

Univerza
v Ljubljani
Fakulteta
*za gradbeništvo
in geodezijo*

ODDELEK ZA
GEODEZIJO



**UNIVERZITETNI
ŠTUDIJ GEODEZIJE
SMER GEODEZIJA**

Kandidatka:

NATAŠA ĐURIĆ

**OBJEKTNO USMERJENA KLASIFIKACIJA ZA
DOLOČANJE DREVESNIH VRST IN ZAZNAVANJE
JAPONSKEGA DRESNIKA**

Diplomska naloga št.: 878

**OBJECT ORIENTED CLASSIFICATION FOR TREE SPECIES
IDENTIFICATION AND DETECTION OF JAPANESE
KNOTWEED**

Graduation thesis No.: 878

Mentorica:

doc. dr. Mojca Kosmatin Fras

Predsednik komisije:

izr. prof. dr. Dušan Kogoj

Somentorica:

Urša Kanjir, univ. dipl. inž. geod.

Ljubljana, 2011

IZJAVA O AVTORSTVU

Podpisana **NATAŠA ĐURIĆ** izjavljam, da sem avtorica diplomske naloge z naslovom:
**»OBJEKTNO USMERJENA KLASIFIKACIJA ZA DOLOČANJE DREVESNIH VRST IN
ZAZNAVANJE JAPONSKEGA DRESNIKA«.**

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

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

Ljubljana, december 2011

.....

(podpis)

ERRATA

Stran z napako

Vrstica z napako

Namesto

Naj bo

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:	528:519.172.1(043.2)
Avtor:	Nataša Đurić
Mentor:	doc. dr. Mojca Kosmatin Fras
Somentor:	Urša Kanjir, univ. dipl. inž. geod.
Naslov:	Objektno usmerjena klasifikacija za določanje drevesnih vrst in zaznavanje japonskega dresnika
Tip dokumenta:	Diplomska naloga – univerzitetni študij
Obseg in oprema:	90 str., 12 pregl., 61 sl., 5 en.
Ključne besede:	objektno usmerjena klasifikacija, drevesne vrste, japonski dresnik, preizkus Kolmogorova in Smirnova, WorldView-2, lidar

Izvleček

V diplomski nalogi obravnavamo uporabnost objektno usmerjene klasifikacije ter predstavimo možnosti uporabe preizkusa Kolmogorova in Smirnova za klasifikacijo drevesnih vrst ter invazivne tujerodne rastlinske vrste japonski dresnik na območju Mestne občine Ljubljana z uporabo satelitskega posnetka WorldView-2 in državnega ortofota. Preizkus Kolmogorova in Smirnova je neparametrični statistični test, kjer s primerjavo empiričnih porazdelitvenih funkcij dveh vzorcev ocenjujemo njuno podobnost. Z uporabo porazdelitvenih funkcij se upoštevajo vsi piksli znotraj segmenta in ne zgolj reprezentativne vrednosti, ki so lahko močno obremenjene s skrajnimi vrednostmi pikslov v segmentu. Segment predstavlja homogeno regijo pikslov s podobnimi funkcijskimi lastnostmi. Visokoločljive slikovne vire za klasifikacijo drevesnih vrst dopolnimo z uporabo digitalnega modela krošenj.

Drevesa v urbanem okolju kot tudi invazivne tujerodne vrste je potrebno razumeti kot prostorski fenomen ter izjemno heterogen in kompleksen pojav. Kakovostni in ciljno usmerjeni podatki o prostorski razporeditvi, vrsti ter stanju so zato osnova za študije ranljivosti, ocene koristi, sistematično načrtovanje ukrepov odstranjevanja in nadzora invazivnih vrst ter ozelenitve in upravljanja z drevnino v določenem obdobju.

Uporabljena metodologija predstavlja obetavno orodje za učinkovitejšo klasifikacijo drevesnih vrst in zaznavanje japonskega dresnika od dosedanjih metod.

BIBLIOGRAPHIC – DOKUMENTALISTIC INFORMATION

UDC:	528:519.172.1(043.2)
Author:	Nataša Đurić
Supervisor:	Assist. Prof. Mojca Kosmatin Fras, Ph.D.
Cosupervisor:	Urša Kanjir, B.Sc. of Geodesy
Title:	Object oriented classification for tree species identification and detection of japanese knotweed
Document type:	Graduation thesis – university studies
Notes:	90 p., 12 tab., 61 fig., 5 eq.
Key words:	object oriented classification, tree species, japanese knotweed, Kolmogorov-Smirnov test, WorldView-2, LIDAR

Abstract:

In graduation thesis the use of object-oriented classification and Kolmogorov-Smirnov test for tree species and Japanese knotweed classification is discussed in the study area of Ljubljana based on aerial and high resolution WorldView-2 satellite imagery. Kolmogorov-Smirnov test is a non-parametric statistical test that evaluates the similarity between two sample sets by comparing their empirical cumulative distribution function. When using empirical cumulative distribution functions all pixels inside the segment are being accounted for instead of just one or two representative values which are likely to be affected by extreme values. A segment represents the homogenous region of pixels with similar functional characteristics. For tree species classification digital canopy model was used along with the high resolution imagery.

Trees in urban areas and invasive alien species should be understood as exceptionally heterogeneous and complex spatial phenomena. Vulnerability analysis, benefit estimation and systematic management strategies can therefore only base on qualitative and task-oriented data about spatial distribution and extent, species and condition of the object being considered.

Methodology described in this graduation thesis is a promising tool for more effective tree species classification and detection of Japanese knotweed.

ZAHVALA

Iskreno se zahvaljujem mentorici doc. dr. Mojci Kosmatin Fras ter somentorici Urši Kanjir, univ. dipl. inž. geod. za strokovno vodstvo, pomoč in nasvete pri nastanku diplomske naloge.

Zahvaljujem se tudi izr. prof. dr. Krištofu Oštirju za dodatno podporo in navdih, saj mnogokrat za vsako rešitev najde problem.

Hvala zaposlenim na Inštitutu za antropološke in prostorske študije, ZRC SAZU za topel sprejem in obilje ustvarjalne energije. Hvala tudi vsem, ki so za namen diplomske naloge prijazno odstopili podatke in namige za izboljšavo.

Hvala staršem in bratu za veliko mero razumevanja in za vse odpustke pri pospravljanju.

In hvala tebi, Luka. » *Great minds discuss ideas...*« (Neznan avtor)

KAZALO

1	UVOD	1
1.1	Motivacija	1
1.2	Sorodna dela	3
1.3	Opredelitev problema, cilja in hipotez naloge	4
1.4	Organizacija naloge	5
2	TEORETIČNA IZHODIŠČA	6
2.1	Multispektralno daljinsko zaznavanje	6
2.1.1	Spekter elektromagnetnega valovanja	6
2.1.2	Spektralni podpis	9
2.1.3	Spektralne lastnosti vegetacije	10
2.2	Lidarska tehnologija	15
2.2.1	Aero lasersko skeniranje	15
2.2.2	Interakcija laserskega žarka s površjem in obdelava podatkov aero laserskega skeniranja	17
2.3	Urbani ekosistemi	20
2.3.1	Vloga in pomen dreves v urbanem okolju	20
2.3.2	Upravljanje z urbano drevnino	21
2.4	Invazivne tujerodne vrste	23
2.4.1	Japonski dresnik	24
2.5	Objektno usmerjena klasifikacija	26
2.5.1	Proces človeškega zaznavanja in interpretacije	26
2.5.2	Postopek objektno usmerjene klasifikacije	26
2.5.2.1	Segmentacija	27
2.5.2.2	Klasifikacija	29
2.6	Statistično preizkušanje domnev	30
2.6.1	Preizkus Kolmogorova in Smirnova	30
3	UPORABLJENI PODATKI, METODOLOGIJA IN PROGRAMSKA OPREMA	32
3.1	Opis podatkov	32

3.1.1	Satelitski posnetek WorldView-2	32
3.1.2	Državni ortofoto	35
3.1.3	Podatki aero laserskega skeniranja	36
3.1.4	Referenčni terenski podatki	38
3.1.4.1	Digitalni kataster dreves	38
3.1.4.2	Poligoni območij pojavljanja japonskega dresnika	39
3.2	Metodologija	40
3.2.1	Opis postopka objektno usmerjene klasifikacije	40
3.2.2	Potek zaznavanja drevesnih vrst	41
3.2.2.1	Predstavitev izbranih postopkov za klasifikacijo drevesnih vrst	43
3.2.3	Potek zaznavanja japonskega dresnika	47
3.2.3.1	Predstavitev izbranih postopkov za klasifikacijo japonskega dresnika	48
3.3	Uporabljena programska oprema	50
4	PRAKTIČNA IZVEDBA NALOGE	51
4.1	Študijska območja	51
4.1.1	Študijsko območje za drevesne vrste	51
4.1.2	Študijsko območje za japonski dresnik	53
4.2	Preizkus metodologije in rezultati	54
4.2.1	Klasifikacija drevesnih vrst	54
4.2.2	Zaznavanje japonskega dresnika	69
4.3	Ovrednotenje rezultatov	76
4.3.1	Ocena kakovosti klasifikacije drevesnih vrst	76
4.3.2	Ocena kakovosti klasifikacije japonskega dresnika	77
4.4	Razprava	86
5	ZAKLJUČEK IN NADALJNJE DELO	88
VIRI		91

Kazalo preglednic

Preglednica 1:	Komponente popisa dreves.	21
Preglednica 2:	Značilnosti spektralnih kanalov senzorja WorldView-2.	33
Preglednica 3:	Lastnosti ortofota.	35
Preglednica 4:	Osnovne tehnične lastnosti skenerja LiteMapper 5600.	36
Preglednica 5:	Vrednosti parametrov objektno usmerjene klasifikacije, izbran atribut in pravilo za izdelavo maske vegetacije.	55
Preglednica 6:	Vrednosti parametrov objektno usmerjene klasifikacije, izbrani atributi in pravila za izločanje senc in trave na pankromatskem satelitskem posnetku.	56
Preglednica 7:	Drevesne vrste, uporabljene za preizkus Kolmogorova in Smirnova.	64
Preglednica 8:	Uporabljene vrednosti parametrov in atributi za izdelavo maske vegetacije.	71
Preglednica 9:	Uporabljene vrednosti parametrov in atributi za izločanje kandidatov japonskega dresnika.	72
Preglednica 10:	Rezultati klasifikacije s preizkusom Kolmogorova in Smirnova.	76
Preglednica 11:	Število referenčnih območij in obravnavanih poligonov na območju lista E2446.	78
Preglednica 12:	Število resnično pozitivnih, lažno pozitivnih in lažno negativnih poligonov na listu E2446.	79

Kazalo slik

Slika 1:	Spekter elektromagnetnega valovanja. Povezavo frekvence valovanja z energijo obravnava Planckova zveza. Večja frekvenca (manjša valovna dolžina) pomeni večjo energijo in obratno. Za živa bitja je nevarnejše valovanje z večjo energijo. (Vir: Kvarkadabra, 2011)	7
Slika 2:	Načini opazovanja površja. (Vir: Kerle et al., 2004)	8
Slika 3:	Spektralni podpis različnih rab. (Vir: University of Calgary, 2011)	9
Slika 4:	Značilen potek odbojne krivulje asimilacijskih organov v različnih delih EM spektra. (Vir: Govender et al., 2009)	10
Slika 5:	Intenziteta absorpcije svetlobe klorofila in karotenoidov. (Vir: UIC, 2011)	11
Slika 6:	Zgradba lista. (Vir: Biology Wiz, 2011)	12
Slika 7:	Spektralne krivulje različnih drevesnih vrst v različnih delih EM spektra. V vidnem delu spektra opazimo majhen razpon vrednosti odboja različnih drevesnih vrst. (Vir: Dr. Nicholar Short's remote sensing tutorial, 2010)	13
Slika 8:	Spektralna krivulja zdrave in suhe vegetacije. (Blue Marble Project, 2003)	14
Slika 9:	Delovanje lidarja. (Vir: LIDAR for vegetation applications 2007)	15
Slika 10:	Interakcija laserskega žarka z drevesno krošnjo (a), Oblak točk in odboji znotraj vegetacije (b) (Vir: Shan, 2008 (a); Terranean mapping technologies, 2011 (b))	17
Slika 11:	Normaliziran DMP. (Vir: Changok, 2007)	18
Slika 12:	Vzorčenje objektov diskretnega snemalnega sistema. (Vir: LIDAR for vegetation applications, 2007)	18
Slika 13:	Razvoj populacije tujerodne vrste s postopnim prilagajanjem na novo okolje. (Vir: Kus Vleenvliet po Richardson et al., 2009)	23
Slika 14:	Značilen sestoj japonskega dresnika v urbanem okolju.	25
Slika 15:	Prehod z nivoja pikslov (a) na raven segmentov (b).	27
Slika 16:	Postopek rasti regij. (Vir: Vision Systems, 1994)	28
Slika 17:	Hierarhična mreža posameznih ravni segmentacije. (Vir: Nussbaum in Menz, 2008)	29
Slika 18:	Graf empirične porazdelitvene funkcije.	31
Slika 19:	Značilna sprememba vrednosti odboja med rdečim kanalom in kanalom Red-Edge. (Vir: Seager et al., 2005)	34
Slika 20:	Posnetek WorldView-2 - pankromatski kanal (a) lažni barvni kompozit (b) izostren lažni barvni kompozit (c).	35
Slika 21:	DOF050 2006 (a), DOF100 IR 2006 (b), DOF050 2011(c).	36
Slika 22:	Prikaz poti leta helikopterja. (Vir: Bernik, 2011)	37
Slika 23:	Digitalni model krošenj, 3D pogled.	37
Slika 24:	Grafični in atributni del vmesnikov Zelene površine in Editiranje dreves.	38
Slika 25:	Koraki objektno usmerjene klasifikacije. Od leve proti desni: vhodna podoba, segmentacija vsebine podobe, združevanje segmentov na podobi, klasifikacija vsebine podobe.	41
Slika 26:	Diagram poteka klasifikacije drevesnih vrst.	42

Slika 27:	Porečje in razvodje. (Vir: Image metrology, 2011)	44
Slika 28:	Razvodja in porečja v tlorisnem pogledu. Maksimalno vrednost oziroma točko z (absolutno) najvišjo vrednostjo iščemo znotraj rumenih poligonov. (Vir: ArcGIS Desktop 9.3 Help)	45
Slika 29:	Diagram poteka zaznavanja japonskega dresnika.	48
Slika 30:	Razmerje med objektom in segmentom.	49
Slika 31:	Park Tivoli. (Vir: Slovenija v presežnikih)	52
Slika 32:	Študijsko območje za drevesne vrste, prikazano z različnimi viri podatkov. V prvi vrsti (od leve proti desni): satelitski posnetek WorldView-2 in posnetek ortofoto DOF050 2011, v drugi vrsti (od leve proti desni): sloj katastra dreves na DOF050 2011 in digitalni model krošenj.	53
Slika 33:	Prekrivanje satelitskega posnetka in lista ortofota z oznako E2303.	53
Slika 34:	Različne drevesne vrste na posnetku ortofoto z oznako E2443 (DOF050 2011). V prvi vrsti (od leve proti desni): rdeča bukev, javorolistna platana, lipa. V drugi vrsti (od leve proti desni): navadna smreka, rdeči ostrolistni javor in pokopališka pobešava vrba.	54
Slika 35:	Izdelava maske vegetacije na satelitskem posnetku WorldView-2. Na sliki so predstavljeni: kompozit v lažni podobi (a), Red-Edge NDVI (b), maska (c).	55
Slika 36:	Sloj drevesnih krošenj, predstavljen s poligoni v svetlo zeleni barvi.	57
Slika 37:	Diagram poteka inverzne razvodne segmentacije, izdelan v programskem okolju ArcMap.	58
Slika 38:	Izhodna sloja postopka inverzne razvodne segmentacije. Rdeče pike ponazarjajo vrhove, črne črte pa razvodja, t.j. meje med porečji.	59
Slika 39:	Sloj točk vrhov z višino nad 2 m.	60
Slika 40:	Značilnosti iskanja vrhov. Levo zgoraj: visok odstotek ujemanja med referenčnimi podatki (modre pike) in slojem vrhov (oranžne pike) za posamična drevesa z velikimi krošnjami. Desno zgoraj: večje število zaznanih vrhov, značilno za listavce. Levo spodaj: položajna neustreznost referenčnih podatkov. Desno spodaj: drevesa v skupini.	61
Slika 41:	Izdelava pasov s polmerom iskanja 3 m.	62
Slika 42:	Rezultat segmentacije digitalnega modela krošenj.	62
Slika 43:	Satelitski posnetek in sloj segmentov ne sovpadata.	63
Slika 44:	Izsek izhodne datoteke postopka pripisovanja vrednosti segmentom.	64
Slika 45:	Porazdelitvene funkcije petih drevesnih vrst v prvih štirih kanalih multispektralnega posnetka WorldView-2.	66
Slika 46:	Porazdelitvene funkcije petih drevesnih vrst v zadnjih štirih kanalih multispektralnega posnetka WorldView-2.	67
Slika 47:	Prikaz vrednosti pikslov petih drevesnih vrst v odvisnosti od valovne dolžine.	68
Slika 48:	Značilni tekstura in barva japonskega dresnika. Prva vrsta (od leve proti desni): DOF050 (2006), DOF100 IR (2006), DOF050 (2011). Druga vrsta (od leve proti desni): DOF050 (2006), DOF100 IR (2006), DOF050 (2011), WorldView-2 (2010).	69
Slika 49:	Sestoj robidovja (domača invazivna vrsta) in zlate rozge (invazivna tujerodna vrsta), potrjen s terenskim ogledom. Od leve proti desni: DOF050 (2006), DOF100 IR (2006), DOF050 (2011).	70

Slika 50:	Izdelava maske vegetacije na posnetkih ortofoto. Na sliki (od leve proti desni) DOF100 IR, NDVI, maska.	71
Slika 51:	Podobjektna gostota za rabi japonski dresnik in obdelovalna površina podana z izrazom »mean«, sloj kandidatov je pridobljen z obdelavo posnetka ortofoto z oznako E2446.	73
Slika 52:	Podobjektna gostota za rabo japonski dresnik podana z izrazom »mean«, sloj kandidatov je pridobljen z obdelavo satelitskega posnetka.	73
Slika 53:	Porazdelitvene funkcije referenčnih rab in neznanega objekta, ki v tem primeru predstavlja območje, ki ni del sloja kandidatov.	74
Slika 54:	Porazdelitvene funkcije referenčnih rab in objekta, ki je del sloja kandidatov.	75
Slika 55:	Izbrano območje za oceno natančnosti klasifikacije na ortofoto posnetku z oznako E2446. Zeleni poligoni so del sloja kandidatov, rdeče pike pa območja pojavljanja japonskega dresnika, uporabimo 1. sklop atributov.	78
Slika 56:	Pravilnost klasifikacije japonskega dresnika na listu ortofota z oznako E2446 (1. sklop atributov).	80
Slika 57:	Primer pravilno zaznanih in spregledanih območij japonskega dresnika na listu ortofota z oznako E2446 (1. sklop atributov).	81
Slika 58:	Izsek območja klasifikacije na listu E2303. Zeleni poligoni so del sloja kandidatov, rdeče pike pa območja pojavljanja japonskega dresnika, uporabimo 1. sklop atributov. Na južni strani slike je spodaj Cesta dveh cesarjev, severneje pa razbremenilni kanal Mali graben.	82
Slika 59:	Pravilnost klasifikacije japonskega dresnika na listu ortofota z oznako E2303 (1.sklop atributov).	83
Slika 60:	Na levi ortofoto iz leta 2006, na desni japonski dresnik v naravi leta 2011.	83
Slika 61:	Pravilno določena območja japonskega dresnika z uporabo vrednosti atributa v 6. kanalu.	84

1 UVOD

V uvodnem poglavju predstavim motivacijo in sorodna dela ter opredelim problem ter cilje naloge. Strukturo naloge na kratko opišem na koncu poglavja.

1.1 Motivacija

Mesta pokrivajo manj kot 1% površine Zemlje, vendar pa prispevajo kar 80% vseh emisij toplogrednih plinov (TreePeople, 2010). Segrevanje ozračja ter ostale globalne motnje v delovanju podnebne sistema se vedno bolj zrcalijo tudi v ogroženosti biotske raznovrstnosti ter delovanju ekosistemov, ki so temelj človekovega obstoja. Značilen odgovor na nestabilno funkcionalnost in ranljivost ekosistemov predstavlja pojav biološke invazivnosti, ki v ekosistemih lahko na novo definira nepovratne in nepredvidljive medsebojne odnose, hkrati pa pomeni eno izmed negativnih gonil globalnih sprememb. Analiza stanja biotske raznovrstnosti na svetovni ravni (Millenium Ecosystem Assessment) je namreč pokazala, da so invazivne tujerodne vrste eden najpomembnejših razlogov za izgubo biotske pestrosti (Kus Veenvliet, 2009).

O nujnosti preprečevanja posledic okoljske krize sta enotni tako znanstvena kot politična sfera. Velik korak k uresničevanju ciljev okoljske politike predstavlja spodbujanje ljudi k prevzemanju odgovornosti za ustvarjanje sonaravnega urbanega okolja ter zavedanje, da aktivno prebivalstvo predstavljajo tudi urbana drevesa, ki so obenem neprecenljiv element biotske pestrosti ter značilen krajinsko arhitekturni gradnik. V zadnjih desetletjih poleg estetske vloge dreves v urbanem okolju v ospredje prihajajo tudi ostale koristi, ki jih prinaša drevnina¹: družbena, gospodarska in ekološka (McPherson, 2006).

Tako drevesa v urbanem okolju kot invazivne tujerodne vrste je torej potrebno razumeti kot prostorski fenomen ter izjemno heterogen in kompleksen pojav (Sridharan, 2010). Kakovostni in ciljno usmerjeni podatki o prostorski razporeditvi, vrsti ter stanju so zato osnova za študije

¹ Z izrazom drevnina navadno označujemo vse lesnate rastline v urbanem okolju, torej ne samo drevesne, ampak tudi grmovne vrste (Brus, 2008).

ranljivosti, ocene koristi, sistematično načrtovanje ukrepov odstranjevanja in nadzora invazivnih vrst ter ozelenitve in upravljanja z drevnino v določenem obdobju.

Popis urbane drevnine navadno vključuje terenski ogled pod vodstvom strokovnjaka s področja gozdarstva ali arboristike t.j. vede, ki se ukvarja s sajenjem in vzdrževanjem (nego) dreves v urbanem okolju (Arboretum Volčji Potok, 2011). Rezultat takšnega popisa sta register in kataster dreves z izbranimi pripadajočimi parametri za posamezno drevo (identifikacijska številka, lokacija, višina, prsni premer, vrsta, stanje, ukrep...).

Tak način zbiranja podatkov je lahko dolgotrajen ter stroškovno in časovno neučinkovit, največkrat tudi neažuren.

Kot primerna alternativa terenskemu delu je v gozdarstvu in ekoloških aplikacijah že dolgo uveljavljena uporaba daljinskega zaznavanja (Oštir, 2006). Ta tehnika pridobivanja podatkov se je uveljavila najprej tam, kjer je bilo potrebno v kratkem času in z zmernimi stroški dobiti oceno o stanju (gozdov) ali kjer doslej taki podatki sploh niso obstajali (Hočevar, 2002). Z izstrelitvijo satelita IKONOS se je leta 1999 začelo obdobje komercialnih visokoločljivih multispektralnih satelitskih snemalnih sistemov, ki so v raziskave zemeljskega površja s tehnikami daljinskega zaznavanja prinesli nove dimenzije. Kmalu so mu sledili IRS (Indian Remote Sensing, 2000), QuickBird (2001), SPOT5 (2002), OrbView3 (2003), WorldView-1 (2007) (Navulur, 2007). Prvo desetletje visokoločljivih satelitskih sistemov se je zaključilo leta 2009 z izstrelitvijo satelita WorldView-2, ki prvi med komercialnimi sateliti zagotavlja 8-kanalno multispektralno podobo v vidnem in bližnje infrardečem spektru z ločljivostjo 1,84 m. Kanal predstavlja območje valovnih dolžin elektromagnetnega spektra, ki ga opazuje posamezni detektor senzorja (Oštir, 2006).

Visokoločljivi posnetki in novo razviti postopki za njihovo obdelavo so omogočili raziskave tudi na področju urbanega gozdarstva. Možnost njihove uporabe za zaznavanje in izločanje drevesnih krošenj v urbanem okolju tako opisuje kar nekaj avtorjev (Tolpekin et al., 2010; Ardila et al., 2010), kljub temu pa v celoti še ni raziskana klasifikacija drevesnih vrst. Vzroke gre pripisati premajhni spektralni ločljivosti snemalnih sistemov (običajno to pomeni en pankromatski ter štirje multispektralni kanali), ki pa je za razlikovanje velikega števila drevesnih vrst v urbanem okolju izrednega pomena (Sridharan, 2010). Podobe satelita WorldView-2 z izboljšano spektralno ločljivostjo tako predstavljajo novo izhodišče za uporabo v aplikacijah urbanega gozdarstva, kot tudi zaznavanja tujerodnih invazivnih rastlinskih vrst z uporabo ostalih visokoločljivih slikovnih virov.

1.2 Sorodna dela

Zaradi obsežnosti obravnavane tematike v tem poglavju na kratko predstavimo zgolj tista dela, ki so predstavljala izhodišče za predmet obravnave diplomskega dela, t.j. klasifikacije drevesnih vrst in japonskega dresnika.

Problem identifikacije in klasifikacije drevesnih vrst v urbanem okolju z uporabo slikovnih in višinskih virov je razmeroma novo področje, vendar pa po uveljavitvi lidarske tehnologije in dostopnosti visokoločljivih podatkov hkrati vse bolj raziskano.

Ardila et al. (2010) so na visokoločljivih posnetkih QuickBird drevesne krošnje izločili s postopkom objektno usmerjene klasifikacije, s poudarkom na definiranju pravil, ki obravnavajo spektralni odziv, teksturo, velikost, geometrijo krošenj ter sence, s katerimi določijo obliko drevesne krošnje.

Možnost in potencial uporabe preizkusa Kolmogorova in Smirnova za klasifikacijo dreves v urbanem okolju in posnetkom WorldView-2 predstavi Sridharan (2010). V prvem koraku študije razišče razločljivost drevesnih vrst v 8 ter 4 kanalih s statističnim postopkom MDS (angl. multidimensional scaling). V naslednjih korakih uporabi večnivojsko objektno hierarhično klasifikacijo, ki urbani gozd obravnava na več ravneh. V zaključku izpostavi uspešnost postopka v primerjavi s tradicionalni tehnikami klasifikacije ter poudari problem nezadostnega definiranja segmentov za nadaljnjo klasifikacijo s preizkusom Kolmogorova in Smirnova.

Zaznavanje japonskega dresnika z uporabo pristopa objektno usmerjene klasifikacije ter visokoločljivih letalskih posnetkov obravnavajo Jones et al. (2011). Metoda, zasnovana na hierarhičnem načinu izločanja, je učinkovita in podaja zanesljive rezultate, ki so jih potrdili s terenskim ogledom. Za nadaljnje delo med drugim predlagajo uporabo posnetkov iz različnih časovnih obdobj (različni letni časi) ter definiranje obstoječih območij pojavljanja japonskega dresnika kot tudi območij z verjetnostjo pojavljanja invazivnih rastlin. Izpostavijo uvedbo zanesljivejših, stabilnejših značilk za zaznavanje japonskega dresnika, ki bodo manj občutljive na spremembe vhodnih podatkov.

1.3 Opredelitev problema, cilja in hipotez naloge

Razvoj satelitskih senzorjev in dostopnost visokoločljivih podob je v zadnjem desetletju pod vprašaj postavila dobro uveljavljene, tradicionalne pikselske tehnike klasificiranja podob. Visokoločljivi satelitski posnetki zaradi geometričnih karakteristik osnovne enote podobe (velikost piksela) in posledično povečanim številom podrobnosti namreč zahtevajo drugačne pristope obdelave. Vrzal med neučinkovitostjo pikselske klasifikacije na eni, ter detajlnostjo visokoločljivih podob na drugi strani, v zadnjih letih zapolnjuje objektno usmerjena klasifikacija (Ardilla et al. po Blaschke, 2010). Ključni metodološki element pri objektno usmerjenem pristopu predstavlja segmentacija (Lang, 2008), ki pomeni razmejevanje podobe v homogene segmente (objekte) z združevanjem sosednjih pikslov s podobnimi funkcijskimi lastnostmi (Kanjir, 2009).

Ker en piksel ne nosi pomembnih semantičnih² informacij in na visokoločljivih posnetkih ne predstavlja geografskega objekta, je izbira pikselskih tehnik za analizo dreves v urbanem okolju ter homogenih sestojev invazivnih tujerodnih rastlinskih vrst neustrezna (Sande, 2010).

Problem predstavlja tudi dejstvo, da v programskih orodjih za objektno usmerjeno klasifikacijo postopku segmentacije navadno sledijo pikselske tehnike razvrščanja v razrede, ki temeljijo na eni ali dveh reprezentativnih statističnih vrednostih segmenta, kot sta na primer povprečje in standardni odklon. Slednji vrednosti imata pomen le v primeru normalne porazdelitve podatkov (Sridharan, 2010), sicer ne podajata realne slike porazdelitve vseh pikslov znotraj objekta t.j. drevesa ali sestoja, kar pa je ključno za razlikovanje in razvrščanje.

Glavni cilj diplomske naloge je raziskati možnosti uporabe preizkusa Kolmogorova in Smirnova za klasifikacijo drevesnih vrst ter invazivne tujerodne rastlinske vrste japonski dresnik na območju Mestne občine Ljubljana z uporabo satelitskega posnetka WorldView-2 in državnega ortofota. Preizkus Kolmogorova in Smirnova je neparametrični statistični test, kjer s primerjavo empiričnih porazdelitvenih funkcij dveh vzorcev ocenjujemo njuno podobnost. Z uporabo porazdelitvenih funkcij se tako upoštevajo vsi piksli znotraj segmenta in ne zgolj reprezentativne vrednosti, ki so lahko močno obremenjene s skrajnimi vrednostmi pikslov v segmentu (Sridharan, 2010). Visokoločljive slikovne vire za klasifikacijo drevesnih vrst dopolnimo z uporabo digitalnega modela krošenj.

² Semantika oziroma pomenoslovje je veda, ki se ukvarja s pomensko platjo jezikovnega znaka, kode ali kakšne druge oblike predstavnosti.

Hipoteze raziskave:

- Objektno usmerjena klasifikacija je primeren pristop k obdelavi visokoločljivih podob.
- Preizkus Kolmogorova in Smirnova predstavlja ustrezno dopolnitev objektno usmerjene klasifikacije.
- Uporaba digitalnega modela krošenj omogoča učinkovito razmejevanje segmentov za nadaljnjo klasifikacijo drevesnih vrst.

1.4 Organizacija naloge

Diplomska naloga je razdeljena na 5 glavnih poglavij. V pričujočem poglavju predstavimo motivacijo, sorodna dela ter opredelimo cilje in hipoteze diplomske naloge. Poglavje 2 opredeli teoretična izhodišča obravnavanega problema t.j. tehnologiji pridobivanja podatkov, uporabljenih v diplomski nalogi, osnovne značilnosti predmetov obravnave ter pristopa klasifikacije. V poglavju 3 utemeljimo izbiro podatkov ter navedemo ključne postopke izbrane metodologije za klasifikacijo drevesnih vrst in zaznavanje japonskega dresnika. Praktični del naloge predstavimo v poglavju 4, kjer najprej opišemo študijska območja. Podajanje rezultatov klasifikacije v tem poglavju sledi shemi metodologije iz poglavja 3. Predstavitvi rezultatov sledi ovrednotenje rezultatov. V poglavju 5 podamo zaključke ter predloge za nadaljnje delo. Na koncu naloge navedemo seznam uporabljene literature.

2 TEORETIČNA IZHODIŠČA

V poglavju podamo teoretične osnove, ki so pomembne za celostno razumevanje predmeta obravnave diplomske naloge. Strukturo poglavja opredeljujejo izbira podatkov oziroma tehnologij pridobivanja podatkov, predmet obravnave ter izbrani pristopi obdelave podatkov. Klasifikacijo drevesnih vrst v urbanem prostoru in invazivne rastlinske vrste japonski dresnik omogočijo visokoločljivi večspektralni slikovni viri ter izvedeni podatki laserskega skeniranja z uporabo postopkov objektno usmerjene klasifikacije ter statističnim preizkusom Kolmogorova in Smirnova.

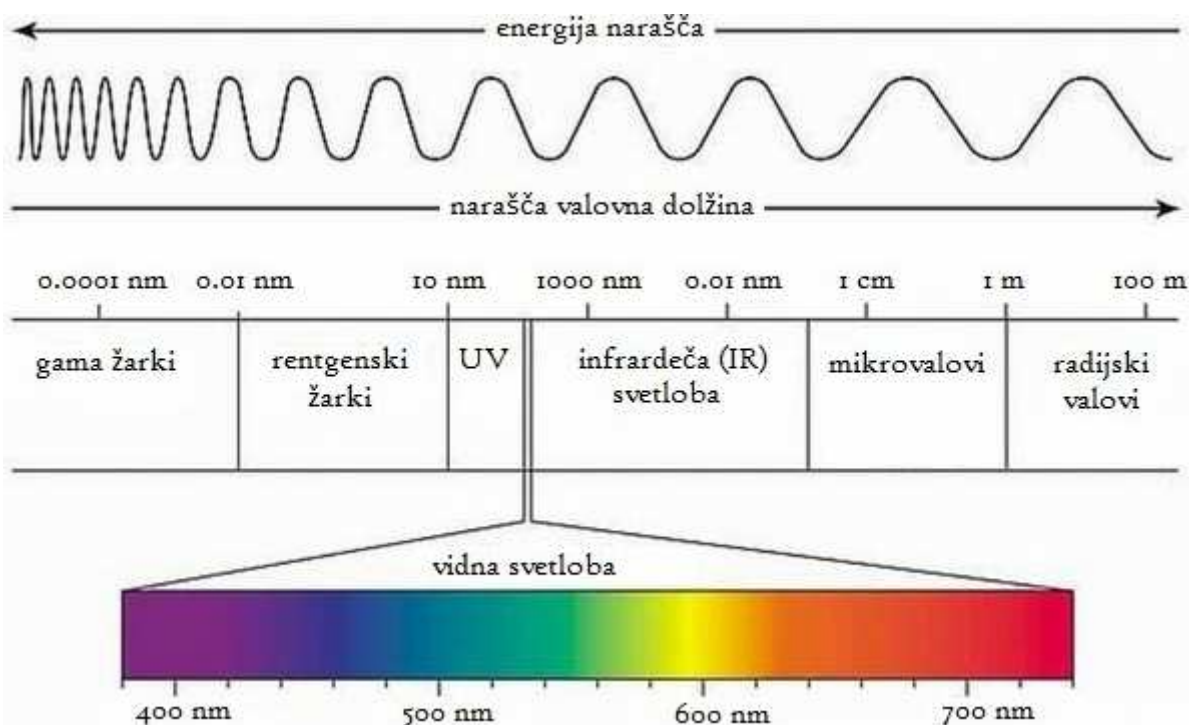
2.1 Multispektralno daljinsko zaznavanje

Tehnologija izdelave multispektralnih senzorjev je v zadnjih desetletjih presegla človeške okvire vidnega zaznavanja sveta in omogočila snemanje površja z zaznavanjem odbite ali izsevane energije hkratno v različnih delih spektra elektromagnetnega valovanja. Daljinsko zaznane podobe so torej rezultat pridobivanja informacij o površju, ne da bi z njim prišli v neposredni stik. Prenos informacij na daljavo omogoča energija elektromagnetnega valovanja.

2.1.1 Spekter elektromagnetnega valovanja

Elektromagnetno (EM) valovanje sestoji iz električnega in magnetnega polja, ki valujeta v smeri pravokotno ena na drugo. Valovanje obeh polj je pravokotno na smer razširjanja EM valovanja. Vsa telesa, ki imajo temperaturo nad absolutno ničlo, sevajo EM valovanje (Kanjir, 2009), ki je posledica gibanja molekul v snovi.

V daljinskem zaznavanju se je za označevanje elektromagnetnega valovanja uveljavila uporaba valovne dolžine, ki je tudi osnova za razdelitev razpona elektromagnetnega spektra na posamezne spektralne pasove. Elektromagnetni spekter je široko zvezno območje sevanja različnih valovnih dolžin (Hočevar, 2002). Čeprav meje med posameznimi deli elektromagnetnega spektra niso ostre, lahko določimo nekaj skupin s podobnimi fizikalnimi lastnostmi (Slika 1).



Slika 1: Spekter elektromagnetnega valovanja. Povezavo frekvence valovanja z energijo obravnava Planckova zveza. Večja frekvenca (manjša valovna dolžina) pomeni večjo energijo in obratno. Za živa bitja je nevarnejše valovanje z večjo energijo. (Vir: Kvardabra, 2011)

V daljinskem zaznavanju so najbolj uporabna spektralna območja infrardeče in vidne svetlobe ter mikrovalovi. Območje valovnih dolžin infrardečega ali termičnega valovanja sega v razponu od približno 700 nm do 1 mm (1 mm = 1000 μm in 1 μm = 1000 nm). Spekter infrardeče svetlobe navadno razdelimo na naslednje pasove: bližnje (0.7–1.4 μm , angl. near infrared, oznaka NIR), kratkovalovno (1.4–3 μm , angl. short wavelength infrared, oznaka SWIR), srednjevalovno (3–8 μm , angl. mid wavelength infrared, oznaka MWIR), dolgovalovno (8–15 μm , angl. long wavelength infrared, oznaka LWIR) in daljno infrardeče območje (15–1000 μm , angl. far infrared, oznaka FIR).

Mikrovalovi zajemajo območje med približno 1 mm in 1 m. Prednost senzorjev, ki delujejo v mikrovalovnem delu EM spektra, predstavljajo dolge valovne dolžine. Te lahko prodirajo skozi oblake, meglice, prah in dež, saj nanje ne vpliva atmosfersko sipanje, ki je izrazito v vidnem delu spektra (Oštir, 2006).

Vidna svetloba je najbolj poznana oblika elektromagnetnega spektra. Zajema zelo majhen del celotnega spektra in sovpada z območjem, v katerem Sonce izseva največ svetlobe in v katerem so človeške oči najbolj občutljive (Oštir, 2006). Območje vidnega sevanja delimo v tri pasove primarnih aditivnih barv³, ki so opredeljeni z razponi valovnih dolžin od 0.40 do 0.50 μm (modra),

³ Čepki v človeškem očesu so prav tako občutljivi na tri osnovne barve.

0.50 do 0.60 μm (zelena) in 0.60 do 0.73 μm (rdeča). Primarnih barv ni mogoče dobiti z mešanjem ostalih barv spektra, nasprotno pa lahko z mešanjem primarnih barv dobimo ostale (Hočevar, 2002). Človeško oko torej sevanja različnih valovnih dolžin zaznava kot barve, vendar izbranih spektralnih pasov ne more zaznavati izolirano. Postopek t.i. filtriranja je značilen za večino senzorjev, ki jih uporabljamo v daljinskem zaznavanju.

Senzorji so naprave, ki zaznavajo elektromagnetno valovanje. Ti beležijo odbito, izsevano ali lastno energijo (Slika 2).



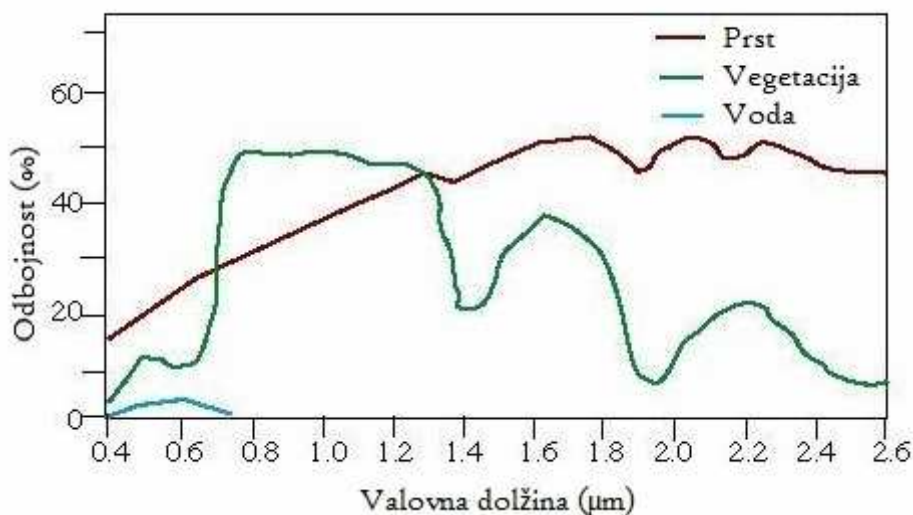
Slika 2: Načini opazovanja površja.
(Vir: Kerle et al., 2004)

Energija, ki iz Sonca pride na Zemljo, se bodisi odbije v vidnem in bližnjem infrardečem delu bodisi absorbira in nato znova izseva v obliki termičnih infrardečih valov. Senzorji, ki uporabljajo naravne vire energije, se imenujejo pasivni senzorji. Z njimi lahko zaznavamo le takrat, ko je vir energije prisoten.

Aktivni senzorji za snemanje uporabljajo lastni vir elektromagnetnega valovanja. Tovrstni senzorji oddajajo valovanje v smeri proti opazovanim predmetom, nato pa merijo intenziteto odbitega valovanja. Prednost aktivnih senzorjev je zmožnost snemanja kadarkoli, ne glede na dnevni ali letni čas. Primer aktivnih senzorjev sta lidar in radar (Oštir, 2006).

2.1.2 Spektralni podpis

Ločevanje predmetov na površju omogoča primerjava odziva odbitega ali izsevanega valovanja pri različnih valovnih dolžinah (Oštir, 2006). Koncept prikaza vrednosti odbojnosti v odvisnosti od valovne dolžine imenujemo spektralni podpis (Slika 3).



Slika 3: Spektralni podpis različnih rab.
(Vir: University of Calgary, 2011)


Spektralne vrednosti pri določeni valovni dolžini predstavljajo povprečno diskretno vrednost odbojnosti. Senzorji namreč beležijo odboj le v več ozkih spektralnih območjih oziroma v t.i. kanalih. Zvezno predstavitev spektralnega podpisa omogočajo hiperspektralni senzorji, ki imajo več sto ali celo tisoč kanalov (Kanjič, 2009).

Spektralni podpis je časovno in prostorsko spremenljiva lastnost posameznega predmeta na površju. Tako se npr. spektralna lastnost lista med vegetacijsko dobo stalno spreminja, prav tako pa so spremenjene vrednosti lahko posledica suše, bolezni in kakovosti tal (Hočevar, 2002). Razumevanje dejavnikov, ki vplivajo na spektralni odziv, je torej nujno za interpretacijo in identifikacijo različnih predmetov, njihovih lastnosti in stanj.

2.1.3 Spektralne lastnosti vegetacije

Analiza vegetacije z uporabo daljinsko zaznanih podob zahteva razumevanje strukture in mehanizmov delovanja vegetacije in njenih odbojnih karakteristik (ENVI user's guide, 2008). Interakcija elektromagnetnega valovanja z vegetacijo je kompleksen pojav, na spektralne vrednosti rastlinja namreč vplivajo številni faktorji, kot so vrsta rastja, fenološko⁴ in fiziološko stanje rastline, refleksijske značilnosti asimilacijskih organov t.j. listov in iglic, namestitvev asimilacijskih organov, vertikalna struktura sestojne strehe in razmerje med deležem osvetljenega in zasenčenega listja oziroma iglic ter sestojna zgradba z ozirom na drevesne vrste. Za spektralni odziv rastja v različnih delih spektra so med vegetacijsko dobo pomembne predvsem spektralne lastnosti asimilacijskih organov (Hočevar, 2002), ki jih določajo naslednje najpomembnejše komponente (Slika 4):

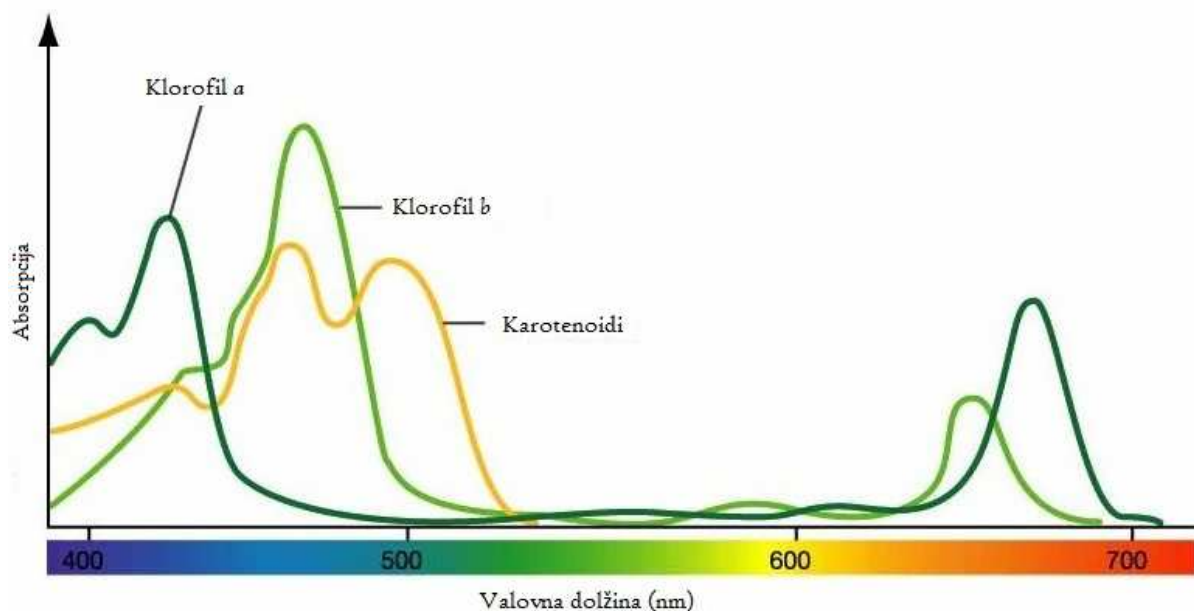
- asimilacijska barvila (pigmenti)
- celična zgradba
- vsebnost vode v celicah



Slika 4: Značilen potek odbojne krivulje asimilacijskih organov v različnih delih EM spektra.
(Vir: Govender et al. 2009)

⁴ Fenologija je veda, ki proučuje zakonitosti periodičnih pojavov v razvojnem ciklu rastlin in živali ter ugotavlja njihovo odvisnost od sezonskih in letnih nihanj podnebnih dejavnikov okolja.

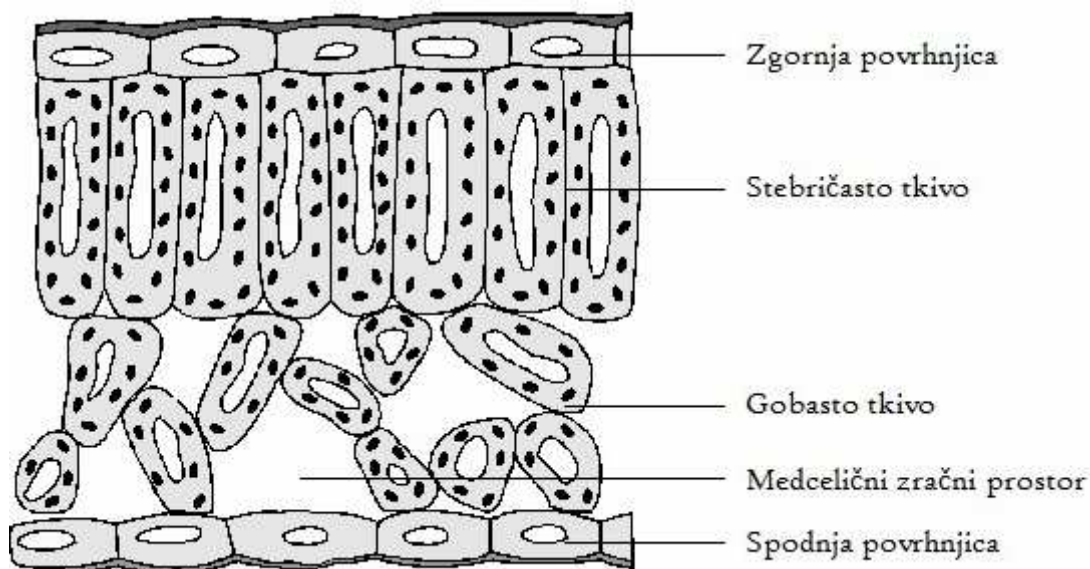
Barvila oziroma pigmenti vplivajo na potek krivulje v vidnem delu spektra. Klorofili, karotenoidi in antocianini so najbolj značilna rastlinska barvila, njihova različna kemična struktura in funkcionalnost pa omogočata absorpcijo EM valovanja pri različnih valovnih dolžinah vidnega spektra (Slika 5). Rastlina na ta način bolje izkorišča razpoložljivo energijo.



Slika 5: Intenziteta absorpcije svetlobe klorofila in karotenoidov.
(Vir: UIC, 2011)

Klorofili so poglavitni fotosintetski pigmenti. Močno absorbirajo valovanje v rdečem in modrem delu spektra, odbijajo pa zeleno svetlobo (Oštir, 2006), kar daje rastlinam značilno zeleno barvo. Največ klorofilov se nahaja v celičnih predelkih oziroma t.i. kloroplasteh⁵ v stebričastem tkivu asimilacijskega organa (Slika 6), kjer prestrežejo večino vpadne svetlobe.

⁵ Celice v notranjosti tkiva lista vsebujejo okoli pol milijona kloroplastov na vsak kvadratni milimeter lista.




Slika 6: Zgradba lista.
(Vir: Biology Wiz, 2011)

Veliko vsebnost klorofila običajno povezujemo z vitalnostjo vegetacije, nasprotno pa se karotenoidi (oranžno rumeni pigmenti) in antocianini (rdeči pigmenti) v visokih koncentracijah pojavljajo v manj zdravi vegetaciji.

Karotenoide zasledimo v membranah kloroplastov v vseh zelenih tkivih, kjer imajo pomembno vlogo pri zbiranju svetlobe, pri odvajanju odvečne svetlobe ter pri odstranjevanju škodljivih molekul, ki nastajajo kot posledica delovanja stresorjev na rastlino. Pogosto je povečanje vsebnosti katerega od zaščitnih karotenoidov del prilagoditvene strategije rastline v stresu (Šircelj, 2008).

Antocianini ščitijo liste pred škodljivim ultravijoličnim sevanjem.

V vidnem delu spektra potekajo odbojne krivulje drevesnih vrst zelo podobno (Slika 7). Njihovo razločevanje samo na osnovi spektralnih vrednosti v tem delu spektra je tako močno oteženo.



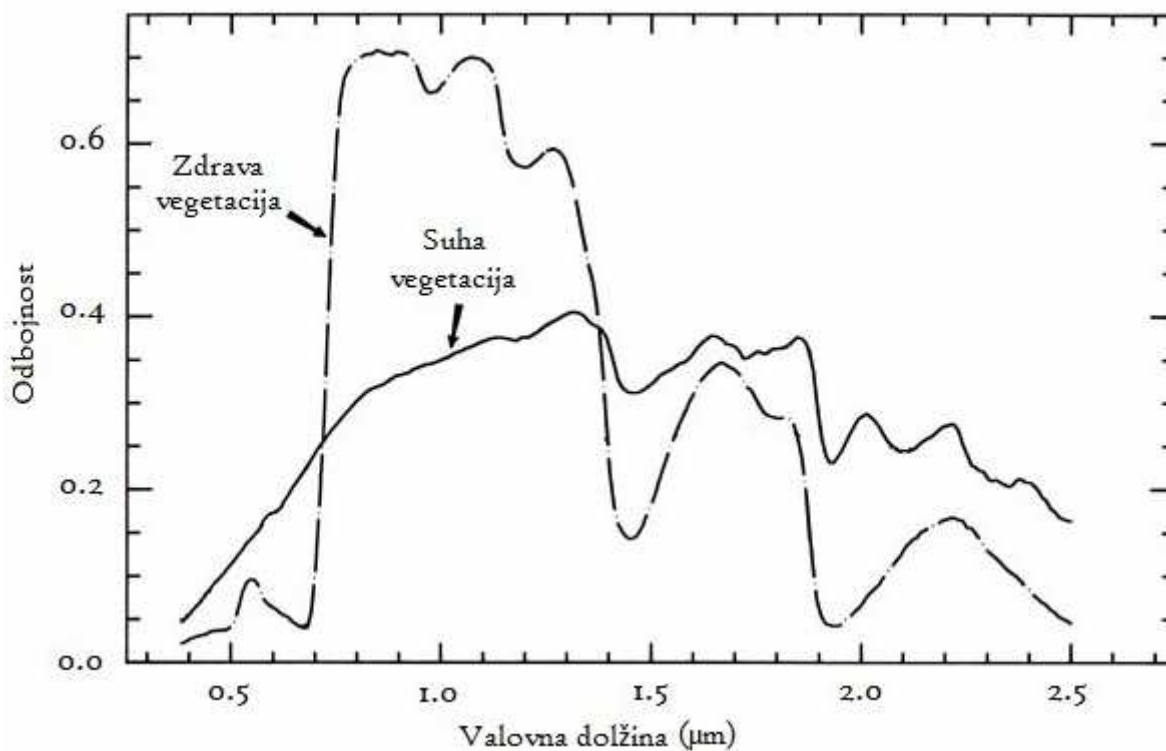
Slika 7: Spektralne krivulje različnih drevesnih vrst v različnih delih EM spektra. V vidnem delu spektra opazimo majhen razpon vrednosti odboja različnih drevesnih vrst.

(Vir: Dr. Nicholas Short's remote sensing tutorial, 2010)

Za potek krivulje v bližnjem infrardečem območju je pomembna predvsem celična zgradba, ki predstavlja odličen difuzni odbojnik za svetlobo bližnjega infrardečega dela spektra. Če bi bile naše oči občutljive na infrardečo svetlobo, bi se nam vitalna in zdrava drevesa zdela izredno svetla, saj je odboj v tem delu spektra petkrat večji kot v vidnem (Oštir, 2006).

Če na celični ravni pride do bolezenskih sprememb ali poškodb, se spremeni tudi vrednost spektralnega odboja. Gobasto tkivo lista infrardeče svetlobe ne lomi in odbija v tolikšni meri kot nepoškodovano tkivo (Slika 8). Zmanjšani odboj infrardečega sevanja spremljajo tudi spremembe odboja v zelenem in rdečem spektralnem pasu, ki skupno povzročajo zelo diferencialno

preslikavanje različnih stopenj poškodovanosti (Hočevar, 2002). Merjenje in opazovanje odboja v infrardečem spektru tako predstavlja zelo natančen mehanizem določanje zdravosti ali poškodovanosti vegetacije (Oštir, 2006).



Slika 8: Spektralna krivulja zdrave in suhe vegetacije.
(Vir: Blue Marble Project, 2003)

Krivuljo odboja v območju srednjega infrardečega spektralnega pasu (1.3 do 2.5 μm) določa vsebnost vode v celicah. Največja absorpcija vode je značilna za območji 1.4, 1.9 in 2.5 μm , vendar pa multispektralni senzorji v teh spektralnih območjih ne omogočajo zaznavanja EM valovanja zaradi izrazite atmosferske absorpcije vode.


Za pridobivanje podatkov svetlobo v infrardečem delu spektra izkorišča tudi vedno bolj uveljavljena lidarska tehnologija.

2.2 Lidarska tehnologija

2.2.1 Aero lasersko skeniranje

Izboljšanje naprav globalnega pozicioniranja in inercialnih navigacijskih sistemov, ki smo mu bili priča na prelomu tisočletja, je omogočilo razvoj lidarskega⁶ snemanja oziroma laserskega skeniranja (Oštir, 2006), ki je danes po zaslugi razvoja zmogljive informacijske infrastrukture za obdelavo zajetih podatkov in razvoja aplikacij že dobro uveljavljena, hitra, natančna in učinkovita metoda zajemanja trirazsežnih podatkov o površju.

Lidarska tehnologija je aktivni sistem snemanja, ki za določanje razdalje do objektov ali površin uporablja svetlobo v vidnem ali infrardečem delu spektra. Laserski oddajnik, ki je nameščen na dnu platforme (Slika 9), t.j. helikopterja ali letala, vsako sekundo odda lastno valovanje (do več deset tisoč kratkih impulzov), optično-mehanska naprava pa laserski žarek v prečni smeri leta odklanja tako, da vsak impulz zadane drugo točko na površju (Gosar, 2007). Odbiti žarek se nato vrne v sprejemnik signalov, ki poleg časa potovanja impulza zabeleži tudi kot odklona optično-mehanske naprave, ki je žarek usmerila.



Slika 9: Delovanje lidarja.

(Vir: LIDAR for vegetation applications, 2007)

⁶ Izraz lidar (angl. LIDAR ali LiDAR) je okrajšava za angleški opis tehnologije (LIght Detection And Ranging).

Razdaljo R med senzorjem in površjem določimo na osnovi merjenega časa potovanja elektromagnetnega impulza med senzorjem in opazovanim predmetom t_L ter znane hitrosti svetlobe skozi zrak c (1):

$$R = \frac{t_L \cdot c}{2} \quad (1)$$

Določitev koordinat točke na zemeljskem površju v referenčnem, na Zemljo vezanem, koordinatnem sistemu omogočata znan položaj in usmerjenost merilne naprave na platformi v vsakem trenutku oddaje laserskega žarka. Položaj je določen s hkratnimi meritvami diferencialnega GPS (angl. differential global positioning system), usmerjenost pa zagotavljajo inercialne meritve (INS, angl. inertial navigation system) treh kotov zasuka (Švab Lenarčič, 2009) okrog prečne, vzdolžne in navpične osi merilne naprave.

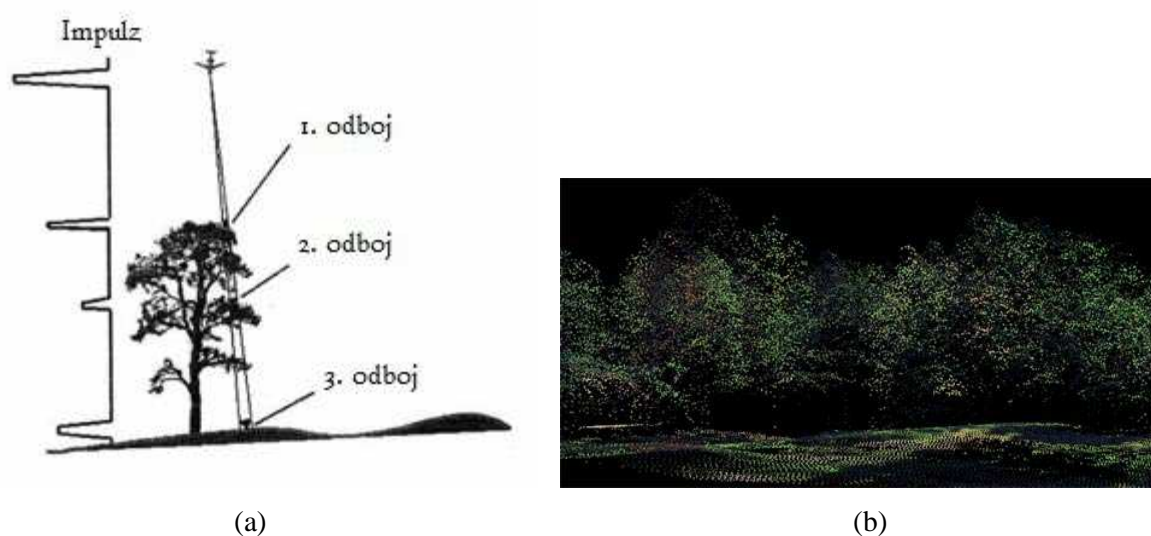
Rezultat laserskega skeniranja in obdelave podatkov je oblak lidarskih točk (Slika 10b). Točke v oblaku so zapisane s tremi prostorskimi koordinatami in praviloma več ostalimi atributi kot sta npr. red odboja in intenziteta odbitega laserskega žarka (Grigillo, 2010).

Oblak lidarskih točk vsebuje pulze, ki so se odbili na različnih predmetih (Oštir, 2006). Vir enega odboja je lahko več predmetov, saj premer laserskega žarka na tleh ni neskončno majhen, ampak ima določen odtis (angl. footprint), navadno od pol do enega metra. Sodobni sprejemniki lahko zaznajo več odbojev, na primer prvega, drugega, tretjega in zadnjega. Tovrstne, t.i. diskretne sisteme majhnega odtisa (angl. discrete return small footprint systems) je treba razlikovati od sistemov, ki beležijo celotno valovno obliko (angl. full waveform) odbite svetlobe (Kobler, 2011) in v primerjavi z diskretnimi sistemi omogočajo beleženje vertikalnega profila predmetov, na katerih je prišlo do odboja (Oštir, 2006).

Zaradi takojšnjega tvorjenja trirazsežnih podatkov, prostorske ločljivosti in točnosti postajajo podatki laserskega skeniranja priljubljen vir za rekonstrukcijo digitalnih modelov reliefa in virtualnih modelov mest (Kobler, 2011), vse bolj pa se lidarska tehnologija uveljavlja tudi v aplikacijah na področju gozdarstva in ekologije. Ker laserski žarek prodira skozi vegetacijo in se pri tem odbija od različnih delov drevesa, lidarska tehnologija omogoča opazovanje parametrov gozda in hkrati površja pod njim (Oštir, 2006).


2.2.2 Interakcija laserskega žarka s površjem in obdelava podatkov aero laserskega skeniranja

Odboj laserskega žarka je eden izmed načinov interakcije valovanja s površjem. Usmerjen laserski žarek se od površja največkrat odbije razpršeno, v vse smeri, na svoji poti pa se lahko odbije večkrat, kar diskretni snemalni sistem zazna kot vrhove povratnega impulza (Slika 10 a). Prvi odboj je navadno posledica odboja na zunanji ovojnici površja, t.j. na vrhovih vegetacije in stavb, najkasneje pa se žarek odbije od najnižjih predmetov oziroma od tal. Ker do odboja lahko pride tudi v notranjosti predmetov na površju, npr. znotraj vegetacije (Oštir, 2006) (Slika 10b), je predpostavka, da zadnji odboji predstavljajo tla, resnična zgolj za odprte površine (Kobler, 2011).



Slika 10: Interakcija laserskega žarka z drevesno krošnjo (a), Oblak točk in odboji znotraj vegetacije (b) (Vir: Shan, 2008 (a); Terranean mapping technologies, 2011 (b))


Odboje od golih tal in ostale odboje ločimo s postopkom filtriranja, kar omogoča izdelavo digitalnega modela reliefa (DMR) in digitalnega modela površja (DMP). DMP predstavlja ploskev skozi točke prvega odboja, medtem ko je DMR ploskovna predstavitev nadmorskih višin točk zadnjega reda t.j. točk, ki so posledica odboja na tleh. Na odprtem območju je DMR enak DMP. Rezultat razlike slojev DMR in DMP so absolutne oziroma dejanske višine objektov nad površjem. Računalniška rastrska predstavitev takšnih višin se imenuje normaliziran digitalni model površja (nDMP), za katerega pa se v aplikacijah na področju gozdarstva uporablja izraz digitalni model krošenj (DMK) (Slika 11).



Slika 11: Normaliziran DMP.

(Vir: Changok, 2007)

Pomembno je upoštevati, da diskretni lidar z majhnim premerom žarka, kakršnega največkrat uporabljamo, podcenjuje drevesne višine. Vzrok je način snemanja, ki z merjenjem posameznih točk objekte le vzorči, pri čemer pogosto zgreši sam vrh drevesa (Slika 12) (Kobler, 2011).



Slika 12: Vzorčenje objektov diskretnega snemalnega sistema.

(Vir: LIDAR for vegetation applications, 2007)

Stopnja podcenjevanja višin krošenj v gozdnem sestoj kot tudi višin posameznih dreves je odvisna od gostote snemanja in premera žarka (Kobler po Lefsky in sod., 2011) ter od koničnosti vrha krošnje, slednja pa od drevesne vrste. Na podcenjevanje višin vplivajo tudi način izračuna DMK in

DMR, stopnje prodiranja laserskega žarka skozi vegetacijo (angl. penetration rate) in količina podrasti v gozdu. Možne so tudi grobe napake DMK zaradi napak v DMR, ker slednji v strmih ali zelo gozdnatem terenu prikazuje vrh dreves, namesto golega reliefa (Kobler po Riano et al., 2011).

2.3 Urbani ekosistemi

Po navedbah Združenih narodov (Marshall, 1999) naj bi v mestih do leta 2030 živel kar 60% svetovne populacije. Mesta predstavljajo svojevrsten, prostorsko in časovno heterogen ekosistem. Interakcije med ljudmi in ekološkimi procesi definirajo drugačno dinamiko delovanja. Čeprav so urbani ekosistemi največkrat nestabilni in jih je težko razumeti, so ključnega pomena za zdravje, blaginjo in kakovost življenja urbanega prebivalstva (Alberti et al., 2008). Prisotnost zelenih površin, posebno gozda ter dreves, v mestih predstavlja kakovosten kontrast urbanemu življenju sodobnega človeka, hkrati pa mu ponuja možnost za umik od vsakdanjosti ter prvobiten stik z naravo.

V zadnjem desetletju je koncept estetizacije urbanih dreves nadomestilo obravnavanje njihovih gospodarskih, socialnih in predvsem okoljskih koristi (McPherson, 2006).

2.3.1 Vloga in pomen dreves v urbanem okolju

Ekološke koristi, ki jih prinašajo drevesa, so za marsikoga skoraj nepredstavljivo velike. V okoljih, ki so intenzivno zasajena z drevesi, je višja relativna vlaga in poleti občutno nižje temperature, kar posredno lahko zmanjša porabe energije za hlajenje, prav tako pa se na površinah pod drevesi lahko zagotovi boljše upravljanje s padavinskimi vodami. Drevesa ustvarjajo senco, pomembna pa so tudi kot element zmanjševanja hitrosti in učinka vetra. Poleg tega drevesa omogočajo filtracijo prahu in aerosolov, vplivajo pa tudi na zmanjševanje emisij ogljikovega dioksida (Brus, 2008), saj ga rastline v procesu fotosinteze uporabljajo za svoje življenje in kot stranski proizvod izločajo kisik, ki ga v mestih primanjkuje.

Četudi je prisotnost urbanih dreves izrednega pomena, jim človek v mestu največkrat ne zagotovi ugodnih ravnih razmer. Zbita tla, pomanjkanje kisika in vode v tleh, onesnaženost zraka in tal, neustrezna velikost ravnega prostora, številne bolezni in škodljivci ter pogoste mehanske poškodbe korenin, debla in krošnje onemogočajo normalen razvoj drevesa, mnogokrat pa drevo fiziološko oslabijo tako, da odmre (Tisa d.o.o., 2011). Izpostavljenost takšnemu stresu zmanjšuje življenjsko dobo drevesa v urbanem okolju, ki v povprečju znaša 15 let (Brus, 2008), hkrati pa vpliva na vitalnost drevnine, drevesa namreč lahko postanejo nevarna.

Ob neustreznih in nestrokovnih ukrepih lahko takšno drevo predstavlja prostorski konflikt. Pravočasna odstranitev nevarnih in potencialno nevarnih dreves oziroma njihovih delov je v

urbanem okolju nujna. Izhodišče za reševanje celostne problematike je torej upravljanje z urbanim drevjem, ki ga je potrebno predhodno evidentirati in zanj izdelati kakovosten, pregleden in zanesljiv kataster (Dolejši, 2009).

2.3.2 Upravljanje z urbano drevnino

Definiranje kakovostnih in kritičnih upravljaljskih strategij zagotavlja maksimiranje javnih koristi, ki jih nudijo drevesa v urbanem okolju (Dolejši, 2009). Popis urbanih dreves in snovanje katastra omogočata ažurno, načrtno, sistematično in strokovno načrtovanje in gospodarjenje z urbano drevnino, hkrati pa je pomembno, da takšna inventura zagotavlja minimalno stopnjo informiranosti, ki še omogoča razumno sprejemanje upravljaljskih odločitev. Upravljanje z mestnim drevjem v splošnem vključuje tri osnovne funkcije: sajenje drevesa, vzdrževanje oziroma nego drevesa in njegov posek (Dolejši, 2009).

Terenski popis drevnine mora zagotoviti podatke, podane v preglednici 1 (Vasle po Miller, 2004).

Preglednica 1: Komponente popisa dreves (Vasle po Miller, 2004).

KATEGORIJA	POPISNI ZNAK
Čas in osebje	Datum popisa
	Popisovalec
	Izvajalec ukrepa
Opis rastišča	Lokacija drevesa/mesta za saditev
	Širina obcestne zelenice
	Prisotnost in višina nadzemne napeljave
	Poškodbe pločnika
	Tla
	Potrebe po zalivanju
	Raba tal
	Onesnaženost
Opis drevesa	Drevesna vrsta
	Velikost drevesa
	Stanje drevesa
Zapisniki vzdrževanja	Zapisnik

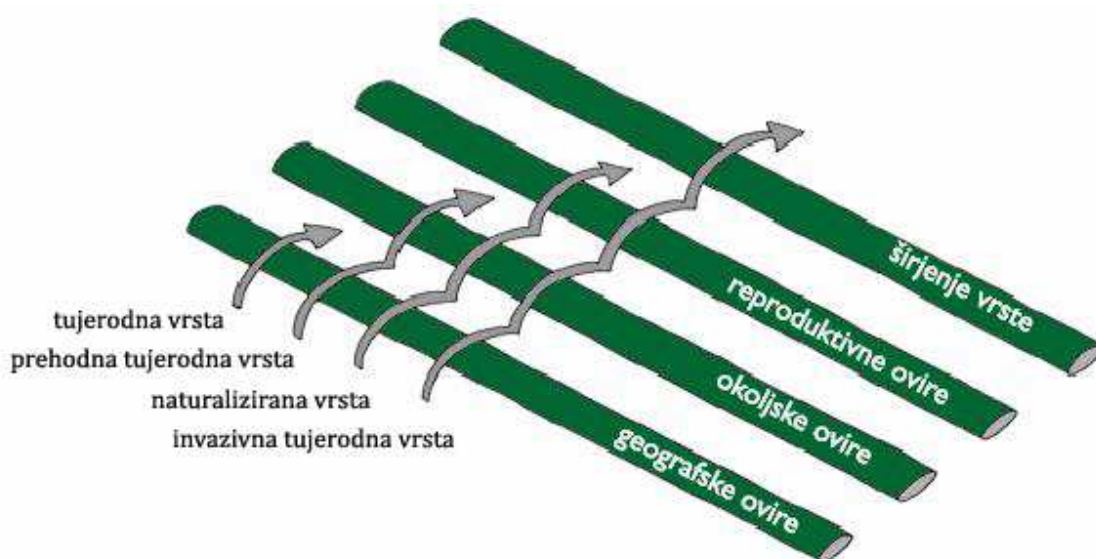
Kataster dreves predstavlja integriran koncept podatkovne baze dreves in slikovnega vira. Takšna evidenca je lahko del zasnove obširnejšega geodetskega informacijskega sistema, ki vključuje tudi stavbe, objekte gospodarske infrastrukture ipd. V tem primeru prestopi okvire urbanega gozdarstva in služi kot pripomoček urbanističnemu načrtovanju (Vasle, 2004).

Brus (2008) meni, da bi ob načrtovanju ozelenitev, kot pomembnem segmentu prostorskega urejanja v urbanem okolju, veliko pozornosti morali nameniti predvsem pravilni izbiri vrst dreves,

ki jih bomo sadili. Pogosto se namreč zgodi, da so v mestno okolje posajene vrste dreves, ki povzročajo težave, pogosto so celo strupene, nevarne ali invazivne.

2.4 Invazivne tujerodne vrste

V biologiji z izrazom tujerodne vrste poimenujemo tiste organizme, ki jih je človek prenesel v okolje, v katerem prej niso bili prisotni. Te lahko pripadajo najrazličnejšim skupinam organizmov (npr. virusi, glive, rastline, živali), prav tako se razlikujejo po virih in poteh naselitve. V Evropo je vsako leto zanesenih na stotine tujerodnih organizmov, vendar pa vsi ne postanejo invazivni. Tujerodna vrsta po naselitvi v novo okolje prehaja skozi različne faze (Slika 13) (Kus Vleenvliet, 2009), kot invazivne pa Konvencija o biološki raznovrstnosti opredeljuje zgolj tiste tujerodne vrste, katerih ustalitev in širjenje ogroža ekosisteme, habitate ali vrste.



Slika 13: Razvoj populacije tujerodne vrste s postopnim prilagajanjem na novo okolje.
(Vir: Kus Vleenvliet po Richardson et al., 2009)

Invazivne tujerodne vrste predstavljajo eno največjih groženj biotski raznovrstnosti. Na domorodne organizme imajo največkrat negativen vpliv, z njimi tekmujejo za hrano in življenjski prostor ter tako spreminjajo strukturo in funkcijo ekosistema, ki za rast domorodnih vrst ni več primeren. Bistvene spremembe in motnje v delovanju ekosistemov pa imajo pogosto tudi socio-ekonomske posledice, npr. nekatere invazivne rastlinske vrste so močno alergene (Fitosanitarna uprava Republike Slovenije, 2011), veliki pa so tudi stroški nadzora tujerodnih vrst, v Evropski uniji leti znašajo 12 milijard evrov letno (Kus Vleenvliet, 2009). Škoda, ki jo povzročijo invazivne tujerodne vrste, je v celoti težko merljiva, saj je nekatere vplive na ekosisteme ter izgubo biotske pestrosti težko ovrednotiti.

Načrtovanje ukrepov na področju tujerodnih vrst močno otežuje njihova populacijska dinamika. Populacije tujerodnih vrst sprva naraščajo počasi (prilagoditvena faza, angl. lag phase), po prilagoditvi na novo okolje (to obdobje lahko pri tujerodnih vrstah traja od nekaj let do nekaj desetletij) pa se začne populacija eksponentno povečevati. V začetnih fazah razvoja populacije invazivnost tujerodne vrste težko zaznamo, čeprav bi bili ukrepi ravno v tem času relativno enostavni in (stroškovno) verjetno učinkoviti. Ko se populacija poveča, invazivnost zlahka zaznamo, vendar invazivno vrsto iz narave težko odstranimo ali pa jo lahko le še nadzorujemo (Kus Vleenvliet, 2009).

Invazivne rastline so ponekod v Sloveniji že popolnoma spremenile domorodne združbe. Ena izmed takšnih invazivnih rastlin je japonski dresnik.

2.4.1 Japonski dresnik

Japonski dresnik (lat. *Fallopia japonica*) je uvrščen med 100 najbolj invazivnih rastlin sveta. Rastlinska vrsta, doma v zmernih predelih Azije (Japonska, Tajvan in severna Kitajska), je bila v Evropo prinesena kot okrasna rastlina v začetku 19. stoletja. V Sloveniji so japonski dresnik prvič opazili v začetku 20. stoletja v okolici Celja (Urbančič-Zemljič, 1999), danes pa je z izjemo submediteranskega in alpskega območja pogost po vsej Sloveniji (Frajman, 2008), kjer ga srečamo zlasti ob rekah, potokih, prometnicah, na gradbiščih in v bližini naselij ali v naseljih.

Spada v družino dresni (*Polygonaceae*) in je hitro rastoča, širokolistna trajnica, ki tvori gosta, homogena in kompaktna rastišča (Slika 14). Zaradi svoje konkurenčnosti se vse bolj vključuje v naravno rastje, kjer izpodriva samonikle rastline ter tako spreminja videz krajine in negativno vpliva na biotsko pestrost. V enem letu zraste preko 2 m v višino in je, podobno kot številne druge invazivne rastline (npr. žlezava nedotika, topinambur, deljenolistna rudbekija), pozno poleti cvetoča rastlina. Pri nas vzcveti konec julija (Frajman, 2008). Nadzemne dele uničijo že prve jesenske slane, preko zime pa ostanejo gola, suha stebela, ki dajejo pokrajini videz zapuščenosti in zanemarjenosti. Spomladi ob dnu suhih stebel odženejo novi poganjki (Urbančič-Zemljič, 1999).



Slika 14: Značilen sestoj japonskega dresnika v urbanem okolju.

Zelo uspešno se razmnožuje na vegetativni način, t.j. brez semen. Stebelni členki se zlahka zakoreninijo, rastlina pa tvori dolge podzemne korenike, s katerimi se močno razraste, zato je zatiranje japonskega dresnika težaven in dolgotrajen proces (Frajman, 2008), stroški z vzdrževanjem prizadetih območij pa veliki.

Japonskemu dresniku je soroden sahalinski dresnik, ki pri nas ni tako razširjen, vendar pa ponekod že poročajo o njegovem invazivnem značaju (Frajman, 2008).

V nadaljevanju opišemo pristope obdelave visokoločljivih podob, ki predstavljajo ustrezno izhodišče za klasifikacijo drevesnih vrst in japonskega dresnika.

2.5 Objektno usmerjena klasifikacija

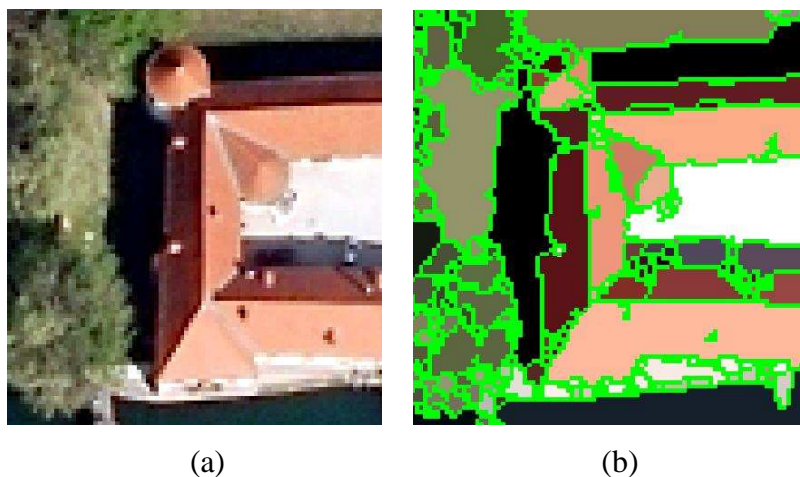
2.5.1 Proces človeškega zaznavanja in interpretacije

Proces človeškega zaznavanja definiramo kot organizacijo in interpretacijo občutkov. Likovna psihologija trdi, da zaznavni procesi oziroma njihove vsebine spontano težijo k obliki, strukturi in organizaciji predmetov, ki so nosilci pomena ter primarni gradniki okolja ali podobe (Peruš, 2000). Človeški možgani imajo prirojeno sposobnost interpretacije vsebine v okolici opazovalca, ki predmete zaznava intuitivno (Navulur, 2007), zametke likov pa je sposoben pretvoriti v popolne like. Popolnost se ohranja tudi ob zasuku, premiku, spremembi barve, vzorca, velikosti, obliki, t.j. spremembi elementov vizualne interpretacije.

Prepoznavanje predmetov je torej bistvenega pomena za interpretacijo in pridobivanje novih informacij (Oštir, 2006). Računalniško podprt objektno usmerjen pristop analize podob je tako soočen s posnemanjem procesa človeške interpretacije (Navulur, 2007) in naprednega prepoznavanja vzorcev.

2.5.2 Postopek objektno usmerjene klasifikacije

Osnovna metodološka enota objektno usmerjenega pristopa klasifikacije je objekt. Povezavo objekta na podobi in resničnega geografskega objekta omogoča postopek segmentacije, ki podobo razdeli na notranje homogene regije (segmente) (Slika 15). Čeprav segmenti oziroma podobjekti še ne predstavljajo končnega objekta na podobi (Kanjir, 2009), je v fazi segmentacije potrebno zagotoviti semantično uporabne segmente, saj ti predstavljajo osnovo za kasnejšo klasifikacijo oziroma razvrščanje segmentov v razrede.



Slika 15: Prehod z nivoja pikslov (a) na raven segmentov (b).

Objektno usmerjena klasifikacija torej temelji na dveh vzajemno odvisnih korakih, t.j. segmentaciji v prvem in klasifikaciji v drugem koraku.

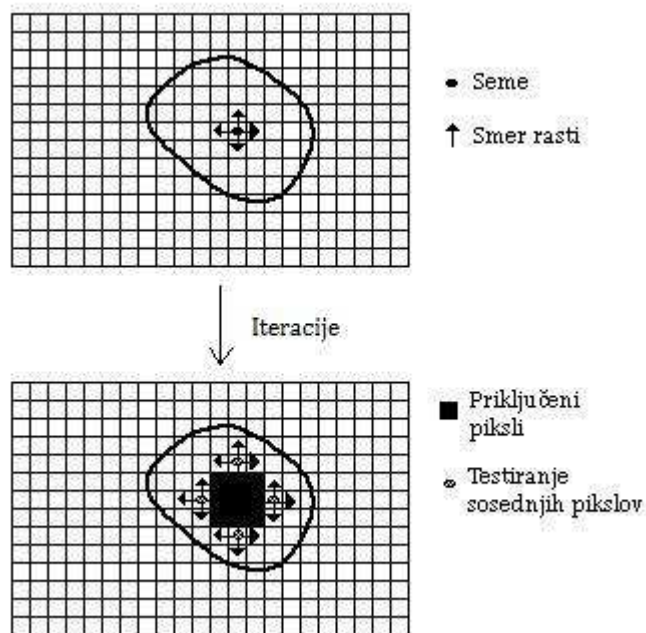
2.5.2.1 Segmentacija

Postopek segmentacije predstavlja koncept definiranja pomenskih entitet podobe t.j. segmentov, ki postanejo nosilci informacije. Segmentu lahko namreč za razliko od piksla poleg spektralnih lastnosti pripišemo tudi številne druge atribute, kot so prostorski (oblika, velikost, dolžina,...), morfološki (parametri oblike, tekstura) in kontekstualni (analiza sosedstva in bližine sosednjih pikslov, ...). Tvorjenje segmentov zmanjšuje stopnjo podrobnosti in zapletenosti podobe (Kanjir, 2009).

V splošnem segmentacijske algoritme delimo v dve skupini:

- algoritmi na osnovi rasti regij (angl. region growing)
- algoritmi na osnovi robov (angl. edge based)

Rast regij je postopek, ki na osnovi določenih pogojev rasti združuje piksele oziroma manjša območja v večja območja (Grigillo, 2010). Proces oblikovanja segmenta poteka iterativno. Primarni začetni piksli (semena, angl. seed) se večajo v regije z njihovimi sosednjimi piksli, ki izpolnjujejo izbrane kriterije homogenosti (Kanjir, 2009), dokler ni dosežen pogoj za prenehanje rasti (Slika 16). V osnovi se rast preneha, ko na podobi ni več pikslov, ki bi zadoščali pogoju podobnosti za vključitev v regijo (Grigillo, 2010).




Slika 16: Postopek rasti regij.

(Vir: Vision Systems, 1994)

Algoritmi na osnovi robov podobe razmejujejo na podlagi iskanja znatnega gradienta sivih vrednosti med sosednjimi piksli v podobi. Predpostavljajo, da največja sprememba intenzitete v izbrani smeri podobe definira meje segmentov. Zaznani robovi tvorijo mrežo mej segmentov.

Segmenti na podobi so vedno del hierarhične mreže (Slika 17), ki predstavlja pojavnost objektov na različnih ravneh segmentacije, hkrati pa pomeni projekcijo pojavnosti resničnih geografskih objektov. Takšen pristop tako omogoča obdelavo heterogenih podob, kjer se geografski predmeti pojavljajo na več ravneh (npr. stavbe, mestna četrt, mesto) (Nussbaum in Menz, 2008). Vsaka raven segmentacije je v celoti preslikava podobe, vendar z različno stopnjo razdrobljenosti segmentov. Za vsak segment so znani odnosi sosednosti (ista raven), podrejenosti (nižja raven) in nadrejenosti (višja raven).

Število ravni segmentacije pogojuje zapletenost klasifikacije. Večje kot je namreč število ravni segmentacije, bolj zapletena je klasifikacija.



Slika 17: Hierarhična mreža posameznih ravni segmentacije.

(Vir: Nussbaum in Menz, 2008)

2.5.2.2 Klasifikacija

Klasifikacija podobe predstavlja povezavo med daljinskim zaznavanjem in geografskimi informacijskimi sistemi (GIS) (Oštir, 2006). Z iskanjem podobnosti med piksli omogoča namreč prehod iz spektralnega v informacijski prostor.

Segment predstavlja nadgradnjo spektralnega razreda, saj pripadnost izbranemu informativnemu razredu določimo na osnovi več lastnosti segmenta, ne le na osnovi spektralne vrednosti. Segmente z enako semantično značilnostjo razvrstimo v isti razred.

Homogene segmente na osnovi atributov v razrede razvrščamo (Kanjir, 2009):

- s tradicionalnimi algoritmi klasifikacij (metoda najmanjše razdalje, metoda največje verjetnosti, paralelepipedna metoda)
- na osnovi definiranih pravil (angl. rule based approach)
- s klasifikacijo mehke logike (angl. fuzzy logic)

Objektno usmerjeno pristop klasifikacije navadno uvrščamo med nadzorovan način klasifikacije, saj uporabnik v procesu pridobivanja rezultatov uporabi lastno znanje o poznavanju površja.

Poleg klasifikacije na osnovi definiranih pravil v diplomski nalogi za razvrščanje segmentov v razrede uporabimo tudi statistični preizkus Kolmogorova in Smirnova.

2.6 Statistično preizkušanje domnev

Statistična domneva oziroma hipoteza je vsaka domneva o slučajni spremenljivki. Razlikujemo parametrične in neparametrične domneve. Parametrična domneva je domneva o vrednosti nekega parametra porazdelitve, neparametrična pa o neparametrični lastnosti porazdelitve slučajne spremenljivke.

Ničelna domneva H_0 je izhodiščna domneva, ki jo želimo preizkusiti. Alternativne domneve $H_i (i = 1, 2, \dots, k)$ so domneve, ki so z ničelno nezdružljive. Preizkus domneve ali test je torej vsak postopek, po katerem lahko na temelju vzorca slučajne spremenljivke ničelno domnevo zavrremo ali ne (Turk, 2005).

2.6.1 Preizkus Kolmogorova in Smirnova

Preizkus Kolmogorova in Smirnova (K-S test) je neparametrični statistični test, kjer na podlagi vzorca preizkušamo domnevo o porazdelitvi populacije (enostranski K-S test), v primeru dveh vzorcev pa preverjamo, ali vzorca pripadata isti porazdelitvi (dvostranski K-S test).

V diplomski nalogi uporabimo dvostranski K-S test. Podobnost med dvema vzorcema ocenimo s primerjavo njunih empiričnih kumulativnih porazdelitvenih funkcij (angl. empirical cumulative distribution function - EDCF). Testno statistiko D definiramo kot največjo absolutno razliko med empiričnima porazdelitvenima funkcijama (2):


$$D = \max(|F_X(x_1) - F_X(x_2)|), \quad (2)$$

kjer sta $F_X(x_1)$ in $F_X(x_2)$ empirični porazdelitveni funkciji diskretnih spremenljivk x_1 in x_2 . Ničelna domneva H_0 pravi, da sta porazdelitvi dveh vzorcev enaki. Če torej vzorca pripadata enaki populaciji, bo vrednost statistike D minimalna (Sridharan, 2010).

Empirično kumulativno porazdelitveno funkcijo zapišemo (3):

$$F_X(x_i) = \frac{i}{n}, \quad (3)$$

kjer je n število elementov vzorca, i pa predstavlja zaporedno številko elementa v razvrščenem vzorcu x_i . Vrednosti elementov vzorca x_i , $i=1, \dots, n$ predhodno razvrstimo po velikosti od najmanjše vrednosti proti največji. Graf empirične porazdelitvene funkcije je stopničast (Slika 18).



Slika 18: Graf empirične porazdelitvene funkcije.

Enako velika vzorca imata za posamezno zaporedno številko elementa i enake vrednosti empirične porazdelitvene funkcije, vendar pa je ta vrednost različna za izbrano vrednost vzorca x_i , kar omogoča razlikovanje in nadaljnjo klasifikacijo na osnovi vrednosti testne statistike. Število elementov v dveh vzorcih je lahko različno.

3 UPORABLJENI PODATKI, METODOLOGIJA IN PROGRAMSKA OPREMA

Poglavje zajema predstavitev uporabljenih podatkov, izbranih postopkov za klasifikacijo drevesnih vrst in zaznavanje japonskega dresnika ter uporabljene programske opreme.

3.1 Opis podatkov

Heterogenost vrstne in prostorske pojavnosti ter specifičnost predmeta obravnave zahtevata preudarno izbiro podatkov. Ti naj v največji meri omogočijo podrobno analizo in zaznavanje predmeta, prav tako pa naj predstavljajo dobro izhodišče za izbiro ustreznih pristopov obravnave, ki bo potencial podatkov dobro izkoristila. V diplomski nalogi uporabimo tako slikovne kot višinske podatke visoke ločljivosti. Višinske podatke, zajete z lidarsko tehnologijo, uporabimo le za primer klasifikacije drevesnih vrst. Slikovni viri so bili pridobljeni tako z letalskim kot satelitskim snemanjem.

3.1.1 Satelitski posnetek WorldView-2

Satelit WorldView-2 je bil izstreljen oktobra 2009 in je po satelitih QuickBird (izstreljen 2001) in WorldView-1 (izstreljen 2007) tretji satelit v orbiti podjetja Digital Globe. Danes je trenutno prvi in edini visokoločljivi komercialni satelit, ki zagotavlja pankromatsko podobo s 0,46 m ločljivostjo in 8-kanalno multispektralno podobo v vidnem in bližnje infrardečem delu spektra s 1,84 m ločljivostjo⁷. Kanali omogočajo zaznavanje EM valovanja v namensko izbranih ozkih spektralnih območjih, v katerih lahko bolje definiramo določene predmete na površju ali pa so ta območja občutljiva na razmere v atmosferi. V preglednici 2 podajamo osnovne značilnosti spektralnih kanalov senzorja satelita WorldView-2 ter možnosti uporabe posamičnih kanalov. V stolpcu status kanala podajamo primerjavo kanalov satelita WorldView-2 s kanali satelita QuickBird.


⁷ To so podatki za nadirne podobe. Pri naklonu 20° znaša ločljivost v pankromatskem kanalu 0,52 m in 2,08 m v multispektralnem.

Satelit WorldView-2 se nahaja v skoraj polarni sončno sinhroni tirnici z naklonom 97,2 °. Okrog Zemlje kroži na višini 700 km, čas ponovnega obiska znaša 1.1 dan, v tem času pa posname 1 milijon km² površine površja. Satelit ima, tako kot QuickBird, 11-bitno radiometrično ločljivost, čemur ustreza 2048 sivih vrednosti.

Preglednica 2: Značilnosti spektralnih kanalov senzorja WorldView-2. (Vir: Digital Globe, 2010)

Spektralni kanal	Valovna dolžina (µm)	Spektralno območje	Status kanala	Značilnost in uporaba
Coastal Blue	0.400 – 0.450	modra	nov kanal	absorbira ga klorofil v rastlinah, merjenje globine voda, znatno občutljiv na atmosfersko sipanja, izboljšanje tehnik atmosferskih popravkov
Blue	0.450 – 0.510	modra	enak kot pri satelitu QuickBird	absorbira ga klorofil v rastlinah, merjenje globine voda, manj občutljiv na atmosfersko sipanje kot kanal Coastal Blue
Green	0.510 – 0.580	zelena	ožji kot pri QuickBird	kartiranje zelene vegetacije (največja vrednost odboja)
Yellow	0.585 – 0.625	rumena	nov kanal	prepoznavanje in klasifikacija predmetov
Red	0.630 – 0.690	rdeča	ožji kot pri QuickBird	prepoznavanje različnih vrst rastlin, klasifikacija gole prsti, cest in geoloških struktur
Red-Edge	0.705 – 0.745	bližnja infrardeča	nov kanal	območje z znatno spremembo odbojnosti klorofila, spremljanje zdravja vegetacije, klasifikacija vegetacije
NIR1	0.770 – 0.895	bližnja infrardeča	ožji kot pri QuickBird	ocena vlage vegetacije in rastlinske biomase, učinkovito ločevanje vodnih površin in vegetacije
NIR2	0.860 – 1.040	bližnja infrardeča	nov kanal	manjša občutljivost na atmosferske vplive
Pankromatski	0.450 – 0.800	/	/	izboljšanje spektralne ločljivosti

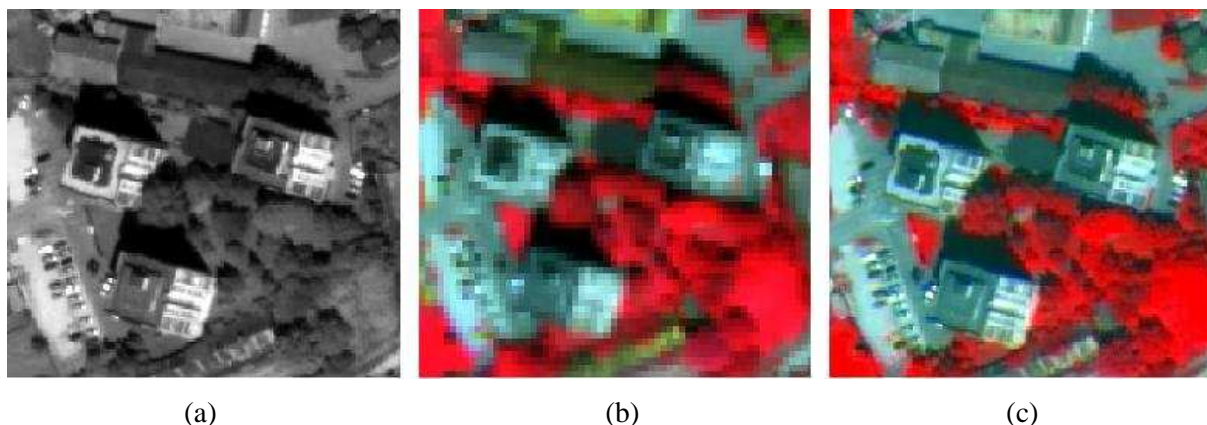
Kombinacija visoke prostorske in spektralne ločljivosti predstavlja primerno izhodišče za analize površja, predvsem pa omogoča podrobnejše študije vegetacije. Posebno pozornost velja nameniti kanalu Red-Edge, ki, kot navedeno v preglednici 1, ustreza valovni dolžini med 0.705 in 0.745 μm , nanaša pa se na znatno in sunkovito spremembo odbojnosti klorofila v rastlinah (Slika 19). Študije so celo pokazale, da je razmerje rdečega in Red-Edge kanala bolj občutljiv kazalnik sprememb stanja vegetacije kot normaliziran vegetacijski indeks (NDVI) (Digital Globe, 2010), prav tako pa je na ta način mogoče natančneje razlikovati med iglavci in listavci.



Slika 19: Značilna sprememba vrednosti odboja med rdečim kanalom in kanalom Red-Edge.

(Vir: Seager et al., 2005)

Satelitski posnetek WorldView-2, uporabljen v diplomski nalogi, je bil pridobljen 10.8.2010 (Slika 20) in predstavlja osnovni vir za klasifikacijo drevesnih vrst. Kot pomožni vir ga uporabimo za določanje območij nahajanja japonskega dresnika, kjer osnovni slikovni vir predstavljajo posnetki ortofoto. Uporabo satelitskih posnetkov je omogočil Inštitut za prostorske in antropološke študije ZRC SAZU.



Slika 20: Posnetek WorldView-2 - pankromatski kanal (a) lažni barvni kompozit (b) izostren lažni barvni kompozit (c).


3.1.2 Državni ortofoto

Ortofoto predstavlja v ortogonalno projekcijo transformirano aerofotografijo. Postopek ortorektifikacije zmanjšuje geometrične napake, ki nastanejo znotraj posnetkov zaradi orientacije senzorja, sistematične napake senzorja, premika zaradi izoblikovanosti površja in ukrivljenosti Zemlje (Kokalj, 2010). Čeprav je ortofoto v merskem smislu enak linijskemu načrtu ali karti, je še vedno samo fotografski prikaz (Slika 21). Vsebinsko, ki jo prikazuje, mora uporabnik namreč znati pravilno interpretirati (Kosmatin Fras, 2004).

V Sloveniji imamo izdelane barvne ortofote s prostorsko ločljivostjo 0,5 m (DOF050), bližnje infrardeče barvne ortofote s prostorsko ločljivostjo 1 m (DOF100 IR) in 491 listov barvnih ortofotov z ločljivostjo 0,25 m (DOF025) (Grigillo, 2010). V preglednici 3 podajamo lastnosti uporabljenih ortofotov. Podatke smo naročili na GURS v formatu TIFF. Enota naročila je list ortofota, ki ustreza razdelitvi na liste TTN5 (Temeljni topografski načrt v merilu 1:5000).

Preglednica 3: Lastnosti ortofota.

	DOF050	DOF100 IR
Opis	barvni ortofoto	bližnje infrardeč ortofoto
Prostorska ločljivost	0,5 m	1 m
Spektralna	3 kanali (barvni prostor RGB)	3 kanali (barvni prostor RGB)
Radiometrična	24-bitna; (8 bitov za posamezen kanal)	24-bitna; (8 bitov za posamezen kanal)
Leto izdelave	2006, 2011	2006



Slika 21: DOF050 2006 (a), DOF100 IR 2006 (b), DOF050 2011(c).

3.1.3 Podatki aero laserskega skeniranja

Naročnik lidarskega snemanja območja krajinskega parka Tivoli, Rožnik in Šišenski hrib z okolico je bila Mestna občina Ljubljana (MOL), Oddelek za varstvo okolja. Podatke snemanj je Gozdarskemu inštitutu Slovenije in Inštitutu za prostorske in antropološke študije (ZRC SAZU) posredovalo podjetje Flycom. Snemanje je bilo izvedeno 24.3.2011, ko vegetacija še ni bila v celoti olistana. Pri snemanju je bil uporabljen zvezni laserski skener LiteMapper 5600, nameščen na helikopterju, z višino leta 400 m nad terenom. Osnovne tehnične značilnosti skenerja podajamo v preglednici 4.

Preglednica 4: Osnovne tehnične lastnosti skenerja LiteMapper 5600. (IGI mbH, 2011)

	Skener LiteMapper 5600
Način zaznavanja odbojev	Zvezno zaznavanje odbojev (neomejeno število zaznanih odbojev)
Vzorec skeniranja	Vzporedne linije (skener z vrtečim večkotnim zrcalom)
Valovna dolžina laserskega žarka	1.550 μm
Frekvenca oddajanje pulzov	180 kHz
Divergenca laserskega žarka	< 0.5 mrad
Velikost točke na tleh	3.1 cm \times 3.2 cm
Zajem intenzitete	16 bitni

Oddaljenost med linijami snemanja je znašala 250 m (Slika 22), kar ob ustrezno izbranih parametrih leta zagotavlja zadostno prekrivanje fotografij med pasovi in tudi v vzdolžni smeri, hkrati pa podvoji gostoto laserskih točk, ki v osnovi znaša 10 točk/m², ob prekrivanju pa približno 20 točk/m² (Bernik, 2011).



Slika 22: Prikaz poti leta helikopterja.
(Vir: Bernik, 2011)

V diplomski nalogi smo za klasifikacijo drevesnih vrst uporabili izvedene podatke laserskega skeniranja t.j. digitalni model krošenj v rastrski obliki z velikostjo piksla 1 m (Slika 23). Kot je opisano v poglavju 2.2.2, digitalni model krošenj predstavlja razliko slojev digitalnega modela površja in digitalnega modela reliefa. Za izračun slednjega je bil uporabljen algoritem REIN (angl. REpetitive INterpolation), posebej namenjen uporabi v strmem gozdnatem reliefu (Kobler, 2011).



Slika 23: Digitalni model krošenj, 3D pogled.

3.1.4 Referenčni terenski podatki

3.1.4.1 Digitalni kataster dreves

Podatke o popisu dreves na zemljiščih MOL je posredovalo podjetje LUZ d.d. (Ljubljanski urbanistični zavod), ki je kataster vzpostavilo, ureja pa ga v sodelovanju s podjetjem Tisa d.o.o. Kataster dreves je del informacijskega portala Zelene površine, ki omogoča vpogled v različne kategorije sistema zelenih površin na območju MOL-a. Dopolnjevanje podatkovne baze dreves omogoča interaktivni vmesnik Editiranje dreves. Oba vmesnika sestavljajo različni grafični in vektorski podatkovni sloji (DOF, kataster, register prostorskih enot, ...), ob poizvedovanju izbranih vsebin pa je na voljo tudi njihov opis (Slika 24).



Slika 24: Grafični in atributni del vmesnikov Zelene površine in Editiranje dreves.

Podatkovna baza katastra dreves v MOL, ki smo jo uporabili za poizvedovanja v GIS orodjih, vsebuje naslednje attribute:

- drevesna vrsta
- tip drevesa (listavec, iglavec)
- datum popisa
- višina
- prioriteta
- ukrep

3.1.4.2 Poligoni območij pojavljanja japonskega dresnika

V diplomski nalogi smo uporabili referenčne terenske podatke različnih avtorjev in iz različnih obdobj (Jogan 2007, Ribeiro 2007, Jarnjak 2011), prav tako pa smo za izbrana območja opravili lasten terenski ogled (5.9.2011, 6.10.2011). Območja pojavljanja japonskega dresnika smo na terenu fotografirali.

Opis izbranih študijskih območij navajamo v podpoglavju 4.1.

3.2 Opis uporabljene metodologije

V diplomski nalogi klasifikacijo drevesnih vrst in japonskega dresnika obravnavamo ločeno. Kljub temu je osnova koncepta obeh uporabljenih metodologij primerljiva. Metodologija obravnave in obdelave podatkov v prvem delu temelji na uporabi objektno usmerjenega pristopa klasifikacije, pri čemer na osnovi definiranih pravil s hierarhično strukturo izločanja ali postopkom segmentacije definiramo kandidate predmeta obravnave. Ti v nadaljevanju predstavljajo izhodišče za končno klasifikacijo s preizkusom Kolmogorova in Smirnova.

V tem podpoglavju najprej navedemo splošen potek objektno usmerjene klasifikacije, nato pa za oba predmeta obravnave dodatno predstavimo izbrane postopke, ki smo jih uporabili v praktični izvedbi naloge.


3.2.1 Opis postopka objektno usmerjene klasifikacije

Objektno usmerjena klasifikacija⁸ sestoji iz dveh glavnih faz, ti pa iz več zaporednih korakov (Slika 25). Prva faza vključuje zaznavanje objektov t.j. segmentacijo, druga pa izločanje le teh t.j. klasifikacijo. V procesu segmentacije se najprej z uporabo algoritma na osnovi robov tvorijo homogene regije. Stopnjo razdrobljenosti (podrobnosti) oziroma velikost segmenta določa le en vhodni parameter t.j. stopnja segmentacije (angl. scale level). Optimalna vrednost stopnje segmentacije je odvisna od prostorske ločljivosti podobe in karakteristik geografskih entitet, ki gradijo pokrajino (Kokalj, 2010). V nadaljevanju lahko definirane segmente združimo (angl. merge), kar omogoča boljše definiranje mej segmentov, prav tako pa lahko manjše segmente združimo v večje. Stopnjo združevanja določa parameter lambda. Algoritem Full Lambda-Schedule v programskem okolju ENVI segmente združuje iterativno glede na kombinacijo spektralnih in prostorskih lastnosti (prirejeno po Kanjir, 2009).

V naslednjem koraku se segmentom pripišejo vrednosti različnih atributov (prostorski, spektralni, teksturni, razmerje kanalov in barvni prostor). Postopek pripisovanja je za visokoločljive podobe lahko dolgotrajen. Na osnovi vrednosti atributov so segmenti kasneje v postopku klasifikacije razvrščeni v razrede bodisi z nadzorovano klasifikacijo bodisi s klasifikacijo z definiranjem pravil, t.j. povežemo izbran atribut in njegovo vrednost, ki določa, kateri segmenti bodo razvrščeni v

⁸ Opisan postopek je značilen za programsko orodje ENVI oziroma modul Feature Extraction. Modul ENVI Feature Extraction omogoča izločanje objektov iz visokoločljivih pankromatskih oziroma multispektralnih podob (Kanjir, 2009).

izbran razred. V diplomski nalogi na prvih ravneh klasifikacije (izdelava maske vegetacije, izločanje kandidatov drevesnih krošenj in japonskega dresnika) uporabimo slednji način.



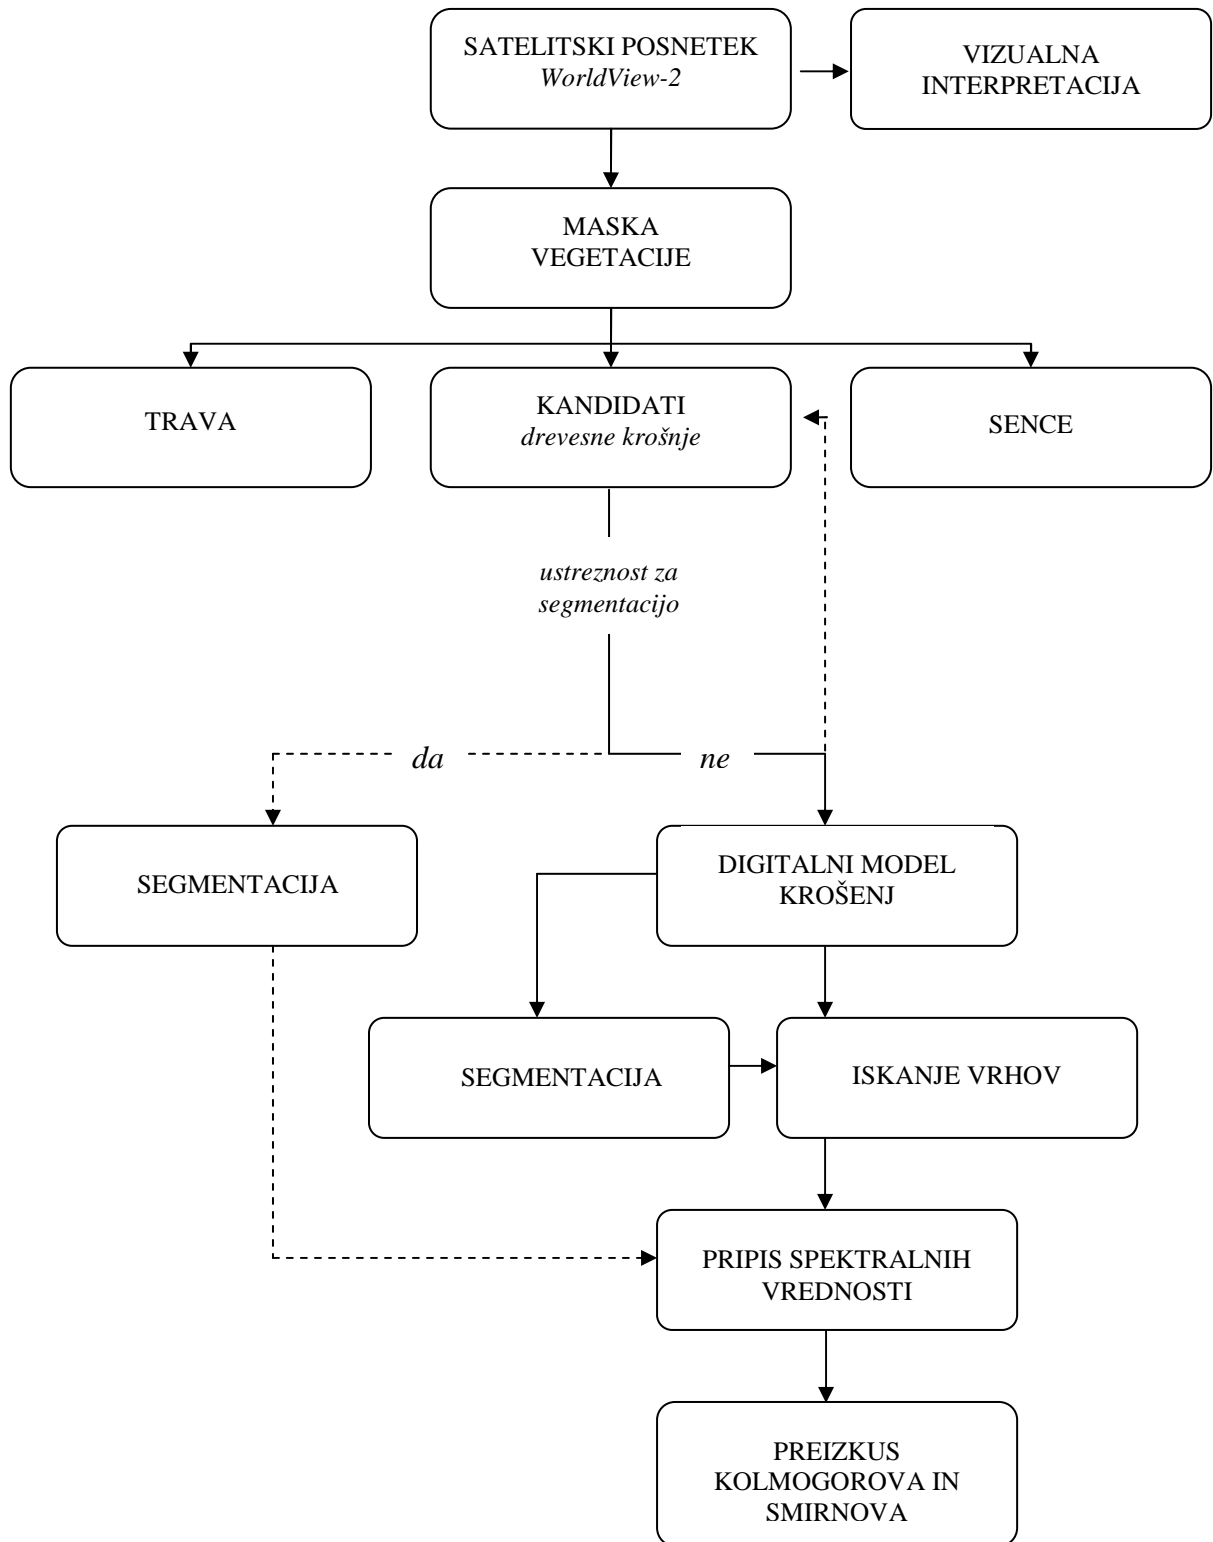
Slika 25: Koraki objektno usmerjene klasifikacije. Od leve proti desni: vhodna podoba, segmentacija vsebine podobe, združevanje segmentov na podobi, klasifikacija vsebine podobe.

3.2.2 Potek zaznavanja drevesnih vrst

Shema poteka klasifikacije drevesnih vrst je predstavljena na sliki 26. V prvem koraku z uporabo multispektralnega posnetka, izostrenega na ločljivost 0,5 m, izdelamo masko vegetacije. V drugem koraku iz sloja vegetacije izločimo površine senc in trave, obenem pa pridobimo kandidate drevesnih krošenj.

Z vizualnim pregledom ocenimo ustreznost sloja kandidatov drevesnih krošenj za nadaljnjo segmentacijo, ki je določena s stopnjo pokritosti sloja krošenj in slikovnega vira. Nizka stopnja prekrivanja bi onemogočila primerno definiranje segmentov, zato nadalje izbiramo med ponovnim definiranjem pravil za izločanje drevesnih krošenj in uporabo digitalnega modela krošenj (če je ta na voljo). V diplomski nalogi se odločimo za slednjo možnost.

Z uporabo postopka inverzne razvodne segmentacije (angl. inverse watershed segmentation) najprej na digitalnem modelu krošenj poiščemo kandidate vrhov ter jih nato uporabimo za razmejevanje segmentov, pridobljenih s segmentacijo sloja digitalnega modela krošenj. Segmentom v nadaljevanju pripišemo spektralne vrednosti multispektralnega posnetka. Tako pridobljeni segmenti predstavljajo vhodni podatek za klasifikacijo drevesnih vrst s preizkusom Kolmogorova in Smirnova.



Slika 26: Diagram poteka klasifikacije drevesnih vrst.

3.2.2.1 Predstavitev izbranih postopkov za klasifikacijo drevesnih vrst

Vizualna interpretacija

Cilj t.i. vizualne interpretacije podob oziroma fotointerpretacije je prepoznavanje in razmejevanje predmetov na podobi. Opazovalec na podobi išče zaključene skupine pikslov, pri tem si največkrat pomaga s fotointerpretacijskim ključem. Opazovanje razlik med predmeti in njihovo okolico vključuje tudi primerjavo glede na enega ali več osnovnih elementov vizualne interpretacije podob, kot so ton, oblika, velikost, vzorec, tekstura, senca in povezava. Povezava upošteva medsebojna razmerja med opazovanim predmetom in drugimi prepoznanimi predmeti ali pojavi v njegovi okolici (Oštir, 2006; Bozja, 2010). Vizualna interpretacija omogoča analizo podobe na vsaki ravni klasifikacije in tako dopolnjuje digitalno obdelavo podob. V nekaterih primerih lahko ugotovitve vizualne interpretacije predstavljajo izhodišče nadaljnjih odločitev, hkrati pa te ugotovitve predstavljajo element notranje kontrole vmesnih faz celotnega poteka digitalne analize.

Raznolikost drevesnih vrst pred računalniško obdelavo podatkov analiziramo z uporabo vseh slikovnih virov (satelitski posnetek, državni ortofoto).

Izdelava maske vegetacije

Vegetacijo iz satelitskega posnetka izločimo z uporabo Red-Edge normaliziranega diferencialnega vegetacijskega indeksa (NDVI), kjer v enačbi za izračun vegetacijskega indeksa (4) namesto infrardečega kanala uporabimo Red-Edge kanal.

$$NDVI = \frac{IR - R}{IR + R} \quad (4)$$

Indeks zavzame vrednosti med -1 in 1, pri čemer višje vrednosti pomenijo bolj intenzivno vegetacijo (Oštir, 2006).

Izločanje drevesnih krošenj, trave in senc

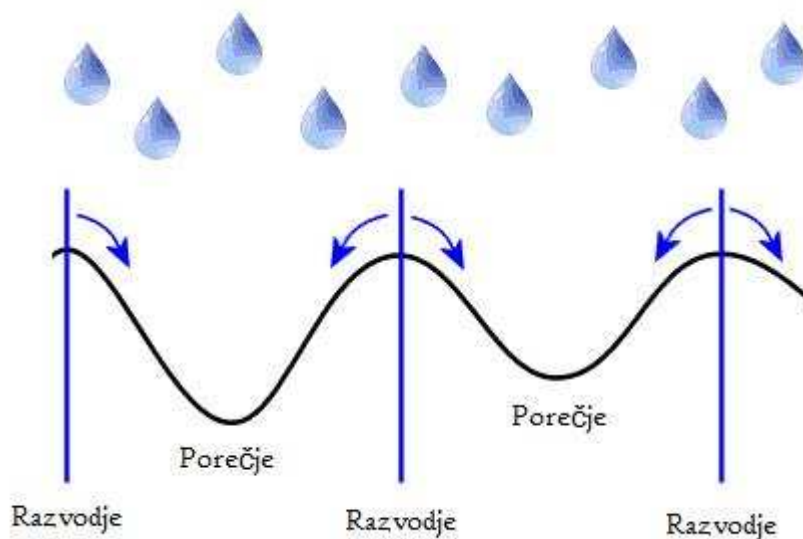
Izločanje temelji na postopku definiranja pravil, t.j. na izbiri atributov in njihovih vrednosti, ki zagotavljajo ustrezno klasifikacijo obravnavanega predmeta (krošenj, trave in senc).

Iskanje vrhov dreves na digitalnem modelu krošenj

Vrhove dreves na sloju digitalnega modela krošenj poiščemo z implementacijo modela inverzne razvodne segmentacije. Inverzna razvodna segmentacija sloni na posnemanju koncepta vodnih porečij in razvodij. Porečje oziroma hidrogrfski bazen predstavlja zaključeno geografsko območje zbiranja in odtekanja vode. Porečja so med seboj ločena z razvodji (Slika 27). Značilno je, da vsa

padavinska voda odteka proti najnižji točki porečja. Vsaka točka na površju lahko pripada zgolj enemu porečju.

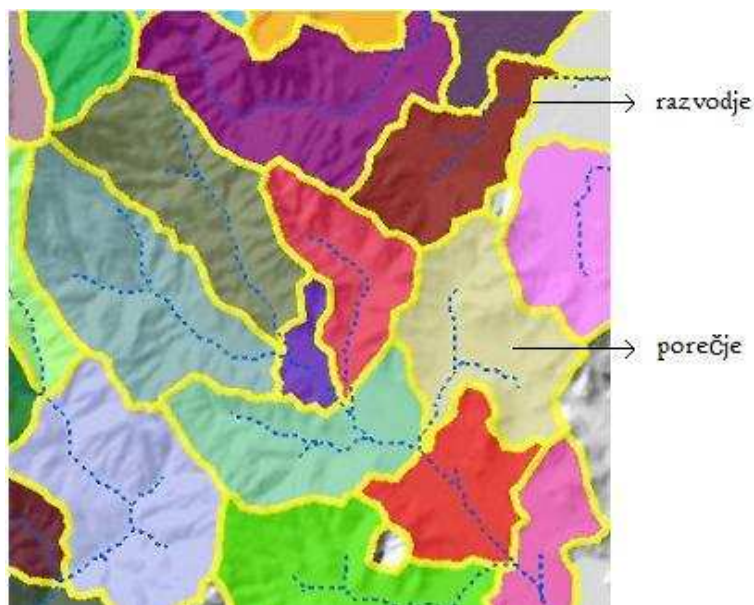
Razvodna segmentacija omogoča kakovostno analizo vodnega sistema, predvsem pa je nepogrešljiva pri hidrološkem modeliranju na osnovi digitalnega modela površja.



Slika 27: Porečje in razvodje.
(Vir: Image metrology, 2011)

Postopek inverzne razvodne segmentacije, ki ga uporabimo v diplomski nalogi, vrhove dreves definira tako, da v prvem koraku obrne (invertira) digitalni model krošenj. Ta je torej zdaj oblikovan kot depresijski model, t.j. z dolinami oziroma porečji (kot na sliki 27), kjer vrhovi postanejo najnižje točke porečij.

V drugem koraku z razvodno segmentacijo razmejimo porečja oziroma t.i. porečja krošenj (Slika 28). Proces razvodne segmentacije temelji na analizi smeri pretoka, ki je določena s smerjo padca z največjim naklonom glede na vsako celico rastra digitalnega modela krošenj. Naklon izrazimo kot razmerje med spremembo v višini in razdaljo med središči celic.



Slika 28: Razvodja in porečja v florisnem pogledu. Maksimalno vrednost oziroma točko z (absolutno) najvišjo vrednostjo iščemo znotraj rumenih poligonov. (Vir: ArcGIS Desktop 9.3 Help)

Rezultat drugega koraka predstavlja vektorski sloj poligonov, ki definirajo meje med porečji. V nadaljevanju ta sloj prekrijemo z digitalnim modelom krošenj, posameznim porečjem pa pripišemo le eno vrednost, t.j. vrednost piksla z (absolutno) največjo vrednostjo. Vrednost piksla na digitalnem modelu krošenj predstavlja podatek o višini.

V diplomski nalogi uporabljen model inverzne razvodne segmentacije je prirejen po Edsonu (2011). Model smo izdelali v programskem okolju ArcMap. Opišemo ga v poglavju 4.2.1.

Segmentacija sloja digitalnega modela krošenj

V procesu segmentacije sloj digitalnega modela krošenj obravnavamo tako kot ostale rastrske slikovne vire, kjer je najprej potrebno izbrati ustrezno vrednost stopnje segmentacije. To vrednost izberemo tako, da se bodo segmenti kar najbolje prilegali obliki krošnje drevesa.

Lažje razmejevanje in definiranje segmentov, ki jih pridobimo s segmentacijo sloja digitalnega modela krošenj, v nadaljevanju omogočajo vrhovi dreves, pridobljeni v prejšnjem koraku. Vendar pa vektorski sloj definiranih segmentov predstavlja le obode krošenj (poligoni) z različnimi atributi (povprečna vrednost in standardni odklon pikslov v segmentu za posamezen kanal, površina in ostali geometrijski atributi...), ki pa za klasifikacijo drevesnih vrst s preizkusom Kolmogorova in Smirnova niso primerni, saj ne vsebujejo informacij o vrednosti pikslov, ki tvorijo regijo. Tem segmentom je zato najprej potrebno pripisati spektralne vrednosti pikslov kanalov izbrane visokoločljive podobe. Cilj je pridobiti segmente, za katere bodo znane vrednosti vseh pikslov znotraj segmenta v vseh kanalih.

Pripisovanje spektralnih vrednosti segmentom (objektom)

Pripisovanje spektralnih vrednosti omogoča povezavo med poligoni in multispektralno visokoločljivo podobo. Ko podobo prekrijemo z vektorskim slojem poligonov (segmentov) se nove regije (angl. region of interest) definirajo tako, da obod regije določa segment, vsakemu pikslu znotraj te regije pa se dodelijo vrednosti pikslov v posameznih kanalih. Rezultat postopka so torej regije z določenim številom pikslov, kjer so za vsak piksel te regije definirani naslednji atributi:

- identifikacijska številka piksla regije
- slikovne koordinate (vrstica in stolpec na vhodni podobi)
- geografske koordinate (geografska širina in dolžina)
- koordinate piksla v državnem koordinatnem sistemu
- vrednosti piksla v posameznih kanalih

Preizkus Kolmogorova in Smirnova

Regije, opisane v prejšnjem odstavku, predstavljajo izhodišče za preizkus Kolmogorova in Smirnova. Uporaba preizkusa temelji na predpostavki, da imajo različne vrste rabe (na primer različne drevesne vrste) v posameznih kanalih značilno empirično porazdelitveno funkcijo, ki je določena na osnovi vrednosti vseh pikslov v regiji. Primerjava porazdelitvenih funkcij različnih rab omogoča njihovo razlikovanje.

V prvem koraku klasifikacije za vsak kanal zagotovimo empirične porazdelitvene funkcije regij, za katere z gotovostjo vemo, katere rabe predstavljajo (referenčne regije). To pomeni, da izberemo vzorce in tako definiramo informacijske razrede. Pomembno je izbrati reprezentativne in dovolj velike vzorce. Prisotnost rabe na določenem območju potrdimo s terenskim ogledom ali različnimi topografskimi in tematskimi kartami.

V naslednjem koraku neznano regijo primerjamo z vsemi referenčnimi regijami, t.j. primerjamo empirično porazdelitveno funkcijo neznane regije z porazdelitvenimi funkcijami vseh referenčnih rab, za vsaj kanal posebej, ob tem pa določimo tudi vrednost statistike D . Neznana regija je v posameznem kanalu razvrščena v razred z najmanjšo vrednostjo statistike. Za vsak par porazdelitvenih funkcij v programskem okolju Matlab s stopnjo zaupanja 95 % določimo tudi vrednost h , ki lahko zavzame vrednost 0 ali 1. Če je vrednost 1, ničelno hipotezo zavrnemo, sicer je ne zavrnemo.

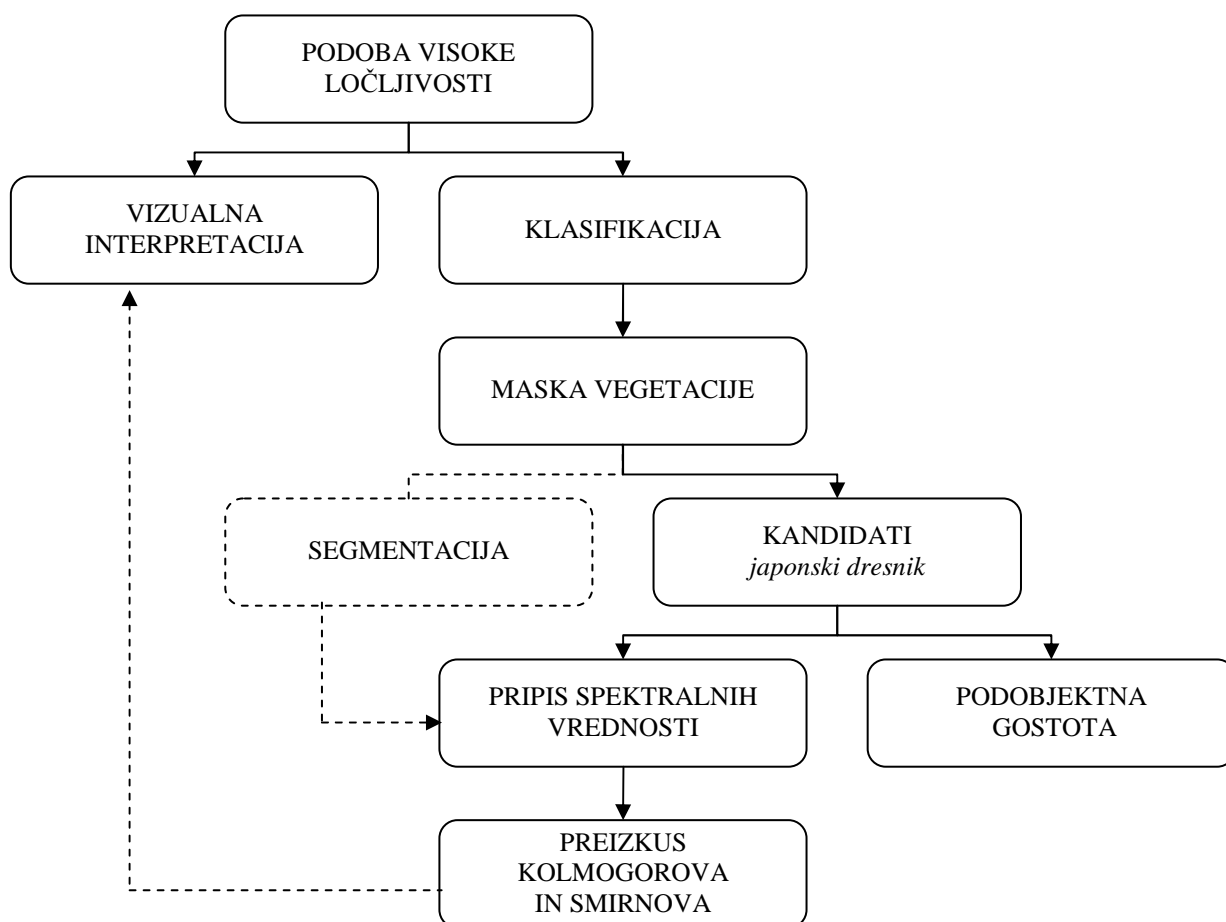
Preizkus Kolmogorova in Smirnova je podoben tradicionalni nadzorovani klasifikaciji, le da tu klasifikacija poteka na ravni segmenta (objekta), hkrati pa upoštevamo značilen vzorec porazdelitve vseh pikslov znotraj segmenta.

3.2.3 Potek zaznavanja japonskega dresnika

Potek zaznavanja japonskega dresnika prikazujemo na sliki 29. Izhodišče vizualne interpretacije in klasifikacije predstavlja podoba visoke ločljivosti. Na prvi ravni pred postopki obdelave vhodnih podatkov vizualno analiziramo vse slikovne vire, opisane v poglavju 3.1. Prepoznavanje območij pojavljanja japonskega dresnika na podobah omogočajo referenčni terenski podatki.

V postopku klasifikacije uporabimo bližnje infrardeči ortofoto DOF100 IR s prostorsko ločljivostjo 1 m ter multispektralni satelitski posnetek WorldView-2, ki smo ga z uporabo pankromatskega posnetka izostrili na ločljivost 0,5 m. Na prvi ravni klasifikacije z uporabo vegetacijskih indeksov izdelamo masko vegetacije, t.j. izločimo vse antropogene in vodne površine. Nato s pomočjo maske definiramo kandidate japonskega dresnika z uporabo atributov v postopku klasifikacije s pravili. Predpostavljamo, da vsi objekti sloja s kandidati japonskega dresnika niso japonski dresnik. Objekte omenjenega sloja v izbrane razrede razvrstimo z uporabo kriterija podobne gostote in preizkusa Kolmogorova in Smirnova.

Metodologija je zasnovana tako, da lahko objekte za preizkus Kolmogorova in Smirnova zagotovimo tudi s segmentacijo sloja maske vegetacije. Tak način klasifikacije je ob nezadostni stopnji samodejnosti algoritma za klasifikacijo s preizkusom Kolmogorova in Smirnova dolgotrajen.



Slika 29: Diagram poteka zaznavanja japonskega dresnika.

3.2.3.1 Predstavitev izbranih postopkov za klasifikacijo japonskega dresnika

Vizualna interpretacija

Vpogled v obsežnost pojavljanja japonskega dresnika omogočijo referenčni poligoni območij nahajanja.

Izdelava maske vegetacije

Za izdelavo maske vegetacije na ortofoto posnetkih uporabimo t.i. modificiran vegetacijski indeks. Ker bližnje infrardeč ortofoto (DOF100 IR) ne vsebuje izvornega rdečega in infrardečega kanala, v izrazu za normalizirani vegetacijski indeks (4), kot kanal R uporabimo zeleni sloj, kot kanal IR pa rdeči sloj, oba z ločljivostjo 1m.

V enačbi (4) ne uporabimo klasičnih kanalov za izračun NDVI (rdeči in bližnji infrardeč kanal), zato govorimo o modificiranem vegetacijskem indeksu NDVI (Grigillo, 2010). Ta lahko zavzame vrednosti na intervalu med -1 in 1 .

Masko vegetacije na satelitskih posnetkih izdelamo z uporabo Red-Edge NDVI.


Izločanje kandidatov japonskega dresnika

Kandidate določimo z uporabo definiranja pravil.

Uporaba kriterija podobjektivne gostote

Podobjektivno gostoto definiramo kot razmerje med celotno površino objekta (zunanji obod) in številom segmentov (podobjektov) v objektu (Slika 30). Predstavlja povprečno površino segmenta in podaja mero razdrobljenosti objekta oziroma teksturno značilnost, s čimer lahko med seboj ločimo nekatere vrste rab v prostoru. Največkrat dobro ločimo med obdelovalnimi in antropogenimi površinami ter vegetacijo.

Kriterij podobjektivne gostote uporabimo za nadaljnjo analizo in klasifikacijo kandidatov obravnavanega predmeta. Segmente pridobimo z uporabo najmanjše vrednosti stopnje segmentacije.



Slika 30: Razmerje med objektom in segmentom.

Preizkus Kolmogorova in Smirnova

Postopek preizkusa Kolmogorova in Smirnova je enak zgoraj opisanemu za klasifikacijo drevesnih vrst v podglavju 3.2.2. Predhodno segmentom pripišemo vrednosti pikselov v posameznih kanalih. Izbiro referenčnih rab za zaznavanje japonskega dresnika pogojuje izbrano študijsko območje.

3.3 Uporabljeni programska oprema

ENVI 4.7

Uporaba: Ostrenje multispektralnih podob, izdelava mask, pripisovanje vrednosti pikslov kanalov objektom (angl. region of interest, ROI).

ENVI Zoom, modul Feature Extraction

Uporaba: Segmentacija in objektno usmerjena klasifikacija (klasifikacija s pravili in nadzorovana klasifikacija).

ESRI ArcGIS 9.3(ArcMap, ArcScene)

Uporaba: Inverzna razvodna segmentacija digitalnega modela krošenj (iskanje vrhov), izračun podobjektne gostote, urejanje podatkov, kartiranje rezultatov, trirazsežni prikaz digitalnega modela krošenj.

Matlab 7.6.0 (R2008a)

Uporaba: Klasifikacija z uporabo preizkusa Kolmogorova in Smirnova.

4 PRAKTIČNA IZVEDBA NALOGE

V poglavju navedem opis testnih območij ter predstavim rezultate praktičnega dela diplomske naloge, na osnovi katerih v nadaljevanju ovrednotim metodologijo za klasifikacijo drevesnih vrst in japonskega dresnika.

4.1 Študijska območja

Metodologijo klasifikacije drevesnih vrst in japonskega dresnika preizkusimo na izbranih območjih Mestne občine Ljubljana.


4.1.1 Študijsko območje za drevesne vrste

Izbrano študijsko območje za klasifikacijo drevesnih vrst je park Tivoli (Slika 31). Približno 5 km² velik park leži v ravninskem delu zahodno od strnjenegega mestnega jedra, pod gozdnimi pobočji Rožnika in Šišenskega hriba (Uradni slovenski turistični informacijski portal, 2011). Park Tivoli je bil po načrtih francoskega inženirja Blancharda oblikovan leta 1813, kasneje, med leti 1921 in 1939 pa je bil delno preurejen po Plečnikovih načrtih. Danes je prepleten s številnimi sprehajalnimi potmi, poseben pečat pa mu daje bogata drevesna dediščina (Slika 32). Po podatkih katastra dreves v parku zasledimo skoraj 90 različnih drevesnih vrst in več kot 2200⁹ dreves. Glavno strukturo parka definira več kostanjevih drevoredov.

⁹ V popisu niso bila zajeta vsa drevesa, zato podatek iz katastra ne podaja realne ocene števila dreves v parku.



Slika 31: Park Tivoli. (Vir: Slovenija v presežnikih)




Slika 32: Študijsko območje za drevesne vrste, prikazano z različnimi viri podatkov. V prvi vrsti (od leve proti desni): satelitski posnetek WorldView-2 in posnetek ortofoto DOF050 2011, v drugi vrsti (od leve proti desni): sloj katastra dreves na DOF050 2011 in digitalni model krošenj.

4.1.2 Študijsko območje za japonski dresnik

Postopke zaznavanja japonskega dresnika, opisane v poglavju 3.2.3.1, smo preizkusili na listih ortofota z oznakami E2446 in E2303 ter na satelitskem posnetku WorldView-2, ki delno prekriva list ortofota E2303 (Slika 33). Območje satelitskega posnetka predstavimo z robnimi koordinatami v državnem koordinatnem sistemu: Y: 458594.608 – 462594.608 m in X : 98341.978 – 100341.978 m.

Na obravnavanih testnih območjih je stopnja pojavljanja japonskega dresnika velika, na voljo pa so tudi podatki terenskih ogledov iz različnih časovnih obdobj.



Slika 33: Prekrivanje satelitskega posnetka in lista ortofota z oznako E2303.

4.2 Preizkus postopkov in rezultati

Postopke, ki so teoretično opisani v poglavju 3.2, in njihovo zaporedje izvedbe, ki je bilo predlagano v obliki načrtovane metodologije, preizkusim z uporabo testnih podatkov na študijskem območju, opisanem v podpoglavju 4.1. Podajanje rezultatov v tem podpoglavju sledi shemi postopka iz poglavja 3.2. Najprej navedem rezultate klasifikacije drevesnih vrst, nato pa japonskega dresnika.

4.2.1 Klasifikacija drevesnih vrst

Vizualna interpretacija

Različne drevesne vrste med seboj najbolj razločimo na posnetku ortofoto DOF050 2011 (Slika 34). Raznolikost vrst, ki jo zazna človeško oko s pomočjo vizualne interpretacije, nakazuje na možnost razlikovanja v spektralnem prostoru.




Slika 34: Različne drevesne vrste na posnetku ortofoto z oznako E2443 (DOF050 2011). V prvi vrsti (od leve proti desni): rdeča bukev, javorolistna platana, lipa. V drugi vrsti (od leve proti desni): navadna smreka, rdeči ostrolistni javor in pokopališka pobešava vrba.

Izdelava maske vegetacije

Empirično izbrana vrednost indeksa Red-Edge NDVI za izdelavo maske vegetacije znaša 0,361. Vsi segmenti z vrednostjo, ki je večja od izbrane empirične vrednosti indeksa, predstavljajo vegetacijo.

Maska (Slika 35c) vsebuje območja z vrednostjo 0 (črna barva, celice brez podatka) in vrednostjo 1 (bela barva, celice s podatkom). Slednja vključujejo le tista območja, kjer je verjetno, da se nahaja vegetacija.



Slika 35: Izdelava maske vegetacije na satelitskem posnetku WorldView-2. Na sliki so predstavljeni: kompozit v lažni podobi (a), Red-Edge NDVI (b), maska (c).

V preglednici 5 navedem vrednosti izbranih parametrov objektno usmerjene klasifikacije, atribut ter pravilo za izdelavo maske vegetacije.

Preglednica 5: Vrednosti parametrov objektno usmerjene klasifikacije (stopnja segmentacije, parameter združitve), izbran atribut in pravilo za izdelavo maske vegetacije v programskem modulu ENVI Feature Extraction.

	WorldView-2
Stopnja segmentacije	38
Parameter združitve	52
Atribut	Red-Edge NDVI
Pravilo	atribut > 0,361

Izločanje drevesnih krošenj, trave in senc


Drevesne krošnje, travo in sence v tem koraku izločam le iz območja, ki je definiran z masko. Pri definiranju kandidatov drevesnih krošenj, ki so glavni predmet obravnave, je izločanje območij s travo (vrzeli med krošnjami) in senc nujno. V nasprotnem primeru lahko sicer znatno poslabšajo rezultate klasifikacije. Problem je posebej izrazit pri sencah, ki so posledica značilnosti kota snemanja.

Vektorski sloj drevesnih krošenj (Slika 36) sem pridobila posredno, t.j. z aritmetično operacijo odštevanja, kjer sem od sloja vegetacije odštela sloj trave in senc. Sloj senc in trave sem definirala z uporabo pravil na pankromatskem posnetku. Sence imajo na tem posnetku izrazito nizke vrednosti pikslov, kar omogoča enostavno izločanje, trava pa ima, v primerjavi s sencami, poleg različnih spektralnih lastnosti tudi drugačno teksturo. Tekstura je značilna razporeditev in frekvenčno spreminjanje sivih tonov na podobi (Oštir, 2006). Poskus klasifikacije senc in trave na multispektralnem posnetku, tako z definiranjem pravil kot nadzorovano klasifikacijo, je bil neuspešen.

Uporabljene vrednosti parametrov objektno usmerjene klasifikacije, izbrane attribute in pravila za izločanje senc in trave podajam v preglednici 6.

Preglednica 6: Vrednosti parametrov objektno usmerjene klasifikacije (stopnja segmentacije, parameter združitve), izbrani atributi in pravila za izločanje senc in trave na pankromatskem satelitskem posnetku v programskem modulu ENVI Feature Extraction.

	Sence	Trava
Stopnja segmentacije	39	39
Parameter združitve	73	73
Atribut	srednja vrednost pikslov pankromatskega kanala (atribut 1)	srednja vrednost pikslov pankromatskega kanala (atribut 1), entropija (atribut 2)
Pravilo	atribut 1 < 172,9	atribut 1 ∈ [302.1, 375.0] ali atribut 2 ∈ [0.1871, 0.1872]

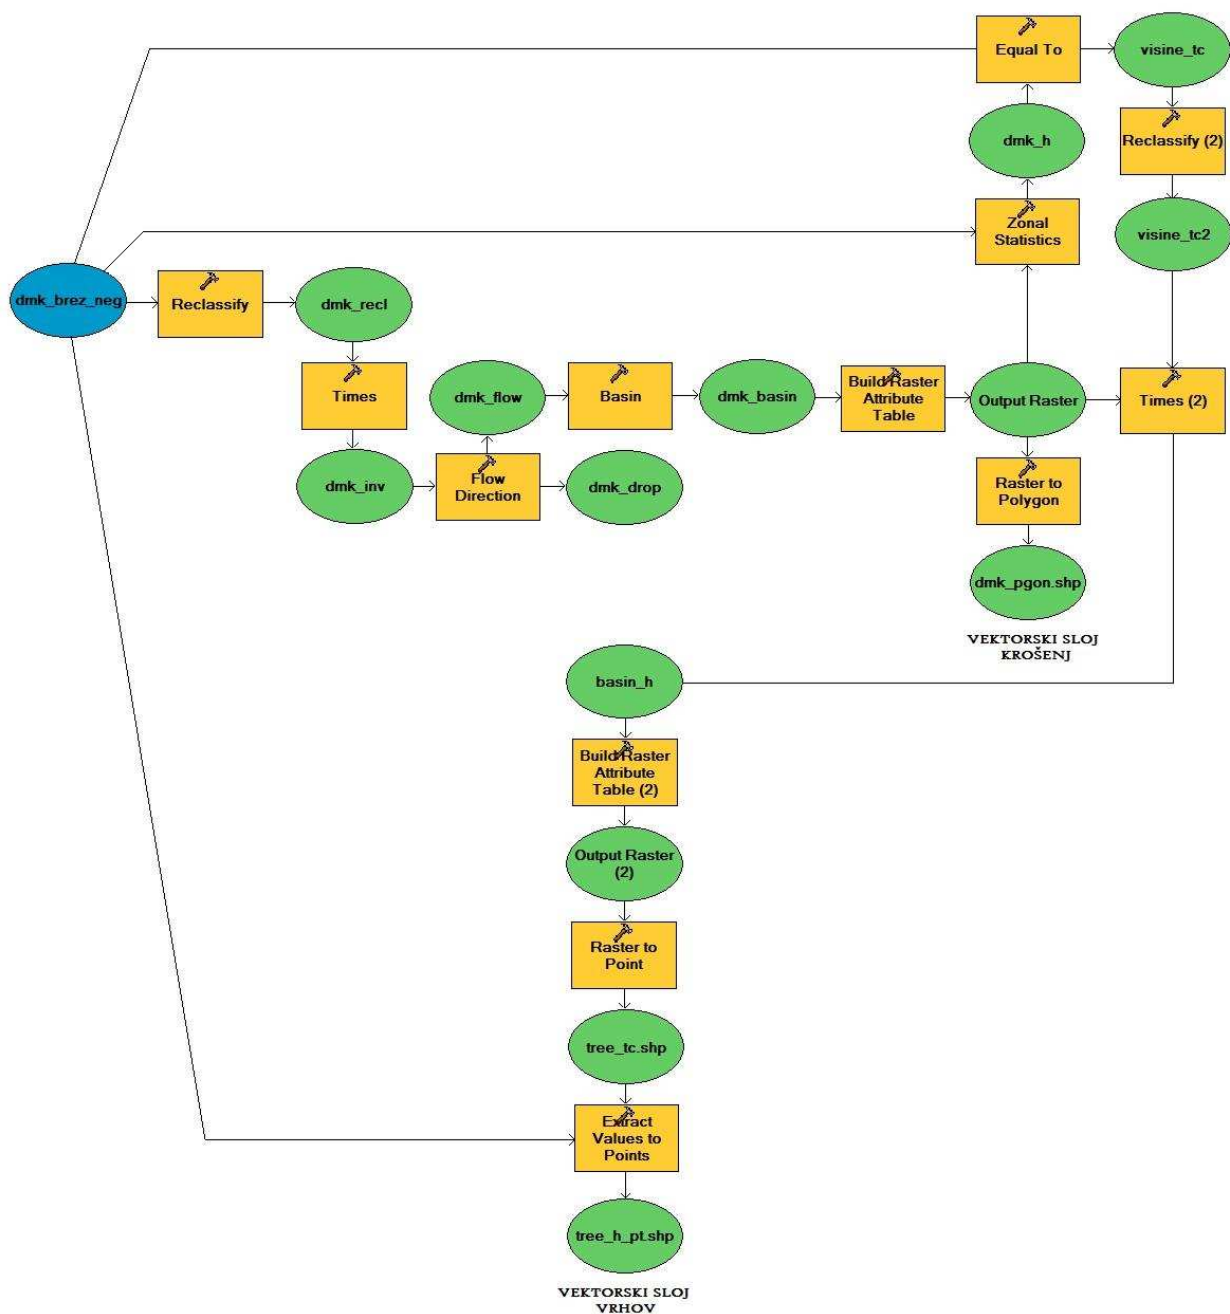


Slika 36: Sloj drevesnih krošenj, predstavljen s poligoni v svetlo zeleni barvi.

Dobljeni sloj drevesnih krošenj ne zagotavlja popolne pokritosti s krošnjami na satelitskem posnetku, zato ocenim, da je neustrezno izhodišče za pridobivanje segmentov za nadaljnjo analizo. Menim, da je sloj lahko ustrezna prostorska komponenta urbanističnega načrtovanja, saj nazorno pokaže, kolikšen je odstotek drevnine v urbanem okolju. V naslednjih korakih segmente definiram z uporabo digitalnega modela krošenj.

Iskanje vrhov dreves na digitalnem modelu krošenj

Diagram poteka inverzne razvodne segmentacije je prikazan na sliki 37.



Slika 37: Diagram poteka inverzne razvodne segmentacije, izdelan v programskem okolju ArcMap.

Končni rezultat inverzne razvodne segmentacije predstavljata vektorska sloja porečij krošenj (poligoni) in vrhov (točke) (Slika 38). Vsakemu porečju krošnje značilno pripada le ena točka, ki je definirana kot lokalno najvišji piksel posameznega porečja. Porečje v tej fazi največkrat še ne definira drevesne krošnje. Ob pregledu sloja vrhov je potrebno upoštevati dejstvo, da na odprtih površinah digitalni model krošenj prikazuje tudi točke na tleh, kjer se je zgodil prvi in edini odboj. Te točke imajo na sloju digitalnega modela krošenj višino približno 0 m. Številčnost teh točk je posledica razgibanosti mikroreliefa.



Slika 38: Izhodna sloja postopka inverzne razvodne segmentacije. Rdeče pike ponazarjajo vrhove, črne črte pa razvodja, t.j. meje med porečji.

V diplomski nalogi obravnavam točke, ki so posledica odboja na drevesnih krošnjah. Te iz sloja vrhov izločim tako, da izberem zgolj tiste točke, katerih višina presega empirično izbrano vrednost 2 m (Slika 39).



Slika 39: Sloj točk vrhov z višino nad 2 m.

Sloj točk vrhov z višino nad 2 m v nadaljevanju primerjam z referenčnim slojem katastra dreves. Vizualna interpretacija razkrije sledeče (Slika 40):

- Odstotek ujemanja referenčnih podatkov s slojem vrhov je za srednje velika posamična drevesa (drevesa, ki niso v skupini) visok.
- Pri listavcih, ki imajo zaobljene krošnje, ter drevesih z velikimi krošnjami vrh navadno ni enolično določen. Temu ustreza tudi večje število točk, t.j. kandidatov vrhov, zaznanih s postopkom inverzne razvodne segmentacije.
- Verjetnost, da laserski žarek zadane vrh iglavca, je majhna.
- Problem določitve vrhov je izrazit za drevesa v skupini, kjer se krošnje različnih drevesnih vrst lahko prekrivajo. Tudi v takšnih primerih značilno dobimo več kandidatov za vrhove, predvsem pa prekrivanje krošenj otežuje definiranje segmentov.
- Točke na referenčnem sloju niso vedno položajno ustrezne t.j. točka ne sovpa s položajem krošnje na slikovnem viru (DOF050 2006, 2011). Ob tem poudarimo, da ni znano, kateri slikovni vir je bil uporabljen za vnos rezultatov popisa dreves, prav tako ni podatkov o tem, ali so bili rezultati popisa geolocirani že ob terenskem delu (uporaba meritev GPS). Položajna neustreznost je največkrat značilna za drevesa v skupini.
- V popis niso bila vključena vsa drevesa.



Slika 40: Značilnosti iskanja vrhov. Levo zgoraj: visok odstotek ujemanja med referenčnimi podatki (modre pike) in slojem vrhov (oranžne pike) za posamična drevesa z velikimi krošnjami. Desno zgoraj: večje število zaznanih vrhov, značilno za listavce. Levo spodaj: položajna neustreznost referenčnih podatkov. Desno spodaj: drevesa v skupini.

V naslednjem koraku okoli točk referenčnega sloja izdelam pas (angl. buffer) (Slika 41). Predpostavljam, da se znotraj ali v bližini izbranega polmera iskanja, glede na posamezno krošnjo oziroma referenčno točko, nahaja vsaj ena točka, zaznana s postopkom inverzne razvodne segmentacije. Preizkusila sem različne polmere iskanja, kot najbolj primerne za študijsko območje pa sem izbrala polmer z vrednostjo 3 m. Površina, ki ustreza krogu s polmerom 3 m, znaša približno 28 m^2 . Krošnje velikih dreves so znatno večje.



Slika 41: Izdelava pasov s polmerom iskanja 3 m.

Segmentacija sloja digitalnega modela krošenj

V postopku segmentacije znaša vrednost parametra segmentacije 49, parameter združevanja pa 44. Segmentom izračunamo attribute ter jih izvozimo v vektorski sloj poligonov (Slika 42).




Slika 42: Rezultat segmentacije digitalnega modela krošenj.

Nadaljnje urejanje sloja segmentov omogoči védenje o položaju vrhov. S segmentacijo sem namenoma ustvarila več segmentov od nujno potrebnih za enolično določitev drevesne krošnje, preveč razdrobljene segmente lahko namreč po potrebi združimo.

Ko urejen sloj segmentov prekrijem čez satelitski posnetek, ugotovim, da sloja ne sovpadata povsem (Slika 43). Razlog za to je kot snemanja satelita, ki podatke o površju zajema v skoraj polarni tirnici (torej ne v zenitu), zaradi česar se objekti nad tlemi zdijo zvrnjeni. Nagnjenost krošenj bi lahko odpravili s postopkom ortorektifikacije satelitskega posnetka, s čimer bi zagotovili, da bi bila vsaka točka na posnetku videti, kot bi jo gledali iz položaja, ki je točno nad njo oziroma pravokotno na Zemljo (Kokalj, 2010).

Sloj segmentov ročno premaknem, tako da ustreza stanju na satelitskem posnetku. Premik je pomemben za kasnejši korak pripisovanja spektralnih vrednosti segmentom, nasprotno bi se segmentom pripisale napačne vrednosti, to pa bi zmanjšalo natančnost klasifikacije. Za določanje velikosti premika si lahko pomagamo s slojem senc, ki smo ga pridobili v začetnih fazah klasifikacije.



Slika 43: Satelitski posnetek in sloj segmentov ne sovpadata.

Pripisovanje spektralnih vrednosti segmentom (objektom)

Rezultat pripisovanja spektralnih vrednosti segmentom predstavlja tekstovna datoteka, izsek te je prikazan na sliki 44.

ID	X	Y	Map X	Map Y	Lat	Lon	B1	B2	B3	B4	B5	B6	B7	B8
1	565	2438	458876.61	99123.48	46.035341	14.468668	359	214	280	369	312	525	599	630
2	566	2438	458877.11	99123.48	46.035341	14.468675	358	213	279	367	310	522	596	628
3	564	2438	458876.11	99123.48	46.035341	14.468662	358	212	275	367	309	525	615	637
4	565	2439	458876.61	99122.98	46.035336	14.468668	360	215	282	372	314	527	601	632
5	566	2439	458877.11	99122.98	46.035336	14.468675	359	214	280	368	311	523	597	629
6	567	2439	458877.61	99122.98	46.035336	14.468681	359	214	280	368	311	523	597	629
7	568	2439	458878.11	99122.98	46.035336	14.468688	362	217	285	375	316	531	604	635
8	569	2439	458878.61	99122.98	46.035336	14.468694	365	221	294	382	314	534	585	643
9	570	2439	458879.11	99122.98	46.035336	14.468700	366	222	295	383	315	535	586	644
10	565	2440	458876.61	99122.48	46.035332	14.468668	361	216	283	373	315	528	602	633
11	566	2440	458877.11	99122.48	46.035332	14.468675	359	214	280	368	311	523	597	629
12	567	2440	458877.61	99122.48	46.035332	14.468681	358	213	279	367	310	522	596	628
13	568	2440	458878.11	99122.48	46.035332	14.468688	358	213	277	365	308	520	594	626
14	569	2440	458878.61	99122.48	46.035332	14.468694	363	219	290	376	310	528	579	638

Slika 44: Izsek izhodne datoteke postopka pripisovanja vrednosti segmentom.

Preizkus Kolmogorova in Smirnova

Za klasifikacijo drevesnih vrst s preizkusom Kolmogorova in Smirnova sem izmed vseh vrst, ki se nahajajo v parku Tivoli, izbrala 10 referenčnih drevesnih vrst (Preglednica 7). Devet drevesnih vrst uvrščamo med listavce, eno pa med iglavce.

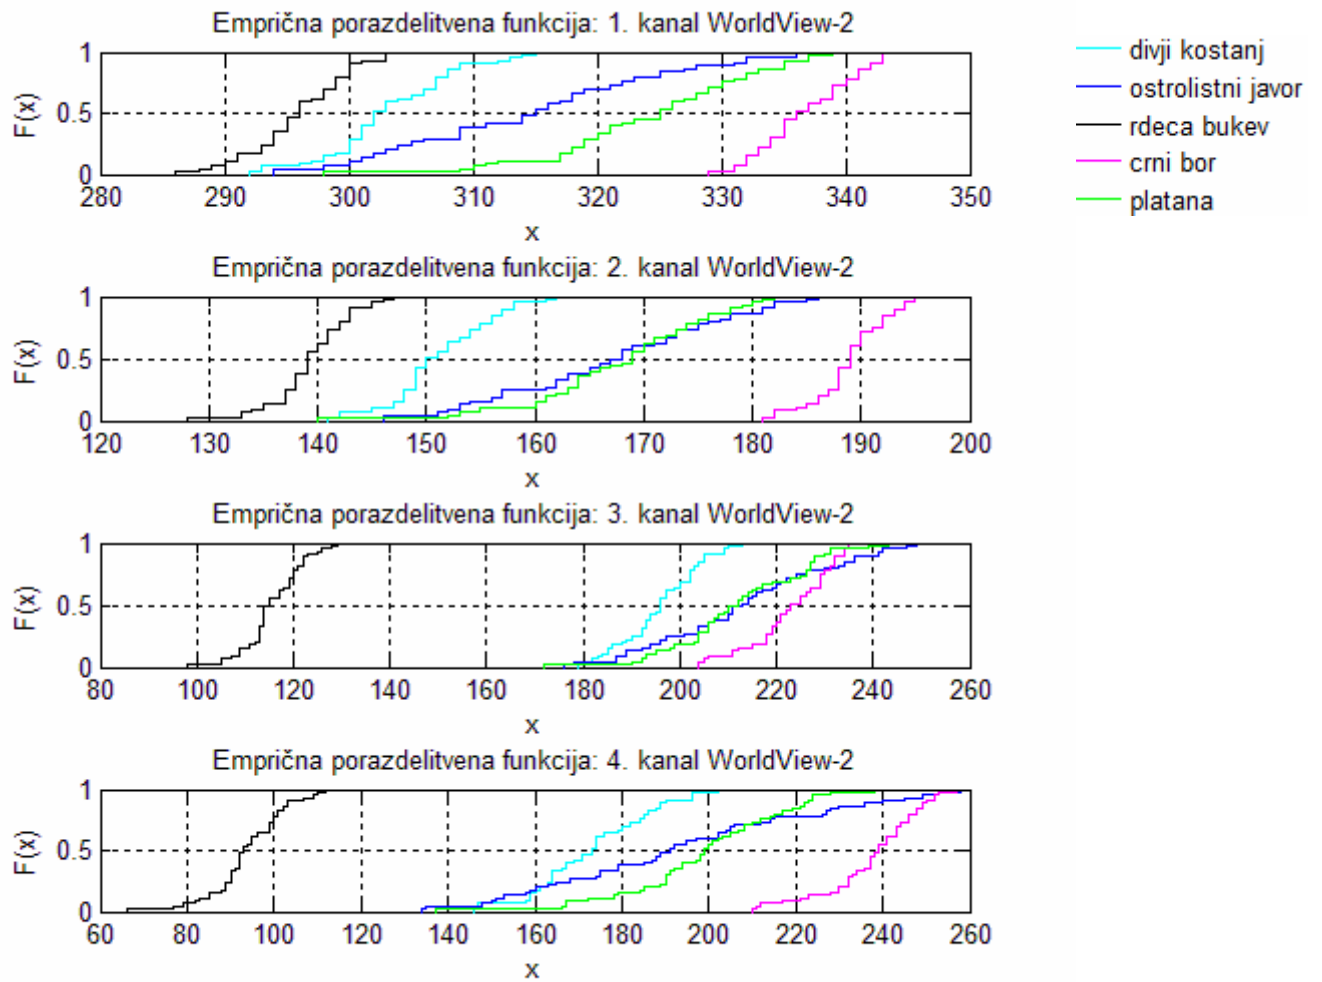
Preglednica 7: Drevesne vrste, uporabljene za preizkus Kolmogorova in Smirnova.

	Slovensko ime drevesne vrste	Znanstveno ime drevesne vrste	Število dreves v parku Tivoli*
1.	Divji kostanj	<i>Aesculus hippocastanum</i>	482
2.	Ostrolistni javor	<i>Acer platanoides</i>	269
3.	Črni bor	<i>Pinus nigra</i>	134
4.	Lipa	<i>Tilia sp.</i>	99
5.	Javorolistna platana	<i>Platanus x hispanica</i>	75
6.	Rdeči hrast	<i>Quercus rubra</i>	63
7.	Ostrolistni rdeči javor	<i>Acer platanoides atropurpureum</i>	12
8.	Pokopališka pobešava vrba	<i>Salix sepulcralis</i>	12
9.	Vrba žalujska	<i>Salix babilonica</i>	9
10.	Rdeča bukev	<i>Fagus sylvatica f. purpurea</i>	7

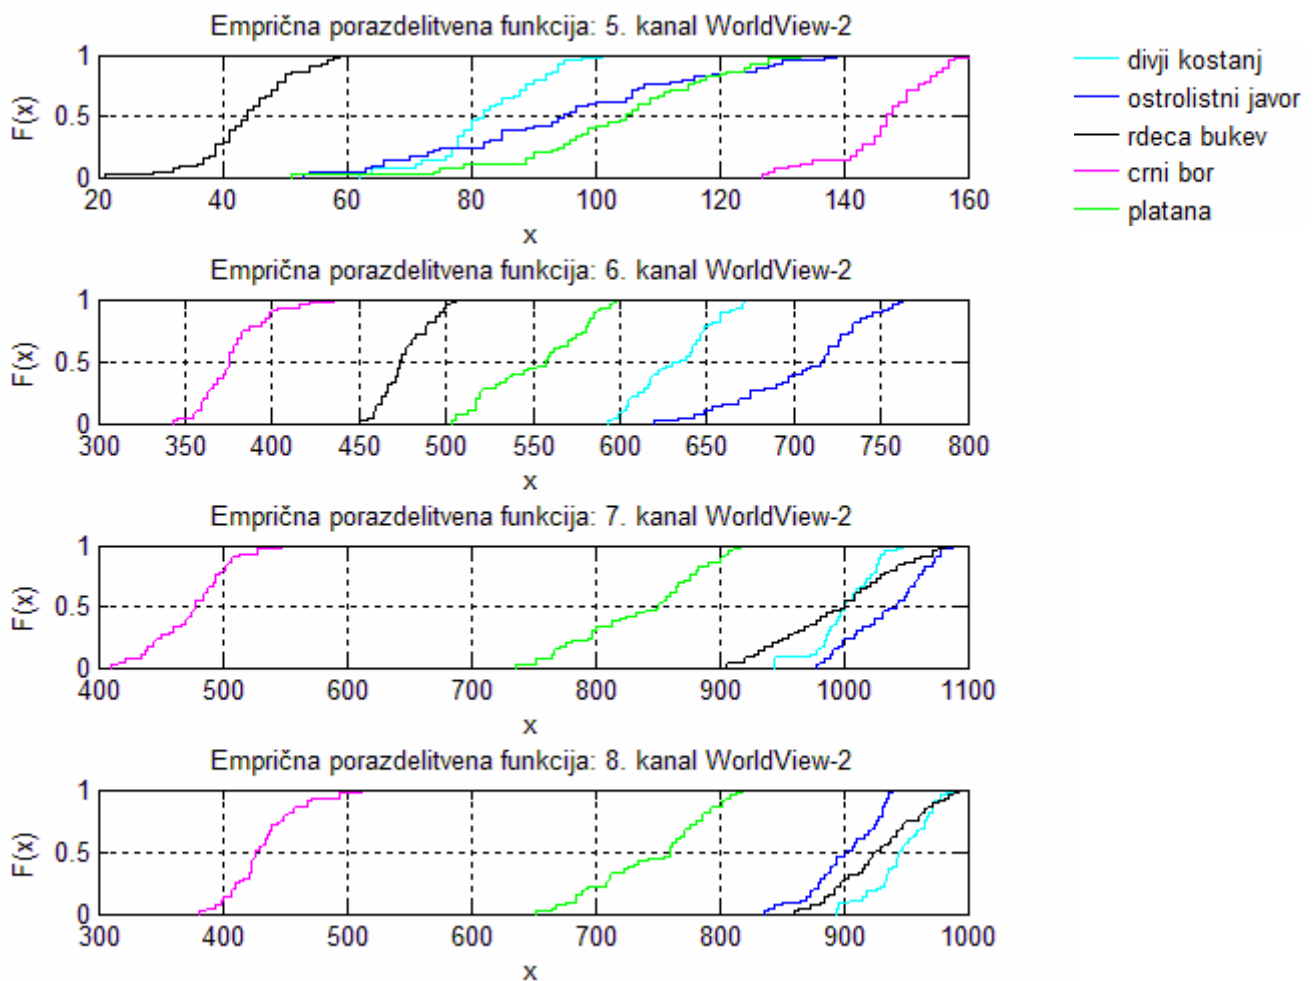
* Podatki so povzeti po bazi katastra dreves

Ker lasten program v programskem okolju Matlab za klasifikacijo s preizkusom Kolmogorova in Smirnova ne zagotavlja visoke stopnje samodejnosti, sem klasifikacijo izvedla na naslednji način:

1. *Izbira učnega vzorca*: Za vsako izmed zgoraj navedenih drevesnih vrst sem najprej definirala referenčni učni vzorec. Pazila sem, da vzorec ne vsebuje premalo pikslov, t.j. ne manj kot 100, prav tako pa je za vsako drevesno vrsto pomembno izbrati piksele v čim večjem delu krošnje.
2. *Izbira neznanega objekta (regije)*: Izbira neznanega objekta je bila nadzorovana, to pomeni, da sem za klasifikacijo izbirala zgolj tiste segmente, ki smo jih v prejšnjih korakih jasno definirali s postopki zaznavanja vrhov in združevanjem segmentov, prav tako pa sem za te segmente vedela, katero drevesno vrsto predstavljajo (podatek iz katastra dreves). V tem primeru govorimo torej o pogojno neznanih segmentih. Za vsako drevesno vrsto sem izbrala najmanj 5 oziroma največ 13 neznanih objektov. Program omogoča klasifikacijo le enega objekta naenkrat, zato je postopek klasifikacije razmeroma dolgotrajen. Objektov z rabo rdeči hrast in pokopališka pobešava vrba nismo razvrščali v razrede, prav tako pa v klasifikacijo nismo vključili krošenj majhnih dreves. V razrede smo razvrstili 75 objektov.
3. *Klasifikacija*: Porazdelitvena funkcija neznanega objekta se primerja s porazdelitvenimi funkcijami vseh rab v vsakem kanalu. Neznana regija je v posameznem kanalu razvrščena v razred z najmanjšo vrednostjo statistike D . Ob vsakokratni klasifikaciji neznanega objekta sem porazdelitvene funkcije neznanega objekta in referenčnih vzorcev grafično predstavila. Ugotovila sem, da je razlikovanje med drevesnimi vrstami najbolj učinkovito in zanesljivo v 6. kanalu, t.j. Red Edge kanalu, do napak pri klasifikaciji pa je najpogosteje prišlo v kanalih vidnega dela spektra (prvih 5 kanalov satelita WorldView-2, preglednica 2). V vidnem delu spektra so namreč razlike v vrednostih pikslov različnih drevesnih vrst izredno majhne, nasprotno pa so velike v 6. kanalu. V infrardečem delu spektra med drugim lahko dobro ločimo iglavce od listavcev. Ugotovitve potrjujeta tudi sliki 45 in 46. Za dokončno razvrščanje objekta v razred sem največjo utež dodelila rezultatu 6. kanala, prav tako pa sem upoštevala rezultate statističnega preizkusa hipotez, t.j. vrednosti h . Rezultate klasifikacije podajamo v podpoglavju 4.3.1.

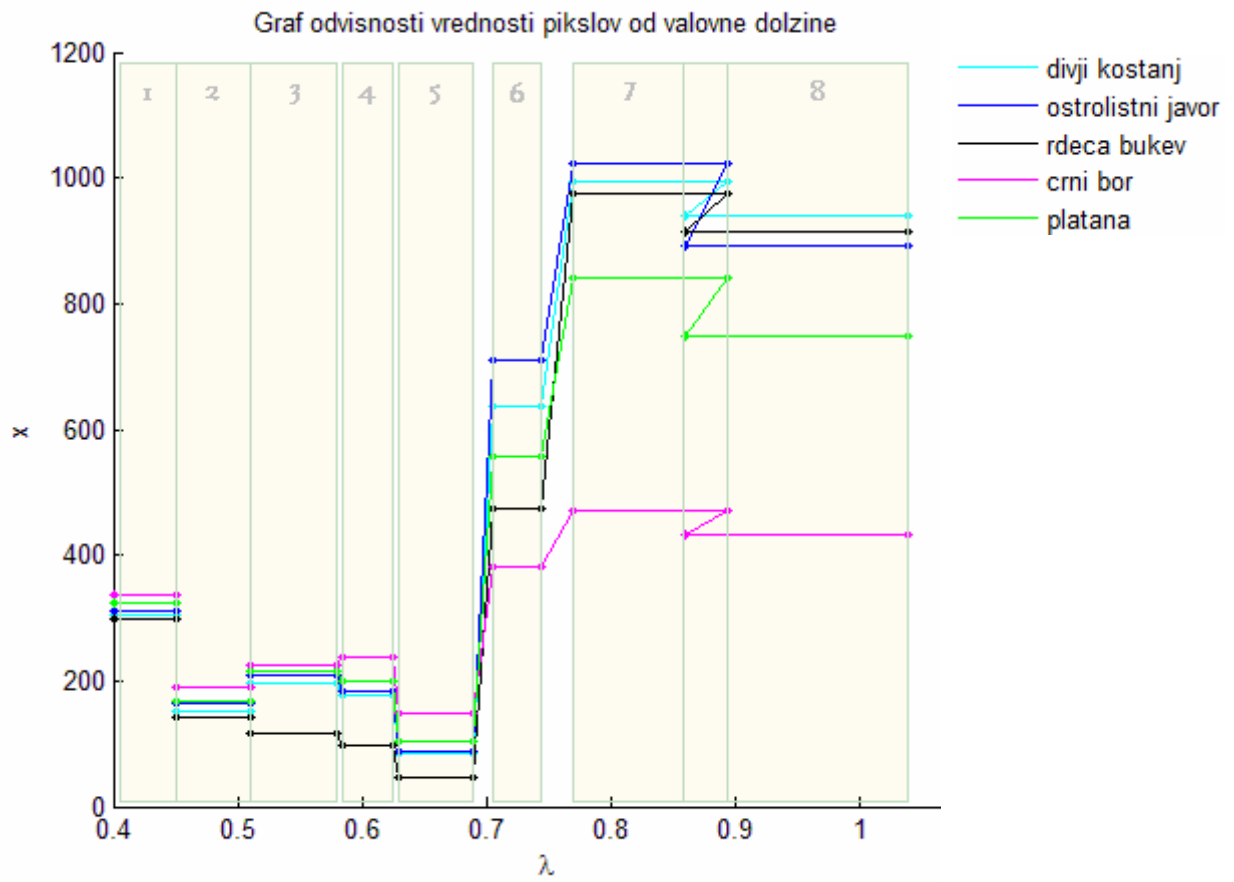


Slika 45: Porazdelitvene funkcije petih drevesnih vrst v prvih štirih kanalih multispektralnega posnetka WorldView-2.



Slika 46: Porazdelitvene funkcije petih drevesnih vrst v zadnjih štirih kanalih multispektralnega posnetka WorldView-2.

Na sliki 47 prikažem vrednosti pikselov petih drevesnih vrst v odvisnosti od valovne dolžine. Porazdelitveno funkcijo segmentov drevesnih vrst v posameznem kanalu sem predstavila s povprečno vrednostjo pikselov.



Slika 47: Prikaz vrednosti pikslov petih drevesnih vrst v odvisnosti od valovne dolžine.

4.2.2 Zaznavanje japonskega dresnika

Vizualna interpretacija

Vizualni pregled slikovnih virov razkrije, da ima japonski dresnik izrazito pojavno obliko in ga je, ob védenju območij obstoja v naravi, razmeroma enostavno ločiti od ostalih najpogostejših rab v prostoru (obdelovalne površine, gozd, drevesa...) (Slika 48).



Slika 48: Značilni tekstura in barva japonskega dresnika. Prva vrsta (od leve proti desni): DOF050 (2006), DOF100 IR (2006), DOF050 (2011). Druga vrsta (od leve proti desni): DOF050 (2006), DOF100 IR (2006), DOF050 (2011), WorldView-2 (2010).

Ob podrobnejši analizi ugotovim, da je japonski dresnik zgolj z vizualno interpretacijo na posnetkih ortofoto težko ločiti od območij z robidovjem, zlato rozgo (Slika 49) in grmičevja. To pomeni, da ne moremo z gotovostjo trditi, da se na izbranem območju (ne) nahaja japonski dresnik. Podobno ugotovim za analizo satelitskih posnetkov.



Slika 49: Sestoj robidovja (domača invazivna vrsta) in zlate rozge (invazivna tujerodna vrsta), potrjen s terenskim ogledom. Od leve proti desni: DOF050 (2006), DOF100 IR (2006), DOF050 (2011).


Obdelava podob, opisana v nadaljevanju, za razliko od vizualne interpretacije omogoča bolj objektivni in definiran pristop določanja vrste rabe, hkrati pa podatke, ki jih nosi podoba, izkorišča na več ravneh.

Pred postopkom klasifikacije z uporabo ortofoto posnetkov je priporočljivo preveriti, ali imata oba posnetka enako razporeditev spektralnih vrednosti (podobnost histogramov oziroma radiometrična enakost). V nasprotnem primeru bi namreč učne vzorce referenčnih rab za preizkus Kolmogorova in Smirnova morali zajeti večkrat, t.j. glede na število spektralno različnih posnetkov.

V nadaljevanju pri posameznem koraku metodologije najprej navedem rezultate klasifikacije za ortofoto posnetke (DOF100 IR), nato pa tudi za satelitski posnetek. Vse korake metodologije in uporabljene vrednosti sem najprej preizkusila na ortofoto posnetku z oznako 2446, nato pa tudi na listu z oznako E2303. Posnetek WorldView-2 sem obravnavala posebej.

Izdelava maske vegetacije

Masko vegetacije na bližnje infrardečem ortofoto posnetku določim z uporabo empirične vrednosti modificiranega NDVI (Slika 50). Izberemo vrednost 0,295.



Slika 50: Izdelava maske vegetacije na posnetkih ortofoto. Na sliki (od leve proti desni) DOF100 IR, NDVI, maska.

Na podoben način izdelam masko na satelitskem posnetku WorldView-2. V preglednici 8 povzemam vrednosti uporabljenih parametrov in atributov objektno usmerjene klasifikacije s pravili za izdelavo maske vegetacije.

Z uporabo maske iz nadaljnjih analiz izključimo vsa območja, ki niso vegetacija. Maska je poleg posnetka vhodni podatek za izločanje kandidatov japonskega dresnika.

Preglednica 8: Vrednosti parametrov objektno usmerjene klasifikacije (stopnja segmentacije, parameter združitve), izbran atribut in pravilo za izdelavo maske vegetacije v programskem modulu ENVI Feature Extraction.

	DOF100 IR	WorldView-2
Stopnja segmentacije	54	54
Parameter združitve	58	58
Atribut	Modificiran NDVI	Red-Edge NDVI
Pravilo	atribut > 0,295	Atribut > 0,36

Izločanje kandidatov japonskega dresnika

Kandidate japonskega dresnika izločimo le na območjih, ki je definiran z uporabo sloja maske vegetacije. Klasifikacija z definiranjem pravil na tej ravni vključuje izbiro ustreznih atributov, ki bodo kar najboljše opisali japonski dresnik in omogočili njegovo izločanje.

V preglednici 9 povzemam vrednosti uporabljenih parametrov in atributov za izločanje kandidatov japonskega dresnika. Vse vrednosti so določene empirično, s poizkušanjem. Stopnjo segmentacije sem vselej izbrala tako, da sem definirala večino območij z japonskim dresnikom, čeprav so bila ob tem območja z drugimi rabami prekomerno segmentirana.

Preglednica 9: Vrednosti parametrov objektno usmerjene klasifikacije (stopnja segmentacije, parameter združitve), izbran atribut in pravilo za izdelavo sloja kandidatov japonskega dresnika v programskem modulu ENVI Feature Extraction.

	DOF100 IR	WorldView-2
Stopnja segmentacije	33	36
Parameter združitve	58	74
Atributi	srednja vrednost pikslov v rdečem (atribut 1) in zelenem kanalu (atribut2), modificiran NDVI (3 atribut)	Red-Edge NDVI (atribut 1), srednja vrednost pikslov v Red-Edge kanalu (atribut 2) in IR2 kanalu (atribut 3)
Pravilo	1. sklop atributov atribut 1 $\in [177, 210]$ in atribut 2 $\in [27, 51]$ 2. sklop atributov* atribut 1 $\in [185, 210]$ in atribut 3 $\in [0.64, 0.67]$	atribut 1 $\in [0.900, 0.984]$, atribut 2 $\in [690, 776]$, atribut 3 $\in [1016, 1172]$

* preverimo le na listu ortofota z oznako E2446

Rezultat klasifikacije so objekti, ki predstavljajo kandidate japonskega dresnika. Z vizualno interpretacijo pridobljenih poligonov glede na vhodni posnetek ugotovim, da se poleg pravilno zaznanega japonskega dresnika na tem sloju nahajajo rabe, ki se v spektralnem prostoru oziroma glede na izbrane vrednosti atributov obnašajo podobno kot japonski dresnik, čeprav to niso (na primer robidovje, zlata rozga, obdelovalne površine (njive, travniki), zelenice v urbanem okolju in grmičevje).

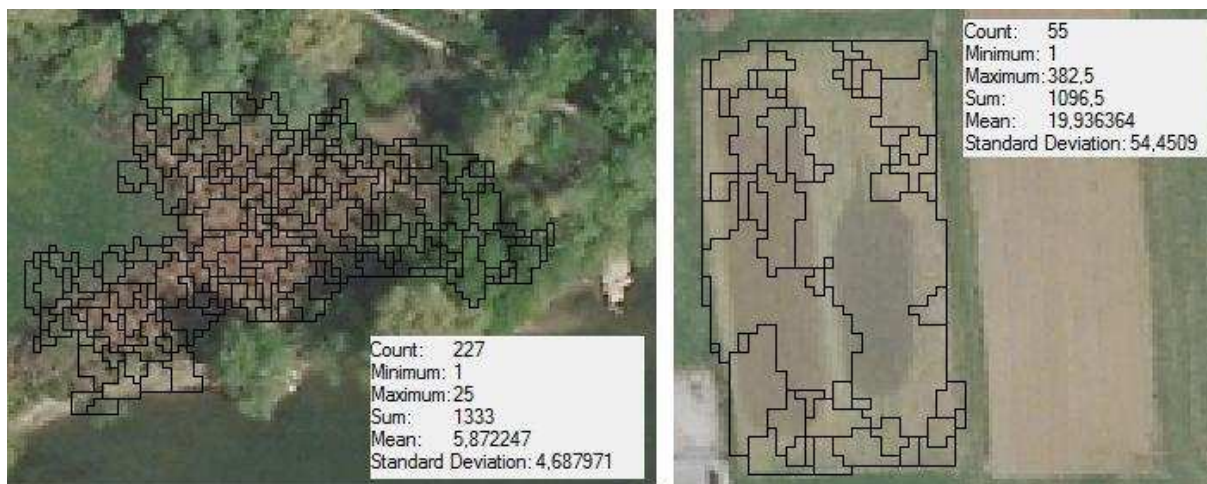
V naslednjem koraku objekte na sloju kandidatov lahko dodatno klasificiramo z uporabo kriterija podobne gostote.

Uporaba kriterija podobne gostote

Vrednost podobne gostote določimo v programskem orodju ArcGIS. Sliki 51 in 52 prikazujeta primer gostote za rabi obdelovalne površine in japonski dresnik na posnetku ortofoto in na satelitskem posnetku, kjer je vrednost gostote podana z izrazom »mean«. Izkaže se, da je pri obdelovalnih površinah vrednost gostote znatno višja kot pri ostalih rabah, ki se pojavijo na sloju kandidatov.

Nadalje ugotovim tudi, da ima večino poligonov japonskega dresnika podobnost vrednosti gostote (empirična vrednost na ortofoto posnetkih je manjša od 7), vendar pa se tej vrednosti močno približa vrednost gostote rab grmičevja in robidovja.

V postopku segmentacije sem za stopnjo segmentacije sloja kandidatov izbrala vrednost 10. Preizkusila smo tudi vrednosti 5 in 20, vendar se velikosti segmentov ob tem ne spremenijo, zato izberem vmesno vrednost. Segmentov ne združujemo, izračunamo jim attribute in jih izvozimo v vektorski sloj.



Slika 51: Podobjektna gostota za rabi japonski dresnik in obdelovalna površina podana z izrazom »mean«, sloj kandidatov je pridobljen z obdelavo posnetka ortofoto z oznako E2446.



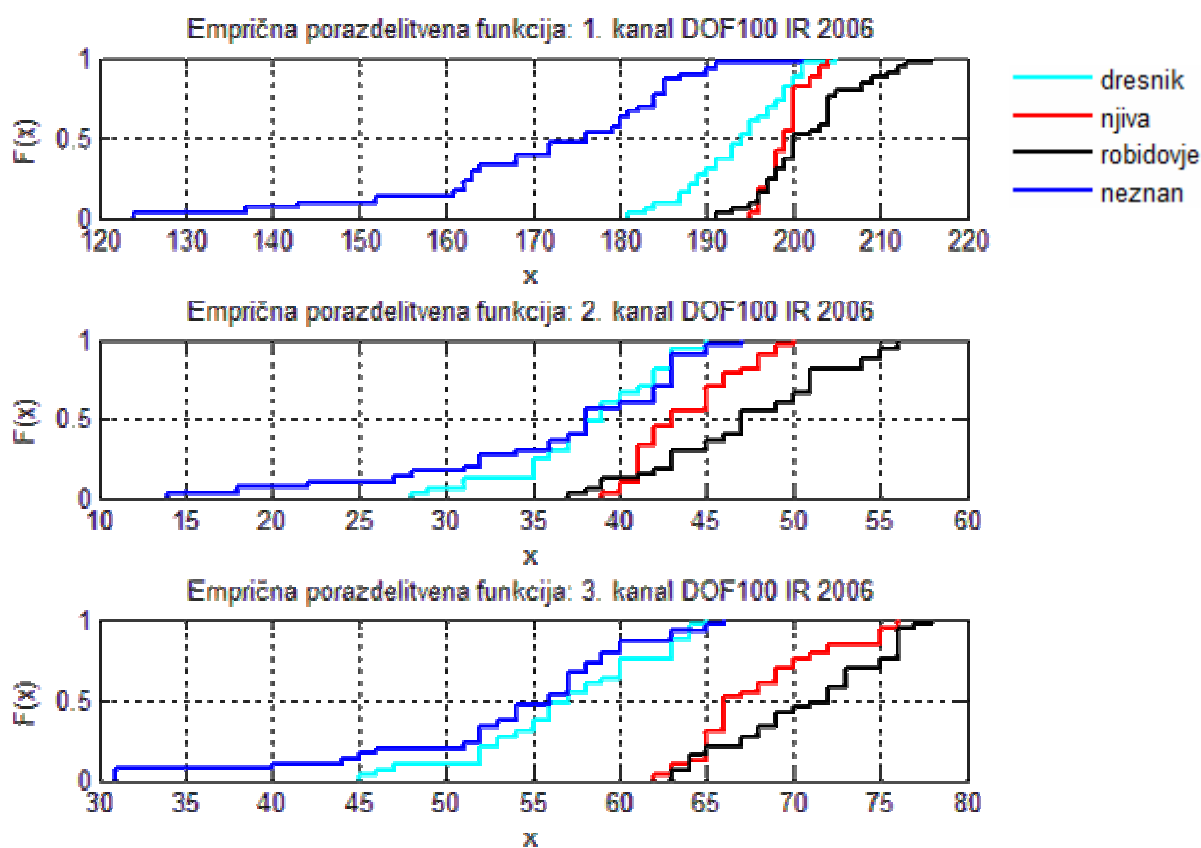
Slika 52: Podobjektna gostota za rabo japonski dresnik podana z izrazom »mean«, sloj kandidatov je pridobljen z obdelavo satelitskega posnetka.

Uporaba kriterija podobjektne gostote je neobvezen korak klasifikacije. Omogoča predvsem odstranjevanje obdelovalnih površin, kar lahko olajša nadaljnjo analizo sloja kandidatov (na primer dodatno klasificiranje objektov s preizkusom Kolmogorova in Smirnova).

Preizkus Kolmogorova in Smirnova

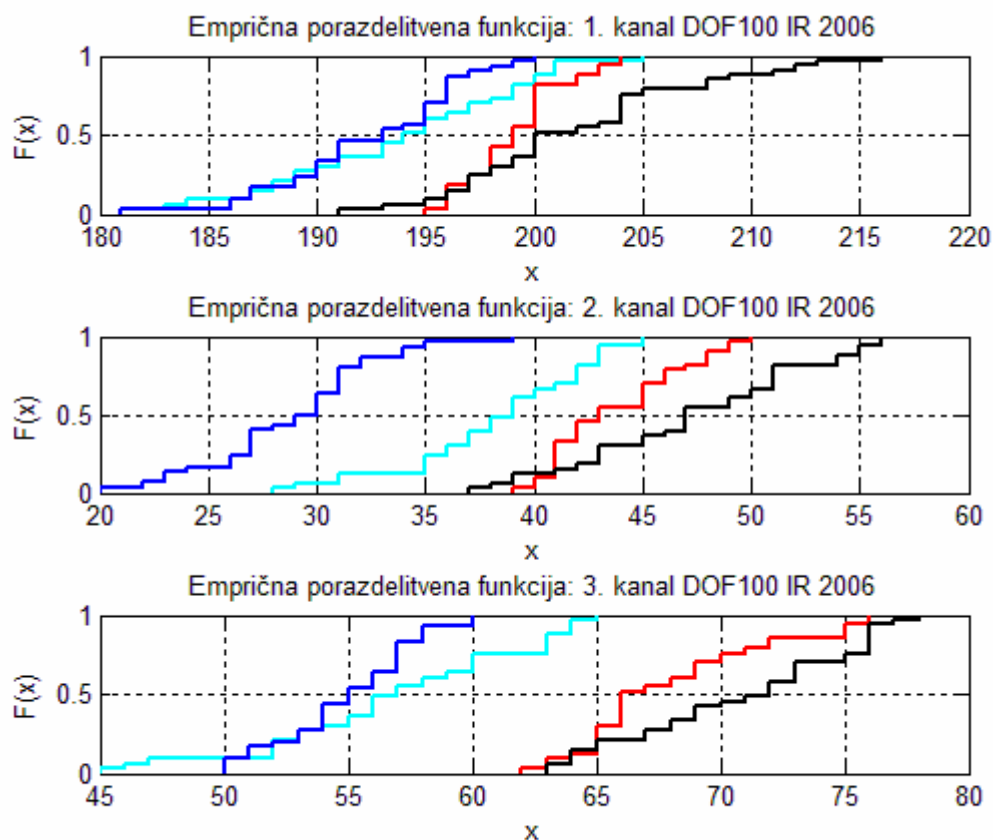
S preizkusom Kolmogorova in Smirnova analiziram območja na listu ortofota z oznako E2446, za katera zagotovo vemo, da je tam prisoten japonski dresnik, vendar ta niso bila del sloja kandidatov. Želim ugotoviti, koliko in katera območja bom s preizkusom klasificirala kot japonski dresnik. Za referenčne rabe izberem japonski dresnik, njivo ter robidovje. Prisotnost rabe na izbranih območjih smo potrdili z referenčnim ogledom. Poligone območij z japonskim dresnikom, ki niso na sloju kandidatov, sem za to analizo zajela ročno.

Slika 53 prikazuje porazdelitveno funkcijo referenčnih rab in objekta, ki v postopku klasifikacije s pravili ni bil klasificiran kot japonski dresnik.



Slika 53: Porazdelitvene funkcije referenčnih rab in neznanega objekta, ki v tem primeru predstavlja območje, ki ni del sloja kandidatov.

Za primerjavo na sliki 54 prikažemo porazdelitvene funkcije referenčnih rab in objekta, ki je del sloja kandidatov (temno modra barva).



Slika 54: Porazdelitvene funkcije referenčnih rab in objekta, ki je del sloja kandidatov.

Preizkusa zaradi nepotrjenih referenčnih rab na terenu nisem uporabila za zaznavanje japonskega dresnika na posnetku ortofota z oznako E2303 kot tudi ne na satelitskem posnetku.

Oceno kakovosti določitve japonskega dresnika na posnetku ortofota E2446 podajam v podpoglavju 4.3.2.

4.3 Ovrednotenje rezultatov

Pri klasifikaciji drevesnih vrst ocenim zgolj končni rezultat klasifikacije t.j. natančnost določitve drevesnih vrst z uporabo preizkusa Kolmogorova in Smirnova. Pri klasifikaciji japonskega dresnika ocenim tako sloj kandidatov kot sloj rezultatov klasifikacije z uporabo preizkusa Kolmogorova in Smirnova.

4.3.1 Ocena kakovosti klasifikacije drevesnih vrst

Rezultate klasifikacije podajam v preglednici 10.

Preglednica 10: Rezultati klasifikacije s preizkusom Kolmogorova in Smirnova.

Drevesna vrsta	Število preizkušenih objektov	Število pravilno klasificiranih objektov	Odstotek pravilnosti [%]
Divji kostanj	13	9	69
Ostrolistni javor	9	7	78
Črni bor	9	8	89
Lipa	13	8	61
Javorolistna platana	12	7	58
Ostrolistni rdeči javor	8	6	75
Vrba žalujka	7	3	43
Rdeča bukev	4	4	100

Rezultati klasifikacije so zadovoljivi. Pri večini drevesnih vrst uspešnost klasifikacije znaša več kot 60 %. Rezultat lahko pripišem primerno pridobljenim segmentom in pa nekoliko idealiziranemu načinu klasifikacije. Vnaprejšnje védenje o drevesni vrsti segmenta operaterju namreč nudi povratno informacijo.

Hkrati se je potrebno zavedati omejitev tovrstnega načina klasifikacije. Do večjih napak prihaja predvsem pri klasifikaciji večjega števila listavcev hkrati, ki so kljub vrstni raznolikosti v infrardečem delu spektra lahko zelo podobni. Ta težava poudarja pomembnost izbire reprezentativnih učnih vzorcev. Vendar pa mnogokrat tudi to ne zagotavlja dobrih rezultatov. Nepravilnost klasifikacije je namreč lahko posledica pojava različne osvetljenosti znotraj drevesne krošnje posamezne drevesne vrste (preosvetljenost na eni ter podosvetljenost na drugi strani krošnje ter sence ostalih dreves na krošnjah) ali pa različnega zdravstvenega stanja posameznega drevesa.

4.3.2 Ocena kakovosti klasifikacije japonskega dresnika

Ocena natančnosti sloja kandidatov japonskega dresnika

Natančnost določitve območij pojavljanja japonskega dresnika na sloju kandidatov sem ocenila z uporabo referenčnih terenskih podatkov. Na lastnem terenskem ogledu sem preverila izbrana dostopna območja na listih ortofota z oznako E2446 in E2303, hkrati pa sem znotraj teh območjih preverjala in beležila območja z japonskim dresnikom, ki niso del sloja kandidatov. Rezultat terenskega sloja je točkovni sloj območij nahajanja japonskega dresnika.

Oceno klasifikacije kandidatov določim z deležem pravilno klasificiranih poligonov glede na območja pojavljanja japonskega dresnika v naravi, prav tako pa določim odstotek nepravilno klasificiranih poligonov. Pri tem posamezne klasificirane poligone na sloju kandidatov tako razvrstim v naslednji dve kategoriji (prirejeno po Grigillo, 2010):

- resnično pozitivni (RP): poligoni, ki jih klasifikacija kot terenski ogled označujeta kot japonski dresnik
- lažno pozitivni (LP): poligoni, ki jih samo klasifikacija označuje kot japonski dresnik

Določimo tudi delež spregledanih območij, t.j. lažno negativnih (LN) poligonov (angl. false negative) japonskega dresnika. To so območja, ki jih zgolj terenski podatki označujejo kot japonski dresnik.

Številčno oceno klasifikacije v nadaljevanju podajam le za list ortofota E2446, za oba sklopa uporabljenih atributov. Razlog za to je v veliki razdrobljenosti poligonov v urbanem območju lista ortofota E2303, tako na sloju kandidatov kot dejansko v naravi. Ker razdrobljenost poligonov ne bi pokazala realne ocene, rezultate klasifikacije za list E2303 zato podajam le v opisni in slikovni obliki.

Na točkovnem sloju območij nahajanja japonskega dresnika je na listu E2446 evidentiranih 105 referenčnih območij. Območje za oceno klasifikacije sloja kandidatov je prikazano na sliki 55. Sloj poligonov sem predhodno generalizirala in sicer sem odstranila vse poligone, manjše od 40 m². Po generalizaciji za oceno natančnosti obravnavam 190 poligonov (Preglednica 11). Seštevek lažno pozitivnih poligonov in referenčnih območij predstavlja vse obravnavane poligone na sloju kandidatov, seštevek resnično pozitivnih in lažno negativnih območij pa vsa referenčna območja. Število resnično pozitivnih, lažno pozitivnih in lažno negativnih območij podajamo v preglednici 12.



Slika 55: Izbrano območje za oceno natančnosti klasifikacije na ortofoto posnetku z oznako E2446. Zeleni poligoni so del sloja kandidatov, rdeče pike pa območja pojavljanja japonskega dresnika, uporabimo 1. sklop atributov.

Preglednica 11: Število referenčnih območij in obravnavanih poligonov na sloju kandidatov japonskega dresnika na območju lista E2446.

	1. sklop atributov	2. sklop atributov
	Število območij	
Vsa referenčna območja	105	105
Vsi obravnavani poligoni	190	/*

* Sloja kandidatov na izbranem območju nismo generalizirali, zato v tej preglednici in v preglednici 12 ne podajamo števila obravnavanih poligonov.

Preglednica 12: Število resnično pozitivnih, lažno pozitivnih in lažno negativnih poligonov na sloju kandidatov japonskega dresnika na listu E2446.

	1. sklop atributov	2. sklop atributov
	Število območij	
Resnično pozitivni*	73	79
Lažno pozitivni**	83	/
Lažno negativni***	32	26

*glede na vsa referenčna območja

** razlika med vsemi obravnavanimi poligoni in vsemi referenčnimi območji.

*** razlika med vsemi referenčnimi območji in resnično pozitivnimi območji

Končno oceno natančnosti podam z odstotkom odkritja (Grigillo, 2010) japonskega dresnika (5):

$$\text{Odstotek odkritja (OO)} = \frac{RP}{RP + LN} \cdot 100 \quad (5)$$

Ta za primer klasifikacije na listu ortofota z oznako E2446 z uporabo 2. sklopa atributov znaša 75%, z uporabo 1. sklopa pa 69.5%. Rezultat je zadovoljiv. Vzroke, ki onemogočajo klasifikacijo japonskega dresnika, gre iskati v značilni pojavnosti japonskega dresnika v naravi. Japonski dresnik se predvsem na brežinah vodotokov nahaja pod krošnjami dreves, na nekaj območjih pa se nahaja med grmičevjem. Drevesne krošnje tako zakrijejo goste sestoje, ki jih z uporabo posnetkov ni mogoče zaznati, prav tako pa ustvarjajo občutek razdrobljenosti sestojev. Ni znano, ali so spregledana območja posledica različnih vrst dresnika. Poleg japonskega dresnika namreč poznamo tudi sahalinski dresnik in pa križanec med omenjenima vrstama, ki nosi znanstveno ime *Fallopia x bohemica*.

Japonski dresnik se v naravi nahaja v različnih fazah rasti, kar pomeni, da na vseh območjih ni enako razvit, kar se odraža tudi v spektralni vrednosti odboja v posameznih kanalih posnetka. Problem je izrazit ob uporabi srednjih vrednosti izbranih atributov, saj te ne odražajo celotne razporeditve pikslov v objektu (sestoju japonskega dresnika), uporaba večje širine intervala uporabljenega atributa pa bi hkrati definirala več lažno pozitivnih poligonov.

Predpostavljamo, da je z vidika načrtovanja ukrepov in nadzora invazivnih vrst večje število lažno pozitivnih poligonov bolj zaželen problem kot pa večje število lažno negativnih poligonov. V našem primeru je število prvih pri uporabi 1. sklopa razmeroma veliko (83) zaradi uporabe nefiltriranega sloja kandidatov. Z uporabo kriterija podobne gostote bi lahko iz tega sloja namreč izločili obdelovalne površine, tudi nekaj grmičevja.

Pomembno je, da v procesu klasifikacije poskušamo zagotoviti čim manjše število lažno negativnih območij t.j. spregledanih območij. Ta območja poskusim klasificirati z uporabo preizkusa Kolmogorova in Smirnova.

Na slikah 56 in 57 podajam primer pravilno zaznanih in spregledanih območij japonskega dresnika na listu ortofota z oznako E2446.



Slika 56: Pravilnost klasifikacije japonskega dresnika na listu ortofota z oznako E2446
(1. sklop atributov).



Slika 57: Primer pravilno zaznanih in spregledanih območij japonskega dresnika na listu ortofota z oznako E2446 (1. sklop atributov).

Za vizualno analizo natančnosti klasifikacije sloja kandidatov na listu E2303 ta sloj predhodno generaliziramo, t.j. izločimo vse objekte s površino, manjšo od 100 m². Sloj kandidatov sem pridobila z uporabo 1. sklopa atributov. Slika 58 prikazuje izsek območja klasifikacije.



Slika 58: Izsek območja klasifikacije na listu E2303. Zeleni poligoni so del sloja kandidatov, rdeče pike pa območja pojavljanja japonskega dresnika, uporabimo 1. sklop atributov. Na južni strani slike je spodaj Cesta dveh cesarjev, severneje pa razbremenilni kanal Mali graben.

Ugotovim, da je sovpadanje referenčnih podatkov in zaznanih poligonov razmeroma veliko (Slika 59), hkrati pa se ob tem pojavi tudi nekaj lažno negativnih območij. Velik del spregledanih območij predstavljajo površine na brežinah vodotoka Mali graben, kjer sestoj je japonskega dresnika zakrivajo krošnje. Opozoriti je potrebno, da na terenskem ogledu nisem preverila vseh manjših sestojev ob Malem grabnu, zato tudi tu ni znano, ali so razdrobljeni klasificirani poligoni tudi zares japonski dresnik. Ob analizi natančnosti je potrebno upoštevati tudi časovno komponento, t.j. klasifikacija je potekala na listu ortofota iz leta 2006, terenski ogled pa sem opravila 5 let kasneje. V nekaj primerih se je tako izkazalo, da japonski dresnik na ortofoto posnetku iz leta ni bil prisoten, medtem ko smo ga v naravi zasledili (Slika 60). Na listu E2446 takšnih primerov nisem zasledila.




Slika 59: Pravilnost klasifikacije japonskega dresnika na listu ortofota z oznako E2303 (1. sklop atributov).



Slika 60: Na levi ortofoto iz leta 2006, na desni japonski dresnik v naravi leta 2011.

Oceno kakovosti določitve japonskega dresnika ocenim zgolj vizualno. Posamezne sloje kandidatov, pridobljene z uporabo treh različnih atributov, primerjam z referenčnimi podatki. Rezultat je optimalen, z izbiro ustreznih vrednosti atributov smo izločili večino japonskega dresnika. Obetaven je rezultat uporabe indeksa Red-Edge NDVI. Čas pridobitve posnetka (mesec avgust) namreč sovпада z vrhom enoletnega vegetacijskega ciklusa japonskega dresnika (cveti

pozno poleti, avgusta in septembra), zato je ta indeks ustrezen pokazatelj območij pojavljanja japonskega dresnika. Zelo pomembno vlogo za določanje teh območij pa ima uporaba atributov v 6. in 8. kanalu (Slika 61). Predpostavljam, da bi najbolj ustrezen rezultat dala kombinacija vseh treh atributov.



Slika 61: Pravilno določena območja japonskega dresnika z uporabo vrednosti atributa v 6. kanalu.

Problem poševnega kota snemanja je posebej izrazit pri satelitskih posnetkih. Objekti nad tlemi so posledično nagnjeni, kar lahko zakrije območja z japonskim dresnikom in onemogoči klasifikacijo. Posebej je to značilno za bregove ob vodotokih.

Ocena natančnosti preizkusa Kolmogorova in Smirnova

S preizkusom Kolmogorova in Smirnova sem preverila, kolikšna je učinkovitost zaznavanja japonskega dresnika na spregledanih območjih. Analiziram vseh 32 spregledanih območij na listu E2446, kjer sem za klasifikacijo sloja kandidatov uporabila 1. sklop atributov.

Od 32 spregledanih območij japonskega dresnika sem z uporabo preizkusa kot japonski dresnik dodatno klasificirala 17 območij, t.j. 53 % vseh spregledanih območij. Preostala neodkrita območja so značilno majhna območja pojavljanja japonskega dresnika ali pa se na teh območjih dresnik nahaja pod grmovjem in krošnjami, kar onemogoča definiranje objekta. Predpostavljam, da bi s preizkusom prav tako pravilno prepoznali večino objektov japonskega dresnika na sloju kandidatov.

4.4 Razprava

Obdelava visokoločljivih slikovnih in višinskih podatkov je razkrila primernost uporabe objektno usmerjene klasifikacije ter preizkusa Kolmogorova in Smirnova za klasifikacijo drevesnih vrst in japonskega dresnika z uporabo visokoločljivih slikovnih in višinskih podatkov.

Ugotovila sem, da je hierarhičen pristop objektno usmerjene klasifikacije ustrezna izbira. Predmeti obravnave se namreč navadno v prostoru pojavljajo na različnih ravneh, zato je enotno stopnjo segmentacije težko opredeliti, t.j. z eno vrednostjo segmentacije ne izločimo vseh obravnavanih objektov na podobi. Vendar pa se je ob uporabi hierarhičnega pristopa klasifikacije potrebno zavedati, da se napake posamezne ravni prenašajo na naslednjo raven. Končna natančnost torej ni neodvisno, enolično določena ocena rezultatov klasifikacije, ampak je odvisna od kakovosti predhodno klasificiranih slojev.

Pri uporabi objektno usmerjene klasifikacije s pravili poskušamo vedno najti kompromis med širino intervala za izbran atribut in številom lažno pozitivnih in lažno negativnih območij. Definiranje sloja krošenj, ki bi predstavljal primeren vhodni podatek za nadaljnjo segmentacijo in preizkus Kolmogorova in Smirnova, je težavno, saj je drevesa najrazličnejših oblik in vrst oziroma njihovo izrazito prostorsko heterogeno pojavnost izziv predstaviti s pravili, posebej pa ne z uporabo prostorskih in geometrijskih atributov. Za klasifikacijo smo zato večinoma uporabili attribute, temelječe na spektralnih lastnostih segmentov.

Pri klasifikaciji japonskega dresnika sem z uporabo dveh različnih zbirk atributov pokazala, da je natančnost klasifikacije v veliki meri odvisna od izbranih vrednosti atributov. Značilna je visoka povezanost med določitvijo intervala in vhodnimi podatki. Definirana širina intervala za vrednosti posameznega atributa je tako ustrezna za testno območje, vendar pa postane problem, če se pojavijo spremembe in odstopanja vhodnih podatkov, kar je za podatke daljinskega zaznavanja zelo značilno. Različni senzorji, položaj Sonca v času snemanja in atmosferski pogoji so le nekateri izmed dejavnikov, ki vplivajo na značilnost satelitske podobe. Ključ do dobrega razlikovanja med objekti na satelitski podobi zagotavljajo le stabilne karakteristike objekta v obravnavi, zato bi bilo smiselno oceniti tudi občutljivost meja intervalov vrednosti izbranih atributov glede na spremembe vhodnih podatkov. Za definiranje atributov bi lahko uporabili tudi metodo strojnega učenja in na ta način za izločanje objektov pridobili attribute, ki smo jih s preizkušanjem spregledali ali pa nam niso zdeli primerni.

Ustrezno dopolnitev objektno usmerjene klasifikacije predstavlja preizkus Kolmogorova in Smirnova. Ocenjujem, da je uporaba porazdelitvenih funkcij primernejša kot klasifikacija s pravili. Pri slednji je operater veliko bolj vpleten v postopek, izkustveno izbira attribute in določa njihove

meje, za katere pa, kot omenjeno, ni nujno, da bodo ustrezni za klasifikacijo ob menjavi uporabljenega vira. Iskanje najbolj ustrezne kombinacije atributov je lahko dolgotrajno in zahteva poznavanje spektralnih karakteristik obravnavanega objekta, prav tako pa se pri klasifikaciji ne upoštevajo vsi piksli znotraj segmenta, temveč le izbrani parametri. Pristop z uporabo porazdelitvenih funkcij je objektiven (izvzemajoč izbiro učnih vzorcev), statistika preizkusa Kolmogorova in Smirnova izkorišča spektralno in radiometrično ločljivost podobe (objektov), kar pomeni, da je ključnega pomena segmentacija podob. Prednost neparametričnih statističnih testov je tudi ta, da predpostavka o normalni porazdelitvi ni nujna.

Učinkovitost preizkusa Kolmogorova in Smirnova zagotovimo le z izbiro ustreznih vhodnih podatkov. To je posebej pomembno, če obravnavamo rabe, ki so si v spektralnem prostoru izredno blizu. Izkazalo se je, da bi bilo določanje drevesnih vrst brez Red-Edge kanala skoraj nemogoče. Nasprotno je bilo zaznavanje japonskega dresnika uspešno že z uporabo posnetkov ortofoto, kar pripisujemo dejstvu, da je bil edini predmet obravnave, prav tako pa so zanj značilne izrazite spektralne karakteristike. Pokazala sem tudi, da bi z uporabo preizkusa lahko zaznali več območij z japonskim dresnikom. Pri tem moramo v obzir vzeti dejstvo, da sem preverjala območja, potrjena s terenskim ogledom. Na osnovi raziskav ugotavljam, da bi metodologijo za stvarnejši prikaz preizkusa morali zasnovati drugače t.j. objekte za preizkus bi pridobili s segmentacijo sloja vegetacije. Potrebno pa se je zavedati, da bi takšen pristop zahteval visoko stopnjo samodejnosti algoritma za preizkus.

Nadalje bo preizkus uspešen tudi in predvsem ob ustrezno izbranih učnih vzorcih.

Pomemben doprinos k identifikaciji dreves v urbanem okolju predstavljajo višinski podatki. V diplomski nalogi uporabim digitalni model krošenj z ločljivostjo 1 m. S postopkom inverzne razvodne segmentacije smo uspešno prepoznali vrhove posameznih dreves, kar je olajšalo definiranje segmentov v nadaljevanju. Za posamezna drevesa je bil odstotek ujemanja visok, kar smo potrdili z vizualno oceno. Skladnosti sloja vrhov z referenčnimi podatki namreč nismo numerično ocenili predvsem zaradi neustrezne položajne točnosti podatkov iz katastra dreves (neustrezna položajna točnost je značilna predvsem za drevesa v skupini), kot zaradi obsežnosti študijskega območja (v parku Tivoli se po podatkih katastra dreves nahaja več kot 2200 dreves). Odstotek ujemanja bi lahko ocenili z uporabo ortofoto posnetka iz leta 2011 (DOF050 2011), ki omogoča podroben vpogled v predmete na površju, letalski posnetek, pridobljen hkrati z podatki laserskega skeniranja, kot tudi stereopare, kjer bi operater ročno zajel posamezna drevesa.

Predloge za izboljšanje klasifikacije drevesnih vrst in japonskega dresnika ter možnosti za nadaljnje delo navedemo v poglavju 5.

5 ZAKLJUČEK IN NADALJNJE DELO

V diplomski nalogi obravnavam uporabnost objektno usmerjene klasifikacije ter preizkus Kolmogorova in Smirnova za določanje drevesnih vrst in zaznavanje japonskega dresnika. Uporaba metodologije temelji na uporabi objektno usmerjenega pristopa klasifikacije, pri čemer v prvem koraku na osnovi definiranih pravil s hierarhično strukturo izločanja ali postopkom segmentacije definiramo kandidate predmeta obravnave. Ti predstavljajo izhodišče za klasifikacijo s preizkusom Kolmogorova in Smirnova. Preizkus Kolmogorova in Smirnova je neparametrični statistični test, kjer s primerjavo empiričnih porazdelitvenih funkcij dveh vzorcev ocenjujemo njuno podobnost.

Izbrano metodologijo sem preizkusila na območjih Mestne občine Ljubljana. Rezultati preizkusa so obetavni tako za drevesne vrste kot za japonski dresnik. S postopkom inverzne razvodne segmentacije smo z uporabo digitalnega modela krošenj uspešno prepoznali vrhove posameznih dreves, s čimer smo lahko bolje definirali segmente, preizkus Kolmogorova in Smirnova pa je na 8-kanalnem satelitskem posnetku WorldView-2 omogočil razlikovanje 8 drevesnih vrst. Natančnost določitve posamezne vrste je v povprečju znašala več kot 60%. Najpomembnejši doprinos satelitskega posnetka predstavlja 6. kanal, t.j. Red-Edge kanal. Rezultati klasifikacije drevesnih vrst so bili namreč najbolj zanesljivi v tem kanalu.

Japonski dresnik smo na posnetkih ortofoto določili s približno 70 % natančnostjo. Glede na referenčne poligone različnih avtorjev je klasifikacija preseгла pričakovanja. Polovico spregledanih območij japonskega dresnika smo uspešno določili z uporabo preizkusa Kolmogorova in Smirnova. Uspešnosti klasifikacije na satelitskih posnetkih nismo ocenili, vendar je glede na vizualno oceno primerjave klasificiranih poligonov in referenčnih podatkov zadovoljiva.

Ocenjujem, da je uporaba posnetkov ortofoto za zaznavanje japonskega dresnika primerna, vendar z vidika časovne ločljivosti manj ugodna. Za učinkovito sprotno spremljanje in odkrivanje novih žarišč japonskega dresnika je ustreznejša izbira satelitskega posnetka.

Nadalje sem ugotovila, da imajo obstoječi večji sestoji japonskega dresnika značilen vzorec pojavljanja. Največ sestojev zasledimo na brežinah vodotokov, ob prometnicah, na gradbiščih in zapuščenih površinah. Prenašanje korenin japonskega dresnika med gradbišči in odlagališči gradbenega materiala postaja v MOL vedno bolj pereč problem. Takšne nenadzorovane površine

namreč omogočajo, da se japonski dresnik vse bolj širi tudi v urbano območje, kjer ga ponekod že zasledimo na javnih zelenih površinah.

Poznavanje prostorske razsežnosti pojavljanja japonskega dresnika lahko predstavlja izhodišče strategij in mehanizmov načrtnega iztrebljanja. Čeprav razvita metodologija, predstavljena v diplomski nalogi, omogoča dokaj zanesljiv način zaznavanja japonskega dresnika, je možnosti za nadaljnje delo še veliko. Ob tem velja izpostaviti predvsem pomembnost zgodnjega zaznavanja majhnih žarišč japonskega dresnika. V zgodnji fazi odkrivanja so ukrepi relativno enostavni in učinkoviti, stroški izkoreninjenja pa še sprejemljivi.

Zaznavanje najmanjših žarišč je značilno omejeno z lastnostmi uporabljenega slikovnega vira, zato bi bilo nadalje rezultate klasifikacije smiselno uporabiti v napovedovalnih modelih, s čimer bi lahko definirali ustreznost posameznih območij, t.j. območij, najbolj verjetnih za naselitev in razširjanje tujerodnih invazivnih rastlin.

Uporabljeno metodologijo bi s prilagoditvami lahko uporabili tudi za zaznavanje ostalih tujerodnih invazivnih rastlin, ki se pojavljajo v Sloveniji, kot so na primer žlezava nedotika, zlata rozga in pa pelinolistna ambrozija.

V obeh primerih predmeta obravnave se je preizkus Kolmogorova in Smirnova tako izkazal kot obetavno orodje za klasifikacijo, vendar sem ob analizi našla pomanjkljivosti, ki se nanašajo tako na lastnost preizkusa kot uporabljenega lastnega algoritma za klasifikacijo v programskem okolju Matlab. Preizkus Kolmogorova in Smirnova je najbolj občutljiv za vrednosti v okolici mediane vzorca, nekoliko manj pa na robovih porazdelitvene funkcije.

Primerno nadgradnjo preizkusa Kolmogorova in Smirnova predstavlja Kuiperjev test. Testno statistiko definiramo kot vsoto največje razdalje prve porazdelitvene funkcije nad (pozitivna razlika) in pod (negativna razlika) drugo porazdelitveno funkcijo. Simetrija razlik tako zagotavlja enako občutljivost za vse vrednosti porazdelitvene funkcije.

Izkazalo se je, da je uporaba lastnega algoritma za klasifikacijo večjih območij zaradi nizke stopnje samodejnosti časovno potratna. Program je namreč zasnovan tako, da omogoča klasifikacijo le enega objekta hkrati. Dolgotrajnost izračuna je prav tako posledica uporabe različnih programskih orodij. Tako sem na primer tekstovne datoteke s spektralnimi vrednostmi segmentov (objektov) pridobila v okolju ENVI, te pa nato uvozila v lasten program. Za nadaljnje delo priporočam zasnovo programa za klasifikacijo s preizkusom Kolmogorova in Smirnova v programskem jeziku IDL, ki je združljiv s programskim okoljem ENVI.

Predpostavljam, da bi ob ustreznih zasnovi algoritma za klasifikacijo s preizkusom Kolmogorova in Smirnova lahko klasificirali večje število vrst, kot to pokaže Sridharan (2010). Večjo natančnost klasifikacije lahko dosežemo s kombinacijo slikovnih virov in digitalnega modela krošenj.

Podatki o drevesnih vrstah, pridobljeni na ta način, bi lahko nadomestili del terenskega popisa urbane drevnine, predvsem pri novi vzpostavitvi katastra dreves. Če kataster dreves že obstaja, je ustrezna nadgradnja tudi informacija o zdravstvenem stanju dreves, ki bi jo lahko pridobili z obdelavo daljinsko zaznanih podob. Menim, da je potencial posnetka WorldView-2 za takšne analize še neizkoriščen.

Ob uporabi veliko različnih podatkov bi morali oceniti tudi stroškovno učinkovitost, t.j. razmerje med stroški terenskega preverjanja na eni, ter stroški obdelave ter doprinos takšne obdelave na drugi strani.

VIRI

Alberti, M. Marzluff, J. M., Shulenberger, E., Bradley, G., Ryan, C., Zumbrunnen, C. 2003. Integrating humans into ecology: opportunities and challenges for studying urban ecosystems. *BioScience* 53, 12: 1169 –1179.

Arboretum Volčji potok, 2011.
<http://www.arboretum.si/>. (Pridobljeno avgust 2011.)

ArcGIS Desktop 9.3 Help. 2011.
http://webhelp.esri.com/arcgisSDEsktop/9.3/index.cfm?TopicName=Delineating_watersheds.
(Pridobljeno oktober 2011.)

Ardila, J. P., Tolpekin, A. V., Bijker, W. 2010. Context-sensitive extraction of tree crown objects in urban areas using VHR satellite images. *The International Archives of the photogrammetry, Remote Sensing and Spatial Information Sciences Vol. XXXVIII-4/C7*.

Bernik, U. 2011. Lidarsko snemanje Rožnik. Elektronska pošta za Đurić, N.: 14. oktober 2011. Osebna komunikacija.

Biology Wiz. 2011.
<http://jeromebiology.blog.com/> (Pridobljeno oktober 2011.)

Blue Marble Project. 2003. NDVI Measurements with Simple Radiometric and photographic Methods.
<http://blumarble.ch/blumarble/About.html>. (Pridobljeno oktober 2011.)

Bozja, K. 2010. Vizualna interpretacija letalskih posnetkov v GE Grosuplje. Diplomsko delo. Ljubljana, Univerza v Ljubljani, Biotehniška fakulteta, Oddelek za gozdarstvo in obnovljive vire. 63 str.

Brus, R. 2008. Drevesa v urbanem okolju. V: Gorenjski glas.

<http://www.gorenjskiglas.si> (Pridobljeno avgust, 2011.)

Changok, L. 2007. Estimation of urban tree crown volume based on object-oriented approach and LIDAR data. Master Thesis. Enchede. International Institute for Geo-Information Science and Earth observation: 83 str.

Digital Globe. 2010. The benefits of the 8 spectral banda of WorldView-2.

www.digitalglobe.com. (Pridobljeno september 2011.)

Dolejši, N. 2009. Kataster urbanega drevja – pomen in uporabnost. V: Hortikultura – možnosti, priložnosti, prenos dobre praks: zbornik izvlečkov, Celje, 20. marec 2009. 21.str.

Dr. Nicholas Short's remote sensing tutorial. 2010.

<http://rst.gsfc.nasa.gov/>. (Pridobljeno oktober 2011.)

Edson, B. C. 2011. Light detection and ranging (LIDAR): What we can and cannot see in the forest for the trees. Dissertation. Oregon State University. 252 str.

Fitosanitarna uprava Republike Slovenije. 2011. Ministrstvo za kmetijstvo, gozdarstvo in prehrano.

<http://www.furs.si/svn/zvr/invrastline.asp>. (Pridobljeno oktober 2011.)

Frajman, B. 2008. Japonski dresnik *Fallopia japonica*, Informativni list 1, Spletna stran tujerodnevrste.info/informativni-listi/INF1-japonski-dresnik.pdf, Projekt Thuja. (Pridobljeno september 2011)

Gosar, A. 2007. Letalsko lasersko skeniranje (LIDAR) Idrijskega in Ravenskega preloma v zahodni Sloveniji. Ujma 21: 139-144.

Govender, M., Dye, P. J., Weiersbye, I. M., Witkowski, E. T. F., Ahmed, F. 2009. Review of commonly used remote sensing and ground-based technologies to measure plant water stress. Water SA, v. 35, n.5.

Grigillo, D. 2010. Samodejno odkrivanje stavb na visokoločljivih slikovnih virih za potrebe vzdrževanja topografskih podatkov. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. 156 str.

Hočevar, M. 2002. Daljinsko pridobivanje podatkov v gozdarstvu. Skripta. Ljubljana, Univerza v Ljubljani, Biotehniška fakulteta. Oddelek za gozdarstvo.

IGI mbH. 2011.

<http://www.igi.eu/>. (Pridobljeno oktober 2011.)

Image metrology. 2011.

<http://www.imagemet.com/>. (Pridobljeno oktober 2011.)

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

<http://www.ittvis.com/>. (Pridobljeno september 2011.)

Jarnjak, M. 2011. Vektorski sloj terenskega ogleda. Osebna storitev.

Jogan, N. 2007. Vektorski sloj terenskega ogleda. Osebna storitev.

Jones, D., Pike, S., Thomas, M., Murphy, D. 2011. Object Based Image Analysis for detection of Japanese Knotweed s.l. taxa (Polygonaceae) in Wales (UK). Remote Sensing 2011, 3, 319-342.

Kanjir, U. 2009. Objektiva klasifikacija rabe tal iz podatkov daljinskega zaznavanja. Diplomski naloga. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. 72 str.

Kerle, N., Janssen, L. L. F., Huurneman, G.C. (ur.). 2004. Principles of remote sensing. ITC Educational Textbook Series. Third Edition. The International Institute for Geo-Information Science and Earth Observation. 540 str.

Kobler, A. 2011. Nove metode za obdelavo podatkov letalskega laserskega skenerja za monitoring gozdnih sistemov. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. 126 str.

Kokalj, Ž. 2010. Uporaba daljinskega zaznavanja pri modeliranju spremenljivk dinamičnega cestninjenja. Doktorska disertacija. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. 197 str.

Kosmatin Fras, M. 2004. Vpliv kakovosti vhodnih podatkov na kakovost ortofota. Geodetski vestnik 48, 2: 167-178.

Kus Veenvliet, J., Veenvliet, P. Bačič, T., Frajman, B., Jogan, N., Lešnik, M., Kebe, L. 2009. Tujerodne vrste: priročnik za naravovarstvenike. Grahovo, Zavod Symbiosis.

Kvarkadabra. 2011.

<http://www.kvarkadabra.net>.(Pridobljeno oktober 2011.)

Lang, S. 2008. Object-based image analysis for remote sensing applications: modelling reality – dealing with complexity. V: Blaschke, T., Lang, S., Hay, G.J. (ur.). Object-based image analysis. Spatial concepts for knowledge-driven remote sensing applications. Berlin, Springer-Verlag: 3-27.

Lewis, P., Hancock, S. 2007. Lidar for vegetation applications.

Marshall. A. (ur.). 1999. The state of world population 1999.

McPherson, E.G. 2006. Urban Forestry in North America. Renewable Resources Journal: 8-12.

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

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

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

Peruš, M. 2000. Biomreže, mišljenje in zavest.

<http://www.dzs.si>. (Pridobljeno oktober 2011.)

Ribeiro, D. 2007. Vektorski sloj terenskega ogleda. Osebna storitev.

Seager, S., Turner, E.L., Schafer, J., Ford, E.B. 2005. Vegetation's Red Edge: A possible Spectroscopic Biosignature of Extraterrestrial Plants. Astrobiology, Volume 5, Number 3.

Shan, J., Toth, C.K. (ur.). 2008. Topographic laser ranging and scanning: principles and processing. New York, Taylor and Francis: 590 str.

Slovenija v presežnikih. 2011.

<http://tomonikon.jalbum.net/Slovenija%20v%20prese%C5%BEenikih/>. (Pridobljeno oktober 2011)

Sridharan, H. 2010. Multilevel urban forest classification using the WorldView-2 8-band hyperspectral imagery.

Šircelj, H. 2008. Karotenoidi v fotosinteznem aparatu in odziv na stres. Acta agriculturae Slovenica, 91-1, 271-282.

Švab Lenarčič, A. 2009. Uporaba lidarskih podatkov za klasifikacijo pokrovnosti. Magistrsko delo. Univerza v Ljubljani. Fakulteta za gradbeništvo in geodezijo. Oddelek za geodezijo. 135 str.

Terranean mapping technologies. 2011.

<http://www.terrestrial.com.au>. (Pridobljeno oktober 2011.)

Tisa d.o.o. 2011.

<http://www.tisa.si>. (Pridobljeno oktober 2011.)

Tolpekin, V. A., Ardila, J. P., Bijker, W. 2010. Super-resolution mapping for extraction of urban tree crown objects from VHR images. The International Archives of the photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVIII-4/C7.

Tree people, 2011.

<http://www.treepeople.org/> (Pridobljeno avgust 2011.)

Turk, G: 2005. Verjetnostni račun in statistika. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

UIC. 2011.

<http://www.uic.edu/classes/bios/bios100/lecturesf04am/lect10.htm>. (Pridobljeno oktober 2011)

University of Calgary. 2011.

<http://www.ucalgary.ca/geog/Virtual/remotaintro.html>. (Pridobljeno oktober 2011.)

Uradni slovenski turistični informacijski portal. 2011.

<http://www.slovenia.info/>. (Pridobljeno oktober 2011.)

Urbančič-Zemljič, M., Škerlavaj, V. 1999. Postaja dresnik (*Reynoutria japonica* Houtt.) v Sloveniji problem? Zbornik predavanj in referatov s 4. Slovenskega posvetovanja o varstvu rastlin, Portorož, 3.-4. marec 1999: 85-90.

Van der Sande, C. J. 2010. Automatic object recognition and change detection of urban trees. The International Archives of the photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVIII-4/C7.

Vasle, L. 2004. Načela sodobnega upravljanja z urbano drevnino v Domžalah. Diplomsko delo. Ljubljana, Univerza v Ljubljani, Biotehniška fakulteta. 85 str.

Vision systems. 1994.

http://www.cs.cf.ac.uk/Dave/Vision_lecture/Vision_lecture_caller.html. (Pridobljeno oktober 2011.)