

Univerza
v Ljubljani

Fakulteta
za gradbeništvo
in geodezijo



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

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

To je izvirna različica zaključnega dela.

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

Mesner, N., 2016. Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk. Magistrsko delo. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. (mentor Oštir, K.): 119 str.

Datum arhiviranja: 27-05-2016

University
of Ljubljana

Faculty of
Civil and Geodetic
Engineering



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

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

This is original version of final thesis.

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

Mesner, N., 2016. Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk. M.Sc. Thesis. Ljubljana, University of Ljubljana, Faculty of civil and geodetic engineering. (supervisor Oštir, K.): 119 pp.

Archiving Date: 27-05-2016

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*

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



**PODIPLOMSKI ŠTUDIJSKI
PROGRAM GEODEZIJA**

Kandidatka:

NIKA MESNER

**ANALIZA MOŽNOSTI UPORABE SAMODEJNE
KLASIFIKACIJE PODOBE ZA VZDRŽEVANJE
PROSTORSKIH PODATKOVNIH ZBIRK**

Magistrsko delo št.: 53/GE

**ANALYSIS OF THE POSSIBILITY OF USING
AUTOMATIC IMAGE CLASSIFICATION FOR THE
MAINTENANCE OF SPATIAL DATABASES**

Graduation – Master Thesis No.: 53/GE

Mentor:

izr. prof. dr. Krištof Oštir

Ljubljana, 19. 05. 2016

IZJAVE

Podpisana Nika Mesner izjavljam, da sem avtorica magistrskega dela z naslovom »Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk«.

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

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

Ljubljana, 19. 5. 2016

Nika Mesner

STRAN ZA POPRAVKE, ERRATA**Stran z napako****Vrstica z napako****Namesto****Naj bo**

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:	528.8:659.2:91(043.3)
Avtor:	Nika Mesner, univ. dipl. inž. geod.
Mentor:	izr. prof. dr. Krištof Oštir
Naslov:	Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk
Tip dokumenta:	magistrsko delo
Obseg in oprema:	119 str., 35 pregl., 30 sl.
Ključne besede:	objektno usmerjena analiza, segmentacija, vzdrževanje prostorskih podatkov, pozidanost tal, iskanje sprememb

Izveček

Vzdrževanje prostorskih podatkov s fotointerpretacijo je časovno in kadrovsko ter zato tudi finančno zelo zahtevno. Težnje upravljavcev podatkov po avtomatizaciji postopka so zelo velike. Kljub številnim raziskavam na tem področju se samodejne metode vzdrževanja v praksi redko uporabljajo.

V magistrski nalogi sem preučila možnosti uporabe objektno usmerjene analize za določitev pozidanih površin na podlagi podatkov daljinskega zaznavanja. Izvedena je analiza vpliva prostorske, spektralne in časovne ločljivosti ter filtriranja in transformacije podobe na kakovost obeh faz objektno usmerjene analize, segmentacije in objektno klasifikacije. Na podlagi rezultatov analize je predlagana optimalna izbira ločljivosti podatkov in predobdelave posnetka za razpoznavo pozidanih površin. Podan je pregled podatkovnih zbirk v Sloveniji, v katerih se vodijo podatki o stavbah, topografiji, pokrovnosti tal in rabi prostora. Ocenjena je tudi možnost uvedbe samodejnih postopkov v proces vzdrževanja. Na testnem območju so na podlagi ortofota in lidarskih podatkov določeni obrisi stavb in druge pozidane površine. Na podlagi enotnega sloja obrisov stavb so identificirane spremembe glede na evidentirano stanje v katastru stavb in dejanski rabi kmetijskih in gozdnih zemljišč z visoko stopnjo popolnosti (več kot 80 %). Bistvena prednost uvedbe samodejnih postopkov v proces vzdrževanja prostorskih podatkov je, da s samodejno identificiranimi spremembami usmerimo operaterja na zajem podatkov le na območja, kjer so spremembe.

BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC:	528.8:659.2:91(043.3)
Author:	Nika Mesner, B. Sc. in Geodesy
Supervisor:	Assoc. Prof. Krištof Oštir, Ph.D.
Title:	Analysis of the possibility of using automatic image classification for the maintenance of spatial databases
Document type:	M. SC. Thesis
Notes:	119 p., 35 tab., 30 fig.
Keywords:	object based image analysis, segmentation, spatial data maintenance, built-up area, change detection

Maintenance of spatial data with photointerpretation is very demanding in terms of time and personnel, therefore tendencies of data owners for the automation of this process are very high. Despite extensive research on automatic extraction of spatial data, these methods are still not in practical use.

In the thesis, I examined the possibility of using object-based image analysis for extraction of the built-up areas with remote sensing data. An analysis of the impact of spatial, spectral and temporal resolution, image filtering and transformation on the quality of object-based image analysis, has been carried out. Based on the results of the analysis the optimal resolution and image pre-processing has been proposed. An overview of buildings, topography, land cover and land use spatial databases in Slovenia is given. The possibility of introducing automated processes in the maintenance process of specific spatial data has been assessed. Object based image analysis has been used for extraction of buildings contours and other built-up areas. This single data layer of buildings and other built-up areas is used for change detection in comparison to registered data in different databases. Completeness of detected changes is very high (more than 80%). The major advantage of proposed automated change detection in the spatial data maintenance process is that the automatically identified changes direct the operator to capture only data on the areas where change exists and so significantly reduces the amount of work.

ZAHVALA

Na tem mestu bi se zahvalila vsem, ki ste kakorkoli pomagali pri izdelavi te naloge. Posebej bi se zahvalila mentorju, doc. dr. Krištofu Oštirju, za podporo na celotni poti, Tatjani Veljanovski za piljenje naloge, ZRC SAZU za uporabo podatkov ter Geodetskemu inštitutu Slovenije za uporabo programske opreme. Hvala tudi večjim in manjšim ramenom, ki mi vedno stojijo ob strani in so moj neizčrpen vir energije.

KAZALO VSEBINE

1	UVOD	1
1.1	Ozadje problema	1
1.2	Cilji in hipoteza.....	2
1.3	Metoda dela	4
1.4	Struktura naloge	4
2	DALJINSKO ZAZNANI PODATKI	6
2.1	Vrste daljinsko zaznanih podatkov	6
2.1.1	Optični posnetki	6
2.1.2	Radarski posnetki	7
2.1.3	Lidarski podatki.....	7
2.2	Ločljivost podatkov	8
2.2.1	Prostorska ločljivost	8
2.2.2	Spektralna ločljivost	9
2.2.3	Radiometrična ločljivost	9
2.2.4	Časovna ločljivost	9
3	OBDELAVA POSNETKOV	10
3.1	Filtriranje.....	10
3.1.1	Filter povprečenja	11
3.1.2	Filter mediana	11
3.1.3	Gaussov filter.....	12
3.2	Transformacije posnetkov	13
3.2.1	Razmerja med kanali	14
3.2.2	Analiza osnovnih komponent	15
3.2.3	Dekorelacijski razteg.....	16
4	METODE INTERPRETACIJE DALJINSKO ZAZNANIH PODATKOV.....	17
4.1	Pikselska klasifikacija.....	17
4.2	Prehod na objektno usmerjeno analizo	17
4.3	Primerjava pikselske in objektno usmerjene analize	18
5	OBJEKTNO USMERJENA ANALIZA	20
5.1	Pristopi objektno usmerjene analize.....	20
5.1.1	Eno-nivojska segmentacija in klasifikacija.....	20
5.1.2	Iterativna eno-nivojska segmentacija in klasifikacija.....	20
5.1.3	Večnivojska segmentacija in klasifikacija	21
5.2	Segmentacija	22
5.2.1	Algoritmi segmentacije.....	24
5.2.2	Lastnosti segmentov	27
5.2.3	Ocena kakovosti segmentacije	28
5.3	Objektna klasifikacija	33
5.3.1	Ocena kakovosti objektno usmerjene analize	33
5.4	Pregled metodologije uporabe objektno usmerjene analize na področju urbane rabe prostora.....	36
6	ANALIZA VPLIVOV NA OBJEKTNO USMERJENO ANALIZO.....	38
6.1	Pregled literature	38
6.2	Študijsko območje in vhodni podatki	38
6.3	Metodologija	41
6.3.1	Analiza vplivov na segmentacijo	41
6.3.2	Analiza vplivov na klasifikacijo	42
6.4	Rezultati.....	44
6.4.1	Vplivi na segmentacijo	44
6.4.2	Vplivi na klasifikacijo	55
6.5	Povzetek rezultatov	62
6.5.1	Analiza vplivov na segmentacijo	62

6.5.2	Analiza vplivov na klasifikacijo	64
7	UPORABA SAMODEJNE KLASIFIKACIJE V PROCESU VZDRŽEVANJA PROSTORSKIH PODATKOV	67
7.1	Kataster stavb.....	67
7.1.1	Vzdrževanje.....	68
7.1.2	Izkušnje z uporabo samodejnih postopkov	69
7.1.3	Pregled uporabe samodejne interpretacije za vzdrževanje podatko o stavbah 71	
7.2	Dejanska raba prostora in pokrovnost tal.....	72
7.2.1	Dejanska raba prostora	72
7.2.2	Pokrovnost tal.....	73
7.2.3	Vzdrževanje.....	74
7.2.4	Izkušnje z uporabo samodejnih postopkov	75
7.2.5	Izkušnje v Sloveniji	76
7.2.6	Ocena možnosti uporabe samodejne interpretacije v praksi	77
7.3	Topografski podatki	77
7.3.1	Vzdrževanje.....	80
7.3.2	Izkušnje z uporabo samodejnih postopkov	82
7.3.3	Izkušnje v Sloveniji	82
7.3.4	Ocena možnosti uporabe samodejne interpretacije v praksi	84
7.4	Primer uporabe samodejne interpretacije za vzdrževanje podatkov.....	84
7.4.1	Študijsko območje in testni podatki	85
7.4.2	Metodologija	86
7.4.3	Rezultati	93
7.5	Povzetek.....	99
8	ZAKLJUČEK.....	103
9	POVZETEK	107
10	SUMMARY.....	109
11	VIRI.....	111

KAZALO PREGLEDNIC

Preglednica 1: Pregled najpogostejših lastnosti segmentov, ki se uporabljajo za klasifikacijo segmentov.	27
Preglednica 2: Uteži in optimalne vrednosti za izračun skupne ocene kakovosti segmentacije obrisov streh (Coillie in sod., 2010).	32
Preglednica 3: Klasifikacijska matrika napak.	34
Preglednica 4: Primeri uporabe večspektralnih kanalov satelitskega senzorja WorldView-2 (DigitalGlobe, 2009).	39
Preglednica 5: Objektni razredi na osnovni in podrobni ravni.	42
Preglednica 6: Analiza rezultatov segmentacije eno-kanalne podobe.	45
Preglednica 7: Analiza rezultatov segmentacije dvo-kanalne podobe.	46
Preglednica 8: Analiza rezultatov segmentacije tri-kanalne podobe.	47
Preglednica 9: Analiza rezultatov segmentacije štiri-kanalne podobe.	47
Preglednica 10: Analiza rezultatov segmentacije pet-kanalne podobe.	48
Preglednica 11: Analiza rezultatov segmentacije šest-kanalne podobe.	48
Preglednica 12: Analiza rezultatov segmentacije sedem-kanalne podobe.	49
Preglednica 13: Analiza vpliva števila spektralnih kanalov na kakovost segmentacije.	50
Preglednica 14: Analiza vpliva prostorske ločljivosti podobe na rezultate segmentacije.	51
Preglednica 15: Analiza vpliva filtriranja podobe na kakovost segmentacije.	53
Preglednica 16: Analiza vpliva transformacije podobe na rezultate segmentacije.	54
Preglednica 17: Analiza rezultatov klasifikacije eno-kanalne podobe.	55
Preglednica 18: Analiza rezultatov klasifikacije dvo-kanalne podobe.	55
Preglednica 19: Analiza rezultatov klasifikacije tri-kanalne podobe.	56
Preglednica 20: Analiza rezultatov klasifikacije štiri-kanalne podobe.	56
Preglednica 21: Analiza rezultatov klasifikacije pet-kanalne podobe.	57
Preglednica 22: Analiza rezultatov klasifikacije šest-kanalne podobe.	57
Preglednica 23: Analiza rezultatov klasifikacije sedem-kanalne podobe.	57
Preglednica 24: Analiza vpliva števila spektralnih kanalov na kakovost klasifikacije.	58
Preglednica 25: Analiza vpliva prostorske ločljivosti na kakovost klasifikacije.	59
Preglednica 26: Analiza vpliva filtriranja podobe na kakovost klasifikacije.	61
Preglednica 27: Analiza vpliva transformacije podobe na kakovost klasifikacije.	61
Preglednica 28: Pregled rezultatov analize vpliva prostorske in spektralne ločljivosti ter transformacij in filtriranja podobe na kakovost segmentacije. Cenilke posameznih podob, ki so v primerjavi z izvirno podobo višje (rdeče polnilo), nižje (zeleno polnilo) in enake (brez polnila). Višje vrednosti cenilk se nanašajo na nižjo kakovost segmentacije in obratno.	64
Preglednica 29: Pregled rezultatov analize vpliva prostorske in spektralne ločljivosti ter transformacij in filtriranja podobe na kakovost klasifikacije. Cenilke posameznih podob, ki so v primerjavi z izvirno podobo višje (rdeče polnilo), nižje (zeleno polnilo) in enake (brez polnila). Višje vrednosti cenilk se nanašajo na višjo kakovost klasifikacije in obratno.	66
Preglednica 30: Obdobje do prvega vzdrževanja DTK50 v letih (Geodetska uprava RS, 2015).	81
Preglednica 31: Ocena natančnosti rezultatov identifikacije sprememb pozidanih površin z metodo objektno usmerjene analize (po piksljih).	94
Preglednica 32: Pravilnost in popolnost identifikacije sprememb pozidanih površin (po objektih).	94

Preglednica 33: Pravilnost in popolnost identifikacije sprememb pozidanih površin (po objektih).....	96
Preglednica 34: Število in površina identificiranih sprememb v katastru stavb.	97
Preglednica 35: Pregled podatkovnih zbirk, v katerih se vodijo podatki o stavbah, dejanska raba prostora, pokrovnost tal in topografski podatki.	101

KAZALO SLIK

Slika 1: Prostorska ločljivost je odvisna od vidnega polja in razdalje med senzorjem in površjem.	8
Slika 2: Izvorni posnetek (a) in rezultat nizkoprepustnega filtriranja s filtrom povprečenja (b).	11
Slika 3: Izvorni posnetek (a) in rezultat filtriranja s filtrom mediana (b), ki ohranja robove. ...	12
Slika 4: Primerjava uteži za izračun povprečja okoliških pikslov s filtrom povprečenja (rdeča linija) in Gausovim filtrom (modra linija).	12
Slika 5: Izvorni posnetek (a) in rezultat filtriranja z Gausovim filtrom (b),	13
Slika 6: Izvorni posnetek (a) in rezultat transformacije z dekorelacijskim raztegom (b).	16
Slika 7: Shematski prikaz iterativne enonivojske segmentacije OLR (Weinke, Lang in Preiner, 2008).	21
Slika 8: Hierarhična mreža segmentov na različnih ravneh.	21
Slika 9: Postopno povečevanje podrobnosti segmentacije in klasifikacije v okviru objektno usmerjene analize (Veljanovski, Kanjir in Oštir, 2011; Baatz, Hoffmann in Willhauck, 2008).	22
Slika 10: Primer prešibke (a), ustrezne (b) in prekomerne (c) segmentacije.	24
Slika 11: Primer segmentacije podobe z večnivojskim algoritmom z maksimalnim (a), minimalnim (b) in uravnoteženim (c) vplivom barve na tvorbo segmentov.	27
Slika 12: Pregled metod ocene kakovosti segmentacije (Zhang, Fritz in Goldman, 2008). ...	29
Slika 13: Precenjene (rdeče) in podcenjene (modre) napake meje testnega in referenčnega geografskega objekta.	32
Slika 14: Študijsko območje analize vplivov na objektno usmerjeno analizo.	39
Slika 15: Pregled območij referenčnih podatkov pozidanih in nepozidanih površin.	44
Slika 16: Vpliv izbire spektralnega kanala na kakovost segmentacije. Najnižji indeks kakovosti kaže na najbolj visoko kakovost segmentacije in obratno.	46
Slika 17: Odvisnost kakovosti segmentacije od števila spektralnih kanalov. Najnižji indeks kakovosti kaže na najbolj visoko kakovost segmentacije in obratno.	51
Slika 18: meja referenčnega objekta (rdeče linije) in meja testnega objekta (rumeno polnilo) na podlagi segmentacije podobe s prostorsko ločljivostjo 0,5 m (a), 1 m (b), 2,5 m (c), 5 m (d), 10 m (e) in 20 m (f).	53
Slika 19: Vpliv spektralne ločljivosti na skupno natančnost klasifikacije pozidanih površin. ..	59
Slika 20: Vpliv prostorske ločljivosti na skupno natančnost klasifikacije pozidanih površin. ..	60
Slika 21: Izdelani listi DTK 5 po letih (Geodetska uprava RS, 2013).	79
Slika 22: Leto izdelave oziroma zadnje obnove podatkov DTK 50 (Geodetska uprava RS, 2015).	80
Slika 23: Število izdelanih listov DTK 5 po letih (Geodetska uprava RS, 2015).	81
Slika 24: Študijsko območje za identifikacijo sprememb pozidanih površin.	85
Slika 25: Metodologija identifikacije sprememb pozidanosti.	87
Slika 26: Metodologija identifikacije sprememb glede na evidentirano stanje v katastru stavb in dejanski rabi kmetijskih in gozdnih zemljišč.	90
Slika 27: Identifikacija sprememb sloja pozidanosti (rdeče) glede na evidentirano stanje (modro). Identificirane spremembe na ortofotu (a) in na podobi RapidEye (b).	93
Slika 28: Rezultat klasifikacije ortofota na objektna razreda pozidane površine (modro) in stavbe (rdeče).	96

Slika 29: Evidentirane stavbe (zelene) in primeri neevidentiranih stavb (rdeče) v katastru stavb: pomožne stavbe (a), stanovanjske stavbe (b) in poslovne ali industrijske stavbe (c). 97

Slika 30: Primeri nerazpoznanih objektov: razširitev ceste (a), prizidek k stavbi (b), novi objekt pri stanovanjski stavbi (c) in novi kmetijski objekt (d). 99

LIST OF TABLES

Table 1: Review of most common attributes of segments used in object-based classification.	27
Table 2: User defined weight optima and settings of normalized weighted segmentation quality measure for the case of roofs segmentation (Coillie in sod., 2010).	32
Table 3: Confusion matrix.	34
Table 4: Some use cases of WorldView-2 multispectral channels (DigitalGlobe, 2009).	39
Table 5: Basic and detailed level of object classes.	42
Table 6: Segmentation results analysis of one-channel image.	45
Table 7: Segmentation results analysis of two-channel image.	46
Table 8: Segmentation results analysis of three-channel image.	47
Table 9: Segmentation results analysis of four-channel image.	47
Table 10: Segmentation results analysis of five-channel image.	48
Table 11: Segmentation results analysis of six-channel image.	48
Table 12: Segmentation results analysis of seven-channel image.	49
Table 13: Analysis of impact of number of spectral channels on segmentation quality.	50
Table 14: Impact of spatial resolution on segmentation quality.	51
Table 15: Impact of image filtering on segmentation quality.	53
Table 16: Impact of image transformation on segmentation quality.	54
Table 17: Classification results analysis of one-channel image.	55
Table 18: Classification results analysis of two-channel image.	55
Table 19: Classification results analysis of three-channel image.	56
Table 20: Classification results analysis of four-channel image.	56
Table 21: Classification results analysis of five-channel image.	57
Table 22: Classification results analysis of six-channel image.	57
Table 23: Classification results analysis of seven-channel image.	57
Table 24: Analysis of impact of number of spectral channels on segmentation quality.	58
Table 25: Analysis of impact of spatial resolution on segmentation quality.	59
Table 26: Analysis of impact of image filtering on classification quality.	61
Table 27: Analysis of impact of image transformation on classification quality.	61
Table 28: Review of the results of the analysis on impact of spatial and spectral resolution, transformation and filtering on segmentation quality. Indices that are in comparison to original image higher (red), lower (green) and equal (black). High indices values refer to lower segmentation quality and vice versa.	64
Table 29: Review of the results of the analysis on impact of spatial and spectral resolution, transformation and filtering on classification quality. Indices that are in comparison to original image higher (red fill), lower (green fill) and equal (no fill). High indices values refer to higher classification quality and vice versa.	66
Table 30: Period to first DTK 50 update in years (Geodetska uprava RS, 2015).	81
Table 31: Accuracy of identified changes of built-up area using object based image analysis (pixel-based).	94
Table 32: Completeness and correctness of identified changes in built-up area (object-based).	94
Table 33: Completeness and correctness of identified changes in built-up area (object-based).	96

Table 34: Number and area of identified changed buildings in building cadastre.	97
Table 35: Review of databases with building data, topographic data, land cover and land use.	101

LIST OF FIGURES

Figure 1: Spatial resolution is a function of field of view and distance between sensor and Earth surface.	8
Figure 2: Original image (a) and results of low-pass filtering with averaging filter (b).	11
Figure 3: Original image (a) and results of filtering with median filter (b), which preserves edges.....	12
Figure 4: Comparison of weight for average pixel value calculation using mean filter (red line) and Gauss filter (blue line).	13
Figure 5: Original image (a) and results of filtering with gaussian filter (b),.....	13
Figure 6: Original image (a) and result of transformation with decorrelation stretch (b).	16
Figure 7: Scheme of iterative one level segmentation OLR (Weinke, Lang in Preiner, 2008).	21
Figure 8: Scheme of hierarhical network of segments on different levels.	21
Figure 9: Gradual increasing segmentation and classification detail in object based image analysis (Veljanovski, Kanjir in Oštir, 2011; Baatz, Hoffmann in Willhauck, 2008).....	22
Figure 10: Example of under- (a), correct (b) and over-segmentation (c).	24
Figure 11: Example of satellite image segmentation using multiresolution algorithm with maximum (a), minimum (b) and balanced (c) impact of color on segmentation creation.....	27
Figure 12: Overview of segmentation quality evaluation methods (Zhang, Fritz in Goldman, 2008).	29
Figure 13: Commission (red) and omission (blue) error between test object boundary and reference geographic object boundary.	32
Figure 14: Impact on object based image analysis study area.	39
Figure 15: Overview of reference data: built-up and non-built-up areas.	44
Figure 16: Impact of spectral channel selection on segmentation quality. Minimum index value indicates the most high quality segmentation and vice versa.	46
Figure 17: Segmentation quality depends on the number of spectral channels. Minimum index value indicates the most high quality segmentation and vice versa.	51
Figure 18: Reference (red line) and test object boundary (yellow fill) based on segmentation of image with spatial resolution 0,5 m (a), 1 m (b), 2,5 m (c), 5 m (d), 10 m (e) in 20 m (f)...	53
Figure 19: Impact of spectral resolution on overall accuracy of built-up area.....	59
Figure 20: Impact of spatial resolution on overall accuracy of built-up area.....	60
Figure 21: Completed DTK 5 maps by year of production (Geodetska uprava RS, 2013). ...	79
Figure 22: DTK 50 maps by year of production or last update (Geodetska uprava RS, 2015).	80
Figure 23: Number of completed maps by year of production (Geodetska uprava RS, 2015).	81
Figure 24: Identification of changes in built-up area study area.	85
Figure 25: Identification of changes in built-up area methodology.	88
Figure 26: Methodology for identification of changes in built-up area, registered in building cadastre and in actual arable and forest land use database.....	90
Figure 27: Built-up area change identification (red) in comparison to registered built-up area (blue). Change identification on ortophoto (a) and on RapidEye image (b).....	93
Figure 28: Extraction of classes built-up area (blue) and buildings (red) based on ortophoto classification.	96

Figure 29: Registered building (green) and some examples of unregistered building (red) in building cadastre: auxiliary buildings (a), residential buildings (b) and business or industrial buildings (c).	97
Figure 30: Examples of unrecognized object: road (a), prizidek (b), new building next to residential building (c) and new agricultural building (d).	99

SEZNAM KRATIC IN OKRAJŠAV

CB	coastal blue	robni moder
B	blue	moder
G	green	zelen
Y	yellow	rumen
R	red	rdeč
RE	red edge	robni rdeč
NIR1, NIR2	near infrared 1, near infrared 2	bližnji infrardeči 1 in 2

SEZNAM IZRAZOV IN POJMOV

Geografska entiteta	<i>ang. geographical entity</i>	Elementi geografske stvarnosti – resnični objekti in pojavi na Zemeljski površini, ki niso naprej deljivi na pojave istega tipa. Po GTS (2005) se uporablja tudi izraz geografski objekt.
Geografski objekt	<i>ang. geographical object</i>	Predstavitev geografske entitete v zbirki podatkov (Šumrada, 2005). V daljinskem zaznavanju tudi geografski objekti na posnetku.
Objekt	<i>ang. object</i>	Predstavitev entitete v zbirki podatkov (Šumrada, 2005). Pri objektno usmerjeni analizi gre za segment razvrščen v objektni razred.
Objektni razred	<i>ang. object class, thematic class</i>	Tematska skupina ali kategorija, ki združuje istovrstne objekte.
Segment	<i>ang. segment</i>	Strukturni oris geografske entitete v zbirki podatkov glede na lastnosti geografskega objekta na posnetku.
Objektno usmerjena analiza podob	<i>ang. object-based image analysis</i>	Niz postopkov, pri katerem se analiza vsebine podobe nanaša na razčlenjevanje (segmentacijo), določitev (klasifikacijo), vrednotenje (ocena natančnosti in poklasifikacija) in analizo pomensko razumljivih prostorskih enot (geografskih objektov).
Objektna klasifikacija	<i>ang. object-based classification</i>	Postopek razvrščanja segmentov v objektno usmerjena klasifikacija, semantična klasifikacija, kontekstualna klasifikacija.
Posnetek	<i>ang. image, picture</i>	Predstavitev resničnosti ne glede na nosilec zajema (optične naprave in analogni ali digitalni senzor). Predstavlja sliko opazovanih predmetov, zajeto v določenem trenutku pri izbrani valovni dolžini. Podaja vrednosti, ki jih je zaznal senzor.
Podoba	<i>ang. image</i>	Digitalna predstavitev podatkov daljinskega zaznavanja v obliki matrike slikovnih elementov. Predstavlja širši pojem od posnetka, saj poleg podatkov samega sensorja vključuje tudi rezultate analiz, transformacij ali interpretacije posnetka.
Dejanska raba prostora	<i>ang. land use</i>	Dejanska raba prostora je območje zemeljskega površja, opredeljeno glede na svojo sedanjo funkcionalno razsežnost ali socialno-ekonomski namen (npr. stanovanjska, industrijska, kmetijska, rekreacijska raba) (Inspire Directive, 2007).

Pokrovnost tal	ang. land cover	Pokrovnost tal je bio-fizični pokrov zemeljskega površja. Določa pokrovnost posameznega dela zemeljskega površja in ne namena oziroma uporabe območja (npr. voda, vegetacija, pozidano) (Inspire Directive, 2007).
Večspektralni posnetek	ang. multispectral image	Posnetek, ki ga tvori več spektralnih pasov (delov elektromagnetnega spektra). Nasprotno se na pankromatskem posnetku posname intenziteta celotnega valovanja.
Veččasovna podoba	ang. multitemporal image	Kompozit posnetkov identičnega območja, ki so bili posneti v različnih časovnih obdobjih.
Zelo visokoločljivostna podoba	ang. very high resolution (VHR) image	Podoba s prostorsko ločljivostjo, višjo od 1 m.
Visokoločljivostna podoba	ang. high resolution (HR) image	Podoba s prostorsko ločljivostjo, od 10 do 100 m.
Večnivojski algoritem	ang. multiresolution algorithm	Algoritem segmentacije, ki se uvršča med algoritme modelno ali slikovno vodenega pristopa. Tvorba segmentov z načinom razraščanja območij temelji na spektralni (barvni) in oblikovni homogenosti skupine pikslov.

1 UVOD

1.1 Ozadje problema

Podatki o prostoru so z razvojem sodobne družbe ter z njim povezanimi prostorskimi in okoljskimi problemi ključnega pomena. Pomagajo razumeti stanje in razvoj prostora v katerem živimo, vpliv posegov v prostor na okolje in na kakovost življenja sedanjih in prihodnjih generacij. Kakovostne zbirke prostorskih podatkov zahtevajo tudi naraščajoče zahteve Evropske unije o poročanju o stanju okolja, prostorskega razvoja ter o oceni vplivov okoljskih in prostorskih politik (Kuntz in sod., 2014). Poleg okoljske in zemljiške politike se prostorski podatki vse pogosteje uporabljajo v kmetijstvu, gozdarstvu, vodarstvu, na področju varstva pred naravnimi in drugimi nesrečami idr.

Po vzpostavitvi zbirke prostorskih podatkov in prvega zajema podatkov predstavlja največji izziv redno vzdrževanje podatkov. Gre za usklajevanje zbirke podatkov z dejanskim stanjem v prostoru. Za potrebe zagotavljanja zahtev uporabnikov je treba zagotoviti redno vzdrževanje zbirk podatkov tako, da le-te izkazujejo realno sliko dejanskega stanja v prostoru. Od konca 20. stoletja predstavljajo osnovni podatkovni vir za pridobitev podatkov o dejanskem stanju prostora različne vrste podatkov daljinskega zaznavanja: satelitski, letalski in radarski posnetki ter v zadnjem desetletju vse bolj tudi lidarski podatki. Prednosti podatkov daljinskega zaznavanja kot vira podatkov o stanju v prostoru so predvsem:

- ažurnost in hitrost zajema podatkov,
- zelo velik prostorski obseg in
- možnost pridobitve podatkov o težko ali nedostopnih območjih.

Območje Slovenije je dobro pokrito s podatki daljinskega zaznavanja, tako z državnimi kot tudi s tujimi (komercialnimi) ponudniki teh podatkov. Od leta 1975 se izvaja projekt cikličnega aerosnemanja, katerega najpogosteje uporabljena izdelka sta danes ortofoto in digitalni model reliefa. V letih 2014–2015 se je izvedlo lasersko skeniranje celotnega državnega ozemlja, na podlagi katerega so izdelani naslednji izdelki: oblak klasificiranih točk, digitalni model reliefa in podobe analitičnega senčenja. Poleg teh državnih podatkov so za celotno državno ozemlje ali posamezne dele na voljo še satelitski posnetki (Sentinel, Landsat, WorldView, RapidEye, GeoEye, OrbView, QuickBird). Toda podatki daljinskega zaznavanja predstavljajo le del prostorskih informacij, ki jih različni akterji v prostoru potrebujejo. Na primer podatki o obstoju in poteku cest v naravi se pridobijo iz različnih podatkov daljinskega zaznavanja (satelitski, letalski posnetki ali lidarski podatki), vendar šele integracija z drugimi prostorskimi podatki (npr. zemljiški kataster, topografski podatki) v enotnem geo-informacijskem okolju daje podatkom praktično vrednost. Podatke daljinskega zaznavanja je treba ustrezno interpretirati in ciljne prostorske podatke zapisati v obliki, ki omogoča integracijo v geo-informacijsko okolje.

Kljub izrednemu napredku tehnologije na področju strojne, programske opreme in samodejnih metod obdelave ostajata glavni metodi vzdrževanja prostorskih zbirk podatkov v večini evropskih držav vizualna fotointerpretacija letalskih in satelitskih posnetkov ter stereozajem. V Sloveniji se s stereozajemom ali s fotointerpretacijo ortofotov vzdržujejo številne podatkovne zbirke, v katerih se vodijo topografski podatki, podatki o dejanski rabi in pokrovnosti tal. Na podlagi zadnjega stanja zbirke prostorskih podatkov operater na ortofotu

ali satelitskem posnetku identificira spremembe in jih ročno zajame. Tovrsten postopek ima naslednje pomanjkljivosti (Holland, Sanchez-Hernandez in Gladstone 2008; Duncan in Smit, 2012):

- časovno in kadrovsko je zelo potraten,
- je subjektiven, saj temelji na izkušnjah posameznega operaterja, in
- je nepopoln (operater lahko izpušča posamezne dele posnetka pri pregledu zaradi nenehnega spreminjanja pogleda).

Zaradi vse večjih potreb po redno vzdrževanih prostorskih podatkih na eni strani in pomanjkljivosti obstoječih metod na drugi strani narašča težnja po popolni ali vsaj delni avtomatizaciji postopka vzdrževanja. Razvoj samodejnih postopkov za razpoznavanje sprememb v prostoru ali za zajem podatkov na podlagi podatkov daljinskega zaznavanja je aktivno področje raziskovanja v zadnjih desetletjih (Champion in Everaerts, 2009; Rottenstainer in sod., 2014). Kljub izrednemu napredku tehnologije za zajem podatkov (satelitski senzorji, brezpilotni letalniki, lidarski podatki) in razvoju algoritmov njihove obdelave, uporaba samodejnih postopkov vzdrževanja prostorskih podatkov še ni zaživela v praksi. Razvoj gre predvsem v smeri delno samodejnih metod, kjer s samodejnimi postopki odkrijemo spremembe v prostoru glede na evidentirano stanje v zbirki podatkov in jih nato evidentirano v skladu s pravili, ki veljajo za obravnavano podatkovno zbirko (fotointerpretacija, terenska izmera, upravni postopek ipd.). Raziskave kažejo, da se lahko na ta način prihrani tudi do 50 % časa, saj se operater namesto na pregled celotnega državnega ozemlja osredotoča le na območja identificiranih potencialnih sprememb (Champion in Everaerts, 2009).

Tudi v Sloveniji se za potrebe vzpostavitve in vzdrževanja prostorskih podatkovnih zbirk trenutno uporablja izključno vizualna interpretacija, medtem ko se samodejna klasifikacija podob uporablja zelo malo ali sploh ne. V letu 2010 je bila v okviru ciljno raziskovalnega projekta (Bric in sod., 2010) raziskana možnost uporabe samodejnih postopkov vzdrževanja prostorskih podatkovnih zbirk državnega topografsko-kartografskega sistema. Rezultati opravljene raziskave in praksa v tujini kažeta, da je treba razvoj usmeriti v polsamodejne postopke in postopke postopoma vključiti v operativno delo. V magistrski nalogi bom raziskala možnosti uporabe metod samodejne klasifikacije podob v procesih vzdrževanja izbranih prostorskih podatkovnih zbirk.

1.2 Cilji in hipoteza

Podatki daljinskega zaznavanja predstavljajo pomemben vir podatkov za pridobivanje informacij o stanju in spremembah zemeljskega površja. Na podlagi podatkov letalskega in satelitskega (optičnega) snemanja ter radarskega in laserskega skeniranja se lahko pridobi različne informacije o prostoru z vizualno (ročno) interpretacijo ali s samodejno klasifikacijo. Pri vizualni interpretaciji operater določa obseg in lokacijo geografskih objektov z iskanjem zaključenih skupin pikslov, medtem ko pri samodejni klasifikaciji geografske objekte na podobi prepozna sistem sam. Razpoznava lahko temelji na spektralnem podpisu posameznih razredov (pikselska klasifikacija) ali na spektralnih, geometričnih, teksturnih in drugih lastnostih skupine pikslov ali segmentov (objektno usmerjena analiza). Pikselska klasifikacija se navadno uporablja za analizo nizko- in visokoločljivostnih posnetkov, medtem ko je za visokoločljivostne manj učinkovita in časovno potratna, saj ti posnetki vsebujejo

preveč podrobnosti (visoka prostorska, spektralna in časovna ločljivost). Navadno se za klasifikacijo visokoločljivostnih posnetkov uporablja objektno usmerjena analiza (Veljanovski, Kanjir in Oštir, 2011).

Objektno usmerjena analiza se izvaja v dveh fazah – segmentacija in objektna klasifikacija. V fazi segmentacije združimo podobne sosednje piksele v segmente, v fazi objektno usmerjene analize segmentom določimo pripadnost objektnim razredom. Izvedenih je bilo več raziskav o analizi vplivov na segmentacijo (Neubert in Harold, 2008; Coillie in sod., 2008; Zhang, Fritts in Goldman, 2008), vendar so se raziskovalci osredotočali predvsem na oceno vpliva uporabe različnih algoritmov segmentacije in nastavitve parametrov posameznega algoritma. Izvedena je bila tudi raziskava o vplivu spektralne in prostorske ločljivosti na kakovost segmentacije (Mesner in Oštir, 2014). Po znanih podatkih druge raziskave na temo analize vplivov na kakovost segmentacije še niso bile izvedene. Poznavanje vplivov na posamezno fazo objektno usmerjene analize je ključnega pomena pri uporabi te metode. Samo tako lahko pridobimo najbolj kakovostne rezultate glede na razpoložljive podatke.

Tudi o uporabi objektno usmerjene analize za potrebe vzdrževanja prostorskih podatkov je bilo izvedenih že več raziskav v tujini in Sloveniji (Grigillo, 2009; Bric in sod., 2010). Rezultati kažejo, da je trenutno prihodnost v razvoju in implementaciji delno samodejnih metod, kjer se z eno izmed tehnik samodejne razpoznave identificirajo spremembe v prostoru. Nato se spremembe evidentirajo v podatkovni zbirki po veljavni metodologiji za zajem in vzdrževanje podatkov obravnavane podatkovne zbirke. To so lahko fotointerpretacija, stereozajem, terenska izmera ali upravni postopek.

Za praktično uporabne rezultate samodejne identifikacije sprememb glede na evidentirano stanje se šteje postopek, ki odkrije vsaj 70 % dejanskih sprememb (popolnost) in ob tem je delež lažno razpoznanih sprememb manjši od 15 % (Mayer, 2006; Rottensteiner, 2014). Pri identifikaciji novih (neevidentiranih) geografskih objektov pa je za uspešnost postopka pomembna predvsem visoka popolnost identifikacije (Champion in sod., 2010), saj to pomeni, da operater ne pregleduje celotnega posnetka in išče spremembe, temveč se osredotoča le na identificirane spremembe. Za pravilno identificirane spremembe zajame podatke in jih vnese v bazo, lažne spremembe pa zavrže. Samo nizka pravilnost torej ne pomeni, da je samodejna identifikacija ekonomsko neučinkovita. Gladstone, Gardiner in Holland (2012) so na podlagi testa uvedbe samodejnih postopkov v procese vzdrževanja ocenili, da kljub nizki pravilnosti (25 %), postopek prihrani približno 50 % časa v primerjavi z ročnim pregledovanjem posnetkov in identifikacijo sprememb. Pri identifikaciji sprememb se je izkazalo, da je postopek učinkovit tudi, če javi spremembe na 50 % področja obdelave in je delež dejanskih sprememb bistveno manjši, saj to v praksi pomeni, da operater pregleduje in zajame podatke le na polovici področja, na preostali polovici, kjer ni identificiranih sprememb, pa tega postopka ne izvaja.

Poleg uporabe samodejnih metod v postopku vzdrževanja prostorskih podatkov se lahko postopek vzdrževanja dodatno optimizira tudi z izdelavo večnamenskih podatkov o stanju v prostoru. Večnamenske podatke lahko predstavljajo podatki o pokrovnosti tal (stavbe, druge pozidane površine, gola tla, drevesa, voda, vegetacija), ki podajo informacijo o dejanskem stanju pokrovnosti v prostoru. Na podlagi primerjave pokrovnosti tal, evidentiranega stanja in drugih tematskih podatkov se lahko identificira sprememba v obravnavani podatkovni zbirki. Podatki o pokrovnosti so lahko podlaga za identifikacijo sprememb glede na evidentirano

stanje v zbirkah prostorskih podatkov, kjer se vodijo podatki o pokrovnosti tal, rabi prostora, topografiji idr. Cilj izdelave večnamenskih podatkov o stanju v prostoru je, da se v enem postopku določi dejansko (ažurno) stanje v prostoru in izdelava nabor potencialnih sprememb za različne podatkovne zbirke.

Na podlagi opisanih ciljev naloge postavim osnovno hipotezo in tri podhipoteze:

Objektno usmerjena analiza omogoča izdelavo večnamenskega sloja pokrovnosti tal, ki je podlaga za vzdrževanje različnih zbirk prostorskih podatkov.

Podhipoteza 1: S filtriranjem in transformacijo posnetka ali izbiro spektralne in prostorske ločljivosti se lahko doseže višja skupna natančnost klasifikacije v primerjavi z izvornim posnetkom.

Podhipoteza 2: Uporaba veččasovnih podob ima pozitiven vpliv na izboljšanje pravilnosti rezultatov objektno usmerjene analize.

Podhipoteza 3: Objektno usmerjena analiza omogoča identifikacijo sprememb pozidanih površin na zelo visokoločljivostnem posnetku in dosega minimum uporabne vrednosti klasifikacije.

1.3 Metoda dela

V magistrski nalogi sem podrobno proučila objektno usmerjeno analizo na primeru uporabe za potrebe vzdrževanja prostorskih podatkov. Poseben poudarek je namenjen ovrednotenju vpliva transformacij in filtriranja posnetkov ter spektralne in prostorske ločljivosti podatkov na kakovost končnih rezultatov. Obravnava vseh sprememb v prostoru bi presegala obseg te naloge, zato sem raziskovalno delo osredotočila na spremembe pozidanih površin, saj so te spremembe zelo pogoste, trajne in med najbolj obremenilnimi za okolje. Zato so osnovna hipoteza in podhipoteze podrobno preverjene na pozidanih površinah in vzdrževanju podatkov, ki se nanašajo na pozidane površine v izbranih zbirkah prostorskih podatkov.

Na podlagi praktičnih primerov identifikacije pozidanih površin z metodo objektno usmerjene analize sem ocenila vpliv filtriranja in transformacije posnetka ali izbire spektralne, prostorske in časovne ločljivosti na skupno natančnost klasifikacije. Opravljene analize in dobljeni rezultati omogočajo razvoj postopka objektno usmerjene analize za razpoznavo pozidanih površin in identifikacijo sprememb v različnih podatkovnih zbirkah. Cilj predlaganega postopka je, da dosega minimum uporabne vrednosti identifikacije pozidanih površin, ki je ocenjen s popolnostjo identifikacije (t. j. deležem identificiranih sprememb glede na vse evidentirane spremembe), ki je večja od 70 % (Mayer, 2006; Rottensteiner, 2014).

Za izvedbo objektno usmerjene analize sem uporabila komercialno programsko orodje eCognition, za filtriranje, transformacijo in druge predobdelave posnetkov pa Erdas Imagine. Za analizo rezultatov objektno usmerjene analize sem uporabila ArcGIS, v katerem sem tudi modelirala postopek za oceno kakovosti segmentacije.

1.4 Struktura naloge

Magistrska naloga je sestavljena iz dveh delov: teoretičnega in praktičnega.

V teoretičnem delu je podan pregled uporabljenih daljinsko zaznanih podatkov, postopkov obdelave podobe in metod interpretacije daljinsko zaznanih podatkov, s poudarkom na objektno usmerjeni analizi. Podrobneje sta predstavljena postopka obdelave daljinsko zaznanih podatkov, uporabljenih v sklopu te naloge – filtriranje in transformacije. Filtriranje se uporablja za glajenje podrobnosti na posnetku. S postopki transformacije se na posnetku poudarijo določeni geografski objekti, kar lahko pomembno vpliva na rezultate objektno usmerjene analize. Sledi pregled metod samodejne klasifikacije posnetkov, s poudarkom na objektno usmerjeni analizi. Podane so teoretične osnove za oceno kakovosti rezultatov segmentacije in objektno usmerjene analize. Razumevanje teoretičnih osnov je ključno za izvedbo praktičnega dela naloge.

V praktičnem delu so predstavljeni trije sklopi analiz: analiza vplivov na objektno usmerjeno analizo, analiza vpliva veččasovnih podob na pravilnost rezultatov ter analiza možnosti uporabe podatkov o pozidanih površinah in stavbah za identifikacijo sprememb glede na evidentirano stanje v različnih podatkovnih zbirkah.

Analiza vplivov na segmentacijo vsebuje štiri sklope testov, ki preverjajo vpliv prostorske in spektralne ločljivosti ter vpliv filtriranja in transformacije posnetkov. Cilj testov je ovrednotenje izbire in predobdelave posnetkov na usklajenost meje segmenta in geografskega objekta. Kakovost segmentacije je ocenjena na podlagi primerjave z referenčnim slojem podatkov in izračunom petih cenilk kakovosti: razlike v površini in obsegu, število nerazpoznanih objektov, položajnega odstopanja in števila segmentov, ki sestavljajo en referenčni objekt. V okviru analize vplivov na objektno usmerjeno analizo ocenjujem vpliv prostorske in spektralne ločljivosti ter filtriranja in transformacije na kakovost rezultatov.

Podan je pregled podatkovnih zbirk v Sloveniji, v katerih se vodijo podatki o pokrovnosti in rabi tal ter topografski podatki in način njihovega vzdrževanja. Na podlagi pregleda domačih in tujih izkušenj z uporabo samodejnih metod v postopku vzdrževanja podatkov je ocenjena možnost uporabe teh postopkov pri vzdrževanju podatkov. Upoštevajoč rezultate analiz vplivov na segmentacijo in objektno klasifikacijo je razvita metodologija za razpoznavanje pozidanih površin. Na testnem območju, ki obsega tako strnjeno urbano kot razpršeno podeželsko poselitev, je ocenjen vpliv veččasovnih podob na pravilnost rezultatov identifikacije sprememb pozidanih površin ter možnost uporabe podatkov o pozidanih površinah in stavbah za identifikacijo sprememb glede na evidentirano stanje v različnih podatkovnih zbirkah.

2 DALJINSKO ZAZNANI PODATKI

V tem poglavju so kratko predstavljene vrste podatkov daljinskega zaznavanja. Večji poudarek je namenjen optičnim posnetkom, ki so bili v okviru praktičnega dela naloge uporabljeni kot osnovni vir podatkov za določitev pozidanosti tal. Sledita še opis prostorske, spektralne, časovne in radiometrične ločljivosti podatkov ter pomen ločljivosti podatkov za različne namene uporabe.

2.1 Vrste daljinsko zaznanih podatkov

2.1.1 Optični posnetki

Optični snemalni sistem je najstarejši in najbolj razširjen sistem daljinskega zaznavanja. Gre za snemanje zemeljskega površja s fotografskimi kamerami ali z večspektralnimi skenerji. Osnovno načelo delovanja pri digitalnih fotoaparatih in skenerjih je zelo podobno. Senzor, ki je po obliki ploskovni ali vrstični, zazna od površja odbito elektromagnetno valovanje v posameznem pasu snemanja in mu priredi številsko vrednost. Rezultat je datoteka, ki vsebuje toliko slojev, kolikor je pasov snemanja, v vsakem pikslu pa je zapisna številka vrednost odbitega valovanja. Tako pridobljene posnetke je treba pred nadaljnjo uporabo ustrezno obdelati. V postopku predobdelave se odpravijo napake v delovanju sensorja, napake geometrije, atmosfere, radiometričnih vrednosti in terena. Nato se posnetek georeferencira v želeni koordinatni sistem (Oštir, 2006).

Glede na platformo, na katero je nameščena snemalna naprava, ločimo letalske in satelitske posnetke. Prva aerosnemanja Slovenije segajo v sedemdeseta leta, od leta 1985 pa se izvajajo redna snemanja s triletnim ciklom. Pomembni prelomnici predstavljata leti 2006, ko se je začelo snemanje z digitalnim fotoaparatom, in 2012, ko se je začelo snemanje v infrardečem delu spektra (Bric in sod., 2015). Letalski posnetki so osnova za izdelavo široko uporabljenih izdelkov, kot sta ortofoto in digitalni model reliefa, ter za zajem prostorskih podatkov s stereorestitucijo. Izdelava državnega ortofota kot najbolj priljubljenega izdelka sega v devetdeseta leta 20. stoletja, njegova kakovost se z leti izboljšuje (Kosmatin Fras, Fabiani in Triglav Čekada, 2014). Danes so za celotno območje Slovenije na voljo aeroposnetki, ortofoti s prostorsko ločljivostjo 25 in 50 cm ter štirimi spektralnimi kanali (rdeč, zelen, moder in bližnji infrardeči kanal) in digitalni model reliefa.

V primerjavi z letalskimi posnetki je prednost visokoločljivostnih satelitskih posnetkov višja spektralna, časovna in radiometrična ločljivost, kar omogoča boljše razpoznavanje med geografskimi objekti, spremljanje stanja, razvoja in sprememb v prostoru. Izdelava satelitskih posnetkov sega v sedemdeseta leta, ko je začel delovati satelitski sistem Landsat. Od takrat sta se bistveno povečala tako število satelitskih sistemov kot tudi ločljivost podatkov. Danes so na razpolago številni satelitski sistemi z visoko prostorsko (manj kot 1 m), spektralno (od 4 do 8 kanalov), radiometrično (do 16 bitov) in časovno ločljivostjo (nekaj tednov). To so npr. GeoEye, QuickBird, Ikonos, WorldView, Orbview, Pleiades idr. (Bric in sod., 2010). Na tem mestu je treba izpostaviti še satelitski sistem Sentinel, ki ga v okviru programa Copernicus financira Evropska komisija in razvija Evropska vesoljska agencija. Pomembnost tega sistema v primerjavi z drugimi satelitskimi sistemi je poleg visoke ločljivosti podatkov (spektralna in časovna) tudi podatkovna politika, ki omogoča polno, brezplačno in odprto razširjanje podatkov (Veljanovski, Lenarčič Švab in Oštir, 2014).

Optični posnetki so uporabni predvsem za interpretacijo posnetkov in zajem prostorskih podatkov, tako s samodejnimi metodami (klasifikacija) kot tudi z ročnim zajemom. Predstavljajo osnovni vir podatkov za izdelavo kart pokrovnosti in topografskih kart (Topan in sod., 2009; Holland in sod., 2006). V okviru te naloge sem optične posnetke, letalske in satelitske, uporabila za določitev pozidanosti tal.

2.1.2 Radarski posnetki

Bistvena prednost radarskega snemanja v primerjavi z optičnim je neodvisnost od stanja v atmosferi (oblaki, prah, dež), kar je posledica snemanja v mikrovalovnem delu spektra. Zato lahko na radarskih posnetkih opazujemo zemeljsko površje ne glede na vremenske razmere in osvetljenost v času snemanja. Poleg tega so elektromagnetni valovi izredno občutljivi na vlago, zaradi česar se radarski posnetki najpogosteje uporabljajo v študijah, ki so povezane z vodo ali vlažnostjo, npr. pomorstvo, hidrologija, geologija (predvsem struktura tal v sušnih predelih), gozdarstvo, vegetacijske analize (stanje, vsebnost vode) idr. (Bric in sod., 2010).

Prvi radarski posnetki so bili nizke do visoke ločljivosti, medtem ko so danes na voljo tudi zelo visokoločljivostni posnetki, npr. CosmoSkyMed, TeraSAR-X, RADARSAT-2. V letu 2014 je postal operativen tudi radarski satelit Sentinel-1, ki snema zemeljsko površje v visoki časovni in prostorski ločljivosti, podatki pa so prosto dostopni.

2.1.3 Lidarski podatki

Podobno kot radarski posnetki so tudi lidarski podatki rezultat aktivne metode daljinskega zaznavanja (Oštir, 2006) – laserskega skeniranja ali lidar (ang. light detection and ranging). Senzor, ki je lahko nameščen na letalu ali helikopterju (zračno lasersko skeniranje) ali na zemeljskem površju (terestrično lasersko skeniranje), oddaja laserski žarek in meri oddaljenost do točk, od katerih se je žarek odbil, čas potovanja in intenziteto. Rezultat laserskega skeniranja je oblak točk z naslednjimi atributi: koordinate točke, intenziteta odbitega valovanja, red odboja idr. (Bric, Triglav Čekada in Bitenc, 2012).

V primerjavi z aerofotografiranjem je bistvena prednost laserskega skeniranja, da omogoča zajem podatkov o površju in objektih pod vegetacijo (Triglav Čekada, Bric in Mongus 2014). Lidarski podatki predstavljajo trenutno najbolj natančne podatke o zemeljskem površju, kar se kaže tudi v zelo široki uporabi teh podatkov. V okviru projekta Lasersko skeniranje Slovenije (v nadaljevanju LSS) je bilo izvedeno lasersko skeniranje celotnega državnega ozemlja, katerega najbolj uporabljen rezultat je natančen model reliefa (Bric in sod., 2015). Do sedaj so se lidarski podatki večinoma uporabljali v raznih študijah na področju vodarstva (Gosar in sod., 2007), gozdarstva (Kobler in Zafran, 2006), geomorfologije (Triglav Čekada, 2011), arheologije (Popit in sod., 2014) in prostorskega načrtovanja (Barborič in sod., 2008). Pričakuje se, da bodo brezplačni podatki, pridobljeni v okviru projekta LSS, pospešili uporabo lidarskih podatkov tako v nadaljnjih študijah kot tudi v operativnih nalogah.

Lidarski podatki predstavljajo odličen dopolnilni vir podatkov k optičnim posnetkom. Na podlagi podatka o višini objektov je možno izboljšati razpoznavanje različnih vrst pokrovnosti tal, npr. stavbe in druge (nizke) pozidane površine, visoka in nizka vegetacija, ipd.

2.2 Ločljivost podatkov

Ločljivost satelitskih posnetkov opredeljuje zmogljivost snemalnega sistema, s katerim so podobe zajete. Ločimo štiri vrste ločljivosti (Oštir, 2006):


- prostorsko,
- spektralno,
- radiometrično in
- časovno ločljivost.

Posamezne vrste ločljivosti so podrobneje opisane v nadaljevanju.

2.2.1 Prostorska ločljivost

Prostorska ločljivost posnetka je definirana kot površina zemeljskega površja, ki ga predstavlja en piksel. Odvisna je od trenutnega vidnega polja (ang. Instantaneous Field of View, IFOV) in razdalje med senzorjem in površjem (Oštir, 2006). Izračunamo jo z množenjem trenutnega vidnega polja (Ω) z razdaljo med senzorjem in površjem (h) (slika 1).

$$s = h \cdot \Omega$$



Slika 1: Prostorska ločljivost je odvisna od vidnega polja in razdalje med senzorjem in površjem.

Figure 1: Spatial resolution is a function of field of view and distance between sensor and Earth surface.

Vidno polje je za posamezen senzor snemalnega sistema konstantno, razdalja med zemeljskim površjem in senzorjem pa ne, saj kot snemanja ni konstanten, zato je tudi prostorska ločljivost na satelitskem posnetku spremenljiva. Maksimalna prostorska ločljivost posnetka je na območju, kjer je snemalni sistem v nadirju. Večji kot je kot snemanja, manjša je prostorska ločljivost.

Prostorska ločljivost določa stopnjo podrobnosti prikaza objektov na posnetku. Na posnetkih nizke ločljivosti so objekti generalizirani (nizka stopnja podrobnosti), medtem ko so na zelo visokoločljivostnih posnetkih prikazani z višjo stopnjo podrobnosti. Pri izbiri podatkovnih virov je treba izbrati snemalni sistem s tako prostorsko ločljivostjo, ki ustreza ravni podrobnosti končnega izdelka. Tako je npr. za kartiranje naselij primeren visokoločljivostni posnetek, medtem ko je za kartiranje posameznih stavb treba uporabiti zelo visokoločljivostni posnetek.

2.2.2 Spektralna ločljivost

Spektralna ločljivost se nanaša na sposobnost senzorja, da zazna elektromagnetno valovanje na čim ožjem območju valovnih dolžin. Definirana je z območjem opazovanih valovnih dolžin (spektralni kanal) in številom spektralnih kanalov, ki jih snemalni sistem lahko zazna.

Senzorji z manjšo spektralno ločljivostjo, t. j. s širokimi pasovi spektralnih kanalov, omogočajo razpoznavanje med razredi, kot sta npr. voda in vegetacija. Medtem, ko senzorji z visoko spektralno ločljivostjo, t. j. ožjimi pasovi in večjim številom spektralnih kanalov, omogočajo tudi razlikovanje med sorodnimi vrstami pokrovnosti tal (npr. različne vrste listavcev).

2.2.3 Radiometrična ločljivost

Radiometrična ločljivost snemalnega sistema se nanaša na sposobnost senzorja, da ločuje med različnimi intenzitetami odbitega elektromagnetnega valovanja. Signal, ki ga senzor zazna, se zapiše v obliki digitalne vrednosti, ta pa se predstavi s celimi števili (Oštir, 2006). Radiometrična ločljivost je izražena v bitih. Tako na primer 16-bitna radiometrična ločljivost pomeni, da so intenzitete odboja na posameznem spektralnem kanalu predstavljene z 2^{16} oziroma 65536 vrednostmi.

2.2.4 Časovna ločljivost

Časovna ločljivost določa obdobje med dvema zaporednima snemanjema istega dela zemeljskega površja. Časovna ločljivost je odvisna od stopnje prekrivanja tirnic snemalnega sistema in od maksimalnega kota snemanja (Oštir, 2006). Visoko časovno ločljivost lahko snemalni sistem zagotovi tudi z zmožnostjo snemanja pod kotom (tudi do 45°). Slabost posnetkov, snemanih pod velikim kotom, je v večjem vplivu razgibanosti reliefa na položajno natančnost posnetka. Časovna ločljivost je zelo pomembna za analizo časovno odvisnih objektov in pojavov, analizo sprememb na zemeljskem površju (naravne nesreče, sezonske in dolgoletne spremembe) in izboljšanje kakovosti klasifikacije. Na območju pozidanih površin se posnetki z visoko časovno ločljivostjo lahko uporabijo za spremljanje realizacije posegov v prostor (npr. gradnja infrastrukturnih objektov).

3 OBDELAVA POSNETKOV

V tem poglavju sta predstavljena izbrana postopka obdelave posnetkov. To sta filtriranje in transformacija, ki lahko pomembno vplivata na izboljšanje kakovosti objektno usmerjene analize.

3.1 Filtriranje

Filtriranje je ena izmed tehnik izboljšave posnetkov, ki se lahko uporablja za odstranjevanje šumov, izostritev ali za iskanje robov. V splošnem je posnetek sestavljen iz treh komponent: ozadja, podrobnosti in šuma (Oštir, 2006). Filtriranje je matematični postopek, s katerim iz izvornega posnetka odstranimo določeno komponento (npr. šum) ali pa izluščimo eno komponento (npr. ozadje za glajenje posnetka) in jo zapišemo v novo podobo. Pri tem opazujemo prostorsko frekvenco oziroma spremembo intenzitete piksla v določeni smeri. Elementi ozadja imajo nizko frekvenco, podrobnosti pa visoko frekvenco. Algoritmi, ki poudarjajo ozadje (posnetek zgladijo), so nizkoprepustni filtri, algoritmi, ki poudarjajo podrobnosti, pa visokoprepustni filtri. Glede na prostor, v katerem izvajamo filtriranje, ločimo tri tehnike filtriranja (Oštir, 2006):

- diskretna Fourierjeva transformacija temelji na dekompoziciji posnetka s pretvorbo podobe v frekvenčni prostor,
- konvolucija temelji na dekompoziciji posnetka z enostavnimi matematičnimi postopki v prostorski domeni,
- diskretna valjčna transformacija združuje tako prostorsko kot tudi frekvenčno filtriranje.

V okviru magistrske naloge sem se ukvarjala s filtri v prostorski domeni. Gre za uporabo 2D-konvolucijskega operatorja, ki pikslom dodeli novo vrednost. Ta se izračuna kot utežna vsota sosednjih pikslom v okolici centralnega piksla (O'Gormann, Sammon in Seul, 2008). Uteži za izračun nove vrednosti pikslom so zapisane v t. i. filtrirni matriki, s katero lahko izvajamo različne operacije:

- glajenje (nizkoprepustni filtri),
- ostrenje (visokoprepustni filtri) in
- odkrivanje robov (filtri robov).

Z nizkoprepustnimi filtri posnetek zgladimo in tako zmanjšamo stopnjo podrobnosti. Slabost teh filtrov je, da se pri glajenju zgladijo tudi robovi. Zato ima uporaba nizkoprepustnih filtrov za potrebe segmentacije naslednje negativne posledice (Garnica, Boochs, in Twardochlib, 2000):

- slabšo položajno natančnost določitve meje,
- spremembo geometrije objektov in
- prešibko segmentacijo sosednjih objektov s podobnimi spektralnimi lastnostmi.

Z uporabo filtrov ohranjanja robov (ang. *edge preserving filters*) se navedenim negativnim posledicam izognemo. Osnovno načelo delovanja teh filtrov je, da se v izračunu upoštevajo le piksli, ki imajo podobno vrednost kot centralni piksel. Na ta način se robovi dobro ohranjajo. Slaba stran teh filtrov pa je, da je stopnja glajenja oziroma zmanjšanja podrobnosti

na posnetku nižja, kar se pri postopku segmentacije lahko kaže v večji razdrobljenosti posnetka na segmente.

Za potrebe segmentacije so tako primerni filtri, ki uravnoteženo združujejo pozitivne lastnosti nizkoprepustnih filtrov (visoka stopnja glajenja na homogenih območjih) in filtrov ohranjanja robov. Poleg tega je za segmentacijo pomembno, da filtri ohranjajo zelo majhna homogena območja (npr. stavbe na območju kmetijske rabe).


Teorija in praktični postopki filtriranja so obsežni, zato so v nadaljevanju le na kratko opisani filtri, ki so bili uporabljeni v okviru analize vplivov filtriranja na objektno usmerjeno analizo. To so filter povprečenja, filter mediana in Gaussov filter.

3.1.1 Filter povprečenja

Filter povprečenja je najbolj preprost primer nizkoprepustnega filtra, pri katerem v izhodno datoteko zapišemo povprečje vrednosti okolice posameznega piksla (O'Gormann, Sammon in Seul, 2008). Okolica je odvisna od velikostnega reda filtrirne matrike. Pri uporabi filtrirne matrike reda tri se izračuna povprečje centralnega piksla in sosednjih osem elementov z naslednjo filtrirno matriko (Oštir, 2006):

$$F = \frac{1}{9} \times \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Filtrirna matrika je normirana, s čimer dosežemo, da so vrednosti pikslov v izhodni datoteki enakega velikostnega reda kot na izvornem posnetku. Primer glajenja posnetka s filtrom povprečenja je prikazan na sliki 2.



Slika 2: Izvorni posnetek (a) in rezultat nizkoprepustnega filtriranja s filtrom povprečenja (b).


Figure 2: Original image (a) and results of low-pass filtering with averaging filter (b).

3.1.2 Filter mediana

Filter mediana je zelo podoben filtru povprečenja, pri čemer se v izhodno datoteko ne zapiše aritmetično povprečje, temveč mediana vrednosti okoliških pikslov. Mediana je vrednost piksla, od katere je polovica vrednosti pikslov v okolici višja, polovica pa nižja. Prednost uporabe mediane v primerjavi s povprečjem je, da je mediana manj občutljiva na vrednosti

posameznih pikslov, ki zelo odstopajo, in da se v izhodno datoteko vpiše vrednost, ki dejansko obstaja na izvornem posnetku (Oštir, 2006).

Rezultat filtra mediana je posnetek z zglajenimi homogenimi območji in ohranjenimi robovi, zaradi česar je primeren za obdelavo podobe pred izvedbo segmentacije. Primer glajenja posnetka s filtrom mediana je prikazan na sliki 3.




Slika 3: Izvorni posnetek (a) in rezultat filtriranja s filtrom mediana (b), ki ohranja robove.

Figure 3: Original image (a) and results of filtering with median filter (b), which preserves edges.

3.1.3 Gaussov filter

Tudi Gaussov filter je zelo podoben filtru povprečenja, pri čemer se v izhodno datoteko ne zapiše enostavno aritmetično povprečje, temveč utežno povprečje okoliških pikslov. Centralni piksel ima pri izračunu največjo utež, z oddaljevanjem od centralnega piksla proti robu okolice izračuna se utež manjša. Primerjava uteži za izračun povprečja okoliških pikslov s filtrom povprečenja in Gaussovim filtrom je predstavljen na sliki 4. Filter povprečenja ima enako utež ne glede na oddaljenost od centralnega piksla, pri Gaussovem filtru pa je utež določena s funkcijo normalne porazdelitve.



Slika 4: Primerjava uteži za izračun povprečja okoliških pikslov s filtrom povprečenja (rdeča linija) in Gaussovim filtrom (modra linija).

Figure 4: Comparison of weight for average pixel value calculation using mean filter (red line) and Gauss filter (blue line).

Elementi filtrirne matrike reda n se izračunajo po (O'Gormann, Sammon in Seul, 2008):


$$F(i, j) = e^{-\frac{1}{2} \left(\frac{d}{\sigma} \right)^2}$$

Kjer je:

$$d = \sqrt{i^2 + j^2}$$

$$\frac{-(n-1)}{2} \leq i, j \leq \frac{(n-1)}{2}$$

Primer glajenja posnetka z Gaussovimi filtrom je prikazan na sliki 5.



Slika 5: Izvorni posnetek (a) in rezultat filtriranja z Gaussovimi filtrom (b),

Figure 5: Original image (a) and results of filtering with gaussian filter (b),

3.2 Transformacije posnetkov

Transformacija posnetka je postopek, ko se iz enega ali več posnetkov izdelava nova podoba, na kateri so poudarjeni geografski objekti, ki so predmet določene analize. Transformirane podobe se lahko uporabijo v postopku klasifikacije, saj se na ta način zmanjša količina podatkov (enostavnejša obdelava podatkov) in hkrati se poudarijo želene lastnosti na podobi, kar lahko pomembno vpliva na kakovost objektno usmerjene analize. Najpogosteje se uporabljajo naslednje transformacije (Oštir, 2006):

- osnovne aritmetične operacije (seštevanje, množenje, odštevanje in deljenje),
- razmerja med kanali (npr. normiran diferencialni vegetacijski indeks),
- Kauth-Thomasova transformacija (ang. tasseled cup),
- analiza osnovnih komponent (PCA, principal component analysis).

Teorija in praktični postopki transformacije posnetkov so zahtevni, zato so v nadaljevanju le na kratko opisane izbrane transformacije, ki so bile uporabljene v okviru magistrske naloge. To so različna razmerja med kanali, analiza osnovnih komponent in dekorelacijski razteg.

3.2.1 Razmerja med kanali

Razmerja med kanali se uporabijo za poudarjanje izbranih geografskih objektov ali pojavov na posnetku, kot so na primer različne vrste pokrovnosti tal, stanje vegetacije, vrste tal. Gre za razpoznavanje majhnih sprememb spektralnega odboja, ki na izvornih meritvah (enem kanalu) niso jasni, jih pa dobro razlikujemo s kombinacijo različnih kanalov. Prednost razmerij v primerjavi z izvornimi kanali je poleg izboljšanja razpoznavanja določenih geografskih objektov tudi zmanjšanje vpliva topografije in osvetlitve (Oštir, 2006).

Eden izmed najpogosteje uporabljenih razmerij med kanali za oceno stanja vegetacije je normiran diferencialni vegetacijski indeks (NDVI, normalized difference vegetation index). Vegetacija ima visoko odbojnost na infrardečem kanalu in nizko na rdečem kanalu, zato se ta dva kanala uporabita za izračun indeksa NDVI, in sicer kot razmerje med razliko in vsoto obeh kanalov (Liang, 2004).

$$NDVI = \frac{IR - R}{IR + R}$$

Indeks NDVI zavzema vrednosti med -1 in 1 in odraža spremembe zelene biomase in vsebnosti klorofila. Zdrava, zelena vegetacija ima visoke vrednosti indeksa NDVI. Manjše vrednosti ima poškodovana vegetacija in najmanjše (navadno negativne vrednosti) voda, pozidane površine in gola tla. Indeks NDVI je zelo učinkovit pri razlikovanju med vegetacijo in nevegetacijo, medtem ko je za razlikovanje med posameznimi vrstami pokrovnosti, ki niso vegetacija, praktično neuporaben. Za razlikovanje med vodo, pozidanimi površinami in golimi tlemi so primernejši indeksi, ki na posnetku poudarijo površine s temi vrstami pokrovnosti tal.

Za razpoznavanje pozidanih površin je bilo predlaganih več indeksov (Zhang, 2003; Kawamura in sod, 1996), ki temeljijo na razmerju kratkovalovnega (SWIR) in bližnjega IR-kanala (NIR). Slaba stran teh indeksov je, da so primerni samo za uporabo na posnetkih, ki snemajo v kratkovalovnem infrardečem pasu, kot sta na primer Landsat in Sentinel-2. V okviru praktičnega dela te naloge sem uporabila satelitski posnetek WorldView-2 in državni ortofoto, ki snemata le v bližnjem IR-pasu, zato uporaba predlaganega indeksa (Zhang, 2003) pozidanosti ni možna. V nekaterih programskih orodjih (Erdas Imagine in ENVI) je predlagan izračun modificiranega indeksa pozidanosti iz posnetka WorldView (WV-BI, WorldView – Built-up Index), ki temelji na razmerju med robnim modrim (CB) in robnim rdečim (RE) kanalom (Pouncey, Swanson in Hart, 1999; Research Systems, 2004):

$$WV-BI = \frac{CB - RE}{CB + RE}$$

V strokovni literaturi nisem zaznala praktičnih primerov uporabe indeksa WV-BI, vendar sem ga kljub temu vključila v analizo vplivov na objektno klasifikacijo.

Za poudarjanje golih tal so Nobrega in sod. (2006) predlagali indikator golih tal (BGI, bare soil general indicator), ki temelji na produktu tretje komponente analize osnovnih komponent (PCA3) in modrega kanala (B).

$$BGI = \frac{PCA3 * B}{-100000}$$

Za poudarjanje vodnih površin je McFeeters (1996) predlagal normiran diferencialni indeks vode (NDWI, normalized difference water index), izračunan kot razmerje med zelenim in bližnjim infrardečim kanalom.

$$NDWI = \frac{G - IR}{G + IR}$$

Vodne površine imajo v splošnem pozitivne vrednosti indeksa NDWI, medtem ko imajo vegetacija in gola tla nižje, tudi negativne vrednosti.

Opisani indeksi poudarijo osnovne tipe pokrovnosti tal na posnetku: vegetacija, pozidane površine, voda in gola tla. Poudarjanje osnovnih tipov pokrovnosti tal lahko pomembno vpliva na kakovost objektno klasifikacije, zato so bili ti indeksi vključeni v nadaljnjo analizo vplivov na objektno usmerjeno analizo (glej 6. poglavje).

3.2.2 Analiza osnovnih komponent

Vrednosti odboja na različnih kanalih večspektralnih senzorjev so lahko zelo korelirane, kar pomeni, da pri obdelavi satelitskih podob nastopajo nadštevilni podatki. Analiza osnovnih komponent (PCA, principal component analysis) je ena izmed transformacij, ki zmanjša korelacijo med posameznimi kanali, obenem pa poveča informacijsko gostoto. Komponente nove (transformirane) podobe so osnovne komponente. Prednosti transformacije PCA so (Smith, 2002):

- poudarjanje značilnosti na podobi,
- zmanjšanje števila kanalov brez izgube bistvenih informacij in
- zmanjšanje količine podatkov.

Zaradi navedenih prednosti PCA je interpretacija pogosto bolj učinkovita od interpretacije vseh (izvornih) kanalov. Poleg tega zmanjšanje števila kanalov olajša zahtevne in zapletene obdelave podatkov, saj le-ta poteka na bistveno manjši količini podatkov.

Za izračun osnovnih komponent poljubne podobe je treba najprej izračunati kovariančno matriko podobe. Kovariančna matrika Σ je kvadratna matrika reda n , kjer je n število spektralnih kanalov izvorne podobe. Elementi kovariančne matrike so:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{12} & \sigma_2^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1n} & \sigma_{2n} & \cdots & \sigma_n^2 \end{bmatrix}$$

Kjer so:

$\sigma_1^2, \sigma_2^2 \dots$ variance digitalnih vrednosti na posameznem spektralnem kanalu

$\sigma_{12}, \sigma_{1n} \dots$ kovariance digitalnih vrednosti na posameznem kanalu.

Izvendiagonalni elementi oziroma kovariance predstavljajo koreliranost med podatki oziroma vrednostmi na posameznih spektralnih kanalih. Drugi korak v izračunu osnovnih komponent je izračun lastnih vrednosti in lastnih vektorjev kovariančne matrike. Lastne vrednosti

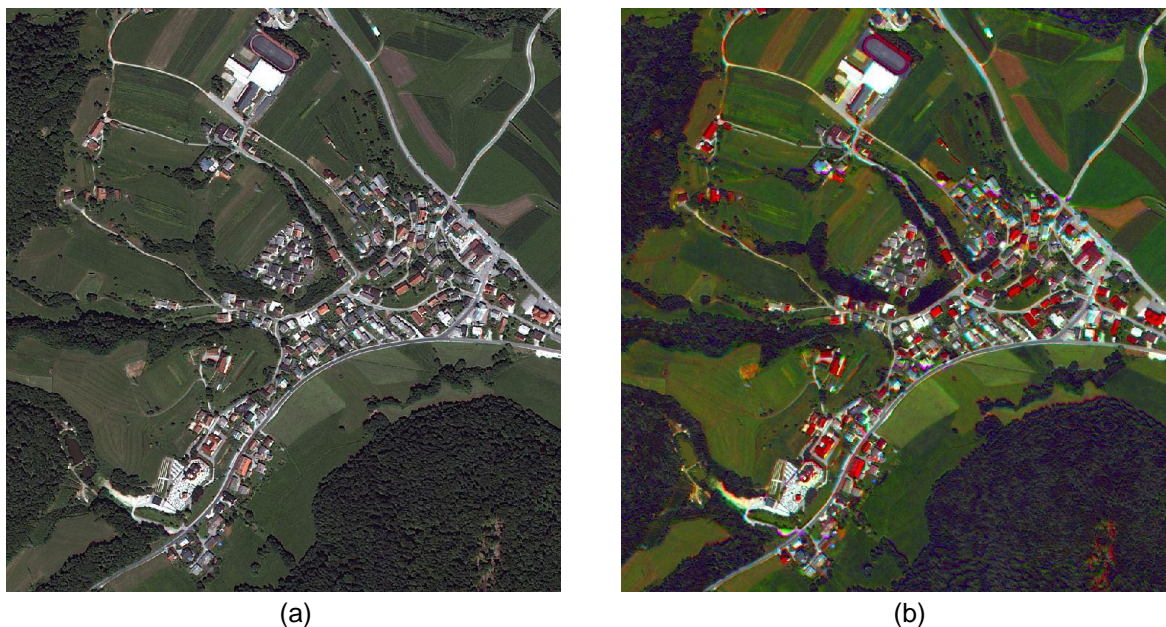
definirajo uteži posameznih osnovnih komponent tako, da prva komponenta predstavlja podatke z najvišjo informacijsko gostoto, zadnja komponenta pa z najnižjo informacijsko gostoto. Lastni vektorji določajo smeri osnovnih komponent, to je smeri z največjim razponom vrednosti (Oštir, 2006).

Vrednosti osnovnih komponent se izračunajo tako, da se podatke izvirne podobe zavrtimo in jih pomnožimo z matriko lastnih vektorjev (Smith, 2002). Koeficienti izračuna vrednosti osnovnih komponent so odvisni od sensorja, območja in časa snemanja. Slabost transformacije PCA je, da so koeficienti izračuna vrednosti osnovnih komponent odvisni od sensorja, časa snemanja in območja snemanja. Temu se lahko izognemo z uporabo Kauth-Thomasove transformacije, ki uporablja enake koeficiente za vse posnetke istega sensorja (neodvisno od območja in časa snemanja).

3.2.3 Dekorelacijski razteg

Transformacija podobe z dekorrelacijskim raztegom temelji na zmanjšanju visoke koreliranosti podatkov večspektralnih podob in izboljšanju kontrasta podobe z raztegom histograma (Gillespie, Kahle in Walker, 1986). V prvem koraku se podoba transformira z analizo osnovnih komponent, nato se za posamezno komponento izvede razteg histograma in končne rezultate ponovno transformira v prostor izvirne podobe.

Rezultat transformacije dekorrelacijskega raztega je podoba z zmanjšano koreliranostjo podatkov in višjo kontrastnostjo (slika 6).



Slika 6: Izvirni posnetek (a) in rezultat transformacije z dekorrelacijskim raztegom (b).

Figure 6: Original image (a) and result of transformation with decorrelation stretch (b).

4 METODE INTERPRETACIJE DALJINSKO ZAZNANIH PODATKOV

Podatki daljinskega zaznavanja so pomemben vir informacij o zemeljskem površju, saj zagotavljajo ažurne podatke o stanju in spremembah v prostoru. Od začetkov snemanja kopnih površin v sedemdesetih letih, s prvim senzorjem za opazovanje Zemlje Landsat, do danes, se je bistveno izboljšala razpoložljivost podatkov. Tudi v smislu povečanja prostorske, spektralne, radiometrične in časovne ločljivosti podatkov. Satelitski posnetki se vse pogosteje uporabljajo za spremljanje stanja in sprememb zemeljskega površja v številnih vedah: prostorsko načrtovanje, zemljiška politika, geodezija, gozdarstvo, kmetijstvo, ekologija, arheologija, varstvo pred naravnimi nesrečami idr. (Oštir, 2006). Vendar satelitski posnetki predstavljajo le »sliko« zemeljskega površja, za praktično uporabo podatkov pa jih je treba obdelati tako, da jih lahko uporabimo v kombinaciji z drugimi podatkovnimi viri, najpogosteje v geografskih informacijskih sistemih (Blaschke, 2010).

Praktično uporaben rezultat interpretacije satelitskih posnetkov predstavlja tematska karta, najpogosteje karta pokrovnosti tal ali karta sprememb pokrovnosti tal. Uveljavljena metoda interpretacije, ki sega v same začetke daljinskega zaznavanja, je vizualna interpretacija. Gre za prikaz enega do treh podatkovnih kanalov satelitskega posnetka (v RGB načinu) na računalniškem zaslonu, ki jih izkušeni operater interpretira in nato digitalizira zahtevane geografske objekte. Metoda je dolgotrajna in subjektivna, zato ne zadošča povečanim zahtevam po rednem in hitrem vzdrževanju prostorskih podatkov v kombinaciji s tehnikami za hiter zajem podatkov in ciljno napovedovanje pomembnih informacij (Lang, 2008). Alternativni pristop vizualni interpretaciji predstavljajo metode samodejne interpretacije (klasifikacije) posnetka. V nadaljevanju sta predstavljeni dve metodi klasifikacije posnetka, in sicer pikselska klasifikacija in objektna klasifikacija.

4.1 Pikselska klasifikacija

Od vzpostavitve prvih satelitskih sistemov za opazovanje Zemlje se je uporabljala pikselska klasifikacija. Metoda temelji na določitvi spektralnega podpisa posameznih razredov in razvrščanju pikslov v izbrane razrede (Veljanovski, Kanjir in Oštir, 2011). Razvita je bila za klasifikacijo satelitskih posnetkov visoke in nizke ločljivosti, zato je uporaba te metode za klasifikacijo visokoločljivostnih posnetkov s prostorsko ločljivostjo, višjo od 1 m (Ikonos, QuickBird, WorldView, idr.), omejena. Vzrok je v razmerju med velikostjo piksla in geografskega objekta, ki je na visokoločljivostnih podobah bistveno manjše kot na visoko ali nizkoločljivostnih podobah (Blaschke, 2010). Glavni pomanjkljivosti, ki zmanjšujeta kakovost pikselske klasifikacije, sta (Liu in Xia, 2010):

- velike variacije spektralnega podpisa posameznega objektnega razreda ter
- neupoštevanje prostorskih, teksturnih in kontekstualnih lastnosti okoliških pikslov pri klasifikaciji.

4.2 Prehod na objektno usmerjeno analizo

Omenjeni pomanjkljivosti pikselske klasifikacije, ki sta bili prisotni že pri klasifikaciji posnetkov visoke in nizke ločljivosti, sta postali z naraščajočo prostorsko ločljivostjo in vse večjo stopnjo podrobnosti objektov na posnetku, vse bolj izraziti. Blaschke in Strobl (2001) sta v provokativni objavi »What's wrong with pixels?« opozorila na pomanjkljivosti pikselske

klasifikacije in predlagala rešitev v spremembi osnovne enote klasifikacije, ki naj ne bi bila več piksel, temveč objekt, sestavljen iz skupine podobnih sosednjih pikslov. Tak pristop uporablja objektno usmerjena analiza. Za razliko od pikselske klasifikacije, ki razvršča piksele v razrede zgolj na podlagi spektralnih vrednosti pikslov, se pri objektno usmerjeni analizi upoštevajo tudi prostorske, teksturne in kontekstualne lastnosti skupine pikslov, ki sestavljajo geografski objekt. Prav te lastnosti so ključne za objektno usmerjeno analizo in glavni razlog za vse bolj razširjeno uporabo te metode.

Poleg zahteve po izboljšanju kakovosti klasifikacije daljinsko zaznanih podatkov so bili ključni dejavniki za prehod iz klasične pikselske na objektno usmerjeno analizo (Veljanovski, Kanjir in Oštir, 2011; Blaschke, 2010):

- naraščanje razpoložljivosti podatkov daljinskega zaznavanja z vse višjo prostorsko, spektralno in časovno ločljivostjo,
- meddržavni programi in sistemi za redno spremljanje stanja zemeljskega površja (npr. Copernicus) ter
- razvoj tehnološke opreme in algoritmov, ki združujejo obdelavo posnetkov in GIS-funkcionalnosti v skupnem objektno usmerjenem okolju.

Naraščajoča razpoložljivost podatkov z visoko ločljivostjo je zagotovo eden izmed temeljnih dejavnikov prehoda. Poleg izboljšanja prostorske in spektralne ločljivosti je za razvoj novih metod zelo pomembna tudi časovna ločljivost. Razpoložljivost podatkov na en teden ali celo nekaj dni je postavila raziskovalce pred nov izziv – razvoj metod za hitro, samodejno in kakovostno obdelavo podatkov. Cilj in hkrati vodilno načelo objektno usmerjene analize je postalo, kako opisati zapleteno in heterogeno vsebino na posnetku na najboljši možni in hiter način ter jo predstaviti v obliki, ki bo čim bolj razumljiva za uporabnike (Blaschke, 2010).

Na drugi strani so uporabniki ključni dejavnik prehoda na nove metode obdelave podatkov. Podatki daljinskega zaznavanja predstavljajo možen odgovor na naraščajoče zahteve po več in boljših informacijah o stanju okolja, skupaj z zahtevami po poročanju o prostorskem razvoju in oceni vplivov okoljske in zemljiške politike (Kuntz in sod., 2014). Za uporabnike pa niso ključnega pomena izvorni podatki daljinskega zaznavanja, temveč razpoložljivost storitev in končnih izdelkov. Razvoj tovrstnih izdelkov in storitev ter visoka razpoložljivost podatkov zahtevajo razvoj metod za samodejno interpretacijo posnetkov in uporabo le-teh v kombinaciji z drugimi prostorskimi informacijami. Objektno usmerjena analiza združuje elemente obdelave posnetkov in GIS-funkcionalnosti, kar je tudi povzročilo širšo uporabo te metode.

Pomemben mejnik v razvoju in razširjenosti uporabe objektno usmerjene analize predstavlja tudi prihod programa eCognition na tržišče (Benz in sod., 2004). Gre za prvi komercialni program, ki je ponudil podporo izvedbi objektno usmerjene analize in uporabi GIS-funkcionalnosti v enem programskem okolju.

4.3 Primerjava pikselske in objektno usmerjene klasifikacije

Izvedenih je bilo več študij o primerjavi pikselske in objektno usmerjene analize. V nadaljevanju so podani izsledki nekaterih ključnih raziskav. Čeprav se je objektna klasifikacija začela v prvi vrsti uporabljati zaradi visokoločljivostnih posnetkov, se je izkazalo, da preseže kakovost rezultatov pikselske klasifikacije tudi na posnetkih nižje ločljivosti. Yan

in sod. (2006) so primerjali kakovost rezultatov pikselske in objektno usmerjene analize na primeru izdelave karte pokrovnosti tal iz satelitskih posnetkov. Analiza, izvedena na satelitskem posnetku visoke prostorske ločljivosti (15 m), je pokazala bistveno višjo skupno natančnost klasifikacije (za 36 %) ter pravilnost in popolnost klasifikacije posameznih razredov v prid objektno usmerjeni analizi. Do podobnih ugotovitev so prišli še Myinta in sod. (2011), ki so dokazali, da je skupna natančnost objektno usmerjene analize pokrovnosti tal v urbanem prostoru za 27 % višja kot s pikselsko klasifikacijo. Oruc, Marangaoz in Buyuksalih (2010) so analizirali primernost uporabe objektno usmerjene analize satelitskega posnetka Landsat. Z objektno usmerjeno analizo so dosegli za 15 % višjo skupno natančnost klasifikacije kot z uporabo pikselske metode. Gao in Mas (2008) sta analizirala vpliv prostorske ločljivosti na kakovost rezultatov. Ugotovila sta, da je prednost objektno usmerjene analize predvsem pri klasifikaciji satelitskih posnetkov zelo visoke do visoke ločljivosti, medtem ko na posnetkih z nizko prostorsko ločljivostjo (100 m in več) uporaba objektno usmerjene analize ne izboljša skupne natančnosti klasifikacije v primerjavi s pikselsko.

Platt in Rapoza (2008) sta primerjavo med obema metodama razčlenila po posameznih komponentah objektno usmerjene analize in tako poskusila ugotoviti ključno komponento, ki zagotavlja višjo kakovost rezultatov v primerjavi s pikselsko klasifikacijo. Ugotovila sta, da niti ena od proučevanih komponent (segmentacija, klasifikator, ekspertno znanje in optimizacija spektralnega prostora) samostojno ne zagotavljajo boljših rezultatov, temveč šele integracija vseh komponent predstavlja prednost objektno usmerjene analize.

5 OBJEKTNO USMERJENA ANALIZA

Objektno usmerjeno analizo je treba razumeti širše kot metodo, katere osnovne enote analize ne predstavlja piksel, temveč skupina podobnih pikslov. Gre za celosten razvoj baze znanja, metodologije in orodij, ki naj bi (nekoč) nadomestili vizualno (ročno) interpretacijo z delno ali popolnoma samodejnimi metodami. Rezultat naj bi bile bolj natančne, ponovljive in manj subjektivne informacije ter zmanjšana količina dela (Hay in Castilla, 2008).

V tehničnem smislu ločimo pri objektno usmerjeni analizi dva osnovna postopka (Blaschke, 2010): segmentacijo in objektno klasifikacijo.

Segmentacija je postopek razmejitve podobe na čim bolj homogene segmente, ki so sestavljeni iz sosednjih pikslov s podobnimi lastnostmi. Za vsak segment so ocenjene tudi njegove lastnosti (spektralne, teksturne, geometrične idr.), ki se uporabijo v drugi fazi objektno usmerjene analize (objektni klasifikaciji). Objektna klasifikacija na podlagi niza pravil razvrsti posamezne segmente v izbrane objektno razrede. Kljub temu, da se na tem mestu obravnava postopek segmentacije in objektno klasifikacije kot ločena postopka, sta medsebojno povezana in se navadno izvajata v cikličnem procesu (Lang, 2008). V nadaljevanju so predstavljeni najpogosteje uporabljeni pristopi objektno usmerjene analize ter oba osnovna koraka – segmentacija in objektna klasifikacija.

5.1 Pristopi objektno usmerjene analize

Možnosti uporabe postopkov segmentacije in objektno klasifikacije v okviru objektno usmerjene analize je več. V nadaljevanju so predstavljeni trije možni pristopi:

- eno-nivojska segmentacija in klasifikacija,
- iterativna eno-nivojska segmentacija (Lang in Langanke, 2006) in
- večnivojska segmentacija in klasifikacija (Burnett in Blaschke, 2003).


5.1.1 Eno-nivojska segmentacija in klasifikacija

Pikselska klasifikacija večnivojsko realnost obravnava samo na eni ravni. Gre za razvrstitev posameznih pikslov v objektno razrede na podlagi spektralnega podpisa. Podobno se lahko tudi objektno usmerjena analiza izvaja na eni ravni in tako ohranja pristop pikselske klasifikacije, spremenjena je le osnovna enota klasifikacije. V tem primeru se oba postopka objektno usmerjene analize, segmentacija in klasifikacija, izvajata ločeno in zaporedoma. Gre za razvrstitev segmentov v objektno razrede na podlagi spektralnih, prostorskih, teksturnih in kontekstualnih lastnosti. Slabost tega koncepta je, da z eno-nivojskim pristopom ni mogoče razpoznati geografskih objektov, ki se lahko na posnetku pojavljajo v različnih merilih (npr. drevo, skupina dreves, park, gozdček, obsežen gozd).

5.1.2 Iterativna eno-nivojska segmentacija in klasifikacija

Alternativo eno-nivojski segmentaciji in klasifikaciji predstavlja iterativna eno-nivojska segmentacija (OLR, ang. One Level Representation), ki sta jo predlagala Lang in Langanke (2008). Gre za iterativen proces izdelave ene ravni segmentacije tako, da končni segmenti pomensko ustrezajo ciljnim objektom analize.

Poleg tega so segmenti na različnih ravneh med seboj topološko urejeni tako, da so meje nadobjektov, objektov in podobjektov med seboj topološko usklajene. Bistvena prednost metode je vertikalna in horizontalna povezanost med segmenti na različnih ravneh (Lang, 2008), kar lahko bistveno izboljša končni rezultat objektno usmerjene analize. V postopku objektno usmerjene analize se lahko poleg spektralnih, prostorskih in kontekstualnih lastnosti segmenta, uporabi tudi podatek o pripadajočih nadobjektih in podobjektih posameznega segmenta. Na ta način je omogočena izvedba klasifikacije po načelu iz velikega v malo. Na sliki 9 (Baatz, Hoffmann in Willhauck, 2008) je prikaz postopnega večanja natančnosti in podrobnosti segmentacije ter klasifikacije od začetnih, približnih objektov do končnih, ciljnih objektov analize.



Slika 9: Postopno povečevanje podrobnosti segmentacije in klasifikacije v okviru objektno usmerjene analize (Veljanovski, Kanjir in Oštir, 2011; Baatz, Hoffmann in Willhauck, 2008).

Figure 9: Gradual increasing segmentation and classification detail in object based image analysis (Veljanovski, Kanjir in Oštir, 2011; Baatz, Hoffmann in Willhauck, 2008).

Glavna slabost pristopa je, da se zaradi topološke usklajenosti mej segmentov napake v segmentaciji prenašajo po ravneh. Poleg tega meje po posameznih ravneh niso ustrezno generalizirane, zato je merilo privzeto in ni specifično za določno raven podrobnosti (Lang, 2008).

5.2 Segmentacija

Segmentacija podobe je proces razdelitve podobe na skupine pikslov, pri čemer je vsak segment homogen in unija dveh sosednjih pikslov ni homogena (Pal in Pal, 1993, Navulur, 2006). Učinkovita segmentacija naj bi posnetek razdelila na objekte tako, kot ga človeški možgani pri vizualni interpretaciji (Hay in Castilla, 2008). Segmentacija predstavlja ključno fazo objektno usmerjene analize (Pal and Pal, 1993; Blaschke, 2010), saj se napake segmentacije prenašajo na nadaljnji postopek objektno usmerjene analize in tako zmanjšujejo natančnost končnih rezultatov (Mesner in Oštir, 2014). Ključne prednosti postopka segmentacije podobe v okviru objektno usmerjene analize so (Hay in Castilla, 2008):

- prehod iz rastrskega v vektorski zapis podatkov,

- možnost uporabe spektralnih, prostorskih, kontekstualnih in teksturnih lastnosti segmentov v postopku objektivne klasifikacije ter
- zmanjšanje podrobnosti na podobi in količine podatkov za nadaljnjo obdelavo v postopku klasifikacije.

Iz vidika formata zapisa podatkov gre pri segmentaciji za prehod iz rastrskega zapisa podatkov v vektorski zapis segmentov, ki nosi podatke izvirnega posnetka. Programi za objektivno usmerjeno analizo imajo različen pristop k obravnavi podatkov o segmentih. Nekateri izvajajo celoten proces rastrsko in omogočajo le izvoz rezultatov v vektorski obliki, drugi pa že med procesom objektivno usmerjene analize operirajo z vektorji.


Bistvena prednost vektorskega formata rezultatov objektivno usmerjene analize je, da omogoča enostavno vključitev v GIS-okolje, kjer se podatki daljinskega zaznavanja lahko uporabijo skupaj z drugimi prostorskimi podatki. Prav zaradi enostavnosti uporabe rezultatov v GIS-okoljih je postopek segmentacije priljubljen pri razvijalcih programske opreme in je vključen v številna brezplačna ter komercialna orodja za obdelavo posnetkov (eCognition, ENVI, ArcGIS, Erdas, Monteverdi, Interimage). Poleg same spremembe formata zapisa podatkov se zaradi združevanja sosednjih pikselov izrazito zmanjša tudi količina podatkov, kar predstavlja nedvomno prednost za nadaljnjo obdelavo.

Druga ključna prednost segmentacije je, da se lahko segmentom dodelijo številne dodatne spektralne, prostorske, kontekstualne in teksturne lastnosti. Prav te so ključne za vso širšo uporabo objektivno usmerjene analize (Blaschke, 2010), saj raziskave (Yana in sod., 2006; Myint in sod. 2011; Platt in Rapoza, 2008) kažejo na bistveno izboljšanje natančnosti rezultatov v primerjavi s pikselo klasifikacijo, ki temelji le na spektralni vrednosti posameznega piksla.

Kljub številnim prednostim postopka segmentacije je treba izpostaviti še tri ključne pomanjkljivosti, ki zahtevajo dodaten razvoj na tem področju. To so (Hay in Castilla, 2008):

- ustreznost stopnje segmentacije,
- zmožnost obdelave (segmentacije) obsežnih podob in
- ponovljivost segmentacije.

V idealnem primeru bi moral biti en geografski objekt predstavljen z enim segmentom, obe meji pa bi morali biti popolnoma usklajeni. V praksi je en geografski objekt sestavljen iz skupine segmentov (prekomerna segmentacija) ali en segment obsega več geografskih objektov (prešibka segmentacija), meja pa ni skladna. Pri prekomerni segmentaciji (slika 10c) je heterogenost med sosednjima segmentoma minimalna in bi morala biti združena v en segment. Nasprotno, pri prešibki segmentaciji lahko en segment obsega dva ali več geografskih objektov in bi ga bilo treba razčleniti (slika 10a). Težava prekomernosti segmentacije je manj težavna kot prešibka segmentacije, saj se »podobni« segmenti lahko naknadno združijo v fazi objektivne klasifikacije, medtem ko je razdelitev segmentov težavnejša. Zato je dobra segmentacija tista, ki je (lahko) malo prekomerna in ni prešibka (Castilla in Hay, 2008). Posledice neustrezne segmentacije (prešibka ali prekomerna) imajo bistven vpliv na kakovost končnih rezultatov objektivno usmerjene analize.



Slika 10: Primer prešibke (a), ustrezne (b) in prekomerne (c) segmentacije.

Figure 10: Example of under- (a), correct (b) and over-segmentation (c).

Kljub temu, da se s segmentacijo zmanjšata stopnja podrobnosti podobe in količina podatkov za nadaljnjo obdelavo, je sam postopek segmentacije velikih večspektralnih posnetkov zelo zahteven, tako za programsko kot tudi za strojno opremo. Težava je z leti zmeraj manjša, saj jo odpravlja hiter razvoj strojne in programske opreme ter novih algoritmov obdelave velikih količin podatkov. Sicer pa so možni pristopi k reševanju te težave razrez posnetka in obdelava manjših območij ter naknadna združitev rezultatov.

5.2.1 Algoritmi segmentacije

Primeri uporabe algoritmov segmentacije v daljinskem zaznavanju segajo v sedemdeseta leta (Dey, Zhang in Zhong 2010). Obsežen pregled razvitih algoritmov do devetdesetih let sta podala Pal in Pal (1993). Ključni preboj na tem področju se je začel z naraščajočo razpoložljivostjo zelo visokoločljivostnih satelitov v devetdesetih (Blaschke, 2010), saj pikselska metoda klasifikacije za te posnetke ni bila več ustrezna. Dodaten pospešek za razvoj na področju segmentacije je bil leta 2000, ko je na trg prišel prvi komercialni program za objektno usmerjeno analizo eCognition (Benz in sod., 2004).

Za segmentacijo so na voljo različni algoritmi, od katerih so nekateri bolj primerni za analizo podob daljinskega zaznavanja, drugi bolj za analize na ostalih področjih (računalniški vid, medicina, nevro-informatika, telekomunikacije ipd.). Predvsem na področju računalniškega vida imajo algoritmi segmentacije daljšo tradicijo, vendar večinoma niso primerni za obdelavo posnetkov daljinskega zaznavanja. Razlogi so predvsem (Veljanovski, Kanjir in Oštir, 2011; Schiewe, 2002):

- posnetki daljinskega zaznavanja obsegajo bistveno večja območja (velike količine podatkov),
- geografski objekti so zelo heterogeni, nimajo jasnih meja in
- posnetki so zajeti v različnih pogojih (čas snemanja, osončenost, stanje atmosfere).

V nadaljevanju se osredotočam na algoritme za segmentacijo daljinsko zaznanih podob. Dey, Zhang in Zhong (2010) ločijo tri kategorizacije algoritmov:

- na podlagi pristopa k objektni analizi, t. j. od spodaj navzgor (angl. bottom-up) in od zgoraj navzdol (angl. top-down),
- na podlagi mer homogenosti, ki se uporabijo za združevanje pikslov v segmente, in

- na podlagi načina tvorbe segmentov.

Kategorizacija na podlagi pristopa objektno usmerjene analize loči slikovno voden pristop (od spodaj navzgor) in modelno voden pristop (od zgoraj navzdol) (Guindon, 1997). Pri slikovno vodenem pristopu se tvorijo segmenti na podlagi združevanja pikslov, pri modelnem pristopu gre za razčlenitev posnetka na segmente na podlagi kriterija homogenosti (Benz in sod., 2004).

Druga raven kategorizacije se loči glede na mero homogenosti, ki se uporabi pri tvorbi segmentov. Mere homogenosti temeljijo na naslednjih spektralnih (barva oziroma ton), prostorskih, teksturnih, kontekstualnih in časovnih lastnostih (Richards in Jia, 2006).

Tretja raven kategorizacije loči segmente glede na način tvorbe segmentov. Pri algoritmih za segmentacijo daljinsko zaznanih podatkov se najpogosteje uporabljata naslednja načina (Dey, Zhang in Zhong, 2010):

- razraščanje območij (ang. region growing) in
- na osnovi robov (ang. edge –based).

Pri algoritmih, ki temeljijo na razraščanju območij, gre za postopno združevanje podobnih pikslov v segmente ob upoštevanju treh kriterijev homogenosti: homogenost znotraj segmenta, ločenost od sosednjih elementov in homogenost oblike (Veljanovski, Kanjir in Oštir, 2011), medtem, ko gre pri algoritmih na osnovi robov za iskanje gradientov na podobi. Tako odkriti gradienti na podobi predstavljajo meje segmentov, vendar se za segmentacijo optično daljinsko zaznanih posnetkov najpogosteje uporabljajo algoritmi, ki temeljijo na razraščanju območij (Lang, 2008). Enega od teh, večnivojski algoritem (ang. multiresolution algoritem), sem uporabila tudi v praktičnem delu naloge in je v nadaljevanju podrobneje predstavljen.

5.2.1.1 Večnivojski algoritem

Glede na tri-nivojsko kategorizacijo algoritmov po Dey, Zhang in Zhong (2010) se večnivojski algoritem uvršča med algoritme modelno ali slikovno vodenega pristopa (odvisno od načina izvedbe objektno usmerjene analize). Pri razvoju algoritma sta Baatz in Schäpe (2000) težila k razvoju algoritma, ki bi bil čim bolj univerzalen za uporabo tako na različnih vrstah podatkov daljinskega zaznavanja kot tudi za različne namene segmentacije. Tvorba segmentov z načinom razraščanja območij temelji na spektralni (h_{barva}) in oblikovni (h_{oblika}) homogenosti skupine pikslov. Splošna enačba za izračun homogenosti segmenta je:

$$h = (1 - w_{barva}) \cdot h_{barva} + w_{oblika} \cdot h_{oblika}$$

Kjer je:

h_{barva} ... spektralna homogenost segmenta,

h_{oblika} ... homogenost oblike segmenta,

w_{barva} ... utež spektralnih vrednosti na izračun homogenosti in

w_{oblika} ... utež oblike na izračun homogenosti.

Spektralna homogenost segmenta (h_{barva}) je izračunana kot utežna vsota standardnih odklonov σ_k digitalnih vrednosti posameznega kanala:

$$h_{barva} = \sum_{k=1}^m w_k \cdot \sigma_k$$


Homogenost oblike segmenta (h_{oblika}) je izračunana kot utežna vsota homogenosti kompaktnosti ($h_{kompaktnost}$) in gladkosti ($h_{gladkost}$):

$$h_{oblika} = (1 - w_{kompaktnost}) \cdot h_{gladkost} + w_{kompaktnost} \cdot h_{kompaktnost}$$

Kompaktnost segmenta je izračunana kot razmerje med obsegom segmenta l in kvadratnim korenem površine segmenta v pikslih n , gladkost pa kot razmerje med obsegom segmenta l in obsegom orisanega pravokotnika.

Postopek segmentacije z večnivojskim algoritmom se začne z izbiro niza začetnih segmentov (v prvem koraku en segment predstavlja en piksel), ki se združujejo s sosednjimi piksli tako, da je homogenost novega segmenta čim nižja. Postopek se ponavlja, dokler segment ne doseže maksimalne vrednosti homogenosti, ki jo uporabnik določi s parametrom merilo. Tako zgrajen segment predstavlja končni segment. Pri segmentaciji z večnivojskim algoritmom je treba poleg parametra merilo določiti še vrednosti parametrov utež barve, oblike, kompaktnosti in gladkosti. S parametrom utež barve in oblike se določi, ali ima pri tvorbi segmentov večji vpliv homogenost digitalnih vrednosti (barve) ali homogenost končne oblike. S parametroma utež kompaktnosti in gladkosti se določi, ali ima pri tvorbi segmentov večji vpliv gladkost ali kompaktnost končnega segmenta.

Primer segmentacije podobe z večnivojskim algoritmom z maksimalnim (slika 11a), minimalnim (slika 11b) ter uravnoteženim vplivom barve in oblike na tvorbo segmentov (slika 11c). Rezultat segmentacije z maksimalnim vplivom barve ($w_{barve}=1$) so sicer zelo homogeni segmenti, vendar so geografski objekti sestavljeni iz velikega števila segmentov, oblika pa je zelo nepravilna. Nasprotno so rezultat segmentacije z minimalnim vplivom barve ($w_{barve} = 0,1$) spektralno zelo nehomogeni segmenti in rezultat je prešibka segmentacija. Z uravnoteženim vplivom barve in oblike ($w_{barve} = w_{oblike} = 0,5$) je na prikazanem območju dosežena najbolj ustrezna segmentacija. Segmenti so homogeni, meja geografskih objektov je usklajena z mejo segmentov in število segmentov je bistveno manjše kot v primeru a.



Slika 11: Primer segmentacije podobe z večnivojskim algoritmom z maksimalnim (a), minimalnim (b) in uravnoteženim (c) vplivom barve na tvorbo segmentov.

Figure 11: Example of satellite image segmentation using multiresolution algorithm with maximum (a), minimum (b) and balanced (c) impact of color on segmentation creation.

5.2.2 Lastnosti segmentov

V fazi objektne klasifikacije se segmenti razvrstijo v objektne razrede na podlagi njihovih lastnosti. Ločimo naslednje, najpogosteje uporabljene skupine lastnosti (Navulur, 2007):

- geometrične,
- spektralne,
- teksturne,
- attribute razmerij spektralnih kanalov,
- kontekstualne in
- časovne lastnosti.

Nabor podatkov, s katerimi je opisana posamezna skupina lastnosti segmenta, je lahko zelo velik. Primeri nekaterih najpogosteje uporabljenih lastnosti segmentov so podani v preglednici 1.

Preglednica 1: Pregled najpogostejših lastnosti segmentov, ki se uporabljajo za klasifikacijo segmentov.

Table 1: Review of most common attributes of segments used in object-based classification.

Skupina lastnosti	Lastnost segmenta
Geometrične lastnosti	površina, dolžina, širina, obseg, razmerje med dolžino in širino, indeks oblike, asimetričnost in usmerjenost, povprečne, minimalne in maksimalne vrednosti koordinat
Spektralne lastnosti	srednja vrednost in standardni odklon posameznega kanala, svetlost, razmerje med posameznimi kanali, ekstremne spektralne vrednosti

Skupina lastnosti	Lastnost segmenta
Teksturane lastnosti	usmerjenost in asimetrija podobjektov, homogenost, kontrast, entropija
Kontekstualne lastnosti	relativna meja, površina, oddaljenost, obstoj, površina, število, relativna površina

5.2.3 Ocena kakovosti segmentacije

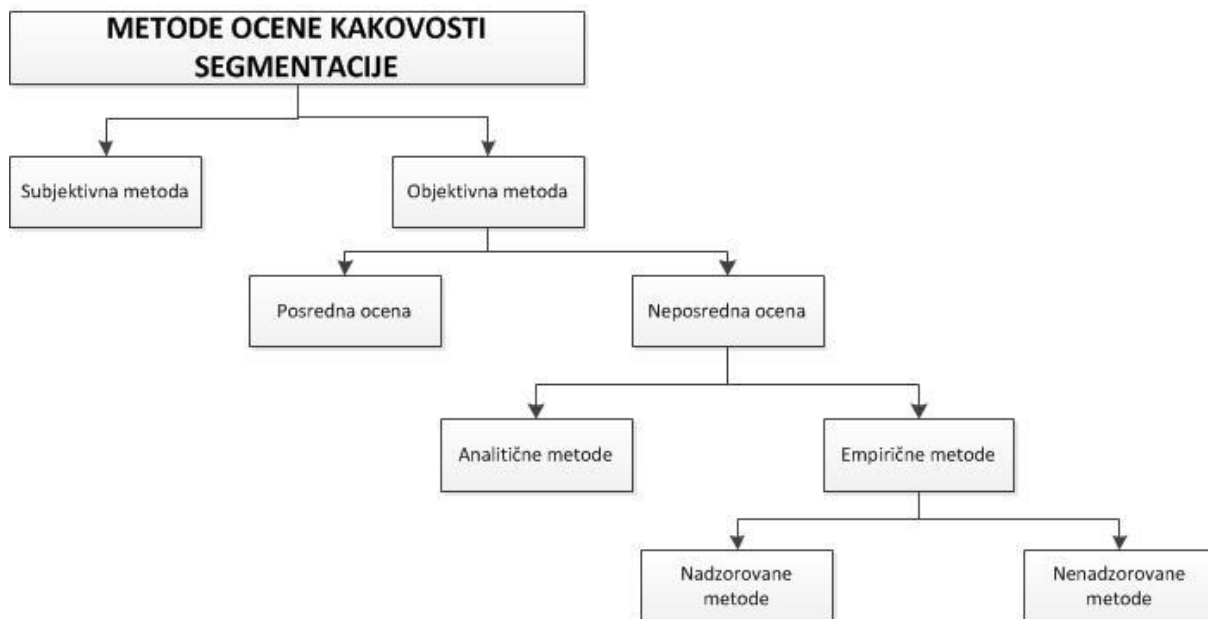
Ocena kakovosti izvedene segmentacije pred nadaljnjim postopkom objektne klasifikacije je zelo pomembna, saj slabi rezultati segmentacije lahko vodijo neposredno v rezultate klasifikacije nižje kakovosti. Metode ocenjevanja kakovosti se lahko uporabijo za (Zhang, Fritz in Goldman, 2008):

- oceno kakovosti tvorjenih segmentov glede na namen uporabe objektno usmerjene analize,
- izbiro optimalnega algoritma segmentacije izbrane podobe in
- izbiro optimalnih nastavitev parametrov izbranega algoritma.

Ustreznost in kakovost izvedene segmentacije sta lahko ocenjeni na podlagi različnih metod. V nadaljevanju je podan pregled najpogosteje uporabljenih metod ocenjevanja kakovosti rezultatov segmentacije, s poudarkom na nadzorovani metodi, ki je uporabljena v praktičnem delu naloge.

5.2.3.1 Metode ocenjevanja kakovosti segmentacije

Metode ocenjevanja kakovosti segmentacije so v osnovi zelo različne in jih lahko razdelimo na podlagi petih različnih pristopov, tako kot je prikazano na sliki 12 (Zhang, Fritz in Goldman, 2008). V nadaljevanju je podan pregled posameznih pristopov.



Slika 12: Pregled metod ocene kakovosti segmentacije (Zhang, Fritz in Goldman, 2008).

Figure 12: Overview of segmentation quality evaluation methods (Zhang, Fritz in Goldman, 2008).

Subjektivna ocena je najpogosteje uporabljena metoda, ki temelji na vizualni oceni rezultatov s strani operaterja. Ocena je subjektivna, saj se od operaterja do operaterja lahko zelo razlikuje. Za pridobitev čim bolj objektivne ocene bi moralo pri ocenjevanju sodelovati večje število operaterjev (ocenjevalcev), končna ocena pa bi morala biti v skladu z natančno opredeljenimi navodili za ocenjevanje (Zhang, Fritz in Goldman, 2008).

Pri objektivnem ocenjevanju ločimo posredno in neposredno ocenjevanje. Pri posrednem ocenjevanju se ocenjuje vpliv različnih metod segmentacije na celoten sistem, pri neposrednem pa se ocenjuje vpliv segmentacije na končne rezultate.

Z analitičnimi metodami segmentacije se ocenjuje algoritem segmentacije neodvisno od rezultatov. Ocena se pridobi na podlagi določenih lastnosti algoritmov segmentacije, kot so strategija obdelave, kompleksnost obdelave, učinkovitost virov in ločljivost segmentacije. V nasprotju z analitičnimi metodami pa se z empiričnimi metodami ocenjuje segmentacija na podlagi rezultatov izvedene segmentacije. V okviru empiričnih metod ločimo nenadzorovane in nadzorovane metode.

Z nenadzorovanimi metodami se ocenjuje kakovost segmentacije zgolj na podlagi rezultatov segmentacije, kar omogoča hitro in neodvisno oceno rezultatov, saj ni treba pridobivati podatkov o referenčnem sloju segmentacije. Ocena temelji na skladnosti rezultatov segmentacije z nizom lastnosti segmentirane podobe, tako kot jo prepoznajo človeški možgani.

Nadzorovane metode ocenjevanja temeljijo na primerjavi odstopanj med segmenti in referenčnim slojem podatkov. V okviru analize rezultatov segmentacije se v splošnem ocenjujejo obstoj, skladnost oblike in položajno odstopanje med mejo referenčnega objekta in objekta, pridobljenega s postopkom segmentacije podobe (Zhang, Fritz in Goldman, 2008).

Priprava referenčnega sloja podatkov predstavlja najbolj zahteven del ocene rezultatov segmentacije z nadzorovano metodo. Način priprave je odvisen od:

- obsega referenčnega sloja (izbrani objektni razredi ali celotna podoba) in od
- zahtevane objektivnosti pripravljenega referenčnega sloja.

Referenčni sloj podatkov se lahko pridobi s fotointerpretacijo posameznih objektov, ki pripadajo določenemu razredu (Coillie in sod., 2010), ali celotno podobo (Albrecht, Lang in Holbling, 2010). Prvi način se navadno uporabi pri ocenjevanju kakovosti segmentacije določenega objektnega razreda (npr. stavbe), drugi način pri ocenjevanju kakovosti segmentacije vseh objektnih razredov.

Ker je priprava referenčnega sloja podatkov izključno ročna, so pripravljene podatki odvisni od operaterja in s tem subjektivni. Za pripravo čim bolj objektivnega referenčnega sloja podatkov je priporočljivo, da se v ročno segmentacijo vključi večje število operaterjev. Izmed množice ročno zajetih objektov na podobi se nato izloči tiste z največjim povprečnim odstopanjem in izmed izbranih izračunamo srednjo vrednost, ki predstavlja referenčni sloj podatkov za ocenjevanje rezultatov segmentacije (Albrecht, Lang in Holbling, 2010). Prednost tako pripravljenega referenčnega sloja podatkov je neodvisnost rezultatov od operaterja, slabost pa dolgotrajna in zahtevna priprava podatkov.

5.2.3.2 Cenilke kakovosti segmentacije

Prvi korak v izračunu vrednosti cenilk kakovosti segmentacije predstavlja identifikacija segmentov, ki sestavljajo en referenčni objekt. Unija identificiranih segmentov sestavlja testni objekt. Lastnosti testnega objekta in pripadajočega referenčnega objekta so osnova za izračun cenilk kakovosti segmentacije. Identifikacija segmentov, ki pripadajo posameznemu referenčnemu objektu, se lahko izvede na več načinov. V strokovni literaturi se najpogosteje uporabljata dva načina. To sta:

- identifikacija segmentov, katerih centriodi ležijo znotraj oboda referenčnega objekta (Coillie in sod., 2010), in
- identifikacija segmentov, katerih površina se za več kot 50 % prekriva s površino referenčnega objekta (Meinel in Herold, 2000; Neubert in Herold, 2008).

Za oceno kakovosti segmentacije se najpogosteje uporabljajo cenilke, ki ocenjujejo obstoj, skladnost oblike, položajno odstopanje in stopnjo ustreznosti segmentacije. Najpogosteje uporabljene cenilke za oceno kakovosti segmentacije so (Coillie in sod., 2010; Neubert in Herold, 2008):

- povprečno število segmentov, ki sestavlja testni objekt,
- povprečno odstopanje površine testnega in referenčnega objekta,
- povprečno odstopanje obsega testnega in referenčnega objekta,
- povprečno odstopanje indeksov oblike (SI, shape index),
- povprečno odstopanje indeksa prileganja površine (AFI, area fit index),
- povprečno položajno odstopanje med mejo testnega in referenčnega objekta ter
- skupna ocena kakovosti segmentacije (nDQM, normalized weighted segmentation quality measure).

Število segmentov, ki sestavljajo testni objekt, je cenilka za oceno stopnje ustreznosti segmentacije. Veliko število segmentov kaže na prekomerno segmentacijo, malo število segmentov v kombinaciji z drugimi cenilkami pa na prešibko segmentacijo.

Razmerje površin je cenilka za oceno skladnosti površin referenčnega in testnega objekta. Izračuna se kot odstopanje med površino referenčnega ter testnega objekta in je izraženo v odstotkih.

Razmerje obsegov je cenilka za oceno skladnosti oblike referenčnega in testnega objekta. Izračuna se kot odstopanje med obsegom referenčnega ter testnega objekta in je izraženo v odstotkih.

Razmerje indeksov oblike je cenilka za oceno skladnosti gladkosti meje referenčnega in testnega objekta. Indeks oblike (SI) je določen z razmerjem med obsegom objekta (o) in štirikratnikom korena površine (P) vrisanega kvadrata.

$$SI = \frac{o}{4 \cdot \sqrt{P}}$$

Razmerje indeksov oblike je izračunano kot odstopanje med indeksom oblike referenčnega in testnega objekta ter je izraženo v odstotkih.

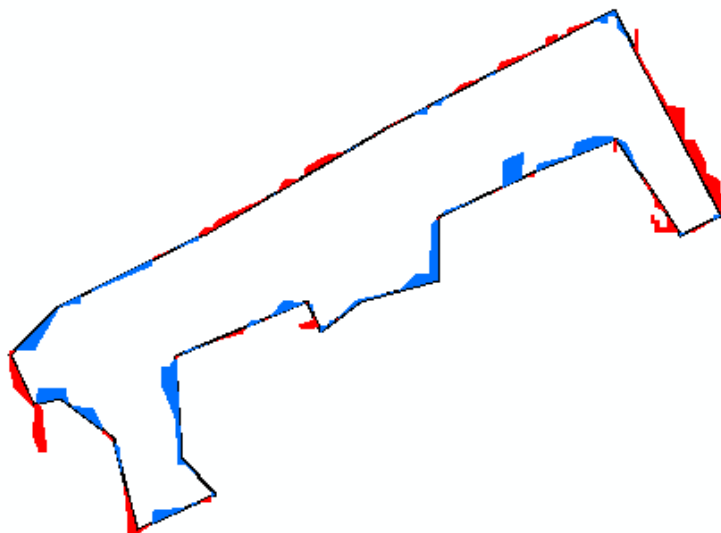
Indeks prileganja površine AFI je cenilka za oceno optimalnosti stopnje segmentacije podobe. Indeks AFI je izračunan kot razmerje površine referenčnega objekta in segmenta z največjo površino (Neubert in Herold, 2008):

$$AFI = \frac{P_{ref.objekta} - P_{najv.segmenta}}{P_{ref.objekta}}$$

Če je vrednost indeksa AFI enaka nič, je segmentacija referenčnega objekta optimalna. V tem primeru pripada referenčnemu objektu testni objekt, ki je sestavljen iz enega segmenta, njuni površini sta popolnoma enaki.

Položajno odstopanje je odstopanje med mejo referenčnega objekta in pripadajočega testnega objekta. Coillie in sod. (2008) ter Neubert in Herold (2008) predlagajo oceno položajnega odstopanja z deležem pikslov testnega objekta, ki ležijo znotraj referenčnega objekta, povečanega z odmikom (ang. buffer zone) 1, 2 in 5 pikslov. Položajno odstopanje je ocenjeno z vrednostjo odmika, pri katerem večina testnega objekta leži znotraj povečanega referenčnega objekta.

Alternativni pristop k izračunu položajnega odstopanja sta predlagala Radoux in Defourny (2008), in sicer na podlagi grafičnega preseka referenčnega in testnega objekta. Presek sestavljajo precenjene oziroma pozitivne napake (ang. comission error) in podcenjene oziroma negativne napake (ang. omission error). Na sliki 13 so prikazane podcenjene napake z modro barvo in precenjene z rdečo barvo.



Slika 13: Precenjene (rdeče) in podcenjene (modre) napake meje testnega in referenčnega geografskega objekta.

Figure 13: Commission (red) and omission (blue) error between test object boundary and reference geographic object boundary.

Radoux in Defourny (2008) predlagata, da se za izračun povprečnega položajnega odstopanja iz skupnega odstopanja meje odstrani groba napaka. Groba napaka je izračunana kot vsota precenjenih in podcenjenih napak (upoštevajoč predznak). Od skupne napake (vsota precenjenih in podcenjenih napak brez upoštevanja predznaka) se nato odšteje grobi pogrešek in rezultat so le sistematične napake, ki so osnova za izračun položajnega odstopanja. Na podlagi vrednosti sistematične napake (v površinskih enotah), ki se deli z obsegom referenčnega objekta, se izračuna povprečno položajno odstopanje meje segmenta v dolžinskih enotah.

V praksi se izkaže, da lahko posamezne cenilke kakovosti segmentacije kažejo nasprotujoče si rezultate. Cenilka število segmentov lahko kaže na zelo kakovostno segmentacijo, vendar odstopanje površin in položajno odstopanje kažeta ravno nasprotno. Zato je treba pri vrednotenju cenilk kakovosti za skupno oceno kakovosti segmentacije upoštevati vse cenilke kakovosti hkrati. Coillie in sod. (2010) za skupno oceno kakovosti segmentacije predlagajo indeks nDQM (normalized weighted segmentation quality measure), ki je določen kot normirana utežna vsota vrednosti posameznih cenilk. Prednost uporabe tega indeksa je, da omogoča splošno oceno kakovosti segmentacije glede na vse uporabljene cenilke in omogoča enostavno vrednotenje med različnimi realizacijami segmentacij. Slaba stran indeksa pa je, da je izračunan kot utežna vsota cenilk, izraženih v različnih merskih enotah (cenilke razmerij v odstotkih, položajno odstopanje v metrih, število segmentov kot celo število ...). Ključno vlogo pri kakovosti določitve indeksa zato igra določitev uteži za posamezne cenilke. Coillie in sod. (2010) predlagajo uteži in optimalne vrednosti za izračun skupne ocene kakovosti segmentacije obrisov streh (preglednica 2).

Preglednica 2: Uteži in optimalne vrednosti za izračun skupne ocene kakovosti segmentacije obrisov streh (Coillie in sod., 2010).

Table 2: User defined weight optima and settings of normalized weighted segmentation quality measure for the case of roofs segmentation (Coillie in sod., 2010).

	Število segmentov	Odstopanje površine	Odstopanje obsega	Odstopanje indeksa oblike	Položajno odstopanje
Optimalna vrednost	10	0	0	0	0
Utež	0.01	0.01	0.001	0.001	0.002

5.3 Objektna klasifikacija

V postopku objektne klasifikacije segmente razvrstimo v objektne razrede na podlagi niza pravil, ki določajo pripadnost posameznih segmentov objektnim razredom. Vzpostavitev pravil temelji na bazi znanja o spektralnih, geometričnih, teksturnih in drugih lastnostih posameznega objektne razreda. Pri klasični pikseli klasifikaciji se pravila vzpostavijo z določitvijo učnih vzorcev, pri objektni klasifikaciji pa lahko tudi z določitvijo mejnih vrednosti posameznih lastnosti segmentov ali z uporabo mehke logike (določitev poljubne funkcije pripadnosti objektnemu razredu). Razvrstitev segmentov v objektne razrede na podlagi določenih pravil se lahko izvede z različnimi metodami. Najpogosteje se uporabljajo (Veljanovski, Kanjir in Oštir, 2011):

- parametrični in neparametrični statistični klasifikatorji,
- odločitvena drevesa,
- mehka logika.

Parametrični in neparametrični statistični klasifikatorji dodelijo pripadnost posameznega segmenta objektnemu razredu na podlagi izbrane metode, na primer (Oštir, 2006): metode najmanjše razdalje, metode najbližjega sosedu, metode največje verjetnosti idr. V okviru analize vplivov, izvedene v tej nalogi, je objektna klasifikacija izvedena z določitvijo učnih vzorcev in določitvijo pripadnosti objektnemu razredu z metodo najbližjega sosedu. Metoda razvrsti segment v objektni razred, katerega vzorec je najbližji segmentu.

5.3.1 Ocena kakovosti objektne klasifikacije

Za oceno kakovosti objektne klasifikacije se lahko uporabijo enaki pristopi kot pri pikseli klasifikaciji, in sicer s klasifikacijsko matriko napak. Drugi možni pristop za oceno kakovosti segmentacije temelji na verjetnosti pripadnosti posameznega segmenta objektnemu razredu. V nadaljevanju so podrobneje predstavljene cenilke kakovosti objektne klasifikacije, ki so izračunane na podlagi obeh pristopov.

5.3.1.1 Klasifikacijska matrika napak

Ocena natančnosti na podlagi klasifikacijske matrike napak poda oceno pravilnosti razdelitve segmentov v klasifikacijske razrede na podlagi primerjave z referenčnim slojem podatkov. Referenčni sloj podatkov sestavljajo vzorci za posamezen objektni razred, ki so lahko pridobljeni s terensko izmero, iz obstoječe baze podatkov, s fotointerpretacijo ali z drugimi metodami zajema podatkov (Zhang in Goodchild, 2002).

S primerjavo referenčnega sloja podatkov, t. j. pravih vrednosti, in rezultatov klasifikacije se izračuna klasifikacijska matrika napak, ki poda stopnjo pravilnosti in popolnosti rezultatov objektne klasifikacije. V klasifikacijski matriki napak so podatki o številu pravilno in lažno klasificiranih osnovnih enot po posameznih objektnih razredih. Pri pikseli klasifikaciji je

osnovna enota piksel, pri objektni klasifikaciji pa je to lahko piksel, segment ali točka. Elementi klasifikacijske matrike napak so podani v preglednici 3.

Preglednica 3: Klasifikacijska matrika napak.

Table 3: Confusion matrix.

Klasifikacija	Referenčni podatki					
	Razred 1	Razred 2	Razred 3	...	Razred n	
Razred 1	a_{11}	a_{12}	a_{13}	...	a_{1n}	
Razred 2	a_{21}	a_{22}	a_{23}	...	a_{2n}	
...	
Razred n	a_{n1}	a_{n2}	a_{n3}	...	a_{nn}	

Če je osnovna enota klasifikacije piksel je v klasifikacijski matriki napak v stolpcih podano število referenčnih pikslov, v vrsticah število klasificiranih pikslov po posameznih razredih. Diagonalni elementi klasifikacijske matrike (a_{ii}) predstavljajo število pravilno klasificiranih pikslov posameznega razreda. Izvendiagonalni elementi (a_{ik}) predstavljajo število lažno klasificiranih pikslov. To je število pikslov objektnega razreda i , ki je lažno klasificirano kot razred k . Elementi klasifikacijske matrike napak so osnova za izračun različnih cenilk kakovosti:

- izdelovalčeva natančnost (PA, producer accuracy),
- uporabnikova natančnost (UA, user accuracy),
- skupna natančnost (OA, overall accuracy) in
- koeficient Kappa (κ , kappa coefficient).

Izdelovalčeva natančnost je mera za oceno popolnosti klasifikacije posameznega razreda. Izračuna se kot razmerje pravilno klasificiranih pikslov razreda i (diagonalni element a_{ii}) in vsote vseh pikslov referenčnih objektov, ki pripadajo razredu i (vsota elementov i -tega stolpca).

$$PA_i = \frac{a_{ii}}{\sum_{k=1}^n a_{ki}}$$

Uporabnikova natančnost je mera za oceno pravilnosti klasifikacije posameznega razreda in predstavlja pomembno informacijo za uporabnika klasificiranih podatkov. Poda oceno verjetnosti, da klasificirana vrednost v razred i dejansko pripada temu razredu (Zhang in Goodchild, 2002). Izračuna se kot razmerje pravilno klasificiranih pikslov razreda i (diagonalni element a_{ii}) in vsote vseh klasificiranih pikslov, ki pripadajo razredu i (vsota elementov i -te vrstice).

$$UA_i = \frac{a_{ii}}{\sum_{k=1}^n a_{ik}}$$

Izdelovalčeva in uporabnikova natančnost sta meri natančnosti za oceno popolnosti in pravilnosti klasifikacije posameznih razredov. Za splošno oceno klasifikacije pa se uporabljata skupna natančnost in Kappa koeficient. Skupna natančnost določa splošno

pravilnost klasifikacije, in sicer kot verjetnost, da je preučevano območje na podobi pravilno klasificirano. Izračuna se kot razmerje med vsoto diagonalnih elementov (vsota vseh pravilno klasificiranih pikslov) in vsoto vseh elementov v matriki napak (vsota vseh pikslov referenčnega sloja podatkov).

$$OA = \frac{\sum_{k=1}^n a_{kk}}{\sum_{i,k=1}^n a_{ik}}$$

Slabost skupne natančnosti, izračunane na podlagi elementov klasifikacijske matrike napak, je, da temelji zgolj na pravilnosti in popolnosti klasifikacije na učnem vzorcu, medtem ko ne poda ocene natančnosti klasifikacije naključnega območja, to je na območjih, za katere ni na razpolago referenčnih podatkov. Zato je bil za splošno oceno natančnosti klasifikacije predlagan Kappa koeficient, ki se izračuna kot razmerje med preučevano in popolnoma naključno klasifikacijo (Zhang in Goodchild, 2002).

$$\kappa = \frac{P_0 - P_e}{1 - P_e},$$

kjer je:

P_0 ... verjetnost pravilnosti preučevane klasifikacije, ki je enaka skupni natančnosti (OA)

P_e ... verjetnost pravilnosti naključne klasifikacije.

$$P_e = \sum_{k=1}^n \frac{\sum_{i=1}^n a_{ki} \cdot \sum_{i=1}^n a_{ik}}{\sum_{i,j=1}^n a_{ij}}$$

Koeficient κ zavzame vrednosti med 0 in 1, kjer vrednost 0 pomeni, da z naključno klasifikacijo pridobimo enake rezultate kot z uporabljenno klasifikacijo. Vrednost npr. 0,53 pa pomeni, da je uporabljena klasifikacija za 53 % višja od naključne.

5.3.1.2 Verjetnost pripadnosti segmentov posameznim razredom

Ocena natančnosti se lahko določi tudi na podlagi verjetnosti pripadnosti segmentov posameznim razredom. Pri klasifikaciji na podlagi pravil in mehke logike se določi funkcija verjetnosti pripadnosti segmentov posameznim razredom. Nato se vsakemu segmentu izračuna verjetnost pripadnosti posameznemu razredu. Segment je klasificiran v razred z največjo verjetnostjo pripadnosti. Na podlagi verjetnosti pripadnosti posameznim razredom se izračunajo naslednje mere natančnosti (Trimble, 2014):

- srednja vrednost, standardni odklon in ekstremi verjetnosti pripadnosti segmentov posameznim razredom ter
- razmerje med drugo in prvo najvišjo verjetnostjo pripadnosti segmentov posameznemu razredu.

Bistvena prednost uporabe teh mer natančnosti v primerjavi s klasifikacijsko matriko napak je možnost ocene natančnosti objektno usmerjene analize brez referenčnega sloja podatkov. Slabost pa, da ne podajo informacije o popolnosti in pravilnosti klasifikacije glede na dejanske geografske objekte v naravi. Zato je smiselno, da te cenilke kakovosti služijo analitiku pri razvoju metodologije. Končno oceno natančnosti je bolje podati s klasifikacijsko matriko napak, na podlagi katere se lahko oceni stopnja skladnosti klasificirane podobe in resničnosti.

5.4 Pregled metodologije uporabe objektno usmerjene analize na področju urbane rabe prostora

V okviru praktičnega dela naloge sem se osredotočila na razpoznavo sprememb pozidanih površin, saj so te spremembe zelo pogoste, trajne in med najbolj obremenilnimi spremembami za prostor in okolje. V nadaljevanju podajam kratek pregled metodologije uporabe objektno usmerjene analize za razpoznavo pozidanosti tal. Nabor primerov aplikativne uporabe objektno usmerjene analize na tem področju je zelo obsežen. Na tem mestu bom izpostavila le nekatere, ki so se osredotočile na pokrovnost tal urbanega prostora, predvsem na pozidane površine.

An, Zhang in Xiaou (2007) so predlagali metodologijo za klasifikacijo sprememb pokrovnosti urbanega prostora z uporabo veččasovnih posnetkov in hierarhične mreže segmentov. Določitev sprememb pokrovnosti med pozidanimi in nepozidanimi površinami temelji na primerjavi klasificiranih večspektralnih posnetkov ter analizi teksturnih in spektralnih lastnosti segmentov. Avtorji navajajo tri ključne prednosti objektno usmerjene analize v primerjavi s tradicionalnimi metodami klasifikacije: višja natančnost klasifikacije posameznih posnetkov ter nižja stopnja odvisnosti končnih rezultatov od radiometričnih in geometričnih napak posameznih posnetkov.

Su in sod. (2008) so proučevali možnosti uporabe teksturnih in lokalnih statističnih prostorskih lastnosti segmentov za izboljšanje natančnosti klasifikacije urbanega prostora na podlagi zelo visokoločljivostnih posnetkov. Z uporabo različnih indeksov GLCM (Gray Level Co-Occurrence Matrix index) in Moranovega prostorskega statičnega indeksa so izboljšali natančnost klasifikacije za 7 %. Salehi in sod. (2012) so za klasifikacijo pokrovnosti tal uporabili hierarhično mrežo segmentov in klasifikacijo na podlagi odločitvenega drevesa. Za podrobno klasifikacijo pokrovnosti na področju urbanega prostora (ceste, zgradbe in parkirne površine) so uporabili digitalni model površja in dosegli več kot 90 % skupno natančnost klasifikacije.

Shackelford in Davis (2003) sta proučevala vpliv metode mehke logike na izboljšanje natančnosti klasifikacije urbanih površin v primerjavi s pikselsko metodo klasifikacije. Z uporabo spektralnih, prostorskih in teksturnih lastnosti segmentov ter razmerja med dolžino in širino segmenta so dosegli od 8 do 11 % višjo natančnost kot s pikselsko klasifikacijo.

Thomas, Hendrix in Congalton (2003) so primerjali tri metode določitve neprepustnih (pozidanih) in prepustnih površin (npr. vegetacija, gola tla) na zelo visokoločljivostnih posnetkih: kombinirano nadzorovano in nenadzorovano pikselsko klasifikacijo, pikselsko klasifikacijo z uporabo dodatnih prostorskih podatkov ter objektno klasifikacijo z uporabo odločitvenega drevesa. Analiza je pokazala, da je pri klasifikaciji zelo visokoločljivostnih

posnetkov ključnega pomena, da se v klasifikacijo vključijo še dodatni podatki o lastnostih segmentov (spektralne vrednosti, oblika, tekstura, kontekstualne lastnosti ipd.).

Kanjir, Veljanovski in Oštir (2011) so proučevali spremembe pokrovnosti tal in širitve pozidanosti v širši ljubljanski regiji. Z metodo predhodne klasifikacije veččasovnih satelitskih posnetkov Landsat iz let 1992, 1999 in 2005 so izdelali karte sprememb. Rezultati kažejo, da je razvita metodologija primerna za oceno širitve pozidanosti na podlagi veččasovnih posnetkov. Kljub temu avtorji predlagajo, da se klasifikacija izvede z uporabo dodatnih prostorskih podatkov, ki lahko bistveno izboljšajo kakovost klasifikacije posameznih posnetkov (npr. lidarski podatki).

6 ANALIZA VPLIVOV NA OBJEKTNO USMERJENO ANALIZO

V okviru magistrske naloge sem izvedla analizo, s katero sem ovrednotila vplive na oba postopka objektno usmerjene analize, segmentacijo in objektno klasifikacijo, pozidanih površin na ravni podrobnosti, ki ustreza merilu 1 : 5000. Posebnost objektov razreda pozidane površine je, da so zelo heterogeni, in sicer po barvi, teksturi, velikosti in obliki. V razred pozidane površine se tako uvrščajo vse stavbe (različne barve strehe), ceste, dvorišča, parkirišča idr. Zaradi heterogenosti in kompleksnosti pozidanih površin je objektno usmerjena analiza zelo zahtevna. Z izvedeno analizo sem ocenila vpliv izbire ločljivosti podatkov, transformacije in filtriranja posnetka na izboljšanje kakovosti segmentacije in objektno klasifikacije pozidanih površin. Na podlagi rezultatov analize sem ocenila optimalno izbiro podatkov in obdelave podobe za potrebe segmentacije in objektno klasifikacije

6.1 Pregled literature

Izvedenih je bilo več raziskav o analizi vplivov na segmentacijo. Neubert in Herold (2008) sta proučevala kakovost segmentacije petih algoritmov, ki so implementirani v različna programska orodja. Kakovost segmentacije sta ocenila na podlagi primerjave referenčnega sloja podatkov in rezultatov segmentacije. Rezultat je kvantitativna ocena posameznih algoritmov, ki se redno posodablja s pojavom novih programskih orodij na tržišče.

Coillie in sod. (2010) so na podlagi nadzorovane metode ocene kakovosti segmentacije ocenili vpliv izbire parametrov merilo, barva in oblika večnivojskega algoritma na segmentacijo stavb (obrisov streh). Predlagana metodologija služi operaterjem pri določanju optimalnih parametrov segmentacije tako, da je kakovost segmentacije najvišja. Garnica, Boochs in Twardochlib (2000) so analizirali vpliv filtriranja posnetka na kakovost segmentacije in ugotovili, da so za segmentacijo najbolj primerni filtri ohranjanja robov. Predlagali so modificiran filter ohranjanja robov, ki ima na homogenih območjih višjo stopnjo glajenja, kar se kaže v višji kakovosti segmentacije.

Analiza vplivov spektralne in prostorske ločljivosti na kakovost segmentacije pokrovnosti tal (Mesner in Oštir, 2014) je pokazala, da ima visoka spektralna ločljivost negativen vpliv na kakovost segmentacije. Po znanih podatkih druge raziskave na temo analize vplivov na kakovost segmentacije še niso bile izvedene.

6.2 Študijsko območje in vhodni podatki

Analizo vplivov na kakovost segmentacije sem izvedla na območju velikosti 5 krat 5 km, ki obsega jugozahodni del Ljubljane in širšo okolico (slika 14). Študijsko območje je izbrano tako, da obsega:

- različne vrste urbanih površin (stavbe, infrastrukturni objekti in druge pozidane površine),
- različne vrste urbane rabe (npr. stanovanjska, industrijska, poslovna raba) in
- različne tipologije poselitve (strnjeno urbano, strnjeno podeželsko naselje in posamezni objekti ali površine v urbani rabi).



Slika 14: Študijsko območje analize vplivov na objektno usmerjeno analizo.

Figure 14: Impact on object based image analysis study area.

Testni posnetek za analizo vplivov na objektno usmerjeno analizo je satelitski posnetek WorldView-2. Posnetek vsebuje podatke z visoko radiometrično (11-bit), prostorsko (0,50 m) in spektralno ločljivostjo (DigitalGlobe, 2009). Osem večspektralnih kanalov (robni moder, moder, zelen, rumen, rdeč, robni rdeč, bližnji IR1 in IR2) omogoča uporabo v številnih aplikacijah. Nekaj primerov uporabe posameznih večspektralnih kanalov posnetka WorldView-2 je podanih v preglednici 4.

Preglednica 4: Primeri uporabe večspektralnih kanalov satelitskega senzorja WorldView-2 (DigitalGlobe, 2009).

Table 4: Some use cases of WorldView-2 multispectral channels (DigitalGlobe, 2009).

Spektralni pas	Valovne dolžine	Primeri uporabe
robni moder (ang. coastal blue)	400–450 nm	analiza vegetacije batimetrične študije določitev atmosferskih popravkov
moder (ang. blue)	450–510 nm	analiza vegetacije razpoznavanje vodnih površin
zelen (ang. green)	510–580 nm	kartiranje zelene vegetacije

Spektralni pas	Valovne dolžine	Primeri uporabe
		razpoznavanje različnih tipov vegetacije
rumen (ang. yellow)	585–625 nm	razpoznavanje različnih tipov vegetacije
rdeč (ang. red)	630–690 nm	ugotavljanje stanja/zdravja vegetacije razpoznavanje različnih tipov vegetacije
robni rdeč (ang. red edge)	705–745 nm	ugotavljanje stanja/zdravja vegetacije razpoznavanje različnih tipov vegetacije
bližnji IR1 (ang. near IR1)	770–895 nm	razlikovanje med vegetacijo in vodnimi površinami razlikovanje med različnimi tipi vegetacije in prsti ocena vlage vegetacije in rastlinske biomase
bližnji IR2 (ang. near IR2)	860–1040 nm	podobno kot bližnji IR1, s tem, da je bližnji IR2 manj občutljiv na atmosferske vplive

Za objektno usmerjeno analizo sem uporabila programsko orodje eCognition (različica 9.3), za analizo rezultatov segmentacije in izračun cenilk kakovosti pa ArcGIS (različica 10.2).

6.3 Metodologija

V okviru analize vplivov na objektno usmerjeno analizo sem na podlagi izvedenih testov ocenila vpliv prostorske in spektralne ločljivosti ter transformacije in filtriranja podobe na kakovost rezultatov obeh postopkov objektno usmerjene analize, segmentacijo in objektno klasifikacijo.

V okviru ocene vpliva prostorske ločljivosti sem testirala vpliv različnih prostorskih ločljivosti posnetka WorldView-2. Izvorno prostorsko ločljivost 0,5 m sem za potrebe testiranja zmanjšala tako, da sem jo prevzorčila na 1 m, 2,5 m, 5 m, 10 m in 20 m.

V okviru ocene vpliva spektralne ločljivosti sem testirala vpliv uporabe števila in kombinacije spektralnih kanalov. Najprej sem ocenila vpliv izbire spektralnih kanalov za posamezno spektralno ločljivost (od enega do osem kanalov). V prvem koraku sem izvedla osem segmentacij, pri čemer sem za vsako segmentacijo uporabila le en kanal. Na podlagi ocene kakovosti segmentacije sem določila kanal, ki zagotavlja najvišjo kakovost segmentacije. Nato sem nadaljevala s kombinacijo dveh kanalov tako, da sem kombinirala najboljši kanal iz prvega koraka s preostalimi sedmimi spektralnimi kanali. Postopek sem ponavljala, dokler nisem v segmentacijo vključila vseh osmih kanalov. Na ta način sem pridobila najboljšo kombinacijo spektralnih kanalov za eno-, dvo-, tri- in večkanalne podobe. Na podlagi primerjave najboljših kombinacij spektralnih kanalov sem ocenila vpliv števila spektralnih kanalov na kakovost segmentacije.

Vpliv transformacije posnetka je ocenjen na podlagi primerjave kakovosti segmentacije različnih transformacij, in sicer analize osnovnih komponent, normaliziranega diferencialnega vegetacijskega indeksa (NDVI), modificiranega indeksa pozidanosti (WV-BI) in dekorelacijskega raztega.

Vpliv filtriranja je ocenjen na podlagi primerjave kakovosti segmentacije podobe, ki sem jo predhodno zgladila z uporabo različnih filtrov glajenja. Uporabila sem dva enostavna nizkoprepustna filtra, in sicer filter povprečenja in Gaussov filter ter filter mediana, ki ohranja robove.

6.3.1 Analiza vplivov na segmentacijo

Izvorni posnetek sem segmentirala z večnivojskim algoritmom tako, da sem vsakokrat uporabila različne kombinacije spektralnih kanalov, prostorske ločljivosti, filtrirane in transformirane podobe. Nastavitve parametrov večnivojskega algoritma sem določila na podlagi rezultatov analize vpliva parametrov na kakovost segmentacije pozidanih površin (Mesner in Oštir, 2014) ter s prilagajanjem parametra merila glede na ločljivost podobe. Rezultat segmentacij je 48 vektorskih slojev segmentov, katerim sem v nadaljevanju analizirala kakovost segmentacije

Za analizo kakovosti segmentacije sem uporabila nadzorovano metodo ocenjevanja, ki temelji na primerjavi odstopanj med rezultatom segmentacije in referenčnim slojem podatkov (Zhang, Fritts in Goldman, 2008). Referenčni sloj podatkov sem izdelala s fotointerpretacijo 90-ih objektov na študijskem območju, in sicer po 30 objektov za posamezno skupino geografskih objektov stavbe (obrisi streh), ceste in druge pozidane površine.

Prvi korak v izračunu vrednosti cenilk kakovosti segmentacije predstavlja identifikacija segmentov, ki sestavljajo en referenčni objekt. Unija identificiranih segmentov sestavlja testni objekt. Analiza rezultatov segmentacije temelji na primerjavi referenčnega objekta in pripadajočega testnega objekta, pridobljenega s postopkom segmentacije podobe. Testni objekt je sestavljen iz segmentov, katerih prekrivanje z referenčnim objektom je večje od 50 % (Meinel in Neubert, 2004; Neubert in Herold, 2008). Za potrebe izračuna cenilk kakovosti segmentacije sta bila tako za referenčne objekte kot tudi za testne objekte izračunana obseg in površina. Za testne objekte je bilo poleg teh izračunano tudi število segmentov, ki sestavljajo pripadajoči referenčni objekt.

Na podlagi tako pripravljenega sloja referenčnih in testnih objektov s pripadajočimi atributi sem ocenila obstoj, skladnost oblike in velikosti ter položajno odstopanje meje z uporabo naslednjih cenilk kakovosti segmentacije:

- število nerazpoznanih referenčnih objektov,
- povprečno število segmentov, ki sestavlja testni objekt,
- povprečno odstopanje površine testnega in referenčnega objekta,
- povprečno odstopanje obsega testnega in referenčnega objekta ter
- povprečno položajno odstopanje med mejo testnega in referenčnega objekta.

Število nerazpoznanih referenčnih objektov se nanaša na referenčne objekte, ki nimajo pripadajočega testnega objekta (prekrivanje testnega in referenčnega objekta je manjše od 50 %). Povprečno položajno odstopanje je izračunano po postopku, ki sta ga predlagala Defourney in Radoux (2008) s tem, da iz skupnega položajnega odstopanja nisem odstranila grobih pogreškov. Podroben opis cenilk kakovosti je podan v 5.3.1.

6.3.2 Analiza vplivov na klasifikacijo

Za potrebe analize vplivov na klasifikacijo sem izvedla segmentacijo na podlagi filtrirane podobe, ki se je v predhodno izvedeni analizi kakovosti na segmentacijo, izkazala kot optimalna izbira za segmentacijo pozidanih površin. V drugi fazi objektno usmerjene analize, klasifikaciji segmentov, sem klasificirala segmente v razreda pozidano in nepozidano. Pozidane površine so zelo heterogene in so sestavljene iz objektov, ki se razlikujejo tako po spektralnih značilnostih kot tudi po velikosti in obliki. Zato sem za potrebe razpoznavanja pozidanih površin uporabila pet klasifikacijskih razredov, ki pripadajo pozidanim površinam (razred pozidano), in štiri razrede, ki pripadajo drugim vrstam pokrovnosti tal (razred nepozidano). Razvrstitev posameznih razredov v razreda pozidano in nepozidano je prikazana v preglednici 16.

Preglednica 5: Objektni razredi na osnovni in podrobni ravni.

Table 5: Basic and detailed level of object classes.

Osnovna raven	Podrobna raven
pozidano	ceste in druge asfaltne površine
	sive strehe
	rdeče strehe
	bele strehe
	črne strehe
nepozidano	vodne površine

Osnovna raven	Podrobna raven
	travnate in druge zelene površine (vegetacija)
	gozd
	gola tla

Uporabila sem metodo klasifikacije na podlagi vzorcev z algoritmom najbližjega soseda. Klasifikacija je bila izvedena na podlagi 180 učnih vzorcev (po 20 za vsak razred). Po izvedeni klasifikaciji v devet razredov na podrobni ravni sem združila pet razredov, ki pripadajo pozidanim površinam (ceste in druge asfaltne površine, sive, rdeče, bele in črne strehe) v razred pozidano, preostale štiri razrede pa v razred nepozidano. Končni rezultati klasifikacije v ta dva razreda so bili osnova za izvedbo analize vplivov na klasifikacijo.

Kakovost rezultatov klasifikacije sem ocenila na podlagi referenčnega sloja podatkov in klasifikacijske matrike napak. Referenčni sloj podatkov sem izdelala z metodo fotointerpretacije. Zajela sem mejo pozidanih površin na štirih testnih območjih in jih uvrstila v razreda pozidano in nepozidano. Referenčni podatki obsegajo štiri območja velikosti 250-krat 250 m z različnimi lastnostmi:

- glede na tipologijo pozidave (razpršeno in strnjeno podeželsko naselje ter mesto) in
- glede na vrsto urbane rabe prostora (npr. industrijska, stanovanjska raba).

V referenčnem sloju podatkov je 153 objektov, od tega 31 objektov razreda pozidano in 122 objektov razreda nepozidano (slika 15).





Slika 15: Pregled območij referenčnih podatkov pozidanih in nepozidanih površin.

Figure 15: Overview of reference data: built-up and non-built-up areas.

Na podlagi referenčnega sloja podatkov in klasificirane podobe sem izračunala klasifikacijsko matriko napak, ki je osnova za izračun naslednjih cenilk natančnosti:

- skupne natančnosti klasifikacije,
- uporabnikove natančnosti in
- proizvajalčeve natančnosti.

Skupno natančnost klasifikacije sem uporabila za splošno oceno klasifikacije, uporabnikovo in proizvajalčevo natančnost pa za oceno vpliva na posamezni razred. Podroben opis cenilk kakovosti klasifikacije je podan v 5.3.1. Poleg ocene vpliva na kakovost rezultatov klasifikacije sem ocenila tudi vpliv transformacije, filtriranja ter spektralne in prostorske ločljivosti na trajanje postopka objektne klasifikacije.

6.4 Rezultati

V nadaljevanju so podani rezultati ocene vplivov na kakovost rezultatov obeh postopkov objektno usmerjene analize, segmentacijo in objektno klasifikacijo pozidanih površin.

6.4.1 Vplivi na segmentacijo

Podani so rezultati ocene vpliva prostorske in spektralne ločljivosti ter transformacije in filtriranja podobe na kakovost rezultatov segmentacije pozidanih površin.

6.4.1.1 Vpliv spektralne ločljivosti

V prvem koraku so podani rezultati ocene odvisnosti kakovosti segmentacije od izbire spektralnih kanalov za eno-, dvo- in večkanalne podobe, v drugem koraku pa še za število spektralnih kanalov, ki se uporabijo za segmentacijo podobe.

Izbira spektralnih kanalov

V preglednici 5 so prikazane vrednosti cenilk kakovosti segmentacije v odvisnosti od izbire spektralnega kanala pri segmentaciji eno-kanalne podobe.

Preglednica 6: Analiza rezultatov segmentacije eno-kanalne podobe.

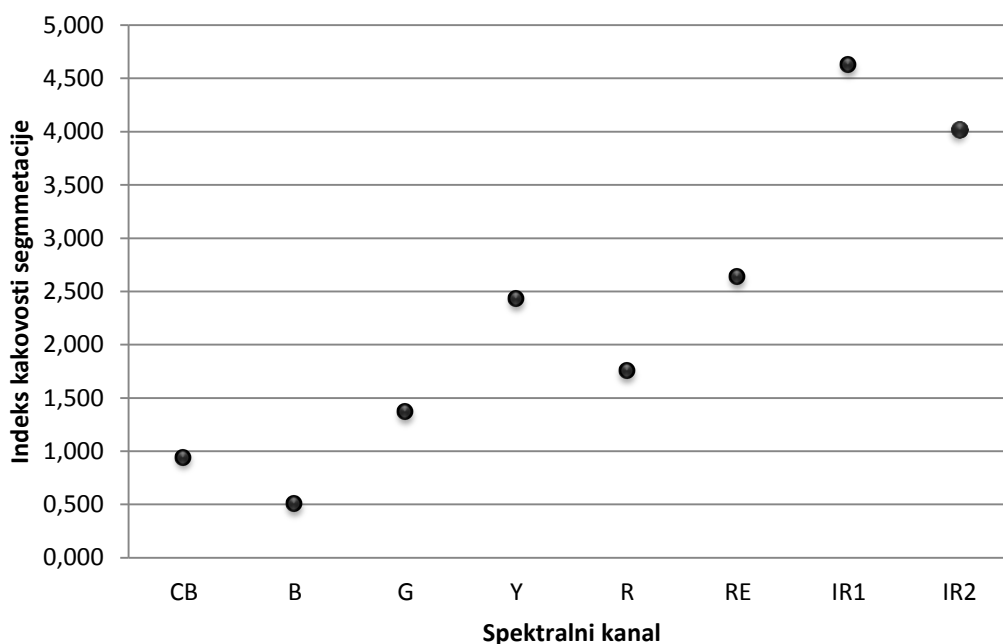
Table 6: Segmentation results analysis of one-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečno odstopanje površine	Povprečno odstopanje obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B	0	10	11,3 %	34,9 %	2,0 piksla	0,5
CB	2	11	12,9 %	37,3 %	2,0 piksla	0,9
G	0	15	10,1 %	42,3 %	1,8 piksla	1,4
R	0	19	9,0 %	34,8 %	1,8 piksla	1,7
Y	0	21	9,6 %	40,5 %	1,8 piksla	2,4
RE	0	21	9,8 %	44,1 %	2,0 piksla	2,6
IR2	0	28	10,4 %	50,7 %	2,0 piksla	4,0
IR1	0	30	11,0 %	49,3 %	2,0 piksla	4,6

Rezultati kažejo, da izbira spektralnega kanala praktično nima vpliva na število nerazpoznanih referenčnih objektov. Ne glede na uporabljeni spektralni kanal (izjema je robni moder) so bili razpoznani vsi referenčni objekti. Izbira spektralnega kanala ima zelo velik vpliv na razdrobljenost podobe na segmente. Povprečno število segmentov, ki sestavljajo en testni objekt, narašča z valovno dolžino spektralnih kanalov. Izjema sta robni moder in bližnji IR2-kanal. Prvi obsega nižje valovne dolžine kot moder kanal, povprečno število segmentov je za ena večje od modrega kanala, drugi pa obsega višje valovne dolžine kot bližnji IR1, povprečno število segmentov je za dva manjše. Rezultat segmentacije modrega kanala testne podobe je najmanj razdrobljena podoba (povprečno 10 segmentov), največja pa s segmentacijo bližnjega IR1-kanala (30 segmentov).

Odstopanja površine so najmanjša pri segmentaciji rdečega kanala (9,0 %) in največja pri robnem modrem kanalu (12,9 %). Izbira spektralnega kanala ima velik vpliv na povprečno odstopanje površin, saj znašajo razlike v povprečnih odstopanjih do 4 %. Prav tako ima izbira spektralnega kanala tudi velik vpliv na povprečno odstopanje obsega. Najmanjše je pri rdečem in modrem kanalu (34,8 in 34,9 %) ter največje pri bližnjem IR2 (50,7 %). Visoke vrednosti povprečnega odstopanja obsega so posledica dejstva, da gre za primerjavo gladke meje referenčnega objekta z mejo segmenta, ki poteka po pikslah. Zato je to predvsem mera za oceno gladkosti meje segmentov. Ocena položajne usklajenosti obeh mej, ki jo ocenjujem na podlagi povprečnega položajnega odstopanja, kaže, da je ta praktično neodvisna od izbire spektralnega kanala. Ne glede na izbrani spektralni kanal se povprečno položajno odstopanje giblje okrog 1 metra (1,8 in 2,0 piksla).

Ovisnost kakovosti segmentacije od izbire spektralnega kanala je prikazana na sliki 16. Na podlagi indeksa kakovosti segmentacije ocenjujem, da je najvišja kakovost segmentacije pozidanih površin na podlagi eno-kanalne podobe z uporabo modrega kanala, najslabša pa z bližnjim IR1 ali IR2. Na podlagi modrega kanala so razpoznani vsi referenčni objekti, razdrobljenost na segmente je med najmanjšimi, prav tako tudi odstopanje obsega. Nekoliko višje je le povprečno odstopanje površine, vendar se pri tem ohranja položajno odstopanje meje okrog dveh pikslov (1 m).



Slika 16: Vpliv izbire spektralnega kanala na kakovost segmentacije. Najnižji indeks kakovosti kaže na najbolj visoko kakovost segmentacije in obratno.

Figure 16: Impact of spectral channel selection on segmentation quality. Minimum index value indicates the most high quality segmentation and vice versa.

V analizo dvo-kanalne podobe sem vključila podobe s kombinacijo modrega in preostalih sedmih kanalov. V preglednici 6 so prikazani rezultati ocene kakovosti segmentacije dvo-kanalne podobe.

Preglednica 7: Analiza rezultatov segmentacije dvo-kanalne podobe.

Table 7: Segmentation results analysis of two-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B, CB	0	10	10,6 %	30,2 %	1,8 piksla	0,9
B, Y	1	17	9,0 %	32,1 %	1,6 piksla	1,6
B, G	0	13	9,9 %	32,1 %	1,8 piksla	1,4
B, R	0	14	9,3 %	34,1 %	1,8 piksla	1,7
B, RE	0	16	8,6 %	31,2 %	1,6 piksla	1,8
B, IR2	0	20	6,5 %	33,6 %	1,6 piksla	2,1
B, IR1	0	22	6,7 %	34,1 %	1,6 piksla	2,5

Ne glede na uporabljeni par spektralnih kanalov so bili razpoznani vsi referenčni objekti (izjema je le kombinacija modrega in rumenega kanala). Najmanjšo razdrobljenost na segmente sem dosegla z uporabo kombinacije modrega in rdečega, zelenega ali robnega modrega kanala, medtem ko je sprememba površine najmanjša pri kombinaciji modrega in bližnjega IR1 ali IR2. Povprečno položajno odstopanje se giblje med 1,6 in 1,8 piksla (0,9 m).

Na podlagi indeksa kakovosti segmentacije ocenjujem (preglednica 6), da je pri uporabi dvo-kanalne podobe najvišja kakovost segmentacije pozidanih površin dosežena z uporabo kombinacije modrega in robnega modrega kanala. Razpoznani so vsi referenčni objekti, razdrobljenost na segmente je najmanjša, prav tako tudi odstopanje obsega. Povprečno položajno odstopanje je sicer največje, vendar se pri tem ohranja položajno odstopanje meje, ki je manjše od dveh pikslav. V analizo tri-kanalne podobe sem zato vključila podobe s kombinacijo modrega, robnega modrega in preostalih šestih kanalov. V preglednici 7 so prikazani rezultati ocene kakovosti segmentacije tri-kanalne podobe.

Preglednica 8: Analiza rezultatov segmentacije tri-kanalne podobe.

Table 8: Segmentation results analysis of three-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B, CB, RE	0	14	8,4 %	29,6 %	1,6 piksla	0,7
B, CB, G	0	12	10,3 %	33,0 %	1,8 piksla	0,7
B, CB, R	0	13	10,1 %	31,0 %	1,8 piksla	0,8
B, CB, Y	0	14	10,6 %	29,6 %	1,6 piksla	1,0
B, CB, IR2	0	17	8,5 %	30,0 %	1,6 piksla	1,1
B, CB, IR1	0	18	7,7 %	28,4 %	1,4 piksla	1,2

Ne glede na izbiro kombinacije spektralnih kanalov so razpoznani vsi referenčni objekti. Najmanjšo razdrobljenost na segmente sem dosegla z uporabo kombinacije modrega, robnega modrega in zelenega kanala. Vendar so pri izbiri te kombinacije kanalov vrednosti preostalih cenilk med najvišjimi. Na podlagi indeksa kakovosti segmentacije ocenjujem, da najvišjo kakovost segmentacije dosežemo s kombinacijo modrega, robnega modrega in robnega rdečega kanala, ki daje nekoliko bolj razdrobljeno podobo na segmente, vendar so vrednosti preostalih cenilk kakovosti med najnižjimi. V nadaljnji analizi sem ocenila kakovost segmentacije štiri-kanalne podobe. V analizo sem vključila pet podob z modrim, robnim modrim, robnim rdečim in preostalimi kanali. V preglednici 8 so prikazani rezultati ocene kakovosti segmentacije štiri-kanalne podobe.

Preglednica 9: Analiza rezultatov segmentacije štiri-kanalne podobe.

Table 9: Segmentation results analysis of four-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B, CB, RE, R	0	15	8,2 %	27,3 %	1,4 piksla	0,4
B, CB, RE, IR2	0	18	7,2 %	30,4 %	1,4 piksla	0,5

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B, CB, RE, G	0	15	9,0 %	31,5 %	1,6 piksla	0,7
B, CB, RE, IR1	0	19	7,5 %	29,1 %	1,4 piksla	0,7
B, CB, RE, Y	0	16	8,3 %	30,2 %	1,8 piksla	1,1

Tudi v primeru segmentacije štiri-kanalne podobe so ne glede na izbiro spektralnih kanalov razpoznani vsi referenčni objekti. Najmanjšo razdrobljenost podobe na segmente sem dosegla s kombinacijo modrega, robnega modrega, robnega rdečega in rdečega ali zelenega kanala, najmanjše položajno odstopanje meje in površine pa z rdečim ali enim izmed infrardečih kanalov. Na podlagi indeksa kakovosti segmentacije ocenjujem, da najbolj kakovostne rezultate segmentacije dosežemo prav s kombinacijo z rdečim kanalom. V nadaljnji analizi sem ocenila kakovost segmentacije pet-kanalne podobe. V analizo sem vključila štiri podobe z modrim, robnim modrim, robnim rdečim, rdečim in preostalimi kanali. V preglednici 9 so prikazani rezultati ocene kakovosti segmentacije pet-kanalne podobe.

Preglednica 10: Analiza rezultatov segmentacije pet-kanalne podobe.

Table 10: Segmentation results analysis of five-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Število segmentov	Sprememba površine	Sprememba obsega	Položajno odstopanje	Indeks kakovosti segmentacije
B, CB, R, RE, G	0	15	8,3 %	27,7 %	1,4 piksla	0,5
B, CB, R, RE, IR1	0	19	6,2 %	28,3 %	1,4 piksla	0,6
B, CB, R, RE, IR2	0	19	6,9 %	29,3 %	1,4 piksla	0,7
B, CB, R, RE, Y	0	17	8,6 %	25,5 %	1,6 piksla	1,0

Če poleg optimalne štiri-kanalne podobe uporabim še zeleni kanal, pridobim najmanj razdrobljeno podobo na segmente in najnižje položajno odstopanje meje segmentov. Na podlagi indeksa kakovosti segmentacije ocenjujem, da najbolj kakovostne rezultate segmentacije dosežemo prav s kombinacijo z zelenim kanalom.

V nadaljnji analizi sem ocenila kakovost segmentacije šest-kanalne podobe. V analizo sem vključila tri podobe z modrim, robnim modrim, robnim rdečim, rdečim, zelenim in preostalimi tremi kanali. V preglednici 11 so prikazani rezultati ocene kakovosti segmentacije šest-kanalne podobe.

Preglednica 11: Analiza rezultatov segmentacije šest-kanalne podobe.

Table 11: Segmentation results analysis of six-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Število segmentov v	Sprememb a površine	Sprememb a obsega	Položajna natančnost	Indeks kakovosti segmentacije
B, CB, G, R, RE, IR2	0	18	6,2 %	26,3 %	1,4 piksla	0,2
B, CB, G, R, RE, IR1	0	18	6,3 %	26,8 %	1,4 piksla	0,3
B, CB, G, R, RE, Y	0	16	8,2 %	25,4 %	1,4 piksla	0,4

Razlike v kakovosti segmentacije različnih šest-kanalnih podob so majhne. Če poleg optimalne pet-kanalne podobe uporabim rumeni kanal, pridobim nekoliko manj razdrobljeno podobo, vendar višje odstopanje površine, medtem ko z uporabo bližnjega IR1 ali IR2 pridobim nekoliko bolj razdrobljeno podobo in manjše površinsko odstopanje. Indeks kakovosti segmentacije kaže, da je v splošnem najboljša kakovost segmentacije, če poleg optimalne pet-kanalne podobe uporabimo še bližnji IR2.

Nadaljevala sem z analizo sedem-kanalne podobe, kjer sem analizirala kakovost segmentacije z uporabo optimalne šest-kanalne podobe in rumenega ali bližnjega IR1-kanala. V preglednici 12 so prikazani rezultati ocene kakovosti segmentacije sedem-kanalne podobe.

Preglednica 12: Analiza rezultatov segmentacije sedem-kanalne podobe.

Table 12: Segmentation results analysis of seven-channel image.

Spektralni kanali	Število nerazpoznanih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
B, CB, G, R, RE, IR1, Y	0	19	7,0 %	24,7 %	1,4 piksla	0,1
B, CB, G, R, RE, IR1, IR2	0	19	6,7 %	28,1 %	1,4 piksla	0,1

Analiza segmentacije sedem-kanalne podobe, kjer pri eni kombinaciji uporabimo bližnji IR1, pri drugi pa bližnji IR2, kaže na praktično enako raven kakovosti segmentacije. Največje razlike so v povprečnem odstopanju obsega. Povprečno odstopanje obsega je z uporabo bližnjega IR1 za 3,4 % nižje, povprečno odstopanje površine je manjše pri uporabi bližnjega IR2-kanala, in sicer za 0,3 %. Vrednosti preostalih cenilk so v obeh primerih enake. Na podlagi cenilk kakovosti ocenjujem, da je kakovost segmentacije sedem-kanalne podobe praktično enaka, ne glede na uporabo bližnjega IR1-ali IR2-kanala. Razlike se kažejo le v bolj gladkih mejah segmentov pri segmentaciji na podlagi bližnjega IR1-kanala, kar se kaže v višji skladnosti obsega.

Število spektralnih kanalov

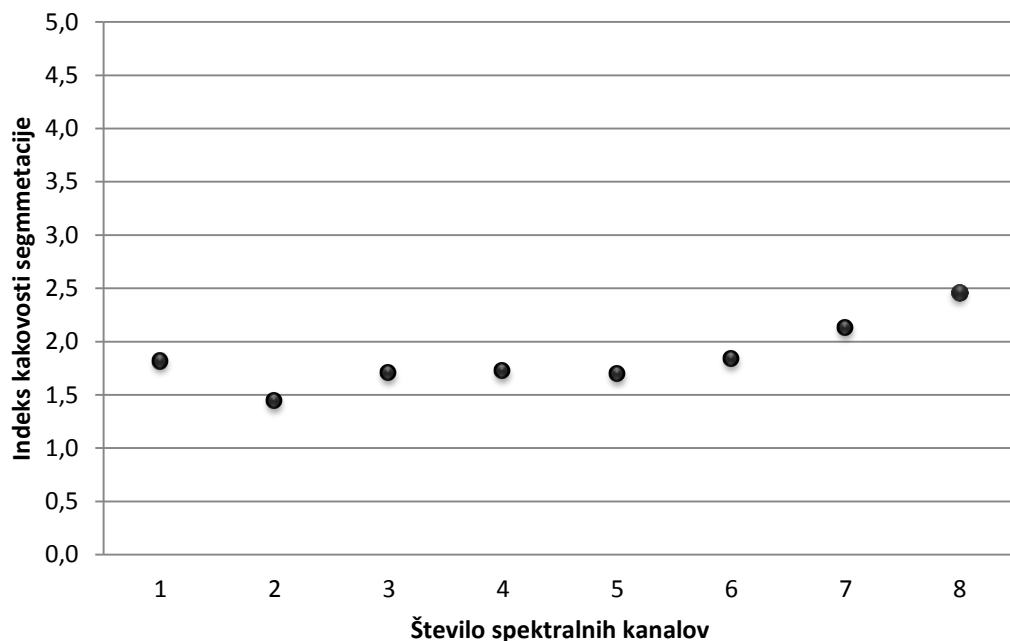
Rezultati analize vpliva števila spektralnih kanalov, na podlagi katerih je podoba segmentirana, so podani v preglednici 13.

Preglednica 13: Analiza vpliva števila spektralnih kanalov na kakovost segmentacije.

Table 13: Analysis of impact of number of spectral channels on segmentation quality.

Število kanalov	Spektralni kanali	Število nerazpoznanih objektov	Število segmentov	Sprememba površine	Sprememba obsega	Položajna natančnost	Indeks
2	B, CB	0	10	10,6 %	30,2 %	0,9	1,4
3	B, CB, RE	0	14	8,4 %	29,6 %	0,8	1,7
4	B, CB, RE, R	0	15	8,2 %	27,3 %	0,7	1,7
5	B, CB, G, R, RE	0	15	8,3 %	27,7 %	0,7	1,7
1	B	0	10	11,3 %	34,9 %	1,0	1,8
6	B, CB, G, R, RE, IR2	0	18	6,2 %	26,3 %	0,7	1,8
7	B, CB, G, R, RE, IR1, Y	0	19	7,0 %	24,70 %	0,7	2,1
8	B, CB, G, R, RE, IR2, Y, IR1	0	20	8,3 %	26,1 %	0,7	2,5

Ne glede na število spektralnih kanalov, uporabljenih pri segmentaciji, so bili razpoznani vsi referenčni objekti. Povprečno število segmentov, ki sestavljajo en testni objekt, narašča sorazmerno s številom spektralnih kanalov, ki jih vključimo v segmentacijo. Segmentacija na podlagi enega kanala ima v povprečju za 50 % segmentov manj kot segmentacija na podlagi vseh osmih kanalov. Spremembe površine so minimalne pri šest-kanalni podobi (6,2 %) in največje pri eno-kanalni (11,3 %), medtem ko je sprememba obsega minimalna pri sedem-kanalni podobi (24,7 %) in maksimalna pri eno-kanalni podobi (34,9 %). Ocena vpliva števila spektralnih kanalov na podlagi indeksa kakovosti segmentacije je prikazana na sliki 16.



Slika 17: Odvisnost kakovosti segmentacije od števila spektralnih kanalov. Najnižji indeks kakovosti kaže na najbolj visoko kakovost segmentacije in obratno.

Figure 17: Segmentation quality depends on the number of spectral channels. Minimum index value indicates the most high quality segmentation and vice versa.

6.4.1.2 Vpliv prostorske ločljivosti

Podani so rezultati ocene kakovosti segmentacije podob s prostorsko ločljivostjo 0,5 m, 1 m, 2,5 m, 5 m, 10 m in 20 m. Vrednosti cenilk kakovosti segmentacije posamezne podobe so podane v preglednici 14.

Preglednica 14: Analiza vpliva prostorske ločljivosti podobe na rezultate segmentacije.

Table 14: Impact of spatial resolution on segmentation quality.

Prostorska ločljivost	Delež nerazpoznanih referenčnih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
0,5 m	0	20	8,3 %	26,1 %	1,4 piksla	18,1
1 m	5 %	5	14,2 %	23,4 %	2,2 piksla	20,0
2,5 m	8 %	4	21,3 %	20,3 %	3,6 piksla	27,9
5 m	48 %	3	21,9 %	16,9 %	5,6 piksla	138,6
10 m	85 %	2	23,8 %	21,3 %	10,8 piksla	248,0
20 m	90 %	2	33,0 %	22,2 %	12,6 piksla	263,8

Prostorska ločljivost ima zelo velik vpliv na razpoznavanje referenčnih objektov. Na podobi izvorne ločljivosti (0,5 m) so bili razpoznani vsi referenčni objekti, z zmanjšanjem prostorske ločljivosti se delež nerazpoznanih objektov povečuje. Pri ločljivosti 1 m je nerazpoznanih 5 % referenčnih objektov, pri 2,5 m 8 %, pri 5 m pa delež nerazpoznanih referenčnih objektov


skokovito narase na 48 %. Pri prostorski ločljivosti 20 m je nerazpoznanih kar 90 % referenčnih objektov.

Pri analizi preostalih cenilk kakovosti je treba upoštevati dejstvo, da je pri podobah z ločljivostjo 5 m in manj veliko število nerazpoznanih objektov. Tako so za podobo s 5-metrsko ločljivostjo odstopanja izračunana na vzorcu 47-ih objektov, za 10-metrsko ločljivost 13- in za 20-metrsko ločljivost le devet objektov. Vzorec za izračun povprečnega odstopanja na podobah z 10- in 20-metrsko ločljivostjo je zelo majhen, zato izračunane statistike ne izražajo nujno dejanskega povprečnega odstopanja na teh podobah. V nadaljevanju se zato osredotočam le na analizo cenilk kakovosti za podobe prostorske ločljivosti do 2,5 m.


Zmanjšanje prostorske ločljivosti ima izrazito negativen vpliv na razpoznavanje referenčnih objektov, vendar ima hkrati pozitiven vpliv na zmanjšanje razdrobljenosti referenčnih objektov na segmente. Z zmanjšanjem prostorske ločljivosti se heterogenost pozidanih površin zmanjšuje, kar se kaže tudi v sorazmerno manjšem povprečnem številu segmentov. Povprečno število segmentov, ki sestavljajo en referenčni objekt, je pri izvorni (0,5-metrski) ločljivosti 20, pri 1-metrski ločljivosti pa le 5.

Povprečno odstopanje površine z zmanjševanjem prostorske ločljivosti narašča. Najmanjša odstopanja površine so pri izvorni podobi (8,3 %) in največja pri podobi z 2,5-metrsko ločljivostjo (21,3 %). Podobno velja tudi za povprečno položajno odstopanje meje segmenta. Najmanjše odstopanje sem zabeležila pri izvorni ločljivosti (0,7 m), največje pri 2,5-metrski ločljivosti (1,8 m). Obratno velja za odstopanje obsega. Največje odstopanje smo zabeležili pri izvorni ločljivosti (26 %), najmanjše pa pri 2,5-metrski ločljivosti (20,3 %).


Na sliki 18 je prikazano ujemanje meje referenčnega objekta (rdeča linija) in testnega objekta (rumena ploskev). Najboljše ujemanje med objektoma je z uporabo 0,5 m ali 1 m ločljivosti (slike 18a in 18b), najslabše pa pri ločljivosti 5 m in več, saj je testni objekt neskladen z referenčnim objektom tako po površini kot tudi po obliki (slike 18d, 18e in 18f).




(a)



(b)



(c)



Slika 18: meja referenčnega objekta (rdeče linije) in meja testnega objekta (rumeno polnilo) na podlagi segmentacije podobe s prostorsko ločljivostjo 0,5 m (a), 1 m (b), 2,5 m (c), 5 m (d), 10 m (e) in 20 m (f).

Figure 18: Reference (red line) and test object boundary (yellow fill) based on segmentation of image with spatial resolution 0,5 m (a), 1 m (b), 2,5 m (c), 5 m (d), 10 m (e) in 20 m (f).

Na podlagi podatkov o cenilkah kakovosti ocenjujem, da se najvišjo kakovost segmentacije pozidanih površin doseže z uporabo izvorne 0,5 m ločljivosti. Z zmanjševanjem prostorske ločljivosti se sicer zmanjša razdrobljenost podobe na segmente, vendar število nerazpoznanih referenčnih objektov hitro narašča.

6.4.1.3 Vpliv filtriranja podobe

Podani so rezultati ocene kakovosti segmentacije filtriranih podob s filtrom povprečenja, Gaussovimi filtrom in filtrom mediana. Vrednosti cenilk kakovosti segmentacije za izvorno podobo in zglajene podobe z uporabo izbranih filtrov so podane v preglednici 15.

Preglednica 15: Analiza vpliva filtriranja podobe na kakovost segmentacije.

Table 15: Impact of image filtering on segmentation quality.

Vrsta filtra	Delež nerazpoznanih referenčnih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
Izvorna podoba	0	20	8,3 %	26,1 %	1,4 piksla	1,1
Mediana	0	15	6,9 %	18,0 %	1,4 piksla	0,1
Filter povprečenja	0	14	9,1 %	22,9 %	1,6 piksla	0,6
Gaussov filter	0	16	7,6 %	23,3 %	1,6 piksla	0,7

Rezultati kažejo, da filtriranje podobe nima vpliva na število nerazpoznanih referenčnih objektov. Ne glede na uporabljeni filter so bili razpoznani vsi referenčni objekti. Segmentacija filtrirane podobe je manj razdrobljena kot segmentacija izvorne podobe. Pri vseh filtriranih podobah sem zabeležila manjše povprečno število segmentov (od 14 do 16) kot pri izvorni podobi.

Filtriranje podobe ima pozitiven vpliv na skladnost obsega, površine in meje objektov. Tako sem zabeležila pri segmentaciji vseh filtriranih podob (razen filter povprečenja) nižje odstopanje površine kot pri izvorni podobi. Položajno odstopanje meje je nekoliko večje pri segmentaciji podobe s filtrom povprečenja in Gaussovimi filtrom. Pri uporabi filtra, ki ohranja robove (mediana), pa je položajno odstopanje meje enako kot pri izvorni podobi. S filtrom mediana prav tako pridobimo podobo z bistveno manjšim odstopanjem obsega, kar kaže na bolj gladko mejo. Rezultati analize kažejo, da ima filtriranje s filtrom mediana, ki ohranja robove, pozitiven vpliv na skladnost oblike, površine in položajnega odstopanja meje segmenta v primerjavi z izvorno podobo.

6.4.1.4 Vpliv transformacije podobe

Podani so rezultati ocene kakovosti segmentacije transformiranih podob. Vrednosti cenilk kakovosti segmentacije za izvorno podobo in transformirane podobe so podane v preglednici 16.

Preglednica 16: Analiza vpliva transformacije podobe na rezultate segmentacije.

Table 16: Impact of image transformation on segmentation quality.

Vrsta filtra	Delež nerazpoznanih referenčnih objektov	Povprečno število segmentov	Povprečna sprememba površine	Povprečna sprememba obsega	Povprečno položajno odstopanje	Indeks kakovosti segmentacije
Izvorna podoba	0	20	8,3 %	26,1 %	1,4 piksla	4,2
PCA	0	8	13,1 %	32,7 %	2,0 piksla	2,5
Dekorelacijski razteg	0	7	15,8 %	21,6 %	2,6 piksla	3,5
WV-BI	0	20	15,3 %	70,8 %	2,8 piksla	7,6
NDVI	0	15	21,6 %	61,5 %	3,0 piksla	7,5

Rezultati analize kažejo, da transformacija podobe nima vpliva na nerazpoznavanje referenčnih objektov, saj so bili ne glede na uporabljeno transformacijo razpoznani vsi referenčni objekti. Ima pa transformacija podobe zelo velik vpliv na vse preostale cenilke kakovosti segmentacije. Segmentacija transformirane podobe je v primerjavi z izvorno podobo bistveno manj razdrobljena. Pri segmentaciji vseh transformiranih podob (razen pri transformaciji indeksa WV-BI) je povprečno število segmentov manjše. Rezultati kažejo, da ima transformacija podobe v splošnem pozitiven vpliv na zmanjšanje razdrobljenosti podobe na segmente. Hkrati pa transformacija podobe kvarno vpliva na skladnost površine, obsega in položaja meje objektov. Tako sem pri segmentaciji vseh transformiranih podob zabeležila bistveno večje odstopanje površine kot pri izvorni podobi (1,6-krat in več). Povprečno odstopanja obsega je najnižje pri dekorelacijskem raztegu (21,6 %), pri izvorni podobi 26,1 %, pri ostalih transformiranih podobah pa več kot 30 %. Transformacija podobe ima tudi negativen vpliv na položajno odstopanje meje objektov, saj je ta pri transformiranih podobah

nekoliko nižja. Povprečno položajno odstopanje znaša za izvorno podobo 1,4 piksla, za vse transformirane podobe pa več kot 2 piksla. Kljub negativnim vplivom na povečanje odstopanja površin, obsega in položajnega odstopanja ocenjujem, da ima uporaba transformacij, ki zmanjšajo koreliranost med podatki (dekorelacijski razteg in PCA), pozitiven vpliv na kakovost segmentacije. Izboljšanje kakovosti segmentacije se nanaša predvsem na zmanjšanje razdrobljenosti podobe na segmente.

6.4.2 Vplivi na klasifikacijo

Podani so rezultati ocene vpliva prostorske in spektralne ločljivosti ter transformacije in filtriranja podobe na kakovost klasifikacije pozidanih površin.

6.4.2.1 Vpliv spektralne ločljivosti

V prvem koraku so podani rezultati ocene odvisnosti kakovosti klasifikacije od izbire spektralnih kanalov za eno-, dvo- in večkanalne podobe, v drugem koraku pa še za število spektralnih kanalov, ki se uporabijo za klasifikacijo podobe.

Izbira spektralnega kanala

V preglednici 17 so prikazane vrednosti skupne natančnosti klasifikacije v odvisnosti od izbire spektralnega kanala za klasifikacijo eno-kanalne podobe.

Preglednica 17: Analiza rezultatov klasifikacije eno-kanalne podobe.

Table 17: Classification results analysis of one-channel image.

Spektralni kanali	Skupna natančnost
CB	84,5 %
B	80,6 %
R	75,1 %
Y	75,7 %
G	70,5 %
IR2	57,7 %
IR1	57,6 %
RE	54,6 %

Rezultati kažejo, da ima izbira spektralnega kanala zelo velik vpliv na skupno natančnost klasifikacije, saj znaša razlika med klasifikacijo na podlagi robnega modrega kanala (najvišja vrednost) in robnega rdečega (najnižja vrednost) skoraj 30 %. V naslednjem koraku sem izračunala skupno natančnost klasifikacije na podlagi dveh kanalov, in sicer kot kombinacijo robnega modrega in preostalih sedmih kanalov. Skupna natančnost klasifikacije dvo-kanalne podobe je podana v preglednici 18.

Preglednica 18: Analiza rezultatov klasifikacije dvo-kanalne podobe.

Table 18: Classification results analysis of two-channel image.

Spektralni kanali	Skupna natančnost
CB, IR1	93,7 %
CB, IR2	93,4 %
CB, G	90,4 %
CB, RE	88,9 %
CB, Y	88,4 %
CB, R	87,0 %
CB, B	86,5 %

Najvišjo skupno natančnost klasifikacije (93,7 %) sem dosegla s kombinacijo robnega modrega in bližnjega IR1-kanala. V primerjavi z eno-kanalno podobo se je natančnost izboljšala za 9,2 %. Druga pomembna ugotovitev je, da se je vpliv izbire kombinacije para spektralnih kanalov na skupno natančnost klasifikacije bistveno zmanjšal v primerjavi z eno-kanalno podobo. Razlika med minimalno in maksimalno skupno natančnostjo eno-kanalne podobe je 30 %, dvo-kanalne pa le 7,2 %. V praksi to pomeni, da več kanalov, kot je vključenih v klasifikacijo, manjši je vpliv izbire kanala. Analizo sem nadaljevala s tri-kanalnimi podobami, in sicer kombinacijo robnega modrega, bližnjega IR1 in preostalih šestih kanalov. Skupna natančnost klasifikacije na podlagi posameznih kombinacij kanalov je podana v preglednici 19.

Preglednica 19: Analiza rezultatov klasifikacije tri-kanalne podobe.

Table 19: Classification results analysis of three-channel image.

Spektralni kanali	Skupna natančnost
CB, IR1, G	93,3 %
CB, IR1, IR2	93,1 %
CB, IR1, B	92,8 %
CB, IR1, RE	92,3 %
CB, IR1, Y	92,0 %
CB, IR1, R	91,8 %

Najvišjo skupno natančnost klasifikacije (93,3 %) sem dosegla s kombinacijo robnega modrega, bližnjega IR1 in zelenega kanala, vendar se ta vrednost minimalno razlikuje od natančnosti klasifikacije dvo-kanalne podobe (za 0,4 % nižja). Razlika med najvišjo in najnižjo skupno natančnostjo tri-kanalne podobe je le 1,5 %.

Preglednica 20: Analiza rezultatov klasifikacije štiri-kanalne podobe.

Table 20: Classification results analysis of four-channel image

Spektralni kanali	Skupna natančnost
CB, IR1, G, B	93,4 %
CB, IR1, G, IR2	92,9 %

Spektralni kanali	Skupna natančnost
CB, IR1, G, RE	91,9 %
CB, IR1, G, Y	91,7 %
CB, IR1, G, R	91,6 %

Nadaljevala sem z analizo klasifikacije štiri-kanalne podobe. Rezultati so podani v preglednici 20. Najvišja skupna natančnost (93,4 %) je na podlagi kombinacije robnega modrega, bližnjega IR1, zelenega in modrega kanala, vendar praktično enaka kot na podlagi tri-kanalne podobe (93,3 %). Izbira kombinacije spektralnih kanalov ima majhen vpliv na skupno natančnost klasifikacije (razlike do 1,8 %).

Preglednica 21: Analiza rezultatov klasifikacije pet-kanalne podobe.

Table 21: Classification results analysis of five-channel image.

Spektralni kanali	Skupna natančnost
CB, IR1, G, B, IR2	92,7 %
CB, IR1, G, B, Y	91,5 %
CB, IR1, G, B, R	91,3 %
CB, IR1, G, B, RE	91,2 %

V preglednici 21 so podani rezultati skupne natančnosti klasifikacije pet-kanalne podobe. Najvišja skupna natančnost (92,7 %) je na podlagi kombinacije vseh kanalov razen rumenega, rdečega in robnega rdečega. V primerjavi s štiri-kanalno podobo je skupna natančnost celo nekoliko nižja (0,7 %), razlike med posameznimi kombinacijami pet-kanalne podobe pa so do 1,5 %.

Preglednica 22: Analiza rezultatov klasifikacije šest-kanalne podobe.

Table 22: Classification results analysis of six-channel image.

Spektralni kanali	Skupna natančnost
CB, IR1, G, B, IR2, Y	91,2 %
CB, IR1, G, B, IR2, R	91,0 %
CB, IR1, G, B, IR2, RE	90,6 %

Nadaljevala sem z analizo klasifikacije šest-kanalne podobe (preglednica 22). Najvišja skupna natančnost (91,2 %) je na podlagi kombinacije vseh kanalov razen rdečega in robnega rdečega. Izbira spektralnega kanala ima majhen vpliv na skupno natančnost klasifikacije. V odvisnosti od izbrane kombinacije znašajo razlike v skupni natančnosti do 0,6 %.

Preglednica 23: Analiza rezultatov klasifikacije sedem-kanalne podobe.

Table 23: Classification results analysis of seven-channel image.

Spektralni kanali	Skupna natančnost
CB, IR1, G, B, IR2, Y, R	90,9 %
CB, IR1, G, B, IR2, Y, RE	90,1 %

Nazadnje sem izvedla še analizo sedem-kanalne podobe (preglednica 23). Rezultati analize sedem-kanalne podobe potrjujejo trend v predhodnih analizah. Skupna natančnost je nekoliko nižja od natančnosti, ugotovljene v predhodni analizi šest-kanalne podobe (0,3 %). Vpliv izbire kombinacije sedmih spektralnih kanalov je majhna, saj znaša razlika v skupni natančnosti med obema kombinacijama le 0,8 %.

Število spektralnih kanalov


Rezultati analize vpliva števila spektralnih kanalov, na podlagi katerih je podoba klasificirana, so podani v preglednici 24.

Preglednica 24: Analiza vpliva števila spektralnih kanalov na kakovost klasifikacije.

Table 24: Analysis of impact of number of spectral channels on segmentation quality.

Število kanalov	Skupna natančnost	Maks. razlika v skupni natančnosti	Min. trajanje obdelave	Pozidano		Nepozidano	
				Uporabnikova natančnost	Proizvajalčeva natančnost	Uporabnikova natančnost	Proizvajalčeva natančnost
2	93,7 %	7,2 %	2,5 min	93,7 %	93,3 %	93,6 %	94,0 %
4	93,4 %	1,8 %	3,5 min	92,7 %	93,9 %	94,1 %	92,9 %
3	93,3 %	1,5 %	3,0 min	92,6 %	93,8 %	94,0 %	92,8 %
5	92,7 %	1,5 %	4,0 min	92,8 %	92,2 %	92,6 %	93,1 %
6	91,2 %	0,6 %	4,5 min	98,9 %	83,0 %	85,9 %	99,1 %
7	90,9 %	0,8 %	5,0 min	98,9 %	82,4 %	85,4 %	99,2 %
8	90,7 %	-	5,5 min	99,0 %	81,9 %	85,1 %	99,2 %
1	84,5 %	29,9 %	2,0 min	83,0 %	85,9 %	86,0 %	83,1 %

Najnižja skupna natančnost klasifikacije razreda pozidano je na podlagi eno-kanalne podobe (84,5 %), najvišja pa na podlagi dvo-kanalne podobe (93,7 %). Pri uporabi treh in več kanalov se skupna natančnost počasi zmanjšuje in pri vseh osmih kanalih je 90,7-odstotna, kar je za 3 % manj kot pri uporabi dvo-kanalne podobe. Odvisnost skupne natančnosti klasifikacije od spektralne ločljivosti je prikazana na sliki 19.



Slika 19: Vpliv spektralne ločljivosti na skupno natančnost klasifikacije pozidanih površin.

Figure 19: Impact of spectral resolution on overall accuracy of built-up area.

Podrobna analiza rezultatov klasifikacije za razreda pozidano in nepozidano kaže, da se s številom spektralnih kanalov izboljšuje uporabnikova natančnost klasifikacije pozidanih površin, vendar se obenem zmanjšuje proizvajalčeva natančnost klasifikacije. Pri uporabi vseh osmih kanalov je sicer velik delež objektov razreda pozidano pravilno klasificiran (99 %), vendar je velik tudi delež dejanskih pozidanih površin, ki so lažno klasificirani kot nepozidano (18,1 %). Najboljše razmerje med obema natančnostima je ob uporabi dveh do petih kanalov. V tem primeru sta obe natančnosti približno uravnoteženi in obe presegata 92 %. Pri klasifikaciji na podlagi enega ali šestih in več kanalov pa je uporabnikova natančnost sicer višja (do 99 %), vendar na račun zmanjšane proizvajalčeve natančnosti (od 82 % do 86 %).

Število kanalov, ki se uporabijo za klasifikacijo, ima tudi velik vpliv na trajanje obdelave. Čas obdelave za testno območje, ki obsega površino 25 km², je za eno-kanalno podobo 2 min, za testno podobo (osem-kanalno) pa dvakrat več (5,5 min).

6.4.2.2 Vpliv prostorske ločljivosti

Podani so rezultati ocene kakovosti klasifikacije podob s prostorsko ločljivostjo 0,5 m, 1 m, 2,5 m, 5 m, 10 m in 20 m. Skupna natančnost klasifikacije posamezne podobe je podana v preglednici 25.


Preglednica 25: Analiza vpliva prostorske ločljivosti na kakovost klasifikacije.

Table 25: Analysis of impact of spatial resolution on segmentation quality.

Prostorska ločljivost	Skupna natančnost	Trajanje klasifikacije	Pozidano		Nepozidano	
			Uporabnikova natančnost	Proizvajalčeva natančnost	Uporabnikova natančnost	Proizvajalčeva natančnost
0,5 m	90,7 %	5'20"	99,0 %	81,9 %	85,1 %	99,2 %
1 m	89,4 %	5'33"	97,0 %	80,9 %	84,2 %	97,6 %

2,5 m	89,1 %	5'35"	96,9 %	80,2 %	83,7 %	97,5 %
5 m	87,2 %	5'41"	96,6 %	76,6 %	81,3 %	97,4 %
10 m	83,4 %	5'42"	94,2 %	70,5 %	77,2 %	95,8 %
20 m	74,1 %	5'37"	81,1 %	61,3 %	69,9 %	86,2 %

Najvišjo skupno natančnost klasifikacije sem dosegla z izvorno prostorsko ločljivostjo, in sicer 90,7 %. Pri zmanjšanju prostorske ločljivosti do 2,5 m je zmanjšanje skupne natančnosti klasifikacije majhno, in sicer do 1,6 %. Pri zmanjševanju prostorske ločljivosti nad 2,5 m pa se vpliv na skupno natančnost klasifikacije postopoma povečuje. Skupna natančnost klasifikacije 5-metrške podobe v primerjavi z izvorno podobo je nižja za 3,5 %, 10-metrške za 7,3 % in 20-metrške za 16,6 %. Odvisnost skupne natančnosti klasifikacije od prostorske ločljivosti posnetka je prikazana na sliki 20.



Slika 20: Vpliv prostorske ločljivosti na skupno natančnost klasifikacije pozidanih površin.

Figure 20: Impact of spatial resolution on overall accuracy of built-up area.

Čas obdelave je praktično neodvisen od prostorske ločljivosti podobe (okrog 5,5 minute). Rezultat je pričakovan, saj je v klasifikacijo, ne glede na prostorsko ločljivost, vključeno enako število spektralnih kanalov (osem).

Uporabnikova in proizvajalčeva natančnost klasifikacije posameznih razredov (pozidano in nepozidano) pada s prostorsko ločljivostjo. Najvišja uporabnikova natančnost pozidanih površin (90,7 %) je dosežena s klasifikacijo izvorne, 0,5-metrške ločljivosti, najnižja (74,1 %) pa s klasifikacijo podobe z 20-metrsko ločljivostjo. Podobno pada tudi proizvajalčeva natančnost, in sicer z 81,9 % (0,5-metrška ločljivost) na samo 61,3 % (20-metrška ločljivost).

6.4.2.3 Vpliv filtriranja

Podani so rezultati ocene kakovosti klasifikacije filtriranih podob s filtrom povprečenja, Gaussovimi filtrom in filtrom mediana. Skupne natančnosti klasifikacije na podlagi izvorne in zglajenih podob so podane v preglednici 27.

Preglednica 26: Analiza vpliva filtriranja podobe na kakovost klasifikacije.

Table 26: Analysis of impact of image filtering on classification quality.

Filter	Skupna natančnost	Trajanje obdelave	Pozidane površine		Nepozidane površine	
			Uporabnikova natančnost	Proizvajalčeva natančnost	Uporabnikova natančnost	Proizvajalčeva natančnost
Mediana	89,3 %	5,3 min	96,9 %	80,7 %	84,1 %	97,6 %
Povprečenja	89,1 %	5,5 min	97,0 %	80,1 %	83,6 %	97,6 %
Gaussov	89,3 %	5,3 min	96,8 %	80,7 %	84,1 %	97,4 %

Skupna natančnost klasifikacije je praktično neodvisna od izbranega filtra in znaša 89,1 % za filter povprečenja ter 89,3 % za filtra mediana in Gaussov filter. Skupna natančnost klasifikacije na podlagi filtriranih podob je za približno 1,5 % nižja v primerjavi s klasifikacijo izvirne podobe.

Prav tako izbira filtra nima bistvenega vpliva niti na uporabnikovo niti na proizvajalčevo natančnost pozidanih površin. Ne glede na izbrani tip filtra se uporabnikova giblje okrog 97 %, proizvajalčeva natančnost pa okrog 80 %. Rezultat je pričakovan, saj razvrstitev segmentov v objektne razrede temelji na povprečnih spektralnih vrednostih posameznega segmenta. Zato so razlike v povprečnih vrednostih segmenta, ki temeljijo na izvorni ali filtrirani podobi, majhne. Na podlagi rezultatov analize ocenjujem, da filtriranje nima bistvenega vpliva na objektno klasifikacijo in da izbira filtra nima vpliva na skupno natančnost klasifikacije.

6.4.2.4 Vpliv transformacije

Podani so rezultati ocene kakovosti klasifikacije transformiranih podob s filtrom povprečenja, Gaussovim filtrom in filtrom mediana. Skupne natančnosti klasifikacije na podlagi izvirne in transformiranih podobe so podane v preglednici 27.

Preglednica 27: Analiza vpliva transformacije podobe na kakovost klasifikacije.

Table 27: Analysis of impact of image transformation on classification quality.

Tip transformacije	Skupna natančnost	Trajanje obdelave	Pozidane površine		Nepozidane površine	
			Uporabnikova natančnost	Proizvajalčeva natančnost	Uporabnikova natančnost	Proizvajalčeva natančnost
Dekorelacijski razteg	89,8 %	2,5 min	92,5 %	86,1 %	87,6 %	93,3 %
PCA	87,3 %	2,5 min	97,7	75,9 %	80,9 %	98,3 %
NDVI	85,1 %	2,0 min	99,8 %	69,7 %	77,6 %	99,8 %
WV-BI	74,1 %	2,0 min	73,3 %	74,1 %	74,9 %	74,1 %

Rezultati analize kažejo, da je skupna natančnost klasifikacije zelo odvisna od izbranega tipa transformacije. Najvišja skupna natančnost (89,8 %) je na podlagi transformirane podobe z

dekorelacijskim raztegom. Klasifikacija na podlagi preostalih tipov transformacij (PCA, NDVI in WV-BI) je slabše natančnosti od klasifikacije izvorne podobe. Skupna natančnost klasifikacije se giblje med 74,1 % in 89,8 %. Najnižja skupna natančnost je na podlagi indeksa WV-BI, in sicer 74,1 %.

Postopek transformacije ima pozitiven vpliv na čas trajanja procesa klasifikacije. Izvorna podoba je klasificirana v 5,3 min, medtem ko se čas obdelave transformiranih podob giblje med 2,0 in 2,5 min. Če čas obdelave preračunamo na celotno območje Slovenije, ocenjujem, da lahko s transformacijo prihranimo približno 30 ur. Skrajšani čas obdelave je temeljnega pomena predvsem pri nekaterih aplikacijah, ki zahtevajo zelo hitro kartiranje (npr. v primeru naravnih nesreč).

Uporabnikova natančnost pozidanih površin je pri uporabi transformacij zelo visoka in znaša več kot 90 %, za indeks NDVI celo več kot 99 %. Vendar je proizvajalčeva natančnost na podlagi NDVI zelo nizka, saj znaša le 69,7 %. Najboljše razmerje med obema natančnostma je doseženo z dekorelacijskim raztegom. Obratno pa velja za razred nepozidano. Uporabnikova natančnost se giblje med 74,9 in 87,6 %, proizvajalčeva pa je višja od 93 % (z izjemo indeksa pozidanosti).

6.5 Povzetek rezultatov

V okviru izvedene analize sem analizirala vplive na kakovost objektno usmerjene analize pozidanih površin na ravni podrobnosti 1 : 5.000. Na podlagi izbranih cenilk kakovosti sem ocenila vplive spektralne in prostorske ločljivosti ter transformacije in filtriranja podobe.

V nadaljevanju podajam povzetek rezultatov analize vplivov na oba osnovna postopka objektno usmerjene analize, segmentacijo in objektno klasifikacijo.

6.5.1 Analiza vplivov na segmentacijo

Pri segmentaciji težimo k optimalni situaciji, ko je odstopanje med mejo segmenta in mejo referenčnega objekta enako nič in ko je en referenčni objekt sestavljen iz le enega segmenta. Toda v praksi se redko soočamo s takim primerom. Navadno je en objekt sestavljen iz več segmentov ali pa en segment obsega dva ali več objektov, meja segmentov pa ni natančno usklajena z mejo geografskega objekta.

Kakovost segmentacije sem ocenila z nadzorovano metodo, ki temelji na primerjavi rezultatov segmentacije z referenčnim slojem podatkov. Uporabila sem naslednje cenilke kakovosti: število nerazpoznanih referenčnih objektov, povprečno število segmentov, povprečno odstopanje obsega, povprečno odstopanje površine in povprečno položajno odstopanje meje.

Vpliv spektralne ločljivosti

S povečevanjem števila spektralnih kanalov, ki se uporabijo za segmentacijo podobe, se poveča predvsem razdrobljenost na segmente, hkrati pa se bistveno ne zmanjšajo vrednosti preostalih cenilk kakovosti segmentacije. Analiza je pokazala, da zgolj s spektralno ločljivostjo ni mogoče vplivati na kakovost segmentacije tako, da bodo referenčni objekti predstavljeni s čim manjšim številom segmentov in da bo hkrati dosežena visoka skladnost

med obema mejama. Lahko pa se z variiranjem spektralnih kanalov približamo eni optimalni situaciji:

- z izbiro dveh kanalov (moder in robni moder) je en referenčni objekt predstavljen z najmanjšim številom segmentov, vendar sta gladkost in položajna usklajenost meje slabši;
- z izbiro vseh kanalov testne podobe (izvorna podoba) je en referenčni objekt sestavljen iz večjega števila segmentov, pri čemer sta skladnost in gladkost meje višji.

Na podlagi teh ugotovitev in vrednosti indeksa kakovosti segmentacije ocenjujem, da se najbolj kakovostna segmentacija pozidanih površin na testnem posnetku doseže z uporabo dveh spektralnih kanalov, in sicer modrega in robnega modrega.

Vpliv prostorske ločljivosti

Pozitivna lastnost zmanjšanja prostorske ločljivosti podobe je zmanjšanje podrobnosti na podobi, kar se kaže v večji homogenosti pozidanih površin. Povprečno število segmentov, ki sestavljajo en referenčni objekt, je pri izvorni ločljivosti 0,5 m dvajset, pri 2,5 m pa le štiri. Vendar se zaradi zmanjšanja podrobnosti na podobi in posledično tudi večjega razmerja med velikostjo piksla in objekta na podobi izredno poveča delež nerazpoznanih referenčnih objektov (8 %). Zato je treba cenilko povprečno število segmentov zmeraj vrednotiti skupaj s številom nerazpoznanih referenčnih objektov. Pozitivna lastnost zmanjšanja prostorske ločljivosti je tudi bolj gladka meja segmentov, vendar se obenem tudi precej poslabša odstopanje površine in meje. Na podlagi izvedene analize ocenjujem, da je za segmentacijo pozidanih površin na ravni podrobnosti 1 : 5000 najbolj primerna segmentacija podobe s prostorsko ločljivostjo 0,5 m.

Vpliv filtriranja podobe

Z izbranimi nizkoprepustnimi filtri (povprečenje, Gaussov in mediana) sem zmanjšala podrobnosti na podobi in jo tako zgladila. Rezultat segmentacije zglajene podobe z uporabo enostavnih nizkoprepustnih filtrov (povprečenje in Gaussov filter) je manj razdrobljena podoba, vendar se hkrati poslabša tudi skladnost meje, površine in obsega (podobno kot pri transformacijah podobe). Ključni rezultat analize vplivov filtriranja in hkrati tudi analize vplivov na segmentacijo je, da se z uporabo filtra mediana, ki ohranja robove, doseže višjo kakovost segmentacije kot s segmentacijo izvorne podobe. To se kaže v višji skladnosti meje, površine in obsega kot pri segmentaciji izvorne podobe.

Vpliv transformacije podobe

Pozitiven učinek transformacij je v splošnem zmanjšanje koreliranosti med podatki na posameznih spektralnih kanalih, kar se kaže v večji homogenosti pozidanih površin. Povprečno število segmentov, ki sestavljajo en referenčni objekt, je pri izvorni podobi 20, pri podobi, transformirani s PCA pa le 8. Podoben učinek sem dosegla z zmanjševanjem prostorske ločljivosti, vendar sem se pri zmanjšani prostorski ločljivosti soočala s problematiko nerazpoznavanja vseh referenčnih objektov, medtem, ko sem s transformacijo dosegla zmanjšanje podrobnosti (manjše število segmentov) in hkrati ohranila razpoznavanje vseh referenčnih objektov. Slaba stran transformacij podob je zmanjšanje skladnosti meje

segmentov in referenčnih objektov. Oblika objektov na analiziranih transformiranih podobah ni skladna z obliko objektov na izvornem posnetku, kar se kaže v višjem položajnem odstopanju meje ter večjem odstopanju površine in obsega.

Primerjava ključnih rezultatov analize vplivov na segmentacijo je podana v preglednici 28.

Preglednica 28: Pregled rezultatov analize vpliva prostorske in spektralne ločljivosti ter transformacij in filtriranja podobe na kakovost segmentacije. Cenilke posameznih podob, ki so v primerjavi z izvorno podobo višje (rdeče polnilo), nižje (zeleno polnilo) in enake (brez polnila). Višje vrednosti cenilk se nanašajo nižjo kakovost segmentacije in obratno.

Table 28: Review of the results of the analysis on impact of spatial and spectral resolution, transformation and filtering on segmentation quality. Indices that are in comparison to original image higher (red), lower (green) and equal (black). High indices values refer to lower segmentation quality and vice versa.

	Delež nerazpoznanih objektov	Število segmentov	Odstopanje površine	Odstopanje obsega	Položajno odstopanje
Izvirna testna podoba (8 kanalov, 0,5 m)	0 %	20	8,3 %	26,1 %	0,7 m
Spektralna ločljivost (2 kanala, CB in B)	0 %	10	10,6 %	30,2 %	0,9 m
Prostorska ločljivost (2,5 m)	8 %	4	21,3 %	20,3 %	1,8 m
Transformacije (PCA)	0 %	8	13,1 %	32,7 %	1,0 m
Filtriranje (Mediana)	0 %	15	6,9 %	18,0 %	0,7 m

Zmanjšanje prostorske ločljivosti ima negativen vpliv na razpoznavanje objektov. Povprečno število segmentov se zmanjša tako z variiranjem spektralne in prostorske ločljivosti podobe kot tudi s transformacijo in filtriranjem podobe. Toda samo s filtriranjem podobe se hkrati doseže nižje povprečno odstopanje obsega in površine ter se ne poveča položajno odstopanje med mejo testnega objekta in mejo referenčnega objekta. Rezultati izvedene analize vplivov na segmentacijo so pokazali, da lahko z uporabo filtrov glajenja podobe, ki ohranjajo robove, pridobimo bolj kakovostne rezultate segmentacije kot s segmentacijo izvorne podobe.

6.5.2 Analiza vplivov na klasifikacijo

Za potrebe analize vplivov na klasifikacijo sem segmentacijo izvedla na filtrirani podobi, objektno klasifikacijo pa na podlagi vzorcev s klasifikatorjem najbližji sosed. Referenčne podatke za oceno natančnosti klasifikacije sem zajela z metodo fointerpretacije in jih uvrstila v razreda pozidano in nepozidano. V referenčnem sloju podatkov je 153 objektov, od tega 31 objektov razreda pozidano in 122 nepozidano.

Natančnost klasifikacije sem ocenila s klasifikacijsko matriko napak, na podlagi katere sem izračunala tri cenilke kakovosti: skupno, uporabnikovo in proizvajalčevo natančnost.

Vpliv spektralne ločljivosti

Izbira spektralnih kanalov ima zelo velik vpliv na skupno natančnost klasifikacije, vendar je ta vpliv odvisen od števila kanalov, na podlagi katerih izvajamo klasifikacijo. Izbira spektralnega kanala na podlagi klasifikacije eno-kanalne podobe povzroči velike razlike v skupni natančnosti (do 30 %), z večanjem števila kanalov se občutljivost na izbiro kanalov manjša in pri tri-kanalni podobi znaša le še 1,5 %.

Najvišja skupna natančnost (93,7 %) je bila dosežena na podlagi klasifikacije dvo-kanalne podobe (robni moder in bližnji IR1), z večanjem števila kanalov pa skupna natančnost postopoma pada in je najnižja pri klasifikaciji izvorne, osem-kanalne podobe (90,7 %).

Ocenjujem, da lahko najvišjo natančnost dosežemo z uporabo majhnega števila kanalov, vendar je v tem primeru zelo pomembna izbira kanalov, ki omogočajo najboljše razlikovanje med objektnimi razredi, v konkretnem primeru med pozidanimi in nepozidanimi površinami. Poleg višje natančnosti je prednost klasifikacije z uporabo manjšega števila kanalov tudi prihranek na času obdelave. Čas obdelave izvorne podobe (osem-kanalne), ki obsega območje v velikosti 25 km², je 5,5 minute, dvo-kanalne podobe pa je vsaj za polovico krajši, 2,5 minute. Prihranki na času trajanja obdelave so pomembni predvsem pri klasifikaciji podatkov na obsežnih območjih, t. j. na ravni regije ali države.

Vpliv prostorske ločljivosti

Prostorska ločljivost ima vpliv na podrobnost razpoznavanja objektov na podobi. V analizi sem preučevala vpliv prostorske ločljivosti na ravni podrobnosti merila 1 : 5000. Zmanjševanje prostorske ločljivosti ima negativen vpliv na kakovost klasifikacije pozidanih površin, vendar je ta vpliv pri zmanjšanju prostorske ločljivosti do 2,5 m majhen. Razlike v skupni natančnosti izvorne (0,5 m) in 2,5 m podobe znašajo največ 1,6 %. Z zmanjšanjem prostorske ločljivosti na 5 m in manj je upad skupne natančnosti bistveno večji in pri 20 m znaša že 16,6 %. Na podlagi rezultatov analize ocenjujem, da ima prostorska ločljivost bistven vpliv na fazo segmentacije, medtem ko na objektno klasifikacijo nima tako velikega vpliva. Če se segmentacija izvede na podobi z visoko prostorsko ločljivostjo ali se za meje segmentov prevzamejo poljubni vektorski podatki (npr. zemljiške parcele), lahko za klasifikacijo uporabimo tudi podobo z nižjo prostorsko ločljivostjo. Na podlagi izvedene analize ocenjujem, da za klasifikacijo pozidanih površin na ravni podrobnosti 1 : 5000 zadošča prostorska ločljivost 2,5 m.

Vpliv filtriranja

Rezultati izvedenih testov klasifikacije zglajene podobe s filtrom povprečenja, mediana in Gaussovimi filtrom kažejo, da postopki filtriranja nimajo vpliva na kakovost klasifikacije. V primerjavi z izvorno podobo je skupna natančnost klasifikacije zglajene podobe nekoliko nižja (1,4 %). Na podlagi izvedenih testov ocenjujem, da uporaba postopkov glajenja podobe za klasifikacijo pozidanih površin ni smiselna.

Vpliv transformacije

Rezultati analize kažejo, da ima transformacija podobe negativen vpliv na skupno natančnost klasifikacije in pozitiven vpliv na čas trajanja obdelave podobe, ki pri transformiranih podobah traja za približno polovico manj časa. Najvišjo skupno natančnost transformiranih podob sem

dosegla z uporabo transformacij, ki zmanjšajo koreliranost med podatki različnih spektralnih kanalov (PCA in dekorelacijski razteg).

Primerjava ključnih rezultatov analize vplivov na objektno klasifikacijo je podana v preglednici 29.

Preglednica 29: Pregled rezultatov analize vpliva prostorske in spektralne ločljivosti ter transformacij in filtriranja podobe na kakovost klasifikacije. Cenilke posameznih podob, ki so v primerjavi z izvorno podobo višje (rdeče polnilo), nižje (zeleno polnilo) in enake (brez polnila). Višje vrednosti cenilk se nanašajo višjo kakovost klasifikacije in obratno.

Table 29: Review of the results of the analysis on impact of spatial and spectral resolution, transformation and filtering on classification quality. Indices that are in comparison to original image higher (red fill), lower (green fill) and equal (no fill). High indices values refer to higher classification quality and vice versa.

	Skupna natančnost	Uporabnikova natančnost (pozidane površine)	Proizvajalčeva natančnost (pozidane površine)	Trajanje obdelave
Izvorna testna podoba (8 kanalov, 0,5 m)	90,7 %	99,0 %	81,9 %	5,5 min
Spektralna ločljivost (2 kanala, CB in IR1)	93,7 %	93,7 %	93,3 %	2,5 min
Prostorska ločljivost (2,5 m)	89,1 %	96,9 %	80,2 %	5,5 min
Transformacije (PCA)	89,9 %	92,5 %	86,1 %	2,5 min
Filtriranje (mediana)	89,3 %	96,9 %	80,7 %	5,5 min

Na podlagi rezultatov analize ocenjujem, da imata samo zmanjšanje prostorske ločljivosti in filtriranje negativen oziroma nimata vpliva na izboljšanje kakovosti klasifikacije pozidanih površin, medtem, ko lahko z optimalno izbiro kombinacije spektralnih kanalov ali s transformacijo posnetka vplivamo na izboljšanje kakovosti klasifikacije. Na ta način lahko tudi zmanjšamo količino podatkov za obdelavo in s tem tudi čas obdelave, ki ga lahko prepolovimo.

Na podlagi izvedenih testov ocenjujem optimalno izbiro podatkov in izbranih postopkov predobdelave posnetka Worldview-2 za objektno usmerjeno analizo pozidanih površin na ravni podrobnosti merila 1 : 5000. Za segmentacijo posnetka je optimalna uporaba filtrirane podobe s filtrom, ki ohranja robove, za klasifikacijo pa podobo z le dvema spektralnima kanaloma – robni moder in bližnji IR1.

7 UPORABA SAMODEJNE KLASIFIKACIJE V PROCESU VZDRŽEVANJA PROSTORSKIH PODATKOV

Po vzpostavitvi zbirke prostorskih podatkov in prvega zajema podatkov je ključnega pomena redno vzdrževanje podatkov. Gre za usklajevanje zbirke podatkov z dejanskim stanjem v prostoru. Za potrebe zagotavljanja zahtev uporabnikov je treba zagotoviti redno vzdrževanje zbirk podatkov tako, da le-te izkazujejo dejansko stanje v prostoru. Klasične metode vzdrževanja podatkov, ki temeljijo na podatkih daljinskega zaznavanja, identificirajo in zajamejo podatke o novih in spremenjenih objektih z metodo fotointerpretacije. Posebej pri zbirkah podatkov, ki obsegajo velika prostorska območja (npr. celo državno ozemlje) je metoda zelo dolgotrajna. Operater mora pregledati celotno državno ozemlje, da identificira lokacije spremenjenih in novih objektov.

V okviru magistrske naloge sem proučila možnost uporabe samodejne klasifikacije, ki bi lahko bistveno izboljšala učinkovitost vzdrževanja podatkov na podlagi podatkov daljinskega zaznavanja. V raziskavi sem se osredotočila na razpoznavo pozidanih površin, saj bi raziskovanje vseh vrst pokrovnosti tal presegalo obseg te naloge. V prvih treh podpoglavjih so podrobneje predstavljene izbrane državne zbirke podatkov, ki bi se lahko vzdrževale na podlagi predlagane metodologije. To so kataster stavb, dejanska raba prostora in pokrovnost tal ter topografski podatki.

Predhodno izvedena analiza vplivov na klasifikacijo pozidanih površin in ugotovitve, ki sledijo iz te analize, so predstavljala temeljna izhodišča pri razvoju metodologije za identifikacijo sprememb pozidanih površin glede na evidentirano stanje. Metodologija je preverjena na primeru katastra stavb in dejanske rabe kmetijskih in gozdnih zemljišč (pozidane površine). V četrtem podpoglavju je predstavljena metodologija in rezultati uporabe metodologije na primeru optičnega posnetka zelo visoke (0,5 m) in serije posnetkov visoke (5 m) prostorske ločljivosti. V zadnjem, petem podpoglavju, je podan povzetek rezultatov.

7.1 Kataster stavb

Topografski podatki o stavbah se vodijo v katastru stavb (obris stavbe) in v državni topografski bazi. V nadaljevanju je podrobneje opisan kataster stavb.

Kataster stavb je temeljna evidenca podatkov o stavbah in delih stavb v Republiki Sloveniji. Povezuje stvarne pravice na stavbah, ki jih vodi zemljiška knjiga, z lokacijo v prostoru (GURS, 2015). Zakonski podlagi za vzpostavitev, vodenje in vzdrževanje katastra stavb sta Zakon o evidentiranju nepremičnin (ZEN – Uradni list RS št. 47/2006) in Pravilnik o vpisih v kataster stavb (Uradni list RS, št. 73/2012).

V kataster stavb se evidentirajo vse stavbe v Republiki Sloveniji, ki ustrezajo definiciji stavbe po ZEN. Ta opredeljuje stavbo kot objekt, v katerega lahko človek vstopi in je namenjen njegovemu stalnemu ali začasnemu prebivanju, opravljanju poslovne in druge dejavnosti ali zaščiti ter ga ni mogoče prestaviti brez škode za njegovo substanco. Za vzpostavitev, vzdrževanje in vodenje katastra stavb je pristojna Geodetska uprava RS. V centralni bazi katastra stavb se vodijo naslednji podatki o stavbah in delih stavb:

- identifikacijska oznaka,
- lastnik,

- upravljavec,
- lega in oblika,
- površina,
- dejanska raba,
- številka stanovanja ali poslovnega prostora ter
- identifikatorji, ki omogočajo povezava z zemljiškim katastrom, registrom prostorskih enot in zemljiško knjigo.

Pravilnik o vpisu stavb v kataster stavb loči dva statusa podatkov: katastrski in registrski podatki. Katastrski podatki so pridobljeni iz elaborata za vpis stavbe v kataster stavb, ki ga izdelata geodetsko podjetje ali projektant, medtem ko so registrski podatki pridobljeni na podlagi prijave za vpis registrskih podatkov ali s prevzemom podatkov iz drugih evidenc (Grilc in sod., 2003).

Za potrebe analize možnosti uporabe samodejne klasifikacije v procesu vzdrževanja katastra stavb se bom v nadaljevanju osredotočila na niz podatkov o stavbi, ki določajo njeno obliko in lego v prostoru. Vse evidentirane stavbe imajo opredeljeno lego v prostoru s koordinatami karakteristične točke fundusa stavbe (centroid). Večina stavb ima opredeljeno tudi obliko z grafičnim prikazom obrisa stavbe v državnem koordinatnem sistemu. Katastrski podatki imajo obris stavbe, določen s presekom najširšega obsega stavbe s terenom, registrski podatki pa kot obris strehe, določen s fotointerpretacijo podatkov CAS.

7.1.1 Vzdrževanje

Kataster stavb je bil vzpostavljen v okviru projekta Vzpostavitev katastra stavb – registrski podatki (LREST), ki se je izvajal med leti 2002 in 2004 (Grilc in sod., 2003). V okviru projekta so bili zajeti registrski podatki o stavbah in delih stavb v Sloveniji. Lega in oblika posamezne stavbe sta bili določeni s fotogrametričnim zajemom obrisov stavb, preostali podatki iz drugih podatkovnih zbirk. Tako vzpostavljena podatkovna zbirka je predstavljala začetno stanje katastra stavb.

V nadaljevanju je podan povzetek Zakona o evidentiranju nepremičnin v delu, ki se nanaša na vzdrževanje podatkov katastra stavb. Vpis nove stavbe v kataster stavb se izvede na podlagi elaborata za vpis stavbe v kataster stavb, ki ga izdelata geodetsko podjetje ali projektant. Investitor gradnje, lastnik stavbe ali dela stavbe, imetnik stavbne pravice ali upravljavec stavbe mora najkasneje v 30 dneh po zaključku gradnje vložiti zahtevek za vpis v kataster stavb. Podoben postopek velja tudi za spremenjene stavbe. Kot sprememba se štejejo:

- sprememba številke stavbe ali številke dela stavbe,
- sprememba lege, oblike ali površine,
- sprememba dejanske rabe,
- sprememba številke stanovanja ali poslovnega prostora,
- združitev in delitev stavbe ali dela stavbe,
- vpis novega dela stavbe ali
- izbris stavbe ali dela stavbe.

Če Geodetska uprava RS ugotovi, da stavba ali del stavbe ni evidentiran v katastru stavb oziroma, da je stavba spremenjena, pozove pristojno osebo, da v treh mesecih po prejemu poziva vloži zahtevo za vpis stavbe v kataster stavb oziroma zahtevo za spremembo podatkov katastra stavb. Če pristojna oseba tega v določenem roku ne stori, Geodetska uprava RS lahko posreduje prijavo prekrškovnemu organu.

Vzdrževanje katastra stavb na podlagi izvajanja zakonskih določil je zagotovljeno predvsem s procesi, ki pogojujejo evidentiranost stavbe v katastru stavb:

- vpis etažne lastnine v zemljiško knjigo,
- pridobitev uporabnega dovoljenja,
- pridobitev hišne številke,¹
- prijava stalnega prebivališča in
- prijava sedeža pravne osebe.

Kljub doslednemu izvajanju zakonskih določil ostaja v praksi velik delež stavb neevidentiran. Nepopolno je tudi poročanje o spremembah evidentiranih stavb (dograditve objektov, rušenje objektov, nadomestni objekti). Za potrebe zagotavljanja kakovosti in popolnosti podatkov o nepremičninah Geodetska uprava RS identificira neevidentirane stavbe oziroma spremembe evidentiranih stavb z ročnim pregledom ortofotov. Postopek iskanja neevidentiranih in spremenjenih stavb je časovno in kadrovsko zelo potraten. Zato so v letu 2013 testirali možnost uporabe samodejnih postopkov za identifikacijo neevidentiranih stavb (Geodetski inštitut Slovenije, 2013). Enotna in popolnoma samodejna metoda se je uporabila na 900 listih ortofoto. Razvoj metod samodejne identifikacije neevidentiranih stavb se je nadaljeval v letu 2014, in sicer v okviru projekta Prenova nepremičninskih evidenc (Mesner in Babič, 2014). Na podlagi kombinacije lidarskih podatkov in ortofotov so bile identificirane neevidentirane, neskladne in porušene stavbe na 700 listih ortofota.

7.1.2 Izkušnje z uporabo samodejnih postopkov

Samodejni zajem podatkov o stavbah predstavlja pomembno raziskovalno področje že skoraj dve desetletji (Rottensteiner in sod., 2014). Predmet raziskovanja so tako različni algoritmi identifikacije stavb kot tudi različne vrste podatkov: satelitski in letalski posnetki (Bric in sod., 2010), stereopari (Holland, Sanchez-Hernandez in Gladstone, 2008), podatki laserskega skeniranja (Matikainen in sod., 2010; Grigillo, Kosmatin Fras in Petrovič, 2011) in kombinacije različnih vrst podatkov. Predmet raziskav so samodejni postopki za izvedbo obeh faz vzdrževanja podatkov (Mayer, 2008):

- identifikacija stavbe (nova, nespremenjena in porušena stavba) in
- zajem obrisa stavbe.

Dosedanje izkušnje kažejo predvsem na uporabnost rezultatov samodejne interpretacije v prvi fazi vzdrževanja, t. j. identifikaciji stavbe. Ta postopek, ki se tradicionalno izvaja na podlagi vizualnega pregleda optičnih posnetkov in vektorskih podatkov o stavbah, je zelo dolgotrajen. Po nekaterih ocenah predstavlja strošek dela vzdrževanja podatkov kar 40 %

¹ Pogoj o pridobitvi hišne številke velja samo v primeru, če Zakon o določanju območij ter o imenovanju in označevanju naselij, ulic in stavb (ZDOIONUS - *Uradni list RS*, št. 25/2008) določa, da mora obravnavana stavba imeti hišno številko.

stroška celotnega zajema (Steinnocher in Kressler, 2006). Visoki stroški vzdrževanja podatkov o stavbah in izkušnje raziskovalcev s samodejnimi postopki identifikacije stavb so razlogi, da so želje in pričakovanja po uvedbi samodejnih postopkov v operativno delo vzdrževanja teh podatkov zelo visoka. Zato je organizacija EuroSDR v letu 2009 izvedla obsežno raziskavo, s katero so skušali oceniti možnost uporabe samodejnih postopkov za identifikacijo neevidentiranih stavb za potrebe vzdrževanja 2D-baz podatkov (Champion in Everaerts, 2009). V raziskavi so proučili popolnost in pravilnost identifikacije stavb z uporabo:

- različnih metodologij,
- različnih vrst podatkov (letalski in satelitski posnetki različne prostorske ločljivosti ter podatki laserskega skeniranja) ter
- na raznolikih območjih glede tipa poselitve in rabe prostora ter glede razgibanosti terena.

Rezultati raziskave so obetajoči, predvsem iz vidika visoke popolnosti rezultatov. Najboljše rezultate so dosegli z uporabo letalskih posnetkov s prostorsko ločljivostjo 20 cm. Popolnost nespremenjenih, porušenih in novih stavb je presegla 95 %. Tudi pravilnost nespremenjenih in novih stavb je zelo visoka (več kot 96 %), vendar so se napake pojavljale predvsem pri identifikaciji porušenih stavb (pravilnost znaša le 22 %). V raziskavi so bili uporabljeni podatki laserskega skeniranja nizke kakovosti zato raziskava ni dala odgovora ali je pravilnost in popolnost klasifikacije možno izboljšati na podlagi natančnega modela površja in reliefa, izdelanega iz laserskih podatkov.

Nadaljnje raziskave kažejo (Matikainen in sod., 2010), da se lahko pravilnost identifikacije stavb bistveno izboljša s kombinirano uporabo podatkov laserskega skeniranja in optičnih posnetkov. Z natančnimi podatki o višini objektov se izloči delež napak, ki nastane pri razlikovanju med stavbami in površjem Zemlje, s spektralnimi podatki iz letalskih posnetkov pa se izločijo predvsem napake, ki nastanejo pri razlikovanju med vegetacijo in stavbami. Z uporabo kombinacije teh podatkov se lahko doseže tudi pravilnost, višja od 86 % (za stavbe, večje od 20 m²).

Tudi v Sloveniji je bilo izvedenih več raziskav s področja samodejne identifikacije stavb (Grigillo, Kosmatin Fras in Petrovič, 2011; Bric in sod., 2010) in dva pilotna projekta identifikacije neevidentiranih stavb v katastru stavb (Geodetski inštitut Slovenije, 2013; Mesner in Babič, 2014). Grigillo, Kosmatin Fras in Petrovič (2011) so razvili algoritem identifikacije novih, spremenjenih in porušenih stavb na podlagi podatkov laserskega skeniranja in letalskih posnetkov. Visoka popolnost in pravilnost rezultatov (93,5 in 78,4 %) kažeta na uporabnost razvitega algoritma za potrebe vzdrževanja podatkov o stavbah. Izvedena je bila tudi obsežna raziskava o uspešnosti samodejne identifikacije z uporabo različnih vrst podatkov (Bric in sod., 2010). Primerjava rezultatov identifikacije na podlagi kombiniranih podatkov laserskega skeniranja in letalskih posnetkov, podatkov cikličnega aerosnemanja, satelitskih posnetkov, je pokazala, da se najbolj kakovostni rezultati dosežejo prav z uporabo kombinacije optičnih posnetkov in podatkov lidarskega snemanja.

Obsežnejšo raziskavo s tega področja je v letu 2014 izvedel ISPRS – International Society for Photogrammetry and Remote Sensing (Rottensteiner in sod., 2014). Na razpolago so dali vzorčne podatke in povabili raziskovalce k obdelavi teh podatkov. Tako so analizirali vpliv

razvitih algoritmov, različnih vrst podatkov in različne prostorske ločljivosti na kakovost končnih rezultatov. Na podlagi analiz več kot 20-ih skupin raziskovalcev je bilo ugotovljeno, da:

- ima bistven prispevek h kakovosti rezultatov algoritem identifikacije stavb,
- višjo kakovost identifikacije stavb dosežemo z uporabo kombinacije optičnih posnetkov in podatkov lidarskega skeniranja,
- so za stavbe, večje od 50 m², z nekaterimi algoritmi dosegli 100-odstotno pravilnost in popolnost identifikacije stavb,
- imajo samodejno pridobljeni obrisi stavb večje nepravilnosti.

V raziskavi sta sodelovali tudi dve slovenski raziskovalni skupini, in sicer Fakulteta za gradbeništvo in geodezijo Univerze v Ljubljani in Znanstvenoraziskovalni center SAZU (Grigillo in Kanjir, 2012) ter Fakulteta za računalništvo in informatiko Univerze v Mariboru (Mongus in sod., 2013). Obe sta dosegli ene izmed boljših rezultatov popolnosti in pravilnosti identifikacije stavb, kar je zelo spodbudno za uporabo samodejnih postopkov v Sloveniji. Možnosti uporabe razvitih metod za potrebe operativnega vzdrževanja podatkov o stavbah v Sloveniji je dal uspešno zaključen projekt laserskega skeniranja Slovenije v letu 2015 (Bric in sod., 2015). Za potrebe samodejne identifikacije stavb se lahko uporabijo tako izvorni podatki (georeferenciran oblak točk) kot tudi klasificiran oblak točk (GKOT). Popolnost in pravilnost klasifikacije stavb v izdelku GKOT sta zelo visoki. Vrednosti se med posameznimi območji snemanja sicer razlikujejo, vendar je na vseh območjih dosežena povprečna popolnost med 97,7 % in 99,7 % ter povprečna pravilnost med 86,3 % in 96,0 % (Triglav Čekada, Bric in Mongus, 2015).

Na podlagi rezultatov navedenih raziskav ocenjujem, da je razvoj na področju postopkov samodejne identifikacije dosegel raven, ki omogoča uporabo teh postopkov v operativni izvedbi, in sicer v fazi identifikacije spremembe, medtem ko bodo za samodejni zajem obrisa stavbe potrebne dodatne raziskave. Prav tako bo treba izboljšati še tehnike identifikacije manjših stavb.

7.1.3 Pregled uporabe samodejne interpretacije za vzdrževanje podatkov o stavbah

V letu 2013 je bil izveden pilotni projekt identifikacije neevidentiranih stavb v katastru stavb (Geodetski inštitut Slovenije, 2013) na podlagi podatkov cikličnega aerosnemanja (CAS), digitalnega modela površja (DMP), izračunanega iz CAS, in digitalnega modela reliefa DMR5. Razvit je bil samodejni postopek identifikacije neevidentiranih stavb, ki ustrezajo kriteriju za vpis v kataster stavb (minimalna površina 4 m² in minimalna višina 2 m). Za potrebe ocene uporabnosti algoritma na obsežnejšem območju so bile identificirane stavbe na celotnem območju snemanja v letu 2013, ki je obsegalo približno 900 listov TTN5.

Pravilnost in popolnost postopka sta bili določeni na šestih območjih, ki obsegajo različne gostote pozidave, razgibanosti terena in vrste urbane rabe prostora. Popolnost je znašala od 68 do 84 %, pravilnost pa od 44 do 81 %. Veliko število napak so predstavljale manjše in nizke stavbe, zato je bila v naslednjem pilotnem projektu omejena samodejna identifikacija stavb na večje stavbe, katerih površina obrisa je znašala več kot 20 m² (Mesner in Babič, 2014). Poleg tega je bila kakovost klasifikacije izboljšana s podatki laserskega skeniranja. Rezultat obeh pilotnih projektov so točkovni sloj podatkov sprememb v katastru stavb z

opredeljenim tipom spremembe (nova, porušena in spremenjena stavba) ter površina in višina spremenjene stavbe. Na testnem območju, ki je obsegalo 700 listov TTN5, je bilo identificiranih skoraj 60.000 sprememb, od tega 52 % novih, 31 % neskladnih in 17 % porušenih stavb.

V Švici se ročno pregleduje celotno državno ozemlje, a spremembe se ugotovijo le na 5 % (Kellenberger in Streilein, 2010). Z uporabo samodejnih postopkov za identifikacijo lokacij v prostoru, kjer je prišlo do spremembe, bi v praksi pomenilo, da bi se operater osredotočil na 5 % površin in ne na celotno državno ozemlje. Poraba časa (in denarja) bi bila v tem primeru znatno nižja.

Velika Britanija je na področju uporabe samodejne identifikacije izvedla korak naprej, saj samodejne postopke deloma že uporabljajo v operativnih nalogah vzdrževanja topografskih podatkov (Gladstone, Gardiner in Holland, 2012). S samodejnimi postopki identificirajo spremembe nizke vegetacije, visoke vegetacije, vode stavb in drugih pozidanih površin. Popolnost rezultatov za stavbe je visoka (92 %), medtem ko je pravilnost precej pod pragom minimalne vrednosti za kakovosten sistem (Mayer, 2008), saj znaša le 22 %. Kljub temu ocenjujejo, da je prihranek časa za zajem spremembe, v primerjavi s klasičnimi postopki, približno 50 %. Kakovost in uporabnost postopka v operativni izvedbi vrednotijo iz vidika števila stavb, ki jih operaterju ni treba preverjati. Champion in Everaerts (2009) ocenjujeta, da je samodejni sistem učinkovit, če izloči od 80 do 90 % stavb, ki jih operater ne preverja.

7.2 Dejanska raba prostora in pokrovnost tal

7.2.1 Dejanska raba prostora

Dejanska raba prostora je območje zemeljskega površja, opredeljeno glede na svojo sedanjo funkcionalno razsežnost ali socialno-ekonomski namen (npr. stanovanjska, industrijska, kmetijska, rekreacijska raba) (Inspire Directive, 2007). Za učinkovito upravljanje s prostorom so podatki o rabi prostora temeljnega pomena za vsako sodobno družbo. V Sloveniji je podatek o dejanski rabi prostora na voljo v:

- evidenci dejanske rabe kmetijskih in gozdnih zemljišč (v nadaljevanju dejanska raba MKGP) ter v
- zemljiškem katastru.

Podatek o vrsti rabe se je do leta 2013 vodil v zemljiškem katastru, in sicer na parcelnih delih. Zaradi nesistematičnega vzdrževanja podatka o vrsti rabe evidentirani podatki niso izkazovali dejanskega stanja v naravi in so bili ukinjeni (Mivšek in sod., 2012). Od leta 2013 dalje se podatek o rabi posamezne zemljiške parcele prevzame iz dejanske rabe MKGP. Podatek se določi z grafičnim presekom zemljiškega katastra (zemljiškokatastrski načrt, lokacijsko izboljšani podatki zemljiškega katastra ali zemljiškokatastrski prikaz) in dejanske rabe MKGP. Raba zemljiške parcele se vodi kot delež posameznih vrst dejanske rabe na zemljiški parceli.

Po ukinitvi podatka o vrsti rabe v zemljiškem katastru je ostal edini vir podatkov o rabi prostora za območje Slovenije z rednim vzdrževanjem dejanska raba, ki jo vodi in vzdržuje Ministrstvo za kmetijstvo, gozdarstvo in prehrano v triletnih ciklih. Gre za zvezen grafični sloj podatkov o podrobni vrsti rabe za kmetijska in gozdna zemljišča ter o osnovni vrsti rabe za

pozidana, vodna in druga zemljišča na območju Slovenije. Osnovni namen vzpostavitve in rednega vzdrževanja te evidence je ugotavljanje upravičenosti kmetijskih gospodarstev do pridobitve kmetijskih subvencij (Arh, 2012). Vendar evidenca zvezno prekriva celotno državno ozemlje s podatki o dejanski rabi in se redno vzdržuje, zato njena uporaba presega namen, za katerega je bila vzpostavljena. Nekaj primerov uporabe evidence:

- določitev dejanske rabe posameznih zemljiških parcel,
- izračun posplošene tržne vrednosti nepremičnin,
- analiza dejanskega stanja v prostoru za potrebe prostorskega načrtovanja,
- spremljanje stanja prostorskega razvoja,
- ugotavljanje sprememb rabe tal (npr. krčenja gozdov),
- statistika rabe tal,
- poročanje v skladu z evropskimi direktivami,
- ocena vplivov in učinkov trajnostnega razvoja okolja idr.

Nekateri praktični primeri uporabe dejanske rabe MKGP (Arh, 2012; Lisec, Pišek in Drobne, 2013; Nastran in Žižek Kulovec, 2014; Foški, 2015) so pokazali, da evidenca ni primerna za ugotavljanje sprememb v prostoru. Razlog so spremembe metodologije med posameznimi leti zajema, zaradi česar so ugotovljene spremembe v prostoru deloma posledica sprememb metodologije in le deloma dejanskih sprememb. Spremembe metodologije so skladne s spremembami politike dodeljevanja kmetijskih subvencij in zato so za osnovni namen, za katerega je bila evidenca vzpostavljena, te spremembe nujne. Je pa uporaba take evidence za druge namene zato lahko sporna. Prav tako je uporaba te evidence za določitev rabe zemljiških parcel neprimerna, saj je položajna natančnost grafičnih podatkov zemljiškega katastra na območju vzdrževanja z grafično metodo bistveno nižja od podatkov dejanske rabe.

Zaradi neprimernosti uporabe te evidence v procesih prostorskega načrtovanja in spremljanja prostorskega razvoja se je pojavila potreba po vzpostavitvi nove evidence dejanske rabe prostora. V letu 2013 je Ministrstvo za okolje in prostor (Kete in sod., 2013) izdelalo metodologijo za novo evidenco dejanske rabe prostora s podrobno členitvijo urbanega prostora in testnim zajemom podatkov za dve občini – Jesenice in Škofja Loka (Mivšek in sod., 2014). Cilji so vzpostavitev evidence dejanske rabe urbanega prostora za celotno Slovenijo, enotnost metodologije v različnih časovnih obdobjih, redno vzdrževanje in usklajenost z drugimi resorji (gozdarstvo, vodarstvo in kmetijstvo). Če bo vzpostavljena, bo ta evidenca predstavljala strokovno podlago za uporabo v številnih procesih, kjer se trenutno uporablja dejanska raba MKGP.

7.2.2 Pokrovnost tal

Pokrovnost tal je bio-fizični pokrov zemeljskega površja. Določa pokrovnost posameznega dela zemeljskega površja in ne namena oziroma uporabe območja (npr. voda, vegetacija, pozidano) (Inspire Directive, 2007). Pokrovnost tal se določa z neposrednimi opazovanji (prosto z očmi ali s pomočjo tehnik daljinskega zaznavanja). Podatki o pokrovnosti tal Slovenije se vodijo v naslednjih podatkovnih zbirkah:

- CORINE Land Cover,
- statistični GIS pokrovnosti tal in

- LUCAS.

CORINE Land Cover (v nadaljevanju CLC) je vzpostavila Evropska okoljska agencija med leti 1985 in 1990 s ciljem zagotavljanja standardiziranih podatkov o pokrovnosti tal in rabi prostora za podporo zemljiški politiki na evropski ravni (Buttner, 2014). Kategorizacija in metodologija implementacije podatkovne baze sta bili dogovorjeni in potrjeni s strani Evropske komisije ter se do danes nista spreminjali. To je temeljnega pomena za primerljivost posameznih zajemov v različnih časovnih obdobjih in za spremljanje sprememb v prostoru.

Za Slovenijo so na voljo podatki CLC za štiri časovna obdobja: 1995, 2000, 2006 in 2012 ter podatki o spremembah med posameznimi obdobji CORINE Land Cover Change (v nadaljevanju CLCC), ki je postal glavni izdelek programa CORINE. Za Slovenijo kot državo Evropske unije in lego v osrčju Evrope so ti podatki pomembni predvsem za podporo zemljiški politiki na evropski ravni, pri pripravi strateških analiz, pri ugotavljanju dejanskega stanja v prostoru in sprememb v prostoru. Eno izmed temeljnih slabosti podatkov CLC in CLCC predstavlja prevelika minimalna enota kartiranja, ki znaša 25 ha (Buttner, 2014). Nizka podrobnost kartiranja onemogoča uporabo podatkov za potrebe zemljiške politike na državni in lokalni ravni. Za Slovenijo je značilna izrazita razdrobljenost poselitve in obdelovalnih površin, zato je težava prenizke podrobnosti podatkov še toliko bolj pereča.

Statistični GIS pokrovnosti in rabe tal so do leta 2005 izdelovali na Statističnem uradu Republike Slovenije, saj podatki CLC niso zadoščali njihovim potrebam, predvsem zaradi prevelike enote kartiranja (25 ha) in neusklajenosti s statističnimi regijami. Bistvene prednosti statističnega GIS pokrovnosti in rabe tal v primerjavi s CLC so (Kuzma, 2013):

- večja raven podrobnosti (najmanjša enota kartiranja je 1 ha)
- usklajenost z mejami statističnih regij in
- uporaba dodatnih prostorskih podatkov pri izdelavi karte pokrovnosti (gozdni rob, obrisi voda, podatki o cestah).

Leta 2006 je evropski statistični urad EUROSTAT začel s projektom izdelave podatkov o pokrovnosti tal in rabi prostora LUCAS (Land Use/Cover Area frame statistical Survey), ki naj bi se uporabljal za potrebe statističnih analiz. Za večino evropskih držav (med njimi tudi Slovenijo) so na voljo podatki za leta 2006, 2009 in 2012. Toda podatki so še manj podrobni kot CLC (najmanjša enota kartiranja je 1 km²) in niso primerni za uporabo niti na lokalni niti na državni ravni (EUROSTAT, 2015).

7.2.3 Vzdrževanje

Dejanska raba MKGP se vzdržuje v rednih triletnih ciklih. Vsako leto se z metodo fotointerpretacije obnovijo podatki za približno tretjino Slovenije. Osnovni vir za vzdrževanje podatkov so ortofoti in množica pomožnih virov podatkov: arhivski ortofoti, topografski podatki, sloj GERK-ov, podatki o gozdovih, idr. Obnova podatkov poteka dvostopenjsko, in sicer na prvi stopnji posamezen poligon pregleda in po potrebi obnovi operater-zajemalec, na drugi stopnji pa obnovljene podatke potrdi in po potrebi popravi operater-kontrolor. Kakovost obnovljenih podatkov se nato preveri za 5 do 10 % podatkov (Nastran in Žižek Kulovec, 2014). Na ta način je zagotovljena visoka kakovost podatkov o dejanski rabi za potrebe ugotavljanja upravičenosti do kmetijskih subvencij.

Dvostopenjska obnova podatkov z metodo vizualne fotointerpretacije ortofotov in drugih pomožnih podatkov sicer zagotavlja kakovostne podatke, vendar je časovno in kadrovsko zelo potratna. Stroški obnove podatkov za celo Slovenijo znašajo po podatkih Programa del državne geodetske službe za leta 2013–2014 in 2014–2015 (Program dela državne geodetske službe, 2015) okrog 750.000 €. Stroški obnove ne vključujejo stroškov aerosnemanja in izdelave ortofotov.

CLC je od prve izvedbe leta 1995 do danes ohranjala metodologijo (podrobnost kartiranja, nomenklatura), medtem ko se je proces izdelave bistveno spremenil, skladno z razvojem tehnologije. CLC 1995 je bil izdelan ročno z izrisovanjem mej poligonov na plastične folije, ki so jih položili na izris satelitskega posnetka v merilu kartiranja, t. j. 1 : 100.000. Analogni izrisi so bili naknadno digitalizirani in zapisani v bazo podatkov. V naslednji izvedbi CLC 2000 se je ročni zajem nadomestil z računalniško podprto fotointerpretacijo, ki se uporablja še danes (Buttner, 2014). Operater na podlagi vizualnega pregleda dveh posnetkov (stari in novi) ugotavlja realne spremembe v prostoru, jih digitalizira in dodeli ustrezne attribute. Rezultat je karta sprememb (CLCC) med dvema zaporednima časovnima obdobjema in je podlaga za izdelavo nove karte CLC. Zaradi velikega obsega dela in subjektivnosti se pojavljajo težnje po uporabi delno samodejnih postopkov odkrivanja sprememb. S strani Evropske okoljske agencije ta sicer še ni predpisana, vendar so nekatere – predvsem velike države (npr. skandinavske države) že implementirale delno samodejne postopke v proces izdelave CLC-kart.

Prvi statistični GIS pokrovnosti in rabe tal je bil izdelan leta 1993 na podlagi satelitskih posnetkov Landsat TM s prostorsko ločljivostjo 30 m in vektorskih podatkov o cestah, železnicah in pozidanih površinah. Kasneje so bili izdelani še trije statistični GIS pokrovnosti in rabe tal (Kuzma, 2013). Osnovna območja pokrovnosti (gozdne, kmetijske, vodne, pozidane in odprte površine) so določena z nadzorovano večspektralno klasifikacijo satelitskih posnetkov in naknadno obdelana z dodatnimi vektorskimi podatki (Švab Lenarčič, 2009; Šabić in sod., 2000). Na voljo so podatki za štiri časovna obdobja: 1993, 1997, 2001 in 2005. Po izdelavi podatkovnega sloja v letu 2005 se Statistični GIS pokrovnosti in rabe tal ne posodablja več.

7.2.4 Izkušnje z uporabo samodejnih postopkov

Tradicionalno se ti podatki zajemajo in vzdržujejo z vizualno interpretacijo letalskih in/ali satelitskih posnetkov ter s terenskimi ogledi. Tovrstni postopki so dolgotrajni, subjektivni in dragi, zato je želja po uvedbi samodejnih postopkov zajema in odkrivanja sprememb zelo visoka. Samodejne metode klasifikacije satelitskih in letalskih posnetkov predstavljajo dobro alternativo klasični vizualni interpretaciji, saj omogočajo natančno, hitro in cenovno ugodno kartiranje večjih površin (Oštir, 2006).

Pomembnost podatkov o rabi in pokrovnosti tal ter težnja po avtomatizaciji postopka zajema in vzdrževanja teh podatkov sta glavna vzroka, da je organizacija EuroSDR v letu 2014 izvedla obsežno raziskavo s tega področja (Dommenech in Mallet, 2014). Proučili so možnost uporabe metode objektne klasifikacije za določitev pokrovnosti in rabe tal ter za identifikacijo sprememb v prostoru. Skupna natančnost identifikacije sprememb v prostoru je v urbanem okolju znašala kar 98,7 %, v ruralnem okolju pa 89,1 %. Pomemben izsledek te

raziskave je dejstvo, da so s samodejno metodo identificirali poligone, na katerih je prišlo do spremembe (9 %) in tako zmanjšali obseg dela za vizualno interpretacijo za več kot 90 %.

Primer dobre prakse uporabe samodejnih metod zajema in vzdrževanja podatkov o pokrovnosti tal in rabe prostora je avstrijski prostorski informacijski sistem LISA (Land Information System of Austria), ki vključuje dva podatkovna sloja – pokrovnost in rabo. Pokrovnost tal je razvrščena v 13 razredov in podatki so zajeti samodejno z metodo objektne klasifikacije v merilu 1 : 10.000. Skupna natančnost klasifikacije znaša 95,5 %, kar ustreza zahtevam uporabnikov. Podatki o pokrovnosti so poleg drugih prostorskih podatkov (zemljiški kataster, namenska raba prostora, prometna infrastruktura idr.) ključni vhodni podatek za izdelavo podatkovnega sloja rabe prostora v merilu 1 : 25.000 (Banko in sod., 2014). Model LISA je uspešno preстал fazo testiranja na 49-ih testnih območjih, kjer je posamezno območje obsegalo površino okrog 30 km². V letu 2014 se je začela faza implementacije modela LISA v okolici največjih urbanih regij v Avstriji, sledil pa bo zajem podatkov za celotno državno ozemlje.

Nekaj primerov s samodejnimi postopki vzpostavitve sloja pokrovnosti CLC in sloja sprememb CLCC najdemo tudi med večjimi evropskimi državami, ki so bile prisiljene razviti alternativne metode zajema podatkov zaradi obsežnih površin, ki jih obsegajo. Skandinavske države (Švedska, Norveška in Finska) uporabljajo samodejne postopke za zajem sprememb na gozdnih površinah in za generalizacijo rezultatov (Buttner, 2014). Glavni cilji uporabe samodejnih postopkov pri obnovi podatkov CLC so:

- zmanjšanje obsega dela,
- izboljšava natančnosti in ponovljivosti rezultatov ter
- izboljšava skladnosti z nacionalnimi bazami podatkov.

Kljub pozitivnim izkušnjam z uporabo samodejnih postopkov pri izdelavi CLC ostaja predpisana metoda še naprej vizualna fotointerpretacija, saj metode še niso razvite do ravni za množično uporabo.

7.2.5 Izkušnje v Sloveniji

Tudi v Sloveniji je bilo izvedenih več pilotnih izvedb določitve pokrovnosti in rabe prostora z uporabo samodejnih metod, vendar bi na tem mestu izpostavila predvsem primere uporabe za določitev pokrovnosti tal na celotnem državnem ozemlju:

- pokrovnost tal za potrebe načrtovanja mobilne telefonije in
- Statistični GIS pokrovnosti tal.

Pokrovnost tal za potrebe načrtovanja mobilne telefonije so izdelali na Znanstvenoraziskovalnem centru SAZU s klasično nadzorovano metodo klasifikacije posnetkov Landsat (Oštir in sod., 2000). Pokrovnost tal je razvrščena v deset razredov, ki so določeni glede na oviro, ki jo le-ta predstavlja za potovanje elektromagnetnega signala, to so:

- trije razredi pozidanih površin glede na gostoto pozidanosti,
- trije razredi gozdnih površin (listnati, iglasti in mešani gozd),
- grmičevje,

- vodne površine,
- odprte površine in
- neklasificirane površine.

Poleg satelitskega posnetka so bili, z namenom izboljšanja kakovosti podatkov pokrovnosti tal, v izdelavo sloja vključeni še naslednji podatkovni sloji:

- digitalni model višin DMV 25 ter
- vektorski podatki o vodotokih in vodnih površinah.

Pri izdelavi statističnega GIS pokrovnosti tal so uporabili nadzorovano klasifikacijo posnetkov Landsat za določitev petih osnovnih razredov pokrovnosti: gozdne, kmetijske, vodne, pozidane in odprte površine. Nato so z uporabo dodatnih vektorskih slojev o stavbah in prometni infrastrukturi pokrovnost podrobneje razčlenili na 17 razredov (Kuzma, 2013).

7.2.6 Ocena možnosti uporabe samodejne interpretacije v praksi

Kljub temu, da je za območje Slovenije na voljo več podatkovnih zbirk o pokrovnosti tal in rabi prostora, se v praksi redno vzdržujeta le dve:

- dejanske raba kmetijskih in gozdnih zemljišč ter
- CLC-pokrovnost tal.

Oba podatkovna sloja se vzdržujeta z metodo računalniško podprte vizualne fotointerpretacije ortofotov za dejansko rabo oziroma satelitskih posnetkov za CLC. Metoda je izredno zamudna, saj mora operater pregledati celotno državno ozemlje (20.000 km²), kljub temu, da so realne spremembe zgolj na manjšem deležu državnega ozemlja.

Glede na rezultate raziskave, ki jo je izvedla organizacija EuroSDR, ocenjujem, da bi se metode samodejne interpretacije lahko uporabile za identifikacijo sprememb v prostoru, kar bi lahko bistveno zmanjšalo obseg dela za vzdrževanje podatkov. Dommenech in Mallet (2014) ocenjujeta, da jim je s samodejnimi metodami uspelo zmanjšati obseg dela za vizualno interpretacijo za več kot 90 %. Za oceno možnosti uporabe samodejne interpretacije za potrebe vzdrževanja podatkov dejanske rabe MKGP bi bilo treba izvesti ciljne raziskave, s katero bi ocenili kakovost identificiranih sprememb po posameznih vrstah dejanske rabe.

7.3 Topografski podatki

Sestavni del državnega topografsko-kartografskega sistema Slovenije, ki ga vodi in vzdržuje Geodetska uprava RS, so tudi topografski podatki in državne karte (Zakon o državnem geodetskem referenčnem sistemu, Uradni list RS, št. 25/14):

- državna topografska karta merila 1 : 50.000 (DTK 50),
- topografska baza DTK 5 ter
- državne pregledne karte meril 1 : 250.000, 1 : 500.000, 1 : 750.000 in 1 : 1.000.000 (DPK 250/500/750/1000).

Poleg podatkov, ki so del državnega topografsko-kartografskega sistema, Geodetska uprava RS še vedno izdaja:

- temeljne topografske načrte merila 1 : 5.000 in 1 : 10.000 (TTN 5/10) ter
- državno topografsko karto merila 1 : 25.000.

TTN 5 so izdelani za območja naselitve in intenzivna kmetijska območja, TTN 10 za preostalo državno ozemlje. Izdelani so bili v 60-ih letih prejšnjega stoletja in so se v omejenem obsegu in nesistematično vzdrževali do leta 1997. Med letoma 1993 in 1995 so se izvorni načrti skenirali in so sedaj na voljo v rastrski obliki. Prav tako so zastareli podatki DTK 25 in GKB 25. DTK 25 je bil izdelan na podlagi topografske karte merila 1 : 25.000 Vojno-geografskega inštituta in kasneje delno obnovljen med leti 1994 in 1999. Kljub temu, da imata TTN 5/10 in DTK 25 širok krog uporabnikov, se je Geodetska uprava RS zaradi previsokih stroškov odločila, da se zbirki ne vzdržujeta več (Petrovič in sod., 2011).

Trenutno se vzdržujejo oziroma so v fazi izdelave le DTK 5, DTK 50 in DPK, zato sem se v nadaljevanju osredotočila na topografske podatke v zbirkah DTK 5 in DTK 50.

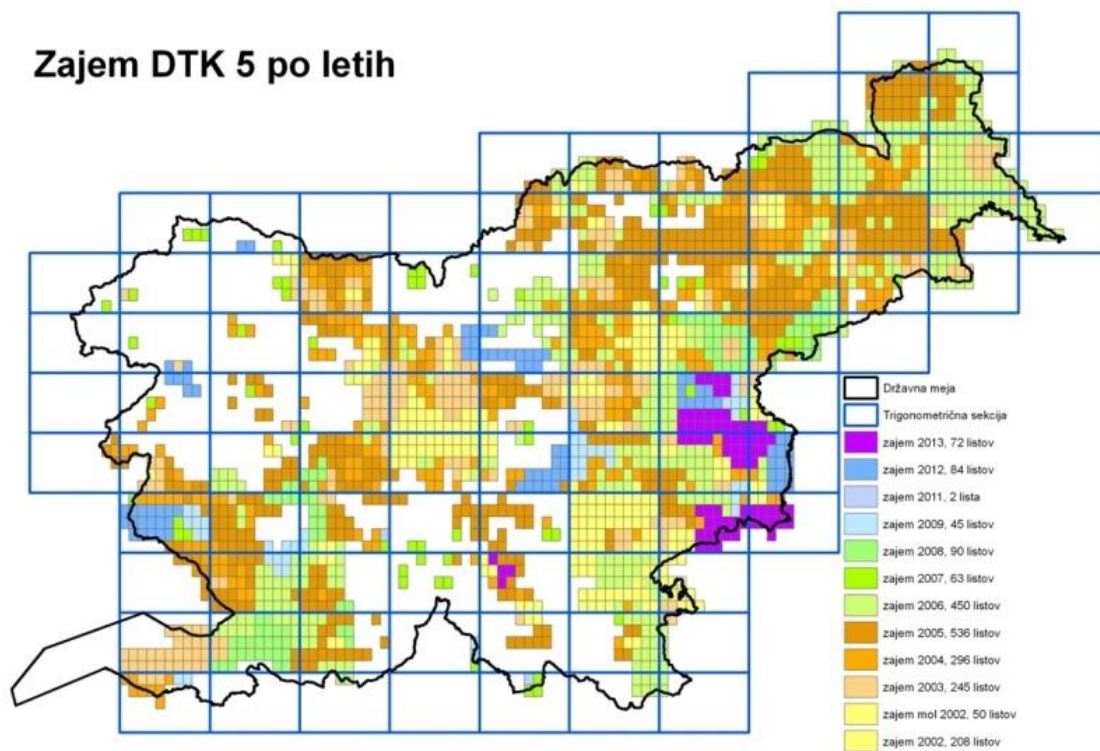
DTK 5 je vektorska zbirka topografskih podatkov homogene natančnosti in podrobnosti, ki ustreza ravni merila 1 : 5000. Do leta 2014 so bili podatki vsebinsko razdeljeni v štiri objektne skupine (zgradbe, promet, pokritost tal, hidrografija). Podatki o višinah in zemljepisnih imenih pa so se vodili v ločenih evidencah: digitalni model reliefa (DMR) in register zemljepisnih imen (REZI).

V letu 2014 je GURS pristopil k prenovi sistema vodenja topografskih podatkov. Na podlagi analize pomenske in vsebinske skladnosti DTK 5, podatkov DMR in REZI s specifikacijami direktive INSPIRE je bil zasnovan Državni topografski model (DTM), katerega bistvene spremembe glede na obstoječe stanje so (Kete in sod., 2014):

- odprava redundance v obstoječih zbirkah podatkov (neusklajenost in podvajanje grafičnih in opisnih podatkov) in neskladnosti s podatki v drugih podatkovnih zbirkah (npr. stavbe v katastru stavb, ceste v zbirnem katastru gospodarske javne infrastrukture),
- povezanost različnih podatkovnih zbirk v funkcionalno celoto,
- povezljivost z drugimi državnimi podatkovnimi zbirkami (npr. register nepremičnin, zbirni kataster gospodarske javne infrastrukture) in
- nadgradljivost z dodatnimi vsebinami (modularnost in razširljivost).

Prenovljeni podatkovni model obsega osem objektnih področij: stavbe (zgradbe), komunalne in javne storitve, prometna omrežja, pokritost tal (pokrovnost), rabo prostora, hidrografijo, zemljepisna imena in nadmorske višine. Obstoječi topografski podatki (DTK 5, REZI in podatki DMR) so bili migrirani v nov podatkovni model, v letu 2016 pa se prvič izvaja tudi zajem v skladu z novim podatkovnim modelom. Metoda zajema podatkov je nadgrajena, saj gre za kombiniran fotogrametrični zajem iz podatkov CAS in LSS, ki vključuje tudi interpretacijo pomožnih virov podatkov.

Zajem podatkov DTK 5 se je začel leta 2002 in do danes so na voljo podatki za približno 65 % državnega ozemlja. Pokritost Slovenije s podatki DTK 5 in leto izdelave sta prikazana na sliki 21 (Geodetska uprava RS, 2013).

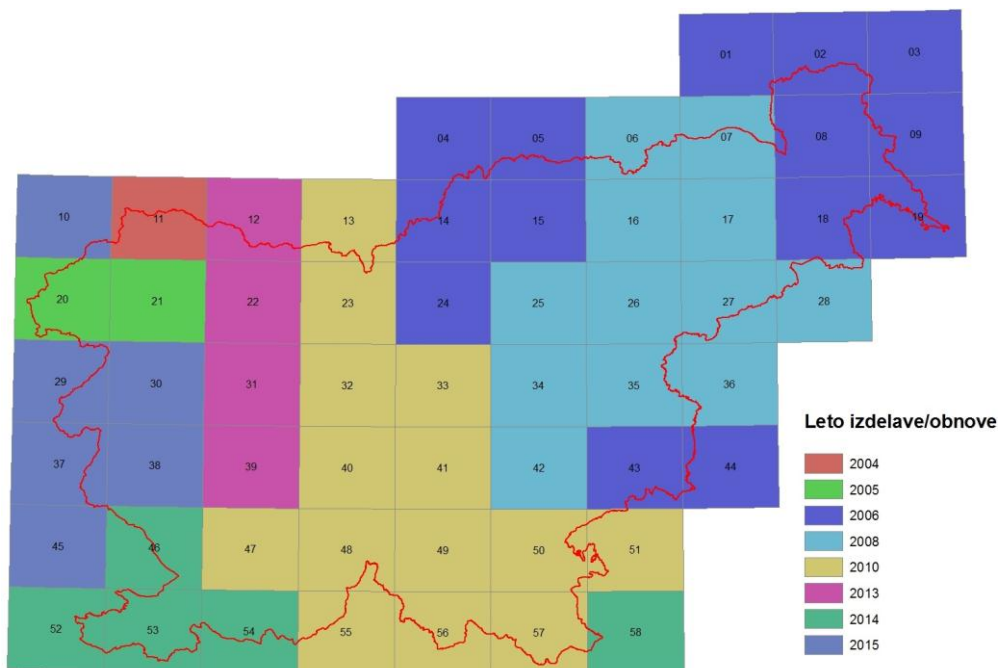


Slika 21: Izdelani listi DTK 5 po letih (Geodetska uprava RS, 2013).

Figure 21: Completed DTK 5 maps by year of production (Geodetska uprava RS, 2013).

DTK 50 je državna topografska karta v merilu 1 : 50.000. Izdelana je bila v letih od leta 2000 do leta 2005 s kombinacijo rastrskih in vektorskih podatkov. Od leta 2006 dalje se karte redno vzdržujejo. Pregled stanja podatkov po posameznih listih je prikazan na sliki 22. Podatki so na voljo v rastrski obliki, za obnovljene liste (95 %) pa tudi v vektorski obliki. Osnovni objektni tipi na DTK 50 so (Geodetska uprava RS, 2015);

- matematični elementi,
- naselja in objekti,
- komunikacije,
- relief,
- hidrografija,
- pokritost tal,
- meje in ločnice ter
- zemljepisna imena.




Slika 22: Leto izdelave oziroma zadnje obnove podatkov DTK 50 (Geodetska uprava RS, 2015).

Figure 22: DTK 50 maps by year of production or last update (Geodetska uprava RS, 2015).

7.3.1 Vzdrževanje

Vzdrževanje podatkov DTK 5 se še ni začelo izvajati, saj še vedno niso izdelani listi za celotno državno ozemlje. Metodologija vzdrževanja podatkov DTK 5 predvideva vzdrževanje s stereo-izvrednotenjem posnetkov CAS. Z opazovanjem in primerjavo stereomodela in nanj projiciranih obstoječih topografskih podatkov DTK 5 operater išče spremembe in po potrebi obnavlja podatke. Iskanje sprememb se izvaja po posameznih objektnih tipih. Tovrstna metoda identifikacije sprememb je zelo zamudna in subjektivna. Posledice so lahko dolgotrajni proces obnavljanja podatkov, visoki stroški obnove in izpuščanje sprememb (Bric in sod., 2010).

Poleg vzdrževanja podatkov, ki se še ne izvaja, predstavlja še resnejšo težavo dolgotrajni zajem podatkov, saj so danes, 13 let po začetku zajema, podatki na voljo le za dve tretjini državnega ozemlja. Po zadnjih podatkih (Geodetska uprava RS, 2015) ostaja neizdelanih še 35 % listov. Iz grafa dinamike zajema podatkov na sliki 23 je razvidno, da je bila večina podatkov zajetih v prvih petih letih, od leta 2002 do leta 2006 (1785 listov), v naslednjih devetih letih pa le 609 listov. Praviloma bi morala biti baza vzpostavljena v desetih letih, v prvem petletnem ciklu pa tudi obnovljena (Petrovič in sod., 2011). Prvi mejnik, vzpostavitev baze v desetih letih, je že presežen, drugi mejnik – obnova podatkov v petih letih pa tudi, saj je večina listov zajetih med leti 2002 in 2006, torej je starost podatkov od 9 do 13 let.



Slika 23: Število izdelanih listov DTK 5 po letih (Geodetska uprava RS, 2015).

Figure 23: Number of completed maps by year of production (Geodetska uprava RS, 2015).

Nesistematična izdelava listov (luknje med posameznimi listi), dolgotrajen zajem, velika časovna neuskkljenost podatkov (tudi med sosednjimi listi) in nepokritost celotnega državnega ozemlja s podatki so le nekateri izmed razlogov za manjše zanimanje za uporabo podatkov DTK 5. Geodetska uprava RS zabeleži približno dvakrat več naročil TTN 5/10 kot DTK 5, kar kaže, da se uporabniki raje odločajo za uporabo zelo zastarelih TTN 5/10 (Petrovič in sod., 2011).

V primerjavi z DTK 5 je vzdrževanje DTK 50 bistveno bolj redno. Primarni viri za vzdrževanje DTK 50 so ortofoti, podatki CAS in terenske meritve. Za posamezne objektne tipe se uporabljajo še pomožni podatki: digitalni model reliefa, kataster stavb, kataster jam, DTK 5 idr. (Bric in sod., 2010). V letih od leta 2000 do leta 2005 je bilo s kombinacijo rastrskih in vektorskih podatkov izdelanih vseh 58 listov DTK 50, ki prekrivajo celotno državno ozemlje. Od leta 2006 dalje se je začela obnova že izdelanih listov z metodo vizualne fotointerpretacije in do sedaj je bilo obnovljenih 95 % listov.

Iz podatkov o vzdrževanju DTK 50 (Preglednica 28) je razvidno, da so obdobja do prve obnove podatkov zelo raznoliki od štiri do 11 let in da samo trije listi še niso bili obnovljeni. Podatki na teh listih so stari od 10 do 11 let (Geodetska uprava RS, 2015).

Preglednica 30: Obdobje do prvega vzdrževanja DTK50 v letih (Geodetska uprava RS, 2015).

Table 30: Period to first DTK 50 update in years (Geodetska uprava RS, 2015).

Cikel vzdrževanja v letih	Število listov
4	10
5	5
6	10
7	11
8	3
9	8

Cikel vzdrževanja v letih	Število listov
10	5
11	3
/	3

7.3.2 Izkušnje z uporabo samodejnih postopkov

Raziskave na temo identifikacije in zajema topografskih podatkov s samodejno interpretacijo podatkov daljinskega zaznavanja so številne. Izkušnje z identifikacijo in zajemom podatkov o stavbah so podane v 7.1.2., za ostale skupine objektnih tipov pa jih podajam v nadaljevanju.

Raziskave na temo hidrografije iz optičnih posnetkov omogočajo identifikacijo samo večjih vodnih površin, pri čemer meja vodne površine ni natančno določena, saj so bregovi pogosto zaraščeni z vegetacijo. Ta prekriva tako rob struge kot tudi vodno površino. Za zajem manjših, ožjih vodotokov pa iz podobnega razloga optični posnetki niso primerni. Nekoliko boljši rezultati se dosežejo z uporabo lidarskih podatkov, še najbolj pa s kombinacijo optičnih posnetkov in lidarskih podatkov.

V Veliki Britaniji so uspešni z razvojem in uporabo delno samodejnih metod v operativnem postopku vzdrževanja topografskih podatkov v ruralnem okolju (Gladstone, Gardiner in Holland, 2012). Z delno samodejnimi metodami identificirajo naslednje spremembe topografije: nove in spremenjene stavbe, površine porasle z drevjem ali grmičevjem, vodne površine, površine golih tal, linearne objekte (ceste, steze, poti, ograje, zidovi). Kot osnovni vir uporabljajo letalske posnetke, iz katerih izdelajo ortofote in digitalni model površja. Skupna natančnost klasifikacije znaša 88,5 %, kar predstavlja, glede na podrobnost iskanih sprememb, zelo dober rezultat.

7.3.3 Izkušnje v Sloveniji

V letu 2011 je bila v okviru ciljno raziskovalnega projekta (Bric in sod., 2010) izvedena obsežna raziskava o uporabi samodejnih postopkov pri zajemu in vzdrževanju naslednjih izbranih topografskih objektnih tipov DTK 5:

- relief,
- vegetacija,
- ceste,
- stavbe in
- hidrografija.

Izkušnje s samodejno identifikacijo stavb so podrobno opisane v 7.1.2, zato v nadaljevanju povzemam samo rezultate testov za preostale štiri objektne tipe.

Relief

Analize samodejnih postopkov identifikacije sprememb reliefa so pokazale, da je tako iz podatkov aerosnemanja kot laserskega skeniranja mogoče zaznavati spremembe reliefa,

vendar se poleg dejanskih sprememb identificirajo tudi lažne spremembe reliefa, ki so posledica:

- različnih virov vzpostavitve modelov reliefa (DMV) in
- različnih postopkov izdelave DMV ob uporabi istega vira podatkov.

Ocenjeno je bilo, da so postopki samodejnih identifikacij sprememb reliefa uspešni in jih bo mogoče uporabiti v praksi, a šele, ko bodo postopki izdelave DMV popolnoma poenoteni.

Vegetacija

Izvedena je bila analiza samodejne razpoznavne vegetacije glede na učinkovitost določanja petih vegetacijskih razredov (gozd – večje površine, gozd – posamezna drevesa, travniki in njive – aktivne in neaktivne) na podlagi satelitskih posnetkov in ortofota. Rezultati analize so pokazali, da rezultati na podlagi obeh virov, v geometričnem in vsebinskem smislu, ustrezajo in na določenih območjih tudi presegajo kakovost trenutnega prikaza objektnega tipa vegetacija v DTK 5. Ob dodatni uporabi lidarskih podatkov bi bilo možno še izboljšati kakovost rezultatov. Za uporabo samodejnih postopkov zajema in vzdrževanja identifikacije je treba uporabiti optični posnetek z infrardečim kanalom in zagotoviti radiometrično usklajenost med posameznimi posnetki. Pri uporabi ortofotov je potrebna tudi radiometrična usklajenost med posameznimi listi ortofota in cikli snemanj.

Ceste

Analiza samodejnih postopkov za identifikacijo cest je pokazala, da je poleg optičnih posnetkov nujna uporaba tudi podatkov o modelu površja in reliefa, ki je lahko izdelan na podlagi podatkov CAS ali laserskega skeniranja. Brez uporabe višinskih podatkov pa so rezultati samodejne identifikacije nižje kakovosti, saj se v objektni tip ceste uvrsti tudi veliko število lažno identificiranih stavb. V objektni tip ceste so se lažno uvrstile tudi nekatere nizke pozidane površine, ki imajo podobne spektralne lastnosti kot ceste (npr. parkirišča in dvorišča).

Hidrografija

V okviru raziskave je bila analizirana možnost uporabe samodejnih postopkov odkrivanja sprememb vodnih površin na zelo visokoločljivostnem satelitskem posnetku. Samodejni zajem točkovnih in linijskih objektov zgolj na optičnih posnetkih ni možen in ni bil vključen v analizo. Ocenjene so bile spremembe vodnih površin na satelitskem posnetku in ortofotu. Največje težave pri iskanju sprememb predstavljajo razlike v vidnosti vodnih površin zaradi:

- različne olistanosti vegetacije na posnetkih,
- srednje in visoke vegetacije, ki prekriva vodno površino ter
- različnega vodostaja vodnih površin.

Zaradi prvih dveh se kot sprememba vodne površine identificira tudi množica površin, ki niso posledica spremembe vodnih površin, ampak posledica prekrivanja vodne površine z vegetacijo na enem posnetku in vidnosti vodne površine na drugem posnetku. Zaradi različnega vodostaja vodnih površin so bile vse vodne površine, ki niso omejene z grajenimi bregovi, identificirane kot spremenjena vodna površina. Razlog je v različnem času snemanj, različnem vodostaju in posledično različnem položaju obalne linije vodne površine. Za višjo

natančnost razpoznavanja vodnih površin bi bilo treba poleg satelitskih posnetkov uporabiti tudi podatke laserskega skeniranja, s katerimi bi izboljšali izločanje vegetacije ob robovih vodnih površin.

7.3.4 Ocena možnosti uporabe samodejne interpretacije v praksi

Izkušnje z uporabo samodejnih postopkov interpretacije kažejo (Gladstone, Gardiner in Holland, 2012), da se tudi za vzdrževanje topografskih podatkov samodejne metode uporabljajo v fazi identifikacije spremembe, medtem ko se zajem podatkov izvede s klasičnimi metodami, npr. fotogrametrični zajem.

Oceno možnosti uporabe samodejne interpretacije v praksi podajam na podlagi rezultatov ciljno raziskovalnega projekta Kombinirani visokoločljivostni postopki zajemanja, razpoznavanja in vzdrževanje prostorskih podatkov (Bric in sod., 2010). Ocena za vzdrževanje podatkov o stavbah je podana v 7.1.4, v nadaljevanju pa podajam oceno še za preostale analizirane objektne tipe, to je: vegetacijo, ceste, hidrografijo in relief. Ocenjujem, da so postopki samodejnih identifikacij sprememb reliefa uspešni in jih bo mogoče uporabiti v praksi, a šele, ko bodo postopki izdelave DMV v Sloveniji popolnoma poenoteni. Prav tako so bili testi uspešni pri identifikaciji vegetacije, medtem ko se metoda ni izkazala kot najbolj uspešna za identifikacijo cest in hidrografije. Za ta dva objektna tipa bi bilo treba razviti metode, ki bi poleg optičnih posnetkov uporabile tudi lidarske podatke.

7.4 Primer uporabe samodejne interpretacije za vzdrževanje podatkov

Možnost uporabe samodejne interpretacije v procesu vzdrževanja prostorskih podatkov sem preverila na primeru katastra stavb in dejanske rabe kmetijskih in gozdnih zemljišč. Na podlagi testnega primera je preverjena osnovna hipoteza, in sicer, ali objektno usmerjena analiza omogoča izdelavo enotnega sloja pokrovnosti tal, ki je podlaga za vzdrževanje različnih zbirk prostorskih podatkov.

Izvedena sta dva sklopa testov, na podlagi katerih sta preverjeni dve podhipotezi:

- Uporaba veččasovnih podob ima pozitiven vpliv na izboljšanje pravilnosti rezultatov objektno usmerjene analize.
- Objektno usmerjena analiza omogoča identifikacijo sprememb pozidanih površin na zelo visokoločljivem posnetku in dosega minimum uporabne vrednosti klasifikacije.

V okviru prvega sklopa testov sem ocenila, ali je pravilnost rezultatov objektno usmerjene analize veččasovnih podob visoke ločljivosti višja v primerjavi z eno podobo zelo visoke prostorske ločljivosti. Ta analiza je pomembna predvsem zaradi dejstva, da so od leta 2015 na voljo brezplačni satelitski posnetki programa Sentinel-2, ki bodo lahko predstavljali pomemben vir za vzdrževanje prostorskih podatkov. V okviru drugega sklopa testov sem analizirala kakovost identifikacije sprememb sloja pozidano, ki so lahko podlaga za vzdrževanje katastra stavb in dejanske rabe MKGP.

7.4.1 Študijsko območje in testni podatki

Študijsko območje predstavlja en list TTN 5 (2250 x 3000 m), ki obsega severovzhodni del Murske Sobote s širšim ruralnim zaledjem (slika 24). Študijsko območje je izbrano tako, da obsega:

- različne tipe sprememb pozidanih površin (nove in spremenjene ceste, stavbe, industrijske in poslovne cone, parkirišča, idr.),
- različne vrste rabe prostora (urbana, kmetijska, gozdna, vodna in druga raba),
- različne vrste urbane rabe (stanovanjska, industrijska, poslovna raba, idr.) in
- različne gostote poseljenosti (strnjeno urbano, strnjeno podeželsko naselje in posamezni objekti/površine urbane rabe).



Slika 24: Študijsko območje za identifikacijo sprememb pozidanih površin.

Figure 24: Identification of changes in built-up area study area.

V okviru izvedenih testov sem uporabila naslednje podatkovne vire:

- barvni in infrardeči ortofoto s prostorsko ločljivostjo 50 cm in štirimi spektralnimi kanali (rdeč, moder, zelen in bližnji infrardeč), ki je bil posnet v letu 2012;
- časovno serijo sedmih satelitskih posnetkov RapidEye s prostorsko ločljivostjo 5 m in petimi spektralnimi kanali (rdeč, moder, zelen, robni rdeč in bližnji IR), ki so bili posneti med 18. majem in 26. oktobrom 2013;
- geo-referenciran in klasificiran oblak točk lidarskega snemanja (2014);
- dejansko rabo kmetijskih in gozdnih zemljišč (2005);
- kataster stavb (2015);
- zbirni kataster gospodarske javne infrastrukture, ceste (2015).

7.4.2 Metodologija

Izvedena sta dva sklopa testov, in sicer:

- prvi sklop: identifikacija sprememb pozidanih površin na enem posnetku zelo visoke in seriji posnetkov visoke prostorske ločljivosti; ter
- drugi sklop: identifikacija pozidanih površin kot enotne podlage za vzdrževanje katastra stavb in dejanske rabe MKGP.

Kriterij uspešnosti izvedenih testov temelji na dejstvu, da rezultati dosegajo minimum uporabne vrednosti klasifikacije. Pri identifikaciji novih (nevidentiranih) geografskih objektov je za uspešnost postopka pomembna predvsem visoka popolnost identifikacije (Champion in sod., 2010), saj to pomeni, da operater ne pregleduje in išče sprememb na celotnem posnetku, temveč se osredotoča le na identificirane spremembe. Mayer in sod. (2006) ter Rottensteiner in sod. (2014) kot kriterij za minimalno uporabnost rezultatov klasifikacije navajajo popolnost, višjo od 70 %

V nadaljevanju je podrobneje opisana metodologija obeh sklopov testov.

7.4.2.1 Identifikacija sprememb pozidanih površin na enem posnetku zelo visoke in seriji posnetkov visoke prostorske ločljivosti

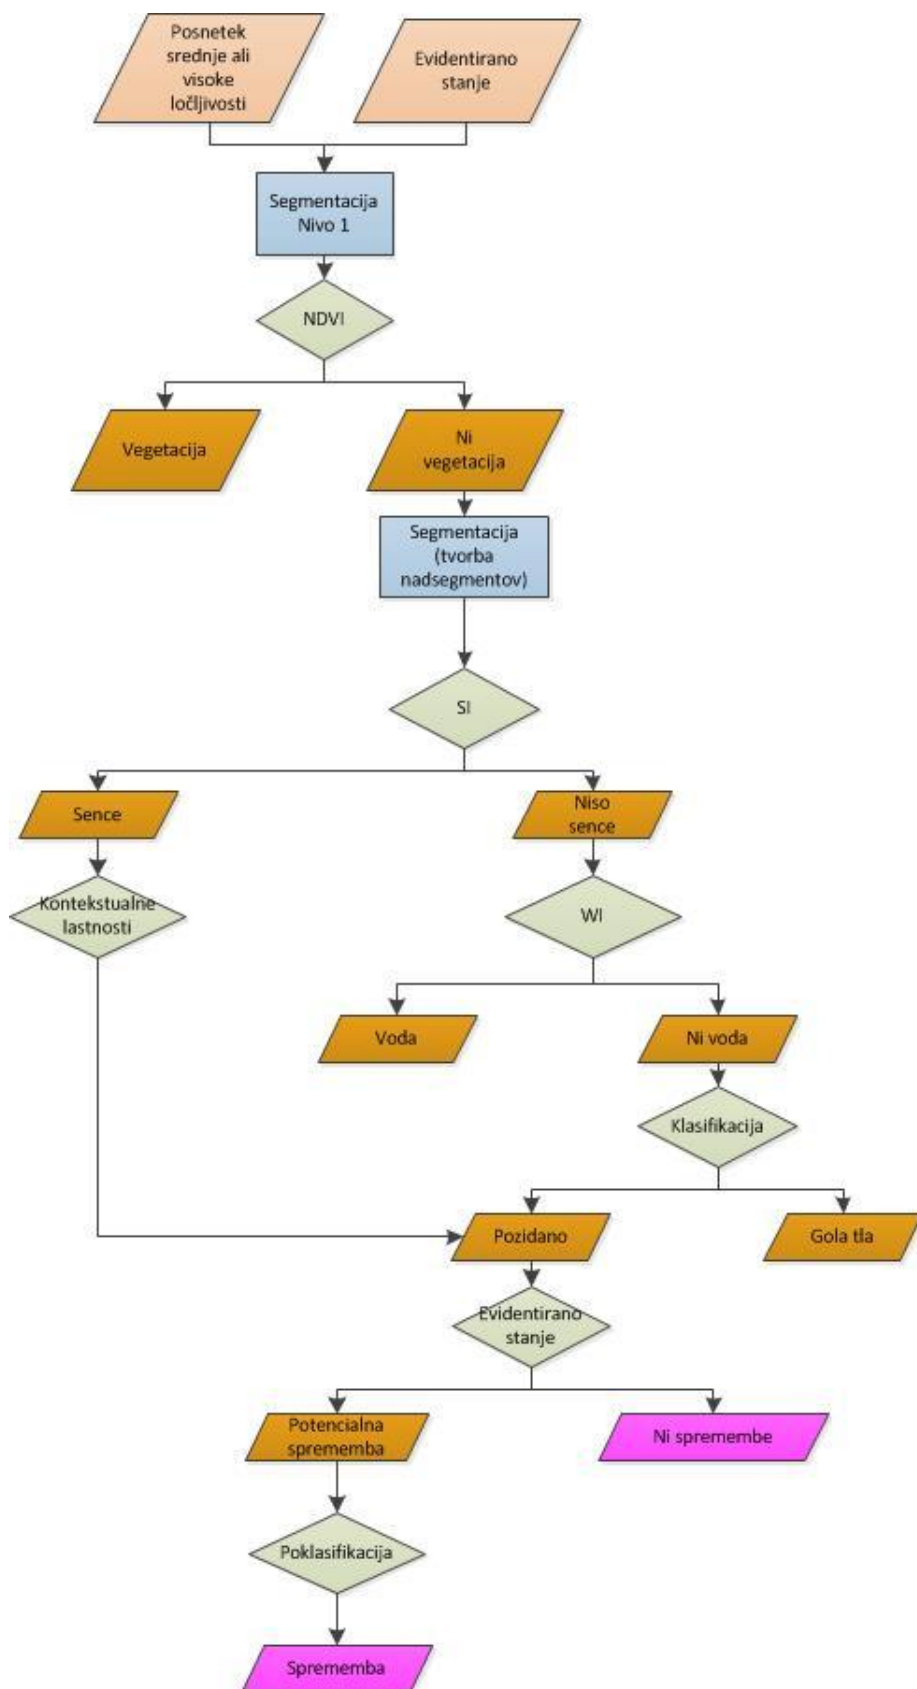
V sklopu testov identifikacije sprememb pozidanih površin na seriji posnetkov visoke ločljivosti in na enem zelo visokoločljivostnem posnetku sem z metodo objektno usmerjene analize identificirala spremembe pozidanih površin glede na evidentirano stanje. Minimalni površinski kriterij za spremembo pozidanosti je določen tako, da so rezultati identifikacije realne spremembe v prostoru, ki so posledica izgradnje novih stavb in gradbeno-inženirskih objektov (stavbe, ceste, železnice, parkirišča in druge pozidane površine v urbani rabi). Osnovna enota spremembe, ki je predmet identifikacije, je pozidana površina funkcionalnega območja nove stavbe ali gradbeno-inženirskega objekta, ki obsega stavbišče in pripadajoče zemljišče (predlog ZUREP, 2015). Minimalno površino funkcionalnega območja sem ocenila na podlagi rezultatov testnega zajema funkcionalnih območij v katastrski občini Bršljin (Geodetski inštitut Slovenije, 2015). Povprečna površina je 544 m², najmanjše pa je funkcionalno območje za bivanje v enostanovanjski hiši, in sicer 132 m². Običajno predstavljajo del funkcionalnega območja tudi nepozidane površine (zelene površine). Površinski kriterij za identifikacijo sprememb pozidanosti temelji na minimalni površini funkcionalnega območja in dejstvu, da del funkcionalnega območja običajno predstavljajo tudi nepozidane površine. Na podlagi teh dejstev sem določila površinski kriterij 100 m².

V sklopu testa sem za primer evidentiranega stanja uporabila podatke o pozidanosti iz evidence dejanske rabe MKGP. V nadaljevanju sem identificirala spremembe pozidanosti na:

- enem zelo visokoločljivostnem posnetku (ortofoto) in
- seriji sedmih posnetkov vidoke ločljivosti RapidEye (v nadaljevanju RE).

Rezultat testa je primerjava pravilnosti rezultatov identifikacije sprememb na podlagi enega posnetka z zelo visoko prostorsko ter serije posnetkov z visoko prostorsko ločljivostjo. Prostorska ločljivost podobe RE (5 m) je v primerjavi z ortofotom (0,5 m) desetkrat nižja.

Metodologija identifikacije sprememb pozidanosti na ortofotu in seriji posnetkov RE je v osnovi enaka (slika 26). Določene prilagoditve so bile izvedene le v nastavitvah parametrov algoritma segmentacije in klasifikacije.



Slika 25: Metodologija identifikacije sprememb pozidanosti.

Figure 25: Identification of changes in built-up area methodology.

Uporabila sem koncept hierarhične mreže segmentov s klasifikacijo na osnovi pravil (odločitveno drevo) in s klasifikatorjem najbližji sosed (uporaba učnih vzorcev).

Rezultati analize vplivov na segmentacijo (glej poglavje 6.2) so pokazali, da najboljše rezultate segmentacije pozidanih površin dosežemo s segmentacijo zglajene podobe. Zato sem v prvem koraku izvedla segmentacijo z večnivojskim algoritmom na mediani podobe z uporabo parametrov primernih za segmentacijo pozidanih površin (Mesner in Oštir, 2014). Nastavitev parametra merilo sem prilagodila prostorski ločljivosti podobe, in sicer 25 za ortofoto in 100 za podobo RE. Nato sem na podlagi indeksa NDVI klasificirala segmente v razreda vegetacija in nevegetacija. Na drugi ravni sem ponovno segmentirala območje podobe, ki je na prvi ravni klasificirano kot nevegetacija, in sicer tako, da sem združila podobne segmente. Za združevanje podobnih segmentov sem uporabila večnivojski algoritem. Novi segmenti so obsegali večje homogene površine, s čimer sem zmanjšala prekomernost segmentacije. Na podlagi indeksa senc sem segmente klasificirala v razred sence in nesence, nato pa objekte, ki pripadajo razredu nesence, še na podlagi indeksa vode NDWI (glej poglavje 3.2.1) v razreda voda in nevoda. Objekti, ki so razvrščeni v razred nevoda, večinoma predstavljajo pozidane površine in gola tla. Ta dva razreda sta si v spektralnem smislu zelo podobna. Za razlikovanje med tema dvema razredoma sem poskusila uporabiti indikator golih tal BGI (glej poglavje 3.2.1), ki je omogočil dobro razpoznavanje golih tal. Toda hkrati se je delež stavb z rdečkastorjavimi strehami uvrstil v razred gola tla. Zato sem ta dva razreda klasificirala s klasifikatorjem najbližji sosed na podlagi indikatorja BGI in prvih treh komponent analize osnovnih komponent. Učne vzorce sem zajela samodejno na podlagi podatkov dejanske rabe MKGP, in sicer sloja njive in pozidano. Objekte razreda pozidano sem nato na podlagi prekrivanja s slojem pozidano v dejanski rabi MKGP razvrstila v razreda sprememba in ni sprememba. Vse preostale razrede vegetacija, sence, voda in gola tla sem tudi razvrstila v razred ni spremembe. Sledila je še poklasifikacija rezultatov, v kateri sem samodejno izločila lažno klasificirane segmente z upoštevanjem geometričnih in kontekstualnih lastnosti objektov, ki pripadajo razredu sprememba. Izločeni so bili:

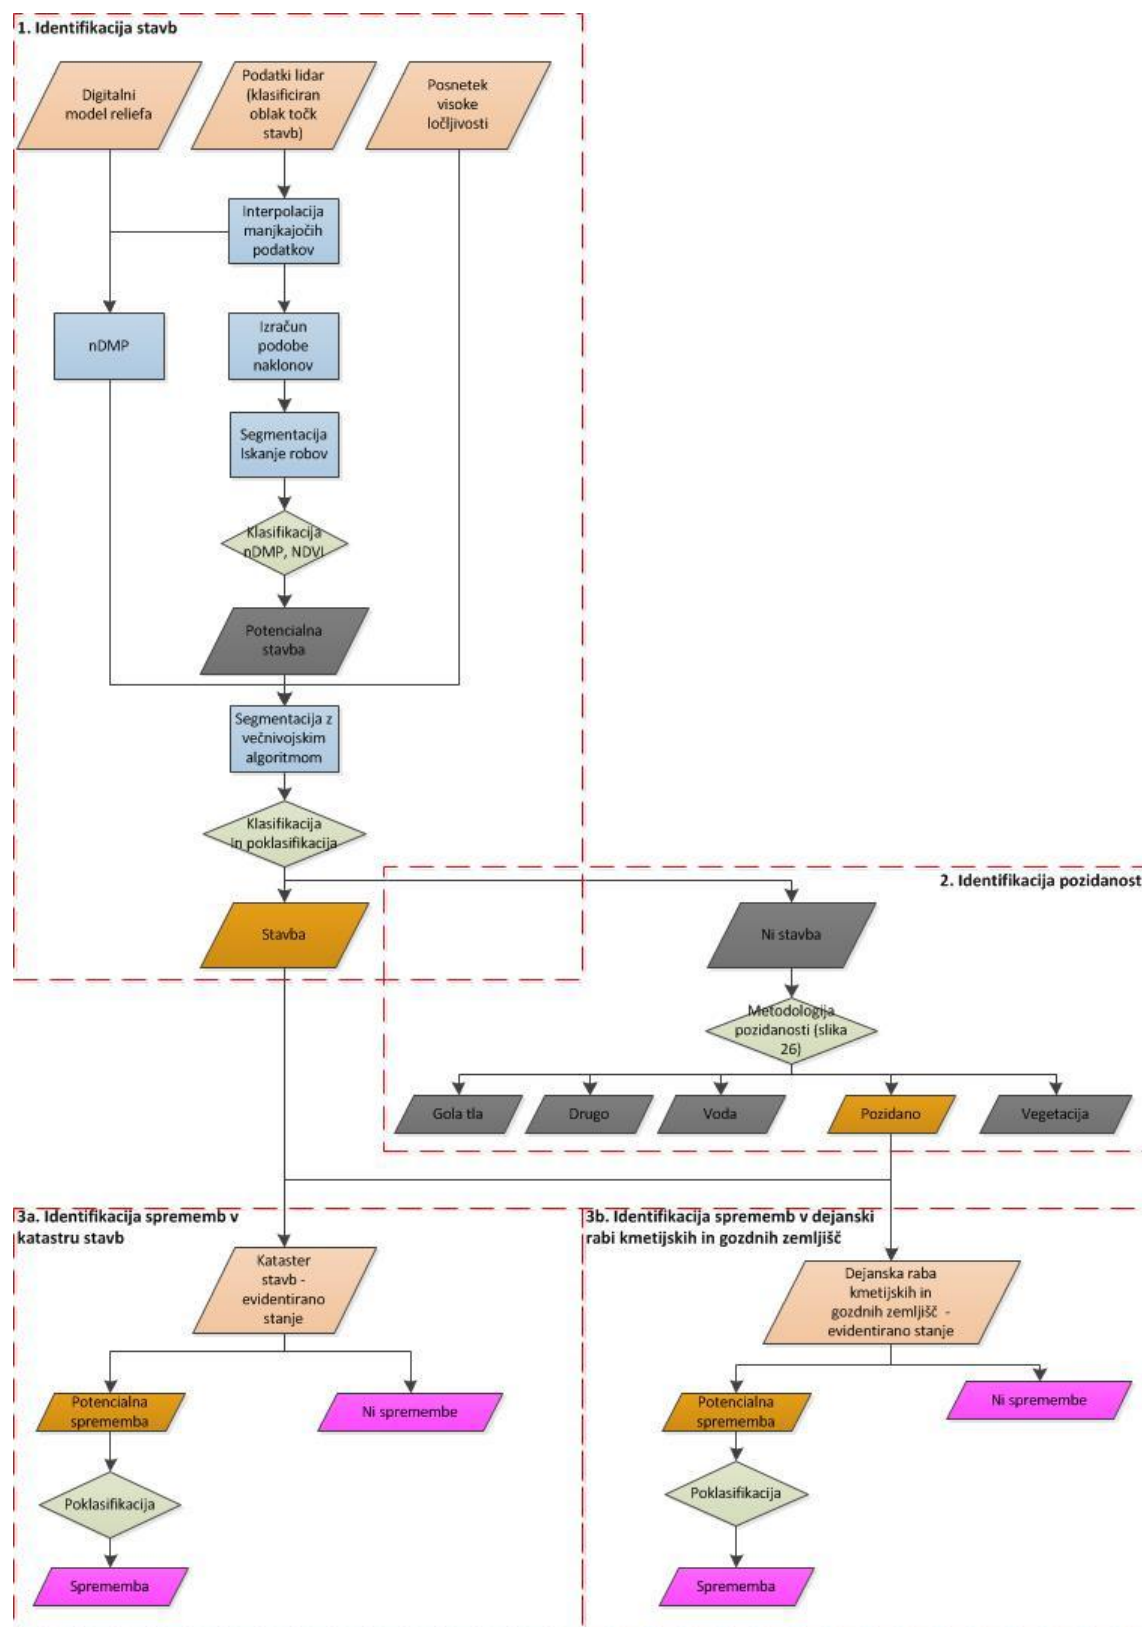
- vsi objekti, ki so manjši od 100 m², ter
- objekti, ki so zelo oddaljeni od območja obstoječe rabe pozidano in imajo posebne geometrijske lastnosti (manjša površina, nepravilne oblike ipd).

Na podlagi opisane metodologije so identificirane spremembe pozidanosti na ortofotu in seriji sedmih podob RE. Za končne rezultate identificiranih sprememb na podlagi RE sem izdelala združen rastrski sloj sprememb, ki temelji na klasifikaciji vseh sedmih posnetkov tako, da sem posameznemu pikslu izračunala prevladujoč razred (sprememba in ni spremembe). Končni rezultat (prevladujočo klasifikacijo) sem ponovno pretvorila v vektorsko obliko s segmentacijo z algoritmom iskanja robov.

7.4.2.2 Identifikacija sprememb pozidanih površin kot podlage za vzdrževanje katastra stavb in dejanske rabe kmetijskih in gozdnih zemljišč

Metodologijo za identifikacijo sprememb za potrebe vzdrževanja katastra stavb in pozidanosti v dejanski rabi MKGP sestavljajo štirje postopki (slika 26):

1. identifikacija stavb,
2. identifikacija drugih pozidanih površin,
3. identifikacija sprememb v katastru stavb in
4. identifikacija sprememb v dejanski rabi MKGP.



Slika 26: Metodologija identifikacije sprememb glede na evidentirano stanje v katastru stavb in dejanski rabi kmetijskih in gozdnih zemljišč.

Figure 26: Methodology for identification of changes in built-up area, registered in building cadastre and in actual arable and forest land use database.

Identifikacija stavb je izvedena na podlagi oblaka točk stavb, digitalnega modela reliefa in ortofota. Iz oblaka točk stavb sem izdelala digitalni model površja stavb, pri čemer sem na območju manjkajočih lidarskih podatkov izvedla interpolacijo. Nato sem iz interpoliranega modela površja stavb izračunala naklon. Obrisi strehe se na podobi naklonov izraža z izrazito spremembo naklona, zato sem za algoritem segmentacije uporabila algoritem iskanja robov (ang. contrast split algorithm). Segmentacijo sem izvedla v več iteracijah tako, da je končni sloj segmentov predstavljal čim boljši približek obrisa stavbe. Sledila je objektna klasifikacija v razreda možna stavba in nestavba, ki je temeljila na višini objekta nDMP (razlika med modelom površja in modelom reliefa) in vrednosti indeksa NDVI. Nato sem obrise potencialnih stavb izboljšala tako, da sem ponovno izvedla segmentacijo z večnivojskim algoritmom na podlagi ortofota. Na podlagi indeksa NDVI sem iz razreda možna stavba odstranila objekte, ki ne predstavljajo stavbe, temveč visoke objekte v neposredni bližini stavbe (npr. visoka vegetacija). S poklasifikacijo, ki je temeljila predvsem na geometričnih lastnostih objektov, sem odstranila lažno klasificirane stavbe. Rezultat je klasificirana podoba na razreda stavbe in nestavbe. Objekti razreda stavbe so vhodni podatek za izvedbo tretjega postopka (identifikacija sprememb v katastru stavb), objekti razreda ni stavba pa za izvedbo drugega postopka (identifikacija drugih pozidanih površin).

Na delu podobe, ki je klasificiran kot nestavba, sem z metodo identifikacije pozidanih površin po metodologiji, ki je uporabljena v 7.4.2.1, identificirala pozidane površine. Metodologija je prilagojena v tej meri, da je uporabljen nižji površinski kriterij. Površinski kriterij je enak minimalnemu površinskemu kriteriju za zajem podatkov o pozidanosti v dejanski rabi MKGP, in sicer 25 m².

Rezultat prvega in drugega sklopa, objekti razreda stavbe in druge pozidane površine, so vhodni podatek za identifikacijo sprememb glede na evidentirano stanje v katastru stavb (sklop 3a) in dejanski rabi MKGP (sklop 3b).

Identifikacija sprememb glede na evidentirano stanje se izvede v različnih podatkovnih zbirkah po enakem postopku. Na podlagi primerjave evidentiranih in identificiranih stavb se, ob upoštevanju pogojev o skladnosti obrisov, izdela sloj možnih sprememb. Nato sem s poklasifikacijo, ki je temeljila predvsem na geometričnih lastnostih objektov, odstranila lažno klasificirane spremembe. Identifikacijo sprememb pozidanosti v dejanski rabi MKGP sem izvedla na podlagi primerjave stavb in pozidanih površin z evidentiranimi pozidanimi površinami. Tudi te spremembe so bile nato poklasificirane tako, da sem na podlagi spektralnih lastnosti, velikosti, oblik in oddaljenosti od evidentirane rabe odstranila lažno klasificirane objekte.

Identificirane spremembe stavb in pozidanosti so vhodni podatek za vzdrževanje katastra stavb in dejanske rabe kmetijskih ter gozdnih zemljišč po veljavni metodologiji zajema podatkov, ki je v primeru katastra stavb upravni postopek, v primeru dejanske rabe kmetijskih in gozdnih zemljišč pa metoda fotointerpretacije.

7.4.2.3 Cenilke kakovosti

Za analizo rezultatov objektno usmerjene analize sem pripravila referenčni sloj podatkov, ki sem ga izdelala s fotointerpretacijo ortofota. Referenčni sloj podatkov vsebuje območja sprememb pozidanosti glede na evidentirano stanje v dejanski rabi MKGP (2005) in

neevidentirane stavbe v katastru stavb (2015). Na podlagi referenčnega sloja podatkov sem ocenila kakovost rezultatov objektno usmerjene analize:

- s klasifikacijsko matriko napak ter
- z oceno pravilnosti in popolnosti identificiranih sprememb.

Na podlagi referenčnega sloja podatkov in klasificirane podobe sem izračunala klasifikacijsko matriko napak. Kakovost klasifikacije sem ocenila na podlagi treh mer natančnosti. Skupno natančnost klasifikacije sem uporabila za splošno oceno klasifikacije, uporabnikovo in proizvajalčevo natančnost pa za oceno natančnosti klasifikacije posameznih razredov. Podroben opis cenilk kakovosti klasifikacije je podan v poglavju 5.3.1.

Na podlagi klasifikacijske matrike napak sem ocenila skladnost klasifikacije z referenčnim slojem po pikslih, nato sem ocenila še natančnost po posameznih objektih, in sicer s popolnostjo in pravilnostjo klasifikacije. Popolnost se nanaša na delež dejanskih sprememb, ki so bile pravilno identificirane v procesu objektno usmerjene analize, pravilnost pa na delež pravilno klasificiranih sprememb glede na vse identificirane spremembe.


7.4.3 Rezultati

V nadaljevanju so podani rezultati izvedenih testov:

- identifikacija sprememb pozidanosti na zelo visokoločljivostnem in seriji posnetkov visoke ločljivosti ter
- vzdrževanje pozidanosti in katastra stavb na podlagi enotnega sloja pokrovnosti tal.

7.4.3.1 Identifikacija sprememb pozidanosti na zelo visokoločljivostnem in seriji posnetkov visoke ločljivosti

Z metodo objektno usmerjene analize sem identificirala spremembe pozidanosti, in sicer na ortofotu (slika 26a) in na seriji sedmih podob RapidEye (slika 26b).



Slika 27: Identifikacija sprememb sloja pozidanosti (rdeče) glede na evidentirano stanje (modro). Identificirane spremembe na ortofotu (a) in na podobi RapidEye (b).

Figure 27: Built-up area change identification (red) in comparison to registered built-up area (blue). Change identification on orthophoto (a) and on RapidEye image (b).

Z metodo fotointerpretacije sem na testnem območju identificirala 60 objektov, ki so večji od 100 m² in pripadajo razredu sprememba. Tako določeni objekti predstavljajo referenčni sloj podatkov za oceno kakovosti klasifikacije s klasifikacijsko matriko napak ter za izračun popolnosti in pravilnosti klasifikacije po posameznih objektih.

Ocena kakovosti identifikacije sprememb sloja pozidano, t. j. stavb in drugih pozidanih površin, ki so večje od 100 m², je podana v preglednici 31.

Preglednica 31: Ocena natančnosti rezultatov identifikacije sprememb pozidanih površin z metodo objektno usmerjene analize (po piksljih).

Table 31: Accuracy of identified changes of built-up area using object based image analysis (pixel-based).

	Skupna natančnost	Sprememba		Ni spremembe	
		Uporabnikova natančnost	Proizvajalčeva natančnost	Uporabnikova natančnost	Proizvajalčeva natančnost
Ortofoto	99,3 %	90,3 %	94,0 %	99,7 %	99,5 %
RE	98,9 %	87,7 %	87,0 %	99,4 %	99,5 %

Skupna natančnost klasifikacije je zelo visoka in znaša 99,3 % na ortofotu in 98,9 % na seriji podob RE. Skupna natančnost se nanaša na natančnost klasifikacije objektov, ki pripadajo razredoma spremembe in ni spremembe. V nadaljevanju podajam še mere natančnosti, ki se nanašajo na posamezna razreda klasifikacije. Uporabnikova natančnost razreda sprememba, ki predstavlja delež pravilno klasificiranih pikslov, je na ortofotu 90,3 %, na seriji podob RE pa 87,7 %. Proizvajalčeva natančnost razreda spremembe, ki predstavlja delež pravilno razpoznanih (glede na vse referenčne podatke), je na ortofotu 94,0 %, na seriji RE pa 87,0 %. Proizvajalčeva in uporabnikova natančnost razreda ni spremembe je tako na ortofotu kot tudi na RE posnetkih zelo visoka in presega 99,4 %. Kakovost klasifikacije posnetkov RE je pričakovano nižja. Največje razlike se kažejo v proizvajalčevi natančnosti razreda spremembe, in sicer za 7 %. Razlika v uporabnikovi natančnosti pa je le 3,6 %, kar pomeni, da sem s posnetkom RE, ki ima kar desetkrat nižjo prostorsko ločljivost od ortofota, pridobila relativno malo lažno razpoznanih pikslov razreda sprememba.

Klasifikacijska matrika napak rezultatov objektno usmerjene analize kaže na zelo visoko stopnjo natančnosti klasifikacije, vendar nič ne pove o popolnosti in pravilnosti klasifikacije posameznih objektov razreda spremembe. Osnovna enota izračuna pri klasifikacijski matriki napak je piksel, zato na podlagi te ocene ni možno realno oceniti, ali so identificirane vse spremembe pozidanosti. Za oceno deleža razpoznanih in pravilno klasificiranih objektov razreda spremembe sem izračunala pravilnost in popolnost klasifikacije po posameznih objektih (preglednica 32).

Preglednica 32: Pravilnost in popolnost identifikacije sprememb pozidanih površin (po objektih).

Table 32: Completeness and correctness of identified changes in built-up area (object-based).

	Površina spremembe	Popolnost	Pravilnost
Ortofoto	> 100 m ²	93,3 %	78,4 %
RapidEye	> 100 m ²	81,6 %	84,5 %

Popolnost identifikacije sprememb je 93,3 % za ortofoto in 81,6 % za serijo RE, pravilnost pa 78,4 % za ortofoto in 84,5 % za serijo RE. Popolnost identificiranih sprememb je torej za 11,7 % višja na podlagi ortofota, medtem ko je pravilnost višja za 6,1 % na seriji posnetkov RE. Upoštevajoč dejstvo, da ima ortofoto višjo prostorsko ločljivost ter nižjo časovno, spektralno in radiometrično ločljivost, ocenjujem, da ima bistven vpliv na višjo popolnost rezultatov prostorska ločljivost.

Vzrokov za višjo pravilnost klasifikacije na podlagi serije RE je lahko več, saj ima podoba RE v primerjavi z ortofotom višjo spektralno, časovno in radiometrično ločljivost. Za ugotovitev, katera ločljivost ima bistveni vpliv na višjo pravilnost klasifikacije serije RE, sem določila še pravilnost klasifikacije posameznih podob RE. Pravilnost klasifikacije je na posameznih podobah zelo različna in se giblje med 51 in 77 %, šele z združitvijo rezultatov klasifikacije vseh podob pa sem pridobila višjo pravilnost rezultatov v primerjavi z ortofotom. Na podlagi teh rezultatov ocenjujem, da ima na pravilnost rezultatov bistven vpliv časovna ločljivost podatkov. Kljub temu, da sem uporabila serijo posnetkov z bistveno nižjo prostorsko ločljivostjo, sem z visoko časovno ločljivostjo dosegla visoko pravilnost rezultatov.

Na podlagi klasifikacije samo enega posnetka predstavljajo najpogosteje lažno klasificirane objekte gola tla (njive), ki so klasificirana kot pozidano in obratno rdečkastorjave strehe, ki so klasificirane kot gola tla. Podobno je zaslediti tudi lažno klasificirane sence in stavbe s temnimi strehami. Kot kažejo rezultati tega testa, je možno lažno klasificirane objekte, ki so zelo pogosti pri klasifikaciji enega posnetka, odstraniti na podlagi klasifikacije serije posnetkov.

7.4.3.2 Identifikacija sprememb pozidanosti za potrebe vzdrževanja katastra stavb in dejanske rabe kmetijskih in gozdnih zemljišč

Delni rezultat objektno usmerjene analize za potrebe identifikacije sprememb pozidanosti glede na dejansko rabo kmetijskih in gozdnih zemljišč je razpoznavna dveh objektnih razredov – pozidane površine in stavbe (slika 28).



Slika 28: Rezultat klasifikacije ortofota na objektna razreda pozidane površine (modro) in stavbe (rdeče).

Figure 28: Extraction of classes built-up area (blue) and buildings (red) based on ortophoto classification.

Objekti razredov stavbe in pozidane površine so uporabljeni tako za identifikacijo sprememb v katastru stavb kot tudi za dejansko rabo kmetijskih in gozdnih zemljišč. Končni rezultat sta dva sloja podatkov, in sicer identificirane spremembe katastra stavb (slika 29) ter dejanske rabe kmetijskih in gozdnih zemljišč. Ocena kakovosti identificiranih sprememb je podana s pravilnostjo in popolnostjo klasifikacije po posameznih objektih glede na referenčni sloj podatkov (preglednica 33).

Preglednica 33: Pravilnost in popolnost identifikacije sprememb pozidanih površin (po objektih).


Table 33: Completeness and correctness of identified changes in built-up area (object-based).

	Površina spremembe	Popolnost	Pravilnost
Kataster stavb	> 25 m ²	91,7 %	83,0 %
Dejanska raba, pozidano	> 25 m ²	82,5 %	79,7 %

Komentar rezultatov identifikacije sprememb v katastru stavb

Z metodo fotointerpretacije sem na testnem območju identificirala 218 novih oziroma spremenjenih stavb, katerih površina presega dvakratnik površine evidentirane stavbe. Z metodo objektno usmerjene analize sem pravilno identificirala 91,7 % oziroma 205 stavb (popolnost). Pravilnost identificiranih sprememb je 83-odstotna, lažno je bilo identificiranih 42 stavb. Lažno identificirane stavbe so pogostejše na območju poslovnih, trgovskih in industrijskih stavb, kjer so kot stavbe razpoznana skladišča materiala na prostem, tovorna vozila idr., medtem ko je število lažno razpoznanih stavb na območju za bivanje (hiše in večstanovanjski objekti) bistveno manjše. Kljub zahtevnosti študijskega območja je izpolnjen minimalni kriterij za uporabno vrednost rezultatov klasifikacije, saj popolnost presega 70 %.

Število neevidentiranih stavb je zelo visoko. Na testnem območju je 1043 stavb, od tega kar 21 % neevidentiranih. Na podlagi analize neevidentiranih stavb sem ugotovila, da gre večinoma za manjše in pomožne objekte (npr. vrtno ute, garaže, lope) ter nekatere večje objekte (stanovanjske hiše). Zelo pogoste so pa tudi izgradnje novih in obsežne dograditve obstoječih objektov na območjih poslovne in industrijske dejavnosti. Nekaj najbolj reprezentativnih primerov neevidentiranih stavb v katastru stavb (slika 29).



Slika 29: Evidentirane stavbe (zelene) in primeri neevidentiranih stavb (rdeče) v katastru stavb: pomožne stavbe (a), stanovanjske stavbe (b) in poslovne ali industrijske stavbe (c).

Figure 29: Registered building (green) and some examples of unregistered building (red) in building cadastre: auxiliary buildings (a), residential buildings (b) and business or industrial buildings (c).

Za boljše razumevanje strukture identificiranih sprememb v nadaljevanju podajam število identificiranih sprememb glede na površino identificiranega obrisa stavbe (preglednica 35).

Preglednica 34: Število in površina identificiranih sprememb v katastru stavb.

Table 34: Number and area of identified changed buildings in building cadastre.

Površina obrisa spremembe	Število sprememb	Delež sprememb [%]
< 50 m ²	125	51 %
51–100 m ²	55	22 %
101–200 m ²	27	11 %
201–500 m ²	20	8 %
> 501 m ²	20	8 %

Rezultati kažejo, da kar 51 % vseh identificiranih sprememb predstavljajo stavbe, katerih obris ne presega 50 m², sledijo stavbe s površino obrisa, manjšo od 100 m² (22 %). Preostanek, 27 % identificiranih sprememb, predstavljajo stavbe z obrisom, večjim od 100 m². Na podlagi deležev identificiranih neidentificiranih stavb po površini ocenjujem, da predstavljajo bistveno težavo vzdrževanja manjše stavbe, saj te predstavljajo polovico vseh identificiranih sprememb.

Komentar rezultatov identifikacije sprememb pozidanosti v dejanski rabi kmetijskih in gozdnih zemljišč

Popolnost identifikacije sprememb, večjih od 25 m², je 82,5 %, pravilnost pa 79,7 %. Površine sprememb sloja pozidano se gibljejo od 25 m² (npr. pomožne kmetijske in druge stavbe) pa do nekaj 10.000 m² (npr. nove industrijske cone, stanovanjske soseske ipd.). Največji delež objektov, ki niso razpoznani z objektno usmerjeno analizo ortofota, so spremembe, ki so po površini manjše in/ali ozke in dolge. To so (slika 30):

- pomožni kmetijski in stanovanjski objekti (npr. lopa, uta, manjši gospodarski objekti),
- spremembe obstoječih stavb (manjši prizidki, razširitev dvorišča stanovanjskih stavb ipd.) ter
- spremembe cestnega telesa (krajši odseki z razširitvijo ceste).



(a)



(b)



Slika 30: Primeri nerazpoznanih objektov: razširitev ceste (a), prizidek k stavbi (b), novi objekt pri stanovanjski stavbi (c) in novi kmetijski objekt (d).

Figure 30: Examples of unrecognized object: road (a), prizidek (b), new building next to residential building (c) and new agricultural building (d).

Na podlagi rezultatov identificiranih sprememb ocenjujem, da predstavljajo največjo težavo pri identifikaciji sprememb pozidanosti manjše in nižje stavbe ter manjše spremembe obstoječe pozidanosti, kot so razširitve cest, dvorišč ipd.

7.5 Povzetek

Podan je pregled podatkovnih zbirk, v katerih se vodijo podatki o stavbah, dejanska raba prostora, pokrovnost tal in topografski podatki. Na podlagi pregleda obstoječega načina vzdrževanja izbranih podatkovnih zbirk in izkušenj s samodejno interpretacijo doma in v tujini sem ocenila možnosti uporabe samodejne klasifikacije v procesu vzdrževanja posamezne podatkovne zbirke. Povzetek je podan v preglednici 35.

Podatki o stavbah se vodijo v državnih topografskih zbirkah in v katastru stavb. Podatki o stavbah v različnih zbirkah podatkov se vzdržujejo ločeno – državni topografski podatki s stereozajemom ali fotointerpretacijo izdelkov CAS, kataster stavb pa z upravnimi postopki, fotointerpretacijo in samodejno klasifikacijo. Kljub rednemu vzdrževanju ostaja velik delež stavb v katastru stavb neevidentiran. Na podlagi rezultatov pilotnih projektov (Geodetski inštitut Slovenije, 2013; Mesner in Babič, 2014), v katerih so bile identificirane neevidentirane stavbe na delu državnega ozemlja, ocenjujem, da se delež neevidentiranih stavb v Sloveniji giblje okrog 100.000. Izvedene so bile številne raziskave s področja samodejne klasifikacije stavb. Za enkrat kaže, da metodologija omogoča identifikacijo sprememb z visoko stopnjo popolnosti in pravilnosti, medtem ko samodejna določitev obrisa stavbe še ne daje praktično uporabnih rezultatov (Rottensteiner in sod., 2014).

Uporaba samodejne klasifikacije za vzdrževanje podatkov o pokrovnosti tal in rabi prostora je ena izmed najbolj pogostih uporab klasifikacije posnetkov. V Sloveniji se za celotno državno ozemlje vodi, oziroma se je vodilo pet podatkovnih zbirk s podatki o pokrovnosti in/ali rabi prostora, vendar se trenutno redno vzdržujeta le še dve – evidenca dejanske rabe kmetijskih in gozdnih zemljišč ter pokrovnost tal Corine Land Cover. Obe zbirki podatkov se vzdržujeta

z vizualno fotointerpretacijo optičnih posnetkov, in sicer prva ortofotov, druga pa satelitskih posnetkov. Tovrstna metoda je izredno zamudna, saj mora operater pregledati celotno državno ozemlje (več kot 20.000 km²), kljub temu, da so realne spremembe zgolj na manjšem deležu državnega ozemlja. Corine Land Cover se vzdržuje s ciklusom 5–6 let, evidenca dejanske rabe kmetijskih in gozdnih zemljišč pa s ciklusom tri leta. Glede na rezultate raziskave, ki jo je izvedla organizacija EuroSDR (Dommenech in Mallet, 2014), ocenjujem, da bi se metode samodejne klasifikacije lahko uporabile za identifikacijo sprememb v prostoru, kar bi lahko bistveno zmanjšalo obseg dela za vzdrževanje podatkov. Ocenjuje se, da se s samodejnimi metodami lahko zmanjša obseg dela vizualne fotointerpretacije za več kot 90 %. Za oceno možnosti uporabe samodejne interpretacije za potrebe vzdrževanja podatkov dejanske rabe MKGP bi bilo treba izvesti ciljno raziskavo, s katero bi ocenili kakovost identificiranih sprememb po posameznih vrstah dejanske rabe.

Stanje topografskih podatkov v Sloveniji je skrb vzbujajoče. Resnejšo težavo od vzdrževanja podatkov DTK 5 predstavlja dolgotrajni zajem, saj danes, 13 let po začetku zajema, še ni zajeto celotno državno ozemlje. Po zadnjih podatkih (Geodetska uprava RS, 2015) ostaja neizdelanih še 35 % listov. Problematična je tudi dinamika zajema, ki je v izrazitem upadu. V prvih letih se je zajemalo tudi po 500 listov na leto, zadnjih osem let pa po manj kot 100 listov na leto. Stanje na področju DTK 50 je bistveno boljše, država je popolnoma pokrita s temi podatki, vzdrževanje poteka redno, a cikli vzdrževanja so zelo dolgi, tudi do 11 let. Izkušnje z uporabo samodejnih postopkov v tujini kažejo (Gladstone, Gardiner in Holland, 2012), da se tudi za vzdrževanje topografskih podatkov samodejne metode uporabljajo v fazi identifikacije spremembe, medtem ko se zajem podatkov izvede s klasičnimi metodami, kot je fotogrametrični zajem.

Preglednica 35: Pregled podatkovnih zbirk, v katerih se vodijo podatki o stavbah, dejanska raba prostora, pokrovnost tal in topografski podatki.

Table 35: Review of databases with building data, topographic data, land cover and land use.

Objektna skupina	Podatkovna zbirka	Vsebina	Način vzdrževanja	Casovna natančnost	Popolnost	Kakovost rezultatov samodejnih metod	Možnosti optimizacije procesa vzdrževanja
podatki o stavbah	kataster stavb	podatki o legi, obliki in lastnostih delov stavb	z upravnimi postopki in fotointerpretacijo	permanentno vzdrževanje	v zbirki ni evidentiranih več kot 100.000 stavb (ocena)	identifikacija novih stavb, večjih od 20 m ² popolnost do 92 % pravilnost 83 %	samodejna identifikacija sprememb – nove, spremenjene, porušene stavbe
raba tal	dejanska raba kmetijskih in gozdnih zemljišč	podatki o rabi in pokrovnosti s podrobno razdelitvijo kmetijske rabe za potrebe dodelitve kmetijskih subvencij	dvostopenjska ročna fotointerpretacija – operater in kontrolor	3 leta	cela Slovenija	skupna natančnost klasifikacije pokrovnosti tal v primerljivi avstrijski zbirki LISA 95,5 % (Banko in sod. 2014)	samodejna identifikacija sprememb rab pozidano in sprememb pokrovnosti na območju GERK-ov
	zemljiški kataster	vrste rabe	z upravnimi postopki	zaradi neažurnosti se podatek o vrsti rabe od leta 2013 ne vodi več			
pokrovnost tal	Corine Land Cover	podatki o pokrovnosti tal	Fotointerpretacija	5–6 let	cela Slovenija		identifikacija sprememb pozidanih in gozdnih površin
	statistični GIS pokrovnosti tal	podatki o pokrovnosti tal	fotointerpretacija in nadzorovana klasifikacija	od leta 2005 dalje se podatki ne vzdržujejo; do leta 2005 na 4 leta	cela Slovenija		
topografski podatki	DTK 5	topografski podatki	stereoizvrednotenje aeroposnetko v	podatki so še v fazi zajema; starost pretežnega deleža podatkov od 9 do 13 let	65 % Slovenije		samo identifikacija sprememb za sloje: stavbe, vegetacija, relief
	DTK 50	topografski podatki	fotointerpretacija	4–11 let	cela Slovenija		identifikacija sprememb

V testnem primeru uporabe metode objektno usmerjene analize za potrebe vzdrževanja prostorskih podatkovnih zbirk sem analizirala primernost metode za vzdrževanje podatkov o pozidanih površinah in stavbah v evidenci dejanske rabe kmetijskih in gozdnih zemljišč ter katastru stavb. Na podlagi testnega primera sem ocenila:

- kakovost rezultatov klasifikacije sprememb pozidanih površin, večjih od 100 m² na enem posnetku zelo visoke in seriji posnetkov visoke prostorske ločljivosti.
- možnost identifikacije sprememb v katastru stavb in pozidanosti v dejanski rabi kmetijskih in gozdnih zemljišč na podlagi enotnega sloja pozidanosti tal in stavb.

Spremembe pozidanosti tal, ki so večje od 100 m², sem določila na eni podobi zelo visoke ločljivosti (ortofotu) in seriji posnetkov visoke ločljivosti (RE). V okviru izvedenega testa sem ocenila, ali lahko z veččasovnimi podobami visoke ločljivosti uspešno identificiramo spremembe pozidanosti. Ocena natančnosti rezultatov je podana s popolnostjo in pravilnostjo identificiranih sprememb po objektih.

Popolnost identifikacije sprememb je 93,3 % za ortofoto in 81,6 % za serijo RE, pravilnost pa 78,4 % za ortofoto in 84,5 % za serijo RE. Popolnost identificiranih sprememb je torej za 11,7 % višja na podlagi ortofota, medtem ko je pravilnost višja za 6,1 % na seriji RE. Upoštevajoč dejstvo, da je pravilnost klasifikacije na posameznih podobah RE zelo različna in se giblje med 51 in 77 %, ocenjujem, da ima na pravilnost rezultatov bistven vpliv časovna ločljivost podatkov. Veččasovne podobe tako omogočajo identifikacijo sprememb z visoko stopnjo pravilnosti, medtem ko ima nižja prostorska ločljivost negativen vpliv na popolnost identificiranih sprememb.

V okviru drugega testa je bil izdelan sloj pokrovnosti tal s klasifikacijo na tri razrede: pozidano, stavbe in nepozidano. Na podlagi enotnega sloja so bile identificirane spremembe glede na evidentirano stanje o stavbah v katastru stavb in o pozidanosti v dejanski rabi kmetijskih in gozdnih zemljišč. Popolnost identificiranih sprememb, večjih od 25 m², je 91,7 % za kataster stavb in 82,5 % za dejansko rabo kmetijskih in gozdnih zemljišč. Rezultat bistveno presega minimalni kriterij glede popolnosti za praktično uporabne rezultate klasifikacije (70 %). Glede na zahtevnost študijskega območja, ki obsega poslovno-industrijsko in stanovanjsko rabo z zelo raznoliko gostoto pozidave, je pravilnost identifikacije sprememb pričakovano nižja. Pravilnost identificiranih sprememb je 78,4 % za dejansko rabo kmetijskih in gozdnih zemljišč ter 84,5 % za kataster stavb. Vendar je za potrebe identifikacije sprememb glede na evidentirano stanje bistveno bolj pomemben kriterij popolnosti, saj kaže na delež dejanskih sprememb, ki so odkrite s samodejnimi postopki in ne zahtevajo dodatnega dela operaterja za iskanje sprememb na celem posnetku, medtem ko pravilnost kaže na število lažno identificiranih sprememb, ki jih operater mora po nepotrebnem obdelati. Rezultati kažejo, da objektno usmerjena analiza omogoča izdelavo večnamenskega sloja pokrovnosti tal, ki omogoča identifikacijo sprememb pozidanih površin in stavb z visoko stopnjo popolnosti.

8 ZAKLJUČEK

V magistrski nalogi sem raziskovala metodo objektno usmerjene analize pozidanih površin za potrebe vzdrževanja prostorskih podatkov. Posebno pozornost sem namenila fazi identifikacije sprememb v prostoru glede na evidentirano stanje. Ukvarjala sem se z ovrednotenjem vpliva transformacij in filtriranja posnetkov ter časovne, prostorske in časovne ločljivosti optičnih posnetkov na kakovost končnih rezultatov objektno usmerjene analize. Obravnava vseh sprememb v prostoru bi presegala obseg te naloge, zato sem raziskovalno delo osredotočila na spremembe pozidanih površin, saj so te zelo pogoste, trajne in med najbolj obremenilnimi spremembami za okolje.

Analizirala sem vpliv filtriranja in transformacije ter prostorske in spektralne ločljivosti na kakovost obeh korakov objektno usmerjene analize, to je segmentacije in objektno klasifikacije. Filtriranje podobe pozitivno vpliva predvsem na segmentacijo, medtem ko na objektno klasifikacijo nima vpliva. Na podlagi praktičnih testov so se izkazali kot najbolj uporabni nizkoprepustni filtri, ki ohranjajo robove (npr. filter mediana). Uporaba filtrirane podobe v fazi segmentacije se kaže v višji položajni usklajenosti meje segmentov in geografskih objektov na podobi ter v zmanjšanju razdrobljenosti posnetka na segmente.

Pozitiven učinek transformacij posnetka je zmanjšanje koreliranosti med podatki na posameznih spektralnih kanalih. V fazi segmentacije se lahko s transformacijo zmanjšajo podrobnosti (manjše število segmentov) in hkrati izboljša razpoznavanje geografskih objektov. Prav tako ima zmanjšanje koreliranosti med podatki pozitiven vpliv na natančnost objektno klasifikacije. Pozitiven učinek transformacij se kaže tudi v zmanjšanju količine podatkov za obdelavo, zaradi česar je čas obdelave tudi do dvakrat krajši. Slaba stran transformacij je zmanjšanje skladnosti meje segmentov in referenčnih objektov. Oblika objektov na analiziranih transformiranih podobah ni skladna z obliko objektov na izvornem posnetku, kar se kaže v višjem položajnem odstopanju meje ter večjem odstopanju površine in obsega.

Prostorska ločljivost ima zelo velik vpliv na segmentacijo podobe. V fazi segmentacije ima zmanjševanje prostorske ločljivosti negativen vpliv na razpoznavanje geografskih objektov. Za identifikacijo pozidanih površin, ki po podrobnosti ustrezajo merilu 1 : 5000, je primerna samo zelo visoka prostorska ločljivost (vsaj 0,5 m), medtem ko je vpliv prostorske ločljivosti na objektno klasifikacijo manjši. Zmanjševanje prostorske ločljivosti ima sicer negativen vpliv na kakovost klasifikacije pozidanih površin, vendar je ta vpliv pri zmanjšanju prostorske ločljivosti od 0,5 do 2,5 metra majhen. Razlike v skupni natančnosti izvorne, 0,5-metrške in 2,5-metrške podobe znašajo le 1,6 %. Rezultati so pokazali, da je visoka prostorska ločljivost zahtevana predvsem v procesu segmentacije, medtem ko se v fazi objektno klasifikacije lahko uporabijo tudi posnetki nižje prostorske ločljivosti.

Spektralna ločljivost ima pomemben vpliv tako na kakovost segmentacije kot tudi klasifikacije. Z izbiro spektralnih kanalov in številom kanalov, ki se uporabijo za segmentacijo podobe, ni mogoče zadostiti obema pogojema optimalne segmentacije. Lahko pa se z variiranjem spektralnih kanalov približamo želeni optimalni situaciji:

- z izbiro majhnega števila kanalov je en referenčni objekt predstavljen z najmanjšim številom segmentov, vendar sta gladkost in položajna usklajenost meje slabši;

- z izbiro vseh kanalov testne podobe (izvirna podoba) sta skladnost in gladkost meje visoki, toda v povprečju je en referenčni objekt sestavljen iz večjega števila segmentov.

Izbira spektralnih kanalov ima lahko zelo velik vpliv na skupno natančnost klasifikacije, vendar je ta vpliv odvisen od števila kanalov, na podlagi katerih izvajamo klasifikacijo. Izbira spektralnega kanala na podlagi klasifikacije enokanalne podobe povzroči razlike v skupni natančnosti do 30 %, z večanjem števila kanalov pa se občutljivost na izbiro kanalov manjša in pri tri-kanalni podobi znaša le še 1,5 %. Ocenjujem, da lahko najvišjo natančnost dosežemo z uporabo majhnega števila kanalov, vendar je v tem primeru zelo pomembna takšna izbira spektralnih kanalov, ki omogočajo najboljše razlikovanje med objektnimi razredi. Poleg višje natančnosti je prednost klasifikacije z uporabo manjšega števila kanalov tudi prihranek pri času obdelave, ki je pomemben predvsem pri obdelavi podatkov na obsežnih območjih, t. j. na ravni regije ali države.

Na podlagi izvedene analize vplivov ocenjujem, da najbolj kakovostno segmentacijo pozidanih površin dosežemo s filtrirano podobo zelo visoke prostorske ločljivosti in klasifikacijo na podlagi obalno modrega in bližnjega infrardečega kanala. Prednosti tako izbranih podatkov in postopkov obdelave sta dve: višja skupna natančnost klasifikacije (za 3 %) in za polovico krajši čas obdelave. *Na podlagi te ugotovitve potrjujem prvo podhipotezo naloge, da se lahko s filtriranjem in transformacijo posnetka ali izbiro spektralne in prostorske ločljivosti doseže višja skupna natančnost klasifikacije v primerjavi z izvornim posnetkom.*

V nadaljevanju sem analizirala pravilnost identifikacije sprememb ob uporabi ene podobe visoke ločljivosti (ortofoto) in veččasovnih podob visoke ločljivosti (RE, RapidEye). Spremembe pozidanih površin, ki so večje od 100 m², sem določila z metodo objektno usmerjene analize na ortofotu in seriji podob RE. Podoba RE ima v primerjavi z ortofotom višjo časovno, spektralno in radiometrično ločljivost ter nižjo prostorsko ločljivost. Prostorska ločljivost podobe RE (5 m) je v primerjavi z ortofotom (0,5 m) desetkrat nižja. Pravilnost rezultatov sem ocenila na podlagi deleža pravilno klasificiranih objektov glede na vse klasificirane objekte razreda pozidane površine.

Pravilnost identifikacije sprememb na podlagi ortofota je 78,4 %, na podlagi serije sedmih podob RE pa 84,5 %. Pravilnost identifikacije sprememb na posameznih podobah RE pa se giblje med 51 in 77 %. Na podlagi teh ugotovitev ocenjujem, da ima časovna ločljivost bistven prispevek k izboljšanju pravilnosti rezultatov in to kljub temu, da se uporabi podoba z bistveno nižjo prostorsko ločljivostjo.

Ocena popolnosti identificiranih sprememb, ki predstavljajo delež pravilno klasificiranih glede na vse spremembe, pa kaže popolnost identifikacije sprememb na ortofotu 93,3 %, na seriji RE pa le 84,5 %. Pri podrobni analizi nerazpoznanih objektov sem ugotovila, da so bili nerazpoznani objekti, ki so ali po površini majhni ali so dolgi in ozki (npr. razširitve cest). Za razpoznavanje teh objektov je visoka prostorska ločljivost ključnega pomena. Veččasovne podobe tako omogočajo identifikacijo sprememb z visoko stopnjo pravilnosti, popolnost identifikacije pa je odvisna predvsem od razmerja med minimalno površino objekta in prostorsko ločljivostjo podobe.

Na podlagi teh ugotovitev potrjujem drugo podhipotezo, da ima uporaba veččasovnih podob pozitiven vpliv na izboljšanje pravilnosti rezultatov objektno usmerjene analize. Pravilnost rezultatov veččasovnih podob visoke ločljivosti je višja v primerjavi z eno podobo zelo visoke

prostorske ločljivosti. Glede na izvedene analize vplivov na objektno usmerjeno analizo ocenjujem, da so podobe visoke ločljivosti uporabne tudi za razpoznavo sprememb objektov visoke ravni podrobnosti. Glede na ugotovitve v analizi vplivov prostorske ločljivosti na objektno klasifikacijo, ocenjujem, da so veččasovne podobe visoke ločljivosti uporabne tudi za identifikacijo manjših sprememb, če se za segmentacijo uporabijo podatki virov z višjo prostorsko ločljivostjo (npr. ortofoto).

Na podlagi izvedenih analiz vplivov na objektno usmerjeno analizo, teoretičnih osnov objektno usmerjene analize in pregleda metodologij klasifikacije pozidanih površin drugih avtorjev sem razvila postopek za identifikacijo novih stavb in sprememb pozidanih površin glede na evidentirano stanje. Evidentirano stanje pozidanosti je privzeto iz evidence dejanske rabe kmetijskih in gozdnih zemljišč, stavb pa iz katastra stavb.

Postopek identifikacije sprememb pozidanih površin temelji na hierarhični mreži segmentov in razredov, kjer sem segmentacijo izvajala na zglajenem ortofotu s filtrom mediana, za objektno klasifikacijo pa sem uporabila metodo odločitvenega drevesa in klasifikacije na podlagi učnih vzorcev. Segmentacija je bila izvedena z večnivojskim algoritmom, klasifikacija pa na podlagi odločitvenega drevesa in metode najbližjega soseda. Za razlikovanje med razredoma gola tla in pozidano, ki sta najbolj sorodna, so bili določeni učni vzorci, in sicer samodejno s prevzemom podatkov o pozidanih površinah in njivah iz dejanske rabe kmetijskih in gozdnih zemljišč. Rezultat je sloj pokrovnosti tal s klasifikacijo na razrede stavbe, pozidane površine in druge vrste pokrovnosti tal. Klasificirana podoba je nato uporabljena za identifikacijo sprememb v dveh različnih zbirkah podatkov: kataster stavb in dejanska raba kmetijskih in gozdnih zemljišč. Na podlagi primerjave objektov razreda pozidane površine in evidentiranega stanja sloja pozidano sem identificirala spremembe. Napake v identificiranih spremembah sem odstranila s samodejnimi postopki na podlagi geometričnih in kontekstualnih lastnosti segmentov. Podoben postopek sem nato ponovila še za identifikacijo neevidentiranih stavb v katastru stavb.

Popolnost identificiranih sprememb, večjih od 25 m², je zelo visoka, in sicer 91,7 % za kataster stavb ter 82,5 % za dejansko rabo kmetijskih in gozdnih zemljišč. Popolnost identificiranih sprememb bistveno presega minimalni kriterij za praktično uporabne rezultate, ki znaša 70 %. Glede na zahtevnost študijskega območja, ki obsega poslovno-industrijsko in stanovanjsko rabo z zelo raznoliko gostoto pozidave je pravilnost identifikacije sprememb pričakovano nižja. Pravilnost identificiranih sprememb je 78,4 % za dejansko rabo kmetijskih in gozdnih zemljišč ter 84,5 % za kataster stavb. *Na podlagi teh rezultatov potrjujem tudi tretjo podhipotezo, in sicer, da objektno usmerjena analiza omogoča identifikacijo sprememb pozidanih površin na zelo visokoločljivostnem posnetku in dosega minimum uporabne vrednosti klasifikacije.*

Praktični test izdelave večnamenskega sloja pokrovnosti s klasifikacijo na razrede stavbe, pozidano in nepozidano, je pokazal, da lahko z enim podatkovnim slojem identificiramo spremembe glede na evidentirano stanje v različnih prostorskih podatkovnih zbirkah. Dosegla sem visoko popolnost identificiranih sprememb v katastru stavb ter dejanski rabi kmetijskih in gozdnih zemljišč in presegla minimalni kriterij glede uporabne vrednosti klasifikacije. Popolnost identificiranih sprememb v katastru stavb je 91,7 %, v dejanski rabi kmetijskih in gozdnih zemljišč pa 82,5 %. *Na podlagi teh rezultatov potrjujem tudi osnovno*

hipotezo, in sicer, da objektno usmerjena analiza omogoča izdelavo večnamenskega sloja pokrovnosti tal, ki je podlaga za vzdrževanje različnih zbirk prostorskih podatkov.

S samodejno klasifikacijo lahko nadomestimo fazo identifikacije sprememb glede na evidentirano stanje v procesu vzdrževanja prostorskih podatkovnih zbirk. Pri tem lahko uporabimo večnamenski sloj pokrovnosti tal, ki služi za identifikacijo sprememb v različnih zbirkah podatkov. Rezultat samodejne identifikacije so opozorilni sloji za posamezne podatkovne zbirke, na podlagi katerih operater evidentira spremembo oziroma sproži upravni postopek za evidentiranje spremembe. Prednosti tovrstnega načina vzdrževanja sta dve: optimizacija procesa identifikacije sprememb posamezne podatkovne zbirke ter zmanjšanje kadrovskih potreb in finančnih sredstev za izvedbo, saj se opozorilni sloji izdelajo v enem postopku, hkrati za več različnih podatkovnih zbirk.

V magistrski nalogi je na podlagi analize vplivov na objektno usmerjeno analizo ocenjena optimalna izbira ločljivosti podatkov in predobdelave optičnih posnetkov za potrebe razpoznavne pozidanih površin. Na podlagi izsledkov analiz je razvita metodologija za razpoznavanje stavb in pozidanih površin ter za identifikacijo sprememb glede na evidentirano stanje v katastru stavb in dejanski rabi kmetijskih ter gozdnih zemljišč. Za vzpostavitev samodejnega sistema za izdelavo opozorilnih slojev z identificiranimi spremembami glede na evidentirano stanje bi bilo treba postopek preveriti tudi na drugih podatkovnih zbirkah, v katerih se vodijo podatki o stavbah in pozidanih površinah.

Ocenjujem, da je razvoj na področju postopkov samodejne identifikacije dosegel raven, ki omogoča uporabo teh postopkov v operativni izvedbi, in sicer v fazi identifikacije spremembe, medtem ko bodo za popolnoma samodejno vzdrževanje potrebne dodatne raziskave.

9 POVZETEK

Po vzpostavitvi zbirke prostorskih podatkov in prvega zajema predstavlja največji izziv redno vzdrževanje. Osnovni podatkovni viri za vzdrževanje prostorskih podatkov so najpogosteje različne vrste podatkov daljinskega zaznavanja. Z interpretacijo le-teh se pridobi ciljne prostorske podatke zapisane v obliki, ki omogoča integracijo v geoinformacijsko okolje. Kljub izrednemu napredku tehnologije na področju strojne in programske opreme ter samodejnih metod obdelave ostajata glavni metodi vzdrževanja prostorskih zbirk podatkov v večini evropskih držav vizualna fotointerpretacija letalskih in satelitskih posnetkov. V Sloveniji se s stereozajemom ali s fotointerpretacijo ortofotov vzdržujejo številne podatkovne zbirke, v katerih se vodijo topografski podatki, podatki o dejanski rabi in pokrovnosti tal.

Vzdrževanje prostorskih podatkov s fotointerpretacijo je časovno in kadrovsko ter zato tudi finančno zelo zahtevno. Zaradi vse večjih potreb po redno vzdrževanih prostorskih podatkih na eni strani in pomanjkljivosti obstoječih metod na drugi strani, narašča težnja po popolni ali delni avtomatizaciji postopka vzdrževanja. Razvoj samodejnih postopkov za interpretacijo podatkov daljinskega zaznavanja je aktivno področje raziskovanja v zadnjih desetletjih. Kljub številnim raziskavam na tem področju se samodejne metode vzdrževanja v praksi redko uporabljajo. V magistrski nalogi sem preučila kakovost določitve pozidanih površin z objektno usmerjeno analizo ter možnost uporabe enega sloja pokrovnosti tal za vzdrževanje različnih zbirk prostorskih podatkov.

Izvedla sem podrobno analizo vpliva prostorske, spektralne in časovne ločljivosti ter filtriranja in transformacije podobe na kakovost določitve pozidanih površin z metodo objektno usmerjene analize. Analize sem izvedla na satelitskem posnetku Worldview s prostorsko ločljivostjo 0,5 m in osmimi spektralnimi kanali (robni moder, moder, rumen, zelen, robni rdeč, bližnji IR1 in IR2). Na podlagi rezultatov analize vplivov na obe fazi objektno usmerjene analize, to je segmentacije in objektno klasifikacije, sem predlagala optimalno izbiro ločljivosti podatkov in predobdelave posnetka za razpoznavo pozidanih površin. V nadaljnji analizi sem izvedla primerjavo rezultatov identifikacije sprememb pozidanih površin na podlagi serije podob visoke ločljivosti in ene podobe zelo visoke ločljivosti.

Ključne ugotovitve izvedenih analiz sem upoštevala pri razvoju metodologije za določitev pozidanih površin in obrisov stavb na podlagi ortofota in lidarskih podatkov. Rezultat je večnamenski sloj pozidanih površin, ki se ga lahko uporabi za vzdrževanje več podatkovnih zbirk. Metodologijo sem preverila na primeru katastra stavb in dejanske rabe kmetijskih in gozdnih zemljišč. Podan je pregled podatkovnih zbirk v Sloveniji, v katerih se vodijo podatki o stavbah, topografiji, pokrovnosti tal in rabi prostora, ter bi jih bilo mogoče vzdrževati na podlagi večnamenskega sloja pokrovnosti tal. Ocenila sem možnost uvedbe samodejnih postopkov v proces vzdrževanja podatkov.

Na podlagi izvedene analize vplivov na objektno usmerjeno analizo sem dokazala, da se najbolj kakovostno segmentacijo pozidanih površin doseže s filtrirano podobo zelo visoke prostorske ločljivosti in klasifikacijo na podlagi robnega modrega in bližnjega IR1 kanala. Prednosti tako izbranih podatkov in postopkov obdelave sta dve: višja skupna natančnost klasifikacije (za 3 %) in krajši čas obdelave (45 %). Pomembna ugotovitev opravljene študije je tudi, da ima zmanjševanje prostorske ločljivosti zelo negativen vpliv na kakovost

segmentacije, medtem ko se v fazi objektne klasifikacije lahko uporabijo tudi posnetki nižje prostorske ločljivosti ter se ob tem bistveno ne poslabša skupna natančnost klasifikacije.

Rezultati analize uporabe veččasovnih podob visoke ločljivosti in ene podobe nizke ločljivosti kažejo, da ima časovna ločljivost bistven prispevek k izboljšanju pravilnosti rezultatov in to kljub temu, da se uporabi podoba z bistveno nižjo prostorsko ločljivostjo. Pravilnost identifikacije sprememb na podlagi ortofota (prostorska ločljivost 0,5 m) je 78,4 %, na podlagi serije sedmih podob RapidEye (prostorska ločljivost 5 m) pa 84,5 %. Pravilnost identifikacije sprememb na posameznih podobah RapidEye se giblje med 51 in 77 %.

Praktični test izdelave večnamenskega sloja pokrovnosti s klasifikacijo na razrede stavbe, pozidano in nepozidano, je pokazal, da lahko z enim podatkovnim slojem identificiramo spremembe glede na evidentirano stanje v različnih prostorskih podatkovnih zbirkah. Dosegla sem visoko popolnost identificiranih sprememb v katastru stavb (91,7 %) ter dejanski rabi kmetijskih in gozdnih zemljišč (82,5 %) in presegla minimalni kriterij glede uporabne vrednosti klasifikacije (80 %).

Bistvena prednost uvedbe samodejnih postopkov v proces vzdrževanja prostorskih podatkov je, da s samodejno identificiranimi spremembami usmerimo operaterja na zajem podatkov le na območja, kjer so spremembe. Pri tem se lahko uporabi večnamenski sloj pokrovnosti tal, ki služi za identifikacijo sprememb v različnih zbirkah podatkov. Rezultat samodejne identifikacije so opozorilni sloji za posamezne podatkovne zbirke, na podlagi katerih operater evidentira spremembo oziroma sproži upravni postopek za evidentiranje spremembe. Prednosti tovrstnega načina vzdrževanja sta dve: optimizacija procesa identifikacije sprememb posamezne podatkovne zbirke ter zmanjšanje kadrovskih potreb in finančnih sredstev za izvedbo, saj se opozorilni sloji izdelajo v enem postopku, hkrati za več različnih podatkovnih zbirk.

Razvoj na področju postopkov samodejne identifikacije je dosegel raven, ki omogoča uporabo teh postopkov v operativni izvedbi, in sicer v fazi identifikacije spremembe, medtem ko bodo za popolnoma samodejno vzdrževanje potrebne dodatne raziskave.

10 SUMMARY

After the establishment of spatial database and the first data acquisition the biggest challenge are regular data updates. The basic data source for spatial data updates are usually different types of remote sensing data. Target spatial data are produced with interpretation of remote sensing data and stored as data format that enables the integration in geo-information environment. Despite remarkable progress of technology in the field of hardware, software and automated classification methods, visual photo-interpretation of aerial and satellite imagery remains the main method for updating spatial databases in most European countries. In Slovenia, topography, land use and land cover databases are mostly updated by photo-interpretation, for example.

Updating process of spatial data with photo-interpretation is very demanding in terms of time and personnel. Growing demand for regular updating of spatial data on the one hand and the shortcomings of existing methods on the other hand, lead to high tendencies of data owners for fully or at least semi-automated update process. The automated extraction of objects from remote sensing data has been an active area of research for decades. Despite extensive research on automatic extraction of spatial data, these methods are still not in practical use. In the thesis, I examined the quality of object-based image analysis of built-up area and the possibility of using a single land cover data layer for updating of multiple spatial databases.

A detailed analysis of the impact of spatial, spectral and temporal resolution and impact of image filtering and transformation on object-based image analysis of built-up area is carried out. The Worldview-1 satellite image with spatial resolution 0.5 m and eight spectral channels (coastal blue, blue, yellow, green, red edge, red, near IR1 and IR2) was used in the analysis. Based on the results of the analysis of the impacts on both phases of object-based image analysis, segmentation and object classification, the optimal resolution and image pre-processing procedures for extraction of the built-up areas, are proposed. Comparison of identification of built-up area changes in the series of high resolution images and one very high resolution image is carried out in a further analysis.

Development of the methodology for extraction of built-up areas and buildings from orthophotos and lidar data is based on key findings of analyzes carried out. The result of extraction is a multi-purpose layer, which is used for updating multiple databases. The methodology has been tested on building cadastre and on database of agricultural and forest land use. An overview of databases in Slovenia, containing buildings, topography, land cover and land use data, which could be updated on the basis of the multi-purpose land cover data layer, and the possibility of automated data update process are assessed.

Based on the analysis of impacts on object-based image analysis, I demonstrated that the best built-up area extraction is achieved with segmentation of the smoothed very high spatial resolution image and classification based on coastal blue and near infrared channel. Advantages of such data selection and pre-processing are two: the overall classification accuracy increment (by 3 %) and shorter processing time (45 %). The important finding of the analysis is also that reducing the spatial resolution has a very negative impact on the quality of segmentation results, while the impact on object classification results is low. Lower spatial resolution images can thus be used for object classification without significantly lowering the overall classification.

The results of the comparative analysis of the identification of changes in built-up areas in the series of high resolution images and one very high resolution image, show that time resolution has significant impact on improving correctness of the results. The correctness of detection of changes in built-up areas in orthophoto (spatial resolution 0.5 m) is 78.4 %, while in the series of seven RapidEye images (spatial resolution 5 m) is 84.5 %. The correctness in single RapidEye images is between 51 and 77 %.

Practical test of producing the multipurpose land cover data layer, containing the classes buildings, built-up and non-built-up areas, has shown that a single data layer can be used to identify changes in comparison to registered data in different spatial databases. High completeness of identified changes has been achieved: 91.7 % for building cadastre and 82.5 % for database of agricultural and forest land use. The minimum criteria for classification results of practical importance (80 %) has been exceeded in both cases.

Major advantage of the proposed automated change detection in spatial data maintenance process is that automatically identified changes highlight the areas where changes exist and doing so significantly reduces the amount of work for data extractors. A single multipurpose layer can be used for identification of changes in different spatial databases. The final results are one change alert layer for each database, based on which operator registers the changed objects or starts an administrative procedure for the update process. Advantages of such data update process are two: optimization of the identifying changes process in individual database and reduction of costs, as change alert layers are produced in one process for different databases.

Development in the field of automatic extraction processes has reached the level, that allows the use in practical update processes. Automatization is feasible in the step of change identification, while additional research is required for fully automated data update.

11 VIRI

1. Albrecht, F., Lang, S., Holbling, D. 2010. Spatial Accuracy assessment of object boundaries for object-based image analysis. V: Addink, E. A. (ur.), Van Coillie, F. M. B. (ur.). GEOBIA 2010 - Geographic Object-Based Image Analysis. Ghent, Belgija, 29. junij – 2. julij, 2010. IAPRS XXXVIII, 4/C7: str. 1682–1777.
2. An, K., Zhang, J., Xiao, Y. 2007. Object-oriented urban dynamic monitoring — A case study of Haidian District of Beijing. *Chinese Geographical Science* 17, 3: 236–242. doi.org/10.1007/s11769-007-0236-1
3. Arh, I. 2012. Spremembe rabe zemljišč v južni in severovzhodni Sloveniji. Diplomsko naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo (samozaložba I. Arh): 86 str.
4. Baatz, M., Hoffmann, C., Willhauck, G. 2008. Progressing from object-based to object-oriented image analysis. V: Blaschke T. (ur.), Lang, S. (ur.), Hay, G. J. (ur.). *Object-based image analysis*. Berlin, Springer: str. 29–42.
5. Banko, G., Mansberger, R., Gallaun, H., Grillmayer, R., Prüller, R., Riedl, M., Stemberger, W., Steinnocher, K., Walli, A. 2014. Land Information System Austria (LISA). V: Manakos, I. (ur.), Braun, M. (ur.). *Land Use and Land Cover Mapping in Europe*. Dordrecht, Springer: str. 237–254.
6. Barborič, B., Triglav Čekada, M., Berk, S., Kosmatin Fras, M. 2008. Metodologija za izboljšavo in harmonizacijo geodetskih podlag za potrebe čezmejnega prostorskega načrtovanja. V: Perko, D. (ur.), Zorn, M. (ur.), Razpotnik, N. (ur.), Čeh, M. (ur.), Hladnik, D. (ur.), Krevs, M. (ur.), Podobnikar, T. (ur.), Repe, B. (ur.), Šumrada, R. (ur.), Gabrovec, M. (ur.), Ravbar, M. (ur.). *Geografski informacijski sistemi v Sloveniji 2007–2008*. Ljubljana, Založba ZRC: str. 273–286.
7. Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. in Heynen, M. 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing* 58, 3–4: 239–258.
8. Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 1: 2–16. [doi:10.1016/j.isprsjprs.2009.06.004](https://doi.org/10.1016/j.isprsjprs.2009.06.004)
9. Blaschke, T., Strobl, J. 2001. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Geo-Information-Systeme* 14, 6: 12–17.
10. Bric, V., Berk, S., Oven, K., Triglav Čekada, M. 2015. Aerofotografiranje in aerolasersko skeniranje Slovenije. V: Kuhar, M. (ur.), Čop, R. (ur.), Ličer, M. (ur.), Vreča, P. (ur.), Rakovec, J. (ur.), Gosar, A. (ur.), Žabkar, R. (ur.), Brilly, M. (ur.), Grigillo, D. (ur.), Bajec, K. (ur.), Rusjan, S. (ur.), Radovan, D. (ur.), Triglav, M. (ur.), Šraj, M. (ur.), Kobold, M. (ur.), Čarman, M. (ur.), Kralj, P. (ur.), Skok, G. (ur.), Stopar, B. (ur.). *Zbornik raziskave s področja geodezije in geofizike 2014*. Ljubljana, Fakulteta za gradbeništvo in geodezijo: str. 57–71.

11. Bric, V., Oven, K., Dežman Kete, V., Mesner, N., Žagar, T., Radovan, D., Petrovič, D., Kosmatin Fras, M., Grigillo, D., Veljanovski, T., Kanjir, U., Oštir, K., Gvozdanovič, T., Smole, D., Bitenc, M. 2010. Kombinirani visokoločljivostni postopki zajemanja, razpoznavanja in vzdrževanje prostorskih podatkov : raziskovalni projekt št. V2-1095 v okviru Ciljnega raziskovalnega programa "Konkurenčnost Slovenije 2006-2013". Ljubljana, Geodetski inštitut Slovenije.
12. Burnett, C., Blaschke, T. 2003. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168, 3: 233–249.
[doi:10.1016/S0304-3800\(03\)00139-X](https://doi.org/10.1016/S0304-3800(03)00139-X)
13. Buttner, G. 2014. CORINE Land Cover and Land Cover Change Products. V: Manakos, I. (ur.), Braun, M. (ur.). *Land Use and Land Cover Mapping in Europe*. Dordrecht, Springer: str. 55–73.
14. Castilla, G., Hay, G. J. 2008. Image objects and geographic objects. V: Blaschke T. (ur.), Lang, S. (ur.), Hay, G. J. (ur.). *Object-based image analysis*. Berlin, Springer: str. 91–110.
15. Champion, N., Everaerts, J. 2009. Detection of Unregistered Building for Updating 2D Databases V: Cramer, M. (ur.), Hyyppä, J. (ur.), Streilein-Hurni, A. (ur.), Sandgren, U. (ur.), Jackson, M. (ur.) *European Spatial Data Research, Official publication Nr. 56*. Amsterdam, EuroSDR: str. 7–54.
16. Champion, N., Boldo, D., Pierrot-Deseilligny, M., Stamon, G. 2010. 2D building change detection from high resolution satellite imagery: A two-step hierarchical method based on 3D invariant primitives. *Pattern Recognition Letters*, 31, 10: 1138–1147.
doi.org/10.1016/j.patrec.2009.10.012
17. Coillie, F. M. B. Van, Camp, N. A. F. Van, Wulf, R. R. De, Bral, L., Gautama, S. 2010. Segmentation quality evaluation for large scale mapping purposes in Flanders, Belgium. V: Addink, E. A. (ur.), Van Coillie, F. M. B. (ur.). *GEOBIA 2010 - Geographic Object-Based Image Analysis*. Ghent, Belgija, 29. junij – 2. julij, 2010. IAPRS XXXVIII, 4/C7: str. 1682–1777.
18. Dey, V., Zhang, Y., Zhong, M. 2010. A Review on Image Segmentation Techniques with remote sensing perspective. V: Wagner W. (ur.), Székely, B. (ur.). *ISPRS TC VII Symposium – 100 Years ISPRS*, Vienna, Austria, 5.–7. julij, 2010. IAPRS XXXVII, 7A: str. 31–42.
19. DigitalGlobe 2009. The Benefits of the 8 Spectral Bands of WorldView-2.
http://global.digitalglobe.com/sites/default/files/DG-8SPECTRAL-WP_0.pdf (Pridobljeno 23.10.2015).
20. Dommenech, E., Mallet, C. 2014. Change detection in high-resolution land use/land cover geodatabases (at object level). V: Remondino, F. (ur.), Pfeifer, N. (ur.), Trollvik, J. A. (ur.), Stoter, J. (ur.), Morley, J. (ur.) *European Spatial Data Research, Official publication Nr. 64*. Dunaj, EuroSDR: str. 9–57.

21. Duncan, P., Smit, J. 2012. An Investigation of Automatic Change Detection for Topographic Map Updating. V: Shortis, M. (ur.), Wagner, W. (ur.), Hyyppä, J. (ur.) XXII ISPRS Congress, Melbourne, Avstralija, 25. avgust – 1. september 2012. IAPRS XXXIX, B7: str. 311–316.
doi.org/10.5194/isprsarchives-XXXIX-B7-311-2012
22. EUROSTAT, 2015. Land cover / use statistics (LUCAS).
<http://ec.europa.eu/eurostat/web/lucas> (Pridobljeno: 18.3.2016).
23. Foški, M. 2015. Pomanjkljivosti podatkov dejanske rabe kmetijskih in gozdnih zemljišč za potrebe spremljanja stanja prostora. Acta Geographica Slovenica. (V tisku).
24. Gao, Y., Mas, J. 2008. A comparison of the performance of pixel based and object based classifications over images with various spatial resolutions. Online Journal of Earth Sciences: 2, 1: 27–35.
25. Garnica, C., Boochs, F., Twardochlib, M. 2000. A New Approach to Edge-Preserving Smoothing For Edge Extraction and Image Segmentation. V. Schenk, T. (ur.), Vosselman, G. (ur.). IAPRS 33, B3: str. 320–325.
26. Geodetska uprava RS. 2015. Portal Prostor.
<http://www.e-prostor.gov.si/> (Pridobljeno 15.11.2015)
27. Geodetski inštitut Slovenije. 2013. Avtomatska klasifikacija stavb. Končno poročilo. Ljubljana, Geodetski inštitut Slovenije.
28. Gillespie, A. R., Kahle, A. B., Walker, R. E. 1986. Color Enhancement of Highly Correlated Images I. Decorrelation and HSI Contrast Stretches. Remote Sensing of Environment 20, 3: 209–235.
[doi:10.1016/0034-4257\(86\)90044-1](http://doi:10.1016/0034-4257(86)90044-1)
29. Gladstone, C. S., Gardiner, A., Holland, D. 2012. A Semi-automatic Method for Detecting Changes to Ordnance Survey Topographic Data in Rural Environments. V: Feitosa, R.Q. (ur.) ; Costa, G.A.O.P. (ur.) ; Almeida, C. M. (ur.) ; Fonseca, L. M. G. (ur.) ; Kux, H.J.H (ur.). Proceedings of the 4th GEOBIA, 7-9 maj, 2012. São José dos Campos, National Institute for Space Research: str. 396–401.
30. Gosar, L., Rak, G., Steinman, F., Banovec, T. 2007. Z LIDAR tehnologijo zajeta topografija v hidravličnih analizah. Gradbeni vestnik 56,1:115–123.
31. Grigillo, D., Kosmatin Fras, M. Petrovič, D. 2011. Samodejen zajem in iskanje sprememb v topografskem sloju stavb iz digitalnega modela površja in multispektralnega ortofota. Geodetski vestnik 55,1:11–45.
[doi: 10.15292/geodetski-vestnik.2011.01.011-027](http://doi:10.15292/geodetski-vestnik.2011.01.011-027)
32. Grigillo, D., Kanjir, U. 2012. Urban object extraction from digital surface model and digital aerial images. V: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 1-3: str. 215-220.
doi:10.5194/isprsannals-I-3-215-2012,2012

33. Grilc, M., Pogorelčnik, E., Triglav, M., Pegan - Žvokelj, B. 2003. Vzpostavitev katastra stavb - registrski podatki. *Geodetski vestnik* 47,3:193–214.
34. Guindon, B. 1997. Computer-based aerial image understanding: A review and assessment of its application to planimetric information extraction from very high resolution satellite images. *Canadian Journal of Remote Sensing* 23, 1: 38–47.
[doi:10.1080/07038992.1997.10874676](https://doi.org/10.1080/07038992.1997.10874676)
35. Hay, G. J., Castilla, G. 2008. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. V: Blaschke T. (ur.), Lang, S. (ur.), Hay, G. J. (ur.). *Object-based image analysis*. Berlin, Springer: str. 75–90.
36. Holland, D., A., Sanchez-Hernandez, C., Gladstone, C. 2008. Detecting Changes to Topographic Features Using High Resolution Imagery. V: Chen, J. (ur.), Jiang, J. (ur.), Nayak, S. (ur.). *IAPRS XXXVII, B4*: str.1153–1158.
37. INSPIRE Directive (2007/2/EC). Official Journal of European Union. L 108/
<http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2007:108:0001:0014:en:PDF>
(Pridobljeno 14.4.2015)
38. Janža, M. 2005. Določitev rabe tal s klasifikacijo satelitske podobe za namene hidrološkega modeliranja na območju zaledja izvira Rižane. *Geologija* 48, 1: 153-160.
39. Kanjir, U., Veljanovski, T., Oštir, K.. 2011. Change detection of urban areas - the Ljubljana, Slovenia case study. V: Stilla, U. (ur.), Gamba, P. (ur.), Juergens, C. (ur.), Maktav, D. (ur.). *JURSE 2011 : proceedings of IEEE-GRSS/ISPRS Joint urban remote sensing event, Munich, Germany, 11. –13. april, 2011*. Munich, IEEE-GRSS, ISPRS.
40. Kawamura, M., Jayamanna, S., Tsujiko, Y. 1996. Relation between social and environmental conditions in Colombo Sri Lanka and the urban index estimated by satellite remote sensing data. *International Archives of Photogrammetry and Remote Sensing*, 31, B7: str. 321–326.
41. Kellenberger, T., Streilein, A. 2010. Current State of Production and Change Detection at swisstopo.
http://www.eurocdr.net/workshops/cd_2010/p-5.pdf (Pridobljeno 7.4.2015)
42. Kete, P., Mivšek, E., Janežič, M., Mesner, N., Zavodnik Lamovšek, A., Foški, M., Drobne, S., Kobetič, L., Košir, U., Puhar, M., Černe, T., Grilc, M. 2013. Izdelava metodologije za zajem podatkov o dejanski rabi pozidanih zemljišč. Raziskovalno poročilo. Ljubljana, Geodetski inštitut Slovenije: 102 str.
43. Kobler, A., Zafran, J. 2006. Podatki letalskega lidarskega snemanja in njihova uporaba pri gospodarjenju z gozdom. V: Hladnik, D. (ur.) *Monitoring gospodarjenja z gozdom in gozdnato krajino*. Ljubljana, Biotehniška fakulteta, Oddelek za gozdarstvo in obnovljive gozdne vire: 360 str.
44. Kosmatin Fras, M., Fabiani, N., Triglav Čekada, M. 2014. Kakovost državnega ortofota v različnih letnikih njegove izdelave. *Geodetski vestnik* 58, 4: 695–709.
[doi:10.15292/geodetski-vestnik.2014.04.695-709](https://doi.org/10.15292/geodetski-vestnik.2014.04.695-709)

45. Kuntz, S., Schmeer, E., Jochum, M., Smith, G. 2014. Towards an European Land Cover Monitoring Service and High Resolution layer. V: Manakos, I. (ur.), Braun, M. (ur.). Land Use and Land Cover Mapping in Europe. Dordrecht, Springer: str. 43-52.
46. Kuzma, I. 2013. Statistični GIS pokrovnosti tal: metodološko pojasnilo. <http://www.stat.si/statweb/Common/PrikaziDokument.aspx?IdDatoteke=8158> (Pridobljeno 15.11.2015).
47. Lang, S. 2008. Object-based image analysis for remote sensing applications: modelling reality – dealing with complexity. V: Blaschke T. (ur.), Lang, S. (ur.), Hay, G. J. (ur.). Object-based image analysis. Berlin, Springer: str. 4–27.
48. Lang, S., Langanke, T. 2006. Object-based mapping and object-relationship modeling for land use classes and habitats. Photogrammetrie Fernerkundung Geoinformation, 1, 5.
49. Liang, S. 2004. Quantitative Remote Sensing of Land Surfaces. New Jersey, Wiley: 560 str.
50. Lisec A., Pišek J., Drobne S. 2013: Analiza primernosti evidence rabe kmetijskih in gozdnih zemljišč za določanje sprememb rabe zemljišč na primeru Pomurske statistične regije. Acta Geographica Slovenica 53, 1: 71-90. Ljubljana. doi.org/10.3986/AGS53104
51. Liu, D., Xia, F. 2010. Assessing Object-based Classification: Advantages and Limitations. Remote Sensing Letters 1, 4: 187–194. doi.org/10.1080/01431161003743173
52. Matikainen, L., Hyypä, J., Ahokas, E., Markelin, L., Kaartinen, H. 2010. Automatic Detection of Buildings and Changes in Buildings for Updating of Maps. Remote Sensing 2, 5: 1217–1248. doi.org/10.3390/rs2051217
53. Mayer, H. 2008. Object extraction in photogrammetric computer vision. ISPRS Journal of Photogrammetry and Remote Sensing 63, 2: 213-222. [doi:10.1016/j.isprsjprs.2007.08.008](https://doi.org/10.1016/j.isprsjprs.2007.08.008)
54. McFeeters. K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, 17, 7: 1425–1432. [doi:10.1080/01431169608948714](https://doi.org/10.1080/01431169608948714)
55. Meinel, G., Neubert, M. 2000. A Comparison of Segmentation Programs for High Resolution Remote Sensing Data. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXV-B4: str. 1097–1102.
56. 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. [doi:10.1117/1.JRS.8.083696](https://doi.org/10.1117/1.JRS.8.083696)

57. Mesner, N., Babič, U. 2014. Informacijska prenova nepremičninskih evidenc 1 in 2: stavbe – avtomatska klasifikacija. Raziskovalno poročilo. Ljubljana, Geodetski inštitut Slovenije: 11 f.
58. Mivšek, E., Mesner, N., Kete, Grilc, M., Puhar, M., Foški, M., Kobetič, L. 2014. Testni zajem urbane rabe : raziskovalno poročilo. Ljubljana: Geodetski inštitut Slovenije: 48 str.
59. Mivšek, E., Pegan Žvokelj, B., Kete, P., Globokar, T. 2012. Dejanska raba vodnih zemljišč in zemljiški kataster. Geodetski vestnik, 56, 4: 663–673.
60. Mongus, D., Lukač, N., Obrul, D., Žalik, B. 2013. Detection of planar points for building extraction from LiDAR data based on differential morphological and attribute profiles. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences II-3/W1: str. 21-26.
61. Myinta, S. W., Gobera, P., Brazela, A., Grossman-Clarke, S., Weng, Q. 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.
[doi:10.1016/j.rse.2010.12.017](https://doi.org/10.1016/j.rse.2010.12.017)
62. Nastran, M., Žižek Kulovec, L. 2014. (Ne)usklajenost uradnih prostorskih evidenc pri ugotavljanju krčitve gozdov v Sloveniji. Geodetski vestnik, 58, 4: 724–745.
doi.org/10.15292/geodetski-vestnik.2014.04.724-745
63. Navulur, K. 2006. Multispectral image analysis using the object-oriented paradigm. CRC press: 184 str.
64. Neubert, M., Herold, H. 2008. Assessment of remote sensing image segmentation quality. V Hay, G. (ur.), Blaschke, T. (ur.), Marceau, D. (ur.) The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science XXXVIII, 4.
65. Nobrega, R. A. A., O'Hara, C. G., Vijayaraj, V., Olson, G., Kim, S., Quintanilha, J. A., & Barros, M. T. L. 2006. Extracting and Classifying Bare Soil Erosion Risk Areas in a Urban Basin Using Object-Oriented Technologies, High Resolution Imagery and Elevation Data. V: Quintanilha, J. A. (ur.), Barros, M. T. (ur.). Geographic Information System and Water Resources, IV AWRA Spring specialty conference, Houston, Texas, 8.–10. maj, 2006. Houston, AWRA.
66. O'Gorman, L., Sammon, M. J., Seul, M. 2008. Practical Algorithms for Image Analysis: Description, Examples, Programs, and Projects. Cambridge, Cambridge University Press: 349 str.
67. Oruc, M., Marangoz, M., Buyuksalih, G. 2004. Comparison of pixel-based and object-oriented classification approaches using Landsat-7 ETM spectral bands. V: Altan, O. (ur.): The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, XXXV, B4: 1118–1122.
68. Oštir, K. 2006. Daljinsko zaznavanje. Ljubljana, Založba ZRC: 250 str.

69. Oštir, K., Stančič, Z., Podobnikar, T. Vehovar, Z. 2000. Pridobivanje in uporaba prostorskih podatkov visoke ločljivosti pri načrtovanju omrežja mobilne telefonije. V: Hladnik, D. (ur.), Krevs, M. (ur.), Perko, D. (ur.), Podobnikar, T. (ur.), Stančič, Z. (ur.). Geografski informacijski sistemi v Sloveniji 1999-2000. Ljubljana, ZRC SAZU, Zveza geografskih društev Slovenije, Zveza geodetov Slovenije: str. 143-152.
70. Pal, N. R., Pal, S. K. 1993. A review on image segmentation techniques. *Pattern Recognition*. 26, 9:1277–1294
[doi.org/10.1016/0031-3203\(93\)90135-J](https://doi.org/10.1016/0031-3203(93)90135-J)
71. Petrovič, D., Podobnikar, T., Grigillo, D., Trajkovski Kozmus, K., Vrečko, A., Urbančič, T., Kosmatin Fras, M. 2011. Kaj pa topografija? Stanje in kakovost topografskih podatkov v Sloveniji. *Geodetski vestnik* 55, 2: 304–318.
[doi: 10.15292/geodetski-vestnik.2011.02.304-318](https://doi.org/10.15292/geodetski-vestnik.2011.02.304-318)
72. Platt, R., Rapoza, L. 2008. An Evaluation of an Object-Oriented Paradigm for Land Use/Land Cover Classification. *The Professional Geographer* 60, 1: 87–100.
[doi: 10.1080/00330120701724152](https://doi.org/10.1080/00330120701724152)
73. Popit, T., Rožič, B., Šmuc, A., Kokalj, Ž., Verbovšek, T., Košir, A. 2014. A lidar, GIS and basic spatial statistic application for the study of ravine and palaeo-ravine evolution in the upper Vipava valley, SW Slovenia. *Geomorphology*, 204: 638–645.
74. Pouncey, R., Swanson, K., Hart, K. 1999. *Erdas Field Guide*. Fifth Edition. Erdas inc. ZDA. <http://www.gis.usu.edu/manuals/labbook/erdas/manuals/FieldGuide.pdf>
(Pridobljeno 14.11.2015.)
75. Pravilnik o vpisih v kataster stavb. Uradni list RS št. 73/2012:1083.
76. Program dela državne geodetske službe za leti 2014 in 2015. 2015
www.gu.gov.si/fileadmin/gu.gov.si/pageuploads/IJZ/pomebni_dokumenti/program_dela/Program_dela_dgs_spremembe_za_let_14in15.doc (Pridobljeno 21.11.2015).
77. Radoux, J., Defourny, P. 2008. Quality assessment of segmentation results devoted to object-based classification. V: Blaschke T. (ur.), Lang, S. (ur.), Hay. G. J. (ur.). *Object-based image analysis*. Berlin, Springer: str. 257–271.
78. Research Systems. 2004. *ENVI User's Guide*, različica 4.1.
http://aviris.gl.fcen.uba.ar/Curso_SR/biblio_sr/ENVI_userguid.pdf
(Pridobljeno 14.11.2015.)
79. Richards, J. A., Jia, X. 2006. *Remote Sensing Digital Image Analysis*. Berlin, Springer: 439 str.
80. Rottensteiner, F., Sohn, G., Gerke, M., Wegner, J. D., Breitkopf, U., Jung, J. 2014. Results of the ISPRS benchmark on urban object detection and 3D building reconstruction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93: 256-271.
[doi:10.1016/j.isprsjprs.2013.10.004](https://doi.org/10.1016/j.isprsjprs.2013.10.004)

81. Salehi, B., Zhang, Y., Zhong, M., Dey, V. 2012. Object-Based Classification of Urban Areas Using VHR Imagery and Height Points Ancillary Data. *Remote Sensing*, 4, 8, 2256–2276.
doi.org/10.3390/rs4082256
82. 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.
83. Shackelford, A. K., Davis, C. H. 2003. A Hierarchical Fuzzy Classification Approach for High-Resolution Multispectral Data Over Urban Areas. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 9: 1920–1932.
doi.org/10.1109/TGRS.2003.814627
84. Smith, L. I. 2002. A tutorial on principal components analysis.
http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf
(Pridobljeno 14.5.2015)
85. Steinnocher, K., Kressler, F. 2006. Change detection. V: Cramer, M. (ur.), Hyypä, J. (ur.), Streilein-Hurni, A. (ur.), Sandgren, U. (ur.), Jackson, M. (ur.) *European Spatial Data Research, Official publication Nr. 50. Utrecht, EuroSDR: str. 111–179.*
86. Su, W., Li, J., Chen, Y., Liu, Z., Zhang, J., Low, T. M., Hashim, S. A. M. 2008. Textural and local spatial statistics for the object oriented classification of urban areas using high resolution imagery. *International Journal of Remote Sensing*, 29, 11: 3105–3117.
doi.org/10.1080/01431160701469016
87. Šabić, D., Lojović, E., Tretjak, A., Skumavec, D. 2000. GIS-inventorizacija Slovenije, z vzdrževanim tematskim slojem pokrovnosti tal, pridobljenih iz daljinsko zaznanih podatkov. V: *Statistična omrežna sodelovanja za večjo evropsko usklajenost in kakovostno sodelovanje, Statistični dnevi 2000, Radenci, 13.–15. november 2000.* Ljubljana, Statistični urad Republike Slovenije, Statistično društvo Slovenije: str. 294-302.
88. Švab Lenarčič, A. 2009. Uporaba lidarskih podatkov za klasifikacijo pokrovnosti. Magistrsko delo. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo (samozaložba A. Švab Lenarčič): 135 str.
89. Thomas, N., Hendrix, C., Congalton, R. G. 2003. A Comparison of Urban Mapping Methods Using High-Resolution Digital Imagery. *Photogrammetric Engineering Remote Sensing*, 69, 9: 963–972.
doi.org/10.14358/PERS.69.9.96
90. Topan, H, Maktav, D., Jacobsen, K., Buyuksalih, G., 2009. Information content of optical satellite images for topographic mapping. *International Journal of Remote Sensing*, 30, 7: 1819 – 1827.
[doi: 10.1080/01431160802642271](https://doi.org/10.1080/01431160802642271)
91. Triglav Čekada, M. 2011. Možnosti uporabe zračnega laserskega skeniranja (LIDAR) za geomorfološke študije. *Geografski vestnik* 83, 2: 81–93.

92. Triglav Čekada, M., Bric, V., Mongus, D. 2015. Napredne analize površja s podatki daljinskega zaznavanja. V: Lisec, A. (ur.), Stopar, B. (ur.), Berk, S. (ur.), Kosmatin Fras, M. (ur.), Geodetska (r)evolucija: zbornik posveta 43. geodetskega dne. Ljubljana: Zveza geodetov Slovenije: 126 str.
93. Trimble. 2014. eCognition Developer User Guide (različica 9.1). Munchen, Trimble..
94. Veljanovski, T., Kanjir, U., Oštir, K. 2011. Objektno usmerjena analiza podatkov daljinskega zaznavanja. Geodetski vestnik 55, 4: 641–664.
[doi: 10.15292/geodetski-vestnik.2011.04.641-664](https://doi.org/10.15292/geodetski-vestnik.2011.04.641-664)
95. Veljanovski, T., Lenarčič Švab, A., Oštir, K. 2014. Sateliti Sentinel - vesoljska komponenta Evropskega programa za opazovanje Zemlje Copernicus. Geodetski vestnik 55, 3: 583–588.
96. Weinke, E., Lang, S., Preiner, M. 2008. Strategies for habitat delineation and spatial change assessment. V: Blaschke T., Lang, S. Hay. G. J. (ur.). Object-based image analysis. Berlin, Springer: str. 713–732.
97. Yan, G., Mas, J. F., Maathuis, B. H. P., Xiangmin, Z., Van Dijk, P. M. 2006. Comparison of pixel-based and object-oriented image classification approaches - a case study in a coal fire area, Wuda, Inner Mongolia, China. International Journal of Remote Sensing, 27, 18: 4039-4055.
[doi:10.1080/01431160600702632](https://doi.org/10.1080/01431160600702632)
98. Zakon o evidentiranju nepremičnin (ZEN). Uradni list RS št. 47/2006: 2024.
99. Zakon o državnem geodetskem referenčnem sistemu (ZDGRS). Uradni list RS št. 25/2014.
100. Zha, Y., Gao, J., Ni, S. 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. International Journal of Remote Sensing, 24, 3: 583–594.
[doi:10.1080/01431160304987](https://doi.org/10.1080/01431160304987)
101. 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.
[doi:10.1016/j.cviu.2007.08.003](https://doi.org/10.1016/j.cviu.2007.08.003)
102. Zhang, J., Goodchild, M. 2002. Uncertainty in Geographical Information. London, Taylor and Francis: 288 str.