh programov prikazuje slika 25.



Slika 25: Primeri segmentacij posnetka RapidEye, izvedenih s podobnimi nastavitvami in z različno programsko opremo: eCognition (a), ENVI FX (b), InterIMAGE (c) in OrfeoToolbox (d).

Figure 25: Examples of segmentation of RapidEye image, obtained by similar settings and different software: eCognition (a), ENVI FX (b), InterIMAGE (c) and OrfeoToolbox (d).

Izbrani programi so bili analizirani predvsem glede ocene zmogljivosti in podpore izvedbi postopka segmentacije. Posamezni programi so bili med seboj primerjani glede vhodnih in izhodnih podatkov, segmentacije in uporabniškega vidika.

V kategoriji vhodni in izhodni podatki sem proučila zmogljivost glede formatov zapisa podatkov, velikosti datoteke (velikost območja obdelave) in radiometričnih ločljivosti podatkov. V drugi kategoriji sem ocenila podporo izvedbi postopka segmentacije z razpoložljivostjo različnih algoritmov segmentacije in orodij za oceno kakovosti segmentacije ter s hitrostjo segmentiranja podob in možnostjo uporabe raznovrstnih podatkov (tematski podatki). V zadnji kategoriji sem ocenila splošno uporabniško izkušnjo s posameznim programom. Povzeti rezultati analize so podani v naslednjih podpoglavjih.

6.1.2.1 Vhodni in izhodni podatki

Vsi štirje programi omogočajo uporabo rastrskih in vektorskih podatkov v standardnih zapisih kot so TIF, IMG, SHP in drugi. Omejitev glede radiometrične ločljivosti ima samo InterIMAGE, v katerem je možno obdelovati največ 8-bitne posnetke. eCognition omogoča tudi uporabo oblaka točk laserskega skeniranja, zapisanega v formatu LAS. V vseh programih je možno zapisati rezultate segmentacije v datoteko SHP. Velikost območja obdelave ni omejena v komercialnih programih ENVI FX in eCognition, medtem ko obstajajo omejitve glede velikosti datoteke za segmentacijo pri obeh odprtokodnih programih. Za segmentacijo s programom InterIMAGE se priporoča uporaba datotek velikosti do 3.000 x 3.000 pikslov, OTB omogoča segmentacijo večjih datotek, vendar teoretično manjših od 10.000 x 10.000 pikslov (v praksi pa nisem mogla obdelati posnetka, večjega od 1.000 x 1.000 pikslov).

6.1.2.2 Segmentacija

Z izjemo programa ENVI FX, ki ima za segmentacijo na voljo le en algoritem, imajo preostali trije programi na voljo niz različnih algoritmov, ki jih je možno tudi kombinirati med seboj. Vsi programi razen OrfeoToolbox omogočajo uporabo dodatnih tematskih podatkov v postopku segmentacije. eCognition podpira uporabo tematskih podatkov v rastrski in vektorski obliki, InterIMAGE le v vektorski obliki, ENVI FX pa samo v rastrski, vendar lahko v programu ENVI vektorski podatek zlahka pretvorimo v rastrskega. Hitrost segmentacije je najvišja v programih ENVI FX in OTB. V programu eCognition je malo počasnejša, v programu InterIMAGE pa občutno počasnejša. Kakovost segmentacije je možno oceniti samo z orodji, vključenimi v OTB.

6.1.2.3 Uporabniški vidik

Vsi štirje programi omogočajo izvedbo vseh faz objektne klasifikacije, t.j. segmentacije in klasifikacije. Z izjemo programa InterIMAGE ostali omogočajo tudi celotno predobdelavo posnetkov in izdelavo končnega izdelka na podlagi klasifikacije. Zaradi obsežnosti funkcionalnosti, ki jih podpirata, sta eCognition in OTB manj pregledna in zahtevnejša za uporabo, medtem ko ENVI FX kljub obsežni funkcionalnosti ostaja uporabniku prijazen.

Slabost obeh komercialnih programov je seveda tudi visoka cena. OTB in InterIMAGE poleg tega, da sta brezplačna, dovoljujeta uporabnikom uporabo izvirne kode in lasten razvoj programa.

6.1.2.4 Dobljene smernice glede algoritmov in programske opreme

Zaradi raznolikosti vgrajenih algoritmov in celotnih postopkov segmentacije so rezultati segmentacije izredno različni. Enostavnega recepta za izbiro najprimernejše programske opreme za segmentacijo ni – vsaka ima tako prednosti kot tudi slabosti. Primernost posameznega programa je zelo odvisna od namena segmentacije, znanja o obdelavi satelitskih posnetkov, obvladanja določenega programskega

jezika, sredstev, ki jih imamo na voljo, velikostjo območja obdelave ter potrebe po hitrosti procesiranja. Pomembno je tudi, ali že imamo na voljo programsko opremo za predobdelavo posnetkov, za klasifikacijo rezultata segmentacije, idr.

Potrebno se je zavedati, da četudi ima uporabnik za določeno aplikativno nalogo na voljo najprimernejšo programsko opremo, so rezultati segmentacije še vedno zelo odvisni od znanja (vsestranskega razumevanja delovanja posamičnih korakov v postopku segmentacije) in izkušenj uporabnika. Brez zadržkov lahko trdimo: slabo ali pomanjkljivo znanje – slaba segmentacija. Ne moremo pa trditi, da velja tudi obratno. Zelo verjetno pa je, da bo uporabnik s primernim znanjem tudi brez finančnega vložka izvedel segmentacijo zavidljive kakovosti.

Ker imamo v VESOLJE-SI na voljo programsko opremo ENVI ter v njem implementiran algoritem za segmentacijo ENVI FX, sem se glede na izvedeno analizo algoritmov in programske opreme za segmentacijo odločila, da za vse postopke segmentacije, ki se tičejo te disertacije, uporabim zgolj algoritem ENVI FX. Pri tem lahko ob pravilni uporabi pridobim segmentacije zelo dobre kakovosti. Zato sem preučila izbrani algoritem ter vpliv njegovih spremenljivk na segmentacijo.

6.2 Preučitev algoritma ENVI FX ter vpliva njegovih spremenljivk na segmentacijo


Algoritmi segmentacije običajno vključujejo parametre, ki omogočajo prilagajanje segmentacije uporabnikovim potrebam. Uporabniki na proces segmentacije gledajo kot na »črno magijo« (Smith in Morton, 2010). Običajno lahko samo tisti uporabniki, ki so seznanjeni z različnimi lastnostmi pokrovnosti oz. objektov zanimanja, ter razumejo proces segmentacije, relativno učinkovito izberejo ustrezne parametre segmentacije. Toda to v praksi ni vedno možno (Zhang et al., 2010). Običajna praksa je, da uporabnik v postopku segmentacije uporabi osnovni daljinsko zaznan posnetek (vse spektralne sloje) ter algoritem segmentacije, ki ga ima na voljo. Na osnovi poskušanja sicer spreminja parametre, globlje pa se v postopek segmentacije ne spušča. Ker pa je celotna klasifikacija predvidoma močno odvisna od kakovosti segmentacije, mora biti postopek segmentacije skrbno izveden. V uvodu poglavja so najprej navedeni osnovni koraki algoritma ENVI FX. V nadaljevanju jih podrobneje razložim ter nakažem njihov vpliv na segmentacijo.

Postopek segmentacije v ENVI Feature Extraction temelji na patentirani tehnologiji, ki jo je izumil Xiaoying (2009). Segmentacija vključuje sledeče korake (Exelis, 2015):

- izračun podobe gradientov ali podobe intenzitete iz vhodne podobe,
- izračun kumulativne porazdelitvene funkcije iz podobe gradientov/intenzitete,
- prilagoditev podobe gradientov/intenzitete glede na izbrano stopnjo merila (izračunano iz kumulativne porazdelitvene funkcije),
- segmentacija prilagojene podobe gradientov/intenzitete z uporabo algoritma razvodij.

6.2.1 Delovanje algoritma razvodij

Algoritem razvodij (angl. watershed algorithm) temelji na konceptu hidroloških razvodij (slika 26). Predpostavljeno je, da voda vedno teče proti najnižji točki. Pokrajino začnemo polniti z vodo v njeni najnižji točki. Nastajajo z vodo napolnjene regije, ločene z jezovi, imenovanimi razvodja (angl. watersheds) (Roerdink in Meijster, 2000). Ko nivo vode doseže najvišji vrh v pokrajini, se postopek ustavi.



Slika 26: Relief jakosti gradienta (a), podoba jakosti gradienta (b), podoba razvodij gradienta (c) in relief razvodij gradienta (d) (Cousty, 2007)

Figure 26: Relief of the gradient magnitude (a), Gradient magnitude image (b), Watershed of the gradient (c) and Watershed of the gradient (relief) (d) (Cousty, 2007)

Podoben postopek se dogaja pri obdelavi digitalnih posnetkov. Temnejši kot je piksel, nižja je njegova »višina«; takšen piksel se imenuje minimum. Algoritem razvodij, ki sta ga napisala Vincent in Soille (1991) in se uporablja pri postopku ENVI FX, razvrsti piksele s povečevanjem vrednosti sivine piksla, nato začne z najnižjimi (minimum) piksli in »poplavi« posnetek, s čimer ga razdeli v regije (območja s podobnimi vrednostmi piksla) glede na izračunana razvodja. Rezultat je segmentirana podoba, kjer je vsakemu območju dodeljena srednja spektralna vrednost vseh pikslov tega območja.

Funkcija razvodij, vgrajena v postopek ENVI FX, uporabi algoritem razvodij na eno-kanalni podobi. Največkrat so to podobe gradienta, tj. podobe, ki vsebujejo značilne robove (Harris Geospatial Solutions, 2016). Regije nastajajo vzdolž robov. Navadno to pripelje do pojava prekomerne segmentacije, še posebej če podobe vsebujejo veliko šuma. Pojav rešujemo bodisi s predobdelavo vhodnih podob bodisi s kasnejšim spajanjem območij na osnovi kriterija podobnosti.

V nadaljevanju poglavja nakazujem kakšen vpliv lahko imajo vhodni podatki, parametri in izbrani koraki segmentacije na samo segmentacijo. Konkreten vpliv različnih končnih segmentacij na klasifikacijo pa je preizkušen v naslednjih poglavjih.

6.2.2 Vpliv metode vpeljave algoritma razvodij na vhodno podobo

Algoritem razvodij lahko na vhodno podobo vpeljemo z dvema metodama: z metodo robov in metodo intenzitete.

Metodo robov uporabimo, kadar imajo objekti zanimanja ostre meje z relativno velikimi gradienti, medtem ko ima notranji del objekta precej enotno intenziteto (z malo ali nič gradienta). Takšni objekti so npr. stavbe ali vozila na nekaterih spektralnih kanalih (npr. vidna svetloba). Z metodo robov ENVI FX izračuna podobo gradienta z uporabo Sobelove metode zaznave robov, kjer so robovi določeni na osnovi kontrastov med vrednostmi pikslov. Algoritem razvodij je nato vpeljan na podobo gradienta in ne na originalno vhodno podobo.

Metodo intenzitete uporabimo v primeru, ko že imamo pripravljeno podobo gradienta, ki smo jo naredili izven ENVI FX (s Sobelovo ali katero drugo metodo zaznave robov).

Izbira ustrezne metode vpeljave algoritma razvodij je torej bistvenega pomena za kakovost segmentacije. Če npr. uporabimo metodo robov na podobi gradienta, bodo rezultati neuporabni. Ob predpostavki, da bomo uporabili ustrezno metodo, lahko rezultate segmentacije izboljšamo (oz. prilagodimo svojim željam) z upoštevanjem dodatne razlage delovanja metod za primer, ko je vhodna podoba več-kanalna.

V primeru več-kanalne vhodne podobe se pri metodi intenzitete v algoritmu razvodij za vsak piksel vpelje vrednost intenzitete, ki je povprečje vrednosti tega piksla v vseh vhodnih kanalih. Po drugi strani se pri metodi robov najprej za vsak piksel in za vsak kanal izračuna prostorska vrednost gradienta, nato pa se v algoritmu razvodij vpelje najvišja vrednost gradienta na pikslu (izmed vseh kanalov). To v praksi pomeni, da želimo imeti vhodno podobo s čim manj kanali ter, v primeru več kanalov, kanale s čim bolj podobnimi vrednostmi.

6.2.3 Vpliv vhodne podobe na segmentacijo

ENVI FX algoritem segmentacije izvede na eno-kanalni podobi gradientov/intenzitete, ki jo izračuna iz vhodne podobe, tudi ko je vhodna podoba več-kanalna. Omeniti moram, da ENVI FX ni eden izmed redkih algoritmov segmentacije, ki deluje na takšen način. Kot že omenjeno, se proces segmentacije v glavnem uporablja v drugih vedah, zato je velika večina algoritmov za segmentacijo namenjena njim. Bistvena razlika večine ved od daljinskega zaznavanja je v tem, da pri svojem delu uporabljajo eno-kanalne podobe. Posledično tudi algoritmi segmentacije večinoma delujejo na eno-kanalnih podobah. In ker so algoritmi segmentacije daljinsko zaznanih podob v veliki večini prevzeti iz drugih ved, še vedno skoraj brez izjeme delujejo na osnovi eno-kanalne podobe.

V primeru uporabe več-kanalne vhodne podobe je zato smiselno upoštevati nekaj priporočil in ne

slepo izvesti segmentacije na originalnem satelitskem posnetku z vsemi spektralnimi kanali. V nadaljevanju navajam nekaj takšnih priporočil.

Predobdelava. Priporočljivo je, da posnetke pred segmentacijo radiometrično popravimo in odpravimo morebitne šume.

Uporaba osnovnih spektralnih kanalov. V splošnem velja manj je več (Mesner in Oštir, 2014), kar pomeni, da uporaba manjšega števila spektralnih kanalov daje bolj kakovostne rezultate segmentacije in obratno. Navadno se kot optimalna izkaže uporaba osnovnih kanalov vidnega spektra. Pomembno je, da imajo vhodni sloji podoben (a ne koreliran) spektralni razpon. Kombinacija npr. kanalov vidne svetlobe in določenega vegetacijskega indeksa ni priporočljiva. Prav tako ni priporočljiva segmentacija kombinacije kanalov vidne svetlobe in kanalov drugih barvnih prostorov, npr. HSI (Harris, 2016).


Prostorska ločljivost. V primerih, ko je prostorska ločljivost posnetka previsoka glede na namen objektne analize, je smiselno posnetek prevzorčiti na nižjo prostorsko ločljivost.

Umetni rastrski sloj. Nekateri avtorji (npr. Dey et al., 2010; Xiao et al., 2010) predlagajo pripravo umetnega rastrskega sloja za segmentacijo, ki ga lahko kombiniramo iz več spektralnih kanalov, vegetacijskih indeksov, osnovnih komponent in različnih filtriranih slojev. Pri operiranju s spektralno visokoločljivimi posnetki je priporočljivo zmanjšati korelacijo podatkov z uporabo transformacij, kot je npr. osnovna analiza komponent.

Podoba gradienta. Če algoritem deluje na podobi gradienta, jo izdelamo z najprimernejšo metodo zaznave robov.

Pri pridobivanju optimalne podobe segmentacije ta priporočila upoštevam. Za lažjo predstavo o vplivu različnih vhodnih podob na segmentacijo pa v nadaljevanju prikazujem nekaj konkretnih primerov na testnih podatkih.


Na sliki 27 je primer segmentacije originalnega bližnje-infrardečega spektralnega kanala in segmentacije istega kanala, na katerem sem pred segmentacijo izvedli operacijo morfološkega zapiranja z velikostjo okna 5 x 5 pikslov. Z morfološkim zapiranjem sem zmanjšala učinek premočne segmentacije v gozdu, kjer vrednosti bližnje-infrardečega kanala zelo variirajo.



Slika 27: Območje, prikazano z vrednostmi bližnje-infrardečega kanala (a); območje, prikazano z vrednostmi bližnje-infrardečega kanala, obdelanega z operacijo morfološkega zapiranja z velikostjo okna 5 x 5 pikslov (b); segmentacija posnetka (a) s parametri merilo 30 in združitev 70 (c); segmentacija posnetka (b) s parametri merilo 30 in združitev 70 (d).

Figure 27: Area shown in near infrared channel (a), area shown in near infrared channel, processed with morphological closing with a 5 x 5 pixel window (b); segmentation of image (a) with parameters scale 30 and merge 70 (c); segmentation of image (b) with parameters scale 30 and merge 70.

Na sliki 28 je primer segmentacije treh različnih vhodnih slojev: rdečega, bližnje-infrardečega (NIR) ter obeh omenjenih hkrati. Spektralne vrednosti ter variacije teh vrednosti med sosednjimi piksli so lahko v različnih delih spektra zelo različne. Tako ima npr. gozd v rdečem delu spektra precejšnjo homogenost pikslov, medtem ko imajo vrednosti v bližnje-infrardečem delu spektra občuten razpon. Temu primerno je tudi segmentacija kanala NIR občutno bolj »razdrobljena« kot segmentacija rdečega kanala. V primeru podobnega spektralnega razpona dveh posameznih kanalov, je segmentacija, pri kateri hkrati uporabimo oba posamezna kanala, nekakšno povprečje posameznih segmentacij.



Slika 28: Območje, prikazano z vrednostmi rdečega kanala R (a); območje, prikazano z vrednostmi bližnje-infrardečega kanala Nir (b); območje, prikazano z vrednostmi R in Nir kanala v kombinaciji RGB = RNirR (c); segmentacija posnetka (a) s parametri merilo 30 in združitev 70 (d); segmentacija posnetka (b) s parametri merilo 30 in združitev 70 (e); segmentacija posnetka (c) s parametri merilo 30 in združitev 70 (f);

Figure 28: Area shown in red channel R (a), area shown in near infrared channel Nir (b); area shown with an RGB combination of channel R and Nir (c); segmentation of image (a) with parameters scale 30 and merge 70 (d); segmentation of image (b) with parameters scale 30 and merge 70 (e); segmentation of image (c) with parameters scale 30 and merge 70 (f).

Na osnovi teorije in nekaj praktičnih primerov lahko zaključim, da imajo vhodni podatki velik vpliv na segmentacijo. Kakšen vpliv imajo na segmentacijo samo in kasneje tudi na klasifikacijo segmentov, raziščemo v naslednjih poglavjih.

6.2.4 Vpliv parametrov na segmentacijo

Nekateri avtorji (Zhang in Maxwell, 2006; Dragut et al., 2010; Mesner in Oštir, 2014) so dokazali, da izbira optimalnih parametrov kaže na korenito izboljšavo rezultatov segmentacije. Zato so parametri vredni pozornosti. Navadno so tudi edina spremenljivka, s katero se uporabniki ukvarjajo.

Vsaka programska oprema za segmentacijo ima na voljo več parametrov. Morda se zdi, da več parametrov pomeni možnost boljše segmentacije, vendar izkušnje uporabnikov kažejo, da temu ni tako. Parametri so namreč medsebojno odvisni, zato je nemogoče takoj najti vse primerne parametre naenkrat (Kim in Madden, 2006). Uporabniki morajo ponavljajoče izbirati set

parametrov in jih testirati na osnovi preizkušanja, dokler ne dosežejo zadovoljivega rezultata. To je navadno utrudljiv in časovno potraten postopek. Velikokrat se zgodi, da uporabnik pri iskanju optimalnih parametrov ne vztraja, zato tudi segmentacija ni optimalna. Ker so parametri segmentacije vedno krajevno značilni, lahko izbira optimalnih parametrov tudi za izkušenega uporabnika s strokovnim znanjem predstavlja dolgotrajen proces. V izogib temu problemu je bilo predlaganih (in v nekatere programske pakete implementiranih) veliko polsamodejnih pristopov za iskanje optimalnih parametrov, npr. enostavna orodja za grafično podporo (npr. (Schneider et al., 1997), interaktivni sistemi (npr. Matsuyama, 1993); Crevier in Lepage, 1997), pri katerih uporabnik oceni rezultat segmentacije na koncu vsake iteracije, do skoraj samodejnih postopkov (npr. Zhang in Maxwell, 2006; Dragut et al., 2010, Zhang et al., 2010), ki zahtevajo minimalno posredovanje uporabnika in zmanjšujejo vpliv izkušenosti operaterja na kakovost rezultatov segmentacije.

Običajno v programski opremi za segmentacijo najdemo enega ali več osnovnih parametrov z opisanim namenom (Hofmann, 2001):


- merilo definira maksimalno stopnjo homogenosti segmentov in s tem velikost segmentov;
- barva/oblika definira vpliv barve (spektralne vrednosti) in oblike na tvorbo segmentov;
- gladkost/kompaktnost definira ali naj bo meja segmenta bolj gladka ali bolj kompaktna;
- uteži slojev se uporabljajo za določanje vpliva posameznega sloja na tvorbo segmentov;
- nastavitve stopnje vpliva na način tvorjenja segmenta (od zgoraj navzdol ali od spodaj navzgor).

Poleg osnovnih parametrov lahko ima vsak program tudi svoje specifične parametre. V primeru algoritmov z znano prekomerno segmentacijo so v postopek segmentacije običajno dodani algoritmi za združevanje segmentov. Namen vseh tovrstnih algoritmov je združevanje sosednjih segmentov s podobnimi spektralnimi in prostorskimi lastnostmi. Pri tem lahko uporabnik zopet izbira med parametri, kot sta metoda in stopnja združevanja.

Za praktični prikaz vpliva parametrov na segmentacijo se osredotočimo na programsko opremo ENVI FX. Ta ima za segmentacijo na voljo dva parametra, in sicer: merilo (angl. scale level) in združitev (angl. merge level).

Merilo se računa iz kumulativne porazdelitvene funkcije podobe gradientov. Merilo 20, npr., pomeni, da bo najnižjih 20 % vrednosti gradienta izločenih iz podobe gradientov. Z večanjem stopnje merila ohranimo objekte z najbolj značilnimi robovi in zmanjšamo število segmentov. Na sliki 29 je primer segmentacije pri isti stopnji združitve ter različni stopnji merila. Razvidno je, da večja stopnja merila pomeni večje in bolj nehomogene segmente. Previsoka stopnja merila (na sliki primer c), lahko ima za posledico prešibko segmentacijo, ki zagotovo vodi v nekakovostno


klasifikacijo (več o tem v nadaljevanju).



Slika 29: Segmentacija spektralnih kanalov R, G, B in NIR s stopnjo združevanja 50 ter stopnjami merila 00 (a), 30 (b) in 50 (c)

Figure 29: Segmentation of spectral channels R, G, B and NIR with merge level 50 and scale levels 00 (a), 30 (b) and 50 (c)

Z algoritmom razvodij dobimo veliko število segmentov, kar navadno smatramo kot slabost, znano kot prekomerna segmentacija. Rezultat lahko izboljšamo z združevanjem segmentov s podobnimi lastnostmi. Združevanje izvedemo tako, da najprej za vsak kanal in vsak segment izračunamo srednjo spektralno vrednost. Nato izračunamo spektralno Evklidsko razdaljo med segmenti, pri čemer lahko uporabimo metodo FLS (angl. Full Lambda Schedule) ali FL (angl. Fast Lambda). Pri prvi metodi sosednje segmente združujemo glede na kombinacijo spektralnih in prostorskih informacij, pri drugi metodi pa glede na dolžino skupne meje. Pri obeh metodah lahko uporabljamo večspektralne informacije. S povečevanjem stopnje združevanja manjšamo število segmentov. Primer različne stopnje združevanja pri isti stopnji merila je prikazan na sliki 30.



Slika 30: Segmentacija spektralnih kanalov R, G, B in NIR s stopnjo merila 00 ter stopnjami združevanja 00 (a), 30 (b) in 60 (c). Združevanje je bilo izvedeno z metodo FLS in spektralnimi kanali R, G, B in NIR.

Figure 30: Segmentation of spectral channels R, G, B and NIR with scale level 00 and merge levels 00 (a), 30 (b) and 60 (c). Merging was performed by Full Lambda Schedule and spectral channels R, G, B and NIR.

Glede na izbrano stopnjo merila in združevanja lahko dobimo prekomerno, optimalno ali prešibko segmentacijo, odvisno od števila segmentov v referenčnem objektu. Prekomerna segmentacija se pojavi, ko zunanja meja unije segmentov istega objekta sicer ustreza meji objekta, a je število segmentov znotraj objekta veliko (npr. slika 30 (a)). Optimalna segmentacija se pojavi, ko zunanja


meja unije segmentov istega objekta ustreza meji objekta in vsebuje samo enega ali zgolj nekaj segmentov. Za prešibko segmentacijo je značilno, da posamezni segmenti pokrivajo več referenčnih objektov iz različnih razredov in segmenta posledično ne moremo pripisati nobenemu razredu, kot npr. na sliki 29 (c).

Pri algoritmu ENVI FX je torej smiselno, da pazljivo izberemo stopnjo merila, pri čemer je zelo pomembno, da stopnja ni previsoka, da ne pride do prešibke segmentacije. Po drugi strani je zaželena čim višnja stopnja združevanja, vendar tudi (izhajajoč iz nadaljnjih analiz) nizka stopnja združevanja rezultata ne bo bistveno pokvarila.

6.2.5 Vpliv parametrov na klasifikacijo

Ker je namen disertacije klasifikacija določenih razredov pokrovnosti, nas zanima kaj različni parametri segmentacije pomenijo za klasifikacijo samo. Stranski produkt analize zanesljivosti ocene segmentacije za napoved ocene klasifikacije (poglavje 3.3 in članek (Švab Lenarčič et al, 2016)) je tudi analiza kakovosti klasifikacije pri različnih parametrih segmentacije.


Na sliki 31 je prikazan referenčni sloj ter klasifikacije osnovnih razredov pokrovnosti, ki so bile izvedene s klasifikatorjem k-Nearest Neighbour, vhodnimi sloji R, G, B in NIR ter segmentacijami s tremi različnimi kombinacijami parametrov. V primeru prekomerne segmentacije (slika 31 (b)) je končna klasifikacija razdrobljena, polna majhnih, napačno klasificiranih segmentov. Z večanjem stopnje merila se sicer večja konsistenca rezultatov, vendar se mestoma začnejo pojavljati večji, napačno klasificirani poligoni, npr. gozd levo spodaj (slika 31 (d)). In te je težko izločiti tudi s postopkom poklasifikacije.



Slika 31: Referenčni sloj (a) ter klasifikacija osnovnih razredov pokrovnosti, izvedena s klasifikatorjem k-Nearest Neighbour, vhodnimi podobami R, G, B in NIR ter parametri segmentacije $\text{merilo_združitve} = 00_00$ (b), 30_50 (c) in 50_50 (d).

Figure 31: Reference layer (a) and final classification image of basic land cover classes, obtained by classifier k-Nearest Neighbour, input images R, G, B and NIR and segmentation parameters $\text{scale_merge} = 00_00$ (b), 30_50 (c) in 50_50 (d).

Oblika in velikost segmentov torej določata obliko in velikost končnih, klasificiranih poligonov. Vendar pa, kot obrazloženo že v poglavju 3, v sklopu disertacije ne upoštevam vseh kriterijev kakovosti klasifikacije, temveč zgolj število pravilno/napačno klasificiranih pikslov. Na takšen način je bil vpliv parametrov na kakovost klasifikacije analiziran tudi v članku Švab Lenarčič et al. (2016). Na sliki 32 je prikazan rezultat skupne natančnosti klasifikacije (OA) pri segmentaciji spektralnih kanalov R, G, B in Nir s stotimi različnimi kombinacijami parametrov merila in združitve.



Slika 32: Rezultati skupne natančnosti klasifikacije vseh osnovnih razredov pokrovnosti. Os x predstavlja parametre segmentacije. V zgornji vrsti so navedeni parametri merila (od 00 do 90), v spodnji vrsti parametri združitev (od 0 do 90). Os y predstavlja vrednost ocene klasifikacije.

Figure 32: Results of overall classification accuracy of all basic land cover classes. X axis represents segmentation parameters. Upper row represents scale parameter (from 00 to 90), lower row represents merge parameter (from 00 to 90). Y axis represents the value of classification evaluation.

Iz rezultata je razvidno, da je klasifikacija približno enako kakovostna in relativno stabilna v intervalu nizke do srednje stopnje merila (od 00 do približno 50), ne glede na razred pokrovnosti in mero kakovosti klasifikacije (Švab Lenarčič et al, 2016). Pri visoki stopnji merila (od približno 50 navzgor), kakovost klasifikacije občutno pade in rezultati klasifikacije postanejo praktično neuporabni. Pri nastavitvi stopnje merila je torej potrebno paziti, da ne pride do prešibke segmentacije.

Parameter združitve, po drugi strani, nima tako močnega vpliva na kakovost klasifikacije kakor parameter merila. V splošnem je bolje uporabiti čim višjo stopnjo združitve, ni pa smiselno posegati po skrajnih vrednostih.

Če številkam matrike napak dodamo še željo po konsistenci rezultatov, je smiselno, da izvedemo kar se da optimalno segmentacijo. Pri vhodnih slojih R, G, B in Nir je to nekje pri merilu 30 in združitvi 70. Seveda drugi vhodni sloji zahtevajo druge optimalne parametre.

7 ANALIZA UPORABNOSTI ENO-KANALNIH VHODNIH PODOB

Pri vizualni interpretaciji pokrovnosti izhajamo iz enega ali več osnovnih elementov, ki so: ton, oblika, velikost, vzorec, tekstura, senca in povezava (Oštir, 2006). Zaradi izredne sposobnosti možganov ter pridobljenih izkušenj, lahko interpretator učinkovito uporablja vse osnovne elemente hkrati. Tudi programska oprema za klasifikacijo zmore upoštevati večino osnovnih elementov, vendar ji moramo le-te pripisati kot atribut na osnovne enote.

Če je osnovna enota piksel, imamo na voljo zgolj element ton (element povezava se običajno uporablja pri postopku poklasifikacije). V večini primerov ton enačimo z vrednostmi osnovnih spektralnih kanalov, ki jih ima določen senzor na voljo. Večje število kanalov praviloma omogoča višjo kakovost klasifikacije. Ker imamo v primeru posnetkov RapidEye na voljo zgolj pet kanalov, lahko predvidoma kakovost klasifikacije zvišamo, če uporabimo dodatne attribute, izpeljane iz spektralnih kanalov. Najbolj znane izpeljane spektralne lastnosti so vegetacijski in drugi indeksi ter druge barvne transformacije.

Če osnovna enota obsega vsaj dva piksla (npr. segment), imamo poleg spektralnih (tona) za klasifikacijo na voljo še teksturne (razporeditev spektralnih vrednosti znotraj osnovne enote) in prostorske lastnosti (oblika, velikost). Prostorske lastnosti uporabljamo le pri specifičnih klasifikacijah (prepoznavanju določenih objektov, npr. letal), zato jim v disertaciji ne posvečam večjega pomena. Po drugi strani pa tekstura lahko pomeni dodano vrednost pri klasifikaciji.

Pri objektno usmerjeni klasifikaciji teksturo pripišemo že obstoječim segmentom, ki smo jih naredili na osnovi homogenosti spektralnih vrednosti pikslov. Tudi takšna tekstura je dobrodošla, vendar imamo v tem primeru lokacijo in obliko segmentov že fiksirano. Zato sem poskusila teksturo upoštevati že pri samem postopku segmentacije.

Ker uporabljen algoritem segmentacije (algoritem razvodij) zahteva eno-kanalno vhodno podobo, sem izdelala večje število spektralnih, teksturnih in kombiniranih eno-kanalnih podob. Te podobe sem testirala kot vhodni podatek v različne korake segmentacije.

Dodatno so informacijsko polne eno-kanalne podobe zaželeno tudi kot vhodni atributni podatek veččasovne klasifikacije, saj lahko znatno zmanjšajo število vhodnih podatkov, s čimer je klasifikacija lažja in krajša. Določitev optimalnih vhodnih podob in njihov doprinos je opisan v poglavju 9.

Osnova za izdelavo vhodnih podob so bili atmosfersko popravljene spektralni kanali posnetka RapidEye 29.7.2013, študijsko območje Pomurje. Posnetki z večjim številom spektralnih kanalov, npr. Sentinel-2, omogočajo izračun še večjega števila indeksov, vendar jih v času testiranja posnetkov Sentinel-2 še nisem imela na voljo. Poleg tega je namen testiranja vhodnih podatkov dosežen že zgolj s posnetki RapidEye.

7.1 Izdelava eno-kanalne podobe iz kombinacije spektralnih lastnosti

Na osnovi osnovnih spektralnih kanalov, množice različnih vegetacijskih indeksov, različnih transformacij med barvnimi prostori in različnih drugih analiz ter kombinacij sem izdelala 154 eno-kanalnih podob, ki vključujejo zgoščene spektralne informacije izbranih spektralnih kanalov. V prvi grobi selekciji sem na osnovi vizualne presoje izbrala 80 podob (preglednica 10), ki jih lahko razdelimo v naslednje skupine:

- posamezni spektralni kanali posnetka RapidEye (moder, zelen, rdeč, robno-rdeč in bližnje-infrardeč);
- širokopasovni vegetacijski indeksi zelenosti, ki nakazujejo skupno količino in kakovost fotosintetičnih snovi v vegetaciji (atmosfersko odporen indeks vegetacije (angl. Atmospherically Resistant Vegetation Index), indeks razlike vegetacije (angl. Difference Vegetation Index), normiran diferencialni vegetacijski indeks (angl. Normalized Difference Vegetation Index), na zemeljsko prst prilagojen vegetacijski indeks (angl. Soil Adjusted Vegetation Index idr.);
- ozkopasovni vegetacijski indeksi zelenosti, ki večinoma temeljijo na vrednostih odbojnosti rdečega, robno rdečega in bližnje infrardečega kanala (indeks razmerij, prilagojen na vpijanje klorofila (angl. Modified Chlorophyll Absorption Ratio Index), robno-rdeč normiran diferencialni vegetacijski indeks (angl. Red Edge Normalized Difference Vegetation Index) idr.);
- indeksi listnega pigmenta, ki predstavljajo merilo pigmentov, povezanih s stresom (indeks odbojnosti antocianinov (angl. Anthocyanin Reflectance Index), indeks odbojnosti karotenoidov (angl. Carotenoid Reflectance Index);
- barvne transformacije (npr. iz barvnega prostora RGB v barvni prostor HSV (angl. Hue Saturation, Value) iz različnih kombinacij originalnih spektralnih kanalov in spektralnih indeksov;
- analiza posameznih komponent (angl. Independent Component Analysis);
- napredna statistika deleža najmanjšega šuma (angl. Forward MNF noise statistics);
- transformacija spektralnega prostora (angl. feature space transformations) (npr. t. i. metoda kape s cofom (angl. tasseled cap), kjer dobimo komponente svetlost, zelenost in rumenost);
- enostavna razmerja kanalov: B/R, B/Rdg, B/Nir idr. in
- interno definirani spektralni atributi.

Vsaka skupina nakazuje prisotnost ali pomanjkanje specifične lastnosti vegetacije/rastlinstva, kot je vrsta rastlinskega pokrova (vrsta listov, njihova oblika in usmerjenost), zgradba rastlin, faza rasti, vsebnost pigmenta ali vode idr. Noben indeks ne more določiti točne koncentracije sestavin v posameznih rastlinah, ampak se vse nanašajo na relativne količine na določenem geografskem območju.


Preglednica 10: Seznam izdelanih eno-kanalnih spektralnih slojev s kraticami, ki so uporabljene v nadaljevanju

Table 10: List of obtained one-band spectral layers with acronyms, used in further chapters

Št.	Ime indeksa
1	Internally defined index: Sum of all individual bands (SUMBANDS)
2	Anthocyanin Reflectance Index 1 (ARI-1)
3	Anthocyanin Reflectance Index 2 (ARI-2)
4	Atmospherically Resistant Vegetation Index (ARVI)
5	Ashburn Vegetation Index (AVI)
6	Burn Area Index (BAI)
7	Blue band (BLUE)
8	Band ratio 1 (Blue/RedEdge) (BR1)
9	Band ratio 2 (Green/RedEdge) (BR2)
10	Band ratio 3 (Red/RedEdge) (BR3)
11	Browning Reflectance Index (BRI)
12	Brightness from Tasseled cap transformation (BRIGHTNESS)
13	Canopy Chlorophyll Content Index (CCCI)
14	Chlorophyll Green Index (CHLGREEN)
15	Chlorophyll RedEdge Index (CHLREDEGE)
16	Carotenoid Reflectance Index 1 (CRI-1)
17	Carotenoid Reflectance Index 2 (CRI-2)
18	Chlorophyll Vegetation index (CVI)
19	Difference Vegetation Index (DVI)
20	Enhanced Vegetation Index 1 (EVI-1)
21	Enhanced Vegetation Index 2 (EVI-2)
22	Green Atmospherically Resistant index (GARI)
23	Green Difference Vegetation Index (GDVI)
24	Green Normalised Difference Vegetation Index (GNDVI)
25	Green band (GREEN)
26	Greenness from Tasseled cap transformation (GREENNESS)
27	Independent Component Analysis - 1st component (ICA-FORWARD-1)
28	Independent Component Analysis - 2nd component (ICA-FORWARD-2)
29	Independent Component Analysis - 3rd component (ICA-FORWARD-3)
30	Independent Component Analysis - 4th component (ICA-FORWARD-4)
31	Independent Component Analysis - 5th component (ICA-FORWARD-5)
32	Infrared Percentage Vegetation Index (IPVI)
33	Leaf chlorophyll index (LCI)
34	Modified Chlorophyll Absorption Ratio Index (MCARI)
35	Forward MNF noise statistics - 1st component (MNF-FORWARD-1)
36	Forward MNF noise statistics - 2nd component (MNF-FORWARD-2)
37	Forward MNF noise statistics - 3rd component (MNF-FORWARD-3)
38	Forward MNF noise statistics - 4th component (MNF-FORWARD-4)
39	Forward MNF noise statistics - 5th component (MNF-FORWARD-5)
40	Modified Non-Linear Index (MNLI)
41	Modified Simple Ratio (MSR)
42	Normalized difference Vegetation Index (NDVI)
43	Internally defined index: Product of all individual bands multiplied by NDVI (SUMBANDS-NDVI)


- 44 Internally defined index: Green band multiplied by NDVI (NDVI-GREEN)
- 45 Hue component of RGB to HSV colour transform (input data: NDVI_GREEN_BLUE_HUE)
- 46 Saturation component of RGB to HSV colour transform (input data: NDVI_GREEN_BLUE_SAT)
- 47 Value component of RGB to HSV colour transform (input data: NDVI_GREEN_BLUE_VAL)
- 48 REDEDGE NDVI
- 49 REDEDGE AND RED NDVI
- 50 Near Infrared band (NIR)
- 51 Hue component of RGB to HSV colour transform (input data: NIR_GREEN_BLUE_HUE)
- 52 Saturation component of RGB to HSV colour transform (input data: NIR_GREEN_BLUE_SAT)
- 53 Value component of RGB to HSV colour transform (input data: NIR_GREEN_BLUE_VAL)
- 54 Hue component of RGB to HSV colour transform (input data: NIR_REDEDGE_RED_HUE)
- 55 Saturation component of RGB to HSV colour transform (input data: NIR_REDEDGE_RED_SAT)
- 56 Value component of RGB to HSV colour transform (input data: NIR_REDEDGE_RED_VAL)
- 57 Non-Linear Index (NLI)
- 58 Optimised Soil Adjusted Vegetation Index (OSAVI)
- 59 Plant Senescence Reflectance Index (PSRI)
- 60 Plant Senescence Reflectance Index with NIR band (PSRI-NIR)
- 61 Hue component of RGB to HSV colour transform (input data: PSRI_NIR_REDEDGE_HUE)
- 62 Saturation component of RGB to HSV colour transform (input data: PSRI_NIR_REDEDGE_SAT)
- 63 Value component of RGB to HSV colour transform (input data: PSRI_NIR_REDEDGE_VAL)
- 64 Red band (RED)
- 65 RedEdge band (REDEDGE)
- 66 Hue component of RGB to HSV colour transform (input data: RED_GREEN_BLUE_HUE)
- 67 Saturation component of RGB to HSV colour transform (input data: RED_GREEN_BLUE_SAT)
- 68 Value component of RGB to HSV colour transform (input data: RED_GREEN_BLUE_VAL)
- 69 Internally defined index: sum of RED and NIR band (SUM-RED-NIR)
- 70 Soil Adjusted Vegetation Index (SAVI)
- 71 Simple ration Index (SR)
- 72 Hue component of RGB to HSV colour transform (input data: SR_GREEN_BLUE_HUE)
- 73 Saturation component of RGB to HSV colour transform (input data: SR_GREEN_BLUE_SAT)
- 74 Value component of RGB to HSV colour transform (input data: SR_GREEN_BLUE_VAL)
- 75 Hue component of RGB to HSV colour transform (input data: SR_NIR_RED_HUE)
- 76 Saturation component of RGB to HSV colour transform (input data: SR_NIR_RED_SAT)
- 77 Value component of RGB to HSV colour transform (input data: SR_NIR_RED_VAL)
- 78 Transformed Chlorophyll Absorption Reflectance Index (TCARI)
- 79 Transformed Difference Vegetation Index (TDVI)
- 80 Yellowness from Tasseled cap transformation (YELLOWNESS)

Za lažjo predstavo indeksov, na slikah 33 do 36 prikazujem nekaj izbranih.




Slika 33: Vegetacijski indeksi: normiran diferencialni vegetacijski indeks (NDVI) (a), prvi indeks odbojnosti antocianinov (ARI-1) (b) in transformiran indeks vpojnosti klorofila (TCARI) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 33: Vegetation indices: Normalized difference Vegetation Index (NDVI) (a), Anthocyanin Reflectance Index 1 (ARI-1) (b) and Transformed Chlorophyll Absorption Reflectance Index (TCARI) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.




Slika 34: Barvne transformacije: intenziteta podobe NirGB (NIR_GREEN_BLUE_VAL) (a), nasičenost podobe NirRdgR (NIR_REDEGE_RED_SAT) (b) in barva podobe RGB (RED_GREEN_BLUE_HUE) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 34: Colour transformations: intensity of image NirGB (NIR_GREEN_BLUE_VAL) (a), saturation of image NirRdgR (NIR_REDEGE_RED_SAT) (b) and hue of image RGB (RED_GREEN_BLUE_HUE) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.



Slika 35: Analiza posameznih komponent originalnih kanalov posnetka RE: druga komponenta (ICA-FORWARD-2) (a), četrta komponenta (ICA-FORWARD-4) (b) in peta komponenta (ICA-FORWARD-5) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 35: Principal component analysis of original RapidEye image channels: second component (ICA-FORWARD-2) (a), fourth component (ICA-FORWARD-4) (b) and fifth component (ICA-FORWARD-5) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.



Slika 36: Metoda »kape s cofom«: svetlost (BRIGHTNESS) (a), zelenost (GREENNESS) (b) in rumenost (YELLOWNESS) (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 36: Tasseled cup method: brightness (BRIGHTNESS) (a), greenness (GREENNESS) (b) and yellowness (YELLOWNESS) (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.

7.2 Izdelava eno-kanalne podobe iz kombinacije teksturnih lastnosti

Nekateri razredi pokrovnosti se od drugih razredov razlikujejo bolj po značilnih spremembah v svetlosti (tekstura), kakor določeni značilni vrednosti svetlosti. Npr. na osnovi spektra vidne svetlobe včasih težko ločimo gozd od bujno rastle poljščine (oboje je videti temno zeleno). Če pa primerjamo njuno variabilnost vrednosti znotraj območja, hitro opazimo, da je pri gozdu veliko višja. To značilnost lahko dokaj enostavno izkoristimo pri sami klasifikaciji pokrovnosti, kjer teksturo uporabimo kot atribut osnovne enote, ki jo klasificiramo. Vendar pa je v tem primeru osnovna enota že določena in pri


segmentacijskem algoritmu razvodij, ki proizvaja visoko homogene segmente, veliko premajhna, da bi na njej izračunana tekstura doprinesla h kakovosti klasifikacije.

Zato sem se odločila uporabiti večje število kazalcev teksture, ki bi morda območja visoke variabilnosti uspeli prikazati kot homogena območja, ki bi jih uporabili kot vhodni podatek v segmentaciji. Dodatni namen je bil prikaz različnih kazalcev teksture za prvo vizualno izbiro najprimernejših tekstur pri postopku klasifikacije.

Za izdelavo eno-kanalne podobe, ki vključuje teksturne lastnosti satelitskega posnetka, sem izhajala iz sledečih statističnih kazalnikov:


- matrike pojavljanja (razpon podatkov, povprečje, varianca, entropija in asimetrija),
- matrike sopojavljanja (povprečje, varianca, homogenost, kontrast, drugačnost, entropija, drugi moment in korelacija),
- konvolucijska filtri (visokoprepustni, nizkoprepustni, Laplaceov, smerni (koti 0° , 90° , 45° , 135°), Gausov visokoprepustni in Gausov nizkoprepustni filter, filter mediane, Sobelov detektor robov in Robertsov detektor robov),
- morfologija (zmanjševanje, razširjanje, odpiranje, zapiranje),
- Lawsove mere teksturne energije,
- drugi filtri, kot je Log-Gabor filter.

Skupno sem izdelala 316 eno-kanalnih podob. Nekaj njih prikazujem na slikah 37 do 38.



Slika 37: Podobe matrike sopojavljanja, narejene z oknom velikosti 3 x 3 s podobo rdečega kanala: povprečje (a), varianca (b), kontrast (c), homogenost (d), drugačnost (e) in entropija (f). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 37: Images of co-occurrence matrix, obtained by 3 x 3 moving window on the red channel image: mean (a), variance (b), contrast (c), homogeneity (d), dissimilarity (e) and entropy (f). The basis was RapidEye image 29.7.2013. Murska Sobota study area.



Slika 38: Podobe konvolucijskih filtrov: smerni filter kota 0° (a); smerni filter kota 135° (b) in visokopasovni filter rdečega kanala (c). Osnova je posnetek RapidEye 29.7.2013, študijsko območje Murska Sobota.

Figure 38: Images of convolution filters: directional filter of angle 0° (a); directional filter of angle 135° (b) and high pass filter of red channel (c). The basis was RapidEye image 29.7.2013. Murska Sobota study area.

8 DOLOČITEV NAJZNAČILNEJŠIH ATRIBUTOV

S postopkom klasifikacije osnovne enote (entitete) razvrstimo v ustrezne razrede pokrovnosti glede na njihove lastnosti oz. attribute. Atribut ali podatkovni element je tisti podatek, ki z vidika vsebine ni več členljiv oz. ga ni možno ali smiselno razstaviti na manjše dele. V našem primeru je atribut piksla npr. vrednost rdečega kanala na točno določenem posnetku. V primeru veččasovne klasifikacije kompleksnejše osnovne enote, kot je GERK, je atribut lahko npr. standardni odklon indeksa PSRI na določen datum.

V prejšnjih poglavjih spoznamo, da imajo algoritmi veččasovne klasifikacije pogosto težave z obdelavo velike količine vhodnih podatkov. Znano je tudi, da lahko prevelika količina podatkov ovira klasifikacijo in rezultate celo poslabša (Masse et al., 2011). Dodatno velika količina podatkov občutno podaljša čas trajanja obdelave. Zato je za klasifikacijo pomembno izbrati čim manjše število atributov, ampak takšnih, ki kar najbolj zvišajo kakovost klasifikacije (Gomez et al., 2016).

V literaturi veččasovne klasifikacije pokrovnosti je kot atribut skoraj izključno zaslediti zgolj vrednosti indeksa NDVI skozi čas. Splošno je namreč znano (Jinru in Baofeng, 2017), da je NDVI eden najuspešnejših indeksov za enostavno in hitro določitev območij rastlinstva in njihovega stanja. Izračuna se z enostavnim razmerjem rdečega in bližnje infrardečega kanala (enačba (5)) in zajema omejene vrednosti od -1 do +1.

$$NDVI = \frac{NIR-R}{NIR+R} \quad (5)$$

Ker rdeč in bližnji- infrardeč kanal vsebujeta več kot 90 % informacij, povezanih z rastlinstvom (Baret et al., 1988), tudi številni drugi indeksi temeljijo na odbojnostih v teh dveh delih spektra. Čeprav so bili največkrat definirani za točno določen namen, je v praksi med njihovimi vrednostmi le malo razlik. To pomeni, da imajo visoko statistično korelacijo oz. podobnost. Ker je podvojenost vhodnih podatkov pri veččasovni klasifikaciji vse prej kot zaželena, je potrebno iz množice indeksov izbrati samo najbolj značilne.

Analiz uporabnosti različnih indeksov/kanalov za potrebe veččasovne klasifikacije pokrovnosti v literaturi ni zaslediti. Ker imam za klasifikacijo pripravljenih 80 spektralnih slojev, sem takšno analizo opravila sama, saj je nujno potrebna (del projekta Sentinel2Agri4Slovenia).

Analizirala sem dve vrsti najznačilnejših atributov: spektralne in teksturne. Pri tem so bili osnova spektralni atributi, saj se teksturni atributi računajo za posamezen spektralni sloj in je edino smiselno, da je le-ta značilen. Cilj je bil postopno izločanje atributov do končnega števila zgolj nekaj najbolj značilnih.

8.1 Določitev najznačilnejših spektralnih atributov


Spektralni atributi temeljijo na spektralnih slojih. Stopnja značilnosti spektralnih atributov je bila določena na osnovi podobnosti (vizualno in s korelacijo), algoritma ReliefF in na osnovi primerjave klasifikacije. V nadaljevanju so podane podrobnosti in rezultati posameznega postopka ter končen izbor najznačilnejših atributov.

8.1.1 Vizualna primerjava


Podvajanje spektralnih slojev sem najprej določala vizualno. Pri tem sem sklepala, da bi bil rezultat klasifikacije dveh podob, ki sta si spektralno zelo podobni (ne glede na razred pokrovnosti), zelo podoben. Zelo podoben bi bil tudi rezultat, če bi v postopku klasifikacije uporabili obe podobi hkrati. Zato sem v primeru velike podobnosti izbrala samo en sloj, pri čemer so imeli prednost osnovni spektralni kanali, sledil je indeks NDVI, nato pa najbolj splošno uveljavljen indeks/kanal posamezne skupine podobnih.

Dodatno v ožji izbor niso prišle podobe, ki so vsebovale veliko šuma, prevelike zrnatosti, neenotnih značilnosti posameznega razreda, in drugačnih motečih lastnosti za klasifikacijo. Dodatno sem izločila spektralne sloje, ki so bili sicer obetavni za klasifikacijo, a je njihov rezultat odvisen od motiva podobe (območje, velikost in s tem razporeditev razredov) in ne od vedno enako določene vrednosti razreda. Takšen primer so npr. podobe, pridobljene z barvno transformacijo HSI ali z analizo osnovnih komponent (PCA).

Izhajala sem iz posnetka RapidEye 29.7.2013, za katerega sem izdelala osemdeset podob, navedenih v prejšnjem poglavju. Podobe sem pregledovala na študijskem območju Murske Sobote. Na slikah 39 in 40 je prikazan primer podobnosti, na sliki 41 pa podobe z veliko količino šuma.




Slika 39: Podobnost podob indeksov NDVI (a) in TDVI (b)
Figure 39: Similarity of images of indices NDVI (a) and TDVI (b)



Slika 40: Podobnost podob indeksov ARI-1 (a) in CVI (b).


Figure 40: Similarity of images of indices ARI-1 (a) and CVI (b)



Slika 41: Primeri podob z veliko šuma: CCCI (a), NDVI_GREEN_BLUE_HUE (b), PSRI_NIR_REDEGE_HUE (c) in SR_GREEN_BLUE_HUE (d)

Figure 41: Examples of images with a lot of noise: CCCI (a), NDVI_GREEN_BLUE_HUE (b), PSRI_NIR_REDEGE_HUE (c) and SR_GREEN_BLUE_HUE (d)

Na osnovi vizualne primerjave sem za klasifikacijo izbrala enajst spektralnih slojev. Ohranila sem vse osnovne spektralne kanale: modrega (BLUE), zelenega (GREEN), rdečega (RED), robno-rdečega (REDEGE) in bližnje-infrardečega (NIR) ter najpogostejše uporabljeni vegetacijski indeks NDVI. Dodatno sem ohranila še pet drugih indeksov, in sicer: ARI-2, BAI, CHLREDEGE, NDVI-GREEN in PSRI-NIR. Izseki podob vseh izbranih spektralnih slojev so prikazani na sliki 42.



Slika 42: Primeri podob atributov, izbranih na osnovi vizualne primerjave: ARI-1 (a), BAI (b), BLUE (c), CHLREDEDGE (d), GREEN (e), NDVI (f), NDVI-GREEN (g), NIR (h), PSRI-NIR (i), RED (j) in REDEDGE (k)

Figure 42: Examples of images of attributes, selected on the basis of visual comparison: ARI-1 (a), BAI (b), BLUE (c), CHLREDEDGE (d), GREEN (e), NDVI (f), NDVI-GREEN (g), NIR (h), PSRI-NIR (i), RED (j) and REDEDGE (k)

8.1.2 Časovna korelacija

Na osnovi vizualne primerjave morda učinkovito izberemo najznačilnejše spektralne sloje, kljub temu pa bi rada njihovo podobnost določila tudi objektivno, numerično. Poleg tega je za veččasovno klasifikacijo zelo pomembno, da se podobnost dveh slojev primerja čez celotno časovno vrsto. Podobnost dveh časovnih vrst lahko učinkovito določimo z linearnim Pearsonovim koeficientom korelacije, ki ga izračunamo po enačbi (6):

$$\rho_{X,Y} = \frac{C(X,Y)}{\sigma_X \sigma_Y} \quad , \quad (6)$$

kjer sta C kovarianca in σ standardni odklon opazovanih grafov, X in Y pa opazovana grafa. S Pearsonovim koeficientom določamo moč povezanosti dveh spremenljivk. Če je koeficient korelacije 0 oz. blizu 0, grafa nista korelirana, bolj kot gre vrednost koeficienta korelacije proti 1, bolj sta si grafa podobna. Z grafoma, katerih korelacija je zelo visoka, bi morali dobiti zelo podoben rezultat veččasovne klasifikacije. Grafa sta močno korelirana tudi v primeru, ko se vrednost koeficienta korelacije bliža številu -1. Tudi v primeru takšne, obratne korelacije, pričakujemo podoben rezultat klasifikacije.


Korelacijo sem računala za študijsko območje Pomurje, za osemdeset različnih spektralnih slojev in za časovno obdobje od aprila do novembra 2013. Ker je končnih kombinacij izračuna korelacij veliko, sem najbolj značilne attribute izbirala na sledeč način: izhajala sem iz grafa indeksa NDVI, nato sem postopoma izločala spektralne sloje, ki imajo z NDVI absolutni koeficient korelacije nad 0,8. Med neizločenimi sem postopek nadaljevala na enak način, pri čemer sem za primerjavo uporabila med njimi bolj znan indeks. Prednost pri izbiri so imeli tudi osnovni spektralni kanali.

Najznačilnejše attribute sem na osnovi korelacij računala za tri primere: neodvisno od razreda pokrovnosti, za osnovne razrede in za osnovne poljščine.

8.1.2.1 Korelacija neodvisna od razreda pokrovnosti

Korelacije, neodvisne od razreda pokrovnosti, sem računala na poljubnem izboru pikslov cele podobe. Na manjšem študijskem območju sem prvotno primerjala korelacije, izračunane iz vseh pikslov, iz 1 % poljubno izbranih pikslov ter 0,5 % poljubno izbranih pikslov. Ker je bila razlika v vrednostih zelo mala, sem z željo po skrajšanju časa izračuna na celotnem posnetku RapidEye (študijsko območje Pomurje) uporabila 0,5 % poljubno izbranih pikslov.

Ker sem pri izračunu korelacij izhajala iz indeksa NDVI, na sliki 43 prikazujem spremenljivost nekaterih izračunanih korelacij v odnosu z NDVI skozi vso rastno sezono. Bolj kot je graf vodoraven in blizu vrednosti 1 oz. -1, bolj je atribut koreliran z atributom NDVI.



Slika 43: Spremenljivost nekaterih izračunanih korelacij v odnosu z NDVI skozi vso rastno sezono

Figure 43: Variability of some calculated correlations in relation to NDVI through the whole growing season

Ko podobnosti časovnih vrst s Pearsonovim koeficientom pretvorimo v številke, dobimo seznam stopnje koreliranosti atributov. V preglednici 11 prikazujem deset najbolj pozitivno, najbolj negativno in najbolj nekoreliranih atributov glede na atribut NDVI, neodvisno od razreda pokrovnosti.

Preglednica 11: Deset najbolj pozitivno, najbolj negativno in najbolj nekoreliranih atributov glede na korelacijo z atributom NDVI, neodvisno od razreda pokrovnosti.

Table 11: Ten most positively, most negatively and most non-correlated attributes according to correlation with NDVI attribute, irrespective of the land cover class.

Spektralni atribut	Visoka pozitivna korelacija z		Nizka korelacija z		Visoka negativna korelacija z
	NDVI	Spektralni atribut	NDVI	Spektralni atribut	NDVI
NDVI	1	BRI	0.081	BLUE	-0.590
SAVI	1	ARVI	0.079	PSRI-NIR	-0.597
IPVI	1	SR_NIR_RED_VAL	0.046	REDEGE	-0.624
TDVI	0.998	EVI	0.023	BR2	-0.684
NIR_REDEGE_RED_SAT	0.989	NDVI-GREEN	0.016	GREEN	-0.685
OSAVI	0.988	SR_GREEN_BLUE_VAL	-0.031	RED_GREEN_BLUE_VAL	-0.787
NDVI_GREEN_BLUE_VAL	0.985	PSRI_NIR_REDEGE_VAL	-0.082	RED	-0.857
LCI	0.978	SUM-RED-NIR	-0.102	CHLGREEN	-0.864
REDEGE AND RED NDVI	0.966	SR_GREEN_BLUE_HUE	-0.225	CHLREDEGE	-0.963
REDEGE NDVI	0.964	BAI	-0.235	BR3	-0.982

Po zgoraj opisanem postopku sem attribute postopoma izločala, tako da sem na osnovi korelacije na celi podobi (neodvisno od razreda pokrovnosti) izbrala attribute, prikazane v preglednici 12.

Preglednica 12: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano neodvisno od razreda pokrovnosti

Table 12: The most characteristic spectral attributes according to correlation strength among attributes, calculated irrespectively of land cover class

Spektralni atributi		
ARI-1	NDVI	REDEDGE
BAI	NIR	SR
BRIGHTNESS	PSRI	SR_NIR_RED_SAT
GNDVI	PSRI_NIR_REEDGE_SAT	SUM-RED-NIR
GREEN	PSRI_NIR_REEDGE_VAL	
NDVI-GREEN	RED_GREEN_BLUE_HUE	

8.1.2.2 Korelacija na osnovnih razredih pokrovnosti

Osnova izračuna je bil referenčni sloj z osnovnimi razredi pokrovnosti. Za vsak razred sem združila vse njegove poligone, s čimer sem dobila en multipoligon na razred. Kot atribut, ki sem ga uporabila pri izračunu korelacije, sem uporabila povprečno vrednost posameznega spektralnega sloja na vseh pikslih posameznega razreda pokrovnosti.


Za lažjo predstavo podobnosti med atributom NDVI in ostalimi atributi pri različnih osnovnih razredih pokrovnosti, na sliki 44 grafično prikazujem vrednosti izračunanih korelacij v obliki t. i. toplotne karte (angl. heatmap), kjer so posamezne stopnje korelacije obarvane. Opaziti je, da je atribut NDVI visoko koreliran vsaj z nekaterimi drugimi atributi, ne glede na osnovni razred pokrovnosti. Nekateri atributi so z atributom NDVI visoko korelirani pri vseh razredih, drugi ne. Podobnost korelacij je zaznati predvsem pri razredih pokrovnosti, vezanih na rastlinstvo (trava, gozd, njive).



Slika 44: Toplotna karta korelacij atributa NDVI z vsemi ostalimi atributi pri osnovnih razredih pokrovnosti. Daljša imena atributov so zapisana v preglednici 10.

Figure 44: Heatmap of correlations of attribute NDVI with all other attributes for basic land cover classes. Entire names of attributes are written in Table 10.

Posamezni atributi niso korelirani zgolj z NDVI, temveč tudi drug z drugim. Na sliki 45 so prikazane toplotne karte korelacij »vsak z vsakim« za vsak osnovni razred posebej. Vrednosti za posamezne attribute so prikazane v enakem vrstnem redu kot na sliki 46, začenši z atributom SUMBANDS (od leve proti desni in od spodaj navzgor). Prikaz toplotnih kart vseh korelacij vseh osnovnih razredov ni namenjen podrobni analizi posameznih korelacij, temveč pridobitvi občutka kako je korelacija odvisna od razreda pokrovnosti. Opazimo lahko, da je veliko atributov visoko koreliranih. Ne zgolj z NDVI, ampak tudi z drugimi atributi. Pri nekaterih razredih bolj (npr. njiva, urbano), pri drugih manj (voda). Je pa pri vseh razredih opaziti podobnost bolj ali manj enakih atributov.



Slika 45: Toplotna karta vseh korelacij vseh atributov pri osnovnih razredih pokrovnosti: njiva (a), trava (b), gozd (c), urbano (d) in voda (e). Atributi so prikazani v enakem vrstnem redu kot na sliki 44 (začenši s SUMBANDS od leve proti desni in od spodaj navzgor).

Figure 45: Heatmap of all correlations and all attributes for basic land cover classes: arable land (a), grass (b), forest (c), build-up (d) and water (e). Attributes are shown in the same order as on image 44 (starting with SUMBANDS from left to right and from bottom to top).

Sledil je izračun najbolj značilnih atributov za posamezen osnovni razred. Ponovno sem uporabila postopek postopnega izločanja. Izbrani najznačilnejši atributi za osnovne razrede pokrovnosti so prikazani v preglednici 13.

Preglednica 13: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano za posamezen osnovni razred pokrovnosti.

Table 13: The most significant spectral attributes according to the correlation strength between the attributes, calculated for each basic land cover class.

Indeks\Razred	njiva	trava	gozd	urbano	voda
ARI-1		x	x		x
ARVI					x
CCCI	x	x		x	x
CHLREDEGE					x
GDVI					x
GNDVI					x
GREEN	x		x		x
LCI			x		
MCARI			x		
MNLI			x		
NDVI	x	x	x	x	x
NDVI-GREEN-BLUE-HUE					x
NDVI-GREEN-BLUE-SAT		x	x		
NDVI-GREEN-BLUE-VAL					x
NIR	x	x	x	x	x
NIR-GREEN-BLUE-HUE					x
NIR-GREEN-BLUE-SAT					x
PSRI-NIR	x	x	x	x	x
PSRI-NIR-REDEGE-SAT	x				
RED-GREEN-BLUE-HUE		x	x		
SR	x			x	
SR-GREEN-BLUE-HUE			x	x	
SR-NIR-RED-HUE					x


Končni seznam najznačilnejših atributov potrjuje sklepe iz toplotnih kart. Korelacija med atributi je pri razredih gozd in voda res šibkejša, zato je končno izbranih značilnih atributov več kot pri ostalih razredih. Se pa atributi med razredi večinoma ponavljajo. In nekaj pri vseh razredih značilnih atributov je najti tudi v primeru korelacije z neupoštevanjem razreda pokrovnosti (preglednica 12), npr. ARI-1, GREEN, NDVI in NIR.

8.1.2.3 Korelacija na osnovnih poljščinah

Na podoben način kot na osnovnih razredih pokrovnosti, sem najznačilnejše attribute določala tudi na osnovnih poljščinah. Poleg drugega referenčnega sloja je bila razlika ta, da korelacije nisem računala na časovnem intervalu celotne rastne sezone (od aprila do novembra), temveč sem poljščine razdelila na dva dela: zimske poljščine (pšenica, ječmen, oljna ogrščica in tritikala) ter poletne poljščine (koruza in buča). Zimske poljščine so posajene v pozni jeseni, vzkljujejo zgodaj pomladi in jih običajno žanjemo zgodaj poleti (junij, julij). Poletne poljščine posejemo spomladi in žanjemo pozno poleti. Za ustrezen

izračun korelacij je potrebno uporabiti ustrezen časovni interval, saj le tako zagotovimo enoličnost poljščine. Na njivah, kjer je pomladi rastla npr. pšenica, lahko poleti rastejo različne poljščine, kot so ajda, ogrščica idr. Za zimske poljščine sem tako določila časovni interval od marca do avgusta, za poletne poljščine pa od aprila do novembra.


Najprej je na sliki 46 prikazana toplotna karta korelacij med atributom NDVI in ostalimi atributi pri različnih osnovnih poljščinah. Opaziti je, da so korelacije precej višje kot pri osnovnih razredih pokrovnosti. To je tudi pričakovano, saj gre za isti razred pokrovnosti.



Slika 46: Toplotna karta korelacij atributa NDVI z vsemi ostalimi atributi pri osnovnih poljščinah pokrovnosti. Daljša imena atributov so zapisana v preglednici 10.

Figure 46: Heatmap of correlations of attribute NDVI with all other attributes for basic crops. Entire names of attributes are written in Table 10.

Nadalje so na sliki 47 prikazane toplotne karte korelacij »vsak z vsakim« za vsako osnovno poljščino posebej. Tudi tukaj je opaziti višjo stopnjo koreliranosti kot v primeru osnovnih razredov pokrovnosti. Ponovno so visoko korelirani približno isti atributi. Dodatno je opaziti, da imata koruza in buča nižje korelacije. Morda za poletni poljščini nisem dobro definirala časovnega intervala.



Slika 47: Toplotna karta vseh korelacij vseh atributov pri razredih osnovnih poljščin: koruza (a), pšenica (b), ječmen (c), oljna buča (d), oljna ogrščica (e) in tritikala (f). Atributi so prikazani v enakem vrstnem redu kot na sliki 44 (začenši s SUMBANDS od leve proti desni in od spodaj navzgor).

Figure 47: Heatmap of all correlations and all attributes for basic crops: maize (a), wheat (b), barley (c), oil pumpkin (d), rapeseed (e) and triticale (f). Attributes are shown in the same order as on image 44 (starting with SUMBANDS from left to right and from bottom to top).

Tudi pri osnovnih poljščinah sem izbor značilnih atributov zaključila s postopkom postopnega izločanja. Izbrani najznačilnejši atributi za osnovne poljščine so prikazani v preglednici 14. Izbor na osnovi številskih vrednosti korelacij potrjuje prve sklepe na osnovi toplotnih kart. Atribut NDVI ima visoko korelacijo z veliko večino ostalih atributov. To pomeni, da pri zimskih poljščinah od skupno osemdeset atributov po izločitvi visoko koreliranih ostane le še peščica najznačilnejših. Pri koruzi in bučah je nabor značilnih atributov malenkost širši.

Preglednica 14: Najznačilnejši spektralni atributi glede na moč korelacije med atributi, izračunano za šest osnovnih poljščin.

Table 14: The most significant spectral attributes according to the correlation strength between the attributes, calculated for each basic croptype.

Indeks\Razred	koruza	pšenica	ječmen	buča	ogrščica	tritikala
ARI-1	x			x		x
BAI	x	x	x	x	x	
BLUE	x					
CHLREDEGE	x					
GREEN	x		x	x		
NDVI	x	x	x	x	x	x
NDVI-GREEN	x	x	x	x	x	x
NIR	x			x		
PSRI		x				
PSRI-NIR				x		x
REDEGE	x			x		
RED-NIR		x		x	x	x

8.1.2.4 Atributi, izbrani s časovno korelacijo

Za dokončen izbor atributov s časovno korelacijo sem primerjala rezultate izbranih atributov na treh primerih: neodvisno od razreda pokrovnosti, za osnovne razrede in za osnovne poljščine (preglednica 15). Izmed 80 možnih atributov se jih v tabelah najznačilnejših (preglednice 12 do 14) pojavlja 34. Precej se jih pojavi zgolj v eni ali dveh možnih pokrovnostih, zato zanje ne moremo trditi, da so res značilni. Atributov, ki se pojavijo pri vsakem primeru razdelitve pokrovnosti vsaj nekajkrat, je zgolj sedem (v preglednici 15 označenih modro):

- ARI-1,
- BAI,
- GREEN,
- NDVI-GREEN,
- NDVI,
- NIR in
- PSRI-NIR.

Te sem izbrala kot najznačilnejše glede na časovno korelacijo in sem jih uporabila pri dodatni izbiri atributov v naslednjih dveh poglavjih. Njihov opis in enačbe so navedene v preglednici 18.

Ker sem v nadaljevanju poleg veččasovne izvajala tudi enočasovno klasifikacijo in ker nisem želela že pred rezultati klasifikacije izločiti osnovnih kanalov, v naslednjih dveh poglavjih uporabim tudi atributa BLUE in RED, čeprav se glede na časovno korelacijo nista izkazala kot najnačilnejša.

Preglednica 15: Najznačilnejši spektralni atributi glede na moč časovne korelacije. Osnovni razredi, označeni od 1 do 5 so: njiva, trava, gozd, urbano, voda. Poljščine, označene od 1 do 6 so: koruza, pšenica, ječmen, buča, ogrščica in tritikala. Izbrani najznačilnejši atributi so obarvani modro. Atributi, ki bodo kot vhodni podatek šli v aplikacijo ReliefF in klasifikacijo, so poudarjeni.

Table 15: The most significant spectral attributes according to the correlation strength. Basic land cover classes, labelled from 1 to 5 are: arable land, grass, forest, build-up and water. Croptypes, labelled from 1 to 6 are: maize, wheat, barley, oil pumpkin, rapeseed and triticale. The selected most significant spectral attributes are coloured in blue. Attributes that will be used as input data in ReliefF application and classification, are printed in bold.

[illegible]

8.1.3 Algoritem ReliefF

Pomembno je vedeti, da izračunane korelacije ne nakazujejo nujno prispevka in pomembnosti določenega spektralnega atributa za kakovost klasifikacije, temveč zgolj redundanco. Zato sem oceno značilnosti atributov izvedla še z algoritmom ReliefF (vgrajenim v programski paket WEKA), ki rangira attribute glede na njihov doprinos h klasifikaciji.

Izbira značilnih atributov (angl. feature selection) je naloga izbire majhne podmnožice atributov, ki je v idealnem primeru nujna in zadostna za opis ciljnega razreda (Kira in Rendell, 1992). Pomembna je tako z vidika hitrosti učenja kot tudi izboljšave kakovosti klasifikacije. Učinkovit algoritem za izbiro statistično najbolj značilnih atributov, imenovan Relief, sta leta 1992 zapisala Kira in Rendell (1992). Operira lahko bodisi z diskretnimi bodisi zveznimi atributi, vendar je omejen na klasifikacijo zgolj dveh razredov. Dve leti kasneje ga je nadgradil Kononenko (1994) v algoritem ReliefF, ki lahko operira s šuma polnimi in nepopolnimi podatki več razredov in je sposoben pravilno oceniti kakovost atributov pri problemih klasifikacije, povezanih z visoko odvisnostjo med atributi (Robnik-Sikonja in Kononenko, 1997).

Najprej sem izhajala iz vseh 80 spektralnih slojev posnetka RapidEye 29.7.2013. Z algoritmom ReliefF sem izbrala 30 najznačilnejših atributov, računanih na mediani poligonov referenčnega sloja. Izbrani atributi so navedeni v preglednici 16.

Preglednica 16: Trideset najznačilnejših atributov po izračunu algoritma ReliefF, izbranih izmed 80 atributov posnetka RapidEye 29.7.2013, računanih kot mediana vrednosti na poligonih referenčnega sloja. S »S« je označena stopnja značilnosti.

Table 16: Thirty most significant attributes according to results of ReliefF algorithm, chosen among 80 attributes of RapidEye image 29.7.2013. The attributes were calculated as median of attribute values of reference layer polygon values. »S« indicates the significance level.

S	Atribut	S	Atribut	S	Atribut
1	SR-GREEN-BLUE-VAL	11	TDVI	21	NDVI-GREEN-BLUE-VAL
2	SR-NIR-RED-VAL	12	PSRI	22	EVI-2
3	SR-NIR-RED-HUE	13	OSAVI	23	TCARI
4	NDVI-REDGER	14	GARI	24	MNLI
5	BR-3	15	PSRI-NIR-REDEGE-HUE	25	EVI
6	SAVI	16	NDVI-REDGE	26	SR
7	NDVI	17	NLI	27	RED-GREEN-BLUE-HUE
8	IPVI	18	CHLREDEGE	28	MCARI
9	ARVI	19	MSR	29	RED
10	LCI	20	PSRI-NIR	30	GNDVI

Med trideset najbolj značilnimi atributi so zgolj trije atributi, izbrani s časovno korelacijo. Ker se izbor najznačilnejših atributov, določenih z algoritmom ReliefF, zelo razlikuje od prejšnjega izbora s časovno korelacijo, sem za hip preskočila postopek in preverila rezultate klasifikacije. Primerjala sem kakovost

klasifikacije osnovnih razredov pokrovnosti na posnetku RapidEye 29.7.2013, osnovni enoti GERK in različnih atributih (mediana na OE), in sicer: devetih atributih, izbranih s korelacijo, osnovnih spektralnih kanalih in trideset najznačilnejših atributih po izboru algoritma ReliefF. Rezultati so v preglednici 17.

Preglednica 17: Rezultati klasifikacije osnovnih razredov pokrovnosti na posnetku RapidEye 29.7.2013, osnovni enoti GERK in različnih atributih (mediana na OE): na devetih atributih, izbranih s korelacijo, na trideset najznačilnejših atributih po izboru algoritma ReliefF in osnovnih štirih spektralnih kanalih.

Table 17: Results of basic land cover class classification of RapidEye image 29.7.2013, mapping unit GERK and different attributes (median on mapping unit): on nine attributes, selected with a correlation, on thirty attributes, selected with ReliefF algorithm and on four basic spectral channels.

Kombinacija atributov	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
devet izbranih	91,13	65,28	97,12	88,39	59,67	89,70
najznačilnejših 30 ReliefF	91,56	68,99	97,12	88,73	80,59	90,48
RED + GREEN + BLUE + NIR	89,86	62,56	97,94	82,75	83,98	88,84

Rezultati atributov algoritma ReliefF so bili pri večini razredov le neznatno boljši od rezultatov, izbranih s korelacijo. Ker pa so bili bistveno boljši pri klasifikaciji vode, sem testno dodala še klasifikacijo z zgolj osnovnimi štirimi spektralnimi kanali. Presenetljivo se je izkazalo, da je klasifikacija z zgolj osnovnimi spektralnimi kanali le malenkost slabša od 30 najboljših atributov iz nabora 80-ih. Ker želim prednost dati osnovnim kanalom ter splošno znanim indeksom in ker se nabor najznačilnejših atributov (izhajajoč iz rezultatov tega poglavja) spreminja glede na datum posnetka in razreda klasifikacije, v nadaljevanju analize izvajam zgolj na devetih spektralnih slojih, ki so se izkazali kot najznačilnejši pri vizualni primerjavi in časovni korelaciji. To so sloji: ARI-1, BAI, BLUE, GREEN, NDVI-GREEN, NDVI, NIR, PSRI-NIR in RED. Ker se jim kasneje podrobneje posvetim, v preglednici 18 na kratko razlagam njihov pomen.

Preglednica 18: Kratek opis devetih izbranih spektralnih atributov

Table 18: Short description of nine selected spectral attributes

Sloj	Ime	Opis
BLUE	moder spektralni kanal	vrednost odbojnosti v modrem delu spektra
GREEN	zelen spektralni kanal	vrednost odbojnosti v zelenem delu spektra
RED	rdeč spektralni kanal	vrednost odbojnosti v rdečem delu spektra
NIR	bližnje-infrardeč spektralni kanal	vrednost odbojnosti v bližnje infrardečem delu spektra
NDVI	normiran diferencialni vegetacijski indeks (angl. Normalized Difference Vegetation Index)	enačba: $NDVI = (NIR - RED) / (NIR + RED)$ NDVI je najbolj znan in uporabljen vegetacijski indeks. Je enostaven, a učinkovit indeks za izmero zelene vegetacije. NDVI normalizira odbojnost zelenih listov v bližnje infrardečem spektru in absorpcijo klorofila v rdečem spektru. Visok indeks nakazuje bujno zeleno rastlinje.
ARI-1	prvi indeks odbojnosti antocianinov (angl. Anthocyanin Reflectance Index 1)	enačba: $ARI-1 = (1/GREEN) - (1/REDEGE)$ ARI-1 je mera odbojnosti, občutljiva na antocianin v listih rastlin. Obratna vrednost antocianina je najvišja v zelenem delu spektra, vendar v tem delu nanjo vpliva tudi klorofil. Učinek vpliva klorofila odstranimo z odštevanjem obratne vrednosti odbojnosti v robnem rdečem delu spektra, kjer je vsebnost klorofila najvišja. Visok indeks nakazuje novo rast ali odmiranje.
BAI	indeks pogorelosti območja (angl. Burn Area Index)	enačba: $BAI = 1 / ((0.1 - RED)^2 + (0.06 - NIR)^2)$ Indeks poudarja z ogljem polno pogorelo območje na posnetkih po požarih.
PSRI-NIR	variacija indeksa PSRI, ki je Indeks odbojnosti staranja rastlin (angl. Plant Senescence Reflectance Index)	enačba: $PSRI = (RED - BLUE) / REDEGE$ Indeks je oblikovan tako, da v največji možni meri poveča občutljivost razmerja količine karotenoidov in klorofila. Višanje indeksa nakazuje na stres rastline, njeno staranje ali zorjenje sadežev.
NDVI-GREEN	izmišljena kombinacija	Enačba naše variacije: $PSRI-NIR = (RED - BLUE) / NIR$ enačba: $NDVI-GREEN = NDVI * GREEN$

Statistično značilne attribute sem v algoritmu ReliefF iskala na primeru enočasovne in veččasovne klasifikacije.

Enočasovno klasifikacijo sem izvajala na treh različnih datumih: 18.5.2013, 29.7.2013 in 14.9.2013 (spomladi, poleti in jeseni). Primerjala sem mediano vrednosti posameznih spektralnih slojev na poligonih referenčnega sloja. Ti poligoni so sicer iz kombinacije dveh različnih slojev (GERK oz. RABA izven GERK). Za njihovo lažje poimenovanje v nadaljevanju disertacije uporabljam poenostavljeno kratico GERK. Klasifikacije sem izvedla s posnetki RapidEye na študijskem območju Pomurja. Statistično značilnost sem določala za klasifikacijo osnovnih razredov in osnovnih poljščin. Značilnost atributov za klasifikacijo (od 1 – najznačilnejši do 9 – najmanj značilen) za posamezen datum posnetka ter posplošena značilnost atributov je prikazana v preglednicah 19 (osnovni razredi) in 20 (osnovne poljščine).

Preglednica 19: Stopnje značilnosti devetih atributov (mediana na OE), določene na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih razredov na posnetku RapidEye in študijskem območju Pomurja. Stopnja pri treh različnih datumih, seštevek posameznih stopenj ter skupna stopnja značilnosti. Nižji seštevek pomeni višjo značilnost atributa.

Table 19: Significance level of nine attributes (median on mapping unit), defined by ReliefF algorithm, used for basic land cover classification of RapidEye image and Pomurje study area. Significance level at three different dates, sum of individual levels and total level of significance. A lower sum means higher significance of attribute.

stopnja značilnosti	atribut	ReliefF stopnja			
		18.5.2013	29.7.2013	14.9.2013	seštevek treh datumov
1	NDVI	4	1	1	6
2	PSRI-NIR	1	2	4	7
3	NIR	3	3	2	8
4	RED	6	4	3	13
5	NDVI-GREEN	2	5	7	14
6	BLUE	5	7	8	20
7	GREEN	7	8	5	20
8	BAI	8	9	6	23
9	ARI-1	9	6	9	24

Preglednica 20: Stopnje značilnosti devetih atributov (mediana na OE), določene na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih poljščin na posnetku RapidEye in študijskem območju Pomurja. Stopnja pri treh različnih datumih, seštevek posameznih stopenj ter skupna stopnja značilnosti. Nižji seštevek pomeni višjo značilnost atributa.

Table 20: Significance level of nine attributes (median on mapping unit), defined by ReliefF algorithm, used for croptype classification of RapidEye image and Pomurje study area. Significance level at three different dates, sum of individual levels and total level of significance. A lower sum means higher significance of attribute.

stopnja značilnosti	atribut	ReliefF stopnja			
		18.5.2013	29.7.2013	14.9.2013	seštevek treh datumov
1	NDVI	2	3	1	6
2	NDVI-GREEN	3	1	6	10
3	PSRI-NIR	1	2	7	10
4	NIR	6	4	2	12
5	RED	5	5	3	13
6	GREEN	4	7	5	16
7	BAI	9	8	4	21
8	ARI-1	8	6	9	23
9	BLUE	7	9	8	24

V primeru enočasovne klasifikacije so tako pri klasifikaciji osnovnih razredov kakor tudi pri klasifikaciji osnovnih poljščin najznačilnejši atributi mediane spektralnih slojev NDVI, NIR, RED, NDVI-GREEN in PSRI-NIR. Atributi slojev BAI, BLUE, GREEN in ARI-1 so bili pri veliki večini klasifikacij najmanj značilni.

Tudi veččasovno klasifikacijo osnovnih razredov in osnovnih poljščin sem izvajala na študijskem območju Pomurja, posnetku RapidEye in mediani poligonov referenčnega sloja. Uporabila sem vse posnetke datumov od 9.4.2013 do 26.10.2013 (13 posnetkov). Ker sem izvajala kvazi veččasovno klasifikacijo, se vrednosti istih spektralnih slojev, a različnih časovnih trenutkov, smatrajo kot svoj, ločen atribut. Izmed skupno 117 atributov v preglednici 21 navajam trideset najboljših po izboru algoritma ReliefF. V preglednici 22 povzemam značilnost posameznega spektralnega sloja, ne glede na datum.

Preglednica 21: Stopnja značilnosti atributov (mediana na OE), določena na osnovi algoritma ReliefF, uporabljenega pri klasifikaciji osnovnih razredov in osnovnih poljščin na posnetku RapidEye, študijsko območje Pomurja.

Table 21: Significance level of attributes (median on mapping unit), defined by ReliefF algorithm, used for basic land cover and croptype classification of RapidEye image on Pomurje study area.

ReliefF stopnja	Atribut	
	Osnovni razredi	Poljščine
1	2013-07-29_NDVI	2013-05-19_NDVI
2	2013-05-19_NDVI	2013-05-18_NDVI
3	2013-07-17_NDVI-GREEN	2013-05-19_PSRI-NIR
4	2013-07-29_PSRI-NIR	2013-05-18_PSRI-Nir
5	2013-05-18_NDVI	2013-05-19_RED
6	2013-07-17_PSRI-NIR	2013-05-19_ARI-1
7	2013-07-17_NIR	2013-07-17_NDVI-GREEN
8	2013-05-18_PSRI-NIR	2013-07-29_PSRI-NIR
9	2013-07-17_NDVI	2013-07-17_PSRI-NIR
10	2013-07-17_RED	2013-05-19_GREEN
11	2013-08-18_NDVI	2013-07-17_GREEN
12	2013-10-08_PSRI-NIR	2013-07-17_NIR
13	2013-07-17_GREEN	2013-07-29_NDVI
14	2013-10-08_NDVI	2013-07-17_RED
15	2013-07-02_NDVI	2013-05-19_BLUE
16	2013-05-19_PSRI-NIR	2013-07-17_NDVI
17	2013-09-14_NDVI	2013-06-15_NDVI
18	2013-05-19_RED	2013-07-17_ARI-1
19	2013-07-29_RED	2013-07-17_BLUE
20	2013-08-18_PSRI-NIR	2013-05-18_RED
21	2013-05-18_NDVI-GREEN	2013-07-02_NDVI
22	2013-10-26_NDVI	2013-07-17_BAI
23	2013-05-19_GREEN	2013-05-18_NDVI-GREEN
24	2013-10-08_NDVI-GREEN	2013-10-26_NDVI
25	2013-05-18_RED	2013-10-26_PSRI-NIR
26	2013-07-02_NIR	2013-05-18_ARI-1
27	2013-10-08_NIR	2013-05-19_NDVI-GREEN
28	2013-10-26_PSRI-NIR	2013-07-29_RED
29	2013-08-18_RED	2013-07-02_NIR
30	2013-05-19_NDVI-GREEN	2013-05-18_GREEN

Preglednica 22: Število pojavitev posameznega spektralnega atributa med trideset najznačilnejšimi atributi (ne glede na datum). Dobljeno iz preglednice 21.

Table 22: Number of occurrences of specific spectral attribute among thirty most specific attributes (irrespective of the capture date). Obtained from Table 21.

Spektralni sloj	Pojavitev med prvih dvajset (ne glede na datum)	
	Osnovni razredi	Poljščine
NDVI	9	7
PSRI-NIR	7	5
RED	5	4
NDVI-GREEN	4	3
NIR	3	2
GREEN	2	3
ARI-1	0	3
BLUE	0	2
BAI	0	1

V primeru kvazi veččasovne klasifikacije so tako pri klasifikaciji osnovnih razredov kakor tudi pri klasifikaciji osnovnih poljščin najznačilnejši atributi slojev NDVI, PSRI-NIR, RED in NDVI-GREEN. Sledita NIR in GREEN. Podobno kot pri enočasovni klasifikaciji, so najmanj značilni atributi ARI-1, BAI in BLUE. Če jih kaže v dobro kakovosti klasifikacije pri klasifikaciji izpustiti, preverjam v sledečem podpoglavju.

8.1.4 Klasifikacija

V poglavju je prikazana učinkovitost posameznega atributa oz. skupine atributov pri klasifikaciji. Izhajala sem iz istih devetih spektralnih slojev kot sem jih testirala z algoritmom ReliefF. Osnovna enota je bila GERK, atribut je mediana vrednosti spektralnega sloja znotraj osnovne enote, študijsko območje Pomurje. Ker je disertacija osredotočena na osnovne razrede pokrovnosti in ker se je pri ostalih metodah določitve značilnih atributov izkazalo, da imajo tako osnovni razredi kot tudi osnovne poljščine približno enake značilne attribute, sem poudarek dala na klasifikacijo osnovnih razredov.

Izvedla sem enočasovno klasifikacijo s tremi različnimi datumi ter veččasovno klasifikacijo s časovno vrsto posnetkov. Pri vsaki vrsti klasifikacije sem naprej preverila učinkovitost posameznega atributa, nato pa učinkovitost skupine atributov, kjer sem uporabila pristop postopnega dodajanja atributov, od posamezno najboljšega do posamezno najslabšega.

Učinkovitost atributa sem poleg skupne natančnosti klasifikacije določala tudi glede na F-mero posameznega razreda. Za učinkovitost atributa ni dovolj, da ima zgolj najvišjo skupno natančnost. Želja je, da vse razrede klasificira približno enako kakovostno.

8.1.4.1 Enočasovna klasifikacija

Enočasovno klasifikacijo sem izvedla na posameznih spektralnih slojih posnetkov RapidEye treh

različnih datumov: 18.5.2013 (preglednica 23), 29.7.2013 (preglednica 24) in 14.9.2013 (preglednica 25).

Preglednica 23: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 18.5.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.

Table 23: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 18.5.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.

Atribut\Razred	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
ARI-1	64,07	0,00	0,00	0,00	0,00	47,14
BAI	59,01	50,75	0,00	0,00	0,00	45,81
BLUE	78,74	7,57	0,00	0,00	0,00	45,87
GREEN	64,07	0,00	0,00	0,00	0,00	47,14
NDVI	74,68	17,74	0,00	0,00	0,00	44,21
NDVI-GREEN	60,54	39,50	0,00	0,00	82,28	46,18
NIR	60,25	50,76	0,00	0,00	93,38	47,28
PSRI-NIR	61,46	7,76	0,00	0,00	0,00	44,60
RED	64,07	0,00	0,00	0,00	0,00	47,14

Preglednica 24: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.

Table 24: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.

Atribut\Razred	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
ARI-1	82,15	0,00	97,14	0,00	0,00	79,01
BAI	64,40	0,00	0,00	1,04	91,99	47,91
BLUE	81,47	0,00	96,01	0,00	0,00	78,17
GREEN	81,94	0,00	96,91	0,00	0,00	78,80
NDVI	80,70	0,00	95,72	0,00	0,00	77,70
NDVI-GREEN	64,07	0,00	0,00	0,00	0,00	47,14
NIR	64,07	0,00	0,00	0,00	0,00	47,14
PSRI-NIR	66,36	0,00	27,54	0,00	0,00	52,46
RED	82,17	0,00	96,51	0,00	0,00	78,85

Preglednica 25: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 14.9.2013. Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje.

Table 25: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 14.9.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area.

Atribut\Razred	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
ARI-1	64,00	0,52	0,00	0,00	0,00	47,06
BAI	62,72	56,65	0,00	0,00	0,00	49,16
BLUE	82,66	17,52	0,00	0,00	0,00	48,67
GREEN	64,07	0,00	0,00	0,00	0,00	47,14
NDVI	83,17	26,11	0,00	0,00	0,00	50,11
NDVI-GREEN	64,07	0,00	0,00	0,00	0,00	47,14
NIR	63,25	55,98	0,00	0,00	0,00	49,49
PSRI-NIR	80,98	27,64	0,00	0,00	0,00	49,45
RED	82,99	23,85	0,00	0,00	0,00	49,20

Rezultati klasifikacije s posameznimi atributi povsem spremenijo sliko o izboru najznačilnejših atributov. Najuspešnejši atributi se sicer med različnimi datumi spreminjajo, svojo vlogo najznačilnejšega ohranja zgolj atribut NDVI. Presenečenje je uspešnost atributa BAI, ki je do sedaj veljal za najmanj značilnega. Skupno vsem datumom in vsem atributom pa je, da so rezultati klasifikacije zelo slabi, zato moramo v primeru enočasovne klasifikacije predvidoma nujno uporabiti kombinacijo več atributov.

Kombinacije sem izvajala s pristopom postopnega dodajanja atributov. Izhajam iz najboljšega atributa, nato mu dodajam drugi najboljši atribut itn. Kombinacije sem izvedla zgolj za 29.7.2013, na štiri različne načine. Prve kombinacije sem sestavila na osnovi osebne presoje kakovosti klasifikacij s posameznimi atributi (preglednica 26). Osnova drugih kombinacij (preglednica 27) je bil vrstni red atributov, kot ga predlaga algoritem ReliefF. Pri tretjem načinu sem skombinirala attribute, ki se v praksi najpogosteje uporabljajo za klasifikacijo pokrovnosti (preglednica 28), v zadnjem načinu (preglednica 29) pa sem naredila nekaj dodatnih, testnih kombinacij, pri katerih sem izhajala iz seznama najboljših in najslabših atributov glede na predlog algoritma ReliefF ter ne vključiti posameznih atributov v postopek klasifikacije.

Preglednica 26: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z najboljšim, potem pa postopoma dodajamo naslednje najboljše glede na osebno presojo kakovosti klasifikacij s posameznimi atributi (preglednica 24).

Table 26: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to personal classification quality evaluation of individual attributes (Table 24).

Kombinacija atributov	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
ARI-1	82,15	0,00	97,14	0,00	0,00	79,01
ARI-1 + RED	82,65	13,73	85,38	0,00	0,00	72,98
oba prejšnja + GREEN	83,25	36,70	96,19	0,48	0,00	80,19
vsi prejšnji + BLUE	87,55	28,61	97,05	89,43	0,00	85,89
vsi prejšnji + NDVI	90,51	59,44	97,67	80,06	0,00	88,48
vsi prejšnji + PSRI-NIR	91,49	64,41	97,53	84,64	0,00	89,63
vsi prejšnji + BAI	90,58	64,36	97,93	87,52	58,80	89,67
vsi prejšnji + NIR	90,23	61,28	97,70	89,26	58,55	89,29
vsi prejšnji + NDVI-GREEN	91,13	65,28	97,12	88,39	59,67	89,70

Za zadovoljiv rezultat vseh osnovnih razredov pokrovnosti je bilo potrebno uporabiti kombinacijo sedmih atributov. Z dodanim osmim in devetim atributom rezultata nisem več bistveno izboljšala. Dober rezultat sem dosegla s kombinacijo atributov ARI-1, RED, GREEN, BLUE, NDVI, PSRI-NIR in BAI. Atributa NIR in NDVI-GREEN k temu rezultatu nista doprinesla.

Preglednica 27: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z najboljšim, potem pa postopoma dodajamo naslednje najboljše glede na vrstni red, kot ga predlaga ReliefF (preglednica 20).

Table 27: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to ReliefF classification quality evaluation of individual attributes (Table 20).

Kombinacija atributov	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
NDVI	80,70	0,00	95,72	0,00	0,00	77,70
NDVI + PSRI-NIR	64,68	0,00	0,00	19,82	0,00	47,79
oba prejšnja + NIR	89,99	60,77	97,73	87,41	49,44	88,62
vsi prejšnji + RED	90,09	58,90	97,76	89,13	93,08	89,08
vsi prejšnji + NDVI-GREEN	89,81	59,37	97,75	82,96	0,00	88,01
vsi prejšnji + ARI-1	91,45	62,76	98,06	87,63	54,72	89,96
vsi prejšnji + BLUE	91,27	64,36	96,44	85,50	44,80	89,06
vsi prejšnji + GREEN	91,22	67,75	97,05	89,26	43,96	89,95
vsi prejšnji + BAI	90,28	64,50	96,54	84,96	53,40	88,91

Z upoštevanjem vrstnega reda, kot ga predlaga ReliefF, sem dobre rezultate dosegla z manjšim številom atributov. S štirimi atributi (NDVI, PSRI-NIR, NIR in RED) sem dosegla boljšo kakovost, kot z dodajanjem kateregakoli ostalega atributa. Naslednji dodan atribut, NDVI-GREEN, je celo popolnoma onemogočil določitev vode. Pri postopnem dodajanju atributov ni opaziti določenega logičnega zaporedja, ki bi omogočal zanesljivo določitev števila uporabnih atributov.

Preglednica 28: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. V praksi najpogostejše uporabljane kombinacije atributov.

Table 28: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The most often used attribute combinations in practice.

Kombinacija atributov	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
RED + GREEN + BLUE	86,86	30,21	96,66	86,19	0,00	85,22
RED + GREEN + BLUE + NIR	89,86	62,56	97,94	82,75	83,98	88,84
RED + GREEN + BLUE + NIR + NDVI	89,67	54,26	95,76	82,26	92,58	87,17

Kanali vidne svetlobe (atributi RED, GREEN in BLUE) na posnetku 29.7.2013 niso bili dovolj za uspešno klasifikacijo osnovnih razredov pokrovnosti. Največje težave predstavlja voda, za katero je znano, da jo najboljše določimo z bližnjim infrardečim kanalom. Atribut NIR, pridružen osnovnim atributom vidne svetlobe, občutno izboljša kakovost klasifikacije, ki kot takšen uspešno konkurira kakovosti klasifikacije, dobljene s kombinacijo vseh devetih atributov. Pri nekaterih razredih (voda) jo celo občutno preseže. Če dodamo tej kombinaciji še atribut NDVI, rezultata ne izboljšamo, le malo premešamo kakovost posameznih razredov.

Preglednica 29: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. Kombinacije najboljših in najslabših atributov glede na predlog algoritma ReliefF ter kombinacije z izključevanjem posameznih atributov.

Table 29: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. Combinations of the best and the worst attributes according to ReliefF algorithm and combinations with excluding specific attributes.

Kombinacija atributov	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
RED + NIR + NDVI	89,03	45,72	96,24	0,00	0,00	81,50
RED + NIR + NDVI + PSRI-NIR	90,09	58,88	97,76	89,15	93,08	89,12
RED + NIR + NDVI + PSRI-NIR + NDVI-GREEN	90,16	60,23	97,64	89,88	69,81	89,06
ARI-1 + BAI + BLUE	85,09	55,34	97,52	5,71	0,00	82,46
ARI-1 + BAI + BLUE + GREEN	89,65	56,75	97,52	84,97	0,00	88,20
ARI-1 + BAI + BLUE + GREEN + NDVI-GREEN	90,47	58,19	97,41	88,22	87,25	89,34
vseh devet brez ARI-1	89,23	51,12	97,82	86,98	83,74	88,08
vseh devet brez BAI	90,06	64,01	95,67	83,49	0,00	88,18
vseh devet brez BLUE	90,84	60,99	97,22	88,17	57,87	89,23
vseh devet brez GREEN	90,70	63,39	97,90	88,49	24,75	89,53
vseh devet brez NDVI	91,30	63,72	98,08	90,75	82,50	90,34
vseh devet brez NDVI-GREEN	89,92	56,14	97,91	87,56	51,16	88,70
vseh devet brez NIR	91,58	61,77	97,43	86,89	85,44	90,05
vseh devet brez PSRI-NIR	90,76	62,45	96,93	88,12	55,44	89,17
vseh devet brez red	90,82	63,44	97,78	88,37	49,22	89,68

Ker me kombinacije v preglednicah 26 do 29 niso pripeljale do sklepa o najznačilnejših atributih, sem naredila nekaj dodatnih testnih kombinacij. V prvih treh vrsticah preglednica 29 sem kombinirala najboljše attribute po predlogu algoritma ReliefF. Zgolj trije najboljši atributi niso bili dovolj, četudi je vključen atribut NIR. S štirimi najboljšimi atributi pa dosežemo eno izmed najvišjih kakovosti za ta primer klasifikacije. K njim dodan atribut NDVI-GREEN precej poslabša kakovost klasifikacije vode.

Če uporabimo kombinacijo treh po presoji algoritma ReliefF najslabših atributov, brez presenečenj dobimo slab rezultat. Ko dodamo še četrtega, se kakovost izboljša, pri petem pa presenetljivo zelo konkurira kombinaciji najboljših atributov.

V nadaljevanju sem testirala klasifikacije z vsemi atributi, pri čemer sem izločala posamezne attribute. Sklepala sem, da bi v primeru izločitve zelo značilnega atributa, dobila občutno slabšo klasifikacijo. Vendar pa sta rezultate pokvarila atributa BAI in GREEN, ki sicer glede na stopnje ReliefF veljata za najmanj učinkovita.

Za potrditev oz. zavrnitev sklepov sem z nekaj kombinacijami atributov klasificirala še osnovne poljščine (preglednica 30).

Preglednica 30: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Mediana atributov na GERK. Študijsko območje Pomurje. V praksi najpogosteje uporabljane kombinacije atributov, uspešna kombinacija pri klasifikaciji osnovnih razredov ter kombinacija vseh devetih atributov.

Table 30: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Median of spectral layer values of GERK mapping unit. Pomurje study area. The most often used attribute combinations in practice, successful combination at basic land cover class classification and combination of all nine attributes.

Atribut\Razred	F-mera (%)					OA (%)	
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
RED + GREEN + BLUE	88,79	73,96	6,76	64,09	25,51	0,00	71,40
RED + GREEN + BLUE + NIR	88,72	72,61	5,87	65,51	22,43	0,00	70,74
RED + GREEN + BLUE + NIR + NDVI	87,58	74,76	14,88	63,25	35,09	0,00	71,22
RED + NIR + NDVI + PSRI-NIR	86,70	75,65	24,31	12,84	2,16	0,00	70,22
vseh devet	90,31	76,05	29,08	71,05	9,01	0,00	73,20

Takoj opazimo, da je osnovne poljščine veliko težje ločiti med seboj kakor osnovne razrede. Poseben problem predstavlja tritikala, saj je dejansko vrsta pšenice. Neznačilen je tudi ječmen in celo ogrščica, čeprav je na pogled živo rumene barve. Teh treh razredov nisem uspešno določila z nobeno kombinacijo atributov. Enako kot pri enočasovni klasifikaciji osnovnih razredov, sem tudi pri enočasovni klasifikaciji osnovnih poljščin (za 29.7.2013) relativno najboljše rezultate dosegla z uporabo zgolj osnovnih spektralnih kanalov. Neobvezno lahko dodamo atribut NDVI, s čimer ne zagotavljamo boljšega rezultata.

Kakovost enočasovne klasifikacije lahko občutno izboljšamo z uporabo več kot enega atributa. Kljub istim učnim točkam in enakemu klasifikatorju, so rezultati klasifikacij nepredvidljivi. Načeloma dodajanje atributov klasifikacijo izboljša, ni pa nujno. Nekateri atributi v določeni kombinaciji klasifikacijo celo poslabšajo. Kljub nejasnim smernicam glede najustreznejše kombinacije atributov je precej jasno, da za dosego enega boljših rezultatov enočasovne klasifikacije zadošča uporaba kombinacije osnovnih spektralnih kanalov.

8.1.4.2 Kvazi veččasovna klasifikacija

Veččasovno klasifikacijo sem izvedla na posameznih atributih časovne vrste posnetkov RapidEye od 4.9.2013 do 26.10.2013. Podobno kot na primerih enočasovne klasifikacije, sem tudi veččasovno klasifikacijo izvajala s različnimi kombinacijami atributov, le da je bilo v tem primeru le-teh več: vsak spektralni sloj ima toliko atributov, kot je datumov posnetkov. Najprej sem klasifikacijo izvedla na posameznih spektralnih slojih skozi čas (preglednica 31). Nato sem izvajala kombinacije s pristopom postopnega dodajanja atributov ostalih spektralnih slojev. Prve kombinacije sem sestavila na osnovi osebne presoje kakovosti klasifikacij s posameznimi atributi (preglednica 32). Osnova drugih kombinacij (preglednica 33) je bil vrstni red atributov, kot ga predlaga algoritem ReliefF. Pri tretjem načinu sem skombinirala attribute, ki se v praksi najpogosteje uporabljajo za klasifikacijo pokrovnosti (preglednica 34).

Preglednica 31: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje. Vsi časi za en sloj, vsak sloj posebej.

Table 31: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. All dates for one layer, each layer separately.

Atributi (vsi časi)	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
ARI-1	90,04	58,45	83,26	81,08	0,00	81,68
BAI	91,13	70,30	89,37	82,37	55,33	86,93
BLUE	89,69	59,73	87,71	52,81	0,00	82,40
GREEN	93,81	65,36	89,87	84,61	1,16	87,19
NDVI	94,36	70,55	90,67	88,47	0,00	88,99
NDVI-GREEN	91,28	60,92	85,28	72,35	1,04	82,93
NIR	94,06	72,34	90,99	82,82	70,16	89,04
PSRI-NIR	95,00	77,81	94,73	89,54	19,86	91,91
RED	94,87	74,02	94,17	89,40	0,00	91,11

Že enspektralni sloj, za katerega imamo na voljo daljšo časovno vrsto, lahko omogoči dobro klasifikacijo, tudi vseh osnovnih razredov. Rezultati se pri večini razredov bistveno ne razlikujejo, pri vodi pa pozitivno izstopata atributa NIR in BAI. Že zgolj s časovno vrsto atributa NIR dobimo kakovost klasifikacije, zelo konkurenčno najboljši enočasovni klasifikaciji, dobljeni s kombinacijo več atributov. Presenetljivo je, da atribut NDVI zaostaja za drugimi atributi, še posebej pri klasifikaciji vode. Verjetno na račun urbanih površin, saj imata oba razreda zelo nizek indeks NDVI.

Preglednica 32: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje. Začnemo z vsemi datumi najboljšega spektralnega sloja, potem pa postopoma dodajamo naslednje najboljše glede na osebno presojo kakovosti klasifikacij s posameznimi atributi (izhajajoč iz preglednice 31).

Table 32: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to personal estimation of classification quality of individual attributes (based on Table 31).

Atributi (vsi časi)	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
NIR	94,06	72,34	90,99	82,82	70,16	89,04
NIR + BAI	93,15	75,76	91,66	83,39	82,56	89,59
oba prejšnja + PSRI-NIR	95,41	82,12	96,86	89,87	70,90	93,64
vsi prejšnji + RED	95,33	72,42	96,83	58,98	72,06	90,53
vsi prejšnji + NDVI	95,16	67,00	93,53	51,33	68,61	87,87
vsi prejšnji + GREEN	95,02	76,38	94,36	88,56	75,30	91,77
vsi prejšnji + NDVI-GREEN	95,38	71,31	92,81	90,69	60,72	90,72
vsi prejšnji + BLUE	95,80	70,02	90,64	91,50	92,18	90,16
vsi prejšnji + ARI-1	93,46	79,61	93,06	89,77	79,99	91,19

Kombinacije spektralnih slojev sicer izboljšujejo rezultat, ne pa bistveno. Dva ali trije sloji povsem zadoščajo. Večje število atributov ne pomeni nujno boljše klasifikacije. Naj spomnim, da en sloj v

primeru veččasovne klasifikacije pomeni 13 atributov, dva sloja 26 itd.

Preglednica 33: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov (N) se iz koraka v korak povečuje. Začnemo z vsemi datumi najboljšega spektralnega sloja, potem pa postopoma dodajamo naslednje najboljše glede na izbiro atributov z algoritmom ReliefF (preglednica 21). Krepmo so označeni atributi najboljših rezultatov.

Table 33: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step. We start with the best attribute than we gradually add the next best attributes according to ReliefF selection of best classification attributes (Table 21). Attributes of the best results are marked bold.

N	Atribut	F-mera (%)					OA (%)
		njiva	trava	gozd	urbano	voda	
1	2013-07-29_NDVI	80,70	0,00	95,72	0,00	0,00	77,70
2	+ 2013-05-19_NDVI	82,45	43,22	51,50	15,58	0,00	63,84
3	+ 2013-07-17_NDVI-GREEN	86,39	69,91	97,82	24,74	0,00	84,78
4	+ 2013-07-29_PSRI-NIR	91,39	68,92	97,30	86,22	0,00	89,40
5	+ 2013-05-18_NDVI	91,28	69,64	98,02	83,46	0,00	89,70
6	+ 2013-07-17_PSRI-NIR	92,43	72,84	98,11	87,93	0,00	90,99
7	+ 2013-07-17_NIR	92,00	70,48	97,63	84,13	0,00	90,09
8	+ 2013-05-18_PSRI-NIR	92,31	53,02	80,59	91,22	0,00	81,41
9	+ 2013-07-17_NDVI	92,26	67,54	95,60	85,61	0,00	89,02
10	+ 2013-07-17_RED	92,17	61,50	91,32	84,31	0,00	86,16
11	+ 2013-08-18_NDVI	93,25	69,38	95,88	88,34	0,00	90,11
12	+ 2013-10-08_PSRI-NIR	94,73	71,57	94,51	87,31	0,00	90,62
13	+ 2013-07-17_GREEN	94,56	70,99	93,37	89,81	0,00	90,22
14	+ 2013-10-08_NDVI	94,43	65,67	91,72	87,88	0,02	88,66
15	+2013-07-02_NDVI	94,28	72,50	92,67	88,08	0,00	90,01
16	+2013-05-19_PSRI-NIR	94,96	67,10	91,16	90,02	0,00	89,10
17	+2013-09-14_NDVI	95,07	74,48	93,43	89,44	11,90	91,02
18	+2013-05-19_RED	95,14	74,03	93,50	91,46	48,13	91,33
19	+ 2013-07-29_RED	95,33	75,22	93,97	91,52	65,17	91,78
20	+ 2013-08-18_PSRI-NIR	95,11	70,78	90,76	92,29	49,04	89,86
21	+ 2013-05-18_NDVI-GREEN	95,06	76,49	93,91	92,56	59,56	91,87
22	+ 2013-10-26_NDVI	94,43	76,32	94,20	90,99	51,26	91,56
23	+ 2013-05-19_GREEN	95,45	76,90	94,54	93,16	56,60	92,29
24	+ 2013-10-08_NDVI-GREEN	95,67	75,83	93,77	92,26	43,96	91,80
25	+ 2013-05-18_RED	95,51	78,09	94,89	92,59	69,60	92,66
26	+ 2013-07-02_NIR	91,99	64,13	82,25	60,49	48,26	82,72
27	+ 2013-10-08_NIR	94,96	70,95	89,19	92,91	38,99	89,26
28	+ 2013-10-26_PSRI-NIR	95,98	77,60	95,18	92,10	63,68	92,81
29	+ 2013-08-18_RED	95,71	78,15	94,78	92,51	48,41	92,54
30	+ 2013-05-19_NDVI-GREEN	95,71	78,15	94,78	92,51	48,41	92,54
117	vsi atributi vseh časov	93,46	79,61	93,06	89,77	79,99	91,19

V primeru veččasovne klasifikacije algoritem ReliefF izbira med vsemi atributi, torej med posameznimi datumi spektralnih slojev in ne posameznih slojev skozi čas. Z dodajanjem atributov izboljšujemo klasifikacijo, ampak vidnega pravila zopet ni. Najboljše (in med seboj primerljive) klasifikacije dobimo z 19-, 25- in 28-timi atributi. Uporaba vseh 117 atributov klasifikacijo določenih razredov malenkost izboljša, medtem ko druge celo malenkost poslabša.

Preglednica 34: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Rezultati klasifikacij z dvema kombinacijama osnovnih spektralnih kanalov ter njima dodanim atributom NDVI. Število atributov je označeno z N.

Table 34: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. Classification evaluation results of two combinations of spectral channels and them added attribute NDVI. Number of attributes is marked with N.

N	atributi (vsi časi)	F-mera (%)					OA (%)
		njiva	trava	gozd	urbano	voda	
39	RED + GREEN + BLUE	95,25	75,97	94,89	91,91	0,00	91,84
52	RED + GREEN + BLUE + NIR	91,78	64,29	79,04	88,45	30,17	83,32
65	RED + GREEN + BLUE + NIR + NDVI	92,00	80,24	96,42	52,68	79,91	89,86

Kombinacija atributov osnovnih kanalov tudi pri veččasovni klasifikaciji osnovnih razredov omogoča kakovost klasifikacije, ki ne zaostaja zelo za najboljšo kombinacijo. Za razliko od enočasovne klasifikacije, ima dodajanje atributa NDVI pri veččasovni klasifikaciji malo večji pomen.

Potrebo po uporabi vseh časov osnovnih atributov sem preverila tako, da sem postopoma izvajala klasifikacijo z določenim številom najznačilnejših atributov po izboru algoritma ReliefF. Rezultati so v preglednici 35.

Preglednica 35: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana atributov na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje, glede na število najznačilnejših atributov po izboru algoritma ReliefF. Rezultati klasifikacij s kombinacijo osnovnih spektralnih kanalov ter njim dodanim atributom NDVI. Število atributov je označeno z N.

Table 35: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step, according to best attribute definition of ReliefF algorithm. Classification evaluation results of combinations of spectral channels and them added attribute NDVI. Number of attributes is marked with N.

N	Atribut (vsi časi)	F-mera (%)					OA (%)
		njiva	trava	gozd	urbano	voda	
10	RED + GREEN + BLUE + NIR	94,38	77,93	96,44	87,68	0,00	91,93
20	RED + GREEN + BLUE + NIR	94,23	78,37	93,42	89,67	49,95	91,23
30	RED + GREEN + BLUE + NIR	94,98	72,39	91,05	90,77	19,86	89,84
40	RED + GREEN + BLUE + NIR	88,48	77,50	79,89	92,12	87,67	84,86
10	RED + GREEN + BLUE + NIR + NDVI	92,48	73,25	92,76	88,04	0,00	89,40
20	RED + GREEN + BLUE + NIR + NDVI	94,11	79,48	94,09	91,42	45,72	91,77
30	RED + GREEN + BLUE + NIR + NDVI	95,56	72,03	91,70	90,38	63,11	90,47
40	RED + GREEN + BLUE + NIR + NDVI	95,04	78,38	94,13	92,04	24,82	91,91

Rezultati kažejo, da za enako dober rezultat ni potrebe po uporabi vseh izbranih slojev vseh časov. Z manj atributi lahko dobimo celo boljši rezultat. Priporočeno število najboljših atributov ostaja neznanka. Vse kaže, da se je najbolje odločiti po nekaj iteracijah.

Preglednica 36: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti vseh spektralnih slojev na GERK. Študijsko območje Pomurje. Število atributov se iz koraka v korak povečuje, glede na število najznačilnejših atributov po izboru algoritma ReliefF.

Table 36: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The number of attributes is enlarging step by step, according to best attribute definition of ReliefF algorithm.

Št. najznačilnejših atributov	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
5	90,81	75,89	45,91	0,00	55,08	0,00	75,47
10	91,86	82,58	65,92	24,19	73,61	0,00	81,10
15	92,18	85,00	67,68	33,06	77,38	0,00	82,72
20	92,47	86,49	73,61	33,78	82,82	40,56	84,68
25	92,93	87,19	76,20	41,35	85,46	32,59	85,63
30	94,14	87,60	77,10	63,65	84,15	33,39	86,87
35	94,03	87,58	76,05	63,96	85,17	31,89	86,51
40	93,90	87,09	75,44	67,27	84,78	30,12	86,16
vsi atributi vseh časov (117)	94,40	87,49	77,10	74,95	85,35	19,84	87,04

Z veččasovno klasifikacijo občutno izboljšamo kakovost klasifikacije osnovnih poljščin. Za nekatere razrede (ječmen in ogrščica) neprimeno boljši rezultat dosežemo že s kombinacijo zgolj petih atributov. Tritikala dolgo ostaja težko določljiva, a jo vsaj delno določimo z uporabo 20-tih atributov. Skupno malenkost boljše rezultate dosežemo s 30 atributi, potem pa do vključno kombinacije vseh atributov vseh časov (117 atributov) rezultata več ne izboljšamo. Za tritikalo ga celo poslabšamo.

Preglednica 37: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetku RapidEye vseh obstoječih datumov od 4.9.2013 do 26.10.2013 (13 datumov). Mediana vrednosti spektralnih slojev na GERK. Študijsko območje Pomurje. Rezultati klasifikacij z dvema kombinacijama osnovnih spektralnih kanalov ter njima dodanim atributom NDVI. Število atributov je označeno z N.

Table 37: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured from 4.9.2013 to 26.10.2013 (13 dates). Median of spectral layer values of GERK mapping unit. Pomurje study area. The classification evaluation results of two combinations of basic spectral channels and them added attribute NDVI. The number of attributes is marked with N.

N	Atribut (vsi časi)	F-mera (%)						OA (%)
		koruza	pšenica	ječmen	buča	ogrščica	tritikala	
39	RED + GREEN + BLUE	94,16	87,31	74,87	66,97	79,14	16,42	86,09
52	RED + GREEN + BLUE + NIR	94,46	86,70	75,80	69,95	83,96	43,45	86,73
65	RED + GREEN + BLUE + NIR + NDVI	94,04	86,42	74,75	67,93	82,33	26,34	85,78

Kot pri veččasovni klasifikaciji osnovnih razredov, lahko tudi pri veččasovni klasifikaciji osnovnih poljščin relativno visoko kakovost klasifikacije dobimo že s kombinacijo osnovnih spektralnih kanalov, vključno s kanalom NIR, ki je pri vseh klasifikacijah precejšnjega pomena. Presenetljivo je, da tudi pri poljščinah, katerih analizo se velikokrat izvaja z indeksom NDVI, ta indeks nima večjega doprinosa h klasifikaciji poljščin. V konkretnem primeru sem določitev tritikale celo poslabšala.

Če se dotaknem še datumov posnetkov, na katerih temelji trideset (glede na ReliefF) najboljših atributov,


zanimivo izstopata meseca maj in julij. Tako za osnovne razrede, kot za poljščine. Zanimivost še poveča dejstvo, da je teoretično najpomembnejši posnetek, 17.7.2013, na dveh tretjinah območja brez podatka.

Preglednica 38: Pogostost pojavitve datuma med najboljših 30 atributov po presoji algoritma ReliefF

Table 38: The frequency of occurrence of individual dates in the top 30 attributes at the discretion of the algorithm ReliefF

Pogostost pojavitve datuma med najboljših 30 atributov po presoji algoritma ReliefF			
Datum posnetka	Osnovni razredi	Osnovne poljščine	Značilnost posnetka
09.04.2013	0	0	
11.04.2013	0	0	1/3 meglice
18.05.2013	4	6	
19.05.2013	5	7	
10.06.2013	0	0	1/3 meglice
15.06.2013	0	1	
02.07.2013	2	2	
17.07.2013	6	9	2/3 območja brez podatka
29.07.2013	3	3	
18.08.2013	3	0	1/4 območja brez podatka
14.09.2013	1	0	
08.10.2013	4	0	1/4 območja brez podatka
26.10.2013	2	2	

Naj rezultate klasifikacije zaključim še s časom obdelave. Na sliki 39 je prikazan čas učenja in klasifikacije pri določenem številu atributov. Videti je, da največ časa zahteva postopek učenja, ki se z višanjem števila atributov eksponentno povečuje. Čas klasifikacije se praktično ne spreminja in tudi v primeru velikega števila atributov traja približno eno minuto. Čas, ki ga porabi algoritem ReliefF za določitev najznačilnejših atributov, linerarno narašča s številom atributov in traja dobrih sedem sekund na atribut, kar pri velikem številu atributov ni zanemarljivo.



Slika 48: Čas izbiranja najznačilnejših atributov z ReliefF, čas učenja, čas same klasifikacije, skupni čas brez izbire atributov z ReliefF ter skupni čas z izbiro atributov z ReliefF pri določenem številu atributov na osnovni enoti GERK.

Figure 48: Time of selecting significant attributes with ReliefF algorithm, training time, classification time, total time without selecting attributes with ReliefF algorithm and total time with selecting attributes with ReliefF algorithm at specific number of attributes and at GERK mapping unit.

8.1.5 Končna določitev najznačilnejših spektralnih atributov

Končna določitev najznačilnejših spektralnih atributov ni trivialna. Rezultati analiz so bili pogosto presenetljivi in predvsem nepredvidljivi. Kot resnična se je izkazala trditev, da lahko prevelika količina podatkov ovira klasifikacijo in rezultate celo poslabša, pri čemer zahteva občutno daljši čas trajanja obdelave. Zato je cilj izbrati čim manjše število atributov, ki pa so zadostni za opis vseh ciljnih razredov. V primeru, da imajo določeni atributi enak doprinos h kakovosti klasifikacije, sem prednost dala osnovnim spektralnim kanalom in bolj splošno znanim indeksom.

Glede na ugotovitve iz tega poglavja je tako za enočasovno kot kvazi veččasovno klasifikacijo, tako za osnovne razrede kot tudi osnovne poljščine dovolj, če izračun vhodnih atributov temeljimo na osnovnih štirih spektralnih kanalih: RED, GREEN, BLUE in NIR. Indeks NDVI v nobenem primeru ni prinašal občutnih izboljšanj, vendar ga v nadaljnjih analizah ne gre izpustiti. Še posebej pri veččasovni klasifikaciji namreč v svetovnem merilu velja za nepogrešljivega.

Tudi na vprašanje o potrebnem in zadostnem številu datumov posnetkov nisem dobila enostavnega odgovora. V primeru neostrih časovnih zahtev se kot najučinkovitejši kaže postopek, kjer uporabimo vse možne čase, potem pa z algoritmom ReliefF izvedemo nekaj iteracij, kjer iščemo najboljšo kakovost končne klasifikacije.

Poglavje določitve najznačilnejših spektralnih atributov zaključujem z zavedanjem, da je klasifikacija kompleksen postopek, odvisen vsaj od atributov, razredov, klasifikatorja in namena. Dobljeni sklepi se nanašajo na pet osnovnih razredov in šest osnovnih poljščin na območju Pomurja. Zato določitve najznačilnejših spektralnih slojev ne gre posploševati na klasifikacijo drugih možnih razredov.

8.2 Določitev najznačilnejših statističnih kazalnikov in teksturnih atributov

Atribut piksla nosi točno vrednost določenega spektralnega sloja v tem pikslu, npr. vrednost indeksa NDVI v določenem časovnem trenutku. V primeru osnovnih enot, večjih od enega piksla, moramo vrednosti določenega spektralnega sloja na posameznih pikslih v osnovni enoti preračunati na eno samo vrednost. To lahko storimo s t. i. statističnimi kazalniki, kot je npr. srednja vrednost ali najmanjša vrednost. Pri tem v osnovi še vedno klasificiramo spektralne vrednosti, le da so te npr. povprečene.

Kadar pa vse spektralne vrednosti znotraj posamezne osnovne enote preračunamo na takšno skupno vrednost, na osnovi katere lahko sklepamo na razporeditev vrednosti v osnovni enoti, govorimo o teksturnih atributih.

Kot že zapisano v tem poglavju, želim količino atributov pri klasifikaciji zmanjšati. Ker pa je tekstura druge vrste podatek kot spektralne vrednosti, pri enočasovni klasifikaciji in omejenemu številu spektralnih kanalov morda zgolj spektralni atributi niso dovolj za kakovostno klasifikacijo in ker se v literaturi teksturni atributi uporabljajo zgolj izjemoma, sem se odločila analizirati tudi učinkovitost teksturnih atributov za klasifikacijo.

Učinkovitost statističnih kazalnikov in teksturnih atributov sem preverjala s klasifikacijo, na enak način kot sem analizirala spektralne attribute. Izhodiščni podatki: študijsko območje Pomurje, posnetek RapidEye, najznačilnejši spektralni atributi. Ker pomembnost teksture predvidoma (in po Haralick et al., 1973) narašča z velikostjo osnovne enote, sem pomembnost teksturnih atributov testirala na osnovni enoti GERK, saj je to največja osnovna enota v tej disertaciji. Izvedla sem enočasovno in veččasovno klasifikacijo za osnovne razrede in poljščine. Pri tem sem preverjala štiri statistične kazalnike in sedem teksturnih atributov. Oboji so na kratko opisani v preglednici 39.

Preglednica 39: Opis analiziranih statističnih kazalnikov in teksturnih atributov

Table 39: Description of analysed statistical indicators and textural attributes

Kratika	Polno ime	Angleški izraz	Opis
Statistični kazalniki			
MEAN	povprečje	mean	Povprečna vrednost atributa znotraj OE.
MED	mediana	median	Srednja vrednost atributa znotraj OE. Določimo jo tako, da vse vrednosti znotraj OE najprej uredimo po velikosti in zapišemo v obliki zaporedja členov. Mediana je vrednost, ki nastopa v sredini tako dobljenega zaporedja.
MAX	maksimum	max	Največja vrednost atributa znotraj OE.
MIN	minimum	min	Najmanjša vrednost atributa znotraj OE.
Teksturni atributi			
VAR	varianca	variance	Mera statistične razpršenosti vrednosti atributov znotraj EO.
STDEV	standardni odklon	stdev	Odstopanje posameznih vrednosti atributa znotraj OE od povprečja vrednosti znotraj OE. Je mera za razpršenost porazdelitve vrednosti in je kvadratni koren variance.
CONTR	kontrast	contrast	Mera kontrastov oz. količine lokalnih variacij vrednosti znotraj OE.
HOMO	homogenost	homogeneity	Mera podobnosti vrednosti pikslov znotraj OE.
DISS	različnost	dissimilarity	Mera različnosti vrednosti pikslov znotraj OE.
ENTRO	entropija	entropy	Mera za količino naključnih vrednosti znotraj OE.
ENERG	energija	energy	Mera značilnosti razporeditve vrednosti znotraj OE. Če se vrednosti ponavljajo v določenih smereh ali v krožnem vzorcu, je znotraj OE močna teksturna energija.

Uporabnost teksturnih atributov sem testirala na najznačilnejših spektralnih atributih (brez NDVI): RED, GREEN, BLUE in NIR. Pomembno je povedati, da se tako statistični kazalniki kot tudi teksturni atributi izračunajo za vsak vhodni sloj. Za štiri spektralne sloje tako dobimo npr. štiri sloje variance: VAR_RED, VAR_GREEN, VAR_BLUE in VAR_NIR. Sloji se med seboj sicer razlikujejo, a zaradi lažje analize sem vedno uporabila teksturne attribute vseh vhodnih spektralnih atributov.

8.2.1 Enočasovna klasifikacija

Enočasovne klasifikacije sem izvedla na posnetku RapidEye 29.7.2013, študijsko območje Pomurje, z vsemi izbranimi statističnimi kazalniki in teksturnimi atributi. Oboje sem računala na osnovni enoti GERK. Najprej sem klasificirala osnovne razrede (preglednici 40 in 41), nato še osnovne poljščine (preglednici 42 in 43).

Preglednica 40: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Statistični kazalniki in teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 40: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Statistical indicators and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
MEAN	90,13	58,98	97,62	87,73	92,20	88,95
MED	89,86	62,56	97,94	82,75	83,98	88,84
MAX	64,34	8,26	0,00	6,50	0,00	47,55
MIN	81,42	21,22	0,00	51,02	26,71	46,74
VAR	82,43	5,85	0,00	79,08	0,00	51,80
STDEV	82,95	7,92	0,00	0,48	0,00	47,01
CONTR	68,70	13,14	0,00	79,92	0,00	51,99
HOMO	80,80	3,18	94,73	0,00	0,00	77,14
DISS	63,86	8,29	0,01	0,00	0,00	47,02
ENTRO	85,15	10,24	96,83	76,62	0,00	82,71
ENERG	84,06	15,10	97,47	76,22	0,00	82,04
MEAN + MED	90,17	59,35	97,50	89,83	65,80	89,08

Po pričakovanju je klasifikacija spektralnih vrednosti najuspešnejša, kadar jih na osnovno enoto preračunamo s statističnim kazalnikom povprečja ali mediane. Uporaba zgolj najmanjše ali največje vrednosti znotraj posameznih osnovnih enot pri klasifikaciji ni smiselna. Prav tako ni smiselno uporabiti obeh, tako povprečja kot mediane, saj gre pri tem za podvajanje vrednosti, kar slabša kakovost klasifikacije in podaljšuje čas postopka. Uporabiti kaže bodisi povprečje bodisi mediano. V mojem primeru se rezultati obeh niso občutno razlikovali, zato sem se zaradi morebitnih ekstremnih vrednosti v osnovni enoti, ki bi lahko kvarile povprečje, odločila za mediano.

Prav tako pričakovani so bili rezultati, da so spektralne vrednosti za klasifikacijo veliko pomembnejše od teksturnih. Zgolj s slednjimi z enočasovno klasifikacijo namreč nisem dobila zadovoljivih rezultatov. Ker pa morda pomembno prispevajo h kakovosti kot dodatni atribut, sem to preverila z nekaj primeri, katerih rezultati so navedeni v preglednici 41.

Preglednica 41: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013. Vse kombinacije statističnega kazalnika in teksturnih atributov so bile izračunane za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 41: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
MED + VAR	90,72	58,29	96,35	86,92	71,16	88,16
MED + CONTR	90,23	63,25	97,93	88,51	91,85	89,42
MED + HOMO	89,97	55,92	97,61	82,05	0,01	87,88
MED + ENTRO	89,99	60,69	98,16	90,12	77,44	89,24
MED + ENERG	89,63	57,99	98,14	87,82	0,00	88,46

Pri enočasovni klasifikaciji osnovnih razredov ni noben teksturni atribut pomembno prispeval h kakovosti klasifikacije, zato sklepam, da jih v klasifikaciji ni smiselno uporabiti.

Preglednica 42: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 42: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Statistical indicators and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
MEAN	88,33	72,78	9,03	66,92	19,57	0,00	70,88
MED	88,72	72,61	5,87	65,51	22,43	0,00	70,74
MAX	80,87	68,99	1,17	20,48	0,00	0,00	64,72
MIN	79,17	62,85	0,20	33,16	27,00	0,00	62,08
VAR	70,28	60,26	0,91	0,00	0,00	0,00	56,50
STDEV	70,36	60,36	1,01	15,50	0,00	0,00	56,61
CONTR	61,38	36,30	0,00	0,13	0,00	0,00	47,11
HOMO	63,24	34,07	6,25	0,00	0,00	0,00	47,77
DISS	58,20	1,89	0,04	0,12	0,00	0,00	41,05
ENTRO	64,94	56,00	0,00	0,62	0,00	0,00	51,94
ENERG	66,19	46,13	8,46	0,00	0,00	0,00	51,42
MEAN + MED	89,31	75,01	21,05	66,71	12,42	0,00	72,53

Tudi v primeru enočasovne klasifikacije poljščin je najbolje uporabiti statistični kazalnik povprečja ali mediane. Glede na rezultate, kateregakoli, ne pa obeh.

Podobno kot pri osnovnih rabah, so tudi pri enočasovni klasifikaciji poljščin zgolj teksturni atributi nezadostni.

Preglednica 43: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013. Vse kombinacije statističnega kazalnika in teksturnih atributov so izračunane za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 43: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
MED + STDEV	89,39	72,51	8,53	67,06	24,38	0,10	71,04
MED + HOMO	88,24	72,09	7,71	66,64	24,06	0,00	69,97
MED + ENTRO	89,19	73,49	24,06	69,17	23,48	0,00	71,83

Za razliko od osnovnih razredov, je pri enočasovni klasifikaciji osnovnih poljščin uporaba teksturnih atributov malenkost bolj smiselna. Pri ječmenu se je pozitivno izkazala entropija. Vendar je, izhajajoč iz analiz spektralnih atributov, višjo kakovost klasifikacije možno doseči z uporabo dodatnega spektralnega atributa kot z uporabljenimi teksturnimi.

8.2.2 Kvazi veččasovna klasifikacija

Kvazi veččasovne klasifikacije sem izvedla na časovni vrsti vseh testnih posnetkov RapidEye leta 2013, študijsko območje Pomurje, z vsemi izbranimi statističnimi kazalniki in teksturnimi atributi. Oboje sem računala na osnovni enoti GERK. Najprej sem klasificirala osnovne razrede (preglednici 44 in 45), nato še osnovne poljščine (preglednici 46 in 47).

Preglednica 44: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov vseh testnih posnetkov RapidEye leta 2013. Teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 44: F-score and overall accuracy (OA) of classification of basic land cover classes on all RapidEye images of year 2013. Statistical indicators and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
MEAN	94,85	81,98	95,82	87,31	64,04	92,77
MED	91,78	64,29	79,04	88,45	30,17	83,32
MAX	88,71	58,46	69,32	72,07	0,00	76,88
MIN	90,16	70,53	85,94	59,26	20,55	82,66
VAR	89,14	40,30	85,00	36,08	18,52	77,72
STDEV	89,46	52,83	82,80	77,78	15,41	80,81
CONTR	88,96	26,16	0,06	79,97	0,98	55,49
HOMO	86,52	61,70	98,01	44,30	0,04	85,00
DISS	63,34	19,31	0,28	6,39	0,09	46,70
ENTRO	91,16	67,08	97,81	88,85	1,97	89,92
ENERG	89,57	65,40	98,14	85,83	20,00	88,36

Pri statističnih kazalnikih sta ponovno prednjačila povprečje in mediana. Za razliko od enočasovne klasifikacije je bila pri kvazi veččasovni klasifikaciji razlika njunih rezultatov večja. Povprečje zaradi morebitnih ekstremnih vrednosti v osnovni enoti zato ni bilo popačeno. Klasifikacija povprečnih spektralnih vrednosti znotraj posameznih osnovnih enot vrne občutno boljše rezultate kakor klasifikacija mediane istih vrednosti.

Kar se tiče teksturnih atributov, ima časovna komponenta pozitiven doprinos. Razen pri teksturah CONTR in DISS precej izboljša kakovost klasifikacije. V nobenem primeru uporabe zgolj ene teksture posnetkov različnih časov ne dobimo kakovosti klasifikacije, ki bi konkurirala veččasovni klasifikaciji s spektralnimi atributi. V kolikšni meri tekstura doprinese kot dodatni atribut spektralnim atributom, pa sem preverila na nekaj primerih kombinacij, navedenih v preglednici 45.

Preglednica 45: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov vseh testnih posnetkov RapidEye leta 2013. Statistični kazalnik in teksturni atributi so bili izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 45: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye images captured in year 2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
MEAN + STDEV	95,49	79,19	95,91	91,32	77,75	94,08
MEAN + HOMO	95,51	81,19	97,65	91,33	77,40	93,96
MEAN + ENTRO	95,30	83,60	97,07	87,81	35,65	93,47
MEAN + ENERG	95,48	83,73	98,78	91,51	65,15	94,66

V splošnem so vsi teksturni atributi rahlo izboljšali kakovost klasifikacije. Za razliko od enočasovne klasifikacije osnovnih poljščin, je v primeru veččasovne klasifikacije osnovnih razredov entropija kakovost določitve enega razreda (vode) močno poslabšala, a skupna kakovost kljub temu ostaja višja kakor brez uporabe entropije. Ostale tri teksture (STDEV, HOMO in ENERG) izboljšajo (ali vsaj približno obdržijo) kakovost določitve vseh razredov. Katero teh treh tekstur uporabiti, je odvisno od namena klasifikacije. Če želimo, da so vsi razredi kar najboljše določeni, bi v našem primeru uporabili homogenost.

Glede na rezultate dosedanjih analiz teksture, sem veččasovno klasifikacijo osnovnih poljščin izvedla zgolj z nekaj kombinacijami spektralnih in teksturnih atributov. Rezultati v preglednici 46.

Preglednica 46: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin vseh testnih posnetkov RapidEye leta 2013. Statistični kazalnik in teksturni atributi so izračunani za spektralne attribute RED, GREEN, BLUE in NIR na GERK. Študijsko območje Pomurje.

Table 46: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye images captured in year 2013. All combinations of statistical indicator and textural attributes were calculated for spectral attributes RED, GREEN, BLUE and NIR on GERK mapping unit. Pomurje study area.

Atribut	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
MEAN	93,89	86,78	76,24	69,53	81,44	17,61	85,87
MED	94,46	86,70	75,80	69,95	83,96	43,45	86,73
MED + STDEV	93,87	85,26	73,49	66,02	77,90	16,78	84,73
MED + HOMO	94,20	86,86	75,28	67,90	80,33	34,92	86,11
MED + ENTRO	94,35	86,51	73,62	68,90	76,47	31,94	85,64
MED + ENERG	94,32	86,28	73,70	67,95	78,97	14,06	85,34

Za razliko od osnovnih razredov, se pri osnovnih poljščinah kot najboljši statistični kazalnik izkaže mediana. Boljša je predvsem pri določitvi tritikale.

Tekstura se pri določitvi osnovnih poljščin z veččasovno klasifikacijo izkaže za povsem nepomembno. Vse teksture pri vseh razredih poslabšajo kakovost klasifikacije, zato je bolje, če jih ne uporabimo.

8.2.3 Končna določitev najznačilnejših statističnih kazalnikov in teksturnih atributov

Za enoštevilično predstavitev vseh spektralnih vrednosti znotraj posamezne osnovne enote sem uporabila štiri različne statistične kazalnike: povprečje, mediano, najmanjšo in največjo vrednost. Po pričakovanju se slednji nista izkazali kot najbolj učinkoviti. Velja torej uporabiti bodisi povprečje bodisi mediano. V našem primeru se rezultati obeh niso občutno razlikovali. V nekaterih primerih je rahlo prednjačila mediana, v drugih povprečje. Načeloma lahko torej uporabimo katerokoli, ne pa obeh hkrati. Pomembno je spomniti, da sem statistične kazalnike računala na osnovni enoti GERK, kjer so vrednosti znotraj enote precej homogene. V primeru velike količine oz. neznane količine ekstremnih vrednosti znotraj osnovne enote, je smiselno uporabiti mediano. Zato sem za testiranje nadaljnjih postopkov uporabila statistični kazalnik MED.

Teksturni atributi kot samostojni vhodni podatki so se tako pri enočasovni kot pri veččasovni klasifikaciji, tako pri osnovnih razredih kot osnovnih poljščinah izkazali kot nezadostni oz. vsaj veliko slabši od spektralnih atributov. Tudi kot dopolnilni atribut spektralnim atributom pri katerikoli enočasovni klasifikaciji niso pokazali uporabnosti. Pri veččasovni klasifikaciji se je njihova uporabnost izkazala kot odvisna od razredov klasifikacije. Pri klasifikaciji poljščin ni nobena tekstura izboljšala rezultatov, vse so jih celo rahlo poslabšale. Pri veččasovni klasifikaciji osnovnih razredov pa so sicer vsi teksturni atributi izboljšali kakovost klasifikacije, a v zelo majhni meri.

Če in kateri teksturni atribut uporabiti, je odvisno od namena klasifikacije, od razredov, prostorske ločljivosti posnetka idr. Zelo pomembna je tudi osnovna enota klasifikacije. Ker pomembnost teksture narašča z večanjem osnovne enote, je v primeru OE manjše od GERK oz. vsaj okoli deset pikslov, uporaba teksture pri klasifikaciji nesmiselna. Dodatno k tej odločitvi pripomore še dejstvo, da vsaka tekstura podvoji količino vhodnih atributov in s tem čas obdelave.

V disertaciji pri nekaterih nadaljnjih analizah uporabim atribut homogenosti (HOMO) kot edini teksturni atribut, saj se je pri analizah tega poglavja izkazal kot najučinkovitejši.

9 DOLOČITEV OPTIMALNE OSNOVNE ENOTE KARTIRANJA

Z osnovno enoto kartiranja fiksiramo lokacijo, velikost in obliko objektov, zato ima pomemben in neposreden vpliv na kakovost klasifikacije. Za različne namene klasifikacij so primerne različne osnovne enote (OE). V primeru zelo visoke prostorske ločljivosti je običajno primerneje uporabiti objektno usmerjeno kot pikselno klasifikacijo. V disertaciji operiram s prostorsko ločljivostjo 10 m in zelo majhnimi velikostmi njiv, zato segmenti niso nujno najboljša rešitev. Dodatno imam opravka z veččasovno klasifikacijo, kjer se v praksi skoraj izključno uporablja pikselna klasifikacija. Segment, kot osnovna enota veččasovne klasifikacije, je šele postal tema raziskav in je v literaturi obravnavan le redko (Inglada et al., 2015).

V prejšnjem poglavju sem določala najznačilnejše attribute klasifikacije, pri čemer sem attribute računala zgolj na osnovni enoti GERK. Razlog za to je bilo predvidevanje, da je GERK najbolj uspešna osnovna enota, saj je na njegovi osnovi izdelan tudi referenčni sloj in je dovolj velika za upoštevanje teksture pri klasifikaciji. To predvidevanje bi rada v tem poglavju potrdila. Dodaten razlog za določitev optimalne osnovne enote je dejstvo, da referenčnega sloja nimamo vedno na voljo za celotno študijsko območje; razpolagamo lahko npr. z le nekaj učnimi točkami/poligoni. V takšnem primeru je GERK sicer lahko še vedno osnovna enota, če ga seveda imamo na voljo. Kjer ga nimamo, npr. območja izven Slovenije, moramo izbrati drugo osnovno enoto.

Namen tega poglavja je zato najprej potrditi ali ovreči predvidevanje, da je GERK najbolj optimalna osnovna enota. Nato pa na različnih primerih klasifikacij določiti drugo (oz. prvo) osnovno enoto, ki omogoča pridobitev najbolj kakovostne klasifikacije. Pri tem moram omeniti, da imamo pri osnovni enoti SEGMENT na voljo veliko število različnih segmentacij. V tem poglavju uporabljam zgolj nekaj najobetavnejših (izbor sledi v nadaljevanju). Natančnejšo pridobitev dobrih segmentov ter možnosti vplivanja na obliko segmentov obravnavam v sledečih poglavjih.


Za klasifikacijo uporabljam attribute mediana RGBNir ter dodatno izmenjaje mediano NDVI ter teksturo HOMO. Klasifikacijo izvajam enočasovno in veččasovno, za osnovne razrede in poljščine. Pri vseh klasifikacijah uporabljam enake osnovne enote.

9.1 Opis osnovnih enot

Optimalno osnovno enoto (OE) določam na izboru sledečih OE:

- PIKSEL,
- MREŽA 3 x 3,
- SEGMENT (segmentacije z različnimi parametri),
- GERK.

Pri OE PIKSEL vsak poligon zajema točno en piksel (slika 51 (a)). Velikost piksla vseh testnih posnetkov je 10 m.



Slika 49: Primeri različnih osnovnih enot: PIKSEL (a), MREŽA 3 x 3 (b), SEGMENT (c) in GERK (d). V ozadju je posnetek RapidEye, prikazan z vidnimi kanali.

Figure 49: Examples of different mapping units: PIXEL (a), 3 x 3 GRID (b), SEGMENT (c) and GERK (d). Background is true colour RapidEye image.

Vrednosti pikslov lahko med sosednjimi piksli zelo variirajo, s čimer je predvidoma klasifikacija otežena. Na pikslu tudi ne moremo računati teksturnih atributov. Dodaten problem lahko pri veččasovni klasifikaciji predstavlja morebiten zamik pikslov med posnetki različnih časov. Omenjene problematike bi morda rešila predefinirana mreža, sestavljena iz t. i. rastrskih oken. Okna so lahko velika 3 x 3 piksle, 5 x 5 pikslov itn. Ker prostorska ločljivost obravnavanih posnetkov ni zelo visoka (vsaj relativno z velikostjo naših razredov), sem kot predefinirano mrežo obravnavala le okna velikosti 3 x 3 piksle (slika 51 (b)).

Ker se lahko zgodi, da posamezno okno mreže 3 x 3 zajema piksle različnih razredov, sem osnovne enote določili na način, pri katerem so v eni enoti (poligonu) zajeti zgolj piksli s homogenimi vrednostmi. Takšne enote so segmenti (slika 51 (c)). Kot obravnavano v disertaciji, je oblika segmentov odvisna od več dejavnikov. Za uporabnost segmenta kot osnovne enote klasifikacije sem v sklopu

projekta Sentinel2Agri4Slovenia preverila več različnih segmentacij. Pri tem sem upoštevala rezultate naših dosedanjih analiz (Švab Lenarčič et al., 2016). Izbor segmentacij, ki sem jih uporabila pri določitvi optimalne enote, podrobneje obrazložim v naslednjem podpoglavju (9.2).

Kot teoretično najboljšo možno osnovno enoto (enako referenčnemu sloju) sem preizkusila tudi OE GERK (slika 51 (d)).

9.2 Izbor segmentacij


Pri izboru segmentacij sem upoštevala rezultate analize zanesljivosti cenilk kakovosti segmentacije za napoved kakovosti klasifikacije, ki je podrobno opisana v članku Švab Lenarčič et al. (2016). Kar se tiče zanesljivosti same, vsebino članka povzemam v poglavju 3.3. Posreden rezultat omenjene analize je tudi kakovost klasifikacije pri različnih parametrih segmentacije. Povzetek tega dela članka opisujem v sledečih odstavkih.

V študiji so bile narejene segmentacije s sto kombinacijami parametrov segmentacije, na vseh segmentacijah je bilo s tremi klasifikatorji klasificiranih pet razredov pokrovnosti. Kakovost klasifikacije je bila ocenjena s sedmimi merami kakovosti. Osnova klasifikacije so bili vsi spektralni kanali posnetka RapidEye 29.7.2013 in prostorsko ločljivostjo 5 m, študijsko območje Murska Sobota.

Od sedmih mer kakovosti, uporabljenih v zgoraj opisani študiji, prikazujem zgolj mero stopnja kakovosti klasifikacije⁷ (CQR), saj je od vseh uporabljenih mer pri omenjeni analizi najbolj podobna F-meri, ki jo praviloma uporabljam v tej disertaciji. Dobljene stopnje kakovosti klasifikacije sem že prikazala v poglavju 3, vendar jih zaradi lažje izbire segmentacij ponovno prikazujem v preglednici 47.

Preglednica 47: Rezultati stopnje kakovosti klasifikacije za pet razredov pokrovnosti. Os x predstavlja parametre segmentacije (zgornja vrsta merilo, spodnja vrsta združevanje), os y predstavlja vrednost ocene klasifikacije. Razpon obeh osi je enak pri vseh razredih.

Table 47: Results of classification quality rate (CQR) for five land cover classes. X axis represents the segmentation parameters (upper row scale, lower row merge), Y axis represents the value of classification quality evaluation. The range of each axis is the same for all classes.



Pri analizi sem potrdila in z različnih vidikov nadgradila domneve nekaterih avtorjev (Liu in Xia, 2010; Belgiu in Dragut, 2014; Van der Linden, 2007), da visoko kakovostna segmentacija ne omogoča nujno

⁷ Stopnja kakovosti klasifikacije (angl. classification quality rate (CQR)) je razmerje med številom resnično pozitivnih (TP) pikslov in vsoto resnično pozitivnih (TP), lažno negativnih (FN) in lažno pozitivnih (FP) pikslov.

visoke kakovosti klasifikacije ter da je klasifikacija občutno manj odvisna od segmentacije, kot smo verjeli do sedaj. Iz rezultatov v preglednici 47 sodeč, je kakovost klasifikacije skoraj enaka in relativno stabilna na intervalu parametra merila od 0 do približno 50, ne glede na razred pokrovnosti. S segmentacijami tega intervala (tako prekomernimi kot »optimalnimi«) lahko dosežemo najbolj kakovostne klasifikacije. Enake parametre lahko uporabimo za vse razrede pokrovnosti. Po drugi strani prešibke segmentacije (v našem primeru približno od merila 50 do 90) občutno znižajo kakovost klasifikacije, v splošnem na zelo nizko stopnjo kakovosti.

Čeprav med kakovostmi klasifikacij na intervalu parametrov meril od 0 do 40 (ne glede na velikost parametra združitve) ni bistvenih razlik, pa so med kakovostmi kljub temu manjše razlike. Ker je težnja uporabiti nekaj takšnih segmentacij, ki omogočajo čim boljšo kakovost klasifikacije, v preglednici 48 prikazujem rezultate, na osnovi katerih je temeljil izbor segmentacij. V prvem delu tabele je za vsak razred pokrovnosti prikazana najnižja in najvišja kakovost klasifikacije ter pripadajoče segmentacije. V drugem delu tabele so navedene tri (po cenilki stopnje kakovosti segmentacije sodeč) najbolj kakovostne segmentacije ter pripadajoče stopnje kakovosti klasifikacije.

Zaradi optimizacije navajanja parametrov segmentacije, bom le-te v nadaljevanju prikazovala na način: `merilo_združitev` (parameter merilo, podčrtaj, parameter združitev).

Preglednica 48: Rezultati stopnje kakovosti klasifikacije, dobljeni pri različnih parametrih segmentacij. Klasifikacija je bila izvedena za osnovne razrede pokrovnosti, s klasifikatorjem k-NN, na segmentacijah v intervalu `merilo_združitev` od 00_00 do 40_90. V prvem delu tabele je za vsak razred pokrovnosti prikazana najnižja in najvišja kakovost klasifikacije ter pripadajoče segmentacije. V drugem delu tabele so navedene tri (po cenilki stopnje kakovosti segmentacije sodeč) najbolj kakovostne segmentacije ter pripadajoče stopnje kakovosti klasifikacije. Parametri segmentacij pri najboljših stopnjah kakovosti klasifikacije (zgornjih 25 % vrednosti intervala min-max) so odebeljeni.

Table 48: Results of classification quality rate obtained at different segmentation parameters. Classification was performed for basic land cover classes, with k-NN classifier and segmentations in the `scale_merge` interval from 00_00 to 40_90. In the first part of the table the minimum and maximum classification quality is shown for each land cover class, together with corresponding segmentations. In the second part of the table three (according to segmentation quality rate) most qualitative segmentations with corresponding classification quality rate are shown. Segmentation parameters at the best classification quality rates (upper 25 % values of the min-max interval) are printed in bold.

Atribut\Razred	Stopnja kakovosti klasifikacije CQR (%)					
	<u>njiva</u>	<u>trava</u>	<u>gozd</u>	<u>urbano</u>	<u>voda</u>	<u>vsi razredi</u>
Najnižja in najvišja kakovost klasifikacije ter pripadajoče segmentacije.						
min CQR	77.40	14.81	78.54	59.00	59.23	69.51
(segmentacija)	(10_00)	(00_20)	(10_00)	(40_90)	(00_20)	(10_00)
max CQR	83.92	28.55	83.18	63.38	72.79	75.09
(segmentacija)	(30_90)	(40_80)	(20_90)	(30_80)	(40_50)	(30_90)
Prve tri najbolj kakovostne segmentacije ter pripadajoče stopnje kakovosti klasifikacije.						
prva naj. segmentacija	40_90	40_90	40_90	40_90	40_90	40_90
(CQR)	(82.60)	(26.22)	(79.49)	(59.00)	(61.70)	(73.37)
druga naj. segmentacija	30_90	30_90	40_80	30_90	30_90	30_90
(CQR)	(83.92)	(27.10)	(80.37)	(60.58)	(70.01)	(75.09)
tretja naj. segmentacija	20_90	20_90	30_90	20_90	20_90	40_80
(CQR)	(83.12)	(26.63)	(83.03)	(61.10)	(59.60)	(74.73)

Analiza zanesljivosti cenilk sicer ni bila narejena pod identičnimi pogoji kot analiza optimalnih osnovnih enot, vendar dovolj podobnimi, da lahko prenesem glavne ugotovitve. Pri analizi osnovnih enot, opisani v nadaljevanju, sem uporabila segmentacije, ki se največkrat pojavijo pri dobri klasifikaciji. To so segmentacije pri parametrih: 20_90, 30_90, 40_80 in 40_90. Namesto parametrov 30_80 sem uporabila parametre 30_70, ki jih v disertaciji veliko uporabljam. Namesto parametrov 40_50 sem uporabila parametre 40_70, saj višja stopnja združevanja večkrat prinese dobre rezultate. Poleg teh parametrov sem dodatno uporabila še parametre: 10_20, 20_40, 50_90 in 60_90. Namen prvih dveh je bil preveriti vpliv prekomerne segmentacije, namen drugih dveh pa vpliv prešibke segmentacije na kakovost klasifikacije.

9.3 Analiza optimalnih enot pri enočasovni klasifikaciji

Pri tej analizi sem primerjala rezultate enočasovne klasifikacije osnovnih razredov in osnovnih poljščin pri različnih osnovnih enotah in nekaj kombinacijah atributov: mediana RGBNir, mediana RGBNirNdvi ter mediana in homogenost spektralnih kanalov RGBNir. Klasifikacijo sem izvajala na posnetku RapidEye 29.7.2013 na študijskem območju Murska Sobota. Uporabila sem klasifikator ANN ter Sobelovo metodo zaznave robov za pridobitev segmentov. Pri vseh klasifikacijah so bile uporabljene iste učne točke.

9.3.1 Enočasovna klasifikacija osnovnih razredov

Rezultati enočasovne klasifikacije osnovnih razredov so predstavljeni v preglednici 49.

Preglednica 49: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na posnetku RapidEye 29.7.2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije. Klasifikator ANN. Vse segmentacije so narejene na RGBNir s Sobelovo metodo zaznave robov.

Table 49: F-score and overall accuracy (OA) of classification of basic land cover classes on RapidEye image 29.7.2013. Pomurje study area. Classifications performed on different mapping units and classification attributes. ANN classifier. All segmentations were performed on RGBNir combination of images and with Sobel edge detection method.

F-mera (%)						OA (%)
Atribut\Razred	njiva	trava	gozd	urbano	voda	
PIKSEL						
med_RGBNir	89,80	1,97	90,35	81,76	82,35	84,85
med_RGBNirNdvi	89,53	3,98	90,72	81,98	82,46	84,85
med_homo_RGBNir	-	-	-	-	-	-
3 x 3						
med_RGBNir	88,86	0,66	88,93	81,84	84,85	84,29
med_RGBNirNdvi	90,04	18,80	89,20	84,03	82,73	85,16
med_homo_RGBNir	88,76	3,13	88,33	81,76	80,66	84,04
GERK_RABA						
med_RGBNir	93,32	30,08	95,75	98,03	91,89	91,89
med_RGBNirNdvi	93,48	28,40	96,20	97,95	89,69	91,19
med_homo_RGBNir	94,40	49,28	95,94	98,21	84,82	92,27

se nadaljuje...

nadaljevanje preglednice 49...

	F-mera (%)					OA (%)
Atribut\Razred	njiva	trava	gozd	urbano	voda	
SEGMENTACIJA 10_20						
med_RGBNir	89,74	1,59	88,74	82,11	0,00	84,34
med_RGBNirNdvi	90,48	2,35	89,27	84,51	86,82	85,75
med_homo_RGBNir	89,49	17,31	88,47	84,12	83,92	84,51
SEGMENTACIJA 20_40						
med_RGBNir	89,89	4,81	88,98	84,35	0,00	84,84
med_RGBNirNdvi	90,15	0,00	88,98	84,18	0,00	85,08
med_homo_RGBNir	89,55	18,29	89,49	84,94	77,26	84,78
SEGMENTACIJA 20_90						
med_RGBNir	90,28	0,00	88,62	87,62	85,81	86,09
med_RGBNirNdvi	90,49	1,75	88,34	86,89	84,44	86,05
med_homo_RGBNir	90,07	3,01	90,07	85,39	82,32	85,80
SEGMENTACIJA 30_70						
med_RGBNir	90,28	10,09	88,52	86,16	84,83	85,83
med_RGBNirNdvi	90,70	16,61	88,89	85,00	5,04	85,52
med_homo_RGBNir	90,24	34,34	88,77	82,83	0,00	84,71
SEGMENTACIJA 30_90						
med_RGBNir	90,54	0,00	88,32	85,83	4,54	85,53
med_RGBNirNdvi	90,81	0,87	88,26	86,89	84,17	86,21
med_homo_RGBNir	90,25	0,23	89,47	85,92	79,33	85,82
SEGMENTACIJA 40_70						
med_RGBNir	90,01	0,43	88,31	86,62	84,35	85,69
med_RGBNirNdvi	90,54	0,21	88,68	86,23	2,65	85,63
med_homo_RGBNir	90,72	27,15	89,21	84,02	82,75	85,60
SEGMENTACIJA 40_80						
med_RGBNir	90,82	2,82	87,89	87,29	85,49	86,26
med_RGBNirNdvi	90,75	2,95	87,84	85,65	0,00	85,48
med_homo_RGBNir	90,23	6,45	88,37	85,62	0,00	85,21
SEGMENTACIJA 40_90						
med_RGBNir	89,75	0,00	87,42	85,23	0,00	84,83
med_RGBNirNdvi	90,55	0,71	87,63	86,13	0,00	85,43
med_homo_RGBNir	90,13	0,43	88,43	86,52	85,67	85,67
SEGMENTACIJA 50_90						
med_RGBNir	89,30	20,98	79,26	85,80	0,00	83,33
med_RGBNirNdvi	88,93	8,83	79,08	85,59	0,00	82,82
med_homo_RGBNir	89,52	24,36	79,23	86,79	84,36	84,09
SEGMENTACIJA 60_90						
med_RGBNir	86,26	0,00	59,82	83,37	0,00	79,09
med_RGBNirNdvi	86,49	1,30	60,78	83,57	17,74	79,36
med_homo_RGBNir	86,18	8,25	60,13	84,02	83,13	79,61

Na osnovi rezultatov sem dobila (oz. potrdila) naslednje sklepe:

- indeks NDVI ne pripomore k višji kakovosti klasifikacije;
- tekstura homogenost občasno pripomore k višji kakovosti trave ali vode, vendar so videti te izboljšave naključne (pri nekaterih OE dobimo veliko višjo kakovost brez upoštevanja homogenosti);
- klasifikator ANN se kaže kot občutljiv na klasifikacijo razredov, katerih število osnovnih enot

(poligonov) je v primerjavi z ostalimi razredi zelo nizko. Primera sta razreda trava, ki pokriva le 7 % testne površine, ter voda, ki pokriva zgolj 1 % testne površine. Voda je namreč v primeru uporabe bližnje-infrardečega kanala dobro ločljiva od ostalih razredov in lahko predvidoma doseže visoko kakovost klasifikacije. Se pa nemalokrat zgodi, da klasifikator razred vodo kar »izpusti«. V katerih primerih se to zgodi iz rezultatov v preglednici 49 ne razberemo; Zdi se kot da gre za naključje, saj ni povezave niti z uporabljenimi atributi niti z uporabljenimi osnovnimi enotami. Smiselno bi bilo narediti nekaj podobnih iteracij klasifikacij, preden podobo dokončno klasificiramo;


- rezultati so v splošnem zelo podobni rezultatom pri analizi zanesljivosti cenilk (Švab Lenarčič et al., 2016), čeprav so bili dodatno uporabljeni še drugi spektralni kanali, uporabila sem drug klasifikator (ANN in ne k-NN) ter drugo število in lokacijo učnih točk. Potrdila sem, da glede na kakovost, osnovano na številu pravilno oz. napačno klasificiranih pikslov, med posameznimi osnovnimi enotami ni večjih razlik (z izjemo OE GERK). Rezultati se začnejo občutno slabšati šele v primeru prešibke segmentacije. Pri osnovnih razredih in prostorski ločljivosti 5 m oz. 10 m (ločljivost pri zgornjih analizah) je to nekje pri vrednosti parametra merilo nad 50;
- osnovne enote velikosti 3 x 3 piksele ne omogočajo boljše klasifikacije kakor piksli sami;
- pričakovano najboljša osnovna enota za vse osnovne razrede je GERK. V primerjavi s pikslom izboljša F-mero posameznih razredov od 4 % do kar 29 %, skupno natančnost klasifikacije na celem posnetku pa za 7 %;
- kar se tiče OE segment, so številčni rezultati (z izjemo prešibke segmentacije) zelo podobni. Tudi rezultate pikselske klasifikacije »premagajo« le malenkostno. Na osnovi števil kot takšnih, bi le težko določili najboljše parametre segmentacije. Zato v nadaljevanju še grafično prikazujem rezultate klasifikacij, ki sem jih dobila s posameznimi osnovnimi enotami.

Za vizualno oceno kakovosti najprej na sliki 50 prikazujem referenčni sloj za klasifikacijo osnovnih enot. Nadaljujem s prikazom rezultatov posameznih osnovnih enot (slike 51 in 54).



Slika 50: Referenčni sloj petih osnovnih razredov z masko (območja ne klasificiramo). Študijsko območje Murska Sobota.

Figure 50: Reference layer of five basic land cover classes with a classification mask (areas under mask are not classified). Murska Sobota study area.




Slika 51: Rezultat klasifikacije z OE piksel (a) in OE GERK (b). Študijsko območje Murska Sobota.

Figure 51: Classification result of mapping unit pixel (a) and mapping unit GERK (b). Murska Sobota study area.

Kot je razvidno že iz rezultata v preglednici 49, tudi na sliki 51 vidimo, da omogoča OE GERK boljšo klasifikacijo trave kakor OE PIKSEL. Pri kakovosti določitve ostalih razredov ni zelo bistvenih razlik. Zelo očitno in logično je, da je rezultat OE PIKSEL veliko bolj razdrobljen kakor rezultat OE GERK. Če bo rezultat klasifikacije uporabljen kot vektorski sloj pri določeni analizi GIS, ima pri tem rezultat


z OE GERK prednost, saj bi v primeru OE PIKSEL dobili zelo veliko majhnih poligonov, ki znajo ovirati prostorske analize in zaradi večje količine podatkov podaljševati postopke. Bi pa v primeru enake kakovosti na OE PIKSEL in GERK predvidoma klasifikacija na pikslah predstavljala boljše izhodišče za postopke poklasifikacije. Prednost piksla je tudi v tem, da ni neposredno vezan na GERK. To bi v primeru, da je GERK napačen, predstavljalo problem (primer travnik sredi gozda (verjetno pod daljnovodom) na jugu študijskega območja).



Slika 52: Rezultat klasifikacije z OE 3 x 3 (a) in OE SEGMENT 20_40 (b). Študijsko območje Murska Sobota.


Figure 52: Classification result of mapping unit 3 x 3 GRID (a) and mapping unit segment 20_40 (b). Murska Sobota study area.

OE 3 x 3 je umetno narejena osnovna enota in tudi rezultat klasifikacije na OE 3 x 3 je videti umeten. Izgubijo/popačijo se lokacije posameznih razredov, pri čemer v primerjavi s pikslom ne izboljšamo kakovosti klasifikacije. OE SEGMENT 20_40 se izkaže kot boljša izbira. Podrobnosti se ohranijo, v primerjavi s pikslom je manj razdrobljenosti. Razreda trava je več kot v primerjavi s pikslom, vendar je večinoma klasificiran napačno.



Slika 53: Rezultat klasifikacije z OE SEGMENT 30_70 (a) in OE SEGMENT 40_90 (b). Študijsko območje Murska Sobota.

Figure 53: Classification result of mapping unit SEGMENT 30_70 (a) and mapping unit SEGMENT 40_90 (b). Murska Sobota study area.



Slika 54: Rezultat klasifikacije z OE SEGMENT 50_90 (a) in OE SEGMENT 60_90 (b). Študijsko območje Murska Sobota.


Figure 54: Classification result of mapping unit SEGMENT 50_90 (a) and mapping unit SEGMENT 60_90 (b). Murska Sobota study area.

Od vseh narejenih segmentacij ima segmentacija 30_70 segmente, ki so po velikosti najbolj podobni velikosti enot GERK (slika 51). Žal kakovost klasifikacije kljub temu zaostaja za kakovostjo klasifikacije z GERK. Pri parametrih 40_90 je že zaznati rahlo prešibko segmentacijo. Nekateri razredi

se že zlivajo v enega in posledično ne morejo biti pravilno klasificirani (trava je v veliki večini skupaj z njivo v enem segmentu).

Za klasifikacijo segmentacij 50_90 oz. celo 60_90 sem pričakovala slab rezultat klasifikacije. In rezultat je dejansko slabši kot pri ostalih OE. Še posebej problematičen je gozd, saj je v segmentih skupaj z razredom njiva. Pri velikih segmentih tako njive »požrejo« velik del gozda.


Rezultati na segmentih so torej v vseh primerih, razen v primerih prešibke segmentacije, zelo podobni. Radrobljenost očitno ne igra zelo velike vloge pri končni kakovosti klasifikacije. Kaj je torej razlog, da segmenti ne omogočajo enako kakovostne klasifikacije kot OE GERK? V nadaljevanju prikazujem OE GERK in nekaj segmentov na vhodnem posnetku RapidEye (slika 55) ter na referenčnem sloju (slika 56), s čimer sem skušala ugotoviti razlog slabše klasifikacije pri segmentih.



Slika 55: OE GERK (a), OE SEGMENT 20_40 (b), OE SEGMENT 30_70 (c) in OE SEGMENT 40_90 (d) na posnetku RapidEye 29.7.2013. Izsek študijskega območja Murska Sobota.

Figure 55: Mapping unit GERK (a), mapping unit SEGMENT 20_40 (b), mapping unit SEGMENT 30_70 (c) and mapping unit SEGMENT 40_90 (d) on RapidEye image 29.7.2013. A section of Murska Sobota study area.

Če meje segmentov gledamo na posnetku RapidEye (slika 55), so videti po večini dobre – v vsakem segmentu je samo en razred. Manjša združevanja se kažejo pri segmentaciji 40_90.



Slika 56: OE GERK (a), OE SEGMENT 20_40 (b), OE SEGMENT 30_70 (c) in OE SEGMENT 40_90 (d) na referenčnem sloju osnovnih razredov za leto 2013. Izsek študijskega območja Murska Sobota.

Figure 56: Mapping unit GERK (a), mapping unit SEGMENT 20_40 (b), mapping unit SEGMENT 30_70 (c) and mapping unit SEGMENT 40_90 (d) on reference layer for year 2013. A section of Murska Sobota study area.

Ko te iste segmente prikažemo na referenčnem sloju (slika 56), pa ugotovimo, da temu ni čisto tako. OE GERK logično idealno ustreza referenčnemu sloju, saj gre dejansko za isti sloj. Segmenti pa niso popolnoma homogeni v smislu števila razredov znotraj njih. Tudi v primeru prekomerne segmentacije ne. Razlogi za to so lahko različni:

- posnetek RapidEye ima drugačno prostorsko ločljivost kot jo je imel posnetek, na katerem se je izvajala vizualna interpretacija referenčnega sloja (digitalni ortofoto z ločljivostjo 0,5 m);

- posnetek RapidEye ima lahko zamik (npr. en piksel) glede na dejansko stanje v naravi;
- delovanje algoritma razvodij, s čimer se gradijo segmenti (segmenti vedno potekajo po robu gradienta, pri čemer večkrat pride do »zamaknjenega roba segmenta«; zaradi »spektralno močnega sosed« nekateri podobni razredi padejo v isto »regijo«, v isti segment);
- razredi klasifikacije so si morda spektralno v uporabljenih vhodnih podobah zelo podobni (npr. trava in njiva);
- referenčni sloj je zajet napačno (bolj malo možnosti, ampak na nekaterih območjih je to opaziti).

Zaradi navedenih razlogov se v mnogih segmentih nahaja več kot en referenčni razred. Popolnoma pravilna (takšna, kot je referenčni sloj) klasifikacija tako ni možna. Poleg tega, da se na en segment klasificira zgolj en razred, je razredna nehomogenost segmentov moteča tudi z vidika učenja klasifikatorja, saj kot vhodni atribut uporabimo srednjo vrednost ali mediano vseh vrednosti v segmentu. Npr. povprečno vrednost trave in njive. S tem je klasifikatorju zelo otežena pravilna klasifikacija sicer razredno homogenih segmentov.

Kaj pa piksel? V pikslu so lahko (še posebej pri nizki prostorski ločljivosti) zajete odbojnosti različnih razredov pokrovnosti. To sicer lahko poslabša klasifikacijo. Ampak vrednost posameznega atributa znotraj piksla pa je, za razliko od večjih nehomogenih OE, samo ena. Kakovost klasifikacije kljub temu zaostaja celo za nekaterimi segmenti, čeprav zelo neznatno. Predvidevam, da je največji razlog za napačno klasifikacijo pikslov (in tudi ostalih osnovnih enot), velika spektralna podobnost posameznih razredov.

9.3.2 Enočasovna klasifikacija osnovnih poljščin


Na enak način kot osnovne razrede sem klasificirala tudi osnovne poljščine. Rezultati enočasovne klasifikacije osnovnih poljščin so predstavljeni v preglednici 50. Klasificirala sem zgolj šest osnovnih poljščin, ves preostali del posnetka sem maskirala in ga ne obravnavam niti pri klasifikaciji niti pri oceni kakovosti.

Preglednica 50: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetku RapidEye 29.7.2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije. Klasifikator ANN. Vse segmentacije so narejene na RGBNir s Sobelovo metodo zaznave robov.

Table 50: F-score and overall accuracy (OA) of classification of basic crop type classes on RapidEye image 29.7.2013. Pomurje study area. Classifications performed on different mapping units and classification attributes. ANN classifier. All segmentations were performed on RGBNir combination of images and with Sobel edge detection method.


Atribut\Razred	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
PIKSEL							
med_RGBNir	84,11	74,89	0,03	52,59	30,14	0,51	70,46
med_RGBNirNdvi	83,70	74,76	0,03	51,55	29,08	4,92	70,12
GERK							
med_RGBNir	90,85	78,61	0,00	69,64	51,14	0,00	76,03
med_RGBNirNdvi	90,71	78,88	1,50	68,47	50,06	0,00	76,05
med_homo_RGBNir	90,57	76,34	14,71	65,49	50,79	19,95	73,91
SEGMENTACIJA 10_20							
med_RGBNir	84,69	73,91	0,08	50,60	27,88	0,00	69,89
med_RGBNirNdvi	84,34	74,91	3,81	51,54	47,58	0,00	71,00
med_homo_RGBNir	83,64	67,01	16,53	36,78	40,75	0,00	65,66
SEGMENTACIJA 20_40							
med_RGBNir	84,34	75,34	5,29	47,68	13,73	0,00	69,35
med_RGBNirNdvi	84,14	74,41	8,84	48,91	8,85	0,00	69,56
med_homo_RGBNir	84,25	70,59	14,45	35,98	42,78	4,57	67,74
SEGMENTACIJA 30_70							
med_RGBNir	83,01	76,38	6,73	42,49	8,48	2,33	69,29
med_RGBNirNdvi	83,09	74,63	11,92	43,64	8,53	0,00	69,10
med_homo_RGBNir	83,80	75,03	13,99	36,37	45,70	9,79	70,79
SEGMENTACIJA 40_70							
med_RGBNir	82,02	74,21	15,80	22,19	1,30	10,80	68,14
med_RGBNirNdvi	82,31	74,78	15,50	11,11	7,11	0,00	68,67
med_homo_RGBNir	82,16	70,47	21,80	6,17	18,35	9,80	64,97
SEGMENTACIJA 40_80							
med_RGBNir	81,67	74,47	5,94	24,96	0,00	0,00	68,08
med_RGBNirNdvi	82,15	73,99	6,86	18,10	11,63	0,00	68,22
med_homo_RGBNir	81,50	70,62	26,57	7,02	17,49	9,82	65,45

Tudi pri klasifikaciji poljščin indeks NDVI v veliki večini ni izboljšal rezultata klasifikacije. Prav tako večinoma ni bilo nobenega doprinosu z uporabo texture HOMO. Sklepi glede uporabnosti posameznih osnovnih enot so podobni kot pri osnovnih razredih. Najboljšo klasifikacijo nudi OE GERK. Zaradi izredno majhne velikosti njiv se prešibka segmentacija pojavlja že vsaj pri parametrih 20_40 (slika 57). Temu primerna je tudi kakovost klasifikacije (slika 58, referenčni sloj glej na sliki 57). Če nimamo na voljo sloja GERK, je v primeru klasifikacije poljščin (v Pomurju na posnetkih z 10 m ločljivostjo) morda najbolje uporabiti kar OE PIKSEL. Sicer pa tudi kakovost klasifikacije na OE GERK ni najboljša. Najverjetnejši razlog je zelo velika podobnost med posameznimi razredi.



Slika 57: OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in SEGMENT 30_70 (d) na referenčnem sloju. Izsek študijskega območja Murska Sobota.

Figure 57: Mapping unit PIKSEL (a), mapping unit GERK (b), mapping unit SEGMENT 20_40 (c) and SEGMENT 30_70 (d) on reference layer. A section of Murska Sobota study area.



Slika 58: Klasifikacija, dobljena z OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in OE SEGMENT 30_70 (d). Izsek študijskega območja Murska Sobota.

Figure 58: Classification results, obtained with mapping units PIKSEL (a), GERK (b), SEGMENT 20_40 (c) and SEGMENT 30_70 (d). A section of Murska Sobota study area.

9.4 Analiza optimalnih enot pri veččasovni klasifikaciji

Pri enočasovni klasifikaciji smo vezani na en sam, točno določen posnetek. Osnovne enote PIKSEL in SEGMENT potekajo točno po robu pikslov. Težav z zamiki posledično ni pričakovati. Drugače je v primeru veččasovne klasifikacije. Posnetki in njihovi piksli so med seboj lahko zamaknjeni. V primeru veččasovne klasifikacije je pravilno uporabiti poravnane posnetke oz. posnetke z istoležnimi piksli. Če originalni posnetki niso istoležni, lahko to storimo s prevzorčenjem. Pri tem nimamo primera zamika pol piksla ali npr. 1,3 piksla. Lahko pa se zgodi, da so piksli sicer poravnani (piksel na piksel), sama vsebina (lokacija objektov) pa je kljub temu zamaknjena za piksel ali celo več. Vzrok je slaba georeferenciranost posnetka. Različna georeferenciranost posnetkov različnih časov predvidoma slabša

možnost dobre klasifikacije.

Naši testni posnetki so prevzorčeni na isto lokacijo in isto velikost piksla; pri nekaterih posnetkih pa se pojavlja zamik vsebine za en piksel. V primeru OE PIKSEL je le-ta fiksna skozi čas. Zamik vsebine vpliva »zgolj« na kakovost klasifikacije. V primeru OE SEGMENT se problematika zamika pojavi že pri določitvi same osnovne enote. Če bi imela npr. njiva homogenost na določenem skupku pikslov, bi imela v primeru istega stanja v naravi (npr. pet dni kasneje), vendar en piksel zamaknjene posnetka, lokacijo segmenta zamaknjeno za en piksel. Dodatno določitev veččasovnega segmenta otežuje dejstvo, da se homogenost na posnetkih, še posebej na razredu njiva, med datumi spreminja. Tako so lahko segmenti aprila precej drugačni kakor septembra.

OE GERK, po drugi strani, je za vsako koledarsko leto določen fiksno. Problematika zamaknjene posnetkov vpliva »zgolj« na klasifikacijo. Dodatno lahko klasifikacijo kvari premik gerkov na mejo pikslov. Gerki namreč lahko potekajo po sredini piksla, klasifikacija pa, ne glede na osnovno enoto, vedno klasificira piksel kot celoto. Ta problematika je sicer odvisna zgolj od prostorske ločljivosti piksla. Višja kot je ločljivost, manjši problem predstavlja.

V tem poglavju želim pridobiti občutek vpliva osnovne enote na klasifikacijo. Zato tudi v primeru veččasovne klasifikacije uporabljam enake segmente kot pri enočasovni klasifikaciji. Kako je najbolje izdelati veččasovno segmentacijo in kako pridobiti najboljše segmente, je tema poglavja 10.4.

Pri analizi sem izvajala kvazi veččasovno klasifikacijo osnovnih razredov in osnovnih poljščin pri različnih osnovnih enotah in nekaj atributih mediana RGBNir. Klasifikacijo sem izvajala na posnetkih RapidEye datumov 9.4.2013 do 26.10.2013 na študijskem območju Murska Sobota. Uporabila sem klasifikator ANN ter Sobelovo metodo zaznave robov za pridobitev segmentov. Pri vseh klasifikacijah so bile uporabljene iste učne točke.


9.4.1 Veččasovna klasifikacija osnovnih razredov

Rezultati veččasovne klasifikacije osnovnih razredov so predstavljeni v preglednici 51 ter sliki 59.

Preglednica 51: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetku RapidEye datumov od 9.4.2013 do 26.10.2013. Študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije mediana RGBNir. Klasifikator ANN. Segmentacije so bile izvedene na posnetku RapidEye 29.7.2013, na slojih RGBNir s Sobelovo metodo zaznave robov.

Table 51: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on all RapidEye images from date 9.4.2013 to 26.10.2013. Murska Sobota study area. Classifications on different mapping units with classification attributes median of RGBNir. ANN classifier. All segmentations were performed on RapidEye image 29.7.2013, on RGBNir layers and with Sobel edge detection method.

Atribut\Razred	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
PIKSEL	94,35	67,62	93,65	86,75	75,85	90,68
GERK	98,68	87,37	98,26	97,98	79,19	97,30
SEGMENTACIJA 20_40	94,57	65,55	91,42	88,61	84,91	90,83
SEGMENTACIJA 30_70	94,55	63,96	91,44	88,80	85,61	90,77



Slika 59: Rezultat kvazi veččasovne klasifikacije osnovnih razredov z OE PIKSEL (a), OE GERK (b), OE SEGMENT 20_40 (c) in OE SEGMENT 30_70 (d). Študijsko območje Murska Sobota.

Figure 59: The result of quasi-multitemporal classification of basic land cover classes with mapping unit PIXEL (a), GERK (b), SEGMENT 20_40 (c) and SEGMENT 30_70 (d). Murska Sobota study area.

Rezultati veččasovne klasifikacije osnovnih razredov so v splošnem veliko boljši kot rezultati enočasovne klasifikacije istih razredov. Podobno kot pri enočasovni klasifikaciji, je najboljša osnovna enota GERK. Na njeni osnovi dobimo klasificirano podobo, ki se od referenčnega sloja razlikuje zelo malo. Na nekaterih delih je celo pravilnejša, saj referenčni sloj ni 100 % pravilen. Rezultati ostalih testiranih osnovnih enot se bistveno ne razlikujejo. Razlika je zopet bolj kot ne v konsistenci. Pri pikslih je razvidna razdrobljenost, ki pa jo predvidoma lahko vsaj delno odpravimo s postopki poklasifikacije; npr. če na GERK pripišemo samo tisti razred, ki se najpogosteje pojavlja znotraj tega GERK. Segmenti razdrobljenost sicer v različni meri »prečistijo«, vendar pri tem nekatere informacije izgubimo (npr. ozke ceste). S tem otežimo uspešnost morebitne poklasifikacije. Možni razlogi za slabši rezultat

klasifikacije s piksli oz. segmenti so enaki kot pri enočasovni klasifikaciji.


9.4.2 Veččasovna klasifikacija osnovnih poljščin

Na enak način kot osnovne razrede sem veččasovno klasificirala tudi osnovne poljščine. Rezultati so predstavljeni v preglednici 52 in na sliki 60. Klasificirala sem zgolj šest osnovnih poljščin, ves preostali del posnetka sem maskirala in ga ne obravnavam niti pri klasifikaciji niti pri oceni kakovosti.

Preglednica 52: F-mera in skupna natančnost (OA) klasifikacije osnovnih poljščin na posnetkih RapidEye datumov od 9.4.2013 do 26.10 2013, študijsko območje Murska Sobota. Klasifikacije na različnih osnovnih enotah in atributih klasifikacije RGBNir. Klasifikator ANN. Segmentacije so bile izvedene na posnetku RapidEye 29.7.2013, na slojih RGBNir s Sobelovo metodo zaznave robov.

Table 52: F-score and overall accuracy (OA) of multitemporal classification of basic crop type classes on all RapidEye images from date 9.4.2013 to 26.10 2013. Murska Sobota study area. Classifications on different mapping units with classification attributes median of RGBNir. ANN classifier. All segmentations were performed on RapidEye image 29.7.2013, on RGBNir layers and with Sobel edge detection method.

Atribut\Razred	F-mera (%)						OA (%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikala	
PIKSEL	87,31	85,73	64,28	53,34	74,96	26,34	81,40
GERK	94,82	91,35	81,29	70,64	83,56	24,76	89,59
SEGMENTACIJA 10_20	86,58	84,46	63,26	9,16	67,49	0,00	79,98
SEGMENTACIJA 20_40	87,01	83,60	64,21	9,49	69,66	0,00	80,15



Slika 60: Rezultat kvazi veččasovne klasifikacije osnovnih poljščin z OE piksel (a), OE GERK (b), OE SEGMENT 10_20 (c) in OE SEGMENT 20_40 (d). Študijsko območje Murska Sobota.

Figure 60: The result of quasi-multitemporal classification of basic crop type classes with mapping unit PIXEL (a), GERK (b), SEGMENT 10_20 (c) and SEGMENT 20_40 (d). Murska Sobota study area.

Tudi pri veččasovni klasifikaciji osnovnih poljščin je najboljša osnovna enota GERK (povprečno 9 % boljša skupna natančnost kot pri ostalih OE). Problematike izredne majhnosti njiv pričakovano ne izboljšamo niti s časovno vrsto posnetkov. Že pri parametrih segmentacije 10_20 prihaja do neustreznega združevanja pikslov, zato se je OE PIKSEL v tem primeru izkazala kot boljša izbira, ki nudi višjo kakovost klasifikacije kakor segmenti. Morda bi kakovost segmentacije izboljšala z veččasovno določenimi segmenti oz. bolje določenimi segmenti. To preverjam v poglavju 10.4.

9.5 Določitev optimalne osnovne enote kartiranja

Pri vseh primerih klasifikacije (enočasovna, veččasovna, osnovni razredi in osnovne poljščine) se je po pričakovanju kot najboljša osnovna enota izkazala OE GERK. Od vseh ostalih testiranih osnovnih enot sem z njeno uporabo dobila od 6–9 % višjo skupno natančnost. Poleg tega imajo rezultati visoko konsistenco in so vektorski. Rezultati vseh ostalih osnovnih enot so bili slabši in v splošnem med seboj zelo podobni. Prekomerna segmentacija ni pokazala bistvenih slabosti. Občutno poslabšanje je bilo zaznati šele v primeru prešibke segmentacije, katere uporabi se je priporočljivo izogniti.

Ker je GERK tudi referenčni sloj, sklepam, da so najboljše osnovne enote kar poligoni referenčnega sloja. Ker tega navadno nimamo na voljo (vsaj ne za celotno območje), je iz rezultatov sledeč potrebno uporabiti takšno osnovno enoto, pri kateri gredo poligoni čim bolj po meji zelenih razredov, jih je v posameznem razredu čim manj, vsak poligon pa naj (vsaj v veliki večini) zajema zgolj en razred. Če takšne osnovne enote nimamo, je najbolje klasifikacijo izvesti kar s pikslji, kasneje pa rezultate skušati izboljšati s postopki poklasifikacije.

Kar se tiče časa izvajanja celotnega postopka klasifikacije z različnimi osnovnimi enotami, prav tako prednjači OE GERK. Sloj je definiran že vnaprej, število enot je nižje kot pri piksljih in segmentih. Segmenti zahtevajo dodaten čas segmentacije, ampak je le-ta z algoritmom ENVI FX zelo kratek (minuta za 25 x 25 km). Z OE PIKSEL imamo načeloma daleč največje število enot, vendar pa je učenje, ki zahteva največ časa, pri vseh OE enako dolgo. Pri vseh OE sem namreč uporabila iste učne točke in iste attribute. Čas same klasifikacije pa je zelo kratek pri vseh OE, tudi v primeru veččasovne klasifikacije (1,4 min za 13 časov in OE PIKSEL; 0,1 min za 13 časov in OE GERK).

Naj na koncu omenim, da osnovne enote, ki sem jih testirala, niso edine osnovne enote, ki so v praksi možne ali želene. So pa daleč najpogostejše. Če npr. želimo najti neupravičeno rabo na njivah s koruzo, bo GERK prevelika osnovna enota. Primernejša bi bila npr. presek sloja GERK s slojem segmentacije. Želja je npr. tudi klasificirati določene razrede na sloj zemljiškega katastra idr. Katerokoli osnovno enoto že izberemo, je zaželeno, da čim manj odstopa od referenčnega sloja.

V naslednjih poglavjih skušam z menjavanjem vhodnih slojev, upoštevanjem tekture ipd. dobiti segmente, ki so čim bolj podobni OE GERK.

10 VPELJAVA NAJSODOBNEJŠIH METOD V POSTOPEK SEGMENTACIJE

V prejšnjem poglavju sem pokazala, da je za izbrane razrede klasifikacije (osnovni razredi in osnovne poljščine) na študijskem območju Pomurja in satelitskih posnetkih z 10 m prostorsko ločljivostjo najboljša osnovna enota klasifikacije GERK. To je veljalo ne glede na razred pokrovnosti in število posnetkov iz različnih časov. Sledili sta OE PIKSEL in različne OE SEGMENT, pri čemer ni bilo bistvene razlike pri skupni natančnosti klasifikacije, temveč zgolj v konsistentnosti rezultatov. Največjo radrobljenost klasificiranih razredov je zaznati pri pikslu, nato pa se le-ta manjša z večanjem parametrov segmentacije. Posebno pozornost je potrebno nameniti prešibki segmentaciji, saj ni primerna za klasifikacijo.

Ker sloja GERK oz. kateregakoli referenčnega sloja za celotno območje obdelave praviloma nimamo na voljo, je naš splošen cilj narediti sloj segmentacije, ki bo čim bolj podoben sloju GERK. Trenutno narejeni segmenti namreč prevečkrat vsebujejo več kot en razred znotraj posamezne enote. Optimalne segmente skušam pridobiti v naslednjem poglavju. Cilj tega poglavja pa je vpeljati nekaj najsodobnejših metod v postopek segmentacije oz. preveriti učinkovitost vpeljave določenih postopkov v segmentacijo.

10.1 Vpeljava različnih metod zaznave robov v postopek segmentacije


V disertaciji za segmentacijo uporabljam algoritem razvodij, pri katerem za vhodno podobo potrebujemo podobo gradienta, izdelano z metodo zaznave robov. V programsko opremo ENVI FX je v postopek segmentacije vgrajena zgolj Sobelova metoda zaznave robov. Zanimivo je izvedeti ali gradientne podobe drugih metod zaznave robov vplivajo na drugačen rezultat segmentacije in posledično na drugačno kakovost klasifikacije. Zato sem poleg Sobelove preizkusila še pet drugih metod zaznave robov: Robertsovo, Prewittovo, Laplaceovo ter metodi Emboss in DoG. Vse metode v osnovi delujejo na eno-kanalni vhodni podobi, vendar je postopek v programu ENVI prilagojen tako, da podpira tudi večkanalne vhodne podobe (vzamejo se najvišje vrednosti gradientov izmed vseh kanalov). Rezultat vseh postopkov zaznave robov je eno-kanalna podoba gradienta. Posamezne metode na kratko opisujem v preglednici 53. Na sliki 61 prikazujem rezultate podob gradienta, ki sem jih izdelala z različnimi metodami zaznave robov na študijskem območju Murske Sobote in posnetku RapidEye 29.7.2013.

Sobelova, Robertsova in Prewittova metoda vrnejo zelo podobne podobe gradienta. V Laplaceovi je zaznati nekaj več šuma, metoda Emboss da občutek reliefa, metoda DoG pa bolj izostri glavne značilnosti kot poudari robove. Vse dobljene podobe gradienta sem uporabila kot edini vhodni podatek v algoritem razvodij. Dodatno sem v postopku segmentacije uporabila metodo združevanja, pri kateri sem uporabila vse štiri spektralne kanale. Vse segmentacije sem naredila z enakimi parametri: stopnja merila 30 in stopnja združevanja 70. Rezultati manjšega dela študijskega območja vseh segmentacij so prikazani na sliki 62.

Preglednica 53: Opis uporabljenih metod zaznave robov


Table 53: Description of used edge detection methods

Metoda zaznave robov	Opis
Sobel	Sobelova metoda poudari območja z visoko prostorsko frekvenco – robove. Običajno se uporablja za iskanje približno absolutne magnitude gradienta v vsaki točki vhodne eno-kanalne podobe. Izračun je počasnejši kot pri Robertsovem postopku, vendar njegovo večje konvolucijsko okno bolj zgladi vhodno podobo in tako naredi postopek manj občutljiv na šum (Fisher et al., 2016b).
Roberts	Robertsova metoda deluje na enak način kot Sobelova metoda, le da je enostavnejša in hitrejša. Glavna slabost je njena občutljivost na šum (Fisher et al., 2016a).
Prewitt	Prewittova metoda zaznava dve vrsti robov: vodoravne in navpične. Robovi se računajo na osnovi razlik med vrednostmi intenzitet pikslov na območju roba (Tutorialspoint, 2016).
Laplace	Laplaceova metoda uvaja Laplaceovo funkcijo, ki označi regije s hitro spremembo intenzitete. S tem postopkom iščemo lokacije, kjer Laplaceova vrednost preide nulo (zamenja predznak) (Fisher et al., 2016c).
Emboss	Metoda Emboss s konvolucijo izdela relief (3D učinek senčenja) vhodne podobe. To doseže z odštevanjem piksla na eni strani centra od tistega na drugi strani centra. Piksli lahko dobijo pozitivni ali negativni rezultat (Vandevenne, 2016).
DoG	Metoda DoG (Difference of Gaussian) deluje na razliki Gaussovih filtrov. V osnovi je nemenjen poudarjanju značilnih elementov oz. izostritvi slike (Drakos in Moore, 2016).



Slika 61: Izhodne podobe metod zaznave robov: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Robovi so bili narejeni na spektralnih pasovih R, G, B in NIR vhodne podobe RapidEye 29.7.2013. Študijsko območje Murska Sobota.

Figure 61: Output images of edge detection methods: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Edges were obtained on spectral bands R, G, B and NIR of input image RapidEye 29.7.2013. Murska Sobota study area.



Slika 62: Segmentacije, narejene z metodo intenzitete s podobami gradienta slike 61: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). Vse segmentacije so bile izvedene z istimi parametri: segmentacija sama je bila narejena na vhodni podobi gradienta s stopnjo merila 30. Segmenti so bili nato združeni na osnovi kanalov R, G, B, Nir ter stopnjo združevanja 70. Na sliki je prikazan manjši izsek študijskega območja Murska Sobota.

Figure 62: Segmentations, obtained with intensity method on gradient images, shown in Figure 61: Sobel (a), Roberts (b), Prewitt (c), Laplace (d), Emboss (e) in DoG (f). All segmentations were performed with the same parameters: scale level 30 on gradient image, merge level 70 on channels R, G, B and Nir. Figure shows small part of Murska sobota study area.

Glede na podobnost podob gradienta metod Sobel, Roberts in Prewitt, so pričakovano podobni tudi rezultati njihovih segmentacij. Laplaceova gradientna podoba z nekaj več šuma posledično vrne manjše segmente. Pri rezultatu segmentacije podob Emboss in DoG je opaziti prešibko segmentacijo, zato so pričakovani slabši rezultati klasifikacije.

Na segmentacijah vseh podob gradienta sem po enakem postopku in z istimi učnimi točkami klasificirala osnovne razrede pokrovnosti. Natančnost klasifikacije sem ocenjevala na vseh pikslah posnetka, tudi na učnih točkah, saj ima v primeru optimalne segmentacije razred voda zgolj dva segmenta. Ker sta ta učna, posledično voda ne bi imela več testnih točk. Rezultate prikazujem v preglednici 54.


Preglednica 54: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na segmentih, osnovanih s podobami gradienta različnih metod zaznave robov. Osnova podob gradienta je bil posnetek RapidEye 29.7.2013. Na segmentih se računa mediana vrednosti spektralnih slojev R, G, B in NIR. Študijsko območje Murska Sobota.

Table 54: F-score and overall accuracy (OA) of classification of basic land cover classes, based on gradient images of different edge detection methods. Input for gradient images was RapidEye image 29.7.2013. Attributes on segments are calculated as median of RGBNir spectral bands. Murska Sobota study area.

Atribut	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
Sobel	90,28	10,09	88,52	86,16	84,83	85,83
Roberts	89,52	4,46	88,48	85,77	81,37	84,83
Prewitt	89,01	9,35	87,76	80,03	80,42	83,34
Laplace	89,74	7,70	87,15	85,16	80,35	84,91
Emboss	89,14	1,38	82,84	83,69	72,86	83,46
DoG	88,98	7,16	82,14	82,87	81,82	83,39

Metode Sobel, Roberts in Prewitt približno enako dobro zaznajo robove. Tudi metoda Laplace ne zaostaja dosti. Po drugi strani metodi Emboss in DoG nista primerni kot osnovi za segmentacijo. Glede na rezultate klasifikacije je dovolj dobro oz. najbolje, če pri klasifikaciji uporabimo kar privzeto metodo zaznave robov, tj. metodo Sobel. Pri tem imamo tudi manj dela, saj odpade predhodni postopek pridobitve podobe gradienta.

Ne glede na to, s katero metodo zaznave robov bi naredili podobo gradienta, bi algoritem ENVI FX segmentacijo izvedel z algoritmom razvodij, ki temelji na konceptu »polnjenja regij«. Največji robovi (gradienti) so jezovi, meje segmentov. Določitev jezov ima matematično osnovo, zato meje med segmenti niso vedno takšne kot bi jih naredil človek na osnovi vizualne interpretacije. Primer na sliki 63.




Slika 63: Podoba gradientov, pridobljena s Sobelovo metodo zaznave robov na posnetku RapidEye 29.7.2013 (transparenten sivi raster) ter segmenti, kot jih vrne algoritem razvodij pri parametrih 30_70 (modre linije). Izsek študijskega območja Murska Sobota.

Figure 63: Gradient image, obtained by Sobel edge detection method on RapidEye image 29.7.2013 (transparent gray raster) and segments, as result of watershed algorithm at parameters 30_70 (blue lines). Part of Murska Sobota study area.

Opaziti je, da v primeru zelo značilnega robu, segmenti potekajo točno po robovih (jezovih). Kjer pa rob ni zelo značilen, pa je »pretakanje vode« težko predvideti in lahko dva podobna sosednja razreda padeta v eno »regijo« oz. segment.

Če na posnetku primerjamo meje OE GERK, kot gredo v postopek klasifikacije⁸, in meje segmentov (slika 64), opazimo, da je prileganje zadovoljivo, ne pa popolno. Človek namreč pri interpretaciji upošteva mnogo več kot le vrednosti pikslov.

⁸ Pri vseh klasifikacijah v disertaciji sloj osnovnih enot rastriram. Zato pri vseh primerih osnovne enote vsebujejo le celo število pikslov. Posamezen piksel se pripiše tisti enoti, kjer leži centroid piksla.



Slika 64: OE GERK v obliki, kot gre v postopek klasifikacije (a), ter OE SEGMENT 30_70, pridobljen s Sobelovo metodo zaznave robov (b). Oboje prikazano na RapidEye posnetku 29.7.2013 v pravih barvah. Izsek študijskega območja Murska Sobota.

Figure 64: GERK mapping unit, in a form as input to classification process (a), and mapping unit SEGMENT 30_70, obtained with Sobel edge detection method (b). Both mapping units are shown on true colour RapidEye image 29.7.2013. Part of Murska Sobota study area.

Posledica neujemanja je, da lahko en segment vsebuje dva ali celo več različnih razredov pokrovnosti. To je seveda z vidika klasifikacije neželjeno. Bi morda kakšen drug algoritem segmentacije bolj približal lokacije segmentov človeški interpretaciji? V poglavju primerjave algoritmov segmentacije (6.1.1) sem že zapisala, da ima vsak algoritem segmentacije svoje prednosti in slabosti. Vsi pa temeljijo na matematični obdelavi vrednosti pikslov vhodne podobe, zato sem poskušala v nadaljevanju segmente približati obliki gerkov z upoštevanjem teksture in različnih vhodnih podob v postopku segmentacije. Pri tem sem pri segmentaciji uporabila zgolj algoritem razvodij in Sobelovo metodo zaznave robov.

10.2 Vpeljava teksture v postopek segmentacije

Pri pisanju teme doktorske disertacije sem pri prebiranju literature opazila, da je v samem postopku segmentacije vedno uporabljena takšna ali drugačna spektralna vhodna podoba. Ker je na nekaterih spektralnih podobah očitno, da imajo določeni razredi zelo močno izraženo strukturo, le-ta pa v primeru uporabe algoritma razvodij vodi v prekomerno segmentacijo, sem postavila hipotezo H1: upoštevanje teksture v postopku segmentacije izboljša kakovost segmentacije in s tem končne klasifikacije.

Del trditve v hipotezi H1, da upoštevanje teksture »izboljša kakovost segmentacije in s tem končne klasifikacije«, temelji na predhodni predpostavki, da sta kakovost segmentacije in klasifikacije neposredno povezani. Da temu ni tako, sem opisala v poglavju 3.3. Zato pri preverjanju hipoteze H1 ne ocenjujem kakovosti segmentacije same, temveč zgolj kakovost končne klasifikacije. Pri tem kljub temu skušam s teksturo dobiti takšno segmentacijo, ki glede na izvedene analize v prejšnjih poglavjih obeta

najboljše rezultate kakovosti klasifikacije. To je takšna segmentacija, kjer je posamezen objekt v enem segmentu. Zato pri segmentaciji posamezne vhodne podobe uporabim takšne parametre, ki bodo segmente čim bolj približale referenčnim poligonom. Pri tem upoštevam, da je bolje, če je objekt rahlo prekomerno segmentiran, kakor prešibko (ugotovitve poglavje 9.5). Parametra segmentacije glede na vizualno presojo prilagodim vsaki vhodni podobi posebej.

Vpliv upoštevanja teksture v postopku segmentacije na kakovost končne klasifikacije preverim računsko z mero kakovosti F-score in skupne natančnosti OA.

Glede na analizo delovanja algoritma razvodij in Sobelovo metodo zaznave robov predpostavljam, da moramo za zeleno obliko segmentov uporabiti takšno teksturno podobo, ki bo objekte, znotraj katerih je variabilnost spektralnih vrednosti visoka, prikazala čim bolj homogeno. S tem bi se predvidoma izognili prekomerni segmentaciji.

Potrebno je poudariti, da v tem poglavju ne analiziram vpliva teksture na klasifikacijo (kjer je atribut lahko npr. varianca rdečega kanala na vseh pikslih segmenta), temveč vpliv teksture na segmentacijo, to je na obliko segmentov. Tekstura torej ni atribut segmenta, ampak jo izračunamo na mrežo določene skupine sosednjih pikslov v obliki teksturnih filtrov. Ker je prostorska ločljivost uporabljenih satelitskih posnetkov že sama po sebi velika glede na velikost objektov na terenu, vzamem najmanjšo možno mrežo, tj. mreža 3 x 3 pikslov.

Atribut klasifikacije sem uporabila standardne (RGBNir) in v vseh primerih enake. Hipotezo sem najprej preverila za enočasovno klasifikacijo.

Rezultate testiranja uporabnosti teksture v postopku segmentacije prikazujem v preglednici 55. V vseh primerih so bile uporabljene enake učne točke. Učni segmenti so morali zadostiti pogoju, da vsebujejo vsaj eno učno točko.

Za lažjo predstavo o obliki segmentov posamezne vhodne podobe ter za razporeditev napak klasifikacije je na slikah 65 do 67 prikazanih nekaj grafičnih primerov.

Preglednica 55: F-mera in skupna natančnost (OA) klasifikacije osnovnih razredov na segmentih, osnovanih na različnih teksturnih vhodnih podobah. Osnova analize je bil posnetek RapidEye 29.7.2013. Na segmentih se za klasifikacijo računa mediana vrednosti spektralnih slojev R, G, B in NIR. Študijsko območje Murska Sobota. Za vsako vhodno podobo sem vzela takšne parametre velikosti in združitve, ki so se iz med vseh možnih vizualno zdeli najbolj podobni poligonu referenčnega sloja. Parametra sta za vsak posamezen primer zapisana v oklepajih (velikost_združitve).

Table 55: F-score and overall accuracy (OA) of classification of basic land cover classes on segments, based on different texture images. The basis was a RapidEye image 29.7.2013. Attributes were calculated as median of spectral values R, G, B and NIR. Pomurje study area. For each input image such segmentation parameters were used that visually seemed the most similar to polygons of reference layer. Parameters for each case are put into brackets in the form (scale_merge).

F-mera (%)						OA (%)
Vhodna podoba \ Razred	njiva	trava	gozd	urbano	voda	
spektralne vhodne podobe - za primerjavo						
R (30_80)	86,67	0,00	43,59	85,17	55,44	80,02
Nir (30_80)	79,89	0,00	80,98	84,88	43,81	76,66
RGBNir (30_70)	84,34	0,00	81,93	85,19	5,74	79,55
teksturne vhodne podobe						
povprečje						
3 x 3 mean R (30_70)	87,90	0,13	60,21	85,77	60,68	81,58
3 x 3 mean Nir (30_70)	81,37	0,25	87,83	84,45	42,44	78,76
3 x 3 mean RGBNir (30_70)	85,12	1,96	88,47	84,29	43,55	80,66
varianca						
3 x 3 var R (01_00)*	88,24	0,30	69,97	84,38	36,15	81,87
3 x 3 var Nir (45_00)*	86,79	5,83	89,68	79,88	35,55	81,70
3 x 3 var RGBNir (40_00)*	78,24	0,93	80,93	87,44	0,00	77,07
homogenost						
3 x 3 homo R (30_60)	88,22	20,75	72,70	83,69	72,09	81,63
3 x 3 homo Nir (30_80)	85,50	1,54	85,62	84,64	58,55	80,90
3 x 3 homo RGBNir (30_80)	85,42	11,21	79,35	83,92	57,25	79,60
entropija						
3 x 3 entro R (30_80)	88,56	0,41	72,95	81,96	62,19	81,76
3 x 3 entro Nir (40_80)	88,60	6,83	74,72	65,03	70,40	80,37
3 x 3 entro RGBNir (30_90)	85,24	5,20	73,39	59,46	64,46	77,68
odpiranje						
3 x 3 open R (30_70)	87,79	0,06	52,71	84,36	0,00	81,36
3 x 3 open Nir (30_70)	82,97	10,43	83,36	83,97	0,00	78,23
3 x 3 open RGBNir (30_80)	81,40	0,05	87,23	83,25	0,00	78,30
zapiranje						
3 x 3 close R (30_70)	88,66	0,85	50,02	85,72	17,32	82,18
3 x 3 close Nir (30_70)	83,83	1,49	88,01	86,76	0,00	80,69
3 x 3 close RGBNir (30_80)	84,41	0,01	82,97	86,47	0,00	80,04
referenčni sloj GERK – za primerjavo						
GERK	92,37	30,77	65,19	65,29	72,36	85,37

*algoritem razvodij z metodo intenzitete




Slika 65: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) osnovnih enot GERK (a) in OE SEGMENT, dobljenih na osnovi podobe RGBNir (b). Vsi podatki klasifikacije so navedeni v preglednici 55.

Figure 65: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of mapping unit GERK (a) and of mapping unit SEGMENT, obtained on RapidEye bands RGBNir (b). All classification information can be seen in Table 55.



Slika 66: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) OE SEGMENT, dobljenih na osnovi morfologije RGBNir: odpiranje (a) in zapiranje (b). Vsi podatki klasifikacije so navedeni v preglednici 55.

Figure 66: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of segments, obtained by morphology filters of RapidEye bands RGBNir: opening (a) and closing (b). All classification information can be seen in Table 55.



Slika 67: Podoba napak klasifikacije (rdeče – napačno klasificirano, zeleno – pravilno klasificirano, temno sivo – drugo) OE SEGMENT, dobljenih na osnovi podob matrik sopojavljanja RGBNir: povprečje (a), varianca (b), homogenost (c) in entropija (d). Vsi podatki klasifikacije so navedeni v preglednici 55.

Figure 67: Classification accuracy image (red – false classification, green – true classification, dark gray – unclassified) of segments, obtained by co-occurrence filters of RapidEye bands RGBNir: mean (a), variance (b), homogeneity (c) and entropy (d). All classification information can be seen in Table 55.

Rezultati so na prvi pogled presenetljivi. Kakovost klasifikacije v nobenem primeru segmentacije ne odstopa bistveno. To velja tako za številčne rezultate (F-score in OA) kot tudi vizualno. Rezultati so kljub vsemu najboljši na OE GERK (kot so pokazale tudi ostale dosedanje analize). Zanimivo je, da rezultati na predvidoma zelo slabih segmentih, npr. dobljenih na RGBNir podobi variance (slika 67 b) sploh niso tako zelo slabi oz. niso veliko slabši od najboljših. Deloma je razlog v razporeditvi osnovnih razredov. Njive pokrivajo večino območja in če je vse klasificirano kot njiva, je klasifikacija že na pol pravilna. S tem na nek način potrjujem tudi ugotovitve glede parametrov segmentacije, in sicer, da parametri segmentacije nimajo pomembnega vpliva na kakovost klasifikacije.


Kljub vsemu lahko iz dobljenih rezultatov sklepam, da v sam postopek segmentacije ni smiselno vpeljevati teksture. Še več: z njo lahko kakovost klasifikacije celo poslabšamo. Hipotezo H1 s tem ovržem.

10.3 Večnivojska segmentacija

V času prijave teme doktorske disertacije sem bila mnenja, da bi bila segmentacija veliko boljša in učinkovitejša, če bi jo prilagodili vsakemu razredu posebej ozirom bi jo izvajali t. i. večnivojsko. Ker posameznih razredov ne moreš izločiti kot segmente določenega razreda, dokler jih ne klasificiraš, je posledično potrebno izvesti tudi večnivojsko klasifikacijo. Zato sem postavila hipotezo H3, ki se glasi: večnivojska objektno usmerjena klasifikacija pokrovnosti daje boljše rezultate kakor enonivojska.

V nadaljevanju je opisan in komentiran hierarhični postopek »po nivojih«, kot sem ga izvajala. Večnivojsko segmentacijo sem izvajala na študijskem območju Murska Sobota na vhodnih podobah 29.7.2013.


Segmentirala sem celotno izbrano vhodno podobo in segmentacijo prilagodila razredu gozd. Razred gozd sem izbrala za prvega, saj je glede na dosedanje rezultate klasifikacij v nalogi najboljše ločljiv od ostalih razredov. Segmentacijo sem izvedla na vhodnih slojih G in R s parametri 30_80 z željo dobiti poligone gozda, čim bolj podobne referenčnim poligonom gozda (slika 68).



Slika 68: Izsek sloja segmentacije gozda, dobljenega na osnovi vhodnih slojev R in G ter parametrov 30_80

Figure 68: Part of forest segmentation layer, obtained on the basis of input layers R and G with parameters 30_80


Dobljene segmente sem klasificirala. Pri tem sem bila precej omejena, saj moramo v primeru klasifikacije zgolj enega razreda uporabiti t. i. enorazredno klasifikacijo (angl. one-class classification). Te klasifikacije so navadno (kot je bilo tudi v našem primeru) osnovane na pravilih (angl. rule based). Pravila je potrebno nastavljanje ročno, kar je časovno zelo potratno, hkrati pa nimamo zagotovljenih optimalnih rezultatov. Kljub temu sem razred gozd precej dobro klasificirala (slika 69).



Slika 69: Izsek klasifikacije gozda kot prvega razreda večnivojske klasifikacije

Figure 69: Part of forest classification as the first class of multilevel classification


Sledil je naslednji »nivo« oz. klasifikacija naslednjega razreda. Izbrala sem urbano, saj ima predvidoma nizko vrednost NDVI. Segmentacijo sem sedaj izvajala na maskirani podobi. To pomeni, da sem vhodne podobe, ki so sedaj lahko bile popolnoma druge kakor pri segmentaciji prvega razreda, segmentirala samo na tistih območjih, kjer ni bil predhodno klasificiran gozd. Uporabila sem vhodno podobo NDVI in jo segmentirala s parametri 40_80 (slika 70).



Slika 70: Izsek sloja segmentacije razreda urbano, dobljenega na osnovi vhodne podobe NDVI ter parametrov 40_80. Območje gozda, klasificiranega v prejšnjem koraku, je maskirano, zato se segmentacija na tem območju ne izvaja.

Figure 70: Part of build-up class segmentation, obtained on the basis of NDVI input image and parameters 40_80. The forest area, classified in the previous step, is masked out, therefore segmentation in this area is not performed.

Potem sem skušala čim boljše klasificirati razred urbano. Klasifikacijo ostalih razredov sem nadaljevala po enakem postopku. Končna klasifikacija vseh razredov po prvi fazi (vsak razred sem klasificirala enkrat) je prikazana na sliki 71. Veliko območij je ostalo neklasificiranih, saj z enorazredno klasifikacijo določamo možna območja izbranega razreda in ne delimo celotnega območja v nekaj izbranih razredov. Ta območja je potrebno ponovno klasificirati po enakem postopku ali pa po večrazredni klasifikaciji.



Slika 71: Rezultat večnivojske klasifikacije osnovnih razredov po prvi fazi (vsak razred je bil klasificiran le enkrat). Vso območje v beli barvi je ostalo neklasificirano in mora ponovno v postopek klasifikacije.

Figure 71: Result of multilevel classification of basic land cover classes after first phase (each class was classified only once). The whole area in white colour remained unclassified and must be once again used in the classification procedure.

Postopka nisem nadaljevala, saj je več kot očitno, da bi bila končna klasifikacija veliko slabša od enonivojske klasifikacije, kjer vse razrede segmentiramo in klasificiramo naenkrat.

Hipoteza »večnivojska objektno usmerjena klasifikacija pokrovnosti daje boljše rezultate kakor enonivojska« je pravzaprav zastavljena preširoko. V njej sta namreč vključeni tako večnivojska segmentacija kot večnivojska klasifikacija. Ker sem jo postavila predvsem zaradi večnivojske segmentacije, najprej komentiram to.

V svojih predhodnih analizah (Švab Lenarčič et al., 2015; Švab Lenarčič et al., 2016) ter analizah v tej disertaciji ugotavljam, da je pri vseh razredih najboljša segmentacija pri približno enakih parametrih segmentacije. Dodatno sem ugotovila, da je skupna natančnost klasifikacije približno enaka pri vseh parametrih segmentacije, razen ko posežemo v prešibko segmentacijo. Na osnovi tega sklepam, da z večnivojsko segmentacijo ne izboljšamo kakovosti segmentacije in s tem klasifikacije.

Kar se tiče večnivojske klasifikacije same, naj zgolj omenim nekaj navedb v strokovni literaturi. Sama

tega nisem preverjala, saj tema presega okvire te disertacije. Nekateri avtorji pišejo, da enorazredni klasifikaciji ne gre zaupati (Mack et al., 2014). Da gre v primeru na pravilih osnovane klasifikacije za veliko ročnega dela in prilagajanja, sem opazila tudi sama na študijskem primeru. Vendar pa lahko v nekaterih člankih (Frazier in Page, 2000; Schneider et al., 2010) preberemo, da so metode za klasifikacijo pokrovnosti zgolj enega razreda napredovale in da hierarhičen način klasifikacije pokrovnosti razred po razred, pri čemer ločujemo en razred od vseh preostalih razredov, zmanjšuje vpliv spektralnih zmot med posameznimi razredi.

Uporabnost večnivojske klasifikacije bi bilo potrebno še preveriti, zagotovo pa je tudi v primeru večnivojske klasifikacije smiselno uporabiti sloj segmentacije, narejen enonivojsko.

10.4 Veččasovna segmentacija

Segmentacija je vezana na posnetek, ki ga segmentiramo. V primeru algoritma razvodij je odvisna od homogenosti vrednosti pikslov na posnetku. Ker se odbojne vrednosti pokrovnosti iz posnetka v posnetek spreminjajo (še posebej je to značilno za različne poljščine na njivah), se število, oblika in lokacija segmentov med posameznimi posnetki razlikuje. Pri enočasovni klasifikaciji to ne povzroča težav, saj tudi klasificiramo samo z vrednostmi enega posnetka. V primeru veččasovne klasifikacije pa na posamezen segment vežemo attribute več posnetkov. Zato je željeno, da so vrednosti pikslov v segmentu čim bolj homogene na vseh posnetkih različnih časov. Iščemo nekakšen presek segmentov skozi čas.


V prejšnjem poglavju sem ugotovila, da je najprimernejša osnovna enota, tako za enočasovno kot za veččasovno klasifikacijo, GERK (oz. poligon referenčnega sloja). Presenetljivo skoraj enako skupno natančnost (a nižjo konsistenco) dosem z osnovno enoto PIKSEL. Obe omenjeni osnovni enoti, GERK in PIKSEL, sta fiksni skozi čas in zato primerni za veččasovno klasifikacijo.

V primeru, ko želimo višjo konsistenco rezultatov (še posebej pri zelo visoki prostorski ločljivosti posnetkov), sloja GERK ali drugega referenčnega sloja pa nimamo, skušamo izvesti čim boljšo segmentacijo. Žal imajo segmenti, kot zgoraj zapisano, pri veččasovni klasifikaciji to slabo lastnost, da se spreminjajo skozi čas. Pri prijavi teme sem sklepala, da v primeru veččasovne klasifikacije ni dobro uporabiti segmentacije, narejene zgolj na enem posnetku, zato sem postavila hipotezo H2, ki pravi: »veččasovna objektno usmerjena klasifikacija zahteva veččasovno segmentacijo«. Pri preverjanju hipoteze primerjam kakovost veččasovne klasifikacije na enočasovno in veččasovno določenih segmentih. Za potrditev hipoteze morajo biti rezultati klasifikacije veččasovno določenih segmentov boljši od rezultatov klasifikacije enočasovno določenih segmentov.

Veččasovno segmentacijo sem izvajala na način večspektralne segmentacije, pri čemer sem združila posnetke različnih časov in s tem dobila več »spektrov«. Segmentacijo sem izvajala z algoritmom razvodij v programu ENVI. Pri izvajanju segmentacije na več posnetkih hkrati naletimo na novo

značilnost algoritma segmentacije, ki ni zanemarljiva, zato jo v nadaljevanju kratko na kratko opisujem. To je vpliv oblakov in maske oblakov na segmentacijo.


Na sliki 72 prikazujem manjše območje nemaskiranih vhodnih podob NDVI posnetkov RapidEye dveh različnih datumov. En posnetek vsebuje oblak, drugi ne.



Slika 72: Nemaskirana vhodna podoba NDVI posnetka RapidEye 15.6.2013 (a) in nemaskirana vhodna podoba NDVI posnetka RapidEye 19.5.2013 (b). Manjše študijsko območje.

Figure 72: Unmasked NDVI input image of RapidEye image 15.6.2013 (a) and unmasked NDVI input image of RapidEye image 19.5.2013 (b). Small study area.


Na sliki 73 prikazujem isto območje in ista posnetka kot na sliki 72, le da posnetka vsebujeta masko oblakov, dobljeno s programom ATCOR.



Slika 73: Maskirana vhodna podoba NDVI posnetka RapidEye 15.6.2013 (a) in maskirana vhodna podoba NDVI posnetka RapidEye 19.5.2013 (b). Manjše študijsko območje.

Figure 73: Masked NDVI input image of RapidEye image 15.6.2013 (a) and masked NDVI input image of RapidEye image 19.5.2013 (b). Small study area.


Na sliki 74 prikazujem segmentacijo na združenih nemaskiranih podobah iz slike 72 ter segmentacijo združenih maskiranih podob iz slike 73.



Slika 74: Segmentacija združenih nemaskiranih vhodnih podob NDVI posnetkov RapidEye 15.6.2013 in 19.5.2013 (a) in segmentacija združenih maskiranih vhodnih podob NDVI istih dveh posnetkov (b). Manjše študijsko območje. Vektorska sloja segmentov sta prikazana na lažnem barvnem prikazu združenih nemaskiranih posnetkov.

Figure 74: Segmentation of combined unmasked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (a) and segmentation of combined masked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (b). Small study area. Segmentation vector layers are shown on false colour image of two combined unmasked RapidEye input images.

Na sliki 75 prikazujem enako segmentacijo kot na sliki 74, le da na maskirani vhodni podobi z oblakom.




Slika 75: Segmentacija združenih nemaskiranih vhodnih podob NDVI posnetkov RapidEye 15.6.2013 in 19.5.2013 (a) in segmentacija združenih maskiranih vhodnih podob NDVI istih dveh posnetkov (b). Manjše študijsko območje. Vektorski sloj segmentov je prikazan na maskirani vhodni podobi NDVI posnetka RapidEye 15.6.2013.

Figure 75: Segmentation of combined unmasked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (a) and segmentation of combined masked NDVI input images of RapidEye images 15.6.2013 and 19.5.2013 (b). Small study area. Segmentation vector layers are shown on masked NDVI input image of RapidEye image 15.6.2013.

Opaziti je, da ima maska oblakov (oz. kakršnakoli druga maska) zelo velik vpliv na oblikovanje segmentov. Maska je v celoti v enem segmentu, zato v primeru, ko je na enem posnetku oblak, na drugih pa ne, na mestu oblaka segmentacije praktično ne izvedemo. Zato moramo veččasovno segmentacijo obvezno izvajati na nemaskiranih posnetkih. Kasnejšo klasifikacijo pa je priporočljivo izvesti na maskiranih posnetkih, saj »močna bela barva« oblaka zelo kvari rezultat klasifikacije.

Testiranje veččasovne segmentacije sem izvajala na posnetkih RapidEye šestih različnih datumov leta 2013 in na študijskem območju Murska Sobota. Segmentacijo sem v vseh primerih izvajala na vhodnih podobah RGBNir s parametri segmentacije 30_70 s Sobelovo metodo robov. V vseh primerih sem uporabila iste učne točke.


Na sliki 76 so prikazane enočasovne segmentacije, narejene na posnetkih treh različnih datumov. Razvidno je, da so segmenti pri različnih datumih različni.



Slika 76: Segmentacija kanalov RGBNir podob RapidEye datumov 19.5.2013 (a), 15.6.2013 (b) in 8.10.2013 (c) na pripadajočih RGB posnetkih.

Figure 76: Segmentation of RGBNir bands of RapidEye images captured on 19.5.2013 (a), 15.6.2013 (b) and 8.10.2013 (c) on corresponding true colour images.

Na sliki 77 so prikazane veččasovne segmentacije, narejene na različnih kombinacijah posnetkov različnih datumov. Opazimo lahko, da veččasovna segmentacija ne predstavlja zgolj preseka segmentov posameznih datumov, temveč nekako uteži pomembnost homogenosti posameznega posnetka. Tako ima lahko veččasovna segmentacija posnetkov šestih datumov celo manj segmentov kot segmentacija enega datuma.



Slika 77: Segmentacije narejene veččasovno na kanalih RGBNir in kombinacijah podob RapidEye datumov: 19.5.2013 in 29.7.2013 (a); 19.5.2013, 15.6.2013, 29.7.2013 in 8.10.2013 (b); 9.4.2013, 19.5.2013, 15.6.2013, 29.7.2013, 18.8.2013 in 8.10.2013 (c). Segmentacije so prikazane na posnetku RapidEye RGB 29.7.2013.

Figure 77: Segmentations obtained by multitemporal segmentation on spectral bands RGBNir and combinations of RapidEye images of dates: 19.5.2013 and 29.7.2013 (a); 19.5.2013, 15.6.2013, 29.7.2013 and 8.10.2013 (b); 9.4.2013, 19.5.2013, 15.6.2013, 29.7.2013, 18.8.2013 and 8.10.2013 (c). Segmentations are shown on true colour RapidEye images 29.7.2013.

Rezultati veččasovnih klasifikacij na dveh nesegmentiranih osnovnih enotah, različnih enočasovno določenih segmentih ter različnih veččasovno določenih segmentih so prikazani v preglednicah 56 (klasifikacija osnovnih razredov) in 57 (klasifikacija poljščin). Klasificirala sem na posnetkih RapidEye datumov od 9.4.2013 do 8.10.2013 in študijskem območju Murska Sobota.

Preglednica 56: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih razredov na posnetkih RapidEye datumov od 9.4.2013 do 8.10.2013, študijsko območje Murska Sobota. Klasifikacije na dveh nesegmentiranih osnovnih enotah, različnih enočasovno določenih segmentih ter različnih veččasovno določenih segmentih. Atributi klasifikacije mediana RGBNir, klasifikator ANN.

Table 56: F-score and overall accuracy (OA) of multitemporal classification of basic land cover classes on RapidEye images captured on dates from 9.4.2013 to 8.10.2013. Murska Sobota study area. Classifications on two nonsegmented mapping units, different single-date obtained segments and different multitemporally obtained segments. Classification attributes: median of RGBNir bands. Classifier: ANN.

Atribut\Razred	F-mera (%)					OA (%)
	njiva	trava	gozd	urbano	voda	
NESEGMENTIRANA OSNOVNA ENOTA						
PIKSEL	94,85	70,16	94,14	88,17	70,87	91,48
GERK	95,81	75,34	76,08	56,91	27,78	91,41
ENOČASOVNA SEGMENTACIJA						
segm_9-4	89,81	59,01	71,10	88,32	71,94	85,04
segm_19-5	91,13	62,59	83,22	89,53	26,45	86,45
segm_15-6	90,69	59,45	86,89	89,35	0,00	86,61
segm_29-7	90,33	59,02	83,99	88,54	42,08	85,88
segm_18-8	89,67	59,78	87,09	88,04	47,55	85,65
segm_8-10	89,93	63,03	86,02	89,59	66,58	86,38
VEČČASOVNA SEGMENTACIJA						
segm_9-4_29-7	91,59	62,32	74,30	88,74	80,84	86,52
segm_19-5_29-7	91,36	62,94	82,59	89,67	24,84	86,94
segm_19-5_29-7_8-10	90,77	63,50	70,65	86,71	29,50	85,04
segm_19-5_15-6_29-7_8-10	91,81	65,88	77,19	88,78	31,16	86,78
segm_19-5_15-6_29-7_18-8_8-10	91,65	63,74	79,89	88,40	20,61	86,50
segm_9-4_19-5_15-6_29-7_18-8_8-10	91,98	65,68	78,65	87,17	0,00	86,59

Preglednica 57: F-mera in skupna natančnost (OA) veččasovne klasifikacije osnovnih poljščin na posnetkih RapidEye od 9.4.2013 do 8.10.2013., študijsko območje Murska Sobota. Klasifikacije na dveh nesegmentiranih osnovnih enotah, različnih enočasovno določenih segmentih ter različnih veččasovno določenih segmentih. Atributi klasifikacije RGBNir, klasifikator ANN.

Table 57: F-score and overall accuracy (OA) of multitemporal classification of basic crop type classes on RapidEye images captured on dates from 9.4.2013 to 8.10.2013. Murska Sobota study area. Classifications on two nonsegmented mapping units, different single-date obtained segments and different multitemporally obtained segments. Classification attributes: median of RGBNir bands. Classifier: ANN.

Atribut	F-mera (%)						OA(%)
	koruza	pšenica	ječmen	buča	ogrščica	tritikalna	
NESEGMENTIRANA OSNOVNA ENOTA							
PIKSEL	89,15	85,26	68,45	57,47	71,12	4,45	82,36
GERK	91,26	85,94	76,25	62,83	72,64	0,00	83,83
ENOČASOVNA SEGMENTACIJA							
segm_9-4	69,59	67,31	47,89	15,04	38,75	0,00	61,26
segm_19-5	75,31	72,68	56,99	25,09	42,45	0,00	66,94
segm_15-6	71,57	69,61	60,62	0,00	50,92	0,00	65,43
segm_29-7	76,37	69,49	53,30	22,47	47,04	0,00	66,03
segm_18-8	73,08	64,97	52,79	36,44	34,40	1,53	61,70
segm_8-10	70,33	64,79	45,28	20,96	53,20	0,94	60,82
VEČČASOVNA SEGMENTACIJA							
segm_9-4_29-7	76,56	69,98	53,50	16,84	51,63	2,23	65,70
segm_19-5_29-7	76,60	69,57	56,33	23,90	46,48	0,00	66,25
segm_19-5_29-7_8-10	73,52	66,44	52,35	17,96	47,51	0,00	63,82
segm_19-5_15-6_29-7_8-10	76,42	69,18	58,24	20,22	47,13	0,00	66,79
segm_19-5_15-6_29-7_18-8_8-10	77,63	68,94	61,12	23,23	48,56	1,54	67,71
segm_9-4_19-5_15-6_29-7_18-8_8-10	76,81	69,83	61,57	0,00	47,37	4,82	67,38

Rezultati so sicer v skladu s predhodnimi ugotovitvami o vplivu segmentacije na kakovost klasifikacije, a še vedno presenetljivi. Skupna natančnost klasifikacije je namreč zelo podobna, ne glede na datum vhodnega posnetka. Še več, uporaba več posnetkov različnih časov v postopku segmentacije ne zagotavlja višje kakovosti klasifikacije. Pri osnovnih razredih ni bila klasifikacija prav nič boljša, pri osnovnih poljščinah pa le malenkost boljša, a le pri nekaterih kombinacijah posnetkov, zato vzorca nisem uspela razbrati.

Na osnovi rezultatov veččasovne segmentacije ter rezultatov predhodnih poglavij lahko zaključim, da veččasovna objektno usmerjena klasifikacija ne zahteva veččasovne segmentacije. Pri prostorski ločljivosti 10 m se je morda (odvisno od potreb uporabnika) segmentaciji najbolje izogniti ter kot osnovno enoto veččasovne klasifikacije uporabiti GERK, RABO oz. kakšen drug referenčni sloj ali pa enostavno klasifikacijo izvesti na pikslu.

11 PRIMERJAVA ENOČASOVNE IN VEČČASOVNE KLASIFIKACIJE

Zadnjo in ključno hipotezo doktorske disertacije, ki se glasi: »H4: veččasovna klasifikacija daje boljše rezultate kakor enočasovna klasifikacija«, preverjam na koncu, tik pred zaključnim poglavjem. Pri primerjavi rezultatov treh metod klasifikacije (enočasovne klasifikacije, kvazi veččasovne klasifikacije ter klasifikacije na osnovi časovnih vrst) namreč upoštevam vse ugotovitve, do katerih sem prišla v prejšnjih poglavjih. Pri klasifikacijah uporabim glede na dosedanje ugotovitve najučinkovitejšo osnovno enoto GERK, najučinkovitejše attribute (mediana vrednosti rdečega, zelenega, modrega⁹ in bližnje infrardečega kanala na posamezni osnovni enoti) ter najučinkovitejši klasifikator (ANN). Klasifikacije izvajam na študijskem območju Pomurje ter vedno na istih učnih točkah.

Ker je rezultat klasifikacije odvisen tudi od oblačnosti posnetkov ter od primernosti datumov posnetkov (kako se na določen datum določeni razredi ločijo med sabo), sem omenjene tri metode klasifikacije izvedla na posnetkih treh različnih senzorjev: RapidEye, SPOT5 Take5 in Sentinel-2. Posnetki imajo podobne lastnosti, vendar so bili posneti pri različnih datumih in z različnimi časovnimi razlikami med posameznimi posnetki v časovni vrsti. Pri veččasovnih klasifikacijah sem uporabila vse posnetke v posamezni časovni vrsti. Pri enočasovni klasifikaciji pa sem izbrala samo datum, ki se je pri primerjavi kakovosti enočasovne klasifikacije različnih datumov na posnetkih RapidEye (poglavje 8.1.4.1) izkazal za daleč najboljšega, tj. 29.7.2013. Pri posnetkih SPOT5 Take5 in Sentinel-2 sem uporabila datum, ki je (ne glede na leto) najbližje izbranemu datumu enočasovne klasifikacije na RapidEye in je v celoti neoblačen.

11.1 Osnovni razredi pokrovnosti

Najprej analiziram rezultate klasifikacij petih osnovnih razredov pokrovnosti (njiva, trava, gozd, urbano in voda) na posnetkih treh različnih senzorjev.

⁹ Pri posnetkih satelita SPOT5 je modri kanal izvzet, saj njegov senzor nima modrega kanala.

11.1.1 RapidEye

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih RapidEye so prikazani v preglednici 58.

Preglednica 58: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih RapidEye študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGBNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 29.7.2013, pri veččasovnih klasifikacijah pa naslednji posnetki RapidEye za leto 2013: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. in 26.10. 2013. V času računanja sta sešeta čas učenja in čas klasifikacije.

Table 58: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on RapidEye imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 29.7.2013 was used. In the case of multitemporal classifications the following RapidEye images for the year 2013 were used: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. and 26.10. 2013. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	njiva	trava	gozd	urbano	voda	povprečje
Metoda klasifikacije						
IZDELOVALČEVA NATANČNOST (%)						
enočasovna	91,28	61,45	98,40	75,97	72,56	79,93
kvazi veččasovna	95,81	84,91	65,81	88,35	18,35	70,65
na osnovi časovnih vrst	93,25	73,5	57,66	89,54	9,05	64,60
UPORABNIKOVA NATANČNOST (%)						
enočasovna	88,48	63,72	97,49	90,85	99,67	88,04
kvazi veččasovna	88,07	51,73	98,94	88,55	84,84	82,43
na osnovi časovnih vrst	88,98	54,11	97,77	89,09	86,73	83,34
F-MERA (%)						
enočasovna	89,86	62,56	97,94	82,75	83,98	83,42
kvazi veččasovna	91,78	64,29	79,04	88,45	30,17	70,75
na osnovi časovnih vrst	90,97	63,87	77,45	89,31	47,85	73,89
SKUPNA NATANČNOST (%)						
enočasovna	-	-	-	-	-	88,84
kvazi veččasovna	-	-	-	-	-	83,32
na osnovi časovnih vrst						83,22
ČAS RAČUNANJA (MIN)						
enočasovna	-	-	-	-	-	0,73
kvazi veččasovna	-	-	-	-	-	6,02
na osnovi časovnih vrst						4217

11.1.2 SPOT5 Take5

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih SPOT5 Take5 so prikazani v preglednici 59.

Preglednica 59: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih SPOT5 Take5 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 1.8.2015, pri veččasovnih klasifikacijah pa naslednji posnetki SPOT5 Take5 za leto 2015: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. in 10.9.2015. V času računanja sta sešeta čas učenja in čas klasifikacije.

Table 59: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on SPOT5 Take5 imagery of Pomurje study area. All classifications used attribute of median RGNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 1.8.2015 was used. In the case of multitemporal classifications the following SPOT5 Take5 images for the year 2015 were used: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. and 10.9.2015. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	njiva	trava	gozd	urbano	voda	povprečje
Metoda klasifikacije						
IZDELOVALČEVA NATANČNOST (%)						
enočasovna	56,24	81,45	92,99	22,66	85,81	67,83
kvazi veččasovna	93,35	90,72	97,20	96,51	90,28	93,61
na osnovi časovnih vrst	91,84	89,26	91,11	88,17	89,90	90,06
UPORABNIKOVA NATANČNOST (%)						
enočasovna	80,00	39,77	95,20	16,71	98,89	66,11
kvazi veččasovna	98,54	77,29	98,76	83,37	91,67	89,93
na osnovi časovnih vrst	94,31	76,36	99,45	78,10	90,04	87,65
F-MERA (%)						
enočasovna	66,05	53,45	94,08	19,24	91,89	64,94
kvazi veččasovna	95,87	83,46	97,97	89,46	90,97	91,55
na osnovi časovnih vrst	93,10	82,78	95,54	83,49	89,99	88,98
SKUPNA NATANČNOST (%)						
enočasovna	-	-	-	-	-	70,50
kvazi veččasovna	-	-	-	-	-	94,53
na osnovi časovnih vrst						91,67
ČAS RAČUNANJA (MIN)						
enočasovna	-	-	-	-	-	0,82
kvazi veččasovna	-	-	-	-	-	7,45
na osnovi časovnih vrst						2898

11.1.3 Sentinel-2

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih Sentinel-2 so prikazani v preglednici 60.

Preglednica 60: Različne ocene kakovosti klasifikacije osnovnih razredov, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih Sentinel-2 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGBNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 6.8.2016, pri veččasovnih klasifikacijah pa naslednji posnetki Sentinel-2 za leto 2016: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. in 3.9.2016. V času računanja sta seštet čas učenja in čas klasifikacije.

Table 60: Different classification quality evaluations of basic land cover classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on Sentinel-2 imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, Sentinel-2 image 6.8.2016 was used. In the case of multitemporal classifications the following Sentinel-2 images for the year 2016 were used: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. and 3.9.2016. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	njiva	trava	gozd	urbano	voda	povprečje
Metoda klasifikacije						
IZDELOVALČEVA NATANČNOST (%)						
enočasovna	91,97	10,15	97,46	89,30	60,13	69,80
kvazi veččasovna	92,50	82,31	90,99	95,14	60,24	84,24
na osnovi časovnih vrst	92,69	79,96	93,07	88,42	53,36	81,50
UPORABNIKOVA NATANČNOST (%)						
enočasovna	80,69	28,13	96,55	75,46	99,75	76,12
kvazi veččasovna	93,88	69,10	98,96	68,68	86,40	83,40
na osnovi časovnih vrst	92,79	67,94	95,21	74,5	74,4	80,97
F-MERA (%)						
enočasovna	85,96	14,92	97,00	81,79	75,03	70,94
kvazi veččasovna	93,18	75,13	94,81	79,78	70,99	82,78
na osnovi časovnih vrst	92,74	73,95	94,14	81,46	63,88	81,23
SKUPNA NATANČNOST (%)						
enočasovna	-	-	-	-	-	83,60
kvazi veččasovna	-	-	-	-	-	90,63
na osnovi časovnih vrst						89,66
ČAS RAČUNANJA (MIN)						
enočasovna	-	-	-	-	-	1,01
kvazi veččasovna	-	-	-	-	-	31,33
na osnovi časovnih vrst						8970

11.2 Osnovni tipi poljščin

Sledijo rezultati klasifikacij šestih osnovnih razredov poljščin (koruza, pšenica, ječmen, buča, ogrščica in tritikala) na posnetkih treh različnih senzorjev.

11.2.1 RapidEye

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih RapidEye so prikazani v preglednici 61.

Preglednica 61: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih RapidEye študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 29.7.2013, pri veččasovnih klasifikacijah pa naslednji posnetki RapidEye za leto 2013: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. in 26.10. 2013. V času računanja sta seštet čas učenja in čas klasifikacije.

Table 61: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on RapidEye imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 29.7.2013 was used. In the case of multitemporal classifications the following RapidEye images for the year 2013 were used: 9.4., 11.4., 18.5., 19.5., 10.6., 15.6., 2.7., 29.7., 14.9., 8.10. and 26.10. 2013. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	koruza	pšenica	ječmen	buča	ogrščica	tritikala	povprečje
Metoda klasifikacije							
IZDELOVALČEVA NATANČNOST (%)							
enočasovna	91,37	89,20	3,15	69,05	17,93	0,00	45,12
kvazi veččasovna	94,60	92,26	77,40	75,07	84,38	28,16	75,31
na osnovi časovnih vrst	67,29	62,44	33,81	63,06	61,19	21,99	51,63
UPORABNIKOVA NATANČNOST (%)							
enočasovna	86,21	61,22	43,36	62,32	29,96	NaN	47,18
kvazi veččasovna	95,11	86,21	80,32	70,56	85,14	73,74	81,85
na osnovi časovnih vrst	65,23	51,47	62,35	60,25	64,56	67,53	61,90
F-MERA (%)							
enočasovna	88,72	72,61	5,87	65,51	22,43	0,00	42,52
kvazi veččasovna	94,86	89,13	78,83	72,75	84,76	40,76	76,85
na osnovi časovnih vrst	66,72	56,93	47,79	61,97	62,88	44,76	56,84
SKUPNA NATANČNOST (%)							
enočasovna	-	-	-	-	-		70,74
kvazi veččasovna	-	-	-	-	-		88,21
na osnovi časovnih vrst							61,72
ČAS RAČUNANJA (MIN)							
enočasovna	-	-	-	-	-		0,28
kvazi veččasovna	-	-	-	-	-		2,73
na osnovi časovnih vrst							2641

11.2.2 SPOT5 Take5

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih SPOT5 Take5 so prikazani v preglednici 62.

Preglednica 62: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih SPOT5 Take5 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 1.8.2015, pri veččasovnih klasifikacijah pa naslednji posnetki SPOT5 Take5 za leto 2015: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. in 10.9.2015. V času računanja sta seštet čas učenja in čas klasifikacije.

Table 62: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on SPOT5 Take5 imagery of Pomurje study area. All classifications used attribute of median RGNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, RapidEye image 1.8.2015 was used. In the case of multitemporal classifications the following SPOT5 Take5 images for the year 2015 were used: 8.5., 13.5., 7.6., 17.6., 22.6., 2.7., 7.7., 12.7., 17.7., 22.7., 1.8., 6.8., 11.8., 26.8., 31.8. and 10.9.2015. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	koruza	pšenica	ječmen	buča	ogrščica	tritikala	povprečje
Metoda klasifikacije							
IZDELOVALČEVA NATANČNOST (%)							
enočasovna	94,05	82,77	22,47	37,03	0,00	0,00	39,39
kvazi veččasovna	94,77	86,23	77,37	88,74	78,02	25,62	75,13
na osnovi časovnih vrst	67,44	62,36	44,27	64,27	63,66	27,23	54,87
UPORABNIKOVA NATANČNOST (%)							
enočasovna	87,72	64,77	30,50	49,74	NaN	NaN	38,79
kvazi veččasovna	94,61	83,97	74,53	82,99	82,96	54,83	78,98
na osnovi časovnih vrst	67,22	58,75	41,58	53,67	78,24	59,85	59,89
F-MERA (%)							
enočasovna	90,77	72,67	25,88	42,45	0,00	0,00	38,63
kvazi veččasovna	94,69	85,08	75,92	85,77	80,41	34,93	76,13
na osnovi časovnih vrst	67,38	60,46	42,89	58,98	71,32	43,55	57,43
SKUPNA NATANČNOST (%)							
enočasovna	-	-	-	-	-	-	69,55
kvazi veččasovna	-	-	-	-	-	-	85,99
na osnovi časovnih vrst	-	-	-	-	-	-	63,66
ČAS RAČUNANJA (MIN)							
enočasovna	-	-	-	-	-	-	0,29
kvazi veččasovna	-	-	-	-	-	-	2,20
na osnovi časovnih vrst	-	-	-	-	-	-	2783

11.2.3 Sentinel-2

Rezultati klasifikacij osnovnih razredov pokrovnosti na posnetkih Sentinel-2 so prikazani v preglednici 63.

Preglednica 63: Različne ocene kakovosti klasifikacije osnovnih poljščin, klasificiranih s tremi metodami klasifikacije: enočasovno klasifikacijo, kvazi veččasovno klasifikacijo ter klasifikacijo na osnovi časovnih vrst. Vse klasifikacije so bile izvedene na posnetkih Sentinel-2 študijskega območja Pomurje. Pri vseh klasifikacijah je bil uporabljen atribut mediane RGNir vseh uporabljenih posnetkov, osnovna enota GERK in klasifikator ANN. Pri enočasovni klasifikaciji je bil uporabljen posnetek 6.8.2016, pri veččasovnih klasifikacijah pa naslednji posnetki Sentinel-2 za leto 2016: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. in 3.9.2016. V času računanja sta sešeta čas učenja in čas klasifikacije.

Table 63: Different classification quality evaluations of basic crop type classes, classified with three classification methods: single-date classification, quasy-multitemporal classification and time series based classification. All classifications were performed on Sentinel-2 imagery of Pomurje study area. All classifications used attribute of median RGBNir of all used images, mapping unit GERK and ANN classifier. In the case of single-date classification, Sentinel-2 image 6.8.2016 was used. In the case of multitemporal classifications the following Sentinel-2 images for the year 2016 were used: 3.4., 13.4., 23.4., 26.4., 3.5., 6.5., 13.5., 16.5., 23.5., 26.5., 5.6., 15.6., 22.6., 25.6., 2.7., 12.7., 15.7., 22.7., 1.8., 6.8., 14.8., 24.8., 31.8. and 3.9.2016. Processing time includes the sum of training time and classification time.

CENILKA KAKOVOSTI	koruza	pšenica	ječmen	buča	ogrščica	tritikala	povprečje
Metoda klasifikacije							
IZDELOVALČEVA NATANČNOST (%)							
enočasovna	95,95	88,99	3,01	79,49	35,96	0,00	50,57
kvazi veččasovna	96,42	88,92	78,52	88,63	85,16	56,42	82,35
na osnovi časovnih vrst	64,19	59,11	43,48	69,51	72,98	53,76	60,51
UPORABNIKOVA NATANČNOST (%)							
enočasovna	89,71	61,24	31,08	59,50	79,90	NaN	53,57
kvazi veččasovna	95,60	86,17	83,02	88,02	89,09	63,44	84,22
na osnovi časovnih vrst	62,37	58,78	51,27	69,59	74,54	68,07	64,10
F-MERA (%)							
enočasovna	92,73	72,55	5,50	68,06	49,60	0,00	48,07
kvazi veččasovna	96,01	87,52	80,71	88,33	87,08	59,72	83,23
na osnovi časovnih vrst	63,17	58,93	47,59	69,55	73,52	60,89	62,28
SKUPNA NATANČNOST (%)							
enočasovna	-	-	-	-	-	-	72,60
kvazi veččasovna	-	-	-	-	-	-	88,87
na osnovi časovnih vrst							62,31
ČAS RAČUNANJA (MIN)							
enočasovna	-	-	-	-	-	-	0,50
kvazi veččasovna	-	-	-	-	-	-	6,92
na osnovi časovnih vrst							5482

11.3 Primerjava rezultatov enočasovne in veččasovne klasifikacije

Veččasovna klasifikacija se je izkazala kot metoda klasifikacije, ki v splošnem, ne pa nujno, omogoča pridobitev kakovostnejšega rezultata klasifikacije kot enočasovna klasifikacija. Ker so bile klasifikacije v vsaki skupini (vsaka preglednica v tem poglavju) izvedene pod istimi pogoji, lahko izključim različne vplive na klasifikacijo, kot so: število in lokacija učnih točk, vrsta klasifikatorja in mnoge druge, v

vsebinsi naloge že omenjene vplive. Iz rezultatov razberem, da je ločljivost posameznih razredov odvisna od ločljivosti atributov posameznega razreda na vhodnem posnetku oz. vhodnih posnetkih. Tako so npr. osnovni razredi lahko med seboj relativno dobro ločljivi že v primeru uporabe zgolj enega vhodnega posnetka (z enočasovno klasifikacijo). Še več, če je en posnetek zelo dober, lahko uporaba več dodatnih posnetkov klasifikacijo celo poslabša. Tako je v primeru posnetka RapidEye 29.7.2013 klasifikacija osnovnih razredov boljša od veččasovnih klasifikacij. Vendar pa v primeru senzorjev SPOT5 Take5 in Sentinel-2 temu ni več tako, čeprav sta izbrana datuma posnetka za enočasovno klasifikacijo v istem »rastnem obdobju«. Pri tem je pomembno tudi povedati, da so rezultati enočasovne klasifikacije pri drugih testiranih datumih še bistveno slabši (primer preglednice v poglavju 8.1.4.1). Poleg tega kakovost enočasovne klasifikacije v primeru težje ločljivih razredov, kot so poljščine, veliko občutneje pade kakor kakovost veččasovne klasifikacije. Enočasovno klasifikacijo gre zato uporabiti zgolj v primeru, če imamo samo en posnetek.

Veččasovno klasifikacijo sem izvedla z dvema med seboj zelo različnima metodama: kvazi veččasovno klasifikacijo in klasifikacijo na osnovi časovnih vrst. Prva metoda je praktično enočasovna klasifikacija z atributi različnih časov. V drugem primeru gre za statistično metodo, ki primerja grafe spreminjanja posameznih atributov skozi čas med posameznimi razredi. Prva metoda je na področju daljinskega zaznavanja dobro uveljavljena in je prilagojena rastrom ter veliki količini pikslov. Druga metoda se je na področju daljinskega zaznavanja uveljavila šele s pojavom časovnih vrst satelitskih posnetkov in je bila prvotno namenjena obdelavi manjše količine podatkov. Ogromna razlika med tema veččasovnima klasifikacijama je v času računanja. Medtem ko se je kvazi veččasovna klasifikacija v najslabšem primeru izvajala dobrih 31 minut, se je klasifikacija na osnovi časovnih vrst v najboljšem primeru izvajala 2641 minut, kar je dobrih 44 ur oz. skoraj dva dni. Pri tem je zelo pomembno omeniti, da sem klasificirala zgolj 25 x 25 km veliko študijsko območje in uporabila precej veliko osnovno enoto. Ker je za klasifikacijo večkrat zeleno, da rezultate dobimo v realnem času, lahko brez slabe vesti zaključim, da je klasifikacija na osnovi časovnih vrst trenutno časovno preveč potratna za praktično uporabo. Poleg tega pri primerjavi kakovosti klasifikacije ugotovimo, da tudi na tem področju zaostaja za kvazi veččasovno klasifikacijo. Pri klasifikaciji osnovnih razredov razlika ni bistvena, pri poljščinah pa. Pred izboljšavami metod klasifikacij na osnovi časovnih vrst za potrebe daljinskega zaznavanja, do katerih bo v prihodnosti skoraj gotovo prišlo, je veliko bolj smiselno uporabiti kvazi veččasovno klasifikacijo.

V tem poglavju sem pri veččasovnih klasifikacijah uporabila vse posnetke, ki sem jih imela na voljo za posamezen senzor. Vendar pa, če primerjam rezultate enočasovne in veččasovne klasifikacije, ter rezultate klasifikacij iz prejšnjih poglavij (še posebej poglavje najznačilnejših atributov (8)), ugotovim, da veččasovna klasifikacija daje boljše rezultate kot enočasovna klasifikacija, pri čemer ni potrebno pretiravati s številom posnetkov. Nekaj kakovostnih posnetkov je več kot dovolj.

12 ZAKLJUČEK

V zaključnem poglavju disertacije najprej potrdim oz. ovržem postavljene hipoteze. Sledi navedba glavnih ugotovitev, ki predstavljajo odgovore na mnoga praktična vprašanja.

Hipotezo H1 – upoštevanje teksture v postopku segmentacije izboljša kakovost segmentacije in s tem končne klasifikacije – ovržem.

Pri postavitvi hipoteze H1 sem predpostavljala, da bi z uporabo ustreznega teksturnega filtra lahko območja z visoko variabilnostjo vrednosti označili kot en homogen objekt, ki bi ga posledično lahko segmentirali v en optimalen segment. Tega žal ni omogočal noben izmed možnih filtrov pojavljanja in sopojavljanja. Ker sem poleg tega pokazala, da prekomerna segmentacija ne kvari kakovosti klasifikacije in da optimalna segmentacija (segment v velikosti objekta) ne zagotavlja najboljše kakovosti klasifikacije, lahko zaključim, da v sam postopek segmentacije ni smiselno vpeljevati teksture. Še več, analize so pokazale, da lahko z njo kakovost klasifikacije celo poslabšamo.

Hipotezo H2 – veččasovna objektno usmerjena klasifikacija zahteva veččasovno segmentacijo – delno ovržem.

V primerih, ko se posnetki časovne vrste med seboj razlikujejo le zaradi sprememb rasti in letnih časov, veččasovna segmentacija ni potrebna. V primeru večjega števila posnetkov lahko nekateri sicer pomembni robovi enega posnetka postanejo nepomembni kar privede do prešibke segmentacije in slabše kakovosti klasifikacije. Veččasovna segmentacija pa je pomembna, kadar posnetki vključujejo oblake. Takrat bi lahko v primeru veččasovne segmentacije naredili nekakšen kompozit sloja segmentacije, brez nesegmentiranih območij pod oblaki. Da bi se izognili morebitni prešibki segmentaciji, je veččasovno segmentacijo predvidoma bolje nadomestiti s presekom enočasovnih segmentacij. Pri tem sicer obstaja možnost, da pridemo do prekomerne segmentacije, vendar, kot sem pokazala, le-ta ne vodi v slabšo kakovost klasifikacije.

Hipotezo H3 – večnivojska objektno usmerjena klasifikacija pokrovnosti daje boljše rezultate kakor enonivojska – ovržem.

V večnivojsko objektno usmerjeno klasifikacijo sta vključeni tako večnivojska segmentacija kot večnivojska klasifikacija. Že pri postavitvi hipoteze je bil poudarek na večnivojski segmentaciji, saj sem predvidevala, da bi bila segmentacija veliko učinkovitejša, če bi lahko njene vhodne podobe in parametre prilagodili vsakemu razredu posebej. V sklopu disertacije sem ugotovila, da je pri vseh razredih najboljša segmentacija pri približno enakih parametrih segmentacije. Dodatno sem ugotovila, da je skupna natančnost klasifikacije približno enaka pri vseh parametrih segmentacije, razen ko dosežemo prešibko segmentacijo. Tudi pri poskusu izvedbe večnivojske segmentacije je bilo očitno, da bo končna klasifikacija večnivojskega pristopa veliko slabša od enonivojskega, kjer vse razrede segmentiramo in klasificiramo naenkrat. Glede uporabnosti same večnivojske klasifikacije ne morem

dati preverjenih zaključkov. Zagotovo pa je tudi v primeru večnivojske klasifikacije smiselno uporabiti sloj segmentacije, narejen enonivojsko.

Hipotezo H4 – veččasovna klasifikacija daje boljše rezultate kakor enočasovna klasifikacija – delno potrdim.

Potrditev hipoteze je odvisna od vrste veččasovne klasifikacije. Kvazi veččasovna klasifikacija skoraj vedno daje boljše rezultate kakor enočasovna klasifikacija. Pomembnost veččasovnosti pri kvazi veččasovni klasifikaciji niha glede na ločljivost razredov na posnetku enega datuma in glede na spreminjanje lastnosti razredov skozi čas. Bolj kot so razredi na posameznem posnetku med seboj težko ločljivi in bolj kot se razredi spreminjajo skozi čas, pomembnejša je. Kvazi veččasovno klasifikacijo lahko izvedemo že s posnetki dveh različnih časov. Več posnetkov v časovni vrsti lahko pomeni boljšo klasifikacijo, vendar pa posnetkov zaradi podvajanja podatkov naj ne bo preveč. Po drugi strani to ne drži za klasifikacijo na osnovi časovnih vrst. Pri tej vrsti klasifikacije je (izhajajoč iz delovanja algoritma) število posnetkov v časovni vrsti izrednega pomena. Takšna veččasovna klasifikacija bi v primeru prenizkega števila posnetkov, posnetkov neustreznih datumov ali posnetkov neustrezne razporeditve datumov predvidoma dala slabše rezultate kakor ustrezna enočasovna klasifikacija. Tudi v našem primeru je bilo tako, čeprav so bile časovne vrste relativno goste.

V nalogi sem večino hipotez ovrgla. Hipoteze sem postavila glede na trditve v literaturi, zato je pomen naloge toliko večji, saj sem dokazala, da nekatere trditve in splošno uveljavljena prepričanja, ne držijo. Vsaka ovržena hipoteza prinaša nove zaključke in spoznanja, ki so v praksi zelo koristna. Poleg tega sem prve tri hipoteze vezala na isto predpostavko, in sicer, da kakovost segmentacije močno vpliva na kakovost klasifikacije. Takšno mnenje je namreč prevladovalo (in še prevladuje) v strokovni literaturi. Ugotovitev, da predpostavka za primere prekomerne segmentacije ne drži, je zato presenetljiva in pomembna.

Poleg spoznanj, vezanih na hipoteze, sem prišla še do nekaj drugih ugotovitev, ki jih navajam v nadaljevanju.

Z višanjem števila atributov se čas klasifikacije občutno daljša. Levji delež časa pripada postopku učenja. Poleg tega preveliko število atributov praviloma poslabša rezultat klasifikacije. Zato je za klasifikacijo pomembno izbrati čim manj atributov, ampak takšnih, ki kar najbolj zvišajo kakovost klasifikacije. Najpomembnejše so vrednosti osnovnih spektralnih kanalov v različnih časih. V disertaciji sem z njimi dobila boljše rezultate kot z daleč najbolj pogosto uporabljenim spektralnim atributom veččasovne klasifikacije – indeksom NDVI.

NDVI je zelo močno koreliran z veliko večino vegetacijskih indeksov. Uporaba dveh koreliranih indeksov pri klasifikaciji pomeni podvajanje, kar vodi v poslabšanje rezultatov. Zato je pri klasifikaciji smiselno uporabiti samo en vegetacijski indeks ali nekaj nekoreliranih indeksov. Omeniti je potrebno,

da je indeks NDVI izračunan iz dveh osnovnih spektralnih kanalov, kar prav tako v primeru njihove skupne uporabe pomeni podvajanje in s tem slabše rezultate.

Podvajanje lahko predstavljajo tudi posnetki različnih časov, ki se med seboj bistveno ne razlikujejo. V primeru kvazi veččasovne klasifikacije zato ni smiselno uporabiti zelo goste časovne vrste posnetkov.

Za preračun vrednosti posameznih pikslov na osnovno enoto kartiranja, večjo od enega piksla, je najprimerneje uporabiti statistični kazalnik povprečja ali mediane. V nekaterih primerih se bolje izkaže prva, v drugih druga, vendar med njima ni velikih razlik. Ni pa smiselno uporabljati obeh hkrati.

Teksturni atributi so kot samostojni vhodni podatki nezadostni oz. veliko slabši od spektralnih atributov. Kot dodatni atribut spektralnim atributom sicer v primerih, ko imajo razredi med seboj res veliko razliko v teksturi, sicer izboljšajo končno kakovost, ampak v zelo majhni meri. Tekstura je v primeru osnovnih enot, velikih zgolj nekaj pikslov, nesmiselna. Dodatno je potrebno imeti v mislih, da teksturni atributi običajno podvojijo količino vhodnih podatkov in s tem čas obdelave.

Osnovna enota veččasovne klasifikacije mora biti fiksna, na vseh posnetkih časovne vrste ista. Temu pogoju ustreza piksel (če so posnetki med seboj poravnani) in poljubne referenčne osnovne enote, ki pravilno zajemajo želene objekte klasifikacije, npr. GERK ali RABA. Enote, v katerih je na posnetku zajetih več razredov klasifikacije hkrati, niso sprejemljive. Poleg tega, da piksel in referenčni sloj zagotavljata fiksno skozi čas, omogočata tudi zelo dobre rezultate klasifikacije. Enote referenčnega sloja pričakovano omogočajo pridobitev najboljših rezultatov. Manj pričakovani so rezultati klasifikacije osnovne enote piksel. Skupna natančnost namreč bistveno ne zaostaja za referenčno enoto, od segmentov pa je nemalokrat celo boljša.

Veččasovna objektno usmerjena klasifikacija je način veččasovne klasifikacije, ki v praksi ni prav pogosto uporabljen in preučen. Osnovna enota takšne klasifikacije je segment, ki se od posnetka do posnetka lahko spreminja. Fiksno segmentov lahko dosežemo s segmentacijo zgolj enega izbranega posnetka. Lahko izvedemo tudi veččasovno segmentacijo, vendar s tem boljši rezultati niso zagotovljeni. Zelo lahko se zgodi, da z njo naredimo več škode kot koristi. V primeru večjih razlik med segmentacijami posameznih posnetkov se kot ustrezna kaže uporaba preseka segmentacij izbranih posnetkov. Ne glede na način pridobitve segmentov (enočasovno ali veččasovno), algoritma segmentacije, vhodne podobe in parametrov, je segment osnovna enota, ki prinaša slabšo natančnost klasifikacije od referenčnega sloja in prav nič boljšo od piksla (v primeru 10 m prostorske ločljivosti). Uporabiti jo je vendarle smiselno v primeru, ko želimo višjo konsistenco rezultatov klasifikacije in vektorski rezultat klasifikacije, ki ga bomo uporabili pri analizah GIS. Z večanjem velikosti segmentov tudi krajšamo čas računanja. Obvezno pa moramo paziti, da klasifikacije ne delamo na prešibki segmentaciji.

Iz primerjave rezultatov kvazi veččasovne klasifikacije in klasifikacije na osnovi časovnih vrst izhaja, da kvazi veččasovna klasifikacija prednjači glede na skupno natančnost klasifikacije in še posebej glede na čas računanja. Pri relativno veliki osnovni enoti (GERK) in ne prevelikem študijskem območju (625 km²) sem kvazi veččasovno metodo izvedla v pol ure, medtem ko sem klasifikacijo na osnovi časovnih vrst izvajala skoraj dva dni. Tako dolg čas obdelave je praktično nesprejemljiv. Metode osnovane na časovnih vrstah sicer še vedno vidim kot potencialno uspešne pri veččasovni klasifikaciji. Vendar do trenutka, dokler teh metod ne prilagodijo rastrom, veliki količini podatkov in drugim lastnostim pokrovnosti, priporočam uporabo kvazi veččasovne klasifikacije.

V disertaciji sem pokazala, da časovne vrste satelitskih posnetkov niso primerne zgolj za spremljanje stanja v določenih trenutkih in določanja sprememb, temveč so zelo uporabne tudi za klasifikacijo pokrovnosti. Pokazala sem, da lahko na osnovi enega posnetka lahko dobimo zelo dober rezultat klasifikacije, vendar je to v veliki meri odvisno od sreče. Veččasovna klasifikacija, po drugi strani, zagotavlja dober rezultat. Skoraj brez izjeme boljšega kot enočasovna klasifikacija. Z uporabo posnetkov različnih časov lahko velikokrat rešimo tudi težave z oblačnostjo posameznega posnetka in podobnostmi med razredi na posnetku določenega datuma.

Kaj pa je to dober rezultat? So rezultati, dobljeni v tej disertaciji, dovolj dobri za končnega uporabnika? Rezultati so dovolj dobri, ko ima uporabnik od njih vsaj kakšno korist. Lokacija osnovnih razredov pokrovnosti je pomemben podatek za MKO in za osveževanje sloja dejanske rabe (RABA). Z enočasovno klasifikacijo sem s posnetkom predvidoma najugodnejšega termina (konec julija, začetek avgusta) dobila skupno natančnost 89 % (RapidEye), 71 % (SPOT5 Take5) in 84 % (Sentinel-2). Z veččasovno klasifikacijo sem dobila skupno natančnost 83 % (RapidEye), 95 % (SPOT5 Take5) in 91 % (Sentinel-2). Pri tem so nekateri razredi klasificirani zelo dobro, okoli 95 % (njiva, gozd), drugi malo slabše. Z veččasovno klasifikacijo sem tako osnovne razrede pokrovnosti določila z okoli 90 % natančnostjo, kar je zelo dober rezultat. Morda ni dovolj dober, da bi samodejno klasifikacijo uporabljali kot osnovo za izdelavo sloja dejanske rabe (sloj je namreč z državnega vidika zelo pomemben in mora biti zanesljiv), vsekakor pa je rezultat dovolj dober, da bi vizualni ročni zajem rabe olajšal oz. interpretatorje vsaj usmerjal v morebitne popravke rabe in spremembe na prejšnja leta.

Kar se tiče klasifikacije osnovnih poljščin, je časovna komponenta bistveno izboljšala rezultat klasifikacije. Z enočasovno klasifikacijo sem s poletnim posnetkom dobila skupno natančnost 71 % (RapidEye), 70 % (SPOT5 Take5) in 73 % (Sentinel-2). Z veččasovno klasifikacijo sem dobila skupno natančnost 88 % (RapidEye), 86 % (SPOT5 Take5) in 89 % (Sentinel-2). Pri tem so bili določeni razredi klasificirani skoraj popolno, preko 95 % (koruza), natančnost klasifikacije drugih pa je bila od rahlo slabše, večina okoli 85 % (pšenica, buča, ...) do precej slabše, tudi zgolj 50 % (tritikala). Velja enako kot za sloj dejanske rabe. Sloj GERK tudi z veččasovno klasifikacijo ni določen dovolj dobro, da bi ga lahko na ARSKTRP uporabili kot zanesljiv vir dejanskih poljščin na gerkih. So pa rezultati kljub temu

zavidljivo dobri in vsekakor uporabni kot pomožni sloj pri kontroli poljščin. Na tem mestu velja omeniti, da lahko preverjamo zgolj eno ali nekaj poljščin (npr. na vseh gerkih, kjer naj bi bila koruza, iščemo tiste, kjer koruze dejansko ni). V takšnem primeru lahko z veččasovno klasifikacijo pridemo do končne natančnosti 99 % (rezultati testne analize VESOLJE-SI za ARSKTRP), kar brez dvoma nakazuje na uporabnost veččasovne klasifikacije.

Klasifikacija je zelo kompleksen postopek, odvisen od mnogih dejavnikov. Že Mailing (1989) je pisal, da so karte pokrovnosti namensko posploševanje realnosti in da vsi postopki pridobitve takšnih kart neizogibno vpeljujejo napake. Vendar pa izboljšava, nadgradnja vsakega od njih prinese boljše rezultate. Uvedba veččasovnosti jih je zagotovo.

13 POVZETEK

Klasifikacija pokrovnosti pomeni razdelitev predmetov na zemeljski površini v razrede pokrovnosti. Na osnovi teh nastanejo karte pokrovnosti, ki so zelo pomembne za številne vede o zemeljskem površju. Primeren vir za izdelavo takšnih kart so satelitski posnetki. Do nedavnega smo klasifikacijo izvajali enočasovno, na posameznih posnetkih. Danes je na voljo že mnogo brezplačno dostopnih časovnih vrst satelitskih posnetkov, tj. nizov posnetkov enakega snemalnega sistema, posnetih ob različnem času. Poleg spektralnih informacij o objektu na površju je razpoložljiva tudi informacija o časovnem spreminjanju spektra tega objekta. Slednja se je po predhodnih študijah izkazala za pomembno spremenljivko v postopku klasifikacije. Metode, ki omogočajo uporabo veččasovnih vrst, imenujemo metode veččasovne klasifikacije pokrovnosti.

Tematika veččasovne klasifikacije se je šele dodobra začela razvijati. Izkušenj in usmeritev za dobro prakso praktično ni, zato sem jih želela pridobiti v sklopu te disertacije. Njen glavni cilj je bil na osnovi spektralnih, teksturnih in časovnih lastnosti optičnih satelitskih posnetkov izvesti klasifikacije osnovnih razredov pokrovnosti in osnovnih poljščin, pri čemer sem uporabljala različne vhodne podobe, attribute, osnovne enote, posnetke različnih senzorjev ter tri metode klasifikacij: enočasovno, kvazi veččasovno ter klasifikacijo na osnovi časovnih vrst. Velik poudarek sem dala preučitvi postopkov segmentacije, saj so izkušnje o uporabnosti objektno usmerjene veččasovne klasifikacije v svetovnem merilu precej skromne. Na osnovi primerjave rezultatov omenjenih klasifikacij sem pridobila naslednje ugotovitve:

- prekomerna segmentacija ne kvari kakovosti klasifikacije, medtem ko jo prešibka kvari občutno;
- upoštevanje texture v postopku segmentacije ne izboljša kakovosti klasifikacije;
- v primeru veččasovne objektno usmerjene klasifikacije je bolj kot veččasovno segmentacijo smiselno uporabiti presek segmentacij posnetkov različnih časov. S tem lahko izboljšamo problematiko oblačnosti ter spreminjanja značilnih robov med posnetki;
- večnivojska objektno usmerjena klasifikacija pokrovnosti ne da boljših rezultatov od enonivojske;
- kvazi veččasovna klasifikacija skoraj vedno da boljše rezultate od enočasovne. Pomembnost veččasovnosti pri kvazi veččasovni klasifikaciji niha glede na ločljivost razredov na posnetku enega datuma in glede na spreminjanje lastnosti razredov skozi čas. Več posnetkov v časovni vrsti lahko pomeni boljšo klasifikacijo, vendar pa naj število posnetkov zaradi podvajanja podatkov ne bo preveliko;
- z večanjem števila atributov se čas klasifikacije občutno daljša. Poleg tega preveliko število atributov praviloma poslabša rezultat klasifikacije. Zato je za klasifikacijo pomembno izbrati čim manj atributov, ki pa naj bodo značilni. Najpomembnejše so vrednosti osnovnih spektralnih kanalov v različnih časih. V izvedenih primerih sem z njimi dobila boljše rezultate

kot z daleč najpogosteje uporabljenim spektralnim atributom veččasovne klasifikacije – indeksom NDVI;

- večina vegetacijskih indeksov je med seboj močno koreliranih. Uporaba dveh koreliranih indeksov pri klasifikaciji pomeni podvajanje, kar poslabša rezultate. Prav tako ni priporočljiva skupna uporaba spektralnih kanalov in iz njih izpeljanih indeksov;
- podvajanje lahko predstavljajo tudi posnetki različnih časov, ki se med seboj bistveno ne razlikujejo. V primeru kvazi veččasovne klasifikacije zato ni smiselno uporabiti zelo goste časovne vrste posnetkov;
- teksturni atributi kot samostojni vhodni podatki v primerjavi s spektralnimi atributi veliko manj doprinesejo h klasifikaciji. Kot dodatek spektralnim atributom ob večjih razlikah v teksturi sicer izboljšajo končno kakovost, vendar le v majhni meri. Tekstura je pri osnovnih enotah, velikih zgolj nekaj pikslov, nesmiselna. Poleg tega dodatni atributi daljšajo čas obdelave;
- ustrezne osnovne enote veččasovne klasifikacije so piksel in poljubne osnovne enote, ki pravilno zajemajo zelene objekte klasifikacije. Najboljšo skupno natančnost sicer dosežemo z osnovno enoto »en objekt je ena osnovna enota«, vendar piksel zanjo ne zaostaja bistveno. Ne glede na postopek pridobitve segmentov je segment osnovna enota, ki prinaša slabšo natančnost klasifikacije od referenčnega sloja in v našem primeru prav nič boljše od piksla. Uporabiti jo vendarle gre v primeru, ko želimo višjo konsistenco rezultatov klasifikacije in vektorski rezultat klasifikacije, ki ga bomo uporabili pri analizah GIS. Z večanjem velikosti segmentov tudi krajšamo čas računanja. Obvezno pa moramo paziti, da klasifikacije ne izvajamo s prešibko segmentacijo;
- s klasifikacijo na osnovi časovnih vrst dobimo slabšo natančnost klasifikacije kot z uporabo kvazi veččasovne klasifikacije, pri čemer je čas izvajanja izredno dolg in trenutno nesprejemljiv za praktično uporabo. Metode veččasovne klasifikacije na osnovi časovnih vrst so obetavne, a potrebne marsikatero prilagoditve.

V disertaciji sem pokazala, da časovne vrste satelitskih posnetkov niso primerne zgolj za spremljanje stanja v določenih trenutkih in določanja sprememb, temveč so zelo uporabne tudi za klasifikacijo pokrovnosti. Veččasovna klasifikacija skoraj brez izjeme zagotavlja boljši rezultat od enočasovne.

V primerih te disertacije so rezultati veččasovne klasifikacije osnovnih razredov in poljščin dovolj kakovostni, da jih lahko uporabniki, ki zahtevajo zelo visoko raven kakovosti (MKO, ARSKTRP) uporabijo vsaj kot dopolnilni sloj za lažjo in usmerjeno vizualno interpretacijo.

14 SUMMARY

Land cover classification is the division of objects on the ground surface into land cover classes. The result is land cover maps, which are of great importance for many earth surface sciences. Satellite imagery is a very suitable source for making such maps. Until recently, the classification was performed on a single-date basis, where individual image was used. Today, a large number of freely available satellite image time series is available, i.e. series of images of the same recording system captured at different times. In addition to the spectral information about the object on the surface, there is also information about changing of object's spectrum over time. The latter, after preliminary studies, appears to be an important variable in the classification process. Methods that allow the use of time series are called multitemporal land cover classification methods.

The topic of the multitemporal classification is at an early stage of development. Research literature resources are scarce. Therefore, the purpose of this dissertation was to gather and share the obtained experience, and provide guidance on good practice. Its main goal was to perform classification of the basic land cover classes and basic crops, on the basis of spectral, texture and time characteristics of optical satellite imagery. In the process, different input images, attributes, basic units, images of different sensors and three methods of classification were used: single-date, quasi-multitemporal and time series based classification. A great deal of emphasis was placed on the segmentation process, since the experience of the usefulness of object-based multitemporal classification on a global scale is very modest. Below are findings based on a comparison of the results of the above-mentioned classifications:

- Over-segmentation does not spoil the quality of the classification, while under-segmentation deteriorates it considerably.
- Consideration of the texture in the segmentation process does not improve the classification quality.
- In the case of a multitemporal object-based classification, it is better to use an intersection of individual image's segmentations of different times rather than multitemporal segmentation. This can improve the problem of cloudiness and the changing of the characteristic edges on images.
- The multi-level object-based land cover classification does not perform better results than a single-level one.
- The quasi-multitemporal classification almost always gives better results than a single-date classification. The importance of multitemporality in the quasi-multitemporal classification varies with the separability of classes on a single date image and in terms of changing of class characteristics over time. More images in time series can make a better classification, but the number of images due to duplication of data should not be too large.
- By increasing the number of attributes, the classification time is considerably longer. In

addition, too many attributes usually deteriorates the classification result. Therefore, it is important to select as few attributes as possible for the classification, which should be characteristic. The most important are the values of the basic spectral bands at different times. In performed cases, better results were achieved using spectral bands rather than with the most commonly used spectral attribute of the multitemporal classification - the NDVI index.

- Most vegetation indices are heavily correlated. The use of two correlated indices in classification means duplication, leading to a deterioration in the results. It is also not advisable to jointly use spectral bands and derived indices.
- Duplication can also occur in the case of images of different times, which do not differ significantly from each other. In the case of a quasi-multitime classification, it is not sensible to use a very dense image time series.
- Texture attributes as independent input data contribute much less to classification than spectral attributes. As additional attribute to the spectral attributes in cases of large texture differences, they improve the final quality, but to a very small extent. The texture is meaningless in the case of very small basic units. Furthermore, additional attributes extend the processing time.
- The appropriate basic units of the multitemporal classification are the pixel and any basic units that correctly include the selected objects of the classification. The best overall accuracy is achieved with the base unit "one object is one base unit", but the pixel does not lag behind it substantially. Regardless of the segmentation process, the segment is the base unit, which results in a worse classification accuracy than the reference layer, and in our case, no better than the pixel. It should nevertheless be used in the case when we want a higher consistency of the classification results and the vector classification result that will be used in GIS analyses. By increasing the size of the segments, we also reduce the computation time. However, we must be careful not to perform the classification with an under-segmentation.
- By using a time series based classification, we obtain a worse classification accuracy than using a quasi-multitemporal classification. Moreover, the execution time of a time series based classification is extremely long and is currently unacceptable for practical use. The methods of time series based multitemporal classification are promising, but many adjustments are needed.

This dissertation shows that image time series are not only suitable for monitoring the land cover state at certain moments and determining changes, but they are also very useful for the land cover classification. The multitemporal classification almost exclusively provides a better result than a single-date classification.

The obtained results of the multitemporal classification of basic classes and crops are sufficient in terms of quality to be used at least as an additional layer by users who require a very high level of quality, for easier and focused visual interpretation.

VIRI

Andrew, M. E., Wulder, M. A., Nelson, T. A. 2014. Potential contributions of remote sensing to ecosystem service assessments. *Progress in Physical Geography*. 38, 3: 328–353.

Agencija Republike Slovenije za okolje – ARSO. 2016. Kazalci okolja v Sloveniji, Padavine in temperatura.

http://kazalci.arso.gov.si/?data=indicator&ind_id=744 (Pridobljeno 23. 1. 2016.)

Aurdal, L., Huseby, R. B., Eikvil, L., Solberg, R., Vikhamar, D., Solberg, A. 2005. Use of hidden Markov models and phenology for multitemporal satellite image classification: applications to mountain vegetation classification. V: *IEEE Xplore Digital Library: proceedings of the International Workshop on the Analysis of Multi-Temporal Remote Sensing Images*, 2005 in Biloxi, MS, USA, May 16–18, 2005. IEEE, str: 220–224.

Baatz, M., Schape, A. 2000. Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. *Angewandte geographische Informationsverarbeitung*. 12: 12–23.

Baret, F., Andrieu B., Guyot G. 1988. A Simple Model for Leaf Optical Properties in Visible and Near-Infrared: Application to the Analysis of Spectral Shifts Determinism. V: *Lichtenthaler H. K. (ur.). Applications of Chlorophyll Fluorescence in Photosynthesis Research, Stress Physiology, Hydrobiology and Remote Sensing*. Springer, Dordrecht: 345–35.

Belgiu, M., Dragut, L. 2014. Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*. 96: 67–75.

Belward, A. S., Skoien, J. O. 2015. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of Photogrammetry and Remote Sensing*. 103: 115–128.

Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*. 65, 1: 2–16.

Blaschke, T., Burnett, C., Pekkarinen, A. 2004. Image Segmentation Methods for Object-based Analysis and Classification. V: *Jong S.M.D. (ur.), Meer F.D.V. (ur.). Remote Sensing Image Analysis: Including The Spatial Domain*. Remote Sensing and Digital Image Processing. Springer, Dordrecht. 5: 211–236.

Cetin, M., Kavzoglu, T., Musaoglu, N. 2004. Classification of Multi-Spectral, Multi-Temporal and Multi-Sensor images Using Principal Components Analysis and Artificial Neural Networks: Beykoz Case. V: *Proceedings of 20th Congress of the International Society of Photogrammetry and Remote Sensing*, Istanbul, 2004.

<http://www.isprs.org/proceedings/XXXV/congress/comm4/papers/480.pdf> (Pridobljeno 21. 2. 2016.)

Cheng, J., Bo, Y., Zhu, Y., Ji, X. 2014. A novel method for assessing the segmentation quality of high-spatial resolution remote-sensing images. *International Journal of Remote Sensing*. 35, 10: 3816–3839.

Chen, L., Ozsu, M. T., Oria, V. 2005. Robust and fast similarity search for moving object trajectories. V: *Proceedings of the 2005 ACM SIGMOD international conference on Management of data - SIGMOD' 05 in Baltimore, Maryland, June 14–16, 2005*: str. 491–502.

Chen, Q., Hu, G., Gu, F., Xiang, P. 2012. Learning optimal warping window size of DTW for time series classification. V: *IEEE Xplore Digital Library: proceedings of the 11th International Conference on*

Information Science, Signal Processing and their Applications (ISSPA), 2012 in Montreal, QC, Canada, July 2–5, 2012.

Chen, Z., Zuo, W., Hu, Q., Lin, L. 2015. Kernel sparse representation for time series classification. *Information Sciences*. 292: 15–26.

Clinton, N., Holt, A., Scarborough, J., Yan, L., Gong, P. 2010. Accuracy Assessment Measures for Object-based Image Segmentation Goodness. *Photogrammetric Engineering & Remote Sensing*. 76, 3: 289–299.

Coillie, F. M. B. V., Pires, P. L. V. M., Camp, N. A. F. V., Gautama, S. 2008. Quantitative segmentation evaluation for large scale mapping purposes. Springer-Verlag, str. 237–256.

Cousty, J. 2007. Discrete watersheds: theory and applications to cardiac image segmentation. Doktorska disertacija. Francija, Université de Marne la Vallée.

Crevier, D., Lepage, R. 1997. Knowledge-Based Image Understanding Systems: A Survey. *Computer Vision and Image Understanding*. 67, 2: 161–185.

Dey, V., Zhang, Y., Zhong, M. 2010. A review on image segmentation techniques with remote sensing perspective. V: IAPRS: proceedings of the ISPRS TC VII Symposium – 100 Years ISPRS, Vienna, Austria, July 5–7, 2010. IAPRS, XXXVIII.

Dežman Kete, V., Ipša, A., Mesner, N., Oven, K. 2008. Prepoznavanje kmetijskih kultur z daljinskim zaznavanjem. V: Perko, D. (ur.), Zorn, M. (ur.), Razpotnik Visković, N. (ur.) et al. *Geografski informacijski sistemi v Sloveniji 2007-2008*. Ljubljana, Založba ZRC, 2008. Str.: 247–257.

Dohare, D., Devi, V. S. 2011. Combination of similarity measures for time series classification using genetic algorithms. V: IEEE Xplore Digital Library: proceedings of the 2011 IEEE Congress on Evolutionary Computation (CEC) in New Orleans, LA, USA, June 5–8, 2011.

Dorren, L. K. A., Maier, B., Seijmonsbergen, A. C. 2003. Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management*. 183, 1: 31–46.

Dragut, L., Tiede, D., Levick, S. R. 2010. ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*. 24, 6: 859–871.

Drakos, N in Moore, R. 2016. Difference of Gaussian (DoG).
<http://fourier.eng.hmc.edu/e161/lectures/gradient/node9.html> (Pridobljeno: 1.3. 2016.)

ESA. 2016. Sentinel-2.
<https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2> (Pridobljeno: 12. 3. 2016.)

Exelis. 2015. Background Segmentation Algorithm.
<http://www.exelisvis.com/docs/BackgroundSegmentationAlgorithm.html> (Pridobljeno: 15. 11. 2015.)

Fisher, R., Perkins, S., Walker, A., Wolfart, E. 2016a. Roberts Cross Edge Detector.
<http://homepages.inf.ed.ac.uk/rbf/HIPR2/roberts.htm> (Pridobljeno: 11. 3. 2016.)

Fisher, R., Perkins, S., Walker, A., Wolfart, E. 2016b. Sobel Edge Detector.
<http://homepages.inf.ed.ac.uk/rbf/HIPR2/sobel.htm> (Pridobljeno: 11. 3. 2016.)

Fisher, R., Perkins, S., Walker, A., Wolfart, E. 2016c. Zero Crossing Detector.
<http://homepages.inf.ed.ac.uk/rbf/HIPR2/zeros.htm> (Pridobljeno: 11. 3. 2016.)

Frazier, P. S., Page, K. J. 2000. Water Body Detection and Delineation with Landsat TM Data. *Photogrammetric Engineering & Remote Sensing*. 66, 12: 1461–1467.

Gao, Y., Mas, J. F. 2008. A comparison of performance of pixel-based and object-based classifications over images with various spatial resolution. *Online Journal of Earth Science*. 2: 27–35.
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.409.6574&rep=rep1&type=pdf>
(Pridobljeno: 19. 8. 2012.)

Glanz, H., Carvalho, L., Sulla-Menashe, D., Friedl, M. A. 2014. A parametric model for classifying land cover and evaluating training data based on multi-temporal remote sensing data. *ISPRS Journal of Photogrammetry and Remote Sensing*. 97: 219–228.

Gomez, C., White, J. C., Wulder, M. A. 2016. Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*. 116: 55–72.

Gong, P., Howarth, P. J. 1990. An assessment of some factors influencing multispectral land-cover classification. *Photogrammetric Engineering & Remote Sensing*. 56, 5: 597–603.

Gorecki, T. 2014. Using derivatives in a longest common subsequence dissimilarity measure for time series classification. *Pattern Recognition Letters*. 45: 99–105.

Guo, D., Atluri, V., Adam, N. 2005. Texture-Based Remote-Sensing Image Segmentation. V: IEEE Xplore Digital Library: proceedings of the 2005 IEEE International Conference on Multimedia and Expo in Amsterdam, Netherlands, July 6, 2005.

Haralick, R., Shanmugan, K., Dinstein, I. 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 3, 6: 610–621.

Harris. 2016. Extract Segments Only.
<http://harrisgeospatial.com/docs/SegmentOnly.html> (Pridobljeno: 24. 3. 2016.)

Herold, M., Latham, J. S., Gregorio, A. D., Schmullius, C. C. 2006. Evolving standards in land cover characterization. *Journal of Land Use Science*. 1, 2–4: 157–168.

Harris Geospatial Solutions. 2016. Watershed.
<http://harrisgeospatial.com/docs/WATERSHED.html> (Pridobljeno: 24. 3. 2016.)

Hofmann, P. 2001. Detecting urban features from IKONOS data using an object-oriented approach. *RSPS Proceedings*, str. 79–91.

Hostert, P., Griffiths, P., van der Linden, S., Pflugmacher, D. 2015. Time Series Analyses in a New Era of Optical Satellite Data. V: Kuenzer C. (ur.), Dech S. (ur.), Wagner W. (ur.). *Remote Sensing Time Series. Remote Sensing and Digital Image Processing*, vol 22. Springer International Publishing. Str: 25–41.

Inglada, J., Arias, M., Tardy, B. et al. 2015. Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery. *Remote Sensing*. 7, 9: 12356–12379.

Jia, K., Liang, S., Wei, X. et al. 2014. Land Cover Classification of Landsat Data with Phenological Features Extracted from Time Series MODIS NDVI Data. *Remote Sensing*. 6, 11: 11518–11532.

Jinru, X., Baofeng, S. 2017. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, 1353691: 17 str.

Kanjir, U. 2009. Objektna klasifikacija rabe tal iz podatkov daljinskega zaznavanja. Diplomaska naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo (samozaložba U. Kanjir): 80 f.

Kim, M., Madden, M. 2006. Determination of optimal scale parameter for alliance-level forest classification of multispectral IKONOS images. *ISPRS Proceeding VI*.

Kim, M., Madden, M., Warner, T. A. 2009. Forest Type Mapping using Object-specific Texture Measures from Multispectral Ikonos Imagery. *Photogrammetric Engineering & Remote Sensing*. 75, 7: 819–829.

Kim, M., Warner, T. A., Madden, M., Atkinson, D. S. 2011. Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects. *International Journal of Remote Sensing*. 32, 10: 2825–2850.

Kira, K., Rendell, L. A. 1992. A Practical Approach to Feature Selection. V: Sleeman, D. H. (ur.), Edwards, P. (ur.). Ninth International Workshop on Machine Learning. Morgan Kaufmann: str. 249–256.

Kononenko, I. 1994. Estimating Attributes: Analysis and Extensions of RELIEF. V: Bergadano, F. (ur.), Raedt, L.D. (ur.). European Conference on Machine Learning. Springer: str. 171–182.

Lefebvre, A., Sannier, C., Corpetti, T. 2016. Monitoring Urban Areas with Sentinel-2A Data: Application to the Update of the Copernicus High Resolution Layer Imperviousness Degree. *Remote Sensing*. 8, 7: 606 str.

Lin, C., Wu, C., Tsogt, K. et al. 2015. Effects of atmospheric correction and pansharpening on LULC classification accuracy using WorldView-2 imagery. *Information Processing in Agriculture*. 2, 1: 25–36.

Liu, D., Xia, F. 2010. Assessing object-based classification: advantages and limitations. *Remote Sensing Letters*. 1, 4: 187–194.

Mack, B., Roscher, R., Waske, B. 2014. Can I Trust My One-Class Classification?. *Remote Sensing*. 6, 9: 8779–8802.

Mailing, D. H. 1989. Measurements from maps: principles and methods of cartometry. Oxford, Pergamon Press: 577 str.

Marpu, P. R., Neubert, M., Herold, H., Niemeyer, I. 2010. Enhanced evaluation of image segmentation results. *Journal of Spatial Science*. 55, 1: 55–68.

Mason, P. J., Manton, M., Harrison, D. E. et al. 2003. The Second Report on the Adequacy of the Global Observing Systems for Climate in Support of the UNFCCC. GCOS-82 (ES). WMO/TD št. 1176.

Masse, A., Ducrot, D., Marthon, P. 2011. Tools for multitemporal analysis and classification of multisource satellite imagery. V: IEEE Xplore Digital Library: proceedings of the 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images in Trento, Italy, July 12–14, 2011.

- Matsuyama, T. 1993. Expert Systems for Image Processing, Analysis, and Recognition: Declarative Knowledge Representation for Computer Vision. V: *Advances in Electronics and Electron Physics* Volume 86. Elsevier: str. 81–171.
- Maus, V., Camara, G., Appel, M., Pebesma, E. 2017. dtwSat: Time-Weighted Dynamic Time Warping for Satellite Image Time Series Analysis. *Journal of Statistical Software*. VV, II. http://pure.iiasa.ac.at/14513/1/applying_twdtw.pdf (Pridobljeno: 24. 11. 2017.)
- Maus, V., Camara, G., Cartaxo, R. et al. 2016. A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 9, 8: 3729–3739.
- Meinel, G., Neubert, M. 2004. A Comparison of Segmentation Programs for High Resolution Remote Sensing Data. *International Archives of Photogrammetry and Remote Sensing*. 35 B, 4: 1097–1105.
- Mesner, N., Oštir, K. 2014. Investigating the impact of spatial and spectral resolution of satellite images on segmentation quality. *Journal of Applied Remote Sensing*. 8, 1, 083696.
- Myint, S. W., Gober, P., Brazel, A. et al. 2011. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*. 115, 5: 1145–1161.
- Navulur, K. 2007. Multi-spectral image analysis using the object oriented paradigm. CRC Press, Taylor & Francis Group. *Remote Sensing Applications Series*: 165 str.
- Neubert, M., Herold, H., Meinel, G. 2006. Evaluation of remote sensing image segmentation quality - further results and concepts. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Salzburg. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.374.3495&rep=rep1&type=pdf> (Pridobljeno: 12. 6. 2016.)
- Neubert, M., Herold, H., Meinel, G. 2008. Assessing image segmentation quality - concepts, methods and application. Blaschke T. (ur.), Lang S. (ur.), Hay G.J. (ur.). *Object-Based Image Analysis. Lecture Notes in Geoinformation and Cartography*. Springer, Berlin, Heidelberg: str. 769–784.
- Oštir, K. 2006. Daljinsko zaznavanje. Ljubljana, Inštitut za antropološke in prostorske študije. Založba ZRC: 250 str.
- Oštir, K., Marsetič, A., Pehani, P. et al. 2014. Procesna veriga za samodejno obdelavo optičnih satelitskih posnetkov v skoraj realnem času. *Digitalni prostor*: str. 207–218.
- Pal, N. R., Pal, S. K. 1991. Entropy: a new definition and its applications. *IEEE Transactions on Systems, Man, and Cybernetics*. 21, 5: 1260–1270.
- Pehani, P., Čotar, K., Marsetič, A., Zaletelj, J., Oštir, K. 2016. Automatic Geometric Processing for Very High Resolution Optical Satellite Data Based on Vector Roads and Orthophotos. *Remote Sensing*. 8, 4: 343.
- Prekopcsak, Z., Lemire, D. 2012. Time series classification by class-specific Mahalanobis distance measures. *Advances in Data Analysis and Classification*. 6, 3: 185–200.
- Rakhman, A., Sun, G. Y., Catur, R. 2009. Building Artificial Neural Network Using WEKA Software. Information System Department, Sepuluh Nopember Institute of Technology at Surabaya, Indonesia. <https://theagroupofbi.files.wordpress.com/2009/11/building-ann-using-weka-group-a.docx>

(Pridobljeno: 5. 4. 2016.)

Reed, T. 1993. A Review of Recent Texture Segmentation and Feature Extraction Techniques. *Computer Vision and Image Understanding*, 57, 3: 359–372.

Robnik-Sikonja, M., Kononenko, I. 1997. An adaptation of Relief for attribute estimation in regression. *Morgan Kaufmann*: str. 296–304.

Roerdink, J. B. T. M., Meijster, A. 2000. The Watershed Transform: Definitions, Algorithms and Parallelization Strategies. *Fundam. Inf.* 41, 1–2: 187–228.

Rogan, J., Chen, D. 2004. Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*, 61, 4: 301–325.

Satellite Imaging Corporation. 2016a. RapidEye Satellite Sensor.
<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/rapideye/> (Pridobljeno: 14. 3. 2016.)

Satellite Imaging Corporation. 2016b. SPOT5 Satellite Sensor.
<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/spot-5/> (Pridobljeno: 14. 3. 2016.)

Satellite Imaging Corporation. 2016c. Sentinel-2 Satellite Sensor.
<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/> (Pridobljeno: 14. 3. 2016.)

Schiewe, J. 2002. Segmentation of high-resolution remotely sensed data-concepts, applications and problems. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 4: 358–363.

Schneider, A., Friedl, M. A., Potere, D. 2010. Mapping global urban areas using MODIS 500-M data: new methods and datasets based on 'Urban Ecoregions'. *Remote Sens. Environ.* 114: 1733–1746.

Schneider, W., Eckstein, W., Steger, C. T. 1997. Real-time visualization of interactive parameter changes in image processing systems. V: Grinstein, G. G. (ur.), Erbacher, R.F. (ur.). *Proceeding of Visual Data Exploration and Analysis IV conference*. SPIE Proceedings Volume 3017.

Schouten, T. E., Gebbinck, M. S. K., Schoenmakers, R. P., Wilkinson, G. G. 1994. Finding thresholds for image segmentation. V: Desachy, J. (ur.). *Image and Signal Processing for Remote Sensing*. SPIE Proceedings Volume 2315.

Shankar, B. U. 2007. Novel Classification and Segmentation Techniques with Application to Remotely Sensed Images. V: Peters J.F. (ur.), Skowron A. (ur.), Marek V.W. (ur.), et al. (ur.). *Transactions on Rough Sets VII. Lecture Notes in Computer Science*, vol 4400. Springer, Berlin, Heidelberg, str: 295–380.

Simonetti, E., Simonetti, D., Preatoni, D. 2014. Phenology-based land cover classification using Landsat 8 time series. Technical Report by the Joint Research Centre of the European Commission. Luxembourg, Publications Office of the European Union.
<http://publications.jrc.ec.europa.eu/repository/bitstream/JRC91912/lb-na-26841-en-n%20.pdf>
(Pridobljeno: 2. 4. 2016.)

Singh, N., Glenn, N. F. 2009. Multitemporal spectral analysis for cheatgrass (*Bromus tectorum*) classification. *International Journal of Remote Sensing*, 30, 13: 3441–3462.

Smith, G. M., Morton, R. D. 2010. Real World Objects in GEOBIA through the Exploitation of Existing Digital Cartography and Image Segmentation. *Photogrammetric Engineering & Remote Sensing*. 76, 2: 163–171.

Smits, P. C., Dellepiane, S. G., Schowengerdt, R. A. 1999. Quality assessment of image classification algorithms for land-cover mapping: A review and a proposal for a cost-based approach. *International Journal of Remote Sensing*. 20, 8: 1461–1486.

Song, C., Woodcock, C. E., Seto, K.C. et al., 2001. Classification and Change Detection Using Landsat TM Data. *Remote Sensing of Environment*. 75, 2: 230–244.

Švab Lenarčič, A., Đurić, N., Čotar, K., Ritlop, K., Oštir, K. 2016. Can segmentation evaluation metric be used as an indicator of land cover classification accuracy?. *Journal of Applied Remote Sensing*. 10, 4, 045010.

Švab Lenarčič, A., Mesner, N., Oštir, K. 2015. Pregled algoritmov in programske opreme za segmentacijo optičnih daljinsko zaznanih posnetkov. *Geodetski vestnik*. 59, 4: 709–722.

Švab Lenarčič, A., Ritlop, K., Đurić, N., Čotar, K., Oštir, K. 2015. Impact of spatial resolution on correlation between segmentation evaluation metrics and forest classification accuracy. V: Bruzzone, L. (ur.). *Image and Signal Processing for Remote Sensing XXI, SPIE Proceeding Volume 9643*.

Townshend, J., Justice, C., Li, W., Gurney, C., McManus, J. 1991. Global land cover classification by remote sensing: present capabilities and future possibilities. *Remote Sensing of Environment*. 35, 2–3: 243–255.

Tutorialspoint. 2016. Prewitt Operator.

https://www.tutorialspoint.com/dip/prewitt_operator.htm (Pridobljeno: 14. 3. 2016.)

Van der Linden, S. 2007. Classifying segmented hyperspectral data from a heterogeneous urban environment using support vector machines. *Journal of Applied Remote Sensing*. 1, 1, 013543.

Vandevenne, L. 2016. Lode's Computer Graphics Tutorial.

<http://lodev.org/cgtutor/filtering.html#Emboss> (Pridobljeno: 14. 3. 2016.)

Veljanovski, T., Kanjir, U., Oštir, K. 2011. Objektno usmerjena analiza podatkov daljinskega zaznavanja. *Geodetski vestnik*. 55, 4: 665–688.

Vincent, L., Soille, P. 1991. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 13, 6: 583–598.

Vlachos, M., Hadjieleftheriou, M., Gunopulos, D., Keogh, E. 2003. Indexing multi-dimensional time-series with support for multiple distance measures. V: *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD'03 in Washington, D.C., Aug 24–27, 2003*. ACM Press: str. 216–225.

Widner, U. 2008. Contribution to the assessment of segmentation quality for remote sensing applications. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XXXVII, B7: 479–484.

Witharana, C., Civco, D. L., Meyer, T. H. 2014. Evaluation of data fusion and image segmentation in earth observation based rapid mapping workflows. *ISPRS Journal of Photogrammetry and Remote Sensing*. 87: 1–18.

Xiao, P., Feng, X., An, R., Zhao, S. 2010. Segmentation of multispectral high-resolution satellite imagery using log Gabor filters. *International Journal of Remote Sensing*. 31, 6: 1427–1439.

Yin, R., Shi, R., Gao, W. 2013. Automatic selection of optimal segmentation scales for high-resolution remote sensing images. V: *Proceedings of SPIE 8869, Remote Sensing and Modeling of Ecosystems for Sustainability X*, 88691A.

Zhang, H., Fritts, J. E., Goldman, S. A. 2008. Image segmentation evaluation: A survey of unsupervised methods. *Computer Vision and Image Understanding*. 110, 2: 260–280.

Zhang, L., Li, X., Yuan, Q., Liu, Y. 2014. Object-based approach to national land cover mapping using HJ satellite imagery. *Journal of Applied Remote Sensing*. 8, 1, 083686.

Zhang, Y. J. 1996. A survey on evaluation methods for image segmentation. *Pattern Recognition*. 29, 8: 1335–1346.

Zhang, Y., Maxwell, T. 2006. A trained segmentation technique for optimization of object-oriented classification. V: *Proceedings of ISPRS commission VII Mid-term Symposium-Remote Sensing from Pixels to Processes*, Enschede, the Netherland, 2006.

Zhang, Y., Maxwell, T., Tong, H., Dey, V. 2010. Development of a supervised software tool for automated determination of optimal segmentation parameters for eCognition. V: Wagner, W. (ur.), Székely, B. (ur.). *Proceedings of ISPRS TC VII Symposium - 100 Years ISPRS*, Vienna, Austria, July 5–7, 2010. IAPRS. XXXVIII, 7B.

Žust, A. 2015. Fenologija v Sloveniji. Priročnik za fenološka opazovanja. Ministrstvo za okolje in prostor, Agencija RS za okolje, Slovenija.
<http://meteo.arso.gov.si/uploads/probase/www/agromet/product/document/sl/Brosura0515.pdf>
(Pridobljeno: 5. 4. 2016.)

Patent:

Xiaoying, J. 2009. Segmentation-based image processing system. Patent: US20090123070 A1, 2009-05-14. Združene države. Urad Združenih držav za patente in blagovne znamke. Google Patents.

Pravilnik:

Pravilnik o evidenci dejanske rabe kmetijskih in gozdnih zemljišč. Uradni list RS, št. 122/08.