

Univerza
v Ljubljani
Fakulteta
*za gradbeništvo
in geodezijo*

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



Podiplomski program Geodezija

Kandidat:

Dejan Grigillo

**Samodejno odkrivanje stavb na visokoločljivih
slikovnih virih za potrebe vzdrževanja
topografskih podatkov**

Doktorska disertacija št. 197

Mentor:
doc. dr. Mojca Kosmatin Fras

Ljubljana, 15. 1. 2010

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*



*PODIPLOMSKI ŠTUDIJ
GEODEZIJE*

DOKTORSKI ŠTUDIJ

Kandidat:

mag. DEJAN GRIGILLO, univ. dipl. inž. geod.

**SAMODEJNO ODKRIVANJE STAVB NA
VISOKOLOČLJIVIH SLIKOVNIH VIRIH ZA POTREBE
VZDRŽEVANJA TOPOGRAFSKIH PODATKOV**

Doktorska disertacija štev.: 197

**AUTOMATIC BUILDING DETECTION FROM HIGH
RESOLUTION IMAGERY FOR MAINTENANCE OF
TOPOGRAPHIC DATA**

Doctoral thesis No.: 197

Temo doktorske disertacije je odobrila Komisija za doktorski študij po pooblastilu s
25. seje Senata Univerze v Ljubljani z dne 24. junija 2008 in imenovala mentorico
doc.dr. Mojca Kosmatin Fras.

Ljubljana, 15. januar 2010

Univerza
v Ljubljani

Fakulteta za
gradbeništvo in
geodezijo



Komisijo za oceno ustreznosti teme doktorske disertacije v sestavi
doc.dr. Mojca Kosmatin Fras, UL FGG
doc. dr. Marko Krevs, UL FF, Oddelek za geografijo
izr.prof.dr. Krištof Oštir, ZRC SAZU in UL FGG

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 18. redni seji
dne 28. maja 2008.

Komisijo za oceno doktorske disertacije v sestavi
doc.dr. Mojca Kosmatin Fras, UL FGG
izr.prof.dr. Krištof Oštir, ZRC SAZU in UL FGG
doc.dr. Dubravko Gajski, Sveučilište u Zagrebu, Geodetski fakultet, Hrvaška
doc.dr. Tomaž Podobnikar, ZRC SAZU

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 4. redni seji
dne 4. novembra 2009.

Komisijo za zagovor doktorske disertacije v sestavi
prof.dr. Matjaž Mikoš, dekan UL FGG
doc.dr. Mojca Kosmatin Fras, UL FGG, mentorica
izr.prof.dr. Krištof Oštir, ZRC SAZU in UL FGG
doc.dr. Dubravko Gajski, Sveučilište u Zagrebu, Geodetski fakultet, Hrvaška

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 6. redni seji
dne 16. 12. 2009.

Univerza
v Ljubljani

Fakulteta za
*gradbeništvo in
geodezijo*



IZJAVA O AVTORSTVU

Podpisani **mag. DEJAN GRIGILLO, univ.dipl.inž.geod.**, izjavljam, da sem avtor doktorske disertacije z naslovom: **»SAMODEJNO ODKRIVANJE STAVB NA VISOKOLOČLJIVIH SLIKOVNIH VIRIH ZA POTREBE VZDRŽEVANJA TOPOGRAFSKIH PODATKOV«.**

Ljubljana, 15. januar 2010

.....
(podpis)

STRAN ZA POPRAVKE, ERRATA

Stran z napako

Vrstica z napako

Namesto

Naj bo

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

- UDK:** 528.72+528.74:528.8:721(043.3)
- Avtor:** Dejan Grigillo
- Mentor:** doc. dr. Mojca Kosmatin Fras
- Naslov:** Samodejno odkrivanje stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov
- Obseg in oprema:** 156 str., 22 pregl., 55 sl., 32 en.
- Ključne besede:** odkrivanje stavb, iskanje sprememb, nDMP, normalizirani digitalni model površja, ortofoto, GeoEye-1, IKONOS, georeferenciranje, obdelava podob, daljinsko zaznavanje

Izvodček

Topografski podatki so podatki o fizičnem stanju površja. Vodimo jih v topografskih bazah, ki jih moramo redno dopolnjevati in vzdrževati. Eden od podatkov v topografskih bazah so podatki o stavbah. V doktorski nalogi so predstavljeni podatkovni viri in obstoječ način vodenja topografskih podatkov o stavbah. Navedeni so novi podatkovni viri, ki jih lahko uporabimo kot alternativo obstoječim. Visokoločljivi slikovni viri omogočajo uporabo samodejnih metod za obnavljanje topografskih baz. Doktorska naloga obravnava možnosti vzdrževanja topografskih podatkov o stavbah z enoslikovnimi postopki, ki temeljijo na samodejnih metodah. Možnosti za samodejni zajem in iskanje stavb so opisane na kombinaciji normaliziranega digitalnega modela površja (nDMP) in ortofota, na stereoparu posnetkov IKONOS in posnetku GeoEye-1. Izvirni prispevek naloge predstavlja nova metoda za samodejni zajem stavb, ki temelji na kombinaciji anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. Uporabljene so metode, ki slonijo na izdelavi maske stavb in njeni končni vektorizaciji. Rezultati samodejnega zajema so ovrednoteni, predlagan je način uporabe rezultatov samodejnega zajema za vzdrževanje topografskih podatkov o stavbah. Predlagane so nadaljnje raziskave, potrebne za nastavitev popolnoma samodejnega sistema za vzdrževanje topografskih podatkov o stavbah. Visokoločljivi satelitski posnetki predstavljajo pomemben nov vir za vzdrževanje topografskih podatkov. V doktorski nalogi so zbrani postopki za njihovo georeferenciranje in metode za izboljšavo posnetkov pred izvajanjem samodejnega iskanja stavb. Podana je ocena njihove primernosti za vzdrževanje topografskih podatkov o stavbah, analizirana je geometrična točnost, ki jo lahko z njimi dosežemo in navedene so prednosti in težave, ki jih prinaša njihova uporaba.

BIBLIOGRAPHIC – DOCUMENTALISTIC INFORMATION

- UDC:** 528.72+528.74:528.8:721(043.3)
- Author:** Dejan Grigillo
- Supervisor:** assist. prof. dr. Mojca Kosmatin Fras
- Title:** Automatic building detection on high resolution imagery for maintenance of topographic databases
- Notes:** 156 p., 22 tab., 55 fig., 32 eq.
- Key words:** building extraction, change detection, nDSM, normalized digital surface model, orthophoto, GeoEye-1, IKONOS, georeferencing, image processing, remote sensing

Abstract

Topographic data are data on the physical state of the surface. They are managed in topographic databases which need to be regularly updated and maintained. Building data are one of the data types in topographic databases. This doctoral thesis presents data sources and existing methods for management of building data. It notes new data sources that can be used as alternatives to the existing ones. High-resolution image sources enable the use of automatic methods for updating topographic databases. This doctoral thesis reviews the possibilities for maintaining topographic data with single-image methods based on automatic methods. The possibilities for automatic capturing and extraction of buildings are described based on a combination of normalized digital surface model (nDSM) and orthophotos, on a stereo IKONOS imagery and on GeoEye-1 image. Alongside, the thesis presents a new method of automatic building extraction based on an original combination of anisotropic diffusion, unsupervised classification, colour segmentation, and region growing. The methods used are based on building mask creation and its final vectorization. The results of automated building extraction were evaluated. A method of using the results for maintaining topographic building data is proposed. The thesis also proposes further research with the aim of designing a future fully automated system for maintaining topographic building data. High-resolution satellite images enable an important new source for maintaining topographic data. This thesis presents a selection of methods for their georeferencing and methods for enhancing images prior to automatic building extraction. We assessed their suitability for maintaining topographic building data, analysed the geometric accuracy they can provide and highlighted the advantages and challenges of their implementation.

ZAHVALA

Hvala vsem, ki ste prispevali znanje, nasvete, podatke ali vsaj kak nasmeh.

Poimenski seznam oseb, ki so prispevale h končni obliki doktorske disertacije, je dolg, vseeno pa naj omenim mentorico doc. dr. Mojco Fras, ostale člane komisije za oceno doktorske disertacije izr. prof. dr. Krištofa Oštirja, doc. dr. Dubravka Gajskega in doc. dr. Tomaža Podobnikarja, predstojnika KKFDZ doc. dr. Dušana Petroviča, predstojnika Oddelka za geodezijo izr. prof. dr. Dušana Kogoja, viš. pred. dr. Mirana Ferlana, izr. prof. dr. Bojana Stoparja in asist. mag. Oskarja Sterleta. Zahvala gre tudi ostalim sodelavcem na Oddelku za geodezijo, Marjani Duhovnik in Petru Prešernu z Geodetske uprave Republike Slovenije ter Lojzetu Miklavčiču iz podjetja Flycom. Pa še kdo bi se našel.

Mojca, hvala za vso podporo in pomoč v zaključni fazi izdelave naloge, Bob, hvala za glasbo.

KAZALO VSEBINE

1	UVOD	1
1.1	Ozadje problema	1
1.2	Pregled obstoječih metod	3
1.3	Izhodišča, cilji in hipoteza	5
1.4	Metoda dela	8
1.5	Struktura naloge	8
2	VODENJE IN NAČIN VZDRŽEVANJA PODATKOV V DRŽAVNIH TOPOGRAFSKIH BAZAH	10
2.1	Vodenje podatkov o stavbah	10
2.1.1	Kataster stavb	11
2.1.2	Državna topografska karta v merilu 1 : 5000	12
2.2	Vzdrževanje topografskih podatkov	13
2.2.1	Vzdrževanje katastra stavb	13
3	SLIKOVNI IN DRUGI PODATKOVNI VIRI ZA VZDRŽEVANJE DRŽAVNIH TOPOGRAFSKIH BAZ	15
3.1	Ciklično aerosnemanje	16
3.2	Državni ortofoto	16
3.3	Satelitski posnetki	17
3.3.1	IKONOS in GeoEye-1	18
3.3.2	QuickBird	25
3.4	Lidar	28

4	IZBRANI POSTOPKI DIGITALNE OBDELAVE PODOB IN VIŠINSKIH PODATKOV	31
4.1	Georeferenciranje podob	31
4.1.1	Planimetrično georeferenciranje satelitskih podob	32
4.1.2	Prostorsko georeferenciranje satelitskih podob	34
4.2	Ostrenje multispektralnih podob	36
4.3	Izboljšanje kontrasta	38
4.3.1	Metode za razteg histograma podob	38
4.3.2	Wallisov filter za izboljšanje kontrasta	40
4.4	Filtriranje	42
4.4.1	Gaussov filter	42
4.4.2	Filtri robov	42
4.4.3	Poudarjanje robov	44
4.4.4	Anizotropna difuzija	46
4.4.5	Ostali uporabljeni filtri	47
4.5	Vektorizacija robov	47
4.5.1	Houghova transformacija	47
4.5.2	Transformacija Radon	50
4.6	Morfološka obdelava podob	51
4.6.1	Strukturni element	52
4.6.2	Dilacija in erozija	52
4.6.3	Odpiranje in zapiranje	53
4.6.4	Morfološka rekonstrukcija	54
4.6.5	Morfologija črnobelih podob	55
4.7	Barvna segmentacija podob	56
4.8	Rast regij	58

4.9	Združevanje podob in višinskih podatkov za iskanje stavb	58
5	METODOLOGIJA IN OPIS TESTNIH PODATKOV	62
5.1	Digitalni ortofoto in digitalni model površja	63
5.2	Stereopar IKONOS	65
5.3	GeoEye-1	67
5.4	Ocena kakovosti samodejnega iskanja in zajema stavb	69
6	IZBRANE METODE ZA SAMODEJNO ODKRIVANJE IN ZAJEM STAVB	71
6.1	Digitalni ortofoto in digitalni model površja	72
6.1.1	Izračun normaliziranega digitalnega modela površja (nDMP)	73
6.1.2	Izračun vegetacijskega indeksa in indeksa senc	74
6.1.3	Nadaljnje obdelave maske stavb	78
6.1.4	Zajem stavb	80
6.1.5	Rezultati zajema stavb in analiza	83
6.2	Stereopar IKONOS	86
6.2.1	Priprava podatkov	88
6.2.2	Izdelava začetne maske stavb	89
6.2.3	Izboljšava maske stavb z barvno segmentacijo	92
6.2.4	Izpopolnitev maske stavb z rastjo regij in vektorizacija	99
6.2.5	Rezultati zajema stavb in analiza	104
6.3	Iskanje stavb na posnetku GeoEye-1	108
6.3.1	Priprava podatkov za iskanje stavb	109
6.3.2	Klasifikacija stavb	111
6.3.3	Izboljšava maske stavb z rastjo regij	114
6.3.4	Rezultati iskanja stavb in analiza	115

7	ANALIZA REZULTATOV IN OVREDNOTENJE CILJEV	119
7.1	Položajna točnost satelitskih posnetkov	119
7.1.1	Točnost georeferenciranja stereopara IKONOS	120
7.1.2	Točnost georeferenciranja posnetka GeoEye-1	121
7.1.3	Ostali dejavniki, ki vplivajo na položajno točnost satelitskih posnetkov	123
7.2	Primernost samodejnega odkrivanja stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov	124
7.2.1	Priporočila za izboljšavo podob pred izvedbo samodejnih postopkov	124
7.2.2	Rezultati samodejnega odkrivanja stavb na visokoločljivih podobah	125
7.3	Odkrivanje sprememb v topografskih bazah	129
7.3.1	Uporaba zajetih podatkov za vzdrževanje topografskih baz	131
8	ZAKLJUČKI	134
9	POVZETEK	138
10	SUMMARY	142
VIRI		146

KAZALO PREGLEDNIC

Preglednica 1: Lastnosti satelitov, primernih za vzdrževanje državnih topografskih baz.....	18
Preglednica 2: Deklarirana položajna točnost in primeri uporabe posnetkov IKONOS.....	19
Preglednica 3: Deklarirana položajna točnost in primeri uporabe posnetkov GeoEye-1.....	19
Preglednica 4: Deklarirana položajna točnost in primeri uporabe posnetkov QuickBird.....	26
Preglednica 5: Lastnosti ortofota.....	64
Preglednica 6: Lastnosti stereopara IKONOS.....	66
Preglednica 7: Lastnosti posnetka GeoEye-1.....	67
Preglednica 8: Ocena samodejnega iskanja stavb na DOF050 in nDMP.....	85
Preglednica 9: Ocena pravilnosti vektorskega zajema stavb na DOF050 in nDMP.....	85
Preglednica 10: Ocena kakovosti rastrskega zajema stavb na DOF050 in nDMP.....	86
Preglednica 11: Ocena samodejnega iskanja stavb na stereoparu IKONOS.....	106
Preglednica 12: Ocena pravilnosti vektorskega zajema stavb na stereoparu IKONOS.....	107
Preglednica 13: Ocena kakovosti rastrskega zajema stavb na stereoparu IKONOS.....	108
Preglednica 14: Ocena samodejnega iskanja stavb na posnetku GeoEye-1.....	116
Preglednica 15: Ocena kakovosti rastrskega zajema stavb na posnetku GeoEye-1.....	117
Preglednica 16: Georeferenciranje stereopara IKONOS.....	120
Preglednica 17: Analiza točnosti georeferenciranja stereopara IKONOS.....	121
Preglednica 18: Georeferenciranje posnetka GeoEye-1.....	122
Preglednica 19: Analiza točnosti georeferenciranja posnetka GeoEye-1.....	122
Preglednica 20: Ocena samodejnega iskanja stavb na različnih podatkovnih virih.....	128
Preglednica 21: Ocena pravilnosti vektorskega zajema stavb z različnih podatkovnih virov.	128
Preglednica 22: Ocena kakovosti rastrskega zajema stavb na različnih podatkovnih virih. ...	129

KAZALO SLIK

Slika 1: Nasičenje in učinek MTFC na pankromatski podobi IKONOS Geo.	24
Slika 2: Delovanje lidarja.....	29
Slika 3: Rezultat ostrenja multispektralne podobe.....	37
Slika 4: Izboljšanje kontrasta.	40
Slika 5: Učinek Wallisovega filtra.	41
Slika 6: Delovanje Laplaceovega filtra.....	45
Slika 7: Ravnina xy (a) in parametrski prostor ab (b) (Gonzales in sod., 2004).....	48
Slika 8: Parametrski prostor Houghove transformacije (Gonzales in sod., 2004).....	48
Slika 9: Delovanje Houghove transformacije.	49
Slika 10: Izračun vrednosti transformacije Radon.....	50
Slika 11: Delovanje transformacije Radon.	51
Slika 12: Primeri strukturnih elementom z označenimi izhodišči.	52
Slika 13: Izvorna podoba, strukturni element in izhodni rezultat dilacije.	53
Slika 14: Izvorna podoba, strukturni element in izhodni rezultat erozije.	53
Slika 15: Prikaz odpiranja in zapiranja: izvorna podoba (a) (Gonzales in sod., 2004), odpiranje (b), zapiranje (c), zapiranje odprte podobe (d).....	54
Slika 16: Odpiranje z rekonstrukcijo: izvorna podoba, zaznamovalec in rekonstruirana podoba.....	55
Slika 17: Izvorna podoba, dilacija, erozija in morfološki gradient.....	56
Slika 18: Evklidska in Mahalonobisova razdalja (Gonzales in sod., 2004).....	57
Slika 19: Posnetki in izbrana testna območja.	68
Slika 20: Diagram poteka zajema stavb na ortofotu in digitalnem modelu površja.	72
Slika 21: DMV, DMP in maska nDMP.	73
Slika 22: Rdeči, zeleni in modri sloj barvnega ortofota DOF050 (zgornja vrsta) in izostrenega bližnjega infrardečega ortofota DOF100IR (spodnja vrsta).	75
Slika 23: Izdelava maske stavb.	77
Slika 24: Popravljen maska stavb.	79
Slika 25: Izdelava obrisov stavb iz maske nDMP.....	80
Slika 26: Zajem stavb na DMP.	82

Slika 27: Rezultati zajema stavb na podatkih laserskega skeniranja prikazani na nDMP in DOF050.	83
Slika 28: Primerjava rezultatov zajema stavb s katastrom stavb.	84
Slika 29: Diagram poteka zajema stavb na ortofotu in digitalnem modelu površja.	87
Slika 30: Pankromatski kanal (a) in barvni kompozit rdečega, zelenega in modrega kanala (b).	89
Slika 31: DMP, DMV in maska nDMP.	90
Slika 32: Maska NDVI, maska cest in izboljšana maska stavb.	91
Slika 33: Čiščenje maske stavb.	92
Slika 34: Barvni kompozit rdečega, zelenega in modrega kanala pred in po obdelavi.	93
Slika 35: Nenadzorovana klasifikacija ISODATA.	94
Slika 36: Primer rezultatov barvne segmentacije podobe.	96
Slika 37: Dopolnitev maske stavb z rezultati barvne segmentacije podobe.	97
Slika 38: Diagram poteka barvne segmentacije.	98
Slika 39: Izdelava nove maske stavb.	99
Slika 40: Robovi na pankromatski in sivi podobi.	100
Slika 41: Siva podoba, prag in nenadzorovana klasifikacija.	101
Slika 42: Rezultat rasti regij.	102
Slika 43: Robovi, določeni s Cannyjevim algoritmom odkrivanja robov.	103
Slika 44: Orientacija in vektorizacija stavbe.	104
Slika 45: Urejanje topologije in primerjava rezultatov z DTK 5.	105
Slika 46: Rezultati samodejnega zajema stavb (a) in DTK 5 (b) na sivi podobi.	105
Slika 47: Shema poteka zajema stavb na posnetku GeoEye-1.	109
Slika 48: Pankromatski ortofoto in barvni kompozit ortofota rdečega, zelenega in modrega kanala.	110
Slika 49: Maska NDVI, negativ maske cest in maskiran barvni kompozit.	112
Slika 50: Rezultat nadzorovane klasifikacije in maska stavb.	113
Slika 51: Končna maska stavb in superimpozicija na barvnem kompozitu.	115
Slika 52: Območje z ročno zajetimi stavbami.	117
Slika 53: Kot snemanja povzroča premik streh.	124
Slika 54: Primerjava katastra stavb s podatki samodejnega zajema.	131
Slika 55: Izrez iz relacijske tabele.	133

OKRAJŠAVE IN SIMBOLI

CAS	Ciklično aerosnemanje Slovenije
CE90	Circular Error 90
DEM	Digital Elevation Model
DLT	direktna linearna transformacija
DMP	digitalni model površja
DMV	digitalni model višin
DSM	Digital Surface Model
DOF	digitalni ortofoto
DRA	Dinamic Range Adjustment
DTK 5	državna topografska karta v merilu 1 : 5000
GIS	geografski informacijski sistem
GML	Geography Markup Language
GURS	Geodetska uprava Republike Slovenije
HSI	Hue Saturation Intensity
KS	kataster stavb
Lidar	Light Detection And Ranging / Laser Imaging Detection And Ranging
LOD	Level of Detail
MTFC	Modulation Transfer Function Compensation
nDMP	normalizirani digitalni model površja
nDSM	Normalized Digital Surface Model
NDVI	normiran diferencialni vegetacijski indeks
OEEPE	Organisation Europeene d'Estudes Photogrammetriques Experementales
OGC	Open Geospatial Consortium
PAS	posebno aerosnemanje
RGB	Red Green Blue
RMSE	Root Mean Square Error
RPC	rational polynomial coefficients
RS	Republika Slovenija
SI	Shadow Index

TDI	Time Delay and Integration
TIFF	Tagged Image File Format
TKSS	topografsko-kartografski sistem Slovenije
TTN 5	temeljni topografski načrt v merilu 1 : 5000
ZEN	zakon o evidentiranju nepremičnin

SLOVAR

Krajši slovar je namenjen poenotenju strokovnih izrazov v doktorski disertaciji. Zaradi boljšega prepoznavanja so pojmi podani v slovenskem in angleškem jeziku. Navedeno literaturo smo uporabili kot izhodišče za opise pojmov in jo nismo povsod dobesedno citirali.

- difuzijsko filtriranje
diffusion filtering Odstranjevanje šuma na podobi ob hkratnem ohranjanju robov oziroma značilnih točk. Difuzija je fizikalni proces, ki izenačuje razlike v koncentracijah brez ustvarjanja ali izenačevanja mase. V primeru obdelave podob predstavlja koncentracijo snovi v določeni točki intenziteta piksla, postopek filtriranja pa izenačuje razlike v intenzitetah različnih delov podobe. (Zaletelj in sod., 1998).
- digitalni model površja
(DMP)
digital surface model
(DSM) Računalniška predstavitev nadmorskih višin zemeljskega površja na določenem območju. Predstavlja zemeljsko površje kot ga vidimo od zgoraj. Poleg samega reliefa prikazuje pojave na terenu kot so zgradbe in vegetacija, na odprtih območjih pa je ekvivalenten digitalnemu modelu višin. (Kraus, 2007; Pfeifer, Mandlbürger, 2009).
- digitalni model reliefa
(DMR)
digital terrain model
(DTM) Digitalni opis oblikovanosti zemeljskega površja. Ne vsebuje le prikaza površja samega, ampak tudi njegov opis z nakloni, ekspozicijo ter plastnicami, padnicami, točkami vrhov ter drugimi značilnimi črtami in točkami. (Podobnikar, 2001).
- digitalni model višin
(DMV)
digital elevation model
(DEM) Računalniška predstavitev nadmorskih višin zemeljskega površja na določenem območju. Je preprostejši približek zapisa digitalnega modela reliefa. Vsebuje samo višinske točke, ki so najpogosteje zapisane v obliki pravilnih kvadratnih celic in pogojno tvorijo ploskev zemeljskega površja. (Podobnikar, 2001).

geografski informacijski sistem (GIS) <i>geographic information system (GIS)</i>	Sistem za zajemanje, shranjevanje, vzdrževanje, obdelavo, povezovanje, analiziranje in predstavitev prostorskih geokodiranih podatkov. Osrednji poudarek je na raznih podatkovnih analizah. GIS sestavljajo strojna oprema, sistemska in posebna programska oprema, uporabniške aplikacije, integrirana baza prostorskih podatkov, vzdrževalci in predvsem uporabniki informacijskega sistema. (Šumrada, 2005a).
georeferenciranje <i>georeferencing</i>	Postopek prevzorčenja podob, s katerim izvedemo geometrijske popravke podobe in pikslom pripišemo koordinate v določeni kartografski projekciji. (Oštir, 2006; Richards, Jia, 2006).
intenziteta <i>intensity</i>	Zaloga vrednosti, ki jih lahko zajame piksel na podobi. V primeru črnobelih podob jo imenujemo tudi sivina (angl. gray level). (Gonzales, Woods, Eddins, 2004).
kontrolna točka <i>check point</i>	Točka, ki jo lahko prepoznamo na podobi in ima znane koordinate v referenčnem koordinatnem sistemu. Na kontrolnih točkah preverjamo točnost georeferenciranja podob.
model senzorja RPC <i>RPC sensor model</i>	Model racionalnih funkcij (angl. Rational Function Model RFM). Opisuje geometrični odnos med slikovnimi koordinatami točke (vrstica, stolpec) in objektnimi koordinatami točke (običajno geografska širina, geografska dolžina in nadmorska višina). Vrstico ali stolpec na posnetku izrazimo kot razmerje dveh kubičnih polinomov, ki sta podana s koeficienti RPC (Rational Polynomial Coefficients). Model senzorja RPC služi za fotogrametrično orientacijo posnetkov. Predstavlja alternativo fizičnim modelom senzorja, pri katerih poznamo geometrične lastnosti senzorja in njegov položaj v prostoru. Koeficiente RPC dobavlja podjetje GeoEye za georeferenciranje njihovih posnetkov. (Dowman, Tao, 2002; Eurimage, 2009; Fraser, Hanley, 2005; Grodecki, Dial, 2003, Tao, Hu, 2002).
natančnost <i>precision</i>	Natančnost je stopnja medsebojne skladnosti ponovljenih opazovanj iste količine. Splošna mera natančnosti je standardni odklon. (Frančula, Lapaine, 2003; Mikhail, Gracie, 1981).

normalizirani digitalni model površja (nDMP) <i>normalised digital surface model (nDSM)</i>	Predstavitev relativnih višin objektov na zemeljskem površju. Vključuje samo objekte, ki segajo nad površino tal. Predstavlja razliko med digitalnim modelom površja in digitalnim modelom višin. (Dorninger, Pfeifer, 2008; Pfeifer, Mandlbürger, 2009).
ortofoto <i>orthophoto</i>	Tudi ortofotografija, ortofotokarta; fotogrametrični izdelek, ki ga dobimo s transformacijo posnetka v ortogonalno projekcijo (Kosmatin Fras, 2004).
oslonilna točka <i>control point</i>	Točka, ki jo lahko prepoznamo na podobi in ima znane koordinate v referenčnem koordinatnem sistemu. Oslonilne točke služijo za georeferenciranje podob.
ostrenje multispektralnih podob <i>pan-sharpening</i>	Postopek, pri katerem z združitvijo nizkoločljivih multispektralnih podob z visokoločljivimi pankromatskimi podobami dobimo visokoločljive multispektralne podobe. (Zhang, 2008).
podoba <i>image</i>	Tudi slika; digitalna predstavitev podatkov daljinskega zaznavanja v obliki matrike slikovnih elementov oziroma pikslov. Podoba lahko predstavlja odbojnost ali lastno sevanje površja in je – odvisno od števila kanalov – enorazsežna ali več razsežna. Izraz poleg tega zajema tudi vse rezultate obdelav, od predobdelave prek izboljšanja in transformacij do klasifikacije, modeliranja in simulacij. V najširšem pomenu je podoba vsaka slika v rastrski obliki. Pojem je širši od posnetka, ki je predstavitev resničnosti, kot jo je zajel senzor. (Oštir, 2006).
posnetek <i>picture, image</i>	Predstavitev resničnosti ne glede na način in platformo zajema. Posnetek nastane z uporabo optičnih naprav ter analognega ali digitalnega sensorja. Predstavlja sliko opazovanih predmetov, zajeto v določenem trenutku pri izbrani valovni dolžini. Posnetek za razliko od podobe podaja vrednosti, ki jih je zajel senzor in so le malo ali skoraj nespremenjene – zaradi lažjega

prikaza in integracije v GIS je lahko geometrično ali radiometrično popravljen in izboljššan. (Oštir, 2006).

prostorska ločljivost
spatial resolution Prostorska ločljivost rastrskih podatkov je merilo, ki podaja razmerje med velikostjo mrežne (gridne) celice v bazi podatkov in velikostjo celice v naravi. V daljinskem zaznavanju predstavlja prostorska ločljivost velikost najmanjšega predmeta, ki ga na podobi zaznamo. (Šumrada, 2005b; Oštir, 2006).

segmentacija
segmentation Postopek delitve podobe na homogena območja (množice sosednjih pikslov). (Oštir, 2006).

standardni odklon
standard deviation Tudi standardna deviacija; mera natančnosti opazovanj. Podaja širino oziroma disperzijo verjetnostne funkcije. Opazovanja višje natančnosti imajo manjši standardni odklon in obratno. Kvadrat standardnega odklona imenujemo varianca. (Mikhail, Gracie, 1981).

srednji pogrešek
root mean square error Mera za odstopanje slučajne spremenljivke od neke standardne oziroma privzete vrednosti. Izračunamo ga:

$$m = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_p)^2},$$

kjer je x_i posamezna vrednost slučajne spremenljivke z n členi, x_p pa standardna oziroma privzeta vrednost. Srednji pogrešek je uporaben kot mera točnosti. (Frančula, Lapaine, 2003)

točnost
accuracy Točnost je stopnja skladnosti ali bližine opazovanj in prave vrednosti. Poleg vplivov slučajnih pogreškov vključuje tudi vpliv sistematičnih pogreškov, ki jih nismo odstranili iz opazovanj. Mero točnosti predstavlja srednji pogrešek odstopanj na kontrolnih točkah. Če ni prisotnih sistematičnih pogreškov, lahko za mero točnosti uporabimo standardni odklon. (Mikhail, Bethel, McGlone, 2001; Mikhail, Gracie, 1981).

topologija
topology Podaja povezljivost in opisuje logične sosedske odnose med lokacijami posameznih geografskih pojavov v prostoru. Topologija predstavlja in

definira geometrično povezanost in razvrstitev (vrstni red) grafičnih gradnikov, ki tvorijo neki geografski objekt, brez uporabe njihove absolutne lokacije oziroma koordinat. V vektorski sestavi grafičnih podatkov (vozlišče – točka, segment – vektor, poligon – območje) je topologija temelj geometrijske organizacije podatkov. Pri rastrski sestavi grafičnih podatkov (gridna celica) je topologija inherentno vgrajena v organizacijo podatkov in so topološki odnosi posredno opredeljeni s položajem celice v matriki vrednosti. (Šumrada, 2005b).

1 UVOD

V poglavju utemeljimo raziskavo in predstavimo problematiko vzdrževanja topografskih podatkov. V njem navajamo osnovne primere samodejnega iskanja in zajema stavb na visokoločljivih slikovnih virih in omenimo pomembne avtorje z obravnavanega področja. V drugem delu poglavja opredelimo hipotezo, predstavimo cilje naloge in izbrano metodologijo dela. Na koncu opišemo še strukturo naloge s kratko vsebino poglavij.

1.1 Ozadje problema

Topografski podatki so podatki o fizičnem stanju površja. Vodimo jih v topografskih bazah. V Sloveniji so topografski podatki shranjeni in dostopni kot posamezni gradniki Topografsko-kartografskega sistema Slovenije (TKSS). Za vzpostavitev in vodenje je pristojna Geodetska uprava Republike Slovenije (GURS). Podatke v topografskih bazah moramo redno dopolnjevati in vzdrževati, po možnosti iz izvornih virov. Vzdrževanje teh podatkov je pomembna stalna naloga, ki je časovno in organizacijsko zahtevna, zanjo so potrebna tudi primerna finančna sredstva. Vzdrževanje se izvaja po ustaljenih postopkih s klasičnimi metodami, kjer usposobljeni strokovnjak ugotavlja spremembe v podatkih in nato te nove podatke z ustrežno opremo zajame. Masovni zajem in vzdrževanje prostorskih (topografskih, kartografskih) podatkov se v veliki meri izvaja s fotogrametričnimi metodami. Eden od podatkov v topografskih bazah so podatki o stavbah. Doktorska disertacija obravnava nove možnosti vzdrževanja teh podatkov.

Poleg obstoječih podatkov državnega letalskega snemanja predstavljajo enega od možnih virov za vzdrževanje podatkov v topografskih bazah satelitski posnetki in drugi podatki daljinskega zaznavanja, ki postajajo ob že zadostni prostorski ločljivosti tudi cenovno vedno bolj dostopni. Po letu 1999 je bilo v različne Zemljine tirnice izstreljenih več komercialnih satelitov, ki zajemajo podobe visoke ločljivosti. Kar nekaj komercialnih satelitov zajema pankromatske posnetke s prostorsko ločljivostjo enega metra ali boljše: GeoEye-1, IKONOS,

OrbView-3, QuickBird, WorldView-1, EROS B. Razen zadnjih dveh vsi snemajo Zemljo tudi z multispektralnimi posnetki. Ti imajo običajno štirikrat slabšo prostorsko ločljivost kot pankromatski posnetki, vendar v veliki meri pripomorejo k boljši interpretaciji podob, z metodami ostrenja pa tudi k njihovi boljši upodobitvi.

Visokoločljivi satelitski posnetki tako postajajo tudi dragocen vir podatkov pri obnavljanju podatkov v prostorskih topografskih bazah. Visoka prostorska ločljivost podob razkriva natančne detajle v urbanih območjih in v veliki meri pospešuje klasifikacijo in zajem urbanih objektov, med drugim tudi stavb (Jin, Davis, 2005). Metode omogočajo zajem stavb s položajno natančnostjo in točnostjo, ki je boljša od enega metra (Baltsavias in sod., 2001a; Fraser in sod. 2002), kar že skoraj povsem dosega zahtevano položajno točnost stavb pri zajemu v državno topografsko karto v merilu 1 : 5000 (DTK 5), ki znaša 0,5 m.

Različne kartografske agencije po svetu so že zelo zgodaj pokazale interes za uporabo satelitskih posnetkov pri zajemu in obnovi podatkov v prostorskih bazah. Prve študije in raziskave o potencialu visokoločljivih satelitskih posnetkov so bile narejene pred dejansko izstrelitvijo prvih komercialnih visokoločljivostnih satelitov (Ridley in sod., 1997; Li, 1998). Možnost uporabe posnetkov IKONOS za topografsko kartiranje, iskanje sprememb in določanje pokrovnosti tal so v letih 1998-2002 raziskali člani OEEPE (Organisation Europeene d'Estudes Photogrammetriques Experementales, Evropska organizacija za eksperimentalne fotogrametrične raziskave). Rezultati so pokazali, da imajo visokoločljivostni posnetki velik potencial zlasti za izdelavo kart pokrovnosti tal in ažuriranje številnih topografskih objektov na kartah v merilu 1 : 10.000 in manjših merilih (Holland in sod., 2002). Ugotovili so, da lahko na tovrstnih posnetkih učinkovito zajamemo ceste, železnice, vodna telesa in večino stavb, težave pa predstavljajo manjši objekti kot so na primer zidovi, ograje in žive meje, ki jih na posnetkih ni mogoče prepoznati v celoti.

Obsežno raziskavo o uporabnosti posnetkov QuickBird za vzdrževanje topografskih kart je v letu 2003 izpeljala Geodetska uprava Velike Britanije (Ordnance Survey, Britain's national mapping agency). Topografske baze v Veliki Britaniji so zajete s položajno točnostjo, ki odgovarja merilom 1 : 1250 v urbanih, 1 : 2500 v ruralnih in 1 : 10.000 v hribovitih predelih. Če povzamemo samo rezultate, ki se nanašajo na odkrivanje stavb na posnetkih QuickBird, so

ugotovili, da lahko stavbe zajamejo s položajno točnostjo, ki ustreza kartam v merilih 1 : 25.000 in 1 : 50.000. Stavbe so bile na posnetkih lahko prepoznavne, vendar zajete preveč generalizirano, da bi lahko ustrezale kompleksnosti, ki jo prikazujejo karte večjih meril. Uporaba posnetkov je bila vseeno zelo učinkovita pri iskanju sprememb v okolju (Holland in sod., 2006).

Osnovni podatki za iskanje in zajem stavb so poleg letalskih posnetkov lahko satelitski posnetki ali njihova kombinirana uporaba z različnimi podatki kot so topografske karte, lidarski ali ostali višinski podatki in različni modeli stavb. Trend pri iskanju stavb na posnetkih je v zadnjih letih prav kombinirana uporaba več podatkovnih virov in integracija posnetkov z drugimi podatkovnimi viri kot so digitalni modeli površja (DMP) in drugi obstoječi sloji GIS, topografski načrti ter spoznanja, pridobljena na podlagi predhodnega pregleda terena.

1.2 Pregled obstoječih metod

Samodejno iskanje in zajemanje stavb iz letalskih in satelitskih posnetkov je že vrsto let pomembna tema raziskav na področju fotogrametrije in daljinskega zaznavanja. Opis metod lahko najdemo v periodičnih zbornikih (Grün in sod., 1995, 1997; Baltsavias in sod., 2001b). Prvotne raziskave so bile opravljene na digitalnih letalskih posnetkih, ki s podobami z velikostjo piksla 1 m ali manj nudijo dovolj veliko prostorsko ločljivost. Predlaganih je bilo več tehnik za samodejno izdelavo dvorazsežnih ali trirazsežnih modelov stavb. Obširen pregled tehnik in pregled stanja raziskav opisuje Mayer (1999). Vse tovrstne študije, razvite na letalskih posnetkih, se danes s pridom uporabljajo tudi za odkrivanje in zajem stavb na visokoločljivih satelitskih posnetkih.

Osnovni podatki za iskanje in zajem stavb so lahko sami posnetki ali njihova kombinirana uporaba z različnimi podatki. Začetni razvoj metod je temeljil na uporabi enega posnetka. Modeli stavb so bili izdelani z analizo geometričnih in radiometričnih lastnosti posnetkov ob uporabi tehnik iskanja robov (Huertas, Nevatia, 1988; Lin, Nevatia, 1998).

Dodatni podatki, ki se ob posnetkih uporabljajo za odkrivanje in zajem stavb, so:

- topografske karte (Förstner and Pluemer, 1997; Haala, 1999);
- lidarski ali drugi višinski podatki (Weidner, Förstner, 1995; Baillard, Maitre, 1999; Hofmann, 2001; Kim, Muller, 2001; Sohn, Dowman, 2003);
- multispektralni in/ali hiperspektralni posnetki (Haala, 1999; Huertas in sod., 1999, 2000; McKeown in sod., 1999; Lee in sod., 2003);
- različni geometrijski modeli stavb, s katerimi modeliramo odkrite stavbe na posnetkih (Braun in sod., 1995; Förstner, Pluemer, 1997; Förstner, 1999).

Glede na število uporabljenih posnetkov v obdelavi delimo metode na enoslikovne, dvoslikovne (stereoskopske) in večslikovne. Razlika med enoslikovnimi in dvoslikovnimi metodami je v uporabi višinskih podatkov, ki jih lahko pridobimo iz stereo posnetkov. Večslikovne metode za iskanje stavb so pri uporabi letalskih posnetkov dokaj redke, medtem ko jih pri obravnavi satelitskih podob v literaturi skoraj ne najdemo, saj običajno nimamo na voljo več posnetkov, s katerimi bi satelitski snemalni sistem zajel isto površino Zemlje v istem časovnem obdobju. Sistemi za enoslikovno odkrivanje stavb na visokoločljivih podobah slonijo na naslednjih postopkih:

- iskanje linij na podobah in njihovo dopolnjevanje z uporabo pravokotnih modelov stavb (Park in sod., 2000);
- uporaba Fourierjeve analize na odkritih linijah za iskanje prevladujočega orientacijskega kota v gruči stavb. Na podlagi analize se izdelajo oblike stavb, ki se uporabijo za izdelavo obrisov stavb (Sohn, Dowman, 2001);
- iskanje položaja in oblike območij, ki predstavljajo kandidate za stavbe, s klasifikacijo multispektralnih podob. Zajem stavb je izveden na odgovarjajočih pankromatskih podobah s postopki segmentacije in pravokotizacije ter uporabi Houghove transformacije za dopolnjevanje segmentov linij (Lee in sod., 2003);
- odkrivanje manjših stavb v primestnih območjih s kombinacijo nadzorovane klasifikacije oblik in nenadzorovane segmentacije podob. Z uporabo različnih pragov segmentacije dobimo kandidate za stavbe. Rezultate klasificiramo z oblikovnim

ujemanjem z modelno podatkovno bazo. Kot stavbe so prepoznani tisti objekti, katerih oblika je bila pravilno klasificirana na več različnih segmentacijah (Segl, Kaufmann, 2001);

- kandidate za stavbe poiščemo s hierarhično klasifikacijo pikslov. Segmentirane podobe, ki vsebujejo spektralne, prostorske in kontekstualne (sence) informacije, analiziramo z mehko logiko (angl. fuzzy logic), ki kategorizira stavbe kot posamezne objektne razrede (Shackelford, Davis, 2003);
- izdelava obrisov z matematičnimi morfološkimi operacijami in klasifikacija stavb in ostalih vrst rabe površin z nevronskimi mrežami (Benediktsson in sod., 2003).

Pri dvoslikovnih postopkih iz stereopara posnetkov izdelamo digitalni model višin, ki ga skupaj s spektralnimi podatki uporabimo za ločitev stavb od ostalih objektov. Natančne obrise stavb nato zajamemo z eno od tehnik za zajem stavb na eni podobi (Koc San, Turker, 2007). S tehnikami slikovnega ujemanja lahko stereo podobe uporabimo tudi za trirazsežni (3D) zajem modelov stavb (Xiong, Zhang, 2006).

1.3 Izhodišča, cilji in hipoteza

V svetu potekajo raziskave za samodejno odkrivanje stavb na visokoločljivih posnetkih že skoraj dve desetletji. V ta namen so bile razvite številne metode (nekatero smo omenili v 1.2). Metode so običajno predstavljene na idealnih podatkih (velike stavbe, ki se nedvoumno ločijo od okolice), rezultatov odkrivanja stavb, ki bi izhajali iz delovnih razmer skoraj ne zasledimo. Slikovni viri se vse več kombinirajo z ostalimi podatki (predvsem podatki lidarskega snemanja). Trend se je razmahnil s povečanim zanimanjem za izdelavo 3D modelov mest, v katerih skušamo najprej samodejno odkriti in nato upodobiti 3D modele stavb, dreves in ostalih objektov, ki v urbanih okoljih segajo nad zemeljsko površje. Eden od standardov, ki zagotavlja poenotenje podatkov 3D modelov mest je CityGML (OGC, 2008). CityGML je odprt podatkovni model, ki temelji na formatu XML za shranjevanje in izmenjavo 3D modelov mest. Predstavlja aplikacijsko shemo za Geography Markup Language verzije 3.1.1 (GML3), ki je mednarodni standard za izmenjavo prostorskih podatkov, izdan od Open Geospatial Consortium (OGC) in ISO TC211. Tematski model CityGML vključuje različne

oblike digitalnega modela reliefa (DMR), objekte (npr. stavbe), vegetacijo, vodna telesa, komunikacije in ostalo mestno infrastrukturo. CityGML razlikuje pet različnih nivojev razpoznavnosti objektov (angl. Level of Detail LOD). Podrobnosti prikaza objektov naraščajo z nivoji LOD:

- LOD0 je najosnovnejša predstavitev, ki jo lahko opišemo kot DMP na katerega je projiciran posnetek ali tematska karta;
- LOD1 je blokovni model, kjer so stavbe predstavljene s prizmatičnimi modeli in ravnimi strehami;
- v LOD2 imajo stavbe oblikovane strehe in tematsko opredeljene fasade;
- LOD3 vsebuje arhitekturne modele z detajlno oblikovanimi zidovi in strehami, balkoni, okni in ostalimi izpostavljenimi deli;
- LOD4 je izpopolnjen LOD3 z dodanim interjerjem stavb.

V Sloveniji vodimo podatke o stavbah v Katastru stavb (KS) in Državni topografski karti v merilu 1 : 5000 (DTK 5), v katerih so shranjeni obodi stavb, njihovi centri, karakteristična točka fundusa in višina kapi. Osnovni slikovni vir za zajem in vzdrževanje državnih topografskih podatkov trenutno zagotavlja letalsko snemanje. Postopki zajema in vzdrževanja potekajo ročno s klasičnimi fotogrametričnimi metodami. Za DTK 5 v Sloveniji še nimamo izdelanega načrta vzdrževanja. Na nivoju digitalne obdelave podob je danes možno avtomatizirati praktično vse faze procesa. V Sloveniji predvsem manjka raziskovalnih dosežkov in izkušenj na tem področju. Z doktorsko nalogo želimo načeti to tematiko na raziskovalnem nivoju, vendar s ciljem, da se postopno izgradi primeren delujoč sistem za slovensko prakso. Pri tem nas zanima, v kolikšni meri lahko samodejni postopki odkrivanja stavb na visokoločljivih podatkovnih virih nadomestijo ročno delo operaterjev pri vzdrževanju podatkov.

V zadnjem desetletju je bilo izstreljeno kar nekaj komercialnih satelitov, ki zajemajo posnetke z visoko prostorsko ločljivostjo. V doktorski nalogi bomo analizirali, kako lahko te nove vire vključimo v obstoječ sistem vzdrževanja topografskih podatkov. Zanima nas uporabnost satelitskih posnetkov za iskanje in zajem podatkov v topografske baze, kakšne so njihove

omejitve in v kolikšni meri lahko nadomestijo podatke letalskega snemanja. V raziskave bomo vključili tudi iz letalskega snemanja izdelane ortofote in višinske podatke (DMP in DMV) ter same podatke iz topografske baze.

Letalski posnetki omogočajo boljšo prostorsko ločljivost (običajno med 0,25 m in 0,5 m) od satelitskih posnetkov in zagotavljajo uporabnost za vzdrževanje podatkovnih baz največjih meril. Zato bomo preverili položajno točnost, ki jo nudijo satelitski posnetki z vidika primernosti za obnavljanje prostorskih baz.

V doktorski nalogi se bomo omejili na ožji raziskovalni problem odkrivanja stavb na visokoločljivih posnetkih in iskanju sprememb glede na podatke v obstoječih bazah. Menimo, da potencial visokoločljivih posnetkov z vidika samodejnega iskanja stavb še ni v celoti izkoriščen. Globalni trend je dopolnjevanje slikovnih virov z ostalimi podatki (npr. lidar), ki omogočajo točnejšo izdelavo 3D modelov stavb. Vendar več podatkov v obdelavi prinaša tudi več operaterskega dela in posledično višje stroške. V doktorski nalogi bomo skušali čim bolj učinkovito izkoristiti visokoločljive slikovne vire za pridobitev optimalnih rezultatov pri iskanju stavb. Z minimalnim dopolnjevanjem slikovnih virov z ostalimi obstoječimi podatki želimo s samodejnimi postopki poiskati spremembe v topografskih bazah, ki vodijo podatke o stavbah. Dodatno bomo poskušali z vektorizacijo zajetih stavb pridobiti podatke o stavbah, ki bi z dopolnitvijo stavb z nadmorskimi višinami ustrezali nivoju razpoznavnosti LOD1 po standardu CityGML.

Glede na opisane cilje postavimo hipotezo.

Visokoločljive slikovne vire lahko z minimalnim dopolnjevanjem s pomožnimi podatkovnimi viri, kot so višinski podatki in topografske karte, izkoristimo za samodejno pridobivanje podatkov o stavbah, ki bodo omogočali vzdrževanje topografskih baz in objektivno kontrolo zajema stavb v topografske baze. Za iskanje stavb na slikovnih virih lahko izdelamo nove samodejne postopke, s katerimi bomo ob visoki stopnji avtomatizacije pridobili zadovoljive rezultate (80 % odkritih stavb) v delovnih razmerah ob uporabi neidealiziranih podatkov iz stvarnega okolja.

1.4 Metoda dela

V okviru doktorske raziskovalne naloge bomo obravnavali različne metode za samodejno iskanje stavb. Glede na razpoložljivost podatkov bomo izbrali tri tipične primere podatkov, ki lahko predstavljajo alternativni vir letalskemu snemanju za vzdrževanje topografskih baz. To so kombinacija višinskih podatkov z visokoločljivim slikovnim virom, stereopar satelitskih posnetkov ali en sam satelitski posnetek. Omejili se bomo na iskanje in zajem stavb z enoslikovnimi postopki, saj smo s pregledom obstoječe literature ocenili, da bi bilo obravnavanje vseh vrst različnih postopkov preobširno za eno samo raziskovalno nalogo. Stavbe, zajete s samodejnimi postopki, bomo primerjali z aktualnim stanjem v grafičnih topografskih bazah, označili spremembe, ki predstavljajo podlago za obnovo baz ter ovrednotili primernost posamezne metode za vzdrževanje grafičnih podatkov o stavbah v državnih topografskih bazah. Večino opisanih postopkov bomo sprogramirali v programu Matlab 6.5. Za nekatere uveljavljene postopke bomo uporabili komercialno programsko opremo (program Erdas Imagine 9.0 za nenadzorovano klasifikacijo, program Socet Set 5.4.1 Export za samodejni zajem DMP, urejanje DMV in prevzorčenje posnetkov z direktno linearno transformacijo DLT, program ENVI 4.4 za ostrenje multispektralnih podob, analizo teksture in objektni pristop nadzorovane klasifikacije, program ArcGIS 9.3 za urejanje topologije). Programiranje zahteva detajlno poznavanje problema samodejnega iskanja stavb. Uporabili bomo podatke iz realnega okolja, ki niso idealizirani za potrebe izdelave naloge. Lastno programiranje in uporaba stvarnih podatkov nam zagotavlja realno oceno primernosti posameznih metod za vzdrževanje topografskih baz. Programiranje je primerna metoda tudi zato, ker s komercialnimi programi zaradi premajhnega nadzora nad programskimi parametri ne dobimo vedno zadovoljujočih rezultatov.

1.5 Struktura naloge

Doktorsko nalogo sestavlja osem vsebinskih poglavij, ki tvorijo tri glavne sklope. Prvi sklop, ki obsega poglavja od 1 do 4, je teoretični. V uvodnem poglavju predstavimo problematiko in podamo pregled pomembne literature in postopkov z obravnavanega področja. V drugem poglavju opisujemo državne topografske baze, ki vodijo podatke o stavbah in način njihovega

vzdrževanja. V tretjem poglavju predstavimo trenutne in možne nove podatke za vzdrževanje baz. V četrtem poglavju opišemo pomembne postopke za predobdelavo (metode za georeferenciranje) in izboljšanje slikovnih in ostalih podatkov pred izvedbo samodejnih postopkov. V tem delu smo zbrali teoretične opise vseh metod in postopkov, ki smo jih uporabili v praktičnem delu naloge.

Drugi sklop, v katerem je predstavljen praktični del doktorske naloge, sestavljata poglavji 5 in 6. V petem poglavju na kratko opišemo uporabljene podatke in metodologijo njihove obdelave, v šestem poglavju pa podajamo detajlne tehnične opise izvedenih postopkov in predlagamo nekatere izvirne rešitve in izboljšave obstoječih postopkov. Praktični del smo izvedli na treh primerih tipičnih kombinacij podatkov, ki se uporabljajo za samodejno iskanje stavb. Kot prvi primer opišemo postopek samodejnega zajemanja stavb na kombinaciji državnega ortofota in digitalnega modela površja. V drugem primeru obravnavamo samodejno iskanje stavb na stereoparu IKONOS, ki ga kombiniramo s podatki o cestah iz podatkovne baze DTK 5. V tretjem primeru opišemo postopek samodejnega iskanja stavb na posnetku s satelita GeoEye-1. Na koncu vsakega primera podajamo oceno uspešnosti določenega samodejnega postopka.

Tretji sklop doktorske naloge predstavlja poglavje 7. V njem podamo skupno oceno samodejnega odkrivanja stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov. Analiziramo primernost satelitskih posnetkov za vključitev v sistem vzdrževanja topografskih podatkov, ocenimo položajno točnost satelitskih podob z vidika primernosti za vzdrževanje topografskih baz in opišemo težave, ki se pojavljajo ob njihovi uporabi. Poiščemo najprimernejšo kombinacijo podatkov in predlagamo nadaljnje raziskave, ki bi bile potrebne za uvedbo povsem samodejnega sistema. V sedmem poglavju podamo tudi način, kako pridobljene rezultate uporabiti za vzdrževanje topografskih podatkov in navedemo zaključne ugotovitve naloge. Zaključne ugotovitve strnemo v osmem poglavju.

2 VODENJE IN NAČIN VZDRŽEVANJA PODATKOV V DRŽAVNIH TOPOGRAFSKIH BAZAH

Topografski podatki so podatki o fizičnem stanju površja. V preteklosti so glavni vir topografskih podatkov predstavljale systemske karte različnih meril. V sedanjem času topografske baze vse bolj postajajo osnovni vir podatkov, karte pa ostajajo le še eden izmed možnih grafičnih izhodov (upodobitev). Ta sprememba povzroča velik premik v principu vodenja topografskih podatkov (Petrovič, 2003).

V Sloveniji so topografski podatki shranjeni in dostopni kot posamezni gradniki Topografsko-kartografskega sistema Slovenije (Radovan in sod., 1996); za vzpostavitev in vodenje je pristojna Geodetska uprava Republike Slovenije. Topografsko-kartografski sistem Slovenije (TKSS) je sklop vseh topografskih podatkov o prostoru v numerični ali grafični, analogni in digitalni obliki, ki jih za potrebe državnih organov in ostalih uporabnikov vzpostavlja, vzdržuje in vodi Geodetska uprava Republike Slovenije. Tvorijo ga trije sklopi: izvorni posnetki stanja, karte in ortofoto ter podatkovne baze. Slednje so organizirane pretežno po vsebinskih področjih. Namenjene so predvsem za najrazličnejša poizvedovanja, za prostorske analize in kot podatkovna osnova za različne upodobitve. Topografske baze smo v Sloveniji pričeli intenzivno vzpostavljati po letu 1991. V začetku so bile vir zajema obstoječe karte (sekundarni vir), v zadnjih letih pa so glavni vir zajema stereopari Cikličnega aerosnemanja Slovenije (CAS) ali pa ortofoto v merilu 1 : 5000 (DOF 5), ki predstavljajo primarni vir.

2.1 Vodenje podatkov o stavbah

Stavba je zgradba, v katero lahko človek vstopi in je namenjena njegovemu stalnemu ali začasnemu prebivanju, opravljanju poslovne in druge dejavnosti ali zaščiti ter je ni mogoče prestaviti brez škode za njeno substanco. Je grajeni objekt, ki ima običajno stene, je pokrit s streho in zasnovan za posamezne določene namene. V zbirki topografskih podatkov je predstavljena z obrisom kapi strehe in tematskimi atributi, topološko je njena oblika

predstavljena s ploskvijo. Ocenjeno število vseh stavb v Sloveniji je 1.400.000 (GURS, 2008).

Osnovni slikovni vir za zajem podatkov predstavljajo podatki CAS, ki se v Sloveniji v merilu 1 : 17.500 izvaja od leta 1975. V letu 2006 je bilo celotno območje Slovenije posneto z digitalnim snemalnim sistemom. Iz podatkov CAS so bili izdelani barvni ortofoti s prostorsko ločljivostjo 0,5 m (DOF050), bližnje infrardeči ortofoti z ločljivostjo 1 m (DOF100IR) in 491 listov barvnih ortofotov z ločljivostjo 0,25 m (DOF025). DOF025 je izdelan le za 25 % celotnega ozemlja Slovenije. Enota za izdelavo ortofota je en list TTN 5. Obstoječi ortofoti se med drugim uporabljajo tudi za kontrolo zajema stavb (GURS, 2008).

Topografski bazi, v kateri v Sloveniji zajemamo podatke o stavbah, sta Kataster stavb (KS) in Državna topografska karta v merilu 1 : 5000 (DTK 5). Pravila, ki opredeljujejo zajem stavb v ti bazi, so opisana v Operativnem navodilu za zajem podatkov o stavbah. V grafična dela baz se zajemajo relativno trajne stavbe, običajno s stenami, pokrite s streho in zasnovane za posamezne določene namene uporabe, imajo površino večjo od 4 m² ter segajo vsaj 2 m nad zemeljsko površje. Poleg oboda stavbe se zajema tudi njen centroid, karakteristična točka fundusa (projekcija obrisa stavbe na teren) in višina kapi. Zahtevana položajna natančnost za zajem stavb znaša 50 cm (GURS, 2001).

2.1.1 Kataster stavb

Kataster stavb (KS) je temeljna evidenca podatkov o stavbah in o delih stavb ter predstavlja tehnično osnovo za evidentiranje pravnih razmerij na stavbah in na delih stavb. Povezuje se z zemljiškim katastrom in zemljiško knjigo. Zakonsko podlago za vzpostavitev, vodenje in vzdrževanje KS dajeta Zakon o evidentiranju nepremičnin (ZEN – Uradni list RS št. 47/06) in Pravilnik o vpisih v kataster stavb (Uradni list RS, št. 22/2007). V njem se vodijo tudi deli stavb, zajeti v skladu z Zakonom o posebnih pogojih za vpis lastninske pravice na posameznih delih stavbe v zemljiško knjigo – uradno prečiščeno besedilo (ZPPLPS-UPB1 – Uradni list RS št. 47/2003), vendar je veljavnost slednjega prenehala 19.11.2004 in vpis v KS na ta način ni več mogoč. Namen vzpostavitve KS je evidentiranje vseh stavb v RS, predvsem za namen pravične obdavčitve nepremičnin in tudi za druge uporabnike.

V KS se vodijo naslednji podatki o stavbah in o delih stavb:

- identifikacijska številka stavbe oziroma dela stavbe,
- lastnik stavbe in delov stavbe,
- upravljavec, če je lastnik država,
- lega, površina in oblika,
- dejanska raba,
- povezava stavbe z zemljiškim katastrom,
- povezava stavbe z registrom prostorskih enot,
- povezava z zemljiško knjigo.

Za stavbe in dele stavb se istočasno vodijo katastrski (se vzpostavijo in vzdržujejo ali na zahtevo lastnika zemljišča, stavbe ali dela stavbe oziroma po uradni dolžnosti) in registrski podatki (se vzpostavijo in vzdržujejo po prijavi oziroma s prevzemom podatkov iz drugih evidenc) (GURS, 2008).

2.1.2 Državna topografska karta v merilu 1 : 5000

Stavbe predstavljajo tudi eno od objektnih področij v državni topografski karti v merilu 1 : 5000 (DTK 5). Topografski podatki DTK 5 predstavljajo zbirko topografskih podatkov homogene natančnosti, ki ustreza ravni merila 1 : 5000. Zajem za DTK 5 se izvaja iz stereoparov posnetkov cikličnega aerosnemanja, enoto zajema predstavlja list merila 1 : 5000 temeljnega topografskega načrta TTN 5. Celotna Slovenija bo s podatki DTK 5 predvidoma pokrita do konca leta 2009 (Duhovnik, 2005). Podatke DTK 5 je mogoče uporabljati za georeferenciranje drugih podatkov v prostoru, kot podlago za prikaz grafičnih delov občinskih prostorskih planskih aktov in za potrebe digitalne kartografije. Možno jih je navezati na podatkovne nize različnih resorjev (GURS, 2008).

2.2 Vzdrževanje topografskih podatkov

Podatke v topografskih bazah moramo redno dopolnjevati in vzdrževati, po možnosti iz izvornih virov. Vzdrževanje teh podatkov je pomembna stalna naloga, ki je časovno in organizacijsko zahtevna, zanjo so potrebna tudi primerna finančna sredstva. Vzdrževanje se izvaja po ustaljenih postopkih s klasičnimi metodami, kjer usposobljeni strokovnjak ugotavlja spremembe v podatkih in nato te nove podatke z ustrežno opremo zajame. Masovni zajem in vzdrževanje prostorskih (topografskih, kartografskih) podatkov se v veliki meri izvaja s fotogrametričnimi metodami.

Vzdrževanje katastra stavb predpisujeta že omenjena Zakon o evidentiranju nepremičnin in Pravilnik o vpisih v kataster stavb, medtem ko program za vzdrževanje Državne topografske karte v merilu 1 : 5000 še ni izdelan.

2.2.1 Vzdrževanje katastra stavb

V nadaljevanju je podan povzetek Zakona o evidentiranju nepremičnin (2006), ki se nanaša na spremembe grafičnega dela katastra stavb. Vpis stavbe ali dela stavbe v kataster stavb se izvede na podlagi elaborata, ki ga izdela geodetsko podjetje ali podjetje, ki izdeluje projektno dokumentacijo, v skladu z zakonom, ki ureja graditev objektov. Elaborat se izdela tudi za spremembo podatkov katastra stavb. Spremembe v katastru stavb se lahko izvedejo tudi na podlagi sodnih postopkov ali po uradni dolžnosti geodetske uprave (če so podatki napačno vpisani zaradi napak v postopku evidentiranja).

Zahtevo za vpis stavbe v kataster stavb vloži investitor gradnje, lastnik parcele, na kateri stoji stavba ali je z njo povezana, imetnik stavbne pravice, lastnik stavbe ali dela stavbe ali upravnik stavbe. Investitor gradnje mora vložiti zahtevo za vpis stavbe v kataster stavb najpozneje v 30 dneh po izvedbi vseh zaključnih gradbenih del. Če se začne stavba uporabljati pred izvedbo vseh zaključnih gradbenih del, mora investitor gradnje vložiti zahtevo za vpis stavbe v kataster stavb ob začetku uporabe stavbe ali dela stavbe. Investitor gradnje mora vložiti zahtevo za vpis stavbe v kataster stavb pred prvo prijavo stalnega bivališča ali sedeža pravne osebe v stavbi. Če geodetska uprava ugotovi, da stavba ali deli stavbe kljub

izpolnjenim zgornjim pogojem ni evidentirana v katastru stavb, pozove investitorja gradnje, da v treh mesecih po prejemu poziva vloži zahtevo za vpis stavbe v kataster stavb.

Zahtevo za spremembo podatkov katastra stavb vloži lastnik stavbe ali dela stavbe, imetnik stavbne pravice ali upravnik stavbe najpozneje v 30 dneh po izvedenih spremembah. Če geodetska uprava ugotovi, da so na stavbi ali delu stavbe nastale spremembe, za katere bi lastnik stavbe ali dela stavbe, imetnik stavbne pravice ali upravnik stavbe moral vložiti zahtevo za spremembo podatkov katastra stavb, pa tega ni storil, pozove lastnika stavbe ali dela stavbe, imetnika stavbne pravice ali upravnika stavbe, da v treh mesecih vloži zahtevo za spremembo podatkov katastra stavb. Lega in oblika stavbe ali dela stavbe se spremenita, če se je spremenil tloris stavbe, višina stavbe ali število etaž v stavbi ali če se je spremenil tloris dela stavbe ali število etaž dela stavbe. Lega in oblika stavbe ali dela stavbe se lahko spremenita tudi, če se vpisani podatki katastra stavb, ki določajo lego in obliko stavbe ali dela stavbe, določijo z večjo natančnostjo. Površina stavbe ali dela stavbe se spremeni, če se je spremenila oblika stavbe ali dela stavbe ali, če se je površina, vpisana v kataster stavb, določila z večjo natančnostjo. Če se na stavbi, ki je vpisana v katastru stavb, zgradi en ali več novih delov stavb, se ti deli vpišejo v kataster stavb po postopku, ki je določen za vpis delov stavbe v kataster stavb ob vpisu stavbe v kataster stavb.

Če se stavba poruši oziroma odstrani, se izbriše iz katastra stavb. Če je njen del fizično odstranjen, se ta del izbriše iz katastra stavb. Izbris stavbe ali dela stavbe se opravi na zahtevo lastnika parcele, na kateri je stala stavba, lastnika stavbe ali dela stavbe, državnega organa, lokalne skupnosti ali po uradni dolžnosti.

Vsebino in sestavine elaborata za vpis stavbe v kataster stavb, elaborata spremembe podatkov katastra stavb, elaborata za evidentiranje stavbe in elaborata za evidentiranje sprememb v katastru stavb na podlagi pravnomočne sodne odločbe ali sodne poravnave, podatke iz zbirke podatkov o upravnih aktih, ki se prevzamejo v kataster stavb kot gostujoči podatki, ter način njihovega vodenja v katastru stavb določa Pravilnik o vpisih v kataster stavb (2007).

3 SLIKOVNI IN DRUGI PODATKOVNI VIRI ZA VZDRŽEVANJE DRŽAVNIH TOPOGRAFSKIH BAZ

V Operativnem navodilu za zajem podatkov o stavbah (GURS, 2001) je navedena zahtevana položajna natančnost za zajem stavb 50 cm. Glede na zahtevano natančnost bomo zato za vzdrževanje državnih topografskih baz izbrali visokoločljive slikovne vire s prostorsko ločljivostjo 1 m ali boljšo. S prostorsko ločljivostjo 1 m ne moremo vedno zadostiti pogoju o položajni natančnosti 50 cm v geometričnem smislu, tovrstni posnetki pa omogočajo ugotavljanje sprememb v topografskih bazah (v atributnem smislu je možno ugotoviti, ali piksel pripada stavbi ali ne). V Sloveniji predstavljajo osnovni slikovni vir podatki Cikličnega aerosnemanja Slovenije (CAS) in iz njih izdelani barvni ortofoti s prostorsko ločljivostjo 0,5 m (DOF050) ali 0,25 m (DOF025) ter bližnje infrardeči barvni ortofoti z ločljivostjo 1 m (DOF100IR). Obstoječe slikovne vire lahko dopolnimo z visokoločljivimi satelitskimi posnetki. Sateliti GeoEye-1, IKONOS, KOMPSAT-2 in QuickBird nudijo pankromatske posnetke z velikostjo piksla 1 m ali manj, poleg tega pa zajemajo površino Zemlje še z multispektralnimi posnetki. Slednji imajo običajno štirikrat slabšo prostorsko ločljivost, ki jo lahko z metodami ostrenja (angl. pan-sharpening) izboljšamo na raven pankromatskih posnetkov. Multispektralni posnetki v veliki meri pripomorejo k boljši interpretaciji podob, pomembni pa so tudi v metodah prepoznavanja objektov (npr. ločevanje vegetacije od drugih vrst rabe). Poleg naštetih je do dne 4.3.2007 deloval satelit Orbview-3, ki je imel zelo podobne lastnosti kot IKONOS, a je prišlo do napak v delovanju senzorja. Podjetje Digital Globe je 8.10.2009 izstrelilo satelit WorldView-2 s prostorsko ločljivostjo 0,46 m za pankromatske in 1,84 m za multispektralne posnetke, podjetje ImageSat pa namerava v letu 2010 izstreliti satelit EROS-C s prostorsko ločljivostjo 0,7 m za pankromatske in 2,8 m za multispektralne posnetke. V nadaljevanju so predstavljene osnovne značilnosti glavnih slikovnih virov za vzdrževanje državnih topografskih baz.

3.1 Ciklično aerosnemanje

Ciklično aerosnemanje (CAS) v merilu 1 : 17.500 v Sloveniji izvajamo od leta 1975. Do leta 2005 so bile letalske fotografije posnete z analognim fotogrametričnim aerofotoaparatom v črnobeli ali barvni tehniki. Od leta 2006 se CAS izvaja z digitalnim fotogrametričnim aerofotoaparatom, posnetki pa imajo prostorsko ločljivost med 0,25 m in 0,5 m. Cikel aerosnemanja se izvaja v obdobju dveh do štirih let za celotno ozemlje Slovenije. Podatki CAS se uporabljajo za prostorski zajem podatkov v državne topografske baze, izdelavo ortofotov in reambulacijo kart. Posnetki CAS zajemajo celotni vidni spekter elektromagnetnega valovanja. Z digitalnim fotoaparatom se snemanje izvaja tudi v bližnjem infrardečem delu spektra. Posnetki so transformirani v državni koordinatni sistem s planimetrično natančnostjo 30 cm in višinsko natančnostjo 40 cm. Skupaj s pripadajočimi orientacijskimi parametri jih lahko pridobimo na Geodetski upravi Republike Slovenije v formatu TIFF (GURS, 2008). Radiometrična ločljivost posnetkov je 24 bitov (8 bitov posamezno za rdeč, moder in zelen podatkovni sloj).

3.2 Državni ortofoto

Državni ortofoti so izdelani iz aeroposnetkov. Med izdelavo je aeroposnetek z upoštevanjem centralne projekcije posnetka in digitalnega modela reliefa (DMR) transformiran (razpačen) v državni koordinatni sistem. Izdelek je v metričnem smislu enak linijskemu načrtu ali karti. V Sloveniji imamo izdelane barvne ortofote s prostorsko ločljivostjo 0,5 m (DOF050), bližnje infrardeče barvne ortofote z ločljivostjo 1 m (DOF100IR) in 491 listov barvnih ortofotov z ločljivostjo 0,25 m (DOF025). Uporabljamo jih kot podlago za prikaz različnih prostorskih informacij, kot osnovo za pridobivanje izpeljanih podatkov in za prostorske analize (GURS, 2008).

Ortofoti DOF050 so izdelani iz barvnih aeroposnetkov CAS in posnetkov posebnega aerosnemanja (PAS) z velikostjo piksla na tleh med 0,25 m in 0,5 m. Rektifikacija posnetkov je bila izvedena na podlagi digitalnega modela višin z gostoto 5 m x 5 m (DMV050). Izdelani so za celotno Slovenijo in razrezani na območja, ki ustrezajo velikosti listov (TTN 5).

Velikost piksla znaša 0,5 m. Podatki so georeferencirani v državnem koordinatnem sistemu s položajno natančnostjo enega metra. Radiometrična ločljivost je 24-bitna (8 bitov posamezno za rdeč, moder in zelen podatkovni sloj). Podatke lahko pridobimo na Geodetski upravi Republike Slovenije (GURS) v georeferenciranem formatu TIFF ali MrSID za območje enega lista TTN 5, državne topografske karte v merilu 1 : 25.000 (DTK 25) ali letalskega posnetka.

Ortofoti DOF025 so izdelani iz barvnih aerosposnetkov CAS in posnetkov posebnega aerosnemanja (PAS) z velikostjo piksla na tleh 0,25 m. Rektifikacija posnetkov je bila izvedena na podlagi DMV050. Izdelani so za 25 % celotnega ozemlja Slovenije (491 listov TTN 5). Velikost piksla znaša 0,25 m. Podatki so georeferencirani v državnem koordinatnem sistemu s položajno natančnostjo 1 m. Radiometrična ločljivost je 24-bitna (8 bitov posamezno za rdeč, moder in zelen podatkovni sloj). Podatke lahko pridobimo na GURS v georeferenciranem formatu TIFF ali MrSID za območje enega lista TTN 5.

Podatki za izdelavo DOF100IR so bili zajeti v letu 2006 z digitalnim fotogrametričnim aerofotoaparatom. Prostorska ločljivost infrardečih ortofotov, ki so izdelani za območja listov TTN 5, je 1 m. 24-bitne podobe dobimo na GURS v georeferenciranem formatu TIFF ali MrSID za območje enega lista TTN 5.

3.3 Satelitski posnetki

Za vzdrževanje državnih topografskih baz bomo uporabili posnetke s satelitov, ki zagotavljajo prostorsko ločljivost enega metra ali boljšo v pankromatskem kanalu in snemajo površino Zemlje tudi z multispektralnimi kanali. Preglednica 1 prikazuje tiste satelite in njihove značilnosti, ki ustrezajo navedenim pogojem (Lemmens, 2008, GeoEye, 2008, Digital Globe, 2008, Spot Image, 2008).

Prednost navedenih satelitskih posnetkov pred letalskimi posnetki ali ortofotom je v boljši radiometrični ločljivosti, ki je v vseh kanalih višja od osmih bitov. Več sivin omogoča boljše prepoznavanje objektov, ki so v senci ali v zasneženih območjih, in daje boljše možnosti za vizualno izboljšavo podob.

Preglednica 1: Lastnosti satelitov, primernih za vzdrževanje državnih topografskih baz.

Table 1: Adequate satellites for maintenance of topographic databases.

Podjetje Satelit	Digital Globe QuickBird	GeoEye GeoEye-1	GeoEye IKONOS	KARI KOMPSAT-2
Datum 1. izstrelitve	18.10.2001	6.9.2008	24.9.1999	28.7.2006
Število satelitov/operativni	1	1	3 / 2	1
Višina [km]	450	681	681	685
Naklon [°]	98	-	98,1	98,13
Lokalni čas preleta	10:30	10:30	10:30	10:50
Ponovno snemanje	3-7 dni; odvisno od φ pri ločljivosti 0,61 m	3 dni pri ločljivosti 0,5 m	3 dni pri ločljivosti 1 m	28 dni
Radiometrična ločljivost	11 bitov	11 bitov	11 bitov	10 bitov
Pankromatski kanal	0,445-0,9 μm	0,450-0,800 μm	0,526-0,929 μm	0,50-0,90 μm
Multispektralni kanali	M 0,45-0,52 μm Z 0,52-0,6 μm R 0,63-0,69 μm bl. IR 0,76-0,9 μm	M 0,445-0,516 μm Z 0,506-0,595 μm R 0,632-0,698 μm bl. IR 0,757-0,853 μm	M 0,445-0,516 μm Z 0,506-0,595 μm R 0,632-0,698 μm bl. IR 0,757-0,853 μm	M 0,45-0,52 μm Z 0,52-0,60 μm R 0,63-0,69 μm bl. IR 0,76-0,90 μm
Prostorska ločljivost pan	0,61 m v nadirju	0,50 m / 0,41 m v nadirju	1 m / 0,82 m v nadirju	1 m
Prostorska ločljivost MS	2,4 m v nadirju	1,65 m v nadirju	4 m / 3,2 m v nadirju	4 m
Širina pasu v nadirju	16,5 km	15,2 km	11,3 km	15 km
Velikost posnetkov	16,5 km x 16,5 km pasovi 16,5 km x 115 km	-	11 km x 11 km pasovi 11 km x 1000 km	15 km x 15 km
Stereo posnetki	da	-	da	da
Format datotek	GeoTIFF 1.0 NITF 2.0/2.1	-	GeoTIFF, NITF, DEM, DTED	GeoTIFF in datoteka RPC

3.3.1 IKONOS in GeoEye-1

Lastnik satelitov IKONOS in GeoEye-1 je podjetje GeoEye. IKONOS je prvi, GeoEye-1 pa eden zadnjih izstreljenih visokoločljivih civilnih satelitov za opazovanje zemeljskega površja. Preglednica 1 opisuje splošne značilnosti obeh satelitov. Podjetje GeoEye razvršča njihove posnetke glede na prostorsko ločljivost (0,5 m in 1 m) in položajno točnost v razrede Geo, GeoProfessional in Precision za mono posnetke ter GeoStereo in Precision za stereo posnetke.

Preglednica 2 podaja deklarirane položajne točnosti (skladnost položaja objektov na posnetkih glede na njihov pravilen položaj na zemeljski površini) in predlagane primere uporabe posnetkov satelita IKONOS (GeoEye, 2008).

Preglednica 2: Deklarirana položajna točnost in primeri uporabe posnetkov IKONOS.

Table 2: Declared positional accuracy and sample application for IKONOS imagery.

1 m mono	CE90	RMSE	Ortofoto	Mozaik	Uporaba
Geo	15 m	8 m	ne	ne	vizualna interpretacija in prepoznavanje sprememb
GeoProfessional	10 m	5 m	da	da	kartiranje velikih območij, uporaba v GIS, raba tal, analize ekonomskega razvoja
Precision	4 m	2 m	da	da	uporaba v urbanih območjih
PrecisionPlus	2 m	1 m	da	da	urbane analize, zemljiški kataster in kataster komunalnih naprav.
1 m stereo	CE90	RMSE	Ortofoto	Mozaik	Uporaba
GeoStereo	15 m	22 m	ne	ne	izdelava DMV poplavljenih območij, urbanistično planiranje, ekonomski razvoj
Precision	4 m	6 m	ne	ne	izdelava DMV poplavljenih območij, urbanistično planiranje

Preglednica 3 podaja deklarirane položajne točnosti in predlagane primere uporabe posnetkov satelita GeoEye-1 (GeoEye, 2008).

Preglednica 3: Deklarirana položajna točnost in primeri uporabe posnetkov GeoEye-1.

Table 3: Declared positional accuracy and sample application for GeoEye-1 imagery.

0,5 m mono	CE90	RMSE	Ortofoto	Mozaik	Uporaba
Geo	5 m	3 m	ne	ne	vizualna interpretacija in prepoznavanje sprememb, nadzor, sledenje prebivalcev
GeoProfessional	10 m	5 m	da	da	kartiranje velikih območij, uporaba v GIS, raba tal, nepremičnine, zavarovalništvo
Precision	4 m	2 m	da	da	uporaba v urbanih območjih
PrecisionPlus	2 m	1 m	da	da	urbane analize, zemljiški kataster in kataster komunalnih naprav.
0,5 m stereo	CE90	RMSE	Ortofoto	Mozaik	Uporaba
GeoStereo	4 m	6 m	ne	ne	izdelava DMV poplavljenih območij, inženirske ocene
Precision	4 m	3 m	ne	ne	izdelava DMV poplavljenih območij, inženirske ocene

CE90 pomeni, da navedeni točnosti ustreza 90 % objektov na posnetkih. RMSE je srednji pogrešek položaja točk na posnetkih. Za doseganje navedenih točnosti v razredih Precision je treba uporabiti oslonilne točke in DMV.

Iz posnetkov razreda Geo so odpravljeni radiometrični pogreški. Posnetke lahko naročimo skupaj s koeficienti RPC (angl. Rational Polynomial Coefficient RPC), ki opisujejo geometrijski model sensorja in omogočajo blokovno izravnavo snopov z uporabo oslonilnih točk, izdelavo ortofota na podlagi DMV ter ostale fotogrametrične operacije. Izdelki GeoProfessional so rektificirani, njihova položajna točnost je še izboljšana v inačicah Precision in PrecisionPlus. Posnetki GeoStereo so namenjeni za vse vrste fotogrametričnih aplikacij. Tudi za njih je na voljo model sensorja RPC. V vseh razredih lahko kupimo pankromatske, multispektralne in izostrene multispektralne podobe z metodo pan-sharpening. V praksi se je izkazalo, da je treba za naloge, ki zahtevajo visoko položajno točnost, satelitske posnetke dodatno izboljšati. V nadaljevanju sta podani geometrična in radiometrična analiza posnetkov s satelitov IKONOS in GeoEye-1.

3.3.1.1 Geometrična kakovost posnetkov IKONOS

Posnetki Precision in Precision Plus, ki nudijo najvišjo metrično natančnost in točnost, so občutno dražji od posnetkov nižje natančnosti (Triglav, 2002). Za natančno georeferenciranje posnetkov moramo ponudniku posnetkov dostaviti DMV in podatke o oslonilnih točkah. S temi podatki lahko georeferenciranje zanesljivo opravimo tudi sami. Večina raziskav je zato usmerjena v uporabo različnih metod za georeferenciranje posnetkov Geo, s ciljem doseganja točnosti iz razredov Precision. Za fotogrametrično oceno metrične natančnosti posnetkov moramo poznati podatke o notranji in zunanji orientaciji sensorja. Podjetje GeoEye ne objavlja podatkov o geometriji sensorjev svojih satelitov niti ne podatkov o preciznih efemeridah. Za oceno metrične natančnosti moramo uporabiti alternativne metode kot je model sensorja RPC ali metode, kjer orientacijo sensorja modeliramo z uporabo oslonilnih točk (podobnostna transformacija, afina transformacija, projektivna transformacija, direktna linearna transformacija DLT). Obsežno geometrično analizo posnetkov IKONOS za 2D in 3D georeferenciranje ter analizo primernosti za iskanje stavb so izvedli na testnem polju v

Melbournu, Avstralija. Analizirali so pankromatske in izostrene multispektralne podobe stereopara in nadirnega posnetka IKONOS Geo. Rezultate so predstavili Baltsavias in sod. (2001), Fraser in sod. (2001a in 2001b) ter Hanley in Fraser (2001). Podobne analize so izvajali tudi drugi avtorji (Büyüksalih in sod., 2003, Eisenbeiss in sod., 2004, Wang in sod., 2005, in številni drugi). Tudi na posnetkih z območja Slovenije je že bila izvedena analiza georeferenciranja posnetkov IKONOS razreda Geo z DLT (Triglav, 2002).

Pred prodajo so posnetki IKONOS geometrično popravljani in umeščeni na ploskev referenčnega elipsoida. Prav tako je izvedena kubična konvolucija na velikost piksla 1 m za pankromatski oziroma 4 m za multispektralne kanale. Stereopari so prevzorčeni v skladu z zahtevami epipolarne geometrije. Na tovrstnih posnetkih lahko preverimo položajno točnost ter linearnost senzorja z različnimi ravninskimi transformacijami (podobnostna – 4 parametri, afina – 6 parametrov, projektivna – 8 parametrov; opis v poglavju 4), ki slikajo iz slikovnega prostora v projekcijsko ravnino, kjer imamo podane koordinate oslonilnih točk, prav tako reducirane v ravnino projekcije. V primeru opisanih testiranj odstopanja na vseh oslonilnih točkah po izvedeni transformaciji niso presegala enega piksla (1 m v objektnem prostoru). Položajni srednji pogreški so znašali 0,4 m v primeru stereoparov Geo, za nadirni posnetek pa so komaj presegli 0,3 m. Pri tem uporaba transformacije višjega reda (več parametrov) ni bistveno vplivala na rezultate (Fraser in sod., 2001b). Hanley in Fraser (2001) sta vse omenjene transformacije izvedla tudi z uporabo le šestih oslonilnih točk. Položajni srednji pogrešek na petindvajsetih kontrolnih točkah razporejenih po celotnem posnetku še vedno ni presegel 0,5 m. Rezultati kažejo na metrično popolnost posnetkov IKONOS Geo. Z njimi lahko kljub nominalni točnosti 8 m (Preglednica 2), ki je v času izvedenih testiranj, ko je bilo lastnik satelita še podjetje Space Imaging, znašala 24 m za posnetke Geo, dosežemo položajno točnost 0,5 m (oziroma 0,5 piksla).

Za analizo kakovosti prostorskih koordinat, pridobljenih iz posnetkov IKONOS, moramo obravnavati dva ali več posnetkov istega območja. Matematični modeli, ki to omogočajo, so model senzorja RPC, DLT in afina projekcija (opis v poglavju 4). Fraser in sod. (2001a in 2001b) so vse navedene modele preskusili na testnem polju v Melbournu. Z uporabo modela senzorja RPC so standardni odkloni relativne orientacije modela v posameznih smereh koordinatnega sistema znašali 0,50 m v smeri vzhod-zahod, 0,45 m v smeri sever-jug in

0,78 m po višini. Rezultati absolutne orientacije so bili zaradi sistematičnih vplivov precej slabši: 8,2 m, 31,5 m in 1,7 m za posamezne smeri. Sistematične vplive so odstranili s translacijo, izračunano iz oslonilnih točk. Položajni srednji pogrešek absolutno orientiranega modela je po popravi dosegel 0,5 m, višinski pa 0,8 m. Meritve so izvedli na stereoparu Geo, narejenim z iste tirnice.

Analizo posnetkov z razširjenim modelom DLT so opravili z različnimi razporeditvami šestih oziroma osmih oslonilnih točk, rezultate pa so preverili na dvajsetih kontrolnih točkah. Položajni srednji pogrešek, izračunan iz odstopanj na kontrolnih točkah, je znašal 0,63 m pri uporabi šestih oziroma 0,45 m pri uporabi osmih oslonilnih točk, višinski pa 0,91 m oziroma 0,85 m. Z vključitvijo tretjega (nadirnega) posnetka se je točnost še izboljšala na približno 0,30 m po planimetriji in 0,55 m po višini. Rezultati z uporabo standardnega modela DLT z enajstimi parametri so bili podobni, kar je privedlo do sklepa, da lahko za manjša območja (do 50 km²), razširitveni parameter L_{12} zanemarimo (Fraser in sod., 2001b).

Orientiranje posnetkov z afino projekcijo je prineslo še boljše rezultate tako pri obravnavi stereopara kot vseh treh posnetkov. Pri različnih konfiguracijah oslonilnih točk so pri uporabi treh posnetkov odstopanja na kontrolnih točkah znašala okoli 0,3 m po položaju in pod 0,5 m po višini. Testno polje je bilo relativno ravno (višinski razpon do 50 m). Podobne rezultate so zato dobili tudi brez predhodne transformacije iz perspektivne projekcije v afino projekcijo.

Z opisanimi testiranjmi so spoznali, da lahko visoko točnost merjenja točk (pogreški pod velikostjo piksla) dosežemo z uporabo osnovnih in cenejših posnetkov IKONOS Geo in to z relativno enostavnimi metodami, ki zahtevajo le manjše število kakovostnih oslonilnih točk. Testiranja so bila sicer izvedena z merjenjem posameznih, dobro opredeljenih točk. V nadaljnjih raziskavah so potrdili, da lahko položajno točnost 1 m dosežemo tudi pri merjenju slabše opredeljenih točk, ki se na primer pojavljajo pri zajemu objektov. Odstopanja koordinat vogalov streh, pridobljenih z meritvami GPS in meritvami na posnetkih pri izračunih z vsemi opisanimi metodami niso presegala enega metra. Meritve so izvajali na vseh treh posnetkih območja (stereopar in nadirni posnetek). Kljub temu pa pri zajemu stavb s stereoparom IKONOS Geo veliko točk ni mogoče natančno izmeriti. V veliko primerih lahko zajamemo le generalizirano obliko stavb. Razlog za slabšo prepoznavnost objektov so sence, mrtvi koti,

slabo opredeljeni robovi (posledica šuma in umetnih tvorb), nasičenost svetlih površin, višinski kot Sonca in senzorja, atmosferski pogoji v trenutku snemanja. Razlogi so opisani v naslednjem poglavju. Primerjava zajetih stavb na podobah IKONOS s stavbami, zajetimi na stereoparu aeroposnetkov, je pokazala, da okoli 15 % stavb na podobah IKONOS ne moremo zajeti (Baltsavias in sod., 2001; Fraser in sod., 2001a).


3.3.1.2 Radiometrična kakovost posnetkov IKONOS

Radiometrično kakovost posnetkov IKONOS in njihovo primernost za iskanje stavb je raziskovalo več avtorjev (Gerlach, 2000, Baltsavias in sod., 2001, Eisenbeiss in sod., 2004, in številni drugi). Izsledke raziskav predstavljamo v nadaljevanju. Nekatere metode, s katerimi lahko posnetke izboljšamo, so opisane v poglavju 4.

IKONOS uporablja vzdolžni skener, ki snema Zemljo z zaporedji vrstic, pravokotnih na smer gibanja satelita. Čakalni čas za registracijo enega piksla je zaradi hitrosti letenja zelo kratek. V senzor je zato vgrajena tehnologija TDI (angl. Time Delay and Integration), ki eno vrstico podobe dejansko izračuna iz več snemalnih vrstic oziroma stopenj. IKONOS uporablja 13 stopenj TDI, kar ojači signal, a ga obenem tudi zgladi in poveča možnost nasičenja svetlih objektov. Ostrenje signala odpravljajo v fazi predobdelave podob v sprejemnem centru z uporabo tako imenovanega postopka MTFC (angl. Modulation Transfer Function Compensation). Podobe so zaradi MTFC vizualno ostrejše, a imajo obenem slabši kontrast in razne umetne tvorbe, opazne predvsem v smeri vzporedni s senzorjem (slika 1). Posledica so slabše opredeljivi robovi objektov, kadar izvajamo samodejne meritve. Naslednja faza predobdelave je uravnavanje dinamičnega razpona DRA (angl. Dynamic Range Adjustment), v kateri z raztegom sivin vizualno popravijo podobe, a se pri tem izgubi absolutna točnost podatkov (postopek izvajajo le za pankromatske podobe). Pri naročanju sicer lahko zahtevamo podobe, ki niso obdelane z DRA. Radiometrična ločljivost sistema IKONOS je 11 bitov, kar pomeni, da lahko loči 2048 vrednosti v vsakem kanalu. Dejanski dinamični razpon podob IKONOS je običajno le nekje med 8 in 9 bitov (Eisenbeiss in sod., 2004). Stopnja šuma je dokaj visoka. Izrazit šum je opazen še posebej po izboljšanju kontrasta, ki ga moramo v večini primerov popraviti pred samodejnim iskanjem stavb. Šum je na multispektralnih

podobah zaradi večjih pikslov manjši, v postopku pan-sharpeninga pa naraste, saj se njegove vrednosti prenesejo s pankromatskih podob.

Poleg šuma postanejo z izboljšanjem kontrasta očitnejše tudi umetne tvorbe: šum v obliki šahovnice; temne in svetle linije v smeri letenja, ki so posledica nepopolne kalibracije senzorja; nasičenje, ki nastane zaradi močnega odboja in razlivanja visokih vrednosti signala v sosednje vrstice v smeri leta. Na stereoparih lahko opazimo pasove in stopničaste spremembe sivin na homogenih območjih, kar je posledica epipolarnega prevzorčenja stereoparov, ter skoke sivin v smeri leta. Z ostrenjem multispektralnih podob s pankromatskimi se pojavijo »duhovi« premikajočih objektov, ki nastanejo zaradi polsekundne zakasnitve snemanja z multispektralnimi kanali. Detajli se izgubljajo tudi zaradi senc in nasičenosti, ki se pogosto pojavlja zaradi osvetljenih vertikalnih svetlih zidov. V veliko primerih uporabniki ne moremo vplivati na radiometrično kakovost in primernost podob IKONOS za zajem stavb. Ti primeri so snemalni kot senzorja, višinski kot Sonca in sence, atmosferski pogoji, letni čas snemanja.



Slika 1: Nasičenje in učinek MTFC na pankromatski podobi IKONOS Geo.

Figure 1: Saturation and MTFC effect in IKONOS Geo panchromatic image.

Slika 1 prikazuje dva primera nasičenja na podobi IKONOS Geo z območja Krškega. Na sliki je lepo viden učinek ostrenja z uporabo metode MTFC (črn obris spodnjega roba nasičene površine). Izrez iz podobe je dvakrat povečan in vizualno izboljššan z linearnim raztegom histograma z nasičenjem (2 % na obeh straneh histograma).

3.3.1.3 Geometrična kakovost posnetkov GeoEye-1

Satelit GeoEye-1 je bil izstreljen septembra 2008, njegove podobe pa lahko naročamo od februarja 2009. Trenutno ponuja najboljšo prostorsko ločljivost med sateliti, namenjenimi komercialni uporabi (0,41 m za pankromatski in 1,65 m za multispektralne kanale). Za končnega uporabnika lastnik satelita podobe prevzorči na prostorsko ločljivost 0,5 m oziroma 2 m. Zaradi kratkega časa obratovanja satelita GeoEye-1 še ni bilo izvedenih veliko analiz njegove geometrične kakovosti. Eno redkih obsežnejših analiz sta predstavila Fraser in Ravanbakhsh (2009). Stereopar GeoEye-1 je bil testiran na testnem polju v Avstraliji. Gre za isto testno polje, ki so ga uporabili za analizo posnetkov IKONOS. Končni rezultat testiranja je bil zelo dober. Položajna točnost georeferenciranih posnetkov je znašala 0,10 m, višinska pa 0,25 m ob uporabi ene same oslonilne točke. Orientacija stereopara je bila vzpostavljena z modelom sensorja RPC. Za odpravo sistematičnih vplivov v modelu sensorja RPC so v izravnavo dodali parametra, ki sta podala translacijo relativno orientiranega modela.

3.3.2 QuickBird

Preglednica 1 podaja splošne podatke o satelitu QuickBird. Pri lastniku satelita, podjetju Digital Globe, lahko naročimo posnetke, ki imajo deklarirane različne položajne točnosti (preglednica 4, Digital Globe, 2008).

Iz vseh posnetkov že v sprejemnih centrih odstranijo geometrično in optično distorzijo sensorja ter izvedejo radiometrične popravke. Podjetje Digital Globe objavlja podatke o snemalnem sistemu, zato so dostopni vsi parametri notranje orientacije, ki jih lahko uporabimo v večini komercialnih fotogrametričnih programov, kjer lahko izdelamo točnejše ortofote ali izvajamo prostorski zajem objektov. Zunanjo orientacijo lahko izračunamo iz podanega položaja satelita v trenutku snemanja. Vzpostavimo jo lahko tudi iz podanih koeficientov RPC. Naročamo lahko pankromatske in multispektralne podobe, s pankromatskimi posnetki izostrene multispektralne podobe so na voljo le za razreda Standard in Orthorectified. Pankromatske podobe imajo prostorsko ločljivost med 61 cm in 72 cm, odvisno od kota snemanja (odstopanje od nadirja 0° - 25°), odgovarjajoča prostorska ločljivost multispektralnih podob je med 2,44 m in 2,88 m.

Preglednica 4: Deklarirana položajna točnost in primeri uporabe posnetkov QuickBird.

Table 4: Declared positional accuracy and sample application for QuickBird imagery.

	CE90	RMSE	Ortofoto	Mozaik	Uporaba
Basic	23 m	14 m	ne	ne	vizualna interpretacija, prepoznavanje sprememb
Standard	23 m	14 m	da	ne	vizualna interpretacija, prepoznavanje sprememb, osnova za izdelavo ortofota
Orthorectified	25,4 m 10,2 m* 4,23 m 4,06 m*	15,4 m 6,2 m* 2,6 m 2,5 m*	da	da	razne analize, interpretacija, prepoznavanje sprememb, klasifikacija
Basic Stereo Pair	6,5 m	-	ne	ne	izdelava DMV, prostorske upodobitve, zajem objektov

* le za območje ZDA in Kanade

CE90 pomeni, da navedeni točnosti ustreza 90 % objektov na posnetkih. RMSE je srednji pogrešek položaja točk na posnetkih.

3.3.2.1 Geometrična kakovost posnetkov QuickBird

Posnetki Basic vsebujejo najmanj predobdelav s strani ponudnika in so zato najcenejši, vendar omogočajo uporabniku, da z naknadno obdelavo izdelava geometrično najbolj natančne izdelke. Posnetki Standard in Orthorectified že vsebuje topografske popravke, izračunane iz DMV. Poleg višje cene je njihova slabost tudi v tem, da zaradi predhodne obdelave njihove geometrične točnosti ne moremo bistveno izboljšati. Za fotogrametrične uporabnike so zanimivi še posnetki Ortho Ready Standard, nekakšen podrazred posnetkov Standard, ki še ne vsebujejo topografskih popravkov in omogočajo uporabniku kakovostnejše georeferenciranje. Za slednje lahko kupimo le izrez iz celotne scene, kar je včasih bolj ekonomično od nakupa posnetkov Basic.

Za natančno georeferenciranje posnetkov QuickBird se največ uporablja model senzorja RPC in strogi fizični 3D model. Georeferenciranje z modelom senzorja RPC opravimo na

podlagi koeficientov RPC, ki jih dobimo skupaj s posnetki. Strogi 3D modeli temeljijo na fotogrametričnih kolinearnih enačbah in opisujejo natančen položaj sensorja med snemanjem. Rešujemo jih z blokovno izravnavo snopov, v kateri pridobimo podatke o notranji in zunanji orientaciji sensorja. Vzpostavitev strogih 3D modelov omogočajo metapodatki o položaju in geometriji sensorja, ki jih skupaj s posnetki Basic dostavlja podjetje Digital Globe.

Rezultate analize geometrične natančnosti in točnosti QuickBirdovih posnetkov Basic je predstavil Robertson (2003). V prvem testu je primerjal natančnost in točnost obeh metod. Izkazalo se je, da so rezultati georeferenciranja z modelom sensorja RPC in strogim fizičnim 3D modelom zelo primerljivi (odstopanja znotraj velikosti enega piksla). Z obema metodama je bila dosežena deklarirana točnost georeferenciranja posnetkov, ki jo za posnetke Basic podaja podjetje Digital Globe. Točnost georeferenciranja izboljšamo z uporabo oslonilnih točk. Robertson je obravnaval tri pasove, sestavljene posamezno iz treh, štirih in enega posnetka. Izmed 31 terenskih oslonilnih točk, je 6 točk uporabil kot oslonilne točke za georeferenciranje, 25 točk pa kot kontrolne točke za analizo točnosti georeferenciranja. Položajna odstopanja v izravnavi na oslonilnih točkah niso presegala enega metra, odstopanja na kontrolnih točkah pa so po posameznih koordinatnih oseh znašala 2,08 m po osi X in 1,33 m po osi Y pri uporabljenem strogem fizičnem 3D modelu in 3,02 m oziroma 0,98 m pri uporabi modela sensorja RPC. Zelo podobne rezultate so objavili tudi drugi avtorji (Toutin, Cheng, 2002, Cheng in sod., 2003, Niu in sod. 2004, Crespi in sod., 2006 in številni drugi).

3.3.2.2 Radiometrična kakovost posnetkov QuickBird

Radiometrične lastnosti posnetkov QuickBird in IKONOS so zelo podobne. Oba sensorja uporabljata tehnologijo TDI. Čeprav v metapodatkih nikjer ne omenijo uporabo MTFC in DRA, ju v podjetju Digital Globe verjetno izvajajo na vseh podobah QuickBird (Eisenbeiss in sod., 2004). Za posnetke QuickBird torej veljajo vse ugotovitve, opisane v poglavju 3.3.1.2. Zaradi manjšega piksla je nasičenje in razlivanje vrstic v smeri leta na QuickBirdovih podobah izrazitejše.

3.4 Lidar

Poleg slikovnih podatkov predstavljajo pomemben vir, ki ga lahko uporabimo za vzdrževanje topografskih podatkov, tudi podatki o nadmorskih višinah točk na zemeljskem površju. Najbolj natančne višinske podatke ponuja lasersko skeniranje. Oblak točk, ki ga skupaj z atributnimi podatki pridobimo z laserskim skeniranjem, že sam omogoča razne metode za samodejni zajem stavb (npr. Dorninger, Pfeifer, 2008; Hofmann, Mass, Streilein, 2002; Pfeifer in sod., 2007; Rottensteiner in sod. 2005; Vosselman, Dijkman, 2001). V slovenskem prostoru je bila izdelana magistrska naloga (Švab Lenarčič, 2009), v kateri je avtorica za prepoznavanje stavb v oblaku točk uporabila standardni odklon višin v oblaku točk. V doktorski nalogi smo se primarno posvetili slikovnim virom in uporabljamo podatke laserskega skeniranja zgolj kot pomožni vir.

Instrument za lasersko skeniranje površin imenujemo lidar. Izraz lidar je okrajšava za Light Detection And Ranging oziroma svetlobno zaznavanje in merjenje razdalj ali Laser Imaging Detection And Ranging oziroma lasersko snemanje, zaznavanje in merjenje razdalj. Gre za tehnologijo, ki omogoča določanje razdalje do objektov ali površin z uporabo laserskih pulzov. Lidar je aktivni instrument, ki proti opazovanim predmetom pošilja kratke laserske pulze in opazuje njihov odboj. Pri tem pridobiva zelo natančne podatke o površju (Oštir, 2006).


Laserske skenerje razdelimo glede na mesto, s katerega zajemajo podatke na (Triglav Čekada, 2009):

- sisteme za zračno lasersko skeniranje (instrument je nameščen v letalo ali helikopter),
- sisteme za terestrično lasersko skeniranje.

Za zajem topografskih podatkov so primerni predvsem sistemi za zračno lasersko skeniranje. Laserski snemalni sistem sestavljajo laserski razdaljemer, optično mehanski skener, sistem pozicioniranja in krmilno procesna enota. Razdaljemer je sestavljen iz oddajnega laserja in sprejemnika signalov. Dva glavna načina delovanja sta diskretni in valovni način.

Diskretni lidar ali pulzni lidar oddaja kratke pulze elektromagnetnega valovanja in meri njihove odboje (vsaj enega, lahko tudi dva ali več). Nekateri sistemi so sposobni zabeležiti tudi intenzivnost odboja, kar omogoča ustvarjanje podobe odbojev. Diskretni lidar ima nekaj pomembnih prednosti, predvsem visoko prostorsko ločljivost ter možnost povečevanja gostote meritev. Sistemi, ki delujejo na ta način, so zelo razširjeni.

Valovni lidar ali zvezni lidar signal oddaja ves čas in meri odboj glede na fazni zamik med oddanim in sprejetim signalom. Glavna prednost valovnega lidarja v primerjavi z diskretnim je zmožnost beleženja vertikalnega profila predmetov, na katerih je prišlo do odboja. Največja pomanjkljivost valovnega lidarja je manjša prostorska ločljivost (Oštir, 2006).



Slika 2: Delovanje lidarja.

Figure 2: Lidar functioning.

Slika 2 prikazuje osnovni princip delovanja sistema za zračno lasersko skeniranje (Kraus, 2007). Skeniranje zemeljskega površja je izvedeno prečno na smer leta zrakoplova, na katerem je nameščen laserski snemalni sistem. Laserski skener prek nihajočih ali vrtečih se zrcal usmerja pulze laserske svetlobe proti zemeljskemu površju, od kjer se žarki (običajno difuzno) odbijejo in vrnejo v sprejemnik signalov. Razdaljo med laserskim skenerjem in točko

na zemeljskem površju, od katere se je žarek odbil, določimo na podlagi hitrosti širjenja valovanja laserskih žarkov in časa, ki preteče od oddaje do sprejema laserskega pulza. Razdalja in natančno izmerjen kot zrcala, ki je usmerilo laserski žarek, določata polarne koordinate točke na zemeljskem površju. Za pretvorbo polarnih koordinat točk v koordinate referenčnega koordinatnega sistema, moramo poznati položaj in orientacijo laserskega skenerja v trenutku oddaje laserskega pulza. Položaj in orientacijo beleži sistem pozicioniranja, ki ga sestavljata sprejemnik globalnih navigacijskih satelitskih sistemov (GNSS) in inercialni navigacijski sistem (INS) na zrakoplovu. Po snemanju podatke s sprejemnika GNSS na zrakoplovu in referenčne postaje GNSS obdelamo z metodo diferencialnega GNSS ali metodo kinematične relativne izmere GNSS. Rezultat laserskega snemanja in obdelave podatkov je oblak lidarskih točk. Točke v oblaku so zapisane s tremi prostorskimi koordinatami in praviloma več ostalimi atributi kot sta npr. red odboja in intenziteta odbitega laserskega žarka (Kraus, 2007; Petrie, Toth, 2009; Švab Lenarčič, 2009).

Osnovni podatek za zajem podatkov z zračnim laserskim skeniranjem je število točk, ki jih instrument registrira za kvadratni meter površine. Nizko ločljivo zračno lasersko skeniranje predstavljajo sistemi, ki zajamejo eno točko na m^2 . Sistemi srednje ločljivosti zajemajo 1 do 5 točk na m^2 in omogočajo izdelavo detajlnih digitalnih modelov višin (DMV). Visokoločljivo lasersko skeniranje, z več kot 5 točk na m^2 , omogoča izdelavo digitalnih modelov površja (DMP) mest, DMP cest in ostalih detajlov (Triglav Čekada, 2009).

4 IZBRANI POSTOPKI DIGITALNE OBDELAVE PODOB IN VIŠINSKIH PODATKOV

Podatki, ki jih zazna letalski ali satelitski senzor, vsebujejo nepravilnosti in pomanjkljivosti, ki jih želimo odstraniti pred nadaljnjo obdelavo. Veliko popravkov opravijo že v sprejemni postaji, precej pa jih mora opraviti vsak uporabnik sam. Ker gre pri tem za operacije, ki se izvajajo pred nadaljnjo obdelavo, to je izboljšanjem, analizo in interpretacijo, govorimo o predobdelavi podob. Vizualna analiza in interpretacija omogočata hitro pridobivanje osnovnih informacij o zemeljskem površju. Digitalne podobe omogočajo preprosto spreminjaje videza. Z izboljšanjem podob lahko ustvarimo prikaze, ki so prilagojeni določenemu namenu in interpretatorju (Oštir, 2006).

V tem poglavju je zbrana teoretična osnova postopkov, ki smo jih uporabili v izdelavi praktičnega dela doktorske naloge. V njem predstavljamo postopke predobdelave in izboljšanja podob, ki jih lahko smiselno izvajamo pred iskanjem stavb na podobah. Obe vrsti postopkov predstavljata pomemben korak, od uspešnosti njune izvedbe so v veliki meri odvisni tudi končni rezultati samodejnega iskanja stavb. K predobdelavi spada georeferenciranje, medtem ko predstavljajo metode za izboljšanje kontrasta in različna filtriranja postopke izboljšanja podob. Poglavju so dodani še ostali izbrani postopki digitalne obdelave podob, ki smo jih uporabili v izdelavi doktorske naloge (vektORIZACIJA, morfološke operacije, barvna segmentacija, rast regij). V poglavju opisujemo tudi združevanje podob z višinskimi podatki. Slednji predstavljajo pomemben dopolnilni vir v postopku iskanja stavb.

4.1 Georeferenciranje podob

Podobe, ustvarjene z daljinskim zaznavanjem, ne vsebujejo kartografske projekcije in nimajo določenega pravega merila. Vsebujejo geometrijske nepravilnosti, ki so posledica številnih dejavnikov, na primer optike senzorja, gibanja snemalnega sistema, gibanja in nestabilnosti platforme, višine, hitrosti in usmerjenosti platforme, oblike reliefa ter ukrivljenosti in vrtenja

Zemlje (Oštir, 2006). Če želimo podobe uporabljati za vzdrževanje topografskih baz, moramo najprej opraviti geometrijske popravke in jih transformirati v izbrani koordinatni sistem oziroma jih georeferencirati. Oba koraka lahko opravimo istočasno z vzpostavitvijo matematičnega odnosa med slikovnimi koordinatami na podobi in koordinatami ustreznih točk v kartografski projekciji (Richards, Jia, 2006). Od ponudnikov posnetkov lahko naročamo podobe, ki že vsebujejo določene geometrijske popravke (npr. vse podobe QuickBird so že popravljene za pogrešek geometrične in optične distorzije senzorja). Od vrste vnesenih popravkov je odvisna cena podob. Slednja še najbolj pride do izraza, kadar naročamo podobe, ki so georeferencirane z najvišjo položajno točnostjo. V splošnem je bolj ekonomičen nakup cenejših nereferenciranih podob ali podob, ki so v prostor postavljene z manjšo točnostjo. Njihovo položajno točnost nato izboljšamo sami z uporabo metod, opisanih v nadaljevanju. Razdelili jih bomo na metode, kjer obravnavamo le en posnetek za določevanje ravninskih koordinat x in y ter metode, pri katerih obdelujemo več podob istega območja za določevanje prostorskih koordinat x , y in z .

Eden od ciljev doktorske naloge je preverjanje položajne natančnosti in točnosti satelitskih posnetkov ter ocena primernosti njihove uporabe za obnavljanje topografskih baz. Pregled literature, opisan v 3.3.1.1, 3.3.1.3, 3.3.2.1, pove, da je doseganje metrske položajne natančnosti in točnosti pri georeferenciranju s podatki satelitov IKONOS, GeoEye-1 in QuickBird dosegljivo. Z enostavno uporabo nekaterih od spodaj navedenih metod, smo rezultate potrdili tudi v praksi. Zaključna analiza položajne točnosti satelitskih posnetkov je podana v 7.1.

4.1.1 Planimetrično georeferenciranje satelitskih podob

Podobe IKONOS in GeoEye-1 Geo so že postavljene v kartografsko projekcijo, vendar je njihov položajni pogrešek prevelik za njihovo uporabo v topografskih bazah. Podobno velja za podobe QuickBird Basic. Njihov položaj v projekcijski ravnini lahko izboljšamo s planimetričnim georeferenciranjem. Georeferenciranje opravimo na podlagi oslonilnih točk, ki jih povežemo s slikovnimi koordinatami z eno od matematičnih preslikav: podobnostno, afino in projektivno transformacijo ali z uporabo polinomov različnih stopenj. Položaju

slikovnih koordinat na podobi (u, v) tako pripišemo položaj v kartografski projekciji (x, y) (1) (Richards, Jia, 2006):

$$\begin{aligned}u &= f(x, y), \\v &= g(x, y).\end{aligned}\tag{1}$$

Podobnostna transformacija (2):

$$\begin{aligned}u &= a_0 + a_1x - b_1y, \\v &= b_0 + b_1x + a_1y.\end{aligned}\tag{2}$$

Enačbi afine transformacije obenem predstavljata tudi enačbe polinoma prve stopnje (3):

$$\begin{aligned}u &= a_0 + a_1x + a_2y, \\v &= b_0 + b_1x + b_2y.\end{aligned}\tag{3}$$

Projektivna transformacija (4):

$$\begin{aligned}u &= \frac{a_1x + a_2y + a_3}{c_1x + c_2y + 1}, \\v &= \frac{b_1x + b_2y + b_3}{c_1x + c_2y + 1}.\end{aligned}\tag{4}$$

Polinoma druge stopnje (5):

$$\begin{aligned}u &= a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2, \\v &= b_0 + b_1x + b_2y + b_3xy + b_4x^2 + b_5y^2.\end{aligned}\tag{5}$$

Uporabljamo lahko tudi polinome višjih stopenj, a je pri tem pomembno, da imamo oslonilne točke dobro razporejene po celotnem območju, ki ga obravnavamo. Pogreški izven območja oslonilnih točk sicer hitro naraščajo.

4.1.2 Prostorsko georeferenciranje satelitskih podob

Fotogrametrično pridobivanje prostorskih podatkov iz stereoparov ali več podob sloni na kolinearnem modelu, ki zahteva poznavanje notranje in zunanje orientacije senzorja. Lastniki satelita IKONOS ne objavljajo teh podatkov, zato je treba za obravnavo več podob istega območja uporabiti alternativne pristope. Prvi pristop je uporaba modela senzorja RPC, drugi pa združuje metode, kjer nepoznavanje orientacije senzorja nadomestimo z uporabo oslonilnih točk (razširjena direktna linearna transformacija DLT, afina projekcija).

4.1.2.1 Model senzorja RPC

Z modelom senzorja RPC (v uporabi je tudi izraz model racionalnih funkcij, angl. Rational Function Model RFM) slikovne koordinate (u, v) izrazimo kot neposredno funkcijo objektne koordinat (x, y, z) . Splošni model senzorja RPC lahko uporabimo tudi za georeferenciranje enega posnetka. Podan je kot (6):

$$\begin{aligned} u &= \frac{P_1(x, y, z)}{P_2(x, y, z)}, \\ v &= \frac{P_3(x, y, z)}{P_4(x, y, z)}, \end{aligned} \tag{6}$$

kjer imajo P_i v primeru polinomov tretje stopnje, ki jih običajno uporabljamo za georeferenciranje posnetkov, obliko (Fraser, Hanley, Yamakawa, 2001b):

$$\begin{aligned} P_i(x, y, z) &= a_{i1} + a_{i2}y + a_{i3}x + a_{i4}z + a_{i5}yx + a_{i6}yz + a_{i7}xz + a_{i8}y^2 + a_{i9}x^2 + a_{i10}z^2 \\ &+ a_{i11}xyz + a_{i12}y^3 + a_{i13}yx^2 + a_{i14}yz^2 + a_{i15}y^2x + a_{i16}x^3 + a_{i17}xz^2 \\ &+ a_{i18}y^2z + a_{i19}x^2z + a_{i20}z^3. \end{aligned}$$

a_{ij} predstavljajo koeficiente racionalnih polinomov in jih v angleški literaturi označuje kratica RPC (Rational Polynomial Coefficients). Polinomi P_i so običajno tretje stopnje, kar pomeni, da imamo za eno podobo 80 koeficientov. Slikovne koordinate (u, v) in objektne koordinate (x, y, z) v enačbi (6) so normalizirane. Normalizacijo dosežemo s translacijo in spremembo

merila. Normalizirane koordinate zavzemajo vrednosti na intervalu med -1 in 1, kar zagotavlja minimalizacijo pogreškov v izračunu koeficientov.

V primeru podob IKONOS Geo so koeficienti RPC pridobljeni na osnovi geometrijskega modela senzorja in njegovega položaja, ki je določen z meritvami GPS in opazovanjem položaja zvezd. Zunanja orientacija, pridobljena iz tovrstnih opazovanj, je podvržena številnim sistematičnim vplivom. Z modelom senzorja RPC dosežemo dobro relativno orientacijo podob, medtem ko je absolutna orientacija bistveno bolj podvržena sistematičnim vplivom. Točnost objektnih koordinat, izračunanih z modelom senzorja RPC, običajno znaša okoli 14 m (Niu in sod. 2004). Točnost obeh orientacij se poslabša, kadar opazujemo podobe, ki niso bile posnete z iste tirnice. Absolutno orientacijo lahko popravimo z uporabo oslonilnih točk. Slednje uporabimo za translacijo modela. Če je v sistematične vplive vključena rotacija, jo odpravimo s prostorsko podobnostno transformacijo.

Na temo izboljšanja georeferenciranja podob z uporabo modela senzorja RPC je bilo v zadnjih letih izvedenih veliko raziskav (Tao, Hu, 2001 in 2002, Di in sod., 2003, Fraser, Hanley, 2003, Grodecki, Dial, 2003, Wang in sod. 2005, in številni drugi). Avtorji so razvili dva pristopa za povečanje geometrične točnosti satelitskih podob. Prvi temelji na izboljšanju koeficientov RPC z uporabo velikega števila oslonilnih točk. Drugi pristop izboljšuje objektne koordinate, izračunane na podlagi modela senzorja RPC. Zanj ne potrebujemo velikega števila oslonilnih točk, poleg že omenjene translacije in podobnostne transformacije, so v uporabi še translacija s spremembo merila, afina transformacija in poprava koordinat s polinomi druge stopnje. Vse popravke lahko izvedemo tako v slikovnem kot objektnem prostoru.

4.1.2.2 Direktna linearna transformacija

Direktna linearna transformacija (DLT) temelji na linearnih projektivnih enačbah in je uporabna za orientacijo linijskih podob, zajetih s satelitskimi snemalnimi napravami. Wang (1999) je predlagal razširitev DLT z dodatnim parametrom L_{12} za popravo slikovnih koordinat (7):

$$u = \frac{L_1x + L_2y + L_3z + L_4}{L_9x + L_{10}y + L_{11}z + 1} + L_{12}xy, \quad (7)$$

$$v = \frac{L_5x + L_6y + L_7z + L_8}{L_9x + L_{10}y + L_{11}z + 1}.$$

Z enačbami (7) lahko izvedemo triangulacijo več podob brez poznavanja notranje in zunanje orientacije senzorja. Parametre L_i izračunamo naenkrat za vse posnetke v blokovni izravnavi snopov. Metoda je uporabna za obravnavo manjših območij. DLT lahko uporabimo tudi za georeferenciranje enega posnetka.

4.1.2.3 Afina projekcija

Namesto projektivnega modela lahko uporabimo afino projekcijo. Enačbe afine projekcije za prostorsko obravnavanje linijskih satelitskih podob imajo obliko (8) (Fraser, Hanley, Yamakawa, 2001b):

$$u = a_0 + a_1x + a_2y + a_3z, \quad (8)$$

$$v = b_0 + b_1x + b_2y + b_3z.$$

Model je uporaben za manjša in ravninska območja. V primeru obravnave večjih območij moramo pred uporabo enačb afine projekcije podobe iz perspektivne pretvoriti v afino projekcijo.

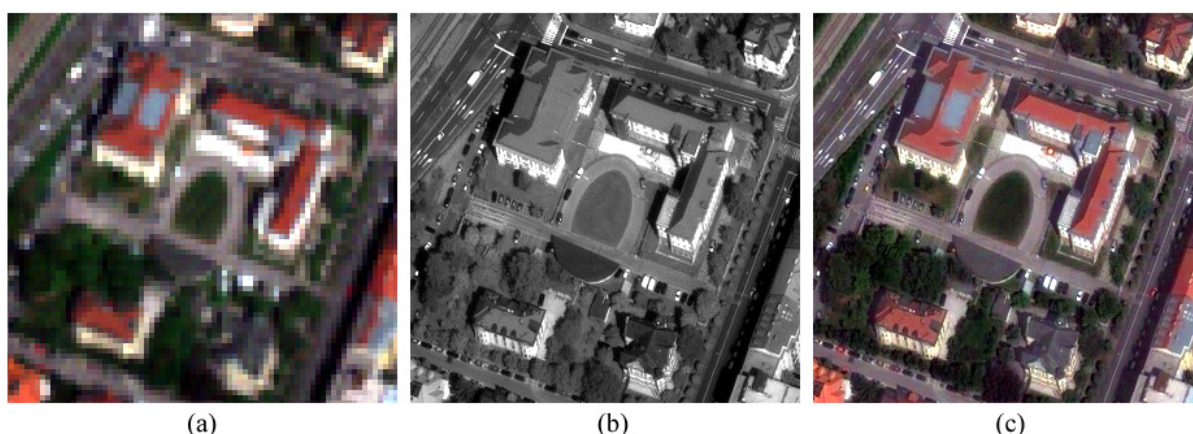
4.2 Ostrenje multispektralnih podob

Ostrenje multispektralnih podob je postopek, pri katerem z združitvijo nizkoločljivih multispektralnih podob z viskoločljivimi pankromatskimi podobami dobimo viskoločljive multispektralne podobe (angl. pan-sharpening).

Za ostrenje multispektralnih podob obstaja več tehnik (Zhang, 2008). V prvo skupino spadajo tehnike, ki temeljijo na pretvorbi barvnega prostora RGB, ki odtenke podaja z osnovnimi barvami (rdeča, zelena in modra) v barvni prostor HSI (barva, nasičenost, intenziteta). V

prostoru HSI nadomestimo kanal, ki podaja intenziteto, s pankromatsko podobo. Z obratno pretvorbo v barvni prostor RGB dobimo izostrene podobe. Podoben princip je uporabljen pri pretvorbi multispektralnih podob v osnovne komponente, kjer prvo komponento nadomestimo s pankromatsko podobo. Tretjo skupino tvorijo tehnike, ki temeljijo na aritmetičnih kombinacijah. V njo spada na primer Broveyeva transformacija, pri kateri vsako od treh multispektralnih podob pomnožimo s pankromatsko, produkt pa nato delimo z vsoto multispektralnih kanalov. Četrta skupina tehnik temelji na uporabi valčnih transformacij (angl. wavelet transform).

Zaradi popačenja barv, do katerega prihaja ob uporabi tradicionalnih tehnik za ostrenje podob, so v zadnjem desetletju razvili številne nove tehnike za ostrenje multispektralnih podob (Ehlers, Klonus, Åstrand, 2008), kot so barvna normalizacija, Gram Schmidtova metoda, modificirana metoda HSI, proporcionalna aditivna valčna metoda in ostale. Razvoj je še posebej pospešil pojav novejših visokoločljivih satelitov (IKONOS, QuickBird). Večina avtorjev (npr. Zhang, 2002, Maxwell, Zhang, 2005, Forsythe, 2005) poroča o zelo dobrih rezultatih, dobljenih z uporabo tehnike za ostrenje PCI (zasledimo jo tudi pod imenom UNB), ki so jo razvili na Univerzi New Brunswick v Kanadi. PCI uporablja metodo najmanjših kvadratov in niz statističnih obdelav za čim boljše prilagoditev intenzitet izostrenih podob intenzitetam na izvornih pankromatskih in multispektralnih podobah.



Slika 3: Rezultat ostrenja multispektralne podobe.

Figure 3: Result of pan-sharpening.

Slika 3 prikazuje rezultat ostrenja multispektralne podobe. Od leve proti desni so prikazani barvni kompozit rdečega, zelenega in modrega kanala (a), pankromatski kanal (b) in izostren barvni kompozit (c). V prikazanem primeru smo uporabili Gram Schmidtovo metodo ostrenja multispektralnih podob na posnetku GeoEye-1.

4.3 Izboljšanje kontrasta

Senzorji na satelitih in letalih so sposobni zajeti širok razpon vrednosti, ki jih omogoča njihova radiometrična ločljivost. Vendar posamezni posnetki le redko zavzamejo celoten razpon vrednosti. Posledica je slab kontrast podob, ki ga lahko izboljšamo z raztegom radiometričnih vrednosti na celotno zalogo vrednosti sensorja. Postopek opravimo z raztegom njihovega histograma.

4.3.1 Metode za razteg histograma podob

Najpogosteje uporabljane metode za razteg histograma so linearni razteg histograma, linearni razteg z nasičenjem in uravnoteženje histograma.

Pri linearnem raztegu histograma poiščemo najmanjšo in največjo vrednost v histogramu podobe, čemur ustrežata najmanjša I_{min} in največja svetlost I_{max} (Oštir, 2006). Histogram nato raztegnemo s transformacijo, ki zapolni celotno območje vrednosti, ki ga omogoča radiometrična ločljivost podobe (od 0 do R_{max} ; npr. od 0 do 255 pri osembitnih podobah). Če je I prvotna vrednost piksla, potem je nova vrednost I_{lin_razt} enaka (9):

$$I_{lin_razt} = R_{max} \frac{I - I_{min}}{I_{max} - I_{min}}. \quad (9)$$

Z linearnim raztegom z nasičenjem na spodnjem in zgornjem delu histograma odrežemo del vrednosti (ekstreme). Praviloma gre za nekaj odstotkov (1 % do največ 10 %) simetrično pri največjih in najmanjših vrednostih. Transformacijo podaja nekoliko spremenjena enačba (9),

namesto največje in najmanjše vrednosti upoštevamo spodnjo I_{s_min} in zgornjo mejo nasičenja I_{s_max} (10):

$$I_{lin_razt_sat} = \begin{cases} 0 & : I \leq I_{s_min} \\ R_{max} \frac{I - I_{s_min}}{I_{s_max} - I_{s_min}} & : I_{s_min} < I < I_{s_max} \\ R_{max} & : I \geq I_{s_max} \end{cases} \quad (10)$$

Vsi piksli, ki so manjši ali enaki od spodnje meje I_{s_min} , dobijo vrednost 0, tisti, ki so večji ali enaki od zgornje meje I_{s_max} pa dobijo vrednost R_{max} (Oštir, 2006).

Pri uravnoteženju histograma je več vrednosti namenjenih tistim svetlostim, ki v podobi nastopajo pogosteje. Najprej izračunamo število pikslov za posamezno vrednost v uravnoteženem histogramu n_t , ki jo dobimo z deljenjem števila vseh pikslov N s številom možnih vrednosti R_{max} (11):

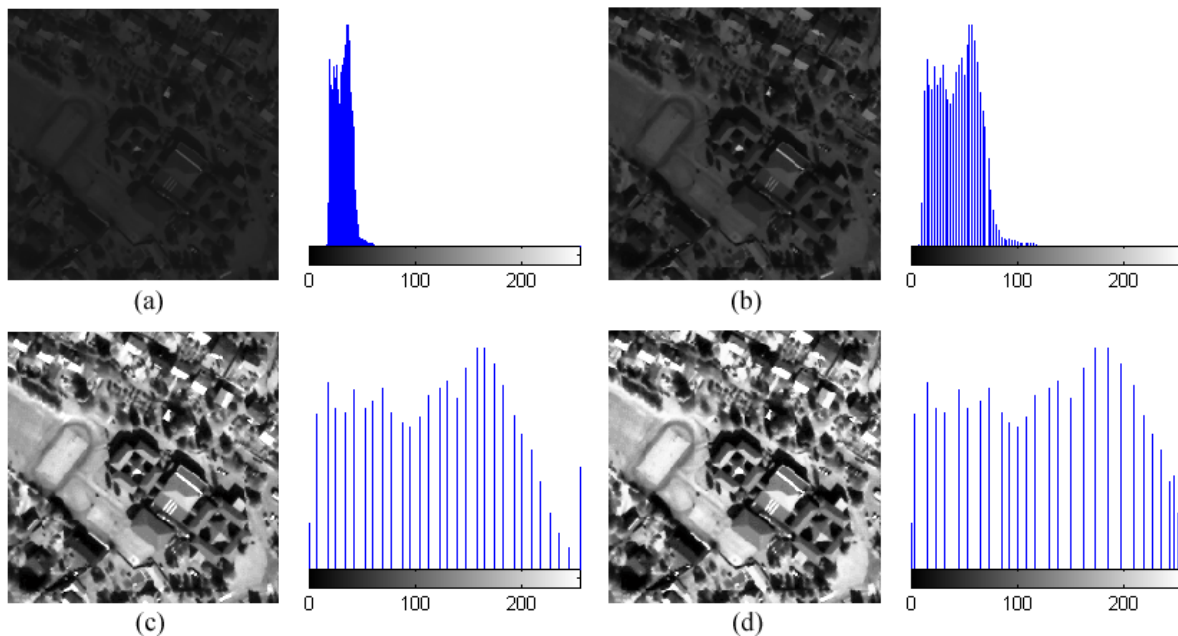
$$n_t = \frac{N}{R_{max}}. \quad (11)$$

Nato histogram podobe spremenimo v kumulativni histogram c_j , to je seštevek pikslov z vrednostmi, manjšimi od izbrane. Za digitalno vrednost j je ta torej (12):

$$c_j = \sum_{i=0}^j n_i, \quad (12)$$

kjer je n_i število pikslov z intenziteto i . Izhodna vrednost I_j , ki ustreza vhodni vrednosti j , je zaokroženo razmerje med kumulativnim številom pikslov in teoretičnim številom pikslov za posamezni razred (13):

$$I_j = \frac{c_j}{n_t}. \quad (13)$$



Slika 4: Izboljšanje kontrasta.

Figure 4: Contrast enhancement.

Slika 4 prikazuje izvorno podobo (a) in podobe, ki imajo kontrast izboljššan z linearnim raztegom histograma (b), linearnim raztegom z nasičenjem 2 % (c) in uravnoteženjem histograma (d). Poleg podob so prikazani ustrezni histogrami. V opisanem primeru smo uporabili izrez posnetka IKONOS, ki smo ga zaradi nazornejšega prikaza transformirali v 8-bitno podobo in mu delno odstranili šum.

4.3.2 Wallisov filter za izboljšanje kontrasta

Z Wallisovim filtrom prilagodimo aritmetično sredino in kontrast podobe želenim vrednostim. Oblika, ki jo predlagata Beyer in Baltsavias (1996) (14):

$$f(m, n) = [g(m, n) - m_g] \frac{cs_f}{cs_g + (1-c)s_f} + bm_f + (1-b)m_g, \quad (14)$$

kjer so:

$g(m, n), f(m, n)$ izvorna in filtrirana podoba;

m_g vhodna lokalna aritmetična sredina v oknu velikosti $i \times j$;

s_g vhodna vrednost lokalnega standardnega odklona v oknu velikosti $i \times j$;

m_f želena vrednost lokalne aritmetične sredine v oknu velikosti $i \times j$,

predlagane vrednosti za 8-bitne podobe: $127 \leq m_f \leq 140$;


s_f želena vrednost lokalnega standardnega odklona v oknu velikosti $i \times j$,

predlagane vrednosti za 8-bitne podobe: $50 \leq s_f \leq 80$; vrednost s_f naj pada z velikostjo okna $i \times j$, da se izognemo ojačenju šuma;

c konstanta za izboljšanje kontrasta, $c \in [0, 1]$, predlog $0,7 \leq c \leq 1$;

b konstanta za izboljšanje svetlosti, $b \in [0, 1]$, predlog $0,5 \leq b \leq 1$;

Klasičen Wallisov filter ima vrednosti $b = 1, c = 1$.



Slika 5: Učinek Wallisovega filtra.

Figure 5: Wallis filter effect.

Velikost okna Wallisovega filtra izberemo glede na velikost objektov na podobi, ki jih želimo izboljšati. Slika 5 prikazuje izrez posnetka IKONOS (a) in učinek Wallisovega filtra (b) z nastavitvami $m_f=127, s_f=80, c = 0,92, b = 1$ ter velikostjo okna 50×50 .

4.4 Filtriranje

Filtriranje je postopek, s katerim določenemu pikslu na podobi pripišemo novo vrednost. To vrednost izračunamo z uteženim povprečjem pikslov v njegovi okolici. Uteži običajno podamo s kvadratno matriko, ki se imenuje filtrirna matrika ali maska (Seul, O'Gorman, Sammon, 2005). Filtriranje podob sestavljajo metode, ki upoštevajo prostorske razsežnosti podatkov in različna merila na podobah (Oštir, 2006). Predstavlja pomemben korak v izboljšavi podob in zajemu podatkov. Teorija in praktični postopki filtriranja so obsežni, poglavje 4.4 predstavlja le kratek opis tehnik, ki so bile v okviru doktorske naloge uporabljene za odkrivanje stavb na visokoločljivih slikovnih virih.

4.4.1 Gaussov filter

Gaussov filter je dvorazsežen konvolucijski filter, ki zamegli podobe in odstrani šum (Oštir, 2006). Oblika filtrirne matrike je določena z Gaussovo porazdelitvijo. Koeficiente filtrirne matrike izračunamo (Seul in sod., 2005) (15):

$$f(i, j) = e^{-\frac{i^2+j^2}{2\sigma^2}}, \quad (15)$$

kjer sta i in j indeksa filtrirnega okna. Filter normiramo, tako da je vsota elementov v filtrirni matriki enaka 1. Stopnjo glajenja določa standardni odklon σ , ki ga določi uporabnik.

4.4.2 Filtri robov

S filtri robov odkrivamo pomembne nezveznosti oziroma hitre spremembe intenzitet med sosednjimi piksli v podobi. Odkrivamo jih z uporabo prvih in drugih odvodov podobe. V postopkih obdelave podob izračunamo prvi odvod z gradientom podobe (Gonzales, Woods, Eddins, 2004). Gradient podobe $f(x, y)$ je opredeljen kot vektor (16):

$$\nabla \mathbf{f} = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}. \quad (16)$$

Magnitudo gradienta izračunamo (17):

$$\nabla f = \text{mag}(\nabla \mathbf{f}) = [G_x^2 + G_y^2]^{1/2}. \quad (17)$$

Pri obdelavi podob enačbo (17) običajno aproksimiramo z izpuščanjem korenjenja ali uporabo absolutnih vrednosti (18):

$$\nabla f \approx G_x^2 + G_y^2 \quad \text{ali} \quad \nabla f \approx |G_x| + |G_y|. \quad (18)$$

Približni enačbi (18) se še vedno obnašata kot odvoda; njuna vrednost je na homogenih območjih enaka 0 in sorazmerna s spremembo intenzitet na območjih, kjer se vrednosti pikslov spreminjajo.

Gradientni vektor kaže smer največje spremembe podobe f na koordinatah (x, y) . Kot največje spremembe izračunamo (19):

$$\alpha(x, y) = \tan^{-1} \left(\frac{G_x}{G_y} \right). \quad (19)$$

Podobno lahko opredelimo drugi odvod (20):

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}. \quad (20)$$

Odvajanje podobe izvajamo s filtriranjem podobe z matriko ustreznega filtra, ki zaznava robove. V nadaljevanju so navedeni največkrat uporabljeni filtri.

Sobelov filter opredeljujeta matriki:

$$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad \text{in} \quad \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}.$$

Prewitt:

$$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad \text{in} \quad \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}.$$

Roberts:

$$\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad \text{in} \quad \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}.$$

Pomemben algoritem za iskanje robov je Cannyjev algoritem. Strnjen opis Cannyjevega algoritma podajajo naslednji koraki (Gonzales, Woods, Eddins, 2004):

- odstranjevanje šuma z uporabo Gaussovega filtra s standardnim odklonom σ ,
- izračun lokalne magnitude gradienta (18) in njegove smeri (19) v vsaki točki obravnavane podobe. Za izračun uporabimo Sobelov, Prewittov ali Robertsov filter. Kot točka na robu je opredeljen piksel, ki predstavlja lokalni maksimum v smeri magnitude gradienta;
- uporaba dveh pragov za določitev močnih ($T2$) in šibkih ($T1$) robov, $T1 < T2$; močne robove predstavljajo pikseli z vrednostjo nad $T2$, pomembne šibke robove predstavljajo pikseli z vrednostjo med $T1$ in $T2$;
- priključitev pomembnih šibkih robov močnim robovom.

4.4.3 Poudarjanje robov

Na enačbi drugega odvoda (20) temelji Laplaceov filter, ki ga prištevamo med visokoprepustne filtre, ki se v obdelavi podob uporabljajo za poudarjanje podrobnosti na njih. Lahko ga uporabimo za poudarjanje robov. Določa ga filtrirna maska:

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}.$$


Maska, ki upošteva tudi diagonalne elemente, ima obliko:

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}.$$

Izboljšavo podobe z Laplaceovim filtrom izraža enačba (21):

$$g(x, y) = f(x, y) + c[\nabla^2 f(x, y)], \quad (21)$$

kjer je $g(x, y)$ izboljšana podoba, c je enak 1, kadar uporabljamo obliko filtrirne maske s pozitivnim središčnim elementom, ali -1 za primer maske, ki je prikazana zgoraj. Laplaceov filter deluje kot odvod in ostri podobo, na homogenih območjih pa je enak 0. Sivine podobe vzpostavimo nazaj s tem, ko rezultatu prištejemo vhodno podobo $f(x, y)$.



Slika 6: Delovanje Laplaceovega filtra.

Figure 6: Laplacian filter functioning.

Slika 6 ilustrira izboljšanje podobe z Laplaceovim filtrom s središčnim elementom -8. Prikazuje vhodno podobo (a), rezultat filtriranja (b) in izboljšano podobo (c), ki jo dobimo tako, da vhodni podobi prištejemo rezultat filtriranja.

4.4.4 Anizotropna difuzija

Difuzijsko filtriranje omogoča glajenje šuma ob hkratnem ohranjanju robov oziroma značilnih točk (Zaletelj in sod., 1998). Nelinearno difuzijsko filtriranje je iterativen proces, opisan s parcialnimi diferencialnimi enačbami. Nelinearni model, ki smo ga uporabili v nalogi, sta predlagala Perona in Malik (1990). Zahteve za njun model so naslednje:

- model naj ima lastnost vzročnosti, kar pomeni, da se pri prehodu k višjim nivojem ne pojavi noben nov (lažen) detajl;
- robovi regij naj bodo pri vsaki ločljivosti ostri in naj ustrezajo pomenskim robovom pri tej ločljivosti;
- pri vseh ločljivostih naj prihaja predvsem do glajenja znotraj regij, ne pa glajenja preko meja regij;
- model naj omogoča ne samo ohranjanje, pač pa tudi poudarjanje robov.

Parcialna diferencialna enačba, ki opisuje model, se glasi (22):

$$\partial_t u = \operatorname{div}(g(x, y, t)\nabla u) = g(x, y, t)\Delta u + \nabla g \nabla u, \quad (22)$$

kjer je u intenziteta pikslov v podobi, g pa difuzijski koeficient. Stopnjo glajenja pri anizotropni difuziji uravnavamo s številom iteracij.

Delovanje anizotropne difuzije prikazuje slika 34 na strani 93.

4.4.5 Ostali uporabljeni filtri


V doktorski nalogi smo poleg opisanih filtrov uporabili še filter mediana ter filter Lee-Sigma za odstranjevanje šuma na podobah, filter povprečenja za glajenje samodejno izdelanega DMP in filter večine za čiščenje maske stavb. Prilagodljiv filter Lee-Sigma je bil sicer razvit za zmanjševanje učinka zrnatosti na radarskih podobah, vendar se je izkazal kot učinkovit pri odstranjevanju šuma na posnetku IKONOS, na katerem se je pojavljal tudi šum z značilnostmi »soli in popra« (angl. salt and pepper noise). Filter Lee-Sigma odstranjuje šum, pri tem pa lahko ohranja pomembne robove na podobah (Xiao, Li, Moody, 2003).

4.5 Vektorizacija robov

V idealnem primeru odkrijemo z metodami filtriranja robov le tiste piksele, ki ležijo na robovih. V praksi ti piksli redko opisujejo popolne robove, saj so naše podobe obremenjene s šumom, prekinitvijo robov zaradi neenakomerne osvetlitve in ostalih učinkov, ki povzročajo hitre spremembe intenzitet podobe. Filtriranju robov zato pogosto sledijo postopki, ki piksele na robovih povežejo v pomembne robove in jih vektorizirajo. Pristopa, ki iščeta in povezujeta segmente linij ter omogočata njihovo vektorizacijo, sta Houghova in Radonova transformacija.

4.5.1 Houghova transformacija

S Houghovo transformacijo obravnavamo točko (x_i, y_i) in vse premice $y_i = ax_i + b$, ki potekajo skozi to točko pri poljubnem a in b . Če enačbo zapišemo kot $b = -ax_i + y_i$, dobimo parametrski prostor (v ravnini ab), ki nam podaja enačbo ene premice za par (x_i, y_i) . Podoben parametrski prostor imajo tudi premice skozi točko (x_j, y_j) . Recimo, da parametrska premica, pripisana paru (x_j, y_j) , seka premico, pripisano paru (x_i, y_i) , v točki (a', b') . a' in b' tako opisujeta premico, ki vsebuje obe točki (x_i, y_i) in (x_j, y_j) v ravnini xy . Slika 7 prikazuje zasnovano Houghove transformacije.




Slika 7: Ravnina xy (a) in parametrski prostor ab (b) (Gonzales in sod., 2004).

Figure 7: xy (a) plane and parameter space ab (b) (Gonzales et al., 2004).

Ko se premica bliža vertikali se a približuje ∞ , zato enačbo premice raje zapišemo v normalni obliki (23):

$$x \cos\theta + y \sin\theta = \rho. \tag{23}$$




Slika 8: Parametrski prostor Houghove transformacije (Gonzales in sod., 2004).

Figure 8: Hough transformation parameter space (Gonzales et al., 2004).

Slika 8 prikazuje geometrično predstavitev parametrov ρ in θ (a), sinusoidi v ravnini $\rho\theta$ (b), (ρ', θ') odgovarja parametroma premice, ki poteka skozi točki (x_i, y_i) in (x_j, y_j) , in razdelitev ravnine $\rho\theta$ v zbiralne celice (c). Zbiralne celice nastanejo z razdelitvijo parametrskega prostora $\rho\theta$. Vrednosti $(\rho_{\min}, \rho_{\max})$ in $(\theta_{\min}, \theta_{\max})$ opisujejo pričakovano zalogo vrednosti parametrov. Običajno so te vrednosti $-90^\circ \leq \theta \leq 90^\circ$ in $-D \leq \rho \leq D$, kjer je D dolžina stranice obravnavane podobe. Velikost celice je odvisna od koraka, pri katerem izvajamo transformacijo (npr. 1° za θ , 1 piksel za ρ) (Gonzales, Woods, Eddins, 2004).

Na začetku so vse vrednosti zbiralnih celic postavljene na 0. Za vsak piksel, ki ima v ravnini xy vrednost 1, z enačbo (23) za celotno zalogo vrednosti θ izračunamo parametre ρ . Vrednosti ρ zaokrožimo v najbližjo zbiralno celico vzdolž osi ρ in povečamo vrednost v celici. Vrednost zbiralne celice na koncu transformacije pomeni število točk v ravnini xy , ki ležijo na premici $x \cos\theta_j + y \sin\theta_j = \rho_i$.




Slika 9: Delovanje Houghove transformacije.

Figure 9: Hough transform functioning.

Slika 9 prikazuje delovanje Houghove transformacije. Vhodna podoba (a) vsebuje 5 točk (točke so zaradi prikaza povečane). Desno je prikazana Houghova transformacija (b). Z rdečimi kvadrati sta pri kotu $\theta = \pm 45^\circ$ označeni presečišči treh sinusoid, kar pomeni, da obstajata dve premici, ki potekata skozi tri točke. Na izhodni podobi (c) so ustrezne točke povezane z daljicama.

4.5.2 Transformacija Radon


Podobno kot Houghova transformacija je opredeljena tudi transformacija Radon. Transformacija Radon omogoča implementacijo Houghove transformacije v programu Matlab.



Slika 10: Izračun vrednosti transformacije Radon.

Figure 10: Radon transform values calculation.

Transformacija Radon predstavlja projekcijo intenzitet podobe vzdolž radialne premice, usmerjene pod kotom θ . Algoritem pred projekcijo vsak piksel razdeli na štiri podpiksle. Projekcija vsakega podpiksela se sorazmerno porazdeli med dve sosednji vrednosti ρ (če projekcija zadane celoštevilčno vrednost ρ , se ρ pripiše polna vrednost podpiksela, t. j. $\frac{1}{4}$). Princip ponazarja slika 10.



Slika 11: Delovanje transformacije Radon.

Figure 11: Radon transform functioning.

Slika 11 prikazuje delovanje transformacije Radon na primeru, ki ga predstavlja slika 9. Vhodna podoba (a) vsebuje 5 točk (točke so zaradi prikaza povečane). Desno je prikazana transformacija Radon (b). Z rdečimi kvadrati sta pri kotu $\theta = \pm 45^\circ$ označeni presečišči treh sinusoid, kar nakazuje, da obstajata dve premici, ki potekata skozi tri točke. Vrednost transformacije Radon v označenih presečiščih je za podani primer 2,47 pri koraku $\theta = 0,5^\circ$. Na izhodni podobi (c) so kolinearne točke povezane s premicama. Uporaba transformacije Radon je na praktičnem primeru opisana v 6.1.4.

4.6 Morfološka obdelava podob

Pri morfološki obdelavi podob govorimo o matematični morfologiji kot orodju za iskanje sestavnih delov podob, ki so pomembni za predstavitev in opis delov podob (obrisi, skeleti), in morfoloških tehnikah za pred in poobdelavo podob kot so morfološko filtriranje, tanjšanje

ter omejevanje. Osnovni morfološki operaciji sta dilacija in erozija, ki ju lahko združujemo tudi v kompleksnejše operacije, kot sta odpiranje in zapiranje podob (Gonzales, Woods, Eddins, 2004). Navedene morfološke operacije nadzorujemo s strukturnim elementom. Operacije so zaradi nazornosti predstavljene na binarnih podobah, v 4.6.5 pa smo opisali njihovo razširitev na večbitne podobe.

4.6.1 Strukturni element

Učinek morfološke operacije na podobi opredeljuje strukturni element. Predstavimo ga lahko kot majhno podobo. V binarnih operacijah je njegova oblika določena z zapisom enk v pravokotni celični mreži. Vsak strukturni element ima opredeljeno tudi svoje izhodišče, ki ni nujno v središču strukturnega elementa (Gonzales, Woods, Eddins, 2004). Slika 12 prikazuje nekaj primerov strukturnih elementov z označenimi središči.


1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1

Slika 12: Primeri strukturnih elementom z označenimi izhodišči.

Figure 12: Examples of structuring elements with marked origins.

4.6.2 Dilacija in erozija


Dilacija je morfološka operacija, ki širi oziroma razteza objekte na podobi. Njeno delovanje prikazuje slika 13. Dilacijo opredeljuje strukturni element (b), ki se med morfološko operacijo piksel za pikselom premika čez izvorno podobo (a). Na mestih, kjer se del strukturnega elementa prekriva z enko v izvorni podobi, se v izhodni podobi (c) na mesto izhodišča strukturnega elementa zapiše enica (Gonzales, Woods, Eddins, 2004).



Slika 13: Izvorna podoba, strukturalni element in izhodni rezultat dilacije.

Figure 13: Original image, structuring element and output of the dilation.

Erozija je morfološka operacija, ki krči oziroma oži objekte na podobi. Njeno delovanje prikazuje slika 14. Enako kot dilacija je opredeljena s strukturalnim elementom (b), ki se piksel za pikselom premika čez izvorno podobo (a). Kadar se celoten strukturalni element prekriva s pikseli, ki imajo v izvorni podobi vrednost ena, se na mesto izhodišča strukturalnega elementa v izhodno podobo (c) zapiše enica (Gonzales, Woods, Eddins, 2004).



Slika 14: Izvorna podoba, strukturalni element in izhodni rezultat erozije.

Figure 14: Original image, structuring element and output of the erosion.

4.6.3 Odpiranje in zapiranje

V praktični obdelavi podob se dilacija in erozija pogosto pojavljata skupaj v različnih kombinacijah. Najpogostejši kombinaciji sta odpiranje in zapiranje. Morfološko odpiranje podobe je sestavljeno iz erozije, ki ji sledi dilacija z istim strukturalnim elementom. Operacija iz podob odstranjuje dele objektov in objekte, ki ne morejo vsebovati celotnega strukturalnega elementa, gladil obrise, prekinja tanke povezave in odstranjuje tanke izbokline.

Morfološko zapiranje podobe je sestavljeno iz dilacije, ki ji sledi erozija z istim strukturnim elementom. Tudi zapiranje gladi obrise objektov, v nasprotju z odpiranjem pa združuje ozke prelome, zapolnjuje tanke ožine in luknje, ki so manjše od strukturnega elementa (Gonzales, Woods, Eddins, 2004). Slika 15 prikazuje delovanje morfološkega odpiranja in zapiranja podobe s strukturnim elementom, ki ima obliko kvadrata dimenzij 20 x 20 pikslov. Uporabljena je bitna podoba z vrednostjo 0 za črno barvo in 1 za belo barvo.



Slika 15: Prikaz odpiranja in zapiranja: izvorna podoba (a) (Gonzales in sod., 2004), odpiranje (b), zapiranje (c), zapiranje odprte podobe (d).

Figure 15: Illustration of opening and closing: original image (a) (Gonzales et al., 2004), opening (b), closing (c), closing of opened image (d).


Slika 15 po vrsti prikazuje izvorno podobo (a), rezultat odpiranja izvorne podobe (b), rezultat zapiranja izvorne podobe (c) in rezultat zapiranja odprte podobe (d).

4.6.4 Morfološka rekonstrukcija

Rekonstrukcija je morfološka operacija, ki poleg izvorne podobe obravnava še njen zaznamovalec (angl. marker), ki nadzoruje rekonstrukcijo. Izvorna podoba in njen zaznamovalec sta podobi z enako velikostjo. Postopek se prične z zaznamovalcem. Objekte zaznamovalca širimo toliko časa, da dosežejo velikost in obliko tistih objektov na podobi, ki jih objekti na zaznamovalcu označujejo pred pričetkom rekonstrukcije (Gonzales, Woods, Eddins, 2004).

Pomembna uporaba rekonstrukcije je odpiranje z rekonstrukcijo, ki jo lahko uporabimo za odstranjevanje neželenih objektov iz podobe. Podobne naloge lahko izvajamo tudi z morfološkim odpiranjem, kjer z erozijo odstranimo neželene majhne objekte, preostale objekte pa obnovimo z naknadno dilacijo. Vendar je v tem primeru končna oblika obnovljenih

elementov močno odvisna od oblike strukturnega elementa. Odpiranje z rekonstrukcijo ohranja elemente, ki ostanejo na podobi po eroziji, popolnoma nespremenjene.




Slika 16: Odpiranje z rekonstrukcijo: izvorna podoba, zaznamovalec in rekonstruirana podoba.

Figure 16: Opening by reconstruction: original image, marker and reconstructed image.

Slika 16 prikazuje primer odpiranja z rekonstrukcijo. Rezultat odpiranja z rekonstrukcijo (c) vsebuje le še tiste objekte izvorne podobe (a), ki jih označuje zaznamovalec (b). Morfološka rekonstrukcija je uporabna tudi za zapiranje lukenj v podobi in odstranjevanje objektov, ki se dotikajo robov podobe.

4.6.5 Morfologija črnobelih podob

Opisane morfološke operacije lahko razširimo tudi na črno bele podobe, ki vsebujejo sivine od črne do bele. V najbolj preprostem primeru predstavlja dilacija izračun lokalnega maksimuma iz tistih pikslov vhodne podobe, ki jih prekriva strukturni element. Enako predstavlja erozija izračun lokalnega minimuma. Dilacijo in erozijo pogosto sestavljamo za pridobitev različnih učinkov. Če dilaciji odštejemo erozijo pridobimo morfološki gradient, ki predstavlja mero lokalnega spreminjanja sivin in ima lastnosti poudarjanja robov na podobi (Gonzales, Woods, Eddins, 2004). Slika 17 prikazuje izsek ortofota z območja Kranja (a), dilacijo podobe (b), erozijo podobe (c) in njen morfološki gradient. Uporabili smo strukturni element kvadrat velikosti 3 x 3 pikslov.



Slika 17: Izvorna podoba, dilacija, erozija in morfološki gradient

Figure 17: Original image, dilated image, eroded image and morphological gradient

Odpiranje in zapiranje črnobelih podob sta opredeljena enako kot pri binarnih podobah. Odpiranje v splošnem odstranjuje majhne svetle detajle iz podob. Pri tem ostanejo ostale sivine in večji svetli objekti relativno nedotaknjeni.

4.7 Barvna segmentacija podob

Segmentacija je postopek, ki razdeli podobo na manjša območja. Barvna segmentacija na podobi izloči objekte, ki imajo določeno barvo. Postopku podamo barvo, ki jo želimo izločiti na podobi oziroma podamo niz barv iz katerega izračunamo povprečje \mathbf{m} , ki ga v barvnem prostoru RGB izrazimo kot vektor. Namen segmentacije je iskanje vseh pikslov na podobi, ki so po barvi podobni \mathbf{m} . Najbolj preprosto mero podobnosti prestavlja evklidska razdalja. Če je


\mathbf{z} poljuben piksel v RGB prostoru, je \mathbf{z} podoben \mathbf{m} , če je razdalja med njima pod določenim pragom T . Evklidsko razdaljo med \mathbf{z} in \mathbf{m} izračunamo (24):

$$\begin{aligned} D(\mathbf{z}, \mathbf{m}) &= \|\mathbf{z} - \mathbf{m}\| = \\ &= [(\mathbf{z} - \mathbf{m})^T (\mathbf{z} - \mathbf{m})]^{1/2} = \\ &= [(z_R - m_R)^2 + (z_G - m_G)^2 + (z_B - m_B)^2]^{1/2}, \end{aligned} \quad (24)$$

kjer je $\|\cdot\|$ norma, indeksi R , G in B pa predstavljajo rdečo, zeleno in modro sestavino vektorjev \mathbf{m} in \mathbf{z} . Točke, ki ustrezajo pogoju $D(\mathbf{z}, \mathbf{m}) \leq T$ predstavljajo sfero z radijem T (Gonzales, Woods, Eddins, 2004). Uporabna posplošitev enačbe (24) je mera za razdaljo (25):

$$D(\mathbf{z}, \mathbf{m}) = [(\mathbf{z} - \mathbf{m})^T \mathbf{C}^{-1} (\mathbf{z} - \mathbf{m})]^{1/2}, \quad (25)$$

kjer je \mathbf{C} kovariančna matrika podanega niza barv, ki ga želimo izločiti na podobi. Razdalja (25) se imenuje Mahalanobisova razdalja. Točke, ki ustrezajo pogoju $D(\mathbf{z}, \mathbf{m}) \leq T$ predstavljajo elipsoid, ki ima glavno os orientirano vzdolž največje razpršenosti podatkov. V primeru, ko je \mathbf{C} enaka enotski matriki, se Mahalanobisova razdalja zreducira v Evklidsko razdaljo (Gonzales, Woods, Eddins, 2004). Slika 18 prikazuje prostora točk, ki ustrezata Evklidski (a) in Mahalanobisovi (b) razdalji v postopku barvne segmentacije podob.



Slika 18: Evklidska in Mahalanobisova razdalja (Gonzales in sod., 2004).

Figure 18: Euclidean and Mahalanobis distance (Gonzales et al., 2004).

4.8 Rast regij

Rast regij (angl. region growing) je postopek, ki na osnovi določenih pogojev rasti združuje piksele oziroma manjša območja v večja območja (Gonzales, Woods, Eddins, 2004). Začne se z nizom točk, ki jih imenujemo seme (angl. seed point). V postopku rasti se semenu na podlagi določenega kriterija podobnosti priključujejo sosednji piksli. Osnovno princip rasti regij opišemo v treh korakih:

- 1) izbira semena,
- 2) testiranje sosednjih pikslov; če zadoščajo pogoju podobnosti, jih priključimo k regiji,
- 3) korak 2 ponavljamo, dokler ni dosežen pogoj za prenehanje rasti.

Izbira semena je odvisna od narave problema, ki ga obravnavamo. Pogoj podobnosti opredelimo na podlagi značilnosti podobe, ki jo obravnavamo, in njenih regij. Te značilnosti so lahko povprečna intenziteta, varianca, barva, tekstura in podobno. Pri tem je treba obravnavati tudi povezljivost regije (ali se piksel dotika regije s celotnim robom ali le z vogalom). Za pridobitev smiselnih regij je treba pravilno postaviti tudi pogoj za prenehanje rasti. V osnovi se rast preneha, ko na podobi ni več pikslov, ki bi zadoščali pogoju podobnosti za vključitev v regijo. Dodatni kriteriji, ki jih zato vključimo v postopek so velikost, podobnost med semenom in razraščeno regijo, oblika in podobni.

4.9 Združevanje podob in višinskih podatkov za iskanje stavb

V podpoglavju opisujemo nekatere uveljavljene postopke za obdelavo višinskih podatkov, ki jih za boljše in lažje iskanje stavb pogosto združujemo s slikovnimi podatki. Pri kombinirani uporabi podob in višinskih podatkov, uporabljamo višinske podatke za določevanje objektov, ki segajo nad zemeljsko površje. To so v glavnem stavbe in vegetacija, ki ju medsebojno ločimo z uporabo podob. V prvi fazi izdelamo digitalni model površja (DMP). DMP je računalniška predstavitev višin na določenem območju, ki poleg samega reliefa prikazuje pojave na terenu kot so zgradbe, vegetacija in drugi objekti (npr. avtomobili). DMP pridobimo z uporabo samodejnih postopkov slikovnega ujemanja na stereoparih podob

(Baillard, Maître, 1999, Baltsavias, Li, Eisenbeiss, 2005, Demir, Baltsavias, 2007) ali neposredno iz podatkov zračnega laserskega skeniranja (Höfle in sod., 2009; Rottensteiner in sod., 2003; Sohn, Dowman, 2003; Tao, Yasuoka, 2002).

Iz DMP izdelamo digitalni model višin (DMV). DMV je računalniška predstavitev nadmorskih višin zemeljskega površja na določenem območju. Je preprostejši približek zapisa digitalnega modela reliefa. DMV vsebuje samo višinske točke, ki so najpogosteje zapisane v obliki pravilnih kvadratnih celic in pogojno tvorijo ploskev zemeljskega površja (Podobnikar, 2001). Za izdelavo DMV iz DMP so se uveljavili štirje osnovni postopki (Pfeifer, Böhm, 2008):

- morfološko filtriranje je lokalna operacija s katero iz oblaka točk izločamo tiste točke, ki ne ležijo na terenu. Pristop temelji na matematični morfologiji črnobelih podob. Sivine v tem primeru predstavljajo višine točk, medtem ko strukturni element določa dovoljene višinske razlike na neki horizontalni razdalji.
- Drugo skupino postopkov predstavljajo zgostitveni pristopi. Metode slonijo na začetnem številu točk, ki gotovo ležijo na terenu. V nadaljevanju s progresivnim filtriranjem iščemo vse več terenskih točk, dokler niso prepoznane vse točke, ki pripadajo terenu.
- Obraten postopek predstavljajo metode iterativnega izločevanja točk. V začetni fazi privzamemo, da vse točke v oblaku opisujejo model terena. V nadaljevanju izločimo iz modela vse točke, ki dejansko ne ležijo na terenu.
- Zadnji pristop predstavlja segmentacija, pri kateri ne obravnavamo posameznih točk v oblaku pač pa jih združujemo v večje segmente, ki pripadajo ali ne pripadajo terenu. Metode imajo prednosti na območjih, kjer obstajajo izraziti segmenti (npr. stavbe).

V kombinaciji s podobami se za izdelavo DMV najbolj pogosto uporabljata morfološko filtriranje in zgostitveni pristopi. Li, Zhu in Shimamura (2008) predlagajo kombiniranje morfološkega zapiranja in odpiranja. Z morfološkim zapiranjem zapolnimo vbokline v DMP. Z morfološkim odpiranjem odstranimo vse izbokline iz DMP, ki jih predstavljajo zgradbe, vegetacija in avtomobili. Velikost objektov, ki jih odstranimo iz DMP z morfološkimi

operacijami določa velikost strukturnega elementa, ki pa je redko dovolj velik, da bi z njim lahko odstranili tudi bloke in sestavljene zgradbe, ki se pogosto nahajajo v urbanem okolju. V izogib težavam pri iskanju ustrezne velikosti strukturnega elementa, predlagajo Rottensteiner in sod. (2003) iterativno filtriranje DMP. V prvem koraku s strukturnim elementom, ki ustreza največjim zgradbam med podatki, izdelamo masko območja, ki vsebuje največje stavbe. V naslednjih korakih dopolnjujemo masko z uporabo manjšega strukturnega elementa, dokler niso poiskana vsa območja, ki vsebujejo tudi stavbe. Sohn in Dowman (2003) sta za izdelavo DMV uporabila metodo zgoščevanja v dveh korakih. V prvem koraku zgostimo model terena s točkami, ki ležijo pod trenutno trikotniško mrežo točk, ki opisujejo teren. Temu sledi korak, ki dodaja točke nad trikotniško mrežo. Rekurzivni postopek se izvaja toliko časa, dokler ne prepoznamo vseh točk, ki ležijo na terenu.

Ko imamo izdelana DMP in DMV lahko začetne kandidate za stavbe dobimo z uporabo višinskega praga na normaliziranem digitalnem modelu površja (nDMP). nDMP dobimo z razliko med DMP in DMV ter vsebuje le še objekte, ki segajo nad površino tal. Iz nDMP izločimo vse objekte, ki merijo v višino manj od določenega praga. V Operativnem navodilu za zajem podatkov o stavbah (GURS, 2001) segajo stavbe vsaj 2 m nad zemeljsko površino, kar lahko privzamemo kot prag. Tako pridobimo začetno masko stavb, ki poleg stavb še vedno vsebuje vegetacijo in tvorbe na terenu, ki so manjše od strukturnega elementa in jih z morfološkim filtriranjem nismo odstranili iz DMV.

Vegetacijo odstranimo iz nDMP z izračunom vegetacijskega indeksa iz multispektralnih podob (Rottensteiner in sod., 2003; Sohn, Dowman, 2003; Tao, Yasuoka, 2002). Vegetacijski indeks opredeljuje stanje vegetacije. Podan je kot razmerje med odbojem v infrardečem in rdečem delu elektromagnetnega spektra. Vegetacija (oziroma klorofil v njej) zelo močno odbija infrardečo svetlobo, rdečo pa slabo. Vegetacijski indeks za vegetacijo je torej zelo visok, medtem ko je za nevegetacijo ali poškodovano vegetacijo nizek. Najpogosteje se uporablja normiran diferencialni vegetacijski indeks (NDVI), ki ga izračunamo z razmerjem med razliko odbojev v infrardečem in rdečem delu spektra ter njuno vsoto (26):

$$NDVI = \frac{IR-R}{IR+R} \quad (26)$$

Indeks NDVI zavzame vrednosti med -1 in 1, pri čemer višje vrednosti pomenijo bolj intenzivno vegetacijo (Oštir, 2006). V primerih, ko je bil DMP izdelan s tehnologijo laserskega skeniranja, lahko kot pogoj za odstranitev vegetacije iz nDMP uporabimo tudi razliko med prvim in zadnjim odbojem laserskega žarka. Začetno masko stavb še izboljšamo z binarnim morfološkim odpiranjem z majhnim strukturnim elementom in s tem iz nDMP odstranimo majhne objekte (npr. ograje) in ločimo stavbe, ki so med seboj povezane s tanko linijo pikselov. Glede na Operativno navodilo za zajem stavb, mora znašati površina stavbe vsaj 4 m².

5 METODOLOGIJA IN OPIS TESTNIH PODATKOV

V tem poglavju predstavljamo metodologijo in utemeljimo izbor podatkov za izdelavo doktorske naloge. Navajamo opis podatkov, na katerih so bili testirani izbrani postopki za samodejno odkrivanje in zajem stavb, in uporabljene metode. Podrobnejši opis metod podajamo v poglavju 6. Metode dela slonijo na izdelavi maske stavb in njeni končni vektorizaciji. Na koncu poglavja opisujemo metode, ki smo jih uporabili za ovrednotenje rezultatov samodejnega iskanja in zajema stavb.

Metodologija samodejnega iskanja stavb na visokoločljivih slikovnih virih zahteva najprej izbiro ustreznih virov. Pregled potencialnih virov smo navedli v poglavju 3. Za odkrivanje stavb smo izbrali slikovne vire, ki zagotavljajo vsaj metrsko prostorsko ločljivost. Metode samodejnega iskanja stavb smo testirali na reprezentativnih vzorcih, izbranih iz delovnega okolja. Za boljše in lažje iskanje stavb na slikovnih podatkovnih virih, smo posnetke združili z višinskimi podatki. Pri uporabi zgolj enega podatkovnega vira lahko naletimo v urbanih okoljih na več težav. Stavbe in ulice so lahko zgrajene iz sorodnih materialov, zato ima njihov zapis na podobah zelo podobne karakteristike, in jih zgolj z uporabo posnetkov težko ločimo. Pri podatkih laserskega skeniranja predstavlja enega od glavnih problemov ločevanje točk na tleh od točk, ki so rezultat odboja od stavb, vegetacije in drugih objektov nad površino tal. Težave se pojavijo pri ločevanju stavb in dreves, ki so blizu skupaj. Krošnje dreves pogosto tudi prekrivajo dele stavb ali celotne stavbe. Vegetacijo lahko odstranimo z uporabo multispektralnih posnetkov (Vosselman, Maas, 2001). Kot višinske podatke smo uporabili digitalni model površja (DMP) v rastrski obliki. Rastrski zapis DMP je lažje dostopen in bolj obvladljiv v kombinaciji s slikovnimi viri. Kot dopolnilni vir za lažje iskanje stavb smo uporabili tudi podatke iz topografske baze (podatki o cestah).

Za samodejno odkrivanje stavb smo izbrali tri različne vire. Najboljšo prostorsko ločljivost zagotavljajo podatki letalskega snemanja. Izvorni posnetki snemanja (posamezni kanali) so običajno težko dostopni. Zato smo se odločili, da bomo za iskanje stavb uporabili ortofoto,

izdelan iz letalskih posnetkov. Ortofoti so že transformirani v državni koordinatni sistem. Ortofoto smo kombinirali z DMP. Izmed satelitskih posnetkov smo kot vira izbrali stereopar IKONOS in posnetek GeoEye-1. IKONOS je prvi visokoločljivi civilni satelit za opazovanje zemeljskega površja, zato so bile na njegovih posnetkih izvedene že številne analize samodejnega zajema stavb. Zanimala nas je primerljivost naših rezultatov z obstoječimi analizami, poleg tega pa je bil stereopar za slovenski prostor že posnet in ga ni bilo treba posebej naročati. Posnetek GeoEye-1 smo vključili v doktorsko nalogo, ker je v času izdelave naloge zagotavljal najvišjo prostorsko ločljivost satelitskih posnetkov.

Za samodejno iskanje stavb smo glede na uporabljene podatke preskusili različne metodologije. Lastnosti snemalnih sistemov in s tem lastnosti posnetkov, ki jih snemalni sistemi zajemajo, se med seboj precej razlikujejo. Metode za obdelavo slikovnih virov so zato v veliki meri odvisne od uporabljenih podatkov. Obstoječe metode smo prilagodili posameznim virom in jih izboljšali s svojimi postopki. Kljub temu je predlagano metodologijo mogoče uporabiti tudi na ostalih podatkovnih virih, ki imajo podobne lastnosti (npr. posnetki QuickBird).

Za ovrednotenje rezultatov bi bilo idealno, če bi imeli na razpolago testno polje, na katerem bi obravnavali vse navedene podatke. Na testnem polju bi imeli izmerjene koordinate oslonilnih in detajlnih točk ter vektorsko zajete vse stavbe. Naši viri so bili narejeni na različnih območjih. Za ovrednotenje rezultatov samodejnega odkrivanja stavb smo zato uporabili statistični kriterij, ki opisuje odstotek odkritih stavb glede na vse stavbe na obravnavanem vzorcu.

5.1 Digitalni ortofoto in digitalni model površja

V 6.1 opisujemo možnosti za odkrivanje in zajem stavb s povezavo digitalnega ortofota in natančnih višinskih podatkov, izdelanih iz lidarskega snemanja, ki je bilo izvedeno v letu 2007 na južnem delu Ljubljane in Ljubljanskem barju. Na voljo smo imeli le DMP ter DMV in ne izvornih lidarskih podatkov (oblak točk z atributi), ki običajno prinašajo tudi podatke o različnem številu odbojev laserskih žarkov in intenziteti odboja, kar močno olajša

interpretacijo podatkov. Za obdelavo smo izbrali že preizkušeno metodo izdelave normaliziranega digitalnega modela površja (nDMP) in odstranjevanje vegetacije z uporabo vegetacijskega indeksa. Modificiran vegetacijski indeks smo v doktorski nalogi izdelali iz infrardečega ortofota. Izdelano masko stavb smo za potrebe doktorske naloge izboljšali z izračunom indeksa senc in analizo teksture nDMP. Končno masko stavb smo vektorizirali z uporabo Houghove transformacije.

Uporabljene slikovne podatke sestavljata barvni ortofoto in bližnji infrardeči ortofoto. Preglednica 5 opisuje njune lastnosti. Za višinske podatke smo uporabili DMP in DMV. Oba višinska modela sta bila zapisana v rastrskem formatu z velikostjo piksla 0,5 m.

Preglednica 5: Lastnosti ortofota.

Table 5: Orthophoto characteristic.

	DOF050	DOF100IR
Opis	barvni ortofoto	bližnjeinfrardeči ortofoto
Leto izdelave	2006	2006
Oznaka lista	E2303	E2303
Datoteka	E230362D (TIF in TFW)	E230360 (TIF in TFW)
Barvni prostor	RGB	RGB
Radiometrična ločljivost	24-bit; 8 bitov za posamezni kanal	24-bit; 8 bitov za posamezni kanal
Prostorska ločljivost	0,5 m	1 m

Ožje območje za testiranje metod za zajem stavb ima površino 500 m x 350 m z robnimi koordinatami v državnem koordinatnem sistemu (slika 19):

Y: 460.725 m – 461.225 m; X: 99.200 m – 99.550 m.

Končne rezultate samodejnega iskanja in zajema stavb smo primerjali z grafičnim delom katastra stavb.

5.2 Stereopar IKONOS

V 6.2 opisujemo možnosti za odkrivanje in zajem stavb na stereoparu IKONOS z območja Cerknice. V začetni fazi je uporabljena metoda podobna metodi, opisani v prejšnjem podpoglavju, le da tu DMP in ortofote izdelamo iz stereopara IKONOS. Nadaljnji postopki se razlikujejo, saj DMP, izdelan s samodejnimi fotogrametričnimi postopki, ne dosega položajne točnosti DMP, izdelanega iz lidarskih podatkov, drugačne pa so tudi radiometrične lastnosti posnetkov IKONOS, iz kateri smo izdelali ortofote. Iz stereopara smo s samodejnimi postopki slikovnega ujemanja izdelali DMP in DMV. Končni DMV smo uredili ročno (s stereopazovanjem na fotogrametrični delovni postaji smo popravili napačno zajete točke). Začetno masko stavb smo izdelali na podlagi nDMP. Višinski podatki, pridobljeni v komercialni programski opremi, nas niso povsem zadovoljili, saj postopek mnogo stavb ni odkril. Po preskusu nekaterih že uveljavljenih metod (nadzorovana klasifikacija), smo se za dopolnitev prvotne maske stavb odločili za uporabo lastne metode, razvite v okviru doktorske naloge. Metoda sloni na kombinaciji anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. Opisana je v poglavjih 6.3.3 in 6.3.4. Končno masko stavb smo vektorizirali s Houghovo transformacijo.

Oslonilne točke (njihovo skupno število je 19) za georeferenciranje ortofotov, ki smo jih v okviru doktorske naloge izdelali iz stereopara IKONOS, smo izmerili na listih državnega ortofota DOF050. Za dejansko uporabo posnetkov za vzdrževanje topografskih podatkov sicer priporočamo meritev oslonilnih točk z eno od geodetskih metod. Ker je osnovni namen doktorske naloge odkrivanje stavb na posnetkih in ker smo kljub merjenju oslonilnih točk na ortofotu dobili zadovoljive rezultate (položajna odstopanja pod 1 m po izvedeni translaciji), terenskih meritev nismo opravili. Za popravo položajnih koordinat, izračunanih na podlagi koeficientov RPC, je zadoščala translacija, saj so koeficienti RPC zagotovili pravo merilo modela, sistematični vplivi pa niso vključevali rotacije. Standardni odklon je pri izračunu translacijskih parametrov znašal 0,58 m po osi Y in 0,44 m po osi X. Položajni srednji pogrešek je znašal 0,71 m (0,56 m po osi Y in 0,43 m po osi X). Georeferenciranje smo izvedli na ožjem območju z robnimi koordinatami v državnem koordinatnem sistemu:

Y: 449.050 m – 451.990 m; X: 71.350 m – 73.500 m.

Za testiranje metod za zajem stavb smo izbrali območje s površino 500 m x 500 m z robnimi koordinatami v državnem koordinatnem sistemu (slika 19):

Y: 450.155 m – 450.655 m; X: 72.340 m – 72.840 m.

Končne rezultate samodejnega iskanja in zajema stavb smo primerjali z grafičnim delom DTK 5.

Preglednica 6: Lastnosti stereopara IKONOS.

Table 6: IKONOS stereopair characteristic.

Stereopar IKONOS	Levi posnetek	Desni posnetek
Opis	pankromatski (PAN) in 4 multispektralni (MS) posnetki IKONOS-2	
Leto izdelave	2007	
Geografske koordinate robov [°]	$\varphi_1 = 45,7785973478$; $\lambda_1 = 14,2951001309$ $\varphi_2 = 45,8858349465$; $\lambda_2 = 14,3356945314$ $\varphi_3 = 45,8573277452$; $\lambda_3 = 14,4891600155$ $\varphi_4 = 45,7501442695$; $\lambda_4 = 14,4482921439$	
Datum	WGS84	
Predobdelava	GeoStereo Standard, MTFC da, DRA ne	
Radiometrična ločljivost	11-bitov, PAN, moder, zelen, rdeč, bližnji infrardeč kanal	
Prostorska ločljivost	1 m PAN, 4 m MS	
Orientacija	koeficienti RPC	
Kot snemanja [°]	77,67802	65,26796
Kot sončnih žarkov [°]	46,66187	49,60760
Pokritost z oblaki	21 %	12 %

Preglednica 6 opisuje lastnosti obeh posnetkov stereopara IKONOS.

5.3 GeoEye-1

V 6.3 opisujemo možnosti za odkrivanje in zajem stavb na posnetku satelita GeoEye-1 z območja Ljubljane. Preglednica 7 opisuje njegove lastnosti. Začetno masko stavb smo izdelali z nadzorovano klasifikacijo, ki temelji na objektivnem pristopu. Masko stavb smo izboljšali z uporabo anizotropne difuzije, nenadzorovane klasifikacije in rastjo regij. Maske nismo vektorizirali, saj so strehe stavb na posnetku premaknjene zaradi zelo velikega kota snemanja, pri katerem je bil izdelan posnetek (približno 63°). Pri obravnavi posnetka GeoEye-1 nismo uporabili višinskih podatkov. GeoEye-1 ima enako prostorsko ločljivost kot državni ortofoto. Ob uporabi DMP bi bila metoda preveč podobna metodi, opisani v 5.1, čemur smo se želeli izogniti.

Preglednica 7: Lastnosti posnetka GeoEye-1.

Table 7: GeoEye-1 image characteristic.

	GeoEye-1
Opis	pankromatski (PAN) in 4 multispektralni (MS) posnetki GeoEye-1
Leto izdelave	2009
Geografske koordinate robov [°]	$\varphi_1 = 46,0169030950; \lambda_1 = 14,4471799738$ $\varphi_2 = 46,1065096354; \lambda_2 = 14,4471799738$ $\varphi_3 = 46,1065096354; \lambda_3 = 14,5776442130$ $\varphi_4 = 46,0169030950; \lambda_4 = 14,5776442130$
Datum	WGS84
Predobdelava	Geo, MTFC da, DRA ne
Radiometrična ločljivost	11-bitov, PAN, moder, zelen, rdeč, bližnji infrardeč kanal
Prostorska ločljivost	0,5 m PAN, 2 m MS
Orientacija	koeficienti RPC
Kot snemanja [°]	62,98391
Kot sončnih žarkov [°]	54,34299
Pokritost z oblaki	8 %


Posnetek (10 km x 10 km) smo transformirali v državni koordinatni sistem z uporabo direktne linearne transformacije (DLT). Oslonilne točke (njihovo skupno število je 21) za

georeferenciranje celotnega posnetka smo izmerili na listih državnega ortofota DOF050 in digitalnega modela višin DMV 5. Položajni srednji pogrešek je po izvedeni transformaciji znašal 0,61 m (0,39 m po osi Y in 0,47 m po osi X). Po georeferenciranju posnetka z DLT smo izdelali ortofoto pankromatskega in multispektralnih kanalov z uporabo državnega DMV 5.

Za testiranje metod za zajem stavb smo izbrali območje s površino 550 m x 450 m z robnimi koordinatami v državnem koordinatnem sistemu (slika 19):

Y: 460.700 m – 461.250 m; X: 99.150 m – 99.600 m.

Končne rezultate samodejnega iskanja in zajema stavb smo primerjali z rezultati ročnega zajema stavb na posnetku GeoEye-1.



Slika 19: Posnetki in izbrana testna območja.

Figure 19: Images and selected test areas.

5.4 Ocena kakovosti samodejnega iskanja in zajema stavb

Po končanem postopku iskanja in zajema stavb smo rezultate ovrednotili. Kakovost pridobljenih rezultatov v doktorski nalogi podajamo z oceno samodejnega iskanja stavb, oceno pravilnosti vektorskega zajema stavb in oceno kakovosti rastrskega zajema stavb.

Oceno samodejnega iskanja stavb smo izračunali iz razmerja med odkritimi stavbami in vsemi stavbami na obravnavanem območju glede na referenčne podatke (posodobljen KS ali DTK 5 oziroma ročni zajem). Rezultate podajamo z odstotkom odkritih stavb. Izračunali smo tudi odstotek stavb, ki jih je samodejni postopek našel, vendar na posnetkih in v naravi dejansko ne obstajajo.

Pravilnost samodejnega vektorskega zajema stavb smo ocenili z vizualno primerjavo zajetih stavb in grafičnih podatkov obstoječe topografske baze. Kot pravilno zajete stavbe smo šteli tiste stavbe, ki v primerjavi z referenčnimi podatki položajno ne odstopajo več kot 1 piksel. Kot generalizirano zajete stavbe smo šteli tiste stavbe, ki so se od referenčnih podatkov razlikovale v manjših detajlih (npr. izpuščeni nadstreški stavb). Prešteli smo tudi stavbe, ki so bile v primerjavi z referenčnimi podatki zajete z občutno premajhno oziroma preveliko površino (zajeta okolica stavbe ali izpuščen večji del stavbe) ali pa njihova prostorska os odstopa od pravilne osi. Rezultate podajamo v odstotkih glede na celotno število stavb v referenčnih podatkih. Pri oceni pravilnosti vektorskega zajema stavb smo upoštevali le tiste stavbe v referenčnih podatkih, ki jih je samodejni postopek našel.

Oceno kakovosti rastrskega zajema stavb podajamo s klasifikacijsko matriko. V ta namen smo rasterizirali tako rezultate vektorskega zajema kot tudi referenčne podatke (KS ali DTK 5). Pri rasterizaciji smo pikslom znotraj vektorskih območij, ki jih določajo obodni poligoni stavb, pripisali vrednost 1, ostalim pikslom pa vrednost 0. Za izračun klasifikacijske matrike smo piksele, ki smo jih v postopku samodejnega zajema stavb na podobah prepoznali kot stavbe, primerjali z referenčnimi podatki. V doktorski nalogi smo uporabili klasifikacijsko matriko, v kateri piksele razvrstimo v štiri kategorije (Shufelt, McKeown, 1993):

- resnično pozitivni (RP): piksli, ki jih referenčni podatki in samodejni postopek označujejo kot stavbe;
- resnično negativni (RN): piksli, jih referenčni podatki in samodejni postopek označujejo kot ozadje (ne pripadajo stavbam);
- lažno pozitivni (LP): samo samodejni postopek označuje piksle kot stavbo;
- lažno negativni (LN): samo referenčni podatki označujejo piksle kot stavbo.

Z uporabo teh štirih kategorij smo izračunali statistične kazalce (27), s katerimi smo ocenili uspešnost samodejnega iskanja stavb:

$$\begin{aligned}
 \text{faktor razvejitve: } & \frac{LP}{RP}, \\
 \text{faktor pogreška: } & \frac{LN}{RP}, \\
 \text{odstotek odkritja: } & 100 \cdot \frac{RP}{RP+LN}, \\
 \text{odstotek kakovosti: } & 100 \cdot \frac{LP}{RP+LP+LN}.
 \end{aligned}
 \tag{27}$$

Faktor razvejitve (angl. branching factor) podaja mero za piksle, ki jih je samodejni postopek napačno prepoznal kot stavbe. Faktor pogreškov (angl. miss factor) izraža stopnjo neodkritih pikslov (samodejni postopek jih ni prepoznal kot stavbe). Odstotek odkritja podaja odstotek pikslov, ki jih je samodejni postopek pravilno prepoznal kot stavbe. Najstrožji kazalec je odstotek kakovosti, ki ocenjuje absolutno kakovost samodejnega zajema in podaja verjetnost, s katero samodejni postopek pravilno razvršča piksle. Pri oceni pravilnosti rastrskega zajema stavb smo upoštevali vse stavbe v referenčnih podatkih (tudi stavbe, ki jih samodejni postopek ni našel).

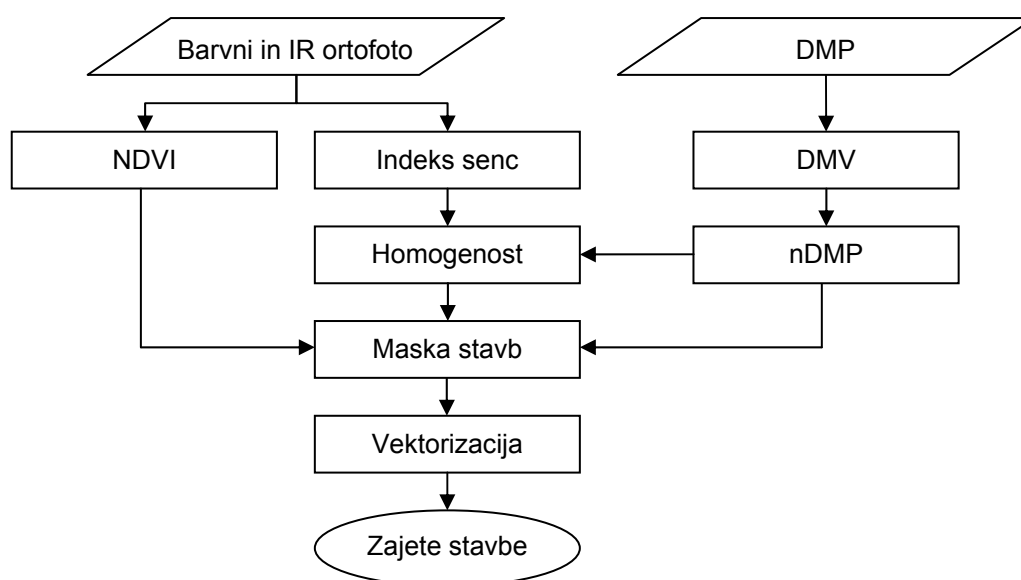
6 IZBRANE METODE ZA SAMODEJNO ODKRIVANJE IN ZAJEM STAVB

V poglavju opisujemo uporabo različnih podatkovnih virov in metod za samodejno iskanje in zajem stavb na visokoločljivih virih. Obravnavamo različne postopke s katerimi želimo potrditi hipotezo, da so visokoločljive podobe uporabne za samodejno odkrivanje stavb. V raziskavah smo uporabili nekatere že uveljavljene postopke, ki smo jih za pridobitev čim boljših rezultatov dodatno izboljšali in uporabili v novih kombinacijah. Razviti postopki temeljijo na izdelavi maske stavb, ki jo uporabimo za končno vektorizacijo.

V poglavju predstavljamo praktično delo, ki smo ga opravili med raziskavami za izdelavo disertacije. Detajlno opisujemo izboljšave ustaljenih postopkov, ki smo jih razvili za potrebe obdelave testnih podatkov. V prvem podpoglavju, kjer opisujemo uporabo digitalnega ortofota in podatkov laserskega skeniranja, je glavni doprinos uporaba indeksa senc za izboljšavo končne maske stavb. V drugem podpoglavju obravnavamo stereopar podob IKONOS, iz katerega smo v prvi fazi izdelali ortofoto in normalizirani digitalni model površja (nDMP), v nadaljnjih korakih pa smo za iskanje stavb uporabili enoslikovne metode. Končno masko stavb smo izdelali z izvorno kombinacijo metod, razvito za potrebe doktorske naloge in sloni na uporabi anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. V tretjem podpoglavju opisujemo postopek iskanja stavb na posnetku GeoEye-1. Prvotno masko stavb smo izdelali v komercialni programski opre, za njeno izboljšavo pa smo uporabili metodo, izdelano pri obravnavi stereopara IKONOS, s tem da smo barvno segmentacijo in rast regij združili v en korak v katerem smo rast regij izvedli na barvni podobi.

6.1 Digitalni ortofoto in digitalni model površja

V tem podpoglavju opisujemo možnosti iskanja stavb s kombiniranjem visokoločljivih slikovnih virov (ortofoto) in podatkov laserskega skeniranja. Uporabili smo podatke barvnega ortofota DOF050, bližnjega infrardečega ortofota DOF100IR (opis v 3.2) in izvedene podatke laserskega skeniranja: digitalni model površja (DMP) in digitalni model višin (DMV), oba v rastrskem zapisu in s prostorsko ločljivostjo 0,5 m. Poudarek je na uporabi izvedenih podatkov laserskega skeniranja, kjer nimamo podatkov o različnih odbojih, ampak obravnavamo le končna izdelka. Metoda je zato uporabna tudi v primeru, da imamo na razpolago natančen DMP, pridobljen iz drugačnega vira (npr. fotogrametrični zajem).



Slika 20: Diagram poteka zajema stavb na ortofotu in digitalnem modelu površja.

Figure 20: Building extraction from orthophoto and digital surface model flowchart.

Postopek lahko strnemo v naslednje korake:


- izdelava normaliziranega digitalnega modela površja (nDMP),
- izločitev vegetacije na podlagi multispektralnega DOF,
- izdelava maske stavb,
- zajem stavb z iskanjem linij, ki opisujejo posamezne objekte na maski.

V okviru doktorske naloge smo masko stavb dodatno izboljšali z izdelavo indeksa senc in analizo teksture nDMP. Najdene linije na maski smo vektorizirali z uporabo Houghove transformacije. Slika 20 orisuje potek zajema. Poleg prikazanih postopkov smo uporabili še vrsto morfoloških operacij za odstranjevanje nepravilnosti v maski stavb.

Slike v tem poglavju zaradi nazornosti predstavljajo le izrez območja, na katerem so bili postopki testirani.

6.1.1 Izračun normaliziranega digitalnega modela površja (nDMP)

Razlika med DMP in DMV predstavlja normaliziran digitalni model površja (nDMP). Na njem so vključeni le objekti, ki segajo nad zemeljsko površino. Iz nDMP je bila izdelana maska, ki vključuje le tista območja, kjer je možnost, da se nahajajo stavbe. Pri izdelavi maske je bil uporabljen prag 2 m (glede na Operativno navodilo za zajem stavb, se v topografskih bazah vodijo le stavbe, ki so višje od dveh metrov). Slika 21 prikazuje DMV (a), DMP (b) in masko nDMP (c). Poleg stavb vsebuje maska še ostale objekte, ki so višji od dveh metrov. Ti objekti v glavnem predstavljajo vegetacijo (drevesa).



Slika 21: DMV, DMP in maska nDMP.

Figure 21: DTM, DSM and nDSM mask.

Poudariti je treba, da smo opisano metodo testirali na relativno ravnem terenu, kjer se običajno nahajajo gosto naseljene površine. Analizo napak, ki bi se lahko pojavile na maski nDMP v primeru razgibanega terena, nismo opravili.


6.1.2 Izračun vegetacijskega indeksa in indeksa senc

Maska, ki smo jo naredili iz nDMP, še vedno vsebuje vegetacijo, ki sega 2 m nad površino tal (drevesa, ...). Vegetacijo odstranimo iz maske z uporabo vegetacijskega indeksa, ki ga običajno izračunamo iz rdečega in bližnjega infrardečega kanala. Ortofoto, pridobljen na Geodetski upravi, ne vsebuje izvornega rdečega in infrardečega kanala. Radiometrična ločljivost barvnega (DOF050) in bližnjega infrardečega (DOF100IR) ortofota je 24-bitna, pri čemer sta oba sestavljena iz treh 8-bitnih slojev, ki vsebujejo vrednosti za rdečo, zeleno in modro barvo za računalniški prikaz. Ker sta prostorski ločljivosti navedenih ortofotov različni (0,5 m za DOF050 in 1 m za DOF100IR), je treba bližnji infrardeči ortofoto izostriti na prostorsko ločljivost 0,5 m. Zaradi tovrstnega zapisa ortofotov smo v raziskavi uporabili svojo metodo za izračun vegetacijskega indeksa, ki temelji na uporabi bližnjega infrardečega ortofota, zapisanega v barvnem prostoru RGB in popravi vegetacijskega indeksa z indeksom senc ter analizo teksture.

Slika 22 v zgornji vrsti prikazuje rdeč (a), zelen (b) in moder (c) sloj DOF050. Ustrezni sloji DOF100IR so prikazani v spodnji vrsti. Z vizualno interpretacijo vseh slojev ugotovimo, da ima vegetacija najvišje vrednosti tonov na rdečem sloju DOF100IR (d) in najnižje vrednosti tonov na zelenem sloju DOF100IR (e). Ta dva zato uporabimo za izračun normaliziranega diferencialnega vegetacijskega indeksa NDVI (26):

$$\text{NDVI} = \frac{IR-R}{IR+R}, \quad (26)$$

v katerem kot kanal R uporabimo zeleni, kot kanal IR pa rdeči sloj, oba izostrena na prostorsko ločljivost 0,5 m. Ker v enačbi (26) nismo porabili klasičnih kanalov za izračun NDVI (rdeč in bližnji infrardeč kanal), lahko govorimo o modificiranem vegetacijskem indeksu NDVI.



Slika 22: Rdeči, zeleni in modri sloj barvnega ortofota DOF050 (zgornja vrsta) in izostrelega bližnjega infrardečega ortofota DOF100IR (spodnja vrsta).

Figure 22: Red, green and blue layer of color orthophoto DOF050 (top row) and pan-sharpened near infrared orthophoto DOF100IR (bottom row).

Razen vegetacije imajo, v primerjavi z zelenim slojem, na rdečem sloju višje vrednosti tonov tudi sence. Modificiran NDVI jih zato razvrsti kot vegetacijo. Uporaba modificiranega NDVI za izločanje vegetacije iz nadaljnje obdelave podatkov tako povzroči nevarnost, da iz obdelave izpadejo osenčeni deli stavb. Pred nadaljnjim postopkom moramo zato odkriti sence, ki se pojavljajo na stavbah.

Sence na podobah prepoznamo z izračunom indeksa senc (SI). Ono in sod. (2007) predlagajo popravo vegetacijskega indeksa z normalizacijo kanalov v obdelavi z njihovimi aritmetičnimi sredinami. Izračun normaliziranih vrednosti kanalov R_d podaja enačba (28):

$$R_d^{(i)} = \frac{r_d^{(i)}}{\frac{1}{N} \sum_{j=1}^N r_d^{(j)}}, \quad (28)$$


kjer predstavljajo r_d izvoren odboj, i je oznaka kanala in N število kanalov v obdelavi. Za izračun normaliziranih kanalov smo uporabili vseh šest slojev digitalnega ortofota. Indeks senc (SI) pridobimo z razliko med normaliziranim in izvornim kanalom (Ono in sod., 2007). Za izračun SI uporabimo izostren rdeči sloj DOF100IR (29):

$$SI = R_d^{rIR} - r_d^{rIR}. \quad (29)$$

Pred izračunom SI smo iz normaliziranega kanala R_d^{rIR} odstranili šum s filtrom mediana velikosti 3 x 3.

Izdelavo maske stavb in popravo vegetacijskega indeksa zaradi senc izvedemo v nekaj skupnih korakih. Z modificiranim NDVI izdelamo masko območja, ki ne vsebuje vegetacije (za prag smo uporabili empirično vrednost 0,36). S konjunkcijo maske, ki izključuje vegetacijo in maske nDMP izdelamo masko stavb, ki ne vsebuje osenčenih delov stavb. To masko v nadaljevanju dopolnimo. Najprej izračunamo indeks senc (SI) in iz njega izdelamo masko senc (SI prevzorčimo na razpon vrednosti med 0 in 1, za sence uporabimo prag 0,08). S konjunkcijo maske SI in maske nDMP dobimo območja, ki vključujejo sence, ki se pojavljajo na območjih, ki segajo nad površino tal (stavbe, vegetacija idr.). Sence, ki ne ležijo na stavbah, izločimo iz maske z analizo teksture. Vegetacija ima na nDMP bolj grobo teksturo od osenčenih streh. Za ločevanje senc na stavbah in vegetaciji izračunamo podobo homogenosti, ki je ena od mer za teksturo. Homogenost pridobimo iz matrike relativnih frekvenc $P(i, j)$, ki izraža pojavnost dveh sosednjih pikslov na podobi ali delu podobe, enega z intenziteto i in drugega z intenziteto j (Haralick in sod., 1973). Homogenost izračunamo (30):

$$f = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(\frac{P(i, j)}{R} \right)^2. \quad (30)$$



Slika 23: Izdelava maske stavb.

Figure 23: Building mask elaboration.

V enačbi (30) predstavlja N_g zalogo intenzitet v podobi, R je konstanta, s katero normaliziramo podobo. Homogenost je bila izračunana s filtrom velikosti 3×3 . Kot kandidati za stavbe so bila obdržana območja s homogenostjo višjo ali enako 0,9, odstranjene so bile površine, ki merijo manj kot 2 m^2 , robovi stavb pa zabrisani z morfološkim zapiranjem s


strukturnim elementom disk velikosti 4. Prvotno masko stavb nato dopolnimo s sencami, ki imajo na maski nDMP vrednost 1 in imajo veliko homogenost.

Slika 23 prikazuje potek izdelave maske stavb. V zgornji vrsti so prikazani barvni ortofoto za predstavitev območja (a), NDVI (b) in prvotna maska stavb, ki ne vključuje osenčenih delov stavb (c). Srednja vrsta prikazuje SI (d) (kontrast je izboljššan z linearnim raztegom histograma z nasičenjem 2,5 %), masko senc (e) in konjunkcijo maske senc z masko nDMP (f). Zadnja vrsta prikazuje podobo homogenosti (g), območja, s katerimi dopolnimo masko stavb (h) (izločena osenčena vegetacija) in masko stavb (i).

6.1.3 Nadaljnje obdelave maske stavb

Maska stavb še vedno vsebuje nekatere nepravilnosti, ki jih je treba odpraviti pred zaključnimi postopki iskanja stavb. Nepravilnosti so lahko posledica raznih objektov, ki so višji od dveh metrov in ne predstavljajo stavb (ograje, tovornjaki), šuma v DMP-ju, napak v izračunu vegetacijskega indeksa in indeksa senc.

Sledi vrsta morfoloških operacij, s katerimi popravimo masko stavb. Masko najprej zakrpamo, tako da v njej zapolnimo luknje. Paziti moramo, da ob tem ne zapolnimo lukenj, ki predstavljajo interjerje stavb (odstranjene so bile luknje, manjše od 3 m²). Iz maske nato odstranimo objekte, ki so tanjši od 1,5 m. Postopek opravimo z morfološkim odpiranjem s strukturnimi elementi z obliko -, |, / in | z razsežnostjo 3. Iz maske odstranimo še objekte, ki imajo površino manjšo od 4 m² (glede na Operativno navodilo za zajem stavb, se v topografskih bazah vodijo le stavbe, ki imajo površino večjo od 4 m²). Tako dobimo masko, na kateri se zanesljivo nahajajo le stavbe. To masko uporabimo kot zaznamovalec (angl. marker) v operaciji morfološkega odpiranja z rekonstrukcijo, s katerim obdelamo prvotno masko stavb. Rekonstruirana maska stavb je eden od vhodnih podatkov za končni zajem stavb.




Slika 24: Popravljen maska stavb.

Figure 24: Corrected building mask.

Slika 24 prikazuje začetno masko stavb (a), zaznamovalec (b), ki vsebuje le še stavbe in rekonstruirano masko stavb (c). Nepravilne oblike stavb na končni maski so v glavnem posledica visoke vegetacije, ki prekriva nekatere strehe, šuma v podatkih nDMP in manjših pogreškov v predhodni obdelavi. Napake niso moteče, saj bo tako pridobljena maska uporabljena le za test površin pri zajemu stavb (opis v 6.1.4) in nadaljnjo pripravo maske nDMP za končni zajem stavb.

Drug vhodni podatek v zajem stavb je maska nDMP, na kateri bomo izvajali zajem. Pred tem je treba opraviti še nekatere izboljšave. Pred končnim zajemom želimo izdelati takšno masko nDMP, da bo en objekt na maski predstavljal eno stavbo oziroma več stavb, če se te v prostoru dotikajo. Na začetku ločimo med seboj objekte v maski, ki so povezani le z enim pikslom in masko odpremo z rekonstrukcijo z že omenjenim zaznamovalcem stavb. Ostale stavbe na maski ločimo s popravljen masko stavb, ki jo zaradi tega še dodatno obdelamo: nepravilnosti na zunanjih obrisih stavb zbrisemo z morfološko erozijo s strukturnim elementom diamant 1, ponovno odstranimo objekte in luknje s površino pod 4 m^2 , zapremo vsak objekt posebej s kvadratom razsežnosti 3×3 (zapiranje vsakega objekta posebej je pomembno, sicer bi združili objekte, ki so zelo blizu skupaj) in razširimo objekte za 2 m v vse strani (le če to ne povzroči združevanje objektov). S konjunkcijo tako dobljene maske stavb in maske nDMP dobimo masko nDMP, kjer so stavbe med seboj ločene. Na maski, pridobljeni s konjunkcijo, zbrisemo objekte, ki se dotikajo stranic območja, odstranimo objekte in luknje

pod 4 m^2 in izdelamo zunanje obrise objektov. Ti obrisi predstavljajo glavni vhodni podatek za končni zajem stavb.



Slika 25: Izdelava obrisov stavb iz maske nDMP.

Figure 25: Building outlines from nDSM mask elaboration.

Slika 25 prikazuje nDMP (a), obdelano masko nDMP (b), ki vsebuje ločene stavbe in obrise stavb (c).

6.1.4 Zajem stavb

Končni zajem stavb izvedemo na izdelanih obrisih stavb, pridobljenih iz nDMP. V obdelavo vključimo še popravljeno masko stavb. Podoba obrisov je rastrska, obrisi niso predstavljeni z ravnimi linijami, kot jih pričakujemo pri stavbah, koti med linijami obrisa niso pravi. Končne obrise stavb zato izdelamo z uporabo Houghove transformacije. To smo v program za zajem vgradili s transformacijo Radon. V zajemu obravnavamo vsak obris posebej.


Potek zajema:

- iskanje orientacije oziroma glavne osi stavbe. S transformacijo Radon poiščemo os, vzdolž katere se razteza stavba. Iskanje izvedemo v smereh od 0° do 180° s korakom pol stopinje. Ker so linije obrisa nepravilne, za vsako stavbo poiščemo dve smeri osi.

Če se smeri med seboj razlikujeta, obdržimo tisto smer, ki je bližja smerem osi sosednjih objektov;

- iskanje vseh premic, ki so vzporedne glavni osi stavbe in opisujejo obris stavbe. Premice iščemo, dokler je največja vrednost v matriki transformacije Radon R_{max} večja ali enaka 3,25 oziroma poiščemo vsaj dve vzporedni premici. Parameter 3,25 pomeni, da na premici verjetno ležijo vsaj 3 piksli, ki označujejo obris stavbe (transformacija Radon razdeli vsak piksel na štiri podpiksle; glej 4.5.2). Premice iščemo na medsebojni oddaljenosti 0,5 m, kar v našem primeru predstavlja velikost enega piksla;
- ker predvidevamo, da imajo stavbe pravokotne stranice, na enak način poiščemo še vse pravokotne premice, ki opisujejo obris stavbe. Pogoj za prenehanje iskanja premic vzdolž osi, ki je pravokotna na glavno os stavbe, nekoliko omilimo ($R_{max} \geq 2,75$ oziroma poiščemo vsaj dve pravokotni premici);
- poiščemo presečišča med seboj pravokotnih premic in iz njih izdelamo pravokotnike;
- vsi pravokotniki ne opisujejo stavbe, zato testiramo vsakega izmed njih. Če je razmerje med površino, ki jo tvori presek pravokotnika s popravljen masko stavb, in površino, izračunano iz oglišč pravokotnika, večje od 0,6, pravokotnik obdržimo, sicer ga zavržemo. Pri obravnavanju interjerjev stavb je test površine izveden z negacijo popravljen maske stavb;
- končni obris stavbe oziroma njenega interjerja izdelamo s polilinijo, ki orisuje obod obdržanih pravokotnikov.

Slika 26 opisuje zajem stavb. Za predstavitev sta izbrani le dve stavbi. Zgornja vrsta prikazuje glavno os stavbe na rastrskem obrisu stavbe (a), glavno os stavbe na nDMP (b) in najdene premice z oglišči, ki opisujejo obris stavbe (c). Srednja vrsta prikazuje izdelane pravokotnike na rastrskem obrisu stavb (d), iste pravokotnike na popravljeni maski stavb (e) in obdržane pravokotnike na obrisu (f). Zadnja vrsta na sliki prikazuje rezultate zajema stavb: na obrisu stavb (g), na nDMP (h) in na barvnem ortofotu DOF050 (i). Obrisi stavb so na barvnem ortofotu videti nekoliko premaknjeni. Dejansko so premaknjene strehe stavb na ortofotu. Premik je posledica izdelave ortofota z uporabo DMV (Kraus, 2007). DMV opisuje zemeljsko površje in ne vključuje stavb.




Slika 26: Zajem stavb na DMP.

Figure 26: Building extraction on DSM.

Če stavbe na obravnavanem območju nimajo pravokotnih oblik, lahko poiščemo premice, ki opisujejo obris stavbe v poljubnih smereh. V tem primeru namesto pravokotnikov izdelamo trikotnike. Sosednja presečišča premic poiščemo z Delauneyevo triangulacijo. Test površin seveda izvedemo z izračunom površine trikotnikov.

6.1.5 Rezultati zajema stavb in analiza

Po nastavitvi pragov za izračun mask iz raznih indeksov, poteka zajem stavb povsem samodejno. Razen podobe, ki opisuje homogenost območja, smo vse ostale korake sprogramirali v programu Matlab. Podobo homogenosti smo izdelali v programu ENVI. Podoba homogenosti predstavlja v kombinaciji z indeksom senc izvorni korak v postopku, s katerim smo izboljšali masko stavb. Slika 27 prikazuje rezultate zajema stavb v primerjavi z nDMP (a) in barvnim ortofotom DOF050 (b).




Slika 27: Rezultati zajema stavb na podatkih laserskega skeniranja prikazani na nDMP in DOF050.

Figure 27: Results of building extraction from laser scan data presented on nDSM and DOF050.

Po končanem zajemu smo rezultate primerjali s podatki aktualnega katastra stavb (KS). Slika 28 prikazuje primerjavo rezultatov zajema (rdeča barva) s KS (modra barva) (a) ter superimpozicijo KS in DOF050 (b). Pomembno je poudariti, da je bil KS za to območje izdelan s terestričnimi meritvami. Pri teh je bil obod stavb določen z meritvami temeljev, kar se razlikuje od fotogrametričnega zajema, pri katerem zajemamo obode streh. Posledično

imajo stavbe v KS manjšo površino. Premik obodov streh na DOF050 je posledica položajnega pogreška ortofota, izdelanega z uporabo DMV, ki ne vključuje stavb.



Slika 28: Primerjava rezultatov zajema stavb s katastrom stavb.

Figure 28: Comparison of building extraction results with building cadastre.

Analizo rezultatov zajema stavb smo zato izvedli s pregledovanjem podatkov KS, DOF050 in DMP ter terenskim ogledom. Glede na KS se na obravnavanem območju nahaja 117 stavb. Samodejni zajem je odkril nekatere spremembe: dodatno je bilo najdenih 5 stavb, v dveh primerih je samodejni postopek zaradi novih prizidkov pravilno združil po 3 stavbe v eno, v štirih primerih sta bili iz istega razloga združeni po dve stavbi. Skupaj je bilo najdenih enajst novih prizidkov. Terenski ogled je pokazal, da dveh stavb, ki ju vodi KS, v naravi ni več, ena dejansko ni stavba (ograjen prostor za smetnjake brez nadstreška). Glede na ugotovljene spremembe se na obravnavanem območju nahaja 111 stavb. Od teh 111 stavb, je bilo glede na primerjavo podatkov nDMP in DOF050 ter obliko stavb v KS, povsem pravilno zajetih 41 stavb, 56 pa se je od podatkov razlikovalo le v manjših detajlih. V večini teh 56 primerov gre za izpuščene nadstreške nad vhodnimi vrati stavb ali balkone, ki jih samodejni postopek ni zaznal, nekatere so posledica vegetacije (drevesa), ki prekriva dele stavbe. Tri stavbe so bile zajete z manjšo površino, kot jo imajo v naravi. Razlog za izgubo površine teh stavb je

vegetacija, ki je nad stavbami. Štiri stavbe so bile zajete s pravilno obliko, vendar se orientacija glavne osi razlikuje od dejanske. Os stavbe je bila določena napačno zaradi dreves, ki so onemogočila prepoznavanje celotne stavbe. Ena stavba je bila zajeta neustrezno, ker ni pravokotna. Boljši rezultat pri tej stavbi bi pridobili, če bi v samodejni postopek vgradili iskanje premic, ki opisujejo obod stavbe, pod kotom 45° glede na glavno os. Šest stavb samodejni postopek zajema ni zaznal. V teh primerih je šlo za stavbe z manjšo površino. Dve smo nehote odstranili v postopku morfološkega odpiranja z rekonstrukcijo, štiri pa samodejni postopek ni odkril, ker jih v naravi skoraj v celoti prekrivajo drevesa (3 vrtna lopa in ena lesena garaža). Na območju smo zajeli 7 stavb, ki dejansko ne obstajajo v naravi. Vse so imele manjšo površino in so se pojavile na asfaltnih površinah ali na robovih dreves. Preglednica 8 prikazuje oceno samodejnega iskanja stavb, preglednica 9 pa oceno pravilnosti samodejnega vektorskega zajema stavb na DOF050 in DMP v primerjavi s KS.

Preglednica 8: Ocena samodejnega iskanja stavb na DOF050 in nDMP.

Table 8: Evaluation of the automatic building detection on DOF050 and nDSM.

	Število	%
Vse stavbe glede na KS	111	100
Odkrite stavbe	105	94,6
Neobstoječe stavbe v naravi	7	5,9

Preglednica 9: Ocena pravilnosti vektorskega zajema stavb na DOF050 in nDMP.

Table 9: Vectorization of buildings on DOF050 and nDSM accuracy evaluation.

	Število	%
Pravilno zajete	41	39,0
Generalizirane	56	53,3
Napačna površina	3	2,9
Napačna orientacija	4	3,8
Drugo	1	1,0

Oceno kakovosti rastrskega zajema stavb na DOF050 in DMP lahko opišemo s klasifikacijsko matriko. Za referenčni podatek smo uporabili rasteriziran KS, ki smo ga dopolnili z

novogradnjami. Odstranili smo tudi stavbe, ki jih v naravi ni več. Rezultate podaja preglednica 10. Končno kakovost zajema znižuje predvsem visok faktor razvejitve. Kot smo že omenili, imajo stavbe, ki smo jih izdelali z vektorizacijo obodov streh, večjo površino od stavb v katastru stavb, ki je bil izdelan z merjenjem temeljev stavb.

Preglednica 10: Ocena kakovosti rastrskega zajema stavb na DOF050 in nDMP.

Table 10: Building extraction on DOF050 and nDSM quality assessment.

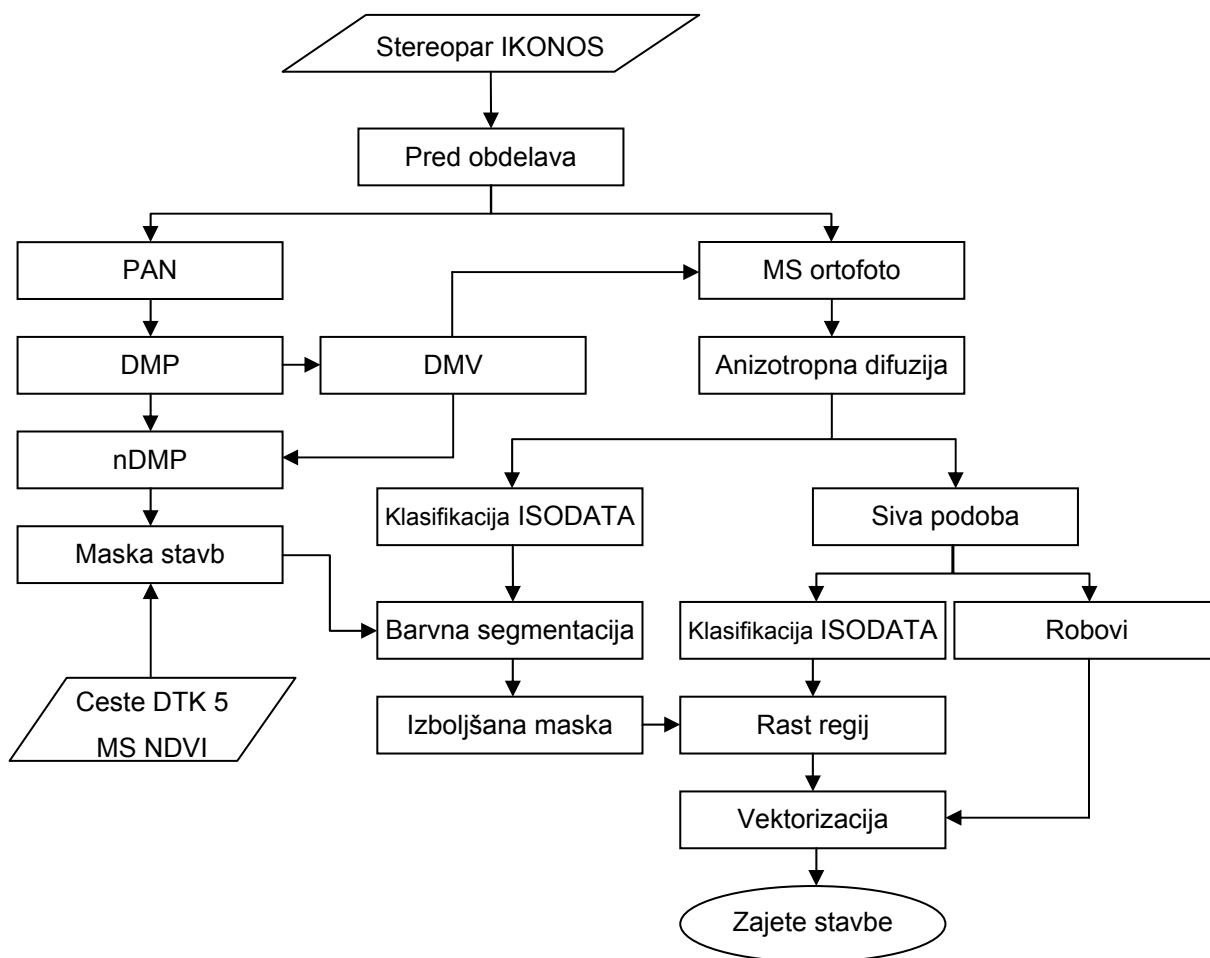
Faktor razvejitve	Faktor pogreška	% odkritja	% kakovosti
0,34	0,04	95,87	71,94

Končni komentar samodejnega zajema je tako naslednji: podatki DMP s prostorsko ločljivostjo 0,5 m, iz katerih je bil izdelan nDMP, niso uporabni za samodejni zajem stavb v topografske baze velikih meril (1 : 5000). Stavbe z enostavno obliko in le deloma prekrte z vegetacijo samodejni postopek prepozna pravilno, skoraj polovica stavb pa je zajeta brez manjših detajlov (nadstreški, balkoni). Rezultat bi lahko bistveno izboljšali, če bi imeli na voljo DMP z višjo prostorsko ločljivostjo (npr. 0,25 m). Vseeno pa so ti podatki omogočili odkrivanje večine sprememb v prostoru in so povsem primerni za iskanje sprememb in kontrolo pravilnosti zajema podatkov v KS in DTK 5. Odstopanja podatkov samodejnega zajema glede na dejanske podatke ne presegajo štirih pikslov (kar v našem primeru znaša 2 m). Zato so ti podatki in opisani postopek primerni za zajem stavb v topografske baze manjših meril (1 : 10.000 in manjša). V skladu s hipotezo naloge se je izkazalo, da je uporaba višinskih podatkov v kombinaciji z visokoločljivimi slikovnimi viri pomembna pri odkrivanju sprememb v topografskih bazah podatkov.

6.2 Stereopar IKONOS

V tem podpoglavju obravnavamo možnosti samodejnega iskanja in zajema stavb na posnetkih IKONOS. Za testiranje hipoteze smo uporabili stereopar podob z območja Cerknice, iz katerega smo izdelali digitalni model površja (DMP) in digitalni model višin (DMV). Iz njiju smo izračunali normaliziran digitalni model površja (nDMP). Po izdelavi DMV smo izdelali

ortofote iz posameznih kanalov. Po pridobitvi DMV je nadaljnji postopek slonel na enoslikovnih metodah. Obravnavano območje ima bolj podeželske kot urbane značilnosti z veliko majhnih družinskih hiš, ki imajo različno orientacijo v prostoru. Klasični obstoječi postopki, ki jih opisujejo različni avtorji in združujejo uporabo nDMP in nadzorovano klasifikacijo (Lee, Shan, Bethel, 2003, Koc San, Turker, 2007), niso dali zadovoljivih rezultatov. Za potrebe disertacije smo zato izdelali metodo, ki sloni na izvorni kombinaciji uporabe anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. Prvotno masko smo izdelali na podlagi nDMP, kasneje pa smo jo dopolnili z uporabo barvne segmentacije. Končno masko smo izdelali z rastjo regij in jo vektorizirali s Houghovo transformacijo.



Slika 29: Diagram poteka zajema stavb na ortofotu in digitalnem modelu površja

Figure 29: Building extraction from IKONOS stereopair flowchart.

Slika 29 orisuje potek zajema. Poleg prikazanih postopkov smo uporabili še niz morfoloških operacij za odstranjevanje nepravilnosti v maski stavb.

6.2.1 Priprava podatkov

V nadaljevanju podajamo opis korakov, s katerimi smo pripravili podatke za iskanje stavb. Multispektralne posnetke smo izostrili s pankromatskima posnetkoma na prostorsko ločljivost 1 m. Za širše območje smo izdelali DMV s celično mrežo 5 m. DMV (kot tudi vsi ostali višinski podatki, omenjeni v nadaljevanju) smo izdelali v programu Socet Set. Njegov programski modul NGATE omogoča samodejno izdelavo DMP in različne morfološke operacije, s katerimi iz DMP odstrani objekte, ki ne pripadajo reliefu. Iz vseh kanalov obeh posnetkov stereopara smo izdelali ortofote. Orientacijo stereopara smo vzpostavili iz koeficientov RPC, ki smo jih pridobili skupaj s posnetki (opis modela sensorja RPC v 4.1.2.1). Za georeferenciranje ortofotov v državni koordinatni sistem je zadoščala translacija. Devetnajst oslonilnih točk za georeferenciranje smo izmerili na državnem ortofotu DOF050 in pankromatskem ortofotu IKONOS. Standardni odklon je pri izračunu translacijskih parametrov znašal 0,58 m po osi X in 0,44 m po osi Y.

Za potrebe iskanja in zajema stavb smo iz pankromatskih podob na testnem območju izdelali DMP in DMV s celično mrežo 1 m. Pred njunim zajemom smo podobi stereopara izboljšali. Iz podob smo odstranili šum z uporabo filtra Lee-Sigma, z Wallisovim filtrom smo izboljšali kontrast, robove pa poudarili z visokoprepustnim Laplaceovim filtrom. Med izboljšavo smo z linearnim raztegom histograma izvorni podobi raztegnili v polno radiometrično ločljivost 11 bitov. DMP smo izdelali povsem samodejno brez nadaljnega urejanja. Ker program pri izdelavi DMV ni odstranil čisto vseh objektov, ki ne pripadajo reliefu, smo DMV naknadno še ročno izboljšali z uporabo orodij, ki omogočajo urejanje površin (polnjenje večjih lukenj in ustvarjanje ravnih ploskev) in zgladili s filtrom povprečenja velikosti 3 x 3. Izboljšavo DMV smo izvedli le v okolici stavb, napake, ki so se na DMV pojavile na območju cest smo kasneje odstranili z uporabo maske cest, napake na območjih vegetacije pa smo odstranili z uporabo vegetacijskega indeksa (opis v 6.2.2).

6.2.2 Izdelava začetne maske stavb


Po pridobitvi višinskih podatkov poteka nadaljnji postopek odkrivanja stavb z enoslikovnimi postopki. Za obdelavo smo izbrali pankromatski in multispektralne kanale levega posnetka stereopara, ki ima malenkost boljše radiometrične značilnosti in je manj obremenjen z oblaki. Slika 30 prikazuje izbrano območje, na katerem smo testirali postopke. Prikaz na sliki ima izboljššan kontrast z linearnim raztegom z nasičenjem 2 %. Za zajem stavb bi bil nadirni posnetek sicer boljši, vendar ga nismo imeli na razpolago.



Slika 30: Pankromatski kanal (a) in barvni kompozit rdečega, zelenega in modrega kanala (b).

Figure 30: Panchromatic band (a) and color composite of red, green and blue band (b).

Iz DMP in DMV s prostorsko ločljivostjo 1 m smo izračunali nDMP. Z uporabo praga 2 m (glede na Operativno navodilo za zajem stavb, se v topografskih bazah vodijo le stavbe, ki so višje od dveh metrov) smo iz nDMP izdelali začetno masko, ki vsebuje kandidate za stavbe, poleg tega pa tudi vegetacijo in ostale objekte, ki so višji od dveh metrov. Slika 31 prikazuje DMP (a), DMV (b) in masko nDMP (c).



Slika 31: DMP, DMV in maska nDMP.

Figure 31: DSM, DEM and nDSM mask.

Visoko vegetacijo in eventualne napake začetne maske zaradi napak v DMV odstranimo z uporabo normaliziranega diferencialnega vegetacijskega indeksa (NDVI), ki ga izračunamo iz rdečega (R) in bližnje infrardečega kanala (IR) (26):

$$NDVI = \frac{IR - R}{IR + R}. \quad (26)$$

Za prag v NDVI, s katerim je bila izločena vegetacija, smo izbrali vrednost 0,2.

Za obravnavano območje smo imeli na razpolago tudi podatke iz baze DTK 5. Ker predvidevamo, da na obstoječih cestah ne bo novogradenj, smo iz začetne maske odstranili tudi obstoječe ceste. Za ta namen smo izdelali masko cest. Za širino cest v maski smo uporabili atributne podatke DTK 5. Slika 32 prikazuje masko NDVI (a), masko cest (b) in izboljšano masko kandidatov za stavbe, iz katere smo odstranili vegetacijo in ceste (c).




Slika 32: Maska NDVI, maska cest in izboljšana maska stavb.

Figure 32: NDVI mask, road mask and enhanced building mask.

Višinski podatki, pridobljeni iz stereopara podob IKONOS, niso natančni kot na primer lidarske meritve. Kandidati za stavbe, predstavljeni na maski, tako nimajo pravih oblik, posamezni objekti na maski so običajno večji od dejanske oblike stavbe. Masko je zato potrebno ustrezno skrčiti, tako da bi bile na njej označene samo stavbe ali vsaj njihovi deli. Postopek opravimo z morfološkimi operacijami nad binarno podobo. Iz maske odstranimo majhne objekte. Glede na Operativno navodilo za zajem stavb, se v topografskih bazah vodijo le stavbe, ki imajo površino večjo od 4 m^2 , zaradi že omenjene slabše natančnosti višinskih podatkov prag povečamo na 6 m^2 . Objekte na maski skrčimo z erozijo (uporabili smo strukturni element disk velikosti 1), odstranimo objekte, ki se dotikajo roba in skrčimo obode objektov za 1 piksel. S filtrom večine, ki pikslu dodeli vrednost 1, če ima vsaj 5 pikselov v njegovi 3×3 okolici vrednost 1, nadaljnje očistimo masko. Zapremo še vse luknje v maski. Slika 33 prikazuje masko stavb pred (a) in po čiščenju (b).

Na očiščeni maski naj bi tako ostali le kandidati za stavbe oziroma deli stavb. Takšno masko v nadaljevanju uporabimo kot osnovo za iskanje stavb, ki jih zaradi samodejnega zajema višinskih podatkov še nismo odkrili.



Slika 33: Čiščenje maske stavb.


Figure 33: Building mask cleaning.

6.2.3 Izboljšava maske stavb z barvno segmentacijo

Samodejni zajem višinskih podatkov ni popoln, na DMP se pojavljajo tudi v naravi neobstoječi objekti ali pa postopek objektov zaradi njihove majhnosti ne zazna. V naravi neobstoječe objekte v glavnem odstranimo z že opisanimi postopki (vegetacijski indeks, maska cest, morfološka obdelava). Treba pa je poiskati tudi objekte, ki jih na maski ni. Nekateri avtorji (npr. Koc San, Turker, 2007) predlagajo dopolnitev maske stavb z nadzorovano klasifikacijo. Vendar je postopek izdelave dobrih vzorcev rabe tal za nadzorovano klasifikacijo v postopku samodejnega iskanja stavb lahko preveč zamuden. V doktorski nalogi za ta namen predlagamo barvno segmentacijo na osnovi obstoječe maske in nenadzorovane klasifikacije, ki omogoča povsem samodejno iskanje. Za barvno segmentacijo je treba multispektralne podobe prej še ustrezno pripraviti.

Pankromatski in multispektralni kanali satelita IKONOS so močno obremenjeni s šumom (poglavje 3.3.1.2). Poleg tega želimo pred uporabo barvne segmentacije čim bolj poenotiti barve, s katerimi je predstavljen posamezen objekt. Iz vsakega multispektralnega kanala

posebej najprej z morfološkim odpiranjem z rekonstrukcijo, ki mu sledi morfološko zapiranje z rekonstrukcijo, odstranimo manjše detajle (npr. dimniki), ki bi ovirali pravilno izvedbo barvne segmentacije (Yang, Liu, Zhong, 2008). Uporabili smo strukturni element disk velikosti 1. Za tem uporabimo anizotropno difuzijo, ki močno zgladi podobo in s tem odstrani šum, obenem pa ohranja robove med ploskvami. Vse štiri multispektralne kanale smo nato prevzorčili iz 11-bitnih v 8-bitne podobo z linearnim raztegom z nasičenjem 2 %. Razteg histograma smo izvedli na barvnem kompozitu za vse štiri kanale hkrati. Slika 34 prikazuje barvni kompozit kanalov vidnega dela spektra pred (a) in po predobdelavi (b). Kompozit, ki prikazuje stanje pred obdelavo ima zaradi nazornejšega prikaza izboljššan kontrast z linearnim raztegom z nasičenjem 2 %.




Slika 34: Barvni kompozit rdečega, zelenega in modrega kanala pred in po obdelavi.

Figure 34: Color composite of red, green and blue band before and after preprocessing.

Barvna segmentacija podobe izhaja iz podanega niza barv (intenzitet posameznih kanalov), potem pa po celotni podobi poišče piksele, ki so po barvi podobni podanemu nizu barv (opis v poglavju 4.7). Vhodni barvni niz izberemo na podlagi trenutne maske stavb. Barvno segmentacijo izvedemo za vsak objekt na maski posebej (na trenutni maski je 132 objektov). Ker so bili objekti na maski pridobljeni iz višinskih podatkov, označuje posamezen objekt na

maski stavbo, ki je na podobi zapisana z različnimi toni (npr. polovica stavbe je osvetljena, polovica je v senci ali pa je del stavbe prekrit s strešniki drugačne barve). Zato je treba pred izvedbo segmentacije masko stavb dodatno razdrobiti. Masko razdrobimo tako, da izračunamo presek maske z nenadzorovano klasifikacijo multispektralnih podob obravnavanega območja. Za nenadzorovano klasifikacijo smo izbrali klasifikacijo ISODATA. Število razredov v klasifikaciji izberemo tako, da se stavbe ločijo od ostalih objektov, vendar pri tem vseeno niso preveč razdrobljene. V predstavljenem primeru smo izbrali 12 razredov. Slika 35 prikazuje rezultat klasifikacije ISODATA. Teoretično je torej možno, da bomo iz vsake stavbe, označene na maski, pridobili 12 različnih nizov barv za izvedbo barvne segmentacije. Barvno klasifikacijo ne izvedemo, če je število pikslov, ki določajo barvni niz, manjše od $1/25$ vseh pikslov, ki na maski označujejo stavbo (s tem v segmentaciji izpustimo tiste dele maske, ki npr. ne označujejo zgolj stavbe, pač pa tudi njeno okolico).



Slika 35: Nenadzorovana klasifikacija ISODATA.

Figure 35: Unsupervised classification ISODATA.

Barvni niz, ki nas zanima v segmentaciji, torej podamo s presekom maske stavb, maske ustreznega razreda klasifikacije in multispektralne podobe, ki jo segmentiramo. Za izračun podobnosti med poljubnim pikslom in nizom barv smo uporabili Mahalanobisovo razdaljo (Gonzales, Woods, Eddins, 2004), za prag pa smo izbrali največjo vrednost standardnega odklona posameznih barvnih komponent v preseku oziroma vrednost 10, v primerih ko največji standardni odklon ni presegal te vrednosti. Zaradi uporabe štirih multispektralnih kanalov razširimo enačbo (24) za izračun Evklidske razdalje v obliko (31):

$$D(\mathbf{z}, \mathbf{m}) = [(z_R - m_R)^2 - (z_G - m_G)^2 - (z_B - m_B)^2 - (z_{nIR} - m_{nIR})^2]^{1/2}, \quad (31)$$


kjer indeks nIR predstavlja bližnjo infrardečo sestavino vektorjev \mathbf{m} in \mathbf{z} . Analogno razširimo tudi enačbo za izračun Mahalanobisove razdalje (25).

V postopku barvne segmentacije izdelamo toliko podob, kolikor imamo razredov nenadzorovane klasifikacije (v našem primeru 12). V vsako podobo dodajamo rezultat barvne segmentacije, ki ga dobimo s posameznim klasifikacijskim razredom določene stavbe. Iz dvanajstih podob potem lahko razberemo, kolikokrat je bil posamezen piksel multispektralne podobe prepoznan kot stavba.

Štiri od dvanajstih podob so bile prazne in jih izločimo iz nadaljnje obdelave. Rezultat je pričakovan, saj vsebuje nenadzorovana klasifikacija tudi razrede, ki ne vsebujejo stavb (npr. vegetacija). Dve podobi sta imeli po izvedenem postopku barvne segmentacije zelo nizko najvišjo vrednost (1 oziroma 2). Tudi ti podobi izločimo. Ostalih šest podob barvne segmentacije pa je vsebovalo višje vrednosti (vsaj 11). Te podobe lahko prepoznamo kot tiste, ki vsebujejo segmentirane stavbe.

Slika 36 ilustrira rezultate barvne segmentacije. Levo je prikazana vsota vseh dvanajstih segmentacij (a), ki nam da občutek, kolikokrat so bili določeni piksli prepoznani kot stavbe. Razpon vrednosti ima od 4 do 33. Podoba vsote lahko predstavlja kriterij, katere od dvanajstih segmentacij obdržati v nadaljnji obdelavi (npr. tiste, ki imajo najvišjo vrednost vsaj četrtno najvišje vrednosti podobe vsot – kriterija niti ni bilo treba uporabiti; kot je že omenjeno, so

bile štiri podobe povsem prazne, dve pa sta vsebovali piksele, ki jih je postopek le enkrat ali dvakrat prepoznal kot stavbe). V sredini (b) je predstavljena segmentacija z nizko največjo vrednostjo 2 in jo ne uporabimo za iskanje stavb. Desno je prikazana podoba segmentacije, ki ima najvišjo vrednost 23 (c). Na njej so segmentirane stavbe z rdečo streho, ki so na obravnavanem območju najbolj pogoste.



Slika 36: Primer rezultatov barvne segmentacije podobe.

Figure 36: Color image segmentation result examples.


Sledi izdelava maske iz šestih obdržanih podob. Tudi na teh niso prikazane le stavbe, zato uporabimo dvakratni kriterij polovice. Na posamezni podobi obdržimo le piksele, ki so bili kot stavbe prepoznani več kot polkrat glede na celotni razpon podobe. Na primer, če ima podoba barvne segmentacije razpon od 0 do 22, obdržimo le piksele, ki imajo vrednosti med 11 in 22. Potem seštejemo vse obdržane podobe in še enkrat uporabimo kriterij polovice. Na vsoti obdržimo le piksele, ki imajo vrednost nad polovico zgornje vrednosti razpona vsote. Na ta način ostanejo le piksli, ki z največjo verjetnostjo predstavljajo kandidate za stavbe ali dele stavb. Rezultat uporabimo za dopolnitev maske stavb.

Novo masko sestavimo z disjunkcijo:

- obstoječe maske stavb pred barvno segmentacijo (slika 33 b),
- konjunkcije maske, izdelane iz nDMP (izboljšane z masko NDVI in masko cest; slika 32 c) in rezultata barvne segmentacije; dobljeno konjunkcijo očistimo s filtrom večine

(v tem koraku smo predvideli, da objekti, ki se nahajajo na maski nDMP in na rezultatu barvne segmentacije, predstavljajo stavbe);

- očiščenega rezultata barvne segmentacije (odstranimo objekte, ki se držijo roba in objekte s površino pod 6 m^2 , objekte stanjšamo z morfološko erozijo in očistimo s filtrom večine).




Slika 37: Dopolnitev maske stavb z rezultati barvne segmentacije podobe.

Figure 37: Completion of building mask with color image segmentation results.

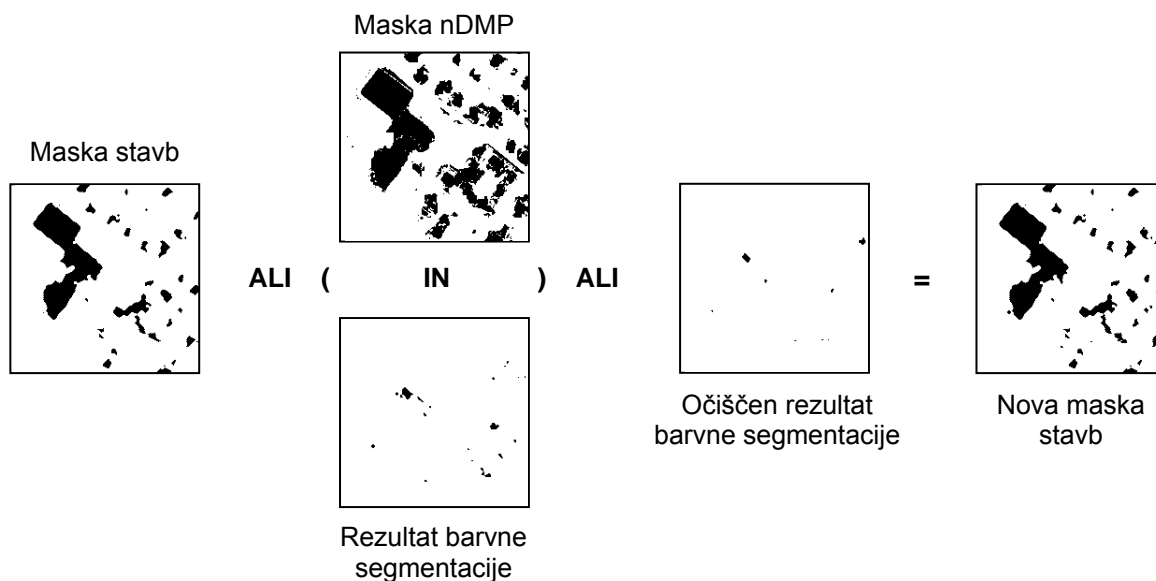
Slika 37 prikazuje obstoječo masko stavb (a), rezultat barvne segmentacije po čiščenju (b) in novo masko stavb (c), izdelano iz zgoraj opisane disjunkcije. Iz slike je razvidno, da smo z barvno segmentacijo dopolnili obliko obstoječih kandidatov za stavbe in poiskali nove.

Slika 38 prikazuje diagram poteka barvne segmentacije. Za izdelavo diagrama smo barvno segmentacijo izvedli na manjšem območju. Izdelavo nove maske z omenjeno disjunkcijo prikazuje slika 39. Maske in rezultati segmentacij so prikazani z negativni.



Slika 38: Diagram poteka barvne segmentacije.

Figure 38: Color segmentation flowchart.



Slika 39: Izdelava nove maske stavb.


Figure 39: New building mask elaboration.

6.2.4 Izpopolnitev maske stavb z rastjo regij in vektorizacija

Do končnega rezultata nas pripeljeta dva koraka. Najprej razširimo objekte na maski stavb, tako da ti čim bolj pravilno opišejo obliko stavb. Postopek izvedemo z rastjo regij. V zadnjem koraku vektoriziramo masko stavb s Houghovo transformacijo.

Objekti, ki na maski predstavljajo kandidate za stavbe, nimajo pravih oblik, kot bi jih pričakovali pri grajenih objektih. Rezultate barvne segmentacije smo tako oklestili, da z njimi nismo razširili objektov na maski do končne oblike stavb. Tudi sicer barvna segmentacija ni povsem primerna za iskanje končne oblike stavb, saj robovi zaradi ostrenja multispektralnih kanalov s pankromatskim niso povsod ostri. Za dopolnitev maske v končno obliko in vektorizacijo stavb, bi bilo smotrno uporabiti pankromatski posnetek. Vendar ima posnetek, ki smo ga imeli na razpolago, slabe radiometrične značilnosti. Zaradi preosvetljenosti posnetka, so na pankromatskem posnetku izpadli številni robovi, predvsem okoli svetlih objektov. Rast regij smo zato izvedli na sivi podobi, izdelani iz multispektralnih kanalov vidnega dela elektromagnetnega valovanja (rdeč, zelen in moder kanal). Siva podoba ima bolj

homogene površine od barvnega kompozita, z njo lažje nadziramo rast regij in pridobimo boljše rezultate, obenem pa izkoristimo tudi radiometrične prednosti multispektralnih kanalov v primerjavi s pankromatskim. Slika 40 prikazuje pankromatski posnetek (a) in sivo podobo (b), izdelano iz rdečega, zelenega in modrega multispektralnega kanala, ki so bili pred tem obdelani, kot je opisano v 6.2.3 (morfološka rekonstrukcija, anizotropna difuzija in linearni razteg z nasičenjem 2 % v 8-bitno podobo). Puščica kaže na nedoločljiv rob na pankromatskem posnetku v primerjavi z robom na novi sivi podobi. Tudi rob na sivi podobi ni oster, kar je posledica ostrenja multispektralnih kanalov s pankromatskim.




Slika 40: Robovi na pankromatski in sivi podobi.

Figure 40: Panchromatic and grayscale image edges.

Rast regij izvedemo za vsak objekt na maski posebej. Začetek rasti regij izhaja iz semena iz katerega zraste regija. Seme dobimo iz obstoječe maske stavb. Enako kot pri barvni segmentaciji, so tudi na sivi podobi stavbe sestavljene iz različnih tonov. Masko ponovno razdrobimo z uporabo nenadzorovane klasifikacije. V predstavljenem primeru je bila siva podoba z nenadzorovano klasifikacijo ISODATA razdeljena v 10 razredov. Seme izračunamo kot mediano intenzitet preseka med sivo podobo, masko stavb in masko ustreznega razreda nenadzorovane klasifikacije. Izbor mediane je primernejši od aritmetične sredine intenzitet, saj ni občutljiva na podatke, ki močno odstopajo. Zato nanjo manj vplivajo tudi eventualni piksli, ki so zastopani na maski, vendar na sivi podobi prikazujejo okolico stavbe. V postopku rasti regij izpustimo tiste dele stavb, ki imajo v preseku površino manjšo od $1/25$ celotne površine stavbe na maski stavb. Pomemben dejavnik v rasti regij je tudi pogoj za testiranje rasti. Pogoj podamo kot podobo, ki za vsak piksel na sivi podobi določa njegov prag.


Podobo praga izdelamo iz maske stavb. Objektom na maski dodelimo vrednost 2. Okoli njih izdelamo bafer pikslov z vrednostjo 1 v širini 7 m. Okoli njega pa še en osem metrski bafer pikslov z vrednostjo 0,5. Ostali piksli obdržijo vrednost 0, s čimer nadziramo rast regij. Regija tako ne more zrasti na območja z vrednostjo 0. Velikost obeh baferjev je izbrana empirično glede na kakovost maske stavb in gostoto pozidave. Nekateri objekti na maski imajo precej manjšo površino od dejanske površine stavb. Z notranjim baferjem dopuščamo, da se bodo stavbe razširile do 7 m na vse strani maske. Zunanji bafer omogoča rast večjim stavbam s homogeno intenziteto na sivi podobi. V primeru obravnave območij z gostejšo pozidavo (urbane površine) bi morali baferja skrčiti. Pragu z ustreznima in že opisanima maskama odstranimo še območja, ki jih prekrivajo ceste in vegetacija. Slika 41 prikazuje vhodne podatke v rast regij: sivo podobo (a), prag (b) in nenadzorovano klasifikacijo (c). Slika 37 (c) prikazuje masko stavb.



Slika 41: Siva podoba, prag in nenadzorovana klasifikacija.

Figure 41: Grey image, threshold and unsupervised classification.

Podobo praga pomnožimo z vrednostjo 20. V rasti regij se bo piksel priključil regiji, če je razlika med vrednostjo piksla na sivi podobi in izračunano mediano manjša ali enaka vrednosti istega piksla na podobi praga. Slika 42 prikazuje delovanje rasti regij. Prikazana je izvorna maska (a), rezultat rasti regij (b) in končni rezultat, ki ima z morfološkima operacijama odpiranja in zapiranja očiščene robove (c). Uporabili smo strukturni element disk z velikostjo 1.



Slika 42: Rezultat rasti regij.

Figure 42: Region growing result.

Na prvi pogled deluje rast regij podobno kot barvna segmentacija, vendar se postopka razlikujeta v bistveni značilnosti. V rast regij je vgrajen pogoj za ustavitev rasti, ki ga podamo s podobo praga. Regija ne more zrasti v območja z vrednostjo praga 0.

Zadnji korak iskanja in zajema stavb je vektorizacija maske stavb. Ta poteka sočasno z rastjo regij. Za masko posameznega objekta, dobljeno z rastjo regij, z uporabo Cannyjevega algoritma izdelamo obris. Obris vektoriziramo s transformacijo Radon, kot je opisano v poglavju 6.1.4., kjer smo vektorizirali masko stavb, narejeno iz lidarskih podatkov.

Natančnost lidarskih podatkov je boljša od podatkov, dobljenih iz stereopara IKONOS. Potek vektorizacije se zato v nekaj korakih, ki so opisani v nadaljevanju, razlikuje. V postopek uvedemo podobo robov, ki jo iz sive podobe izdelamo s Cannyjevim algoritmom. Pri tem nastavimo parametre v algoritmu tako, da poiščemo le najbolj izrazite robove (v prikazanem primeru $\sigma = 0,5$, $T1 = 0,2$, $T2 = 0,4$). Slika 43 prikazuje odkrite robove. Orientacijo posamezne stavbe v prostoru izračunamo s Houghovo transformacijo. Če na preseku razširjene maske objekta in podobe robov Houghova transformacija ne odkrije roba, ki bi meril vsaj tri piksele, objekt izpustimo iz vektorizacije. S tem iz zajema izločimo eventualne stavbe, ki so prikazane na maski stavb, vendar dejansko ne obstajajo v naravi. Ostale spremembe v postopku vektorizacije: pogoj za iskanje vzporednih in pravokotnih premic


zaradi manjših objektov (prostorska ločljivost IKONOS-a je 1 m) omilimo ($R_{max} \geq 2$); premice iščemo na medsebojni oddaljenosti 1 m; pravokotnik obdržimo, če je razmerje med površino, ki jo tvori presek pravokotnika z masko stavb iz rasti regij, in površino, izračunano iz oglišč pravokotnika, večje od 1/3.



Slika 43: Robovi, določeni s Cannyjevim algoritmom odkrivanja robov.

Figure 43: Edges determined with Canny edge detector.

Slika 44 (a) prikazuje najmočnejši najden rob na preseku razširjene maske objekta in podobe robov. Najmočnejši rob določa orientacijo, ki je uporabljena za vektorizacijo stavbe (slika 44 b).




Slika 44: Orientacija in vektorizacija stavbe.

Figure 44: Building orientation and vectorization.

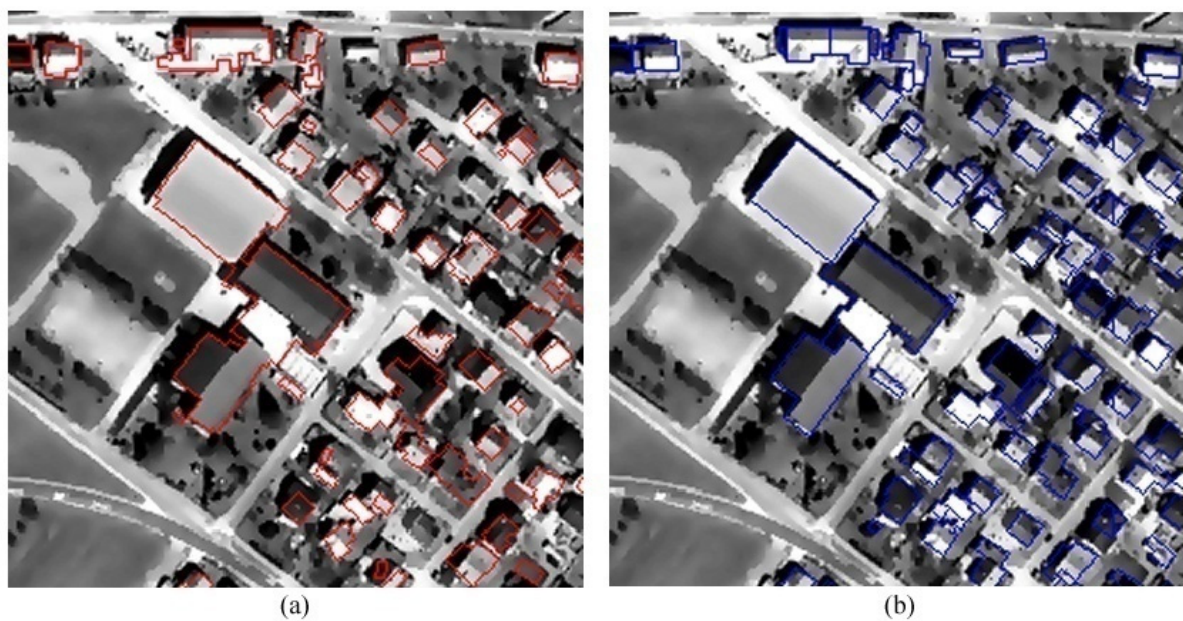
6.2.5 Rezultati zajema stavb in analiza

Po predobdelavi in pripravi podatkov, poteka zajem stavb povsem samodejno. Izdelavo ortofotov in samodejni zajem DMP ter DMV smo izvedli v programu za digitalno fotogrametrijo Socet Set. V njem smo izvedli tudi edini korak, ki je zahteval ročno urejanje (urejanje DMV). Nenadzorovani klasifikaciji smo izdelali v programu Erdas Imagine. Vse ostale korake smo v skladu z izbrano metodologijo dela sprogramirali v programu Matlab. V postopku iskanja in zajema stavb smo uporabili izvorno kombinacijo anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. Po končanem zajemu smo v programu ArcGIS uredili topologijo zajetih stavb. Slika 45 prikazuje rezultat urejanja topologije in primerjavo zajema z DTK 5. Puščica na sliki (a) prikazuje niz stavb, ki se med seboj prekrivajo. S topološkimi operacijami smo te stavbe združili v eno. Urejen rezultat je prikazan na sliki (b) z rdečo barvo. Z modro barvo je prikazana DTK 5.



Slika 45: Urejanje topologije in primerjava rezultatov z DTK 5.

Figure 45: Topology editing and comparison of results with DTK 5.



Slika 46: Rezultati samodejnega zajema stavb (a) in DTK 5 (b) na sivi podobi.

Figure 46: Results of automatic building extraction (a) and DTK 5 (b) on grayscale image.

Rezultate zajema smo analizirali na podlagi primerjave z obstoječo bazo DTK 5. Slika 46 prikazuje superimpozicijo sive podobe in rezultata samodejnega zajema stavb (a) ter superimpozicijo sive podobe in DTK 5 (b).

Na obravnavanem območju je samodejni postopek prepoznal 142 stavb. V petih primerih je bila ena stavba v naravi zajeta z dvema arealoma, 8 pa je bilo v naravi dejansko neobstoječih stavb. Dejansko je torej samodejni postopek odkril 129 stavb. Glede na DTK 5 obstaja na območju 28 stavb, ki jih postopek ni prepoznal. Pregled posnetka je pokazal, da dveh izmed teh stavb dejansko ni več v naravi. Skupno se torej na območju nahaja 155 stavb. Razmerje 129 : 155 nam poda 83,2 % odkritih stavb. Rezultat je primerljiv z rezultati ostalih avtorjev. Fraser, Baltsavias in Gruen (2001a) so v svojih raziskavah potrdili, da na podobah IKONOS ne moremo zajeti okoli 15 % stavb. Razlog za slabšo prepoznavnost stavb so sence, mrtvi koti, slabo opredeljeni robovi (posledica šuma in umetnih tvorb), nasičenost svetlih površin, višinski kot Sonca in senzorja, atmosferski pogoji v trenutku snemanja. Večina manjkajočih stavb je temne barve. Temni toni so očitno predstavljali težavo samodejnemu postopku za izdelavo DMP. Nekatere temne stavbe tako niso bile zajete na DMP in jih zato z barvno segmentacijo ne moremo odkriti. Vse stavbe, ki jih samodejni postopek ni našel, so bile sicer na posnetkih prepoznavne. Stereopar IKONOS je primeren za ročni 3D zajem podatkov o stavbah, vendar smo se v nalogi osredotočili le na samodejne postopke. Preglednica 11 prikazuje oceno samodejnega iskanja stavb na posnetku IKONOS v primerjavi s posodobljeno DTK 5.

Preglednica 11: Ocena samodejnega iskanja stavb na stereoparu IKONOS.

Table 11: Evaluation of the automatic building detection on the IKONOS stereopair.

	Število	%
Vse stavbe glede na DTK 5	155	100
Odkrite stavbe	129	83,2
Neobstoječe stavbe v naravi	8	4,9

Slabše rezultate dobimo, če analiziramo položajno točnost zajema. Izmed 129 stavb je samodejni postopek le 20 stavb zajel povsem pravilno (s točnostjo enega piksla). 42 stavb je

zajel s premajhno površino, 34 stavbam je postopek generaliziral obliko (npr. manjkajoči prizidki) ali jih popačil, 14 stavb je bilo zajetih s preveliko površino, dve pa sta bili občutno premaknjeni glede na pravilni položaj. V devetih primerih je postopek dve sosednji stavbi združil v eno, v enem primeru pa so bile združene 3 oziroma 5 stavb. 21 stavb nima povsem pravilne orientacije osi v prostoru. Razlogov za napake je več. Stereopar je bil posnet v mesecu oktobru pri višinskem kotu Sonca $49,6^\circ$. Posledica so relativno dolge sence in različna osvetljenost streh. Zaradi različne osvetljenosti je kar nekaj stavb zajetih s premajhno površino, zaradi senc so izpadli nekateri prizidki. Kota snemanja sta bila za posnetka stereopara $65,3^\circ$ in $77,7^\circ$. Za zajem bi bil bolj primeren nadirni posnetek, ki pa ga nismo imeli na razpolago. Nadirni posnetek bi omogočal boljše ločevanje posameznih stavb. Posnetka sta preosvetljena zaradi česar je predvsem svetle stavbe težko (včasih nemogoče) ločiti od betonske okolice. Te stavbe so praviloma zajete s preveliko površino. Rezultati so slabši na območju, ki ga deloma prekriva šibka oblačnost (slika 34 desno zgoraj). Del stavb v nekaterih primerih prekriva visoka vegetacija, zato teh stavb ni mogoče zajeti s pravilno obliko. Na območju se pretežno nahajajo manjše družinske hiše. Odkriti robovi so bili zato v nekaterih primerih prekratki, da bi lahko postopek pravilno izračunal orientacijo stavbe. Preglednica 12 prikazuje oceno pravilnosti vektorskega zajema na stereoparu IKONOS. Vsota odstotkov v tretjem stolpcu preglednice presega 100 %, saj smo v analizi nekatere stavbe šteli dvakrat (npr. stavbe z napačno površino in orientacijo).

Preglednica 12: Ocena pravilnosti vektorskega zajema stavb na stereoparu IKONOS.

Table 12: Vectorization of buildings on IKONOS stereopair accuracy evaluation.

	Število	%
Pravilno zajete	20	15,5
Generalizirane	34	26,4
Napačna površina	56	43,4
Napačna orientacija	21	16,3
Drugo	2	1,6

Preglednica 13 prikazuje oceno kakovosti rastrskega zajema stavb na posnetku IKONOS, ki jo podajamo s klasifikacijsko matriko. Kot referenčne podatke smo uporabili popravljeno in

rasterizirano DTK 5, iz katere smo izbrisali stavbe, ki jih v naravi ni več. Iz rezultatov razberemo, da smo s samodejnim postopkom vektorizacije izdelali močno generalizirane floris stavb. Faktor razvejitve razkriva, da je bila v veliko primerih vektorizirana tudi okolica stavb. Obratno lahko iz faktorja pogreška in % odkritja razberemo, da smo stavbe vektorizirali s premajhnimi areali.

Preglednica 13: Ocena kakovosti rastrskega zajema stavb na stereoparu IKONOS.

Table 13: Building extraction on IKONOS stereopair quality assessment.

Faktor razvejitve	Faktor pogreška	% odkritja	% kakovosti
0,34	0,68	59,49	49,46

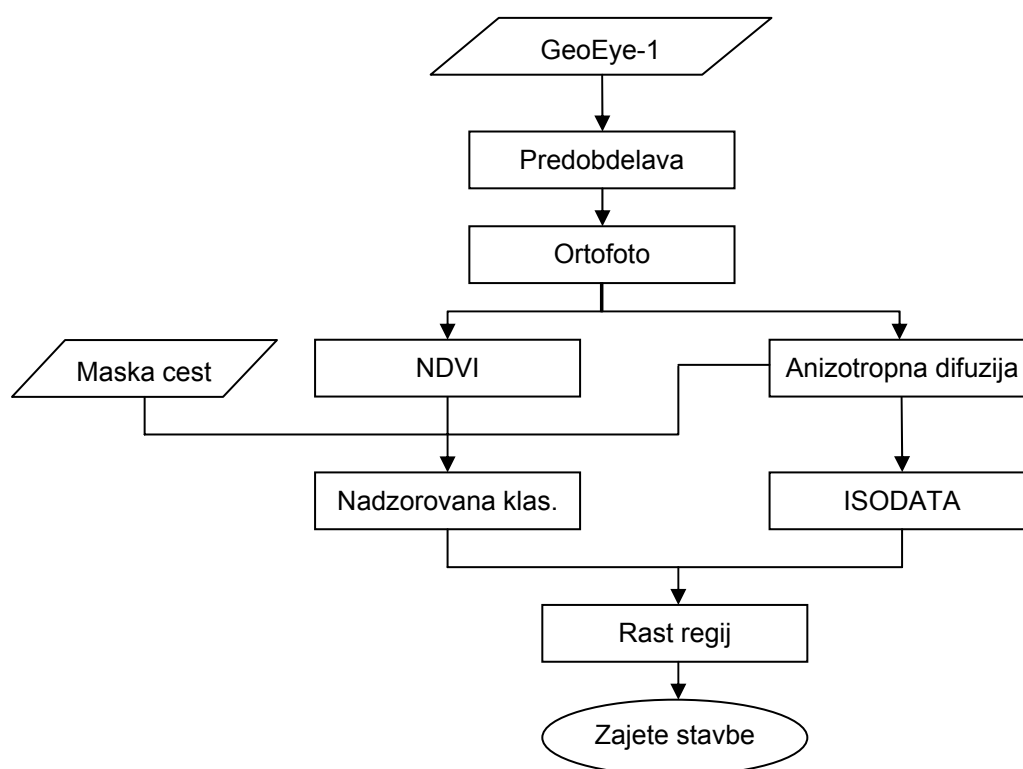
Dodatno smo ocenili tudi kakovost rastrskega zajema stavb samo za tiste stavbe, ki jih je samodejni postopek prepoznal. Za izračun ocene smo iz referenčnih podatkov izbrisali stavbe, ki jih samodejni postopek ni prepoznal. Faktor pogreška je v tem primeru znašal 0,49, % odkritja 67,12, končni % kakovosti pa je še vedno ostal relativno slab (54,85 %).

Poudariti velja, da smo samodejni postopek testirali na stvarnih podatkih, ki so bili daleč od idealnih. Večje, enakomerno osvetljene stavbe, ki se lepo ločijo od okolice, je postopek prepoznal pravilno. Vseeno pa ne moremo trditi, da je samodejni postopek primeren za zajem podatkov v topografske baze velikih meril (večjih od 1 : 25.000). Pri zajemu podatkov v topografsko bazo bi bila nujna tudi interakcija operaterja, ki bi samodejni postopek opozoril na spregledane stavbe. V skladu s hipotezo naloge lahko samodejni postopek uporabimo za odkrivanje sprememb v prostoru in kontrolo popolnosti zajema podatkov v topografske baze.

6.3 Iskanje stavb na posnetku GeoEye-1

V tem podglavju obravnavamo možnosti iskanja stavb na podobi GeoEye-1. Posnetek prikazuje območje Ljubljane, za testno območje pa smo uporabili južni del mesta, ki smo ga obravnavali že v 6.1. Satelit GeoEye-1 je najmlajši izmed komercialnih satelitov, ki snemajo visokoločljive podobe in literature, ki bi obravnavala postopke iskanja stavb na njegovih

podobah praktično še ni na voljo. Prvotno masko stavb smo izdelali v programu ENVI (modul Feature Extraction). V nadaljnjih korakih smo jo izboljšali z uporabo metode, razvite pri obravnavi podobe IKONOS, ki vključuje uporabo anizotropne difuzije, nenadzorovano klasifikacijo in segmentacijo. Barvno segmentacijo in rast regij smo združili v en korak v katerem smo rast regij izvajali na multispektralni podobi. Končne maske nismo vektorizirali, saj je obravnavan posnetek preveč poševen (kot snemanja 63°). Strehe stavb so zato premaknjene glede na pravilno lego in zajem podatkov v topografsko bazo ni smiseln. Slika 47 orisuje potek iskanja stavb. Poleg prikazanih postopkov smo uporabili še vrsto morfoloških operacij za odpravljanje nepravilnosti maske.




Slika 47: Shema poteka zajema stavb na posnetku GeoEye-1.

Figure 47: Building extraction from GeoEye-1 image flowchart.

6.3.1 Priprava podatkov za iskanje stavb

Multispektralne kanale posnetka smo izostrili na ločljivost pankromatskega kanala (0,5 m pri podobah GeoEye-1). Območje, ki ga pokriva posnetek, meri 10 km x 10 km, zato smo za

izračun orientacije posnetka uporabili direktno linearno transformacijo (DLT). DLT smo izračunali na podlagi enaindvajsetih oslonilnih točk, pridobljenih z meritvami točk na barvnem ortofotu DOF050 in digitalnem modelu višin DMV 5. Položajni srednji pogrešek po izvedeni transformaciji je znašal 1,23 piksla (0,61 m) na podobi (0,39 m po osi Y in 0,47 m po osi X). Ortofoto pankromatskega in multispektralnih kanalov smo izdelali z uporabo državnega DMV 5. Največje položajno odstopanje med koordinatami, izmerjenimi na izdelanih ortofotih, in koordinatami kontrolnih točk, izmerjenimi na državnem ortofotu DOF050, je znašalo 0,63 m. Izbrali smo 5 kontrolnih točk znotraj testnega območja za zajem stavb.



Slika 48: Pankromatski ortofoto in barvni kompozit ortofota rdečega, zelenega in modrega kanala.

Figure 48: Panchromatic orthophoto and color composite orthophoto of red, green and blue band.

Slika 48 prikazuje ortofoto pankromatskega kanala (a) in barvni kompozit, izdelan iz ortofotov rdečega, zelenega in modrega kanala (b).

6.3.2 Klasifikacija stavb

Za izdelavo začetne maske stavb moramo najprej ločiti stavbe od ostalih vrst rabe tal na podobi. V prej opisanih primerih smo to nalogo opravili na podlagi nDMP in vegetacijskega indeksa NDVI. Iskanje stavb na podobi GeoEye-1 smo izvedli brez uporabe višinskih podatkov. Eden od razlogov za to je poševnost posnetka, izogniti pa smo se želeli tudi ponavljanju metode, ki smo jo uporabili pri obdelavi ortofota in nDMP, saj imajo posnetki GeoEye-1 enako prostorsko ločljivost kot DOF050. Ena od možnosti za ločevanje stavb je uporaba klasifikacije. Preskusili smo več vrst nadzorovane in nenadzorovane klasifikacije. Najboljše rezultate smo dobili z izvedbo klasifikacije v modulu Feature Extraction programa ENVI. Pri tem se je izkazalo, da je za pridobitev sprejemljivih rezultatov zelo pomembna tudi predobdelava in izboljšava podob, ki jo bomo opisali v nadaljevanju.

ENVI Feature Extraction je modul za objektno klasifikacijo pankromatskih ali multispektralnih podob. Pri tem obravnava njihove prostorske in spektralne lastnosti. Pristop, ki ga program uporablja, je objektni, kar je glavna prednost pred klasično nadzorovano klasifikacijo, ki v kategorije razvršča posamezne piksele. Objektni pristop daje pri visokoločljivih podobah boljše rezultate, saj poleg spektralnih lastnosti analizira tudi prostorske lastnosti in teksturo posameznih objektov. Segmentacijska metoda na osnovi robov je pravilno ločila skoraj vse objekte na podobi, precej slabši pa so bili rezultati nadzorovane klasifikacije, ki smo jo uporabili za razvrščanje segmentiranih objektov na multispektralnih kanalih. Pri iskanju stavb je bilo moteče predvsem mešanje stavb z ostalimi betonskimi in asfaltiranimi površinami. Najboljši rezultat smo dobili z uporabo vseh štirih multispektralnih podob, ki smo jih pripravili na naslednji način:


- odstranjevanje manjših tvorb in delno odstranjevanje šuma z morfološkim odpiranjem z rekonstrukcijo, ki mu je sledilo morfološko zapiranje z rekonstrukcijo. Uporabljen je bil strukturni element disk velikosti 1;
- glajenje podob z uporabo anizotropne difuzije;
- uporaba Wallisovega filtra za prilagodljivo izboljšanje kontrasta;
- poudarjanje robov z Laplaceovim filtrom;

- linearni razteg histograma z nasičenjem 1 % na polno radiometrično ločljivost 11 bitov;
- maskiranje vegetacije z izračunom vegetacijskega indeksa NDVI;
- maskiranje cest.

Vegetacijski indeks NDVI smo izračunali iz ortofotov rdečega (R) in bližnje infrardečega kanala (IR) (26):

$$NDVI = \frac{IR - R}{IR + R}. \quad (26)$$

Masko cest smo izdelali iz podatkov topografske baze DTK 5. Za širino cest v maski smo uporabili atributne podatke DTK 5.



Slika 49: Maska NDVI, negativ maske cest in maskiran barvni kompozit.


Figure 49: NDVI mask, road mask negative and color composite with masks applied.

Slika 49 prikazuje masko NDVI (a), negativ maske cest (b) in barvni kompozit ortofota rdečega, zelenega in modrega kanala po končani predobdelavi za klasifikacijo (c).

Klasifikacijo smo izvedli na podlagi izbranih vzorcev. Stavbe smo razdelili na 7 podkategorij (glede na barvo strehe), ostali vzorci so predstavljali asfalt (temni in svetli asfalt posebej), beton, atletska površina in maskirano ozadje. Za vsako kategorijo smo v povprečju določili

med 10 in 11 vzorcev. Nekaj nad dvajset vzorcev smo izbrali za asfaltne površine in sive strehe, saj se te dva razreda v klasifikaciji pogosto mešata med seboj (Lee, Shan, Bethel, 2003).

Po končani nadzorovani klasifikaciji smo združili poligone, ki predstavljajo stavbe in odstranili ostale kategorije. Izmed preostalih poligonov smo izločili tudi tiste, ki so imeli površino manjšo od 4 m^2 (glede na Operativno navodilo za zajem stavb, se v topografskih bazah vodijo le stavbe, ki imajo površino večjo od 4 m^2) in izdelali začetno masko stavb. Z morfološkimi operacijami smo masko dodatno očistili (morfološko odpiranje in zapiranje za odstranjevanje nepravilnosti na robovih in zapiranje manjših lukenj v maski).



Slika 50: Rezultat nadzorovane klasifikacije in maska stavb.


Figure 50: Supervised classification result and building mask.

Slika 50 prikazuje rezultat nadzorovane klasifikacije (a) in masko stavb pred morfološko obdelavo (b).

6.3.3 Izboljšava maske stavb z rastjo regij

Začetno masko stavb smo izboljšali z rastjo regij na multispektralnih kanalih. Ker so stavbe na maski sestavljene iz različnih tonov (npr. različna osvetljenost stavb zaradi Sonca) smo jo razdrobili z nenadzorovano klasifikacijo. Multispektralno podobo smo s klasifikacijo ISODATA razdelili na 10 razredov. S presekom med začetno masko in razredi nenadzorovane klasifikacije smo iz nadaljnega postopka izločili tiste dele maske, katerih presek ni presegal 10 % površine celotne maske. Za vsak del maske, razdeljen z nenadzorovano klasifikacijo, smo izračunali mediano in standardni odklon radiometričnih vrednosti za vsakega od štirih multispektralnih kanalov. Mediano smo uporabili kot seme za rast regij.

Rast regij smo nadzirali s podobo praga, ki smo jo izdelali iz začetne maske stavb. Objektom na maski smo dodelili vrednost 2. Okoli njih smo 5 m širok izdelali bafer pikselov z vrednostjo 1, okoli tega pa še pet metrski bafer pikselov z vrednostjo 0,5. Ostali piksli so obdržali vrednost 0. Iz praga smo z masko NDVI in masko cest odstranili še območja, ki jih prekrivajo ceste in vegetacija. V postopku rasti regij smo med obdelavo posameznega dela maske podobo praga pomnožili z enainpolkratno vrednostjo standardnega odklona intenzitet barvne podobe pod površino obravnavanega dela maske. Območjem, ki smo jim iz praga prvotnega praga odstranili vegetacijo in ceste, smo prišteli vrednost 5. S tem omogočimo rasti regij, da stavbe najde tudi tam, kjer se v dejanskem tlorisu nahaja cesta, na posnetku pa je zaradi kota snemanja 63° stavba. Ali omogočimo rasti regij, da stavbo najde tam, kjer smo iz praga napačno izločili vegetacijo (npr. zaradi vpliva senc na izračun NDVI). V rasti regij smo tako prvotni maski priključili vse tiste piksele, katerih Mahalanobisova razdalja od mediane ni presegla vrednosti piksela na podobi praga. Končno masko smo še očistili z morfološkimi operacijami (morfološko odpiranje in zapiranje za odstranjevanje nepravilnosti na robovih in zapiranje manjših lukenj v maski).



Slika 51: Končna maska stavb in superimpozicija na barvnem kompozitu.

Figure 51: Final building mask and color composite superimposition.

Slika 51 (a) prikazuje končno masko stavb. Iz končne maske smo izdelali obrise. Superimpozicijo obrisov stavb na barvnem kompozitu rdečega, zelenega in modrega kanala prikazuje slika 51 (b). Ostalih operacij (npr. glajenje in pravokotizacija linij) na obrisih nismo izvajali, saj zaradi že omenjenega kota snemanja posnetek ni primeren a neposreden zajem stavb v topografsko bazo.

6.3.4 Rezultati iskanja stavb in analiza

Georeferenciranje posnetka GeoEye-1 in izdelavo ortofotov smo izvedli v programu za digitalno fotogrametrijo Socet Set. Nadzorovano klasifikacijo smo izdelali v modulu ENVI Feature Extraction, nenadzorovano pa v programu Erdas Imagine. Ostale korake smo sprogramirali v programu Matlab in potekajo samodejno. Za izboljšavo maske stavb, narejene z nadzorovano klasifikacijo, smo uporabili prilagojeno metodo, ki smo jo razvili med postopkom obdelave posnetka IKONOS. Uspešnost samodejnega iskanja in zajema stavb smo ocenili na dva načina: s primerjavo odkritih stavb na celotnem testnem območju s katastrom stavb (KS) in s primerjavo z ročno zajetimi stavbami.

Na testnem območju se glede na KS nahaja 174 stavb (stavbe, ki se v KS dotikajo, smo šteli kot eno stavbo, saj samodejni postopek iskanja stavb ne omogoča ločevanja takšnih stavb). S samodejnim postopkom smo našli 152 stavb (87,4 %). Dvaindvajset stavb nismo našli. Vse neodkrite stavbe so manjše in v sklopu večjih, najdenih stavb (vrtne lope in garaže). Polovico izmed njih v celoti ali deloma prekriva visoka vegetacija in jih tudi z ročnim zajemom ne bi zmogli pravilno interpretirati. Na območju smo našli tudi 7 stavb (3,9 %), ki v naravi in na posnetku dejansko ne obstajajo. Vse te stavbe so bili manjše in na asfaltnih površinah ali pa je postopek registriral avtomobile. Preglednica 14 podaja oceno samodejnega iskanja stavb na posnetku GeoEye-1 glede na KS.


Preglednica 14: Ocena samodejnega iskanja stavb na posnetku GeoEye-1.

Table 14: Evaluation of the automatic building detection on GeoEye-1 image.

	Število	%
Vse stavbe glede na KS	174	100
Odkrite stavbe	152	87,4
Neobstoječe stavbe v naravi	7	3,9

Oceno kakovosti rastrskega zajema stavb smo izračunali s primerjavo rezultatov z ročno zajetimi podatki na posnetku GeoEye-1. Za ročni zajem stavb smo izbrali manjše območje, na katerem se nahaja 100 stavb. Slika 52 prikazuje območje z ročno zajetimi strehami stavb.

Izmed sto ročno zajetih stavb na območju je predlagani postopek v celoti ali vsaj deloma našel vse stavbe. Na območju sta se pojavili tudi dve stavbi, ki ju je samodejni postopek prepoznal, a v resnici na posnetku in v naravi ne obstajata. Oceno kakovosti rastrskega zajema stavb podajamo s klasifikacijsko matriko (preglednica 15).



Slika 52: Območje z ročno zajetimi stavbami.

Figure 52: Manually delineated buildings area.

Preglednica 15: Ocena kakovosti rastrskega zajema stavb na posnetku GeoEye-1.

Table 15: Building extraction on GeoEye-1 image quality assessment.

Rezultat	Faktor razvejitve	Faktor pogreška	% odkritja	% kakovosti
po klasifikaciji	0,24	0,15	86,67	71,68
po dodatni obdelavi	0,13	0,18	84,79	76,53

Preglednica 15 podaja oceno kakovosti rastrskega zajema stavb na posnetku GeoEye-1. Navedena sta rezultata v dveh različnih fazah zajema stavb, po opravljeni nadzorovani klasifikaciji in v zadnji vrsti preglednice po izvedeni rasti regij in morfoloških operacijah. Iz preglednice je razvidno, da smo končno kakovost zajema izboljšali predvsem z odstranitvijo napačno klasificiranih pikslov v nadzorovani klasifikaciji. To so bile v glavnem fasade stavb, manjša območja asfalta, betona, senc in ostalih manjših objektov (avtomobili), ki jih je

klasifikacija prepoznala kot stavbe. Po obdelavi se sicer za malenkost zmanjša odstotek odkritja, še vedno pa je samodejni postopek našel vse stavbe.

Z vidika samodejne obdelave podatkov je bilo pri iskanju stavb moteče predvsem dejstvo, da je bilo treba za pravilne rezultate klasifikacije določiti veliko število vzorcev. Za vsako kategorijo smo v povprečju določili med 10 in 11 vzorcev. Odstotek kakovosti bi bil višji, če sam posnetek ne bi bil močno zvrnjen (kot snemanja 63°), saj so bile kot deli stavb v veliko primerih klasificirane tudi fasade stavb, ne le strehe, ki smo jih zajeli med ročnim zajemom. Faktor razvejitve je zato ostal razmeroma visok (0,13). Še vedno pa je odstotek kakovosti precej višji kot ga podajajo različni avtorji (Lee, Shan, Bethel, 2003; Jin, Davis, 2005; Koc San, Turker, 2007) pri obravnavi posnetkov IKONOS, kjer je odstotek kakovosti ocenjen med 50 % in 70 %. Rezultat kaže na velik potencial za iskanje stavb na posnetkih GeoEye-1, vsekakor pa bi morali za iskanje uporabiti nadirni posnetek oziroma ga kombinirati z višinskimi podatki, na podlagi katerih bi lahko izdelali popolni ortofoto. Višinski podatki bi omogočili natančnejšo izdelavo začetne maske stavb, saj bi že na podlagi nDMP lahko ustrezno ločili strehe od ostalih betonski površin na tleh oziroma bi s podatki nDMP naknadno izboljšali rezultate nadzorovane klasifikacije (Demir, Poli, Baltsavias, 2008). Glede na hipotezo naloge se je posnetek GeoEye-1 izkazal kot pomemben vir za iskanje sprememb v topografskih bazah.

7 ANALIZA REZULTATOV IN OVREDNOTENJE CILJEV

V tem poglavju analiziramo rezultate samodejnega zajema stavb na različnih podatkovnih virih, ki smo jih izbrali za testiranje hipoteze naloge, ovrednotimo zastavljene cilje in podamo zaključke naloge. V poglavju predlagamo tudi način uporabe pridobljenih rezultatov za potrebe vzdrževanja topografskih podatkov.

7.1 Položajna točnost satelitskih posnetkov

Eden od ciljev doktorske naloge je bil preverjanje položajne točnosti, ki jo nudijo satelitski posnetki. Satelitski posnetki morajo za vzdrževanje topografskih baz v merilu 1 : 5000 in ob upoštevanju grafične natančnosti 0,2 mm zagotavljati vsaj metrsko položajno točnost. Iz pregleda literature, ki smo ga opisali v 3.3.1.1, 3.3.1.3 in 3.3.2.1, lahko razberemo, da lahko s podatki satelitov IKONOS, GeoEye-1 in QuickBird zadostimo temu pogoju. Strožji je pogoj v Operativnem navodilu za zajem podatkov o stavbah (GURS, 2001), kjer je navedena zahtevana položajna natančnost za zajem stavb 50 cm. Položajna točnost satelitskih posnetkov je malenkost slabša od pogoja iz Operativnega navodila.

Z rezultati praktičnega dela smo potrdili, da lahko satelitske posnetke postavimo v prostor državnega koordinatnega sistema z metrsko točnostjo. Obdelali smo stereopar posnetkov IKONOS in posnetek GeoEye-1. Oba satelita sta v lasti podjetja GeoEye, ki ne objavlja podatkov o fizičnem modelu senzorja. Kljub temu je uporaba koeficientov RPC omogočala popolno fotogrametrično obdelavo stereopara IKONOS. Obdelavo GeoEye-1 smo naredili le z enim posnetkom, zato smo za georeferenciranje posnetka v prostor uporabili eno od empiričnih metod. Koordinate v prostoru državnega koordinatnega sistema in slikovne koordinate smo povezali z direktno linearno transformacijo (DLT).

7.1.1 Točnost georeferenciranja stereopara IKONOS

Orientacijo stereopara IKONOS smo izvedli na podlagi koeficientov RPC, ki opisujejo geometrijski model sensorja in smo jih dobili skupaj s posnetki. Prostorske operacije (izdelava DMP in DMV) smo izvedli kar v modelu sensorja RPC. Izdelane ortofote smo georeferencirali v državni koordinatni sistem na podlagi devetnajstih oslonilnih točk, izmerjenih na državnem ortofotu DOF050. Za umestitev ortofotov v državni koordinatni sistem je zadoščala translacija.

Preglednica 16: Georeferenciranje stereopara IKONOS.

Table 16: IKONOS stereopair georeferencing.

	DOF050		IKONOS		Pred translacijo		Po translaciji		Položajni pog. [m]
	Y [m]	X [m]	Y [m]	X [m]	ΔY [m]	ΔX [m]	ΔY [m]	ΔX [m]	
1	449402,98	73147,19	449049,11	72105,80	353,87	1041,39	0,27	0,67	0,72
2	450006,45	73052,02	449653,01	72011,51	353,44	1040,51	-0,16	-0,21	0,26
3	450751,31	73057,36	450398,25	72016,91	353,07	1040,45	-0,53	-0,26	0,60
4	451009,03	73077,56	450655,11	72036,88	353,92	1040,69	0,32	-0,03	0,32
5	451313,34	73173,46	450958,77	72131,99	354,57	1041,48	0,97	0,76	1,23
6	449550,58	72545,78	449197,17	71504,89	353,41	1040,89	-0,19	0,18	0,26
7	450052,73	72597,97	449699,23	71557,29	353,51	1040,68	-0,09	-0,03	0,10
8	450322,34	72610,18	449968,99	71569,41	353,35	1040,76	-0,25	0,05	0,26
9	450801,75	72583,52	450448,94	71542,95	352,81	1040,58	-0,79	-0,14	0,81
10	451250,67	72797,33	450896,10	71756,36	354,57	1040,97	0,97	0,26	1,00
11	449534,93	71961,97	449181,66	70922,18	353,27	1039,78	-0,33	-0,93	0,99
12	450085,77	71878,74	449732,66	70838,36	353,12	1040,37	-0,48	-0,34	0,59
13	450880,09	72198,26	450526,79	71156,94	353,30	1041,32	-0,31	0,61	0,68
14	451529,70	72187,41	451175,49	71146,07	354,21	1041,34	0,61	0,62	0,87
15	449416,28	71601,65	449063,39	70561,40	352,90	1040,25	-0,71	-0,46	0,84
16	449884,94	71529,96	449532,17	70489,45	352,77	1040,51	-0,83	-0,20	0,86
17	450778,12	71899,26	450423,84	70858,75	354,27	1040,52	0,67	-0,20	0,70
18	450958,82	71621,26	450604,56	70580,93	354,26	1040,33	0,66	-0,39	0,77
19	451349,82	71804,51	450996,00	70763,75	353,82	1040,76	0,22	0,05	0,22

Preglednica 16 podaja rezultate merjenja oslonilnih točk na stereoparu IKONOS. Translacijska parametra smo izračunali na podlagi odstopanj, podanih v 6. in 7. stolpcu preglednice in znašata 353,60 m po osi Y oziroma 1040,71 m po osi X. Standardna odklona translacijskih parametrov sta:

- po osi Y: 0,58 m,
- po osi X: 0,44 m.

Analizo položajne točnosti georeferenciranih ortofotov izračunamo iz odstopanj med koordinatami n oslonilnih točk, ki smo jih izmerili na ortofotu, izdelanem iz posnetka IKONOS, in premaknili za izračunano translacijo (x_i) ter koordinatami oslonilnih točk, izmerjenih na DOF050 (x_p). Srednji pogrešek m izračunamo (32) (Frančula, Lapaine, 2003):

$$m = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_p)^2} . \quad (32)$$

Preglednica 17: Analiza točnosti georeferenciranja stereopara IKONOS.

Table 17: IKONOS stereopair georeferencing accuracy assessment.

	Oslonilne točke (19)			Kontrolne točke (15)		
	os Y [m]	os X [m]	položaj [m]	os Y [m]	os X [m]	položaj [m]
m	0,56	0,43	0,71	0,57	0,44	0,72
max	0,97	-0,93	1,23	-1,18	-0,94	1,23
min	-0,09	-0,03	0,10	0,11	-0,04	0,15
povprečje	-	-	-	-0,40	-0,33	0,64

Preglednica 17 podaja srednje pogreške in največje (*max*) ter najmanjše (*min*) odklone po koordinatnih oseh in po položaju točk. Položajna odstopanja smo preverili tudi na petnajstih kontrolnih točkah. Samo na eni kontrolni točki je bilo položajno odstopanje večje od enega metra (1,23 m).

7.1.2 Točnost georeferenciranja posnetka GeoEye-1

Posnetek GeoEye-1 smo transformirali v prostor državnega koordinatnega sistema z uporabo DLT, ki je primerna za georeferenciranje manjših območij. Naš posnetek pokriva območje 10 km x 10 km. Enaindvajset oslonilnih točk za georeferenciranje posnetka, smo izmerili na listih državnega ortofota DOF050 in digitalnega modela višin DMV 5.

Preglednica 18: Georeferenciranje posnetka GeoEye-1.

Table 18: GeoEye-1 image georeferencing.

	DOF050 in DMV 5			GeoEye-1		DLT		Položajni pog. [m]
	Y [m]	X [m]	Z [m]	u [pix]	v [pix]	ΔY [m]	ΔX [m]	
1	459289,42	105566,23	314,40	-7028,49	-6710,01	-0,47	-0,19	0,51
2	461939,63	105799,39	304,88	-7484,36	-1411,34	0,67	0,24	0,71
3	465295,45	105909,86	284,30	-7685,06	5302,30	-0,96	-0,11	0,97
4	458269,86	103778,64	309,30	-3448,99	-8747,90	-0,01	-0,04	0,04
5	460075,46	104366,13	308,90	-4622,83	-5138,31	0,00	0,08	0,08
6	463901,03	104269,17	294,58	-4414,37	2512,67	0,13	0,45	0,47
7	465768,39	102882,57	291,39	-1639,45	6246,79	0,51	-0,16	0,53
8	457968,78	101489,92	306,18	1129,92	-9349,69	-0,15	-0,32	0,35
9	459921,27	102833,65	305,72	-1556,14	-5446,31	0,05	-0,30	0,30
10	461712,56	103020,16	302,50	-1925,43	-1864,60	0,30	-0,14	0,33
11	463897,80	102332,44	296,30	-543,93	2506,07	0,31	-0,16	0,35
12	461435,47	101250,86	299,73	1615,19	-2417,16	-0,31	-0,29	0,42
13	463928,56	100736,77	288,46	2654,17	2569,00	-0,02	0,20	0,20
14	466020,08	101404,24	286,79	1321,65	6750,95	0,33	0,12	0,35
15	458896,31	99304,82	295,69	5510,54	-7493,49	0,15	0,88	0,89
16	460438,21	99147,01	292,99	5828,69	-4410,18	-0,10	0,52	0,53
17	462648,22	98946,89	288,45	6232,10	8,92	0,00	-0,44	0,44
18	464773,91	97794,37	296,07	8539,64	4262,22	-0,89	0,74	1,16
19	462461,83	97448,79	288,92	9227,03	-364,70	0,38	-1,43	1,48
20	460073,91	98382,16	292,50	7358,22	-5138,87	0,04	0,33	0,33
21	461633,08	99450,07	291,46	5223,63	-2021,30	0,04	0,03	0,05

Preglednica 18 podaja rezultate merjenja oslonilnih točk na posnetku GeoEye-1. Slikovne koordinate (u , v) so podane v pikslih glede na slikovni koordinatni sistem z izhodiščem v sredini posnetka.

Preglednica 19: Analiza točnosti georeferenciranja posnetka GeoEye-1.

Table 19: GeoEye-1 image georeferencing accuracy assessment.

	Oslonilne točke (21)			Kontrolne točke (5)		
	os Y [m]	os X [m]	položaj [m]	os Y [m]	os X [m]	položaj [m]
m	0,39	0,47	0,61	0,33	0,40	0,52
max	-0,96	1,43	1,48	-0,53	0,54	0,63
min	0,00	0,03	0,04	0,07	0,05	0,35
povprečje	-	-	-	-0,24	0,36	0,51

Preglednica 19 podaja srednje pogreške m (32) in največje (max) ter najmanjše (min) odklone po koordinatnih oseh in po položaju točk. Položajna odstopanja smo preverili tudi na ortofotih, ki smo jih izdelali iz posnetka GeoEye-1. V ta namen smo na območju, kjer smo testirali postopke samodejnega zajema stavb, izbrali pet kontrolnih točk. Največje položajno odstopanje na kontrolnih točkah je znašalo 0,63 m.

7.1.3 Ostali dejavniki, ki vplivajo na položajno točnost satelitskih posnetkov

Georeferenciranje ni edini dejavnik, ki vpliva na položajno točnost zajetih stavb na satelitskih posnetkih. Velike spremembe v kakovosti posnetka in njegovi primernosti za zajemanje objektov so povezane z variacijami kota snemanja, kota sončnih žarkov in senc, letnih časov, atmosferskih pogojev ter ali je območje posneto v stereo ali mono tehniki. Razen na zadnjo lastnost uporabniki ne moremo vplivati. Obstajajo le omejene možnosti, da bi naročnik narekoval datum snemanja, čas in vremenske pogoje (Fraser in sod., 2002). Pri naročanju posnetkov QuickBird lahko zahtevamo časovno okno snemanja in interval kota snemanja (najmanjši in največji odklon od nadirja). Precej bolj omejene imamo možnosti pri naročanju posnetkov IKONOS in GeoEye-1. Podamo lahko le datum, po katerem naj bi bilo izvedeno snemanje. Kota snemanja ne moremo natančno zahtevati pač pa lahko izbiramo le med dvema opcijama: 60° - 90° oziroma 72° - 90° (Eurimage, 2009).

Na položajno točnost zajetih stavb še posebej močno vpliva kot snemanja. Slika 53 prikazuje superimpozicijo posnetka GeoEye-1 in katastra stavb. Zaradi kota snemanja 63° so strehe stavb premaknjene glede na svojo tlorisno lego. Velikost premika je odvisna od kota snemanja in višine stavbe. Možnosti za premostitev težave so izdelava popolnega ortofota, za kar rabimo natančen DMP ali prostorske modele stavb (zadnja možnost ni smiselna pri uporabi posnetkov za vzdrževanje topografskih baz, saj bi bil popolni ortofoto pravilen le na območjih stavb, ki so že zajete v bazi). Manj zanesljiva metoda je določanje višine stavb iz dolžine senc in kota sončnih žarkov.

Težavo pri interpretaciji in zajemu stavb pogosto predstavljajo tudi sence, ki prekrivajo detajle stavb in okolice ter tako onemogočajo pravilno prepoznavanje obrisa stavbe.



Slika 53: Kot snemanja povzroča premik streh.

Figure 53: View angle causes building roofs displacement.

7.2 Primernost samodejnega odkrivanja stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov

Primernost samodejnega odkrivanja stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov bomo podali na podlagi rezultatov praktičnega dela naloge. V raziskavah se je izkazalo, da so končni rezultati v veliki meri odvisni od izboljšanja podob pred izvedbo samodejnih postopkov. Zato si najprej oglejmo metode, ki smo jih uporabili za izboljšanje podob.

7.2.1 Priporočila za izboljšavo podob pred izvedbo samodejnih postopkov

Visokoločljive satelitske podobe so močno obremenjene s šumom. Kljub temu, da novejši satelitski sistemi snemajo 11-bitne podobe, podobe redko zajamejo celotno zalogo vrednosti. Dejanski dinamični razpon zavzema nekje med 8 in 9 bitov, zato kontrast največkrat ni najboljši. Pred nadaljnjo obdelavo moramo zato v čim večji meri odstraniti šum in izboljšati kontrast podob.

Za odstranjevanje šuma se je kot učinkovita izkazala kombinacija morfoloških operacij in anizotropne difuzije. Z morfološkim odpiranjem z rekonstrukcijo, ki mu sledi morfološko zapiranje z rekonstrukcijo, smo najprej odstranili manjše objekte (npr. dimniki) in umetne tvorbe, šum pa smo učinkovito odstranili z uporabo anizotropne difuzije, ki je poleg glajenja ohranila ostre robove objektov. V vseh primerih je zadoščalo 9 iteracij filtriranja z anizotropno difuzijo.

Po odstranitvi šuma smo izboljšali kontrast podob. Pri tem se je uporaba Wallisovega prilagodljivega filtra izkazala za učinkovitejšo od klasičnih metod za razteg histograma. Wallisov filter izboljšuje kontrast znotraj trenutnega okna, v katerem izračuna lokalno aritmetično sredino in standardni odklon ter ju prilagodi želenim vrednostim. Lokalno delovanje filtra močnejše izboljša kontrast od klasičnih metod. Pri uporabi filtra je pomembna izbira velikosti okna, ki jo nastavimo glede na velikost objektov, ki jih želimo poudariti.

Za izboljšavo dinamičnega razpona celotne podobe smo uporabili linearni razteg histograma. Večina programske opreme za obdelavo podob danes že omogoča obdelavo 11-bitnih ali 16-bitnih podob. Za samodejni zajem DMP smo zato podobo raztegnili v 11-bitno. Tudi pri klasifikaciji podob smo dobili boljše rezultate z 11-bitnimi podobami. Za upodobitve in iskanje homogenih površin v postopkih barvne segmentacije in rasti regij smo podobe skrčili v 8-bitne, ki so zagotovile večjo homogenost površin.

Kot koristna operacija pred izdelavo DMP in iskanjem robov se je izkazalo tudi izboljšanje robov, ki smo ga izvedli s prištevanjem drugega odvoda podobe izvorni podobi. Drugi odvod smo izračunali z Laplaceovim filtrom s središčnim elementom -8.

7.2.2 Rezultati samodejnega odkrivanja stavb na visokoločljivih podobah

Za oceno primernosti samodejnega odkrivanja stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov na kratko strnimo rezultate samodejnega zajema, ki smo ga opisali v poglavju 6.

Za najprimernejšo metodo za samodejni zajem se je izkazala kombinirana uporaba državnega ortofota DOF050 in digitalnega modela površja (DMP). Z metodo smo odkrili 94,6 % vseh stavb na testnem območju. Zaradi enake prostorske ločljivosti ortofota in posnetkov satelita GeoEye-1 (0,5 m) lahko upravičeno sklepamo, da bi podobne rezultate dobili tudi z uporabo satelitskih posnetkov GeoEye-1, če bi iz njih izdelali kakovosten popolni ortofoto. Razlike med samodejnim zajemom in grafičnimi podatki topografske baze so se pojavile le v manjših detajlih (izpuščeni nadstreški nad vhodnimi vrati ali manjšimi balkoni). Na razpolago za samodejni zajem smo imeli DMP s prostorsko ločljivostjo 0,5 m. Rezultat bi lahko izboljšali z uporabo DMP z višjo prostorsko ločljivostjo. V doktorski disertaciji Triglav Čekada (2009) za izdelavo načrtov v merilu 1 : 5000 predlaga visokoločljivo lasersko skeniranje z vsaj 12 točk na m², oziroma 20 točk na m² v primeru bujne vegetacije. S takšno gostoto skeniranih točk lahko izdelamo DMP s prostorsko ločljivostjo 0,25 m ali boljšo, s tem pa bi odpravili tudi težave pri zajemanju manjših detajlov. Ostale napake samodejnega zajema so bile posledica vegetacije, ki delno ali pa v celoti zakriva stavbe. Iz tega lahko sklepamo, da zgolj DMP ni zadosten podatek za zajem vseh stavb, ampak bi morali uporabiti celotne rezultate laserskega skeniranja s podatki o različnih odbojih laserskih žarkov, s čimer bi odkrili tudi stavbe in dele stavb pod vegetacijo. Težave, ki jih pri samodejnem prepoznavanju stavb povzročajo sence, smo učinkovito rešili z izračunom indeksa senc in analizo teksture DMP. Kombinacijo obeh postopkov smo razvili v okviru doktorske naloge. V nobenem primeru pa samodejni zajem ni sposoben razločiti posameznih stavb, ki se v naravi držijo skupaj. Takšne stavbe lahko zajamemo le z enim arealom, medtem ko so v topografski bazi zajete v več areali.

Na posnetku IKONOS smo s samodejnim postopkom odkrili 83,2 % stavb na testnem območju, kar je primerljivo z rezultati ostalih avtorjev (Fraser, Baltsavias, Gruen, 2001a). Samodejni postopek je našel 4,9 % stavb, ki dejansko ne obstajajo v naravi ali na posnetku. Povsem pravilno smo zajeli le 15,5 % stavb. DMP in DMV smo izdelali na stereoparu podob IKONOS, kasnejša obdelava je v skladu z izbrano metodologijo doktorske naloge temeljila na obravnavi enega posnetka. Na enem posnetku lahko samodejni postopek pravilno prepozna le stavbe, ki so enakomerno osvetljene in imajo velik kontrast v primerjavi z okolico. Težave pri samodejnem zajemu predstavljajo tudi sence in šibka oblačnost. Slabša prostorska ločljivost (1 m) in poševno snemanje stereopara včasih onemogočata ločevanje stavb, ki so v prostoru zelo skupaj. V 8,5 % je samodejni postopek združil dve ali več sosednjih stavb v en areal.

Obravnavano območje je imelo bolj podeželske kot urbane značilnosti z veliko majhnih družinskih hiš, ki imajo različno orientacijo v prostoru. Podatki so bili daleč od idealnih, na kakršnih so predstavljeni rezultati iskanja stavb v različni literaturi. Za optimalne rezultate iskanja stavb smo zato v okviru doktorske naloge razvili postopek, ki sloni na izvorni kombinaciji uporabe anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij.

Samodejni postopek je na posnetku GeoEye-1 v celoti ali vsaj delno našel vse stavbe na ožjem območju, ki smo ga primerjali z ročnim zajemom. Na celotnem testnem območju je postopek spregledal 12,6 % stavb. V vseh primerih so bile to manjše stavbe (garaže in vrtno lope), ki jih v večini primerov v celoti ali deloma prekriva vegetacija in jih tudi z ročnim zajemom ne bi mogli pravilno interpretirati. Več stavb bi našli, če bi za iskanje uporabili posnetke, narejene v zimskem času. Vendar bi se s tem povečalo število lažnih stavb, ki bi jih odkril samodejni postopek (stavbe, ki dejansko ne obstajajo v naravi ali na posnetku). Samodejni postopek bi našel stavbe na območjih, ki smo jih sicer odstranili iz iskanja z uporabo vegetacijskega indeksa (gola tla, njive). Kakovost iskanja stavb je bila boljša kot na posnetku IKONOS predvsem zaradi boljše radiometrične kakovosti in višje prostorske ločljivosti posnetkov (1 m za posnetek IKONOS, 0,5 m za posnetek GeoEye-1). Postopek je prepoznal tudi 3,9 % stavb, ki v naravi ali na posnetku dejansko ne obstajajo. Težava samodejnega zajema na enem posnetku je predvsem v ločevanju streh od ostalih betonskih in asfaltnih površin, kar zahteva skrben izbor vzorcev za nadzorovano klasifikacijo. Samodejni postopek iskanja stavb lahko optimiziramo, če za rešitev opisane težave uporabimo višinske podatke (normalizirani digitalni model površja nDMP). Z uporabo višinskih podatkov lahko tudi izboljšamo kakovost rezultatov iskanja.

Preglednica 20 prikazuje skupne rezultate samodejnega iskanja stavb na vseh treh uporabljenih podatkovnih virih. Z vsemi tremi metodami samodejnega iskanja stavb smo v celoti ali vsaj deloma odkrili več kot 80 % vseh stavb na območju, kar je skladno s hipotezo doktorske naloge. Odstotek odkritih stavb je izračunan glede na vse stavbe, ki se nahajajo na referenčnih virih (KS, DTK 5 ali ročni zajem stavb). V preglednici je podan tudi odstotek stavb, ki jih je samodejni postopek našel, vendar na posnetkih in v naravi dejansko ne obstajajo.

Preglednica 20: Ocena samodejnega iskanja stavb na različnih podatkovnih virih.

Table 20: Evaluation of the automatic building detection from different data sources.

	DOF in DMP	IKONOS	GeoEye-1
Odkrite stavbe [%]	94,6	83,2	87,4
Neobstoječe stavbe [%]	5,9	4,9	3,9

Preglednica 21 prikazuje pravilnost vektorskega zajema stavb na vseh treh uporabljenih podatkovnih virih. Kot pravilno zajete stavbe smo šteli tiste stavbe, ki v primerjavi z referenčnimi podatki položajno ne odstopajo več kot 1 piksel. Na posnetku GeoEye-1 nismo izvajali vektorizacije stavb. Obrisi stavb, ki smo jih našli na DOF in DMP ustrezajo nivoju razpoznavnosti LOD1 po standardu CityGML. Točnost je v standardu CityGML podana s standardnim odklonom absolutnih koordinat točk. CityGML za LOD1 predpisuje položajno točnost 5 m, pri tem pa morajo biti upoštevane vse stavbe s površino obrisa vsaj 6 m x 6 m (OGC, 2008). Na posnetku IKONOS samodejni postopek ni našel nekaterih večjih stavb.

Preglednica 21: Ocena pravilnosti vektorskega zajema stavb z različnih podatkovnih virov.

Table 21: Vectorization of buildings from different data sources accuracy evaluation.

	DOF in DMP	IKONOS	GeoEye-1
Pravilno zajete [%]	39,0	15,5	-
Generalizirane [%]	53,3	26,4	-
Napačna površina [%]	2,9	43,4	-
Napačna orientacija [%]	3,8	16,3	-
Drugo [%]	1,0	1,6	-

Preglednica 22 prikazuje oceno kakovosti rastrskega zajema stavb na vseh treh podatkovnih virih v primerjavi z referenčnimi podatki. Vektorizirane stavbe iz samodejnega zajema stavb na ortofotu in DMP smo primerjali s KS, stavbe, zajete na posnetku IKONOS, smo primerjali z DTK 5. Stavb na posnetku GeoEye-1 nismo vektorizirali. Ocena kakovosti je pri posnetku GeoEye-1 izračunana s primerjavo pikslov, ki smo jih klasificirali kot stavbe, in pikslov iz ročnega zajema stavb na posnetku. Odstotek kakovosti zajema je najboljši v primeru zajema

stavb na posnetku GeoEye-1. Pri tem je treba upoštevati dejstvo, da smo za ročni zajem izbrali le stavbe, ki jih je mogoče nedvoumno interpretirati na posnetku. Kakovost zajema stavb na ortofotu in DMP je slabša predvsem zaradi visokega faktorja razvejitve. KS je bil na testnem območju izdelan s terestričnimi meritvami temeljev stavb, pri samodejnem zajemu pa smo vektorizirali obode streh. V splošnem so zato stavbe na DMP zajete z večjo površino.

Preglednica 22: Ocena kakovosti rastrskega zajema stavb na različnih podatkovnih virih.

Table 22: Building extraction from different data sources quality assessment.

	Faktor razvejitve	Faktor pogreška	% odkritja	% kakovosti
DOF in DMP	0,34	0,04	95,87	71,94
IKONOS	0,34	0,68	59,49	49,46
GeoEye-1	0,13	0,18	84,79	76,53

Glede na visoke odstotke odkritih stavb (preglednica 20), nizke odstotke pravilno zajetih stavb (preglednica 21) in slabši odstotek kakovosti rastrskega zajema (preglednica 22) lahko potegnemo sklep, da so predlagane metode primernejše za iskanje sprememb v topografskih bazah velikih meril (1 : 5000) kot za dejanski zajem v bazo podatkov.

7.3 Odkrivanje sprememb v topografskih bazah

Prepoznavanje sprememb v podatkovni bazi je eno glavnih opravil organizacije, ki vodi bazo. V večini primerov je to še vedno ročno delo, ki ga opravljajo fotogrametri ali terenski ogledniki. Spremembo lahko opravijo tudi na podlagi elaborata, ki ga izdelata geodetsko podjetje, podjetje, ki izdeluje projektno dokumentacijo, investitor gradnje, lastnik parcele, na kateri stoji stavba ali je z njo povezana, imetnik stavbne pravice, lastnik stavbe ali dela stavbe ali upravnik stavbe, državni organ, lokalna skupnost ali pa se sprememba opravi po uradni dolžnosti. Enega zadnjih virov sprememb podajajo strokovnjaki za interpretacijo podob, ki s skrbnim pregledom ortofotov označijo spremembe. Spremembe v topografski bazi se običajno zajamejo na fotogrametričnih delovnih postajah, ki omogočajo zajem objektov v stereo

tehniki. Kljub vsem navedenim virom sprememb, običajno interpretatorji še vedno odkrijejo spremembe, ki še niso bile evidentirane.

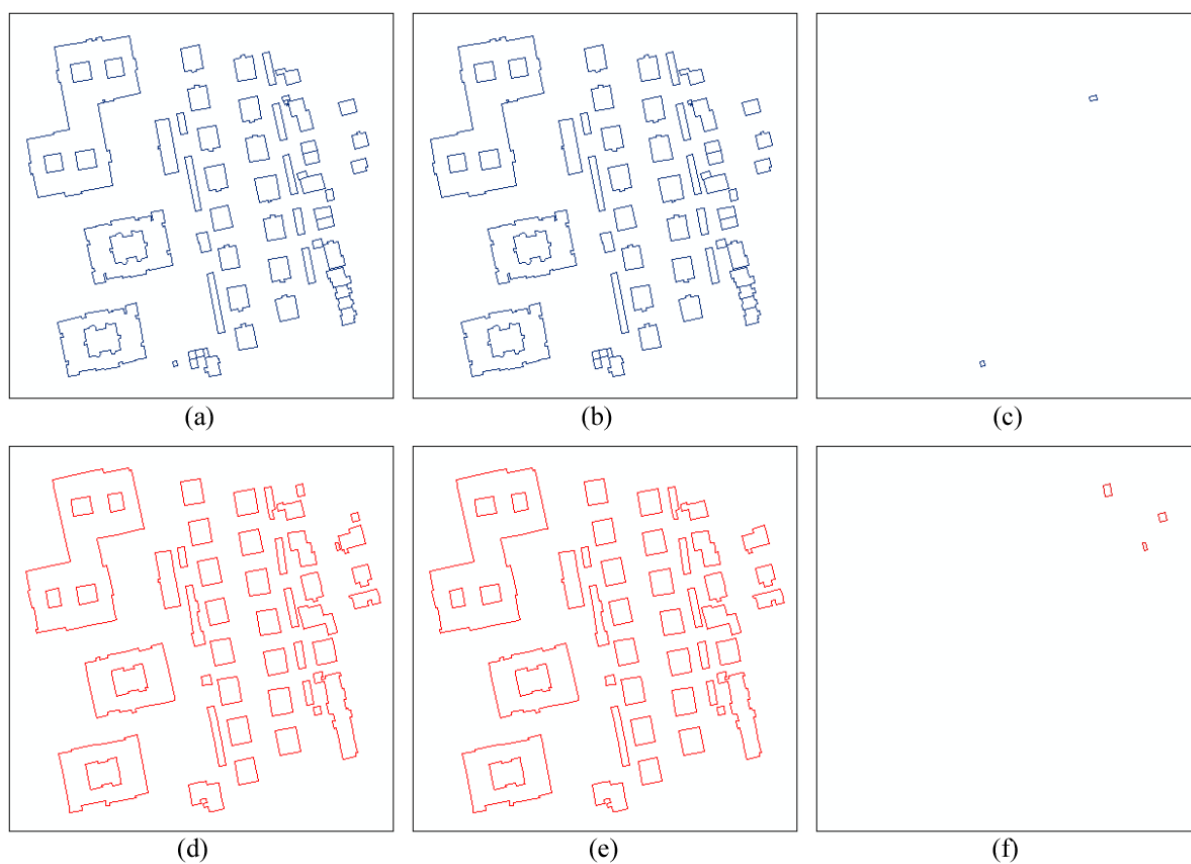
Ročno pregledovanje podob zahteva skrbno načrtovano metodologijo in koncentracijo. Geodetska uprava Velike Britanije je v letu 2007 izvedla raziskavo, v kateri so odkrili, da je pri pregledovanju podob in neprestanem spreminjanju povečave težko slediti območjem na podobah, ki so že bila pregledana. Operaterjem se lahko pripeti, da spregledajo del podobe (predvsem v vogalih) in tako spremembe ostanejo neoznačene. Avtomatizacijo delovnega postopka za zajem podatkov lahko izvedemo v različnih fazah. Popolnoma samodejni zajem je že vrsto let tema raziskav svetovne fotogrametrične skupnosti, vendar bo v bližnji prihodnosti težko realiziran. Na to dejstvo opozarja tudi naša raziskava. Realnejša je avtomatizacija odkrivanja sprememb, pri kateri mora sistem le odkriti, da gre za spremembo, ne glede na to, za kakšno vrsto spremembe gre. Na odkrito spremembo opozorimo operaterja, ki sprejme končno odločitev o njeni potrditvi ali zavrnitvi in jo po potrebi izvrši. Tovrsten postopek lahko prihrani velike količine časa in poveča objektivnost v delovnem postopku vzdrževanja topografskih podatkov (Holland in sod., 2008).

V zadnjih desetletjih je bila izvedena vrsta raziskav za samodejno odkrivanje sprememb na podlagi podob, posnetih v različnih časovnih obdobjih. Tehnike so dobrodošle, vendar pogosto označijo tudi spremembe, ki nas ne zanimajo in so posledica na primer manjše spremembe vegetacije ali premikanja prometa. Učinkovitost tehnik je v veliki meri odvisna od narave podatkov, ki jih opazujemo. Odkrivanje sprememb v topografskih bazah, ki vodijo podatke o stavbah, je še najbolj učinkovita s primerjavo obstoječih topografskih podatkov z ažurnimi podobami (Holland in sod., 2008).

V naši raziskavi smo uporabili enoslikovne tehnike za odkrivanje in zajem stavb na podobah visoke ločljivosti. Ocenili smo, da so zajeti podatki uporabnejši za odkrivanje sprememb kot za dejanski zajem stavb v bazo. V nadaljevanju podajamo predlog uporabe samodejno pridobljenih podatkov za vzdrževanje topografskih baz.

7.3.1 Uporaba zajetih podatkov za vzdrževanje topografskih baz

Ena od možnosti uporabe samodejno zajetih podatkov za vzdrževanje ustrezne topografske baze je primerjava obeh podatkovnih virov v sistemu GIS. Postopek predstavljamo na praktičnem primeru, v katerem so rezultati samodejnega zajema stavb na kombinaciji ortofota in višinskih podatkov primerjani s podatki katastra stavb (KS).



Slika 54: Primerjava katastra stavb s podatki samodejnega zajema.

Figure 54: Building cadastre and automatic extraction results comparison.

Pred iskanjem sprememb moramo podatke ustrezno pripraviti. S konjunkcijo med KS in najdenimi stavbami odkrijemo stavbe, ki so v KS in jih je samodejni postopek našel. Z operatorjem »izključujoči ALI« med KS in omenjeno konjunkcijo ugotovimo, katere stavbe nismo uspeli poiskati. Izključujoči ALI, ki ga izvedemo med rezultati zajema in konjunkcijo, nam da odkrite novogradnje. Slika 54 prikazuje primerjavo KS (v zgornji vrsti) in

samodejnega zajema stavb (v spodnji vrsti). Levo je prikazan popoln izrez podatkov (a in d), v sredini je prikazana konjunkcija obeh podatkovnih virov (b in e). Slika 54 (c) prikazuje stavbe, ki jih samodejni postopek ni prepoznal. Slika 54 (f) prikazuje novogradnje, odkrite s samodejnim postopkom.

Na primeru vidimo, da samodejni postopek ni odkril dveh manjših stavb. Iz njunega centroida v relacijski tabeli odčitamo njune koordinate in na razpoložljivih podatkih preverimo njun dejanski obstoj. Ena stavba predstavlja kiosk s površino 11,8 m² (glede na KS), druge stavbe ne moremo identificirati, saj jo na ortofotu popolnoma prekriva vegetacija. Ker smo v postopku iskanja uporabili samo izveden višinski model in ne celotnih podatkov laserskega skeniranja, kjer bi v tem primeru imeli podane tudi različne odboje laserskih žarkov, nam tudi pregled višinskih podatkov ne da odgovora. V takšnih primerih lahko dejanski obstoj stavbe ugotovimo le s terenskim ogledom.

Postopek je dodatno našel tri stavbe. Vse tri so očitne tako na ortofotu kot na višinskih podatkih. Stavbe bo treba na novo zajeti v KS. Lahko ga dopolnimo iz podatkov samodejnega zajema ali pa iz relacijske baze odčitamo koordinate, ki bodo vodile operaterja pri zajemu na letalskih posnetkih.

Stavbe na konjunkciji med KS in najdenimi stavbami primerjamo med seboj v odnosu ena proti mnogo. Ena od težav pri samodejnem iskanju stavb je v tem, da postopek ni sposoben ločiti stavb, ki se držijo skupaj. Zato je enemu centroidu na podatkih samodejnega zajema v določenih primerih ustrezalo več centroidov stavb iz KS. S poizvedovanjem po lokaciji povežemo ustrezne centroide samodejnega zajema s centriidi KS. Pri zelo strnjeni poselitvi obstaja nevarnost, da samodejni postopek napačno poveže centroide. V tem primeru je bolje, da stavbe, ki se v KS dotikajo, združimo v en areal. Tako lahko uporabimo poizvedovanje v odnosu ena proti ena. S poizvedovanjem po relacijski bazi lahko primerjamo površino zajetih stavb na obeh podatkovnih virih. Primerjamo lahko tudi razliko v dolžini obrisa, položaj centroidov in podobno.

OBJECTID *	Shape_Length	Shape_Area	OBJECTID	Shape_Length	Shape_Area
25	25.744387	39.170513	21	91.999742	325.506776
23	52.180101	166.220789	21	91.999742	325.506776
22	21.658897	28.573671	21	91.999742	325.506776
21	62.707068	228.806698	22	62.000493	238.00352
20	37.911145	84.735316	23	66.000264	180.504099
18	65.537413	132.837288	25	64.999913	137.499598

Slika 55: Izrez iz relacijske tabele.

Figure 55: Relational table clipping.

Slika 55 prikazuje izrez iz relacijske tabele. V prvem stolpcu so navedeni identifikatorji stavb, v drugem dolžina obrisa areala, v tretjem površina areala na KS. Stolpci 4 do 6 pomenijo isto za stavbe iz samodejnega zajema. Na primeru je razvidno, da se na stavbo samodejnega zajema z identifikatorjem 21 navezujejo stavbe z identifikatorji 22, 23 in 25 iz KS. Seštevek površin stavb 22, 23 in 25 na KS je precej manjši od površine stavbe 21 na samodejnem zajemu. Razlika v površini kaže na možne prizidke, kar so potrdili tudi dodatni pregledi podatkov. Stavba 21 na KS ima površino približno enako stavbi 22 iz samodejnega zajema. Do sprememb v naravi verjetno ni prišlo. Na splošno imajo stavbe v KS manjšo površino, kar je posledica že omenjenega dejstva, da je bil KS na tem območju izdelan s terestričnimi meritvami temeljev stavbe, pri samodejnem zajemu pa smo lahko določevali le obode streh stavb. V večini primerov imajo zato stavbe na KS približno za 10 % manjšo površino. O gotovi spremembi v naravi lahko govorimo, če se površini razlikujeta vsaj za 25 %. Iz relacijske baze preberemo koordinate centroidov, kjer smo ugotovili spremembe. KS bo treba na teh lokacijah posodobiti.

8 ZAKLJUČKI

V doktorski nalogi smo raziskovali, na kakšen način lahko visokoločljive slikovne vire vključimo v vzdrževanje obstoječih topografskih podatkov. Osredotočili smo se na nove satelitske posnetke, ki z metrsko prostorsko ločljivostjo prinašajo nov podatkovni vir v vzdrževanje topografskih podatkov. Zanimala nas je njihova uporabnost za iskanje sprememb in zajem topografskih podatkov, kakšne so pri tem omejitve in v kolikšni meri lahko nadomestijo ročno delo operaterjev in podatke letalskega snemanja, ki trenutno predstavljajo primarni vir za vzpostavitev in vzdrževanje topografskih podatkov. Osredotočili smo se na postopke samodejne obdelave podob. Zaradi obsežnosti tematike smo se v raziskavi omejili na objektni razred stavb in enoslikovne metode. Visokoločljive slikovne vire smo kombinirali z drugimi viri podatkov, kot so višinski podatki, ali že obstoječimi podatkovnimi viri v topografski bazi. Spoznanja, ki jih navaja literatura, smo preverili v praktičnem delu doktorske naloge. V ta namen smo postavili hipotezo, da je mogoče visokoločljive slikovne vire z minimalnim dopolnjevanjem s pomožnimi podatkovnimi viri (višinski podatki, obstoječe topografske karte) izkoristiti za samodejno pridobivanje podatkov o stavbah. V doktorski nalogi smo potrdili hipotezo, da lahko za iskanje stavb na slikovnih virih izdelamo nove samodejne postopke, s katerimi je mogoče ob visoki stopnji avtomatizacije odkriti nad 80 % vseh stavb na obravnavanem območju.

S samodejno obdelavo satelitskih posnetkov še ne moremo v celoti nadomestiti letalskega snemanja, ki se trenutno uporablja za vzdrževanje topografskih podatkov v podatkovnih bazah velikih meril (1 : 5000). S postopki samodejnega odkrivanja ne moremo prepoznati vseh stavb, ki se nahajajo v prostoru. Za izboljšanje detekcije je nujno interaktivno sodelovanje operaterja, ki bi samodejni postopek opozoril na neodkrita stavbe. S samodejnimi postopki nismo uspeli prepoznati manjših detajlov stavb (npr. balkoni, nadstreški, manjši prizidki), stavbe so bile zajete v generalizirani obliki. Opisane postopke bi zato lahko uporabili le za zajem podatkov v topografske baze manjših meril (1 : 10.000 ali 1 : 25.000). Vendar pa nov zajem v topografske baze dejansko ni potreben. Topografsko-kartografski sistem (TKSS) v Sloveniji že obstaja, topografski podatki so se v preteklih desetletjih vanj

zajemali s tradicionalnimi metodami kot so terenske meritve in fotogrametrični zajem. Za vzpostavitev in vodenje topografskih podatkov je pristojna Geodetska uprava Republike Slovenije. Glavna naloga v vodenju topografskih podatkov zato ni zajem novih podatkov, pač pa njihovo vzdrževanje. V postopku vzdrževanja je zelo pomembno iskanje sprememb, ki so se zgodile v prostoru in še niso evidentirane v topografskih bazah.

Podatki o stavbah se v katastru stavb (KS) vzdržujejo na podlagi elaboratov, ki jih izdelajo geodetska podjetja, podjetja, ki izdelujejo projektno dokumentacijo, investitor gradnje, lastnik parcele, na kateri stoji stavba ali je z njo povezana, imetnik stavbne pravice, lastnik stavbe ali dela stavbe ali upravnik stavbe, državni organ, lokalna skupnost ali pa se sprememba opravi po uradni dolžnosti. V praktičnem delu naloge smo med obdelavo podatkov odkrili, da kljub vzpostavljenemu sistemu vzdrževanja, vse spremembe niso vnesene v KS ali DTK 5. Med topografskimi podatki, ki smo jih od geodetske uprave pridobili v marcu 2009 in ortofoti, izdelanimi leta 2006 ali satelitskimi posnetki iz leta 2007 obstajajo razlike v obliki podrhtih stavb ali novogradenj. Ena od sprememb, ki jih uradno vzdrževanje ne odkrije, so tudi črne gradnje. Topografske podatke moramo zato nujno vzdrževati tudi s pregledom slikovnih podatkovnih virov. Za tovrstno iskanje sprememb so se satelitski podatki izkazali kot pomemben člen. Na posnetku IKONOS smo s samodejnimi postopki odkrili 83,2 %, na posnetku GeoEye-1 pa 87,4 % vseh stavb na obravnavanem območju. S samodejnim iskanjem sprememb na visokoločljivih slikovnih virih lahko opozorimo operaterja na spremembo v prostoru, slednji pa to spremembo zavrne ali sprejme in jo evidentira v topografsko bazo. Samodejnost postopka pri tem prinese večjo objektivnost pri iskanju sprememb. Opisane postopke lahko uporabimo tudi za kontrolo zajema podatkov v državne topografske baze. Satelitske posnetke bi lahko razen za iskanje sprememb pri stavbah, uporabili tudi za iskanje ostalih sprememb v prostoru (npr. krčenje gozda, spremembe v površini njiv).

Na podlagi raziskav, ki smo jih izvedli, lahko ugotovimo, da povsem samodejni sistem za vzdrževanje topografskih baz velikih meril (1 : 5000), kjer v postopku ne bi sodeloval tudi usposobljen operater, še ni izvedljiv. Raziskave, ki smo jih opravili z enoslikovnimi metodami, je treba razširiti in nadgraditi z dvo ali večslikovnimi metodami. Na tem področju še vedno ni povsem izkoriščeno letalsko snemanje, kjer imamo prostor pokrit z več posnetki. S samodejnim iskanjem linij in odkrivanjem homolognih linij (iste linije, ki pripadajo stavbi

na različnih posnetkih) bi pridobili tudi podatke o višini objektov in izdelali prostorske modele stavb. Višinski podatki so zelo pomembni pri samodejnemu odkrivanju stavb na posnetkih in bi jih morali vsekakor vključiti v nadaljnje raziskave. Na kombinaciji digitalnega ortofota in digitalnega modela površja (DMP), izdelanega iz podatkov lidarskega snemanja, smo odkrili 94,6 % vseh stavb na obravnavanem območju. Z obdelavo DMP lahko stavbe učinkovito ločimo od okolice (npr. od ostalih betonskih površin). Višinske podatke lahko izdelamo s klasičnimi fotogrametričnimi metodami iz letalskih ali stereo satelitskih posnetkov. Z vidika samodejnosti izdelave DMP je zelo pomembno lasersko skeniranje. Z laserskim skeniranjem z gostoto 12 do 20 točk na m² pridobimo učinkovite podatke za izdelavo načrtov v merilu 1 : 5000 (Triglav Čekada, 2009). Poleg tega že sam oblak lidarskih točk z atributi omogoča kakovostno izdelavo 3D modelov stavb (Dorninger, Pfeifer, 2008). Velik potencial za iskanje stavb v kombinaciji s podatki laserskega snemanja kažejo tudi satelitske podobe GeoEye-1 s prostorsko ločljivostjo 0,5 m, ki ustreza prostorski ločljivosti državnega ortofota, izdelanega iz letalskih posnetkov.

Za iskanje sprememb med stavbami v topografskih bazah, so primerni satelitski posnetki, ki imajo prostorsko ločljivost 1 m ali boljšo. Z uporabo oslonilnih točk jih lahko v prostor postavimo z zadovoljivo točnostjo za zajem podatkov v topografske baze. Samo uporaba pankromatskih podob večkrat ni dovolj. V raziskavi se je izkazal tudi pomen multispektralnih podob, ki omogočajo boljše prepoznavanje stavb. V primerjavi letalskih in satelitskih podob imajo slednje nekaj prednosti in slabosti. Prednosti so:

- operativnost satelitskih snemalnih sistemov 365 dni na leto. Za območja, ki so podvržena nenehnim spremembam lahko naročimo periodične posnetke;
- visoka frekvenca ponovnega obiska (3-7 dni);
- relativno hitra obdelava podob;
- snemanje ni omejeno z zahtevami letalske kontrole;
- podobe pokrivajo velika območja, kar zmanjša potrebo po izvajanju blokovne izravnave snopov in izdelavi mozaikov;
- lažji dostop do oddaljenih in prepovedanih območij;
- končni uporabnik ni odvisen od lastnega snemalnega sistema in letalske opreme;

- omogočajo hiter zajem topografskih podatkov velikih območij.

Slabosti v primerjavi z letalskimi posnetki so:

- običajno poševni posnetki, ki jih dobimo s strani dobavitelja posnetkov. Naročniki imamo le omejene možnosti za podajanje zahtev za snemanje podob (Fraser in sod., 2002; Eurimage, 2009). Nagnjenost senzorja pri snemanju, ki je večja od 25° običajno ni primerna za zajem objektov v topografske baze (Holland, 2008);
- ne moremo natančno vplivati na čas snemanja in dostavo podob;
- drugačen produkcijski postopek od že ustaljenega fotogrametričnega postopka;
- slabša prostorska ločljivost;
- velika verjetnost, da bodo del zemeljske površine na podobah prekrivali oblaki.

Na nivoju digitalne obdelave podob je danes možno avtomatizirati praktično vse faze procesa. V Sloveniji nam manjkajo predvsem raziskovalni dosežki in izkušnje na tem področju. Za slovenski prostor predstavlja doktorska naloga začetek raziskovanj na področju samodejnega iskanja in zajema stavb za potrebe vzdrževanja topografskih podatkov in predlaga nekatere izboljšave v trenutnem vzdrževanju topografskih podatkov. Prispevek doktorske naloge znanosti predstavlja lasten postopek za iskanje stavb na visokoločljivih satelitskih posnetkih, ki temelji na uporabi anizotropne difuzije in izvorni kombinaciji barvne segmentacije, rasti regij in nenadzorovane klasifikacije.

9 POVZETEK

Topografske podatke vodimo v topografskih bazah. Enega od objektnih področij v topografskih bazah predstavljajo stavbe. V Sloveniji vodimo podatke o stavbah v katastru stavb in Državni topografski karti v merilu 1 : 5000 (DTK 5). Podatke v topografskih bazah moramo redno dopolnjevati in vzdrževati. Izvorni vir za vzdrževanje predstavljajo posnetki cikličnega aerosnemanja in iz njih izdelani barvni in bližnje infrardeči ortofoti. Vzdrževanje se izvaja po ustaljenih postopkih s klasičnimi fotogrametričnimi metodami. V doktorski nalogi smo raziskali, kako lahko obstoječe izvorne vire razširimo z uporabo novih virov in avtomatiziramo sistem vzdrževanja. Omejili smo se na ožji raziskovalni problem samodejnega odkrivanja stavb na visokoločljivih podobah z enoslikovnimi postopki.

Po letu 1999 je bilo v različne Zemljine tirnice izstreljenih več komercialnih satelitov, ki zajemajo posnetke visoke ločljivosti. Sateliti GeoEye-1, IKONOS, KOMPSAT-2 in QuickBird snemajo pankromatske posnetke z velikostjo piksla 1 m ali manj, poleg tega pa zajemajo površino Zemlje še z multispektralnimi posnetki. V raziskavi smo analizirali, kako lahko te nove vire vključimo v obstoječ sistem vodenja topografskih podatkov. Zanimala nas je uporabnost satelitskih posnetkov za iskanje in zajem podatkov v državne topografske baze, položajna točnost, ki jo lahko z njimi dosežemo, kakšne so njihove omejitve in v kolikšni meri lahko nadomestijo podatke letalskega snemanja ter ročno delo operaterjev. Postavili smo hipotezo, da visokoločljive satelitske podatke lahko uporabimo za vzdrževanje topografskih podatkov o stavbah. Izdelamo lahko nove samodejne postopke, s katerimi bomo odkrili vsaj 80 % vseh stavb na obravnavanem območju. Z raziskavami, izvedenimi v okviru doktorske naloge, smo hipotezo potrdili.

Hipotezo in postavljene cilje smo v praksi preverili na treh različnih primerih podatkov, ki lahko nadomestijo obstoječe izvorne vire. Metoda dela je slonela na izdelavi natančne maske stavb in njeni vektorizaciji. Uporabili smo pretežno lastne programske rešitve, ki omogočajo popoln nadzor nad različnimi vhodnimi parametri v samodejne postopke.

V prvem primeru smo uporabili državni barvni ortofoto s prostorsko ločljivostjo 0,5 m, bližnji infrardeči ortofoto s prostorsko ločljivostjo 1 m, digitalni model površja (DMP) in digitalni model višin (DMV), oba izdelana iz podatkov lidarskega snemanja ter zapisana v rastrskem formatu z velikostjo piksla 0,5 m. Masko stavb smo izdelali iz normaliziranega digitalnega modela površja (nDMP), iz katerega smo z uporabo normaliziranega diferencialnega vegetacijskega indeksa (NDVI) odstranili vegetacijo in jo naknadno izboljšali z lastno metodo, ki jo sestavljata kombinacija indeksa senc in analiza teksture nDMP. Končno masko stavb smo vektorizirali z uporabo Houghove transformacije.

V drugem primeru smo uporabili stereopar posnetkov IKONOS. S samodejnimi fotogrametričnimi metodami slikovnega ujetanja smo izdelali DMP in DMV. V nadaljnjem postopku smo uporabili enoslikovne metode. Izdelali smo ortofote posameznih kanalov in izračunali nDMP. Začetno masko stavb smo izdelali iz nDMP. Z NDVI in podatki o cestah, dobljenih iz DTK 5, smo iz maske odstranili vegetacijo in prometne površine. Zaradi napak v samodejni izdelavi DMP smo masko izboljšali z lastno metodo, ki temelji na kombinaciji anizotropne difuzije, nenadzorovane klasifikacije, barvne segmentacije in rasti regij. Končno masko smo vektorizirali s Houghovo transformacijo.

V zadnjem primeru smo obravnavali posnetek GeoEye-1. Začetno masko stavb smo izdelali z nadzorovano klasifikacijo, ki temelji na objektnem pristopu. Masko smo izboljšali z uporabo NDVI, podatkov o cestah in postopka rasti regij na multispektralnih podobah. Končne maske nismo vektorizirali, saj neposreden zajem stavb v podatkovno bazo zaradi poševnega posnetka (kot snemanja 63°) ni smiseln.

Za najprimernejšo metodo za samodejni zajem se je izkazala kombinirana uporaba DMP in ortofota. Z njo smo odkrili 94,6 % vseh stavb na testnem območju. Ortofoto letalskega snemanja lahko nadomestimo s popolnimi ortofoti, izdelanimi iz podobe GeoEye-1. Samodejni postopek generalizira kompleksnejše stavbe. Tako pri ortofotu kot pri posnetku GeoEye-1 ovira iskanje visoka vegetacija, ki v celoti ali delno prekriva stavbe. Težavo lahko odpravimo z uporabo celotnih podatkov laserskega skeniranja z gostoto 12-20 točk na m², iz katerih lahko izdelamo DMP z boljšo prostorsko ločljivostjo, stavbe pod vegetacijo pa

odkrijemo iz različnih odbojev laserskih žarkov. Na posnetku IKONOS je samodejni postopek prepoznal 83,2 % stavb na testnem območju. Na enem posnetku lahko samodejni postopek pravilno prepozna le stavbe, ki so enakomerno osvetljene in imajo velik kontrast v primerjavi z okolico. Interpretacijo samodejnega zajema je poslabšala slabša radiometrična kakovost podob, sence in šibka oblačnost. V nekaj primerih je postopek združil stavbe, ki so v prostoru zelo skupaj. Slabost enoslikovnih metod brez dodatnih višinskih podatkov se je pokazala pri obdelavi posnetka GeoEye-1. S klasifikacijo težko ločimo strehe od nekaterih betonskih in asfaltnih površin, kar smo nadoknadili z večjim številom izbranih vzorcev. Na posnetku GeoEye-1 smo s samodejnim postopkom prepoznali 87,4 % stavb na testnem območju.

S samodejnim iskanjem stavb na visokoločljivih podobah še ne moremo povsem nadomestiti letalskega snemanja in ročnega zajema podatkov v baze velikih meril (1 : 5000). Rezultati so uporabni za objektivnejše odkrivanje sprememb, na katere lahko opozorimo operaterja, ki te spremembe evidentira v bazo. Spremembe lahko poiščemo s poizvedovanjem v sistemu GIS.

Za iskanje sprememb med podatki o stavbah so primerni satelitski posnetki, ki imajo prostorsko ločljivost 1 m ali boljše in zaznavajo površino Zemlje tudi z multispektralnimi kanali. Z uporabo oslonilnih točk jih lahko v prostor postavimo z zadovoljivo točnostjo za zajem podatkov v topografske baze. V primerjavi letalskih in satelitskih posnetkov imajo slednji nekaj prednosti in slabosti. Prednosti so operativnost satelitskih snemalnih sistemov vse dni v letu, visoka frekvenca ponovnega obiska, relativno hitra obdelava podob, snemanje ni omejeno z zahtevami letalske kontrole, podobe pokrivajo velika območja, lažji dostop do oddaljenih in prepovedanih območij, končni uporabnik ni odvisen od lastnega snemalnega sistema in letalske opreme, omogočajo hiter zajem topografskih podatkov velikih območij. Slabosti v primerjavi z letalskimi posnetki so: običajno poševni posnetki, zmanjšan vpliv na pogoje in čas snemanja, nezanesljiv rok za dostavo podob, drugačen produkcijski postopek od že ustaljenega, slabša prostorska ločljivost in velika verjetnost, da bodo del zemeljske površine na podobah prekrivali oblaki.

V doktorski nalogi smo zbrali opis uporabljenih postopkov za predobdelavo (georeferenciranje) in izboljšavo podob pred izvedbo samodejnih postopkov. Predlagali smo

nekatero izboljšavo obstoječih postopkov za samodejni zajem stavb. Za slovensko prakso predstavlja doktorska naloga začetek raziskovanj na področju samodejnega iskanja in zajema stavb za potrebe vzdrževanja topografskih podatkov. Rezultati omogočajo objektivnejše odkrivanje sprememb v prostoru in kontrolo zajema v baze. Za vzpostavitev samodejnega sistema za vzdrževanje topografskih podatkov predlagamo nadaljnje raziskave s stereoskopskimi ali večslikovnimi postopki in vključitev podatkov laserskega skeniranja v postopek iskanja in zajema stavb.

10 SUMMARY

Topographic data are managed in topographic databases. Building data are one of the object types in topographic databases. In Slovenia, building data is managed within the Building Cadastre and the National Topographic Map with the scale of 1 : 5000 (DTK 5). The data in topographic databases need to be regularly updated and maintained. The original source used for maintaining the data are images acquired with cyclic aerial survey and colour and near-infrared orthophotos acquired from them. Maintenance is performed through standard photogrammetric methods. This doctoral thesis explores the possibilities for expanding the existing original sources with the use of new sources and solutions for installing an automatic maintenance. The scope is limited to the immediate research problem of automatic building extraction in high-resolution images with single-image processing.

After 1999, several commercial satellites with high-resolution imaging capability were launched into different orbits around Earth. The GeoEye-1, IKONOS, KOMPSAT-2 and QuickBird satellites capture panchromatic images with pixel sizes of 1 m or less, and additionally capture the Earth's surface with multi-spectral images. The research analysed how these new sources can be integrated into the existing topographic data management system. We were interested in how satellite imaging for data extraction and capturing can be applied in management of the national topographic database, the positional accuracy they can provide, and their limitations and scope within which they can be used to replace aerial survey data and manual work of the operators. This paper hypothesises that high-resolution satellite images can be used for maintaining topographic databases of buildings. New methods for automatic capturing at least 80 % of buildings on test area can be developed. Hypothesis was confirmed through researches, executed in doctoral thesis.

The hypothesis and the set aims were tested in practice on three different examples of data that can be used to replace the existing sources. The work method was based on creating an

accurate building mask and its vectorization. We mainly used own software solutions that enable total control of input parameters in automatic processes.

The first example used the national colour orthophotos with spatial resolution of 0.5 m, near-infrared orthophotos with spatial resolution of 1 m, the digital surface model (DSM) and the digital elevation model (DEM), both produced from lidar data and recorded in the 0.5 m pixel size raster format. The building mask was created from the normalized digital surface model (nDSM) to which the normalized difference vegetation index (NDVI) was applied to remove the vegetation. We further improved the data by applying our own method that combines the shadow index and nDMP texture analysis. The final building mask was vectorized using the Hough transform.

The second example used a stereopair of IKONOS images. Automatic photogrammetric methods of image matching were used to create DSM and DEM. In further processing, single-image methods were used. We created orthophotos of individual bands and calculated the nDSM. The initial building mask was created from nDSM. The NDVI and the road data extracted from DTK 5 were used to remove vegetation and traffic surfaces. Due to errors in automatic creation of the DSM, we improved the mask with our own method based on a combination of anisotropic diffusion, unsupervised classification, colour segmentation and region growing. The final mask was vectorized using the Hough transform.

The last example analyses the GeoEye-1 image. The initial building mask was created with supervised classification based on the object approach. The mask was enhanced using NDVI, road data and the process of region growing on multispectral images. We did not vectorize the final mask since direct capturing of buildings into the database is not feasible due to the obliqueness of images (63° sensor view angle).

The method that proved most suitable for automatic building extraction was the combined use of DSM and orthophotos. Method detected 94.6 % of all buildings in test area. The aerial imaging orthophotos can be replaced with true orthophotos created from the GeoEye-1 imagery. The automatic processing generalises more complex buildings. Similar to orthophotography, the problem of the GeoEye-1 image is in tall vegetation that completely or partially obscures

buildings. The problem can be resolved using the complete data from laser scanning with 12–20 points per m² density, which can be used to create a DSP with higher spatial resolution, while the buildings obscured by the vegetation are extracted based on different reflections of laser beams. The automatic processing of the IKONOS image identified 83.2 % of buildings in the test area. On a single image, the automatic processing is only capable of identifying buildings that are evenly lit and highly contrasted compared to the surroundings. The interpretation of the automatic capturing was negatively influenced by poor radiometric quality of images, shadows and moderate cloud cover. In some cases, the processing merged buildings that were close together. The weakness of single-image methods without the use of elevation data was revealed in the processing of the GeoEye-1 image. Classification is insufficient for distinguishing roofs from some of the concrete and asphalt surfaces. This was offset by using a greater number of training samples in classification. The automatic processing of the GeoEye-1 image identified 87.4 % of buildings in the test area.

The automatic building extraction on high-resolution images cannot yet completely replace aerial survey and manual capturing of data in large scale (1 : 5000) databases. The results can be used for more objective identification of changes, of which we can alert the operator who can enter these changes into the database. The changes can be searched with a query in the GIS system.

The most suitable imagery for identifying changes in building data are satellite images with the spatial resolution of 1 m or higher which can also scan the Earth's surface with multispectral bands. By using control points we can place images in space with adequate accuracy for acquisition of data for topographic databases. Comparing aerial and satellite images, the later have a few advantages and weaknesses. Their advantages lie in the constant operation of satellite imaging systems throughout the year, high revisiting frequency, relatively high image processing speed, no limitations to captured areas by flight control restrictions, larger area coverage, easier access to remote and restricted areas, they do not require own capturing systems and aerial equipment and they enable fast capturing of topographic data of large areas. The weaknesses compared to aerial images are: typically off-nadir viewing angles, lesser control over capturing conditions and time, unreliable image

delivery times, the production process which differs from the standard method, lower spatial resolution and high probability of cloud cover over portions of the captured surface.

This doctoral thesis presents a collection of methods used for pre-processing (georeferencing) and methods for enhancing images prior to automatic processing. It proposes a few improvements to existing methods for automatic building extraction. In the Slovenian professional environment, it represents the initial research in the field of automatic extraction and capturing of buildings for the purposes of maintaining topographic data. The results enable more objective identification of spatial changes and better control of capturing data for databases. For the purposes of setting up an automatic system for maintaining topographic data, we recommend further research of stereo or multiple image methods and incorporation of laser scanning data in the process of building extraction and capturing.

VIRI

Baillard, C., Maitre, H. 1999. 3D reconstruction of urban scenes from aerial stereo imagery: A focusing strategy. *Computer Vision and Image Understanding* 76, 3: 244–258.

Baltsavias, E., Pateraki, M., Zhang, L. 2001. Radiometric and geometric evaluation of Ikonos Geo images and their use for 3D building modeling. V: *Proceedings of the Joint ISPRS Workshop on High resolution mapping from space*. Hannover, Germany, September 2001. London, International Society for Photogrammetry and Remote Sensing.

Baltsavias, E. 2004. Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems. *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 3-4: 129-151.

Baltsavias, E., Li, Z., Eisenbeiss, H. 2005. DSM Generation and interior orientation determination of IKONOS images using a testfield in Switzerland. V: *Proceedings of the ISPRS Hannover Workshop 2005: High Resolution Earth Imaging for Geospatial Information*. Hannover, Germany, 17.-20. maj 2005. Hannover, Univerza v Hannoveru, Institute of Photogrammetry and GeoInformation.

Benediktsson, J. A., Pesaresi, M., Arnason, K. 2003. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations. *IEEE Transactions on Geoscience and Remote Sensing* 41, 9: 1940–1949.

Beyer, H., Baltsavias, E. 1996. 3D Image Metrology Systems and Applications. V: *Tutorial notes*, 18. ISPRS Congress. Vienna, Austria, 9. Julij 1996. Dunaj, TU Wien.

Braun, C., Kolbe, T. H., Lang, F., Schickler, W., Steinhage, V., Cremers, A. B., Förstner, W., Plümer, L. 1995. Models for photogrammetric building reconstruction. *Computer Graphics* 19, 1: 109–118.

Büyüksalîh, G., Oruç, M., Koçak, G. 2003. Geometric accuracy testing of IKONOS Geo-produkt mono imagery using different sensor orientation models. *Turkish Journal of Engineering & Environmental Sciences* 27, 5: 347-360.

Cheng, P., Toutin, T., Zhang, Y., Wood, M. 2003. QuickBird – geometric correction, path and block processing and data fusion. *Earth Observation Magazine* 12, 3: 24-30.

Crespi, M., Giannone, F., Poli, D. 2006. Analysis of rigorous models for pushbroom sensors. Application with QuickBird. V: *Proceedings of the ISPRS Commission 1, WG 4. Paris, France, 4.-7. Julij 2006. International Archives of Photogrammetry and Remote Sensing* 36, 1: 23-28.

Demir, N., Baltsavias, E. 2007. Object extraction at airport sites using DTMs/DSMs and multispectral image analysis.

http://www.photogrammetry.ethz.ch/general/persons/henri/PFG_Baltsavias.pdf (16.8.2008)

Demir, N., Poli, D., Baltsavias, E. 2008. Extraction of buildings and trees using images and lidar data. V: *Proceedings of the XXI International Congress of ISPRS. Beijing, China. ISPRS XXXVII, B4: 313-318.*

Di, K., Ma, R., Li, R. 2003. Rational functions and potential for rigorous sensor model recovery. *Photogrammetric Engineering and Remote Sensing* 69, 1: 33-41.

Dial, G., Bowen, H., Gerlach, F., Grodecki, J., Oleszczuk, R. 2003. IKONOS satellite, imagery, and products. *Remote Sensing of Environment* 88, 1: 23-36.

Digital Globe 2008. Spletna stran podjetja Digital Globe.

<http://www.digitalglobe.com/> (10.11.2008)

Dorninger, P., Pfeifer, N. 2008. A comprehensive automated 3D approach for building Extraction, reconstruction and regularization from airborne laser scanning point clouds. *Sensors* 8, 11: 7323-7343.

Dowman, I., Tao, V. 2002. An update on the use of rational functions for photogrammetric restitution. *ISPRS Journal* 7, 3: 22-29.

Duhovnik, M. 2005. Zajem topografskih podatkov DTK 5. *Geodetski vestnik* 49, 3: 441-443.

Ehlers, M., Klonus, S., Åstrand, P. J. 2008. Quality assessment for multi-sensor multi-date image fusion. V: *Proceedings of the XXI International Congress of ISPRS. Beijing, China. ISPRS XXXV, B4: 499-506.*

Eisenbeiss, H., Baltsavias, E., Pateraki, M., Zhang, L. 2004. Potential of IKONOS and QuickBird imagery for accurate 3D point positioning, orthoimage and DSM generation.

<http://www.cartesia.org/geodoc/isprs2004/comm7/papers/237.pdf>. (17.11.2008)

Eurimage 2009. Spletna stran korporacije Eurimage S.p.A.

<http://www.eurimage.com/> (9.12.2009)

Förstner, W. 1999. 3D-city models: Automatic and semiautomatic acquisition methods. V: D. Fritsch and R. Spiller (ur.). Photogrammetric week. Heidelberg, Germany, Wichmann Verlag: 291–303.

Förstner, W., Pluemer, L. 1997. Semantic modeling for the acquisition of topographic information from images and maps. Basel, Birkhaeuser Verlag.

Fraser, C. S., Baltsavias, E., Grün, A. 2001a. 3D building reconstruction from high-resolution IKONOS stereo images. V: Baltsavias, E., Grün, A. and Gool, L. V. (ur.). Automated Extraction of Man-Made Objects from Aerial and Space Images (III). Lisse, Swets & Zeitlinger: 331-344.

Fraser, C.S., Hanley H. B., Yamakawa, T. 2001b. Sub-metre geopositioning with IKONOS Geo Imagery. V: Proceedings of the Joint ISPRS Workshop on High resolution mapping from space. Hannover, Germany, September 2001. London, International Society for Photogrammetry and Remote Sensing.

Fraser, C. S, Baltsavias, E., Grün, A. 2002. Processing of Ikonos imagery for submetre 3D positioning and building extraction. ISPRS Journal Photogrammetry and Remote Sensing 56, 3: 177-194.

Fraser, C. S., Hanley, H. B. 2003. Bias compensation in rational functions for IKONOS satellite imagery. Photogrammetric Engineering and Remote Sensing 69, 1: 53-57.

Fraser, C. S., Hanley, H. B. 2005. Bias-compensated RPCs for sensor orientation of high-resolution satellite imagery. Photogrammetric Engineering and Remote Sensing 71, 8: 909-915.

Fraser, C. S., Ravanbakhsh, M. 2009. Georeferencing from GeoEye-1 Imagery: Early Indications of Metric Performance. V: Proceedings of the High-Resolution Earth Imaging for

Geospatial Information, ISPRS Hannover Workshop 2009, 2.-5. Junij 2009. Hannover, Univerza v Hannoveru, Institute of Photogrammetry and GeoInformation.

Forsythe, K., W. 2005. Monitoring rapid urban expansion: A case study of Calgary, Alberta, Canada. V: Moeller, M. in Wentz, E. (ur.). Proceedings of the ISPRS joint conference, 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005). Tempe, Arizona, ZDA, 14.-16. marec 2005.

Frančula, N., Lapaine, M. (ur.). 2003. Geodetski rječnik. Zagreb, Državna geodetska uprava, Geodetski fakultet Sveučilišta u Zagrebu.

GeoEye 2008. Spletna stran podjetja GeoEye.

<http://www.geoeye.com/CorpSite/> (10.11.2008)

Gerlach, F. 2000. Characteristics of Space Imaging's one-meter resolution satellite imagery products. International Archives of Photogrammetry and Remote Sensing 33, B1: 128-135.

Gonzales, R. C., Woods, R. E., Eddins, S. L. 2004. Digital image processing using Matlab. New Jersey, Pearson Prentice-Hall.

Grodecki, J., Dial, G. 2003. Block adjustment of high-resolution satellite images described by rational polynomials. Photogrammetric Engineering and Remote Sensing 69, 1: 59-68.

Grün, A., Baltsavias, E., Henricsson, O. (ur.). 1997. Automatic extraction of man-made objects from aerial and space images. Basel, Švica, Birkhaeuser Verlag.

Grün, A., Kuebler, O., Agouris, P. (ur.). 1995. Automatic extraction of man-made objects from aerial and space images. Basel, Švica, Birkhaeuser Verlag.

GURS 2008. Kataster stavb.

http://www.gu.gov.si/si/delovnapodrocja_gu/podatki_gu/ (25.4.2008)

Haala, R. 1999. Combining multiple data sources for urban data acquisition. V: D. Fritsch and R. Spiller (ur.). Photogrammetric week. Heidelberg, Germany, Wichmann Verlag: 329–340.

Hanley, H. B., Fraser, C. S. 2001. Geopositioning accuracy of IKONOS imagery: indications from 2D transformations. Photogrammetric Record 17, 98: 317-329.

Haralick, R.M., Shanmugan, K., Dinstein, I. 1973. Textual features for image Classification. IEEE Transactions on Systems, Man and Cybernetics 3, 6: 610-621.

Höfle, B., Mücke, W., Dutter, M., Rutzinger, M., Dorninger, P. 2009. Detection of building regions using airborne LIDAR – A new combination of raster and point cloud based GIS methods. Talk: Geoinformatics Forum, AGIT. Salzburg, 7.-10. julij 2009. V: Geospatial Crossroads @ GI_Forum '09 – Proceedings of the Geoinformatics Forum Salzburg: 66-75.

Hofmann, A. D., Mass, H.-G., Streilein, A. 2002. Knowledge-based building detection based on laser scanner data and topographic map information.

<http://www.isprs.org/commission3/proceedings02/papers/paper025.pdf> (25.10.2009)

Hofmann, P. 2001. Detecting buildings and roads from IKONOS data using additional elevation information. *GeoBIT/GIS* 6, 1: 28–33.

Holland, D. A. (ur.), Guilford, R. (ur.), Murray, K. (ur.). 2002. OEEPE-Project on Topographic Mapping from High Resolution Space Sensors. OEEPE Official Publication 44.

Holland, D. A., Boyd, D. S., Marshall, P., 2006. Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors. *ISPRS Journal of Photogrammetry and Remote Sensing* 60, 3: 212-223.

Holland, D. A. 2008. Topographic mapping, change detection and map update. V: Jacoben, K., Baltsavias, E., Holland, D. (ur.). Information extraction from high resolution optical satellite sensors. Tutorial 10, Section 8, XXIst ISPRS Congress, 4. julij 2008, Peking, Kitajska.

Holland, D. A., Sanchez-Hernandez, C., Gladstone, C. 2008. Detecting changes to topographic features using high resolution imagery. V: Proceedings of the XXI International Congress of ISPRS. Beijing, China. *ISPRS XXXVII*, B4: 1153-1158.

Huertas, A., Nevatia, R. 1988. Detecting buildings in aerial images. *Computer Vision, Graphics and Image Processing* 41, 2: 131-152.

Huertas, A., Kim, Z. W., Nevatia, R. 2000. Multisensor integration for building modeling. V: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hilton Head, South Carolina, 13.-15. Junij 2000. New York, IEEE.

Jin, X., Davis, C. H. 2005. Automated building extraction from high-resolution satellite imagery in urban areas using structural, contextual and spectral information. *EURASIP Journal on Applied Signal Processing* 2005, 14: 2196-2206.

- Key, H., Lemmens, M. 2006. Technology in focus: High Resolution. *GIM International* 20, 4.
- Kim, J.-R., Muller, J.-P. 2001. Assessment of automated techniques for extracting vegetation and buildings from 1 m stereo multispectral IKONOS and 1 m pan-sharpened IKONOS coupled with scanning laser altimetry. V: *Proceedings of the Joint ISPRS Workshop: High Resolution Mapping from Space 2001*. Hannover, Germany, 19.-21. September 2001. London, International Society for Photogrammetry and Remote Sensing.
- Koc San, D., Turker, M. 2007. Automatic building extraction from high resolution stereo satellite images. V: *Proceedings of the Conference on Information from SAR and optical data with emphasis on developing countries, ISPRS Commission VII, WG2 & WG7*. 16.-18. maj 2007, Istanbul, Turčija.
- Kosmatin Fras, M. 2004. Vpliv kakovosti vhodnih podatkov na kakovost ortofota. *Geodetski vestnik* 48, 2: 167-178.
- Kraus, K. 2007. *Photogrammetry: Geometry from images and laser scans*. Second Edition. Berlin, Walter de Gruyter GmbH & Co.
- Lee, D. S., Shan, J., Bethel, J. 2003. Class-guided building extraction from IKONOS imagery. *Photogrammetric Engineering and Remote Sensing* 69, 2: 143–150.
- Lemmens, M., 2008. High res. satellite imagery. *GIM International* 22, 7: 18-21.
- Li, R. 1998. Potential of high-resolution satellite imagery for national mapping products. *Photogrammetric Engineering and Remote Sensing* 64, 12: 1165–1170.
- Li, Y., Zhu, L., Shimamura, H. 2008. Integrated method of building extraction from digital surface model and Imagery. V: *Proceedings of the XXI International Congress of ISPRS*. Beijing, China. ISPRS XXXV, B3b: 81-85.
- Lin, C., Nevatia, R. 1998. Building detection and description from a single intensity image. *Computer Vision and Image Understanding* 72, 2: 101-121.
- Mathworks, The 2005. *Image Processing Toolbox User's Guide*. The Mathworks, Inc.
- Maxwell, T., Zhang, Y. 2005. A fuzzy logic approach to optimization of segmentation of object-oriented classification. V: *Proceedings of the SPIE 50th Annual Meeting – Optics & Photonics 2005*. San Diego, Californija, USA, 31.7.-4.8.2005: 528-538.

Mayer, H. 1999. Automatic object extraction from aerial imagery – A survey focusing on buildings. *Computer Vision and Image Understanding* 74, 2: 138-149.

McKeown Jr., D., Cochran, S., Ford, S., McGlone, C., Shufelt, J., Yocum, D. 1999. Fusion of HYDICE hyperspectral data with panchromatic feature extraction. *IEEE Transactions on Geoscience and Remote Sensing* 37, 3: 1261–1277.

Mikhail, E., Bethel, J., McGlone, C. 2001. *Introduction to Modern Photogrammetry*. New York, John Wiley & Sons, Inc.

Mikhail, E., Gracie, G. 1981. *Analysis and adjustment of survey measurements*. New York, Van Nostrand Reinhold.

Niu, X., Wang, J., Di, K., Lee, J.-D., Li, R. 2004. Evaluation of the geopositioning accuracy of QuickBird imagery.

http://dgrc.org/dgo2004/disc/posters/tuesposters/rp_niu.pdf (25.10.2008)

OGC, 2008. *OpenGIS® City Geography Markup Language (CityGML) Encoding Standard*. Gröger, G., Kolbe, T. H., Czerwinski, A., Nagel, C. 2008 (ur.). Open Geospatial Consortium Inc.

<http://www.opengeospatial.org/standards/citygml> (28.10.2009)

Ono, Ak., Kajiwara, K., Honda, Y., Ono, At. 2007. Development of vegetation index using radiant spectra normalized by their arithmetic mean. V: *Proceedings of the Asian Conference on Remote Sensing, Asian Association on Remote Sensing*. Kuala Lumpur, Malezija, 12.-16. november 2007.

Oštir, K. 2006. *Daljinsko zaznavanje*. Ljubljana, Založba ZRC, ZRC SAZU.

Park, W., Kwak, S., Kim, T. 2000. Line-rolling algorithm for automated building extraction from 1-meter resolution satellite images. V: *Proceedings of International Symposium on Remote Sensing*. Kyung-Ju, Korea, november 2000: 31–36.

Parker, J. R., 1997. *Algorithms for image processing and computer vision*. John Wiley & Sons, Inc.

Perona, P., Malik, J. 1990. Scale-Space and Edge Detection Using Anisotropic Diffusion. *IEEE Transactions on Pattern Analysis and Machine intelligence* 12, 7: 629-639.

Petrie, G., Toth, K. 2009. Introduction to laser ranging, profiling, and scanning. V: Shan, J., Toth, K. (ur.). Topographic laser ranging and scanning: Principles and processing. Boca Raton, USA, Taylor & Francis Group: ch. 1.

Petrovič, D. 2003. Predlog vodenja in vzdrževanja topografskih podatkov v Sloveniji. Geodetski vestnik 47, 3: 215-223.

Petrovič, D. 2006. Ocena kakovosti Državne topografske karte v merilu 1 : 50.000. Geodetski vestnik 50, 2: 187-200.

Pfeifer, N., Böhm, J. 2008. Early stages of LiDAR data processing. V: Li, Z., Chen, J., Baltsavias, E. (ur.). Advances in photogrammetry, remote sensing and spatial information sciences: 2008 ISPRS congress book. London, Taylor & Francis Group: 169-184.

Pfeifer, G., Mandlbürger, G. 2009. LIDAR data filtering and DTM generation. V: Shan, J., Toth, K. (ur.). Topographic laser ranging and scanning: Principles and processing. Boca Raton, USA, Taylor & Francis Group: ch. 11.

Pfeifer, N., Rutzinger, M., Rottensteiner, F., Muecke, W., Hollaus, M. 2007. Extraction of building footprints from airborne laser scanning: Comparison and validation techniques. V: Proceedings of the Joint IEEE-GRSS/ISPRS Workshop on Remote Sensing and Data Fusion over Urban Areas, Urban 2007, Pariz, Francija.

Podobnikar, T. 2001. Digitalni model reliefa iz geodetskih podatkov različne kakovosti. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

Pravilnik o vpisih v kataster stavb. UL RS št. 22/2007: 1083.

Radovan, D., Rojc, B., Petrovič, D., Renner, R., Brajnik, M. 1996. Zasnova strategije topografsko-kartografskega sistema Slovenije. Ljubljana, Geodetski inštitut Slovenije.

Richards, J. A., Jia, X. 2006. Remote sensing digital image analysis. Fourth Edition. Springer-Verlag Berlin Heidelberg.

Ridley, H., Atkinson, P., Aplin, P., Muller, J.-P., Dowman, I. 1997. Evaluating the potential of the forthcoming commercial U.S. high-resolution satellite sensor imagery at the Ordnance Survey. Photogrammetric Engineering and Remote Sensing 64, 12: 1165-1170.

Robertson, B. C. 2003. Rigorous geometric modeling and correction of QuickBird Imagery. V: Proceedings of the Geoscience and Remote Sensing Symposium IGARSS '03, 2: 797-802.

Rottensteiner, F., Trinder, J., Clode, S., Kubik, K. 2003. Building detection using LIDAR data and multispectral images. V: Changming, S., Adriaasen, T., Oursekin, S., Talbot, H. (ur.). Proceedings of the Seventh Biennial Australian Pattern Recognition Society Conference, Digital Image Computing: Techniques and Applications. Sidney, 10.-12. december 2003. Sydney, CSIRO.

Segl, K., Kaufmann, H. 2001. Detection of small objects from high-resolution panchromatic satellite imagery based on supervised image segmentation. IEEE Transactions on Geoscience and Remote Sensing 39, 9: 2080–2083.

Seul, M., O’Gorman, Sammon, M. J. 2005. Practical Algorithms for image analysis. 6th printing. Cambridge University Press.

Shackelford, A. K., Davis, C. H. 2003. A combined fuzzy pixelbased and object-based approach for classification of highresolution multispectral data over urban areas. IEEE Transactions on Geoscience and Remote Sensing 41, 10: 2354–2363.

Shan, J., Lee, S. D. 2005. Quality of building extraction from IKONOS imagery. Journal of Surveying Engineering 131, 1: 27-32.

Shufelt, J. A., McKeown, D. M. 1993. Fusion of monocular cues to detect man-made structures in aerial imagery. CVGIP: Image Understanding 57, 3: 307-330.

Sohn, G., Dowman, I. J. 2001. Extraction of buildings from high-resolution satellite data. V: Baltsavias, E., Grün, A. and Gool, L. V. (ur.). Automated Extraction of Man-Made Objects from Aerial and Space Images (III). Lisse, Swets & Zeitlinger: 345-355.

Sohn, G., Dowman, I. 2003. Building Extraction Using Lidar DEMs and Ikonos Images. V: Proceedings of the ISPRS working group III/3 workshop 3-D reconstruction from airborne laserscanner and InSAR data, Dresden, Germany, 8.-10. oktober 2003.

Spot Image 2008. Spletna stran podjetja Spot Image.

<http://www.spotimage.fr/web/en/> (10.11.2008)

Šumrada, R. 2005a. Tehnologija GIS. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

Šumrada, R. 2005b. Strukture podatkov in prostorske analize. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

Švab Lenarčič, A. 2009. Uporaba lidarskih podatkov za klasifikacijo pokrovnosti. Magistrsko delo. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo.

Tao, C. V., Hu, Y. 2001. A comprehensive study of the rational function model for photogrammetric processing. *Photogrammetric Engineering and Remote Sensing* 67, 12: 1347-1357.

Tao, C. V., Hu, Y. 2002. 3D reconstruction methods based on the rational function model. *Photogrammetric Engineering and Remote Sensing* 68, 7: 705-714.

Tao, G., Yasuoka, Y. 2002. Combining high resolution Satellite imagery and airborne laser scanning data for generating bareland DEM in urban areas. V: *Proceedings of the International workshop on visualization and animation of landscape*. Kunming, Kitajska, 26.-28. februar 2002. ISPRS Commision V WG 6.

Toutin, T., Cheng, P. 2002. QuickBird – a milestone for high-resolution mapping. *Earth Observation Magazine* 11, 4: 14-18.

Triglav, M. 2002. Analiza uporabnosti in gospodarnosti IKONOS-a v Sloveniji. *Geodetski vestnik* 46, 3: 219-227.

Triglav Čekada, M. 2009. Optimizacija metodologije obdelave in analiza natančnosti letalskega laserskega skeniranja pri zajemu geodetskih podatkov za lokalno prostorsko planiranje. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

Vosselman, G., Dijkman, S. 2001. 3D building model reconstruction from point clouds and ground plans. *The International Archives of the Photogrammetry and Remote Sensing* XXXIV, 3/W4: 37-44.

Vosselman, G., Maas, H. G. 2001. Adjustment and filtering of raw laser altimetry data.

<http://www.tu-dresden.de/ipf/photo/publikationen/aeltere/>

Vosselmann_Maas_OEPEStockholm2001.pdf (26.10.2008)

- Wang, Y. 1999. Automated triangulation of linear scanner imagery. V: Proceedings of the Joint ISPRS Workshop on Sensors and Mapping From Space. Hannover, 27.-30. September, 1999.
- Wang, J., Di, K., Li, R. 2005. Evaluation and improvement of geopositioning accuracy of IKONOS stereo imagery. ASCE Journal of Surveying Engineering 131, 2: 35-42.
- Weidner, U., Förstner, W. (1995). Towards automatic building reconstruction from high resolution digital elevation models. ISPRS Journal of Photogrammetry and Remote Sensing 50, 4: 38–49.
- Xiao, J., Li, J., Moody, A. 2003. A detail-preserving and flexible adaptive filter for speckle suppression in SAR imagery. International Journal of Remote Sensing 24, 12:2451-2465.
- Xiong, Z., Zhang, Y. 2006. Automatic 3D building extraction from stereo Ikonos images. <http://ieeexplore.ieee.org/iel5/4087812/4241146/04241991.pdf?tp=&isnumber=4241146&arnumber=4241991> (7.4.2007)
- Yang, J.-H., Liu, J., Zhong, J.-C. 2008. Anisotropic Diffusion with Morphological Reconstruction and Automatic Seeded Region Growing for Color Image Segmentation. V: Proceedings of the 2008 International Symposium on Information Science and Engineering, Volume 2: 591-595.
- Zakon o evidentiranju nepremičnin (ZEN). UL RS št. 47/2006: 2024.
- Zaletelj, J., Likar, B., Tasič, J., Pernuš, F. 1998. Nelinearno difuzijsko filtriranje pri avtomatski točkovni poravnavi slik. V: Zbornik sedme Elektrotehniške in računalniške konference ERK '98. Portorož, Slovenija, 24.-26. september 1998: 257-260.
- Zhang, Y. 2002. Problems in the fusion of commercial high-resolution satellite as well as Landsat 7 images and initial solutions. V: Proceedings of the ISPRS Symposium on Geospatial Theory. Ottawa, Kanada, 8.-12 julij 2002.
- Zhang, Y. 2008. Pan-sharpening For Improved Information Extraction. V: Li, Chen, Baltsavias (ur.). Advances in Photogrammetry, Remote Sensing and Spatial Information Sciences. Peking, Kitajska, 2008 ISPRS Congress Book: 185-203.