Objektno orijentirana klasifikacija zemljišnoga pokrova pomoću multispektralnih satelitskih snimaka - primjer Grada Zagreba

Valožić, Luka

Doctoral thesis / Disertacija

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:443175

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOGRAFSKI ODSJEK

Luka Valožić

OBJEKTNO ORIJENTIRANA KLASIFIKACIJA ZEMLJIŠNOGA POKROVA POMOĆU MULTISPEKTRALNIH SATELITSKIH SNIMAKA – PRIMJER GRADA ZAGREBA

DOKTORSKI RAD

Zagreb, 2015.

University of Zagreb

FACULTY OF SCIENCE
DEPARTMENT OF GEOGRAPHY

Luka Valožić

OBJECT-ORIENTED LAND COVER CLASSIFICATION USING MULTISPECTRAL SATELLITE IMAGES – CASE STUDY: THE CITY OF ZAGREB

DOCTORAL THESIS

Zagreb, 2015

Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOGRAFSKI ODSJEK

Luka Valožić

OBJEKTNO ORIJENTIRANA KLASIFIKACIJA ZEMLJIŠNOGA POKROVA POMOĆU MULTISPEKTRALNIH SATELITSKIH SNIMAKA – PRIMJER GRADA ZAGREBA

DOKTORSKI RAD

Mentor: izv. prof. dr. sc. Aleksandar Toskić

Zagreb, 2015.

University of Zagreb

FACULTY OF SCIENCE
DEPARTMENT OF GEOGRAPHY

Luka Valožić

OBJECT-ORIENTED LAND COVER CLASSIFICATION USING MULTISPECTRAL SATELLITE IMAGES – CASE STUDY: THE CITY OF ZAGREB

DOCTORAL THESIS

Supervisor: Aleksandar Toskić, PhD, Associate Professor

Zagreb, 2015

Doktorska disertacija predložena Geografskom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja akademskog stupnja doktora interdisciplinarnih znanosti, polje geografija, grana primijenjena geografija.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Doktorski rad

OBJEKTNO ORIJENTIRANA KLASIFIKACIJA ZEMLJIŠNOGA POKROVA POMOĆU MULTISPEKTRALNIH SATELITSKIH SNIMAKA - PRIMJER GRADA ZAGREBA

Luka Valožić

U istraživanju je provedena objektno orijentirana klasifikacija zemljišnog pokrova upravne prostorne jedinice Grada Zagreba pomoću multispektralnih satelitskih snimaka RapidEye. U istraživanju su upotrijebljeni računalni programi eCognition 9 i ArcGIS 10. Ispitane su metode nadzirane klasifikacije i klasifikacije na temelju skupa pravila. Točnost uspješno izvedene klasifikacije procijenjena je pomoću matrice pogrešaka i kapa koeficijenta. Klasifikacijom na temelju pravila postignuta je ukupna točnost klasifikacije 92,06% i kapa koeficijent 0,89. Podaci dobiveni klasifikacijom zemljišnog pokrova upotrijebljeni su u nastavku istraživanja kao morfološko-fizionomska obilježja za diferencijaciju urbanih, periurbanih i ruralnih naselja, te za izradu dazimetrijske tematske karte gustoće naseljenosti i razmještaja stanovništva. Znanstveni doprinosi su izrada postupka i algoritma za klasifikaciju zemljišnog pokrova, izrada tematske karte i GIS-slojeva podataka Grada Zagreba sa zemljišnim pokrovom vegetacije, izgrađenih površina, golog tla i vodenih površina, te prijedlog upotrebe udjela izgrađenih površina kao dodatne varijable u modelima za tipologiju. Spoznaje iz istraživanja će također omogućiti unapređenje visokoškolskog obrazovanja na studijima geografije na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu.

131 stranica, 20 grafičkih priloga, 11 tablica, 204 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: objektno orijentirana klasifikacija, zemljišni pokrov, multispektralne satelitske snimke RapidEye, urbana i periurbana područja, V-I-S model

Mentorica: izv. prof. dr. sc. Aleksandar Toskić

Povjerenstvo: doc. dr. sc. Aleksandar Lukić, doc. dr. sc. Andrija Krtalić, izv. prof. dr. sc. Aleksandar Toskić

Rad prihvaćen: 2. veljače 2015.

Rad je pohranjen u Središnjoj geografskoj knjižnici na Geografskom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19/II, Zagreb i u Nacionalnoj i sveučilišnoj knjižnici, Ulica Hrvatske bratske zajednice 4, Zagreb.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Doctoral Thesis

OBJECT-ORIENTED LAND COVER CLASSIFICATION USING MULTISPECTRAL SATELLITE IMAGES - CASE STUDY: THE CITY OF ZAGREB

Luka Valožić

Abstract: An object-oriented land cover classification using RapidEye multispectral satellite imagery has been performed for the entire area of the City of Zagreb. Computer software eCognition 9.0 and ArcGIS 10 have been used for the research. Research includes both supervised and rule-based classification methods. Accuracy of classification method was assessed by error matrix and kappa statistic. Accuracy assessment resulted with an overall accuracy of classification at 92.06% and kappa statistic of 0.89. Data acquired by land cover classification were used as morphological-physiognomic characteristics for the differentiation of urban, peri-urban and rural settlements as well as for the production of dasymetric thematic map of population density. Scientific contributions made by this research are: production of land cover classification ruleset, production of land cover map and land cover shapefiles for the area of the City of Zagreb with classes: vegetation, impervious surfaces, bare soil, and water. A proposal has been made for the usage of the share of impervious surfaces as additional variable in the models for the typology of settlements. Scientific experience gained by this research will help improve higher education geography studies at the Faculty of Science, University of Zagreb.

131 pages, 20 figures, 11 tables, 204 references; original in Croatian

Keywords: object-oriented classification, land cover, RapidEye multispectral imagery, urban and peri-urban area, V-I-S model

Supervisor: Aleksandar Toskić, PhD, Associate Professor

Reviewers: Aleksandar Lukić, PhD, Assistant Professor; Andrija Krtalić, PhD, Assistant Professor; Aleksandar Toskić, PhD, Associate Professor

Thesis accepted: 2nd February 2015

Doctoral Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19/II, Zagreb, and in the National and University Library, Hrvatske bratske zajednice 4, Zagreb.

Josipi i Eriku

mami, tati i burazu

Zahvaljujem mentoru Aleksandru Toskiću na svom njegovom strpljenju, razumijevanju i dobroj volji koju mi je pružio tijekom izrade doktorskog rada. Zahvaljujem Aleksandru Lukiću i Andriji Krtaliću na inspiraciji, sugestijama, savjetima koje sam često tražio i dobio u luda doba dana ili noći. Posebnu zahvalu iskazujem svojim kolegama geografima, Marinu, Petri i Slavenu na skakanju u pomoć i strpljivom slušanju svih mojih *kukanja* o doktorskom radu. U istoj maniri zahvaljujem svim kolegama i kolegicama asistentima koji su, preuzimanjem nekih od brojnih obaveza i dužnosti na Geografskom odsjeku, omogućili meni više vremena za rad na disertaciji. Zahvaljujem svim ostalim kolegama geografima i djelatnicima Geografskog odsjeka Prirodoslovno-matematičkog fakulteta na pruženoj pomoći i potpori tijekom doktorskog studija. Pritom valja posebno istaknuti rad studentske referade i benevolenciju njezine djelatnice Ivane Erdelez. Zahvaljujem i ostalim djelatnicima fakulteta na ljubaznosti i profesionalnosti koju su pokazali tijekom cjelokupnog procesa *doktoriranja*.

It is better to be vaguely right than exactly wrong.

Carveth Read

London, 1898

SADRŽAJ

1. UVOD 1
2. TEMA ISTRAŽIVANJA 6
   2.1. Objektno orijentirana analiza slika 6
   2.2. Klasifikacija zemljišnog pokrova 10
   2.3. Multispektralne satelitske snimke 16
   2.4. Prostorni obuhvat – Grad Zagreb 17
3. CILJEVI I HIPOTEZE ISTRAŽIVANJA 26
   3.1. Ciljevi istraživanja 26
   3.2. Hipoteze istraživanja 29
4. TEORIJSKI OKVIR ISTRAŽIVANJA 31
   4.1. Daljinska istraživanja 31
      4.1.1. Elektromagnetsko zračenje i spektralna svojstva tvari 34
      4.1.2. Senzori u daljinskim istraživanjima 43
      4.1.3. Satelitski sustav RapidEye 46
   4.2. Geoinformatika 49
      4.2.1. Geografski informacijski sustavi 51
      4.2.2. Geografska objektno orijentirana analiza slika 54
   4.3. Geografija 56
5. PODACI I METODOLOGIJA ISTRAŽIVANJA 63
   5.1. Podaci 63
      5.1.1. Multispektralne satelitske snimke sustava RapidEye 63
      5.1.2. Vektorski podaci u GIS-u 66
      5.1.3. Referentni podaci za provjeru točnosti klasifikacije 66
      5.1.4. Popis stanovništva 2011. 68
   5.2. Metodologija 69
      5.2.1. Predobrada podataka 69
      5.2.2. Multirezolucijska segmentacija snimaka 74
      5.2.3. Nadzirana klasifikacija zemljišnog pokrova 76
      5.2.4. Klasifikacija zemljišnog pokrova na temelju skupa pravila 80
      5.2.5. Provjera točnosti klasifikacije 86
      5.2.6. Primjena obrađenih podataka 89

5.2.6.1. V-I-S model analize urbanih područja 89
5.2.6.2. Dazimetrijska karta 93
6. REZULTATI ISTRAŽIVANJA I RASPRAVA 98
6.1. Tumačenje točnosti metoda klasifikacije 98
6.2. Primjenjivost podataka o zemljišnom pokrovu za diferencijaciju tipova naselja u urbanom i periurbanom prostoru 100
6.3. Mogućnosti poboljšanja metodologije 101
7. ZAKLJUČAK 102
7.1. Znanstveno-istraživački doprinos istraživanja 102
7.2. Doprinos istraživanja visokoškolskoj nastavi 103
LITERATURA 104
IZVORI 123
PRILOG A: Popis slika 125
PRILOG B: Popis tablica 126
PRILOG C: Summary 127
PRILOG D: Životopis 131

1. UVOD

Svatko tko se bavi geografijom poznaje *glad* za prostornim podacima i informacijama, kako bi upravo na temelju njih obogatio svoje znanje o društvenim te prirodnim pojavama i procesima na Zemlji. Neovisno o njezinoj obrazovnoj ili akademskoj razini i identitetu ili značaju koji joj se pridaje u suvremenom društvu, od osnovnoškolskog do visokog obrazovanja, enciklopedijskog i faktografskog ili znanstveno-istraživačkog karaktera geografije – učenje geografije i rad u geografiji iziskuju enormne količine smislenih, ažurnih i pouzdanih podataka. Polazeći od pojmova mjesta i lokacije, položaja i smještaja, koordinata i adrese, preko sadržaja prostora, mjere i količine tog sadržaja, jakosti i učestalosti, tokova i trenda, dolazi se do složenijih promišljanja i preispitivanja prostorne problematike Zemljine površine, geosfere ili geoprostornih sustava koji su objekt istraživanja geografije (Hard, 1973; Vresk, 1997).

Svako geografsko znanstveno istraživanje zahtijeva akumuliranje postojećih i stvaranje novih podataka, a njihova će obrada i tumačenje dovesti do novih spoznaja, odnosno potvrditi ili opovrgnuti postavljene hipoteze i postojeće teorije (Vresk, 1997). Istovremeno, kritički nastrojeno znanstveno djelovanje podrazumijeva radoznalost i propitkivanje svega pa tako i metoda prikupljanja i obrade podataka na kojima se temelje znanstvena istraživanja te sva ostala tumačenja, prosudbe i odluke pojedinaca, skupina ljudi ili cjelokupnog društva.

Opći društveni razvoj te napredak znanosti i tehnologije tijekom druge polovice 20. stoljeća omogućio je gotovo nemjerljivu, ali svakako vrlo teško pojmljivu količinu prikupljanja, obrade, proizvodnje, pohrane i razmjene podataka (Hilbert i Lopez, 2011). Tradicionalnim geografskim metodama objedinjavanja podataka iz pisanih izvora, često prikupljenih radom statističkih i arhivskih službi, ili s druge strane neposrednim mjerenjima i opažanjima *na terenu*, odnosno u samom prostoru proučavanja, kao i načinima distribucije geografskih informacija i znanja putem tiskanih medija: knjiga, publikacija, različitih dokumentacija, karti, grafičkih priloga i dr., s razvojem suvremenih tehnologija pridružili su se brojni novi izvori podataka i mogućnosti njihove obrade i razmjene, a njima su prethodila velika znanstvena otkrića suvremenog doba često popraćena novim znanstvenim paradigmama (Kuhn, 1962; Vresk, 1991, 1997).

Razvoj računala, suvremenih telekomunikacija te zrakoplovstva, raketne i svemirske tehnike omogućili su geografiji kao i svim ostalim znanstvenim disciplinama posve nove uvide u svijet, a cjelokupnom društvu ulazak u informacijsko doba (Kranzberg, 1985; Castells, 2010).

Informatizacija društva promijenila je geografiju te ju i dalje nastavlja mijenjati. Uz razvoj telekomunikacijskih tehnologija na kojima se temelji suvremeno širenje i jačanje mreže veza znanstvenog, akademskog i stručnog kadra i opću računalnu podršku ljudskom intelektualnom radu, najznačajniji aspekt informatizacije geografije su geografski informacijski sustavi. Njihova pojava i razvoj doprinijeli su jačanju geografske znanstveno-istraživačke djelatnosti, ali i razvoju i jačanju primijenjene geografije kroz stvaranje rješenja za niz konkretnih, stvarnih, svakodnevnih prostornih problema (Longley i dr., 2005).

Upotrebom GIS-a interdisciplinarnost geografije dodatno je naglašena jer je njihova struktura neraskidivo povezana s brojnim znanstvenim disciplinama, a kad su u pitanju obrada i analiza prostornih podataka njihova je primjena univerzalna. Digitalni prostorni podaci koji se koriste u geografskim informacijskim sustavima često potječu iz sustava za daljinska istraživanja.

Otkako postoje, daljinska istraživanja tehnološki se usavršavaju s ciljem što bržeg prikupljanja sve pouzdanijih i preciznijih prostornih podataka, ali je za znanstveni i opći društveni napredak vjerojatno važnija njihova sve učestalija upotreba u civilne svrhe i otvaranje široj javnosti. Izlazak iz okvira strogih ograničenja vojnih i obavještajnih djelatnosti koje su prve prepoznale njihov značaj bio je postepen i uvjetovan povijesnim okolnostima 20. stoljeća. Pravno skidanje tajnosti s podataka prikupljenih pomoću daljinskih istraživanja i komercijalizacija djelatnosti koje su nužne za uspostavu i funkcioniranje sustava za daljinska istraživanja omogućile su široj znanstvenoj zajednici i općoj javnosti pristup bogatom i značajnom izvoru podataka o Zemlji (Kramer, 2002; Bušljeta Vdović, 2006; Campbell i Wynne, 2011).

Za geografiju su daljinska istraživanja prije svega bogat izvor prostornih podataka. Velika većina sustava za daljinska istraživanja usmjerena je na prikupljanje podataka sa Zemljine površine i zato privlače pozornost brojnih geografa i znanstvenika iz drugih znanstvenih disciplina koji u svojem radu koriste geoinformacije (Donnay i dr., 2001; Rashed i Jürgens, 2010; Yang, 2011). Kad je riječ o daljinskim istraživanjima Zemlje, vrlo često koristi se termin motrenje Zemlje (engl. *earth observation*, krat. *EO*).

Osim detekcije i bilježenja zapisa elektromagnetskog zračenja pristiglog s promatranog objekta s određene udaljenosti, daljinska istraživanja također u širem smislu podrazumijevaju mnogobrojne složene metode njihove obrade, interpretacije, analize i vizualizacije (Lillesand i dr., 2004; Richards i Jia, 2006; Campbell i Wynne, 2011). Metodologija daljinskih istraživanja sve se intenzivnije povezuje sa znanjima i vještinama iz drugih znanstvenih disciplina među kojima je i geografija.

Promatranje Zemljine površine odozgo iz tzv. ptičje perspektive, koje je uobičajeno u daljinskim istraživanjima podudara se s perspektivom korištenom za kartografsko prikazivanje Zemljine površine ili sažetije rečeno – karte, jednom od osnovnih i nezaobilaznih geografskih sredstava rada, vizualizacije i komunikacije prostornih informacija i znanja o prostoru (Getis i dr., 2006). Ta se sličnost može shvatiti kao prednost u povezivanju znanstvenih disciplina geografije i daljinskih istraživanja. Interdisciplinarnost proizišla iz ispreplitanja različitih znanstvenih disciplina može rezultirati povećanjem primjenjivosti znanosti i omogućiti izvršavanje jasno definiranih zadaća javne vrijednosti. Primjer takvog zadatka jest klasifikacija zemljišnog pokrova određenog prostora.

Iako je cilj ovog rada ispitivanje metoda klasifikacije zemljišnog pokrova, njegova svrha su mjerenja i analize podataka dobivenih određenom metodom klasifikacije te izrada tematskih karata zemljišnog pokrova proučavanog prostora, odnosno Grada Zagreba. Rezultati klasifikacije najzornije se predočavaju kartografskim prikazivanjem analiziranog područja, odnosno tematskim kartama na kojima je cijelo istraženo područje podijeljeno u zadane klase zemljišnog pokrova. Prema tome ovaj se rad može svrstati u primijenjenu geografiju jer se bavi konkretnom zadaćom prikupljanja informacija o prostornim obilježjima odabranog područja (Vresk, 1997). Takve se geografske informacije mogu upotrijebiti u svrhu upravljanja prostorom, prostornog planiranja i uređenja te u daljnjim istraživanjima modela u geografiji, geoznanostima i znanostima o okolišu pomoću kojih se nastoji objasniti pojave i procese na Zemlji. Daljinska istraživanja zbog svoje karakteristike sustavnog i opetovanog promatranja Zemljine površine pružaju ažurne podatke kao osnovu za detekciju i praćenje promjena u okolišu. Dovoljno je spomenuti da satelitski sustav RapidEye, korišten u ovom istraživanju, pruža mogućnost redovitog dnevnog snimanja istog područja te da je njegov ukupni dnevni kapacitet snimanja Zemljine površine do 5.000.000 km^2 (BlackBridge RapidEye, 2014). Provedeno istraživanje također obuhvaća pripremu i obradu prostornih podataka ili informacija te kontrolu i analizu rezultata klasifikacije zemljišnog pokrova.

Pojmovi zemljišnog pokrova (engl. *land cover*) i načina korištenja zemljišta (engl. *land use*) ili klase na koje se oni dijele, često se spominju i upotrebljavaju zajedno u znanstvenoj literaturi ili se objedinjuju i izmjenjuju unutar jedne klasifikacijske sheme za potrebe konkretnog istraživanja (Anderson i dr., 1971, 1976). Daljinska istraživanja igraju veliku ulogu u suvremenim postupcima klasifikacije Zemljine površine ili krajolika prema određenim obilježjima, ali sama po sebi, bez dodatnih ili pomoćnih izvora podataka, ne mogu poslužiti za dovoljno pouzdano utvrđivanje načina korištenja zemljišta (Ridd, 1995). Društveni ili ekonomski značaj promatrane jedinice prostora koji se podrazumijeva upotrebom termina način korištenja zemljišta, moguće je istražiti upotrebom podataka prikupljenih terenskim radom ili pridruživanjem podataka iz službenih izvora poput katastra. Također, način korištenja zemljišta moguće je donekle dokučiti na temelju indikatora prisutnosti određene pojave ili procesa u prostoru u kombinaciji s *a priori* znanjem stručnjaka ili osobnim iskustvom interpretatora snimaka.

Snimke nastale bilježenjem elektromagnetskog zračenja reflektiranog ili emitiranog sa Zemljine površine sadrže vrijednosti mjera reflektancije ili radijancije i one su, između niza ostalih čimbenika, uvjetovane biološkim i fizikalnim svojstvima tvari i materijala prisutnih u promatranom prostoru. Upravo se na temelju jedinstvene interakcije energije i materije u prirodi sadržaj snimljenog dijela Zemljine površine može uopćiti u klase zemljišnog pokrova. Prema tome, za potrebe ovog istraživanja usvojen je stav da klase zemljišnog pokrova proizlaze iz fizikalnih, bioloških i kemijskih svojstava objekata mjerljivih instrumentima te da se one ne bi trebale miješati s klasama načina korištenja zemljišta iza kojih stoji tipologija temeljena na društvenom, kulturnom ili ekonomskom značaju određene jedinice prostora. Za ovo istraživanje upotrijebljene su satelitske snimke i termin daljinskih istraživanja će se u radu često upotrebljavati u kontekstu takvog tipa podataka.

Imajući na umu problematiku geografske metodologije i objekta proučavanja (Roglić, 1960) valja napomenuti da nastojanje ovog rada nije usko specijaliziranje u specifičnu znanstveno-istraživačku nišu i odvajanje od znanstvene discipline geografije, već istraživanje potencijalnih izvora podataka te usavršavanje metoda njihove analize i sinteze upravo s ciljem povećanja istraživačkih mogućnosti i sposobnosti geografije u Hrvatskoj, sa svrhom povećanja njezine primjenjivosti. Rad se ne želi ograditi niti odreći geografskih znanja, nego upravo suprotno – želi ih iskoristiti za uspješno izvršavanje konkretnog zadatka i ispunjenje jasnog cilja. Treba naglasiti da je ovo istraživanje provedeno na temelju rada i literature cijenjenih

stručnjaka koje u velikoj mjeri čine geografi ili znanstvenici iz srodnih disciplina koji djeluju na geografskim sveučilišnim odsjecima i institutima diljem svijeta. U konačnici, geografi su primarna ciljana skupina čitateljstva za koje je provedeno ovo istraživanje i napisan ovaj rad.

Tema istraživanja predstavljena je u sljedećem poglavlju kroz detaljnija objašnjenja ključnih pojmovi iz naslova rada te prikaz odabranog prostora istraživanja – Grada Zagreba.

2. TEMA ISTRAŽIVANJA

2.1. Objektno orijentirana analiza slika

Poimanje objektno orijentirane analize slika ovisi o različitim definicijama pojedinih autora koje ju tumače kao: a) konceptualni pristup analizama digitalnih slikovnih datoteka ili kao b) konkretna tehnička rješenja, metode i postupke koji se upotrebljavaju za analiza slika.

Bez obzira na šire ili uže definicije objektno orijentirane analize slika, njihovu osnovu čini segmentacija slike kao glavna metoda ili postupak koji prethodi svim mogućim daljnjim postupcima analize. Segmentacija slike je postupak podjele slike na manje međusobno odvojene dijelove ili jednostavnije rečeno, skupine piksela koje se međusobno ne preklapaju. Unutar pojedinog dijela slike, odnosno segmenta, nalaze se pikseli sa sličnim obilježjima ili pikseli objedinjeni prema nekom uzorku, a izvan njega su pikseli koji zbog svoje različitosti ili neuklapanja u uzorak nisu dodijeljeni tom segmentu. Pridavanjem semantičke dimenzije segmentima slike, primjerice tijekom klasifikacije zemljišnog pokrova, stvaraju se objekti s određenim značenjem koji predstavljaju stvarne entitete sa Zemljine površine.

Kako bi se provela objektno orijentirana analiza i klasifikacija snimaka prikupljenih daljinskim istraživanjima treba primijeniti neku od metoda segmentacije digitalnih slikovnih datoteka. Metode segmentacija spadaju u znanstvene discipline digitalne analize i obrade slika te računalnog vida. U literaturi postoje različite podjele metoda segmentacija u tipove (Gonzalez i Woods, 2002; Navulur, 2006; Sonka i dr., 2007), ali za potrebe ovog rada bit će dovoljno razvrstati ih prema principu djelovanja algoritama segmentacije:

- na osnovi pragova digitalnih vrijednosti (engl. *thresholding*)
- na osnovi rubova ili granica između sastavnih dijelova slike (engl. *edge based*)
- na osnovi unutrašnjosti područja ili regija slike (engl. *region based*)

Prva skupina metoda je najjednostavnija i promatrano iz aspekta računalne obrade podataka, najbrža i najmanje zahtjevna. Postavljanjem praga unutar raspona brojčanih vrijednosti piksela koji čine digitalnu sliku, ona se može podijeliti na segmente. Pritom se u obzir može uzeti cjelovita slika (engl. *global threshold*) ili njezini određeni manji dijelovi (engl. *local threshold*). Odvojeni pragovi mogu se primijeniti i u slučaju višespektralnih ili multispektralnih snimaka (engl. *multispectral thresholding*). Kao pomagala za utvrđivanje vrijednosti praga ili pragova mogu se upotrijebiti metode njihove detekcije na temelju *a priori*

znanja o udjelu objekata unutar slike ili njihovom rasporedu (engl. *p-tile thresholding*) te distribucije vrijednosti u histogramu pri čemu se one za potrebe segmentacije mogu uspoređivati s normalnom statističkom razdiobom (engl. *histogram shape thresholding* i *optimal thresholding*) (Gonzalez i Woods, 2002; Navulur, 2006; Sonka i dr., 2007).

Druga navedena skupina metoda segmentacija temelji se na rubovima ili granicama sastavnih dijelova slike. Te granice predstavljaju diskontinuitete prisutne u slici koji se temelje brojčanim vrijednostima nijansi sive boje (engl. *grayscale*), boje ili teksture. Za njihovo prepoznavanje i određivanje unutar zadane slike mogu se upotrijebiti algoritmi za praćenje granica (engl. *boundary* ili *border tracing*), modela aktivnih kontura (engl. *active contour modeling*) ili Houghovu transformaciju (Gonzalez i Woods, 2002; Navulur, 2006; Sonka i dr., 2007).

Treća skupina metoda segmentacije odnosi se na algoritme koji upotrebljavaju homogenost ili uniformnost pojedinih dijelova digitalne slike radi njezine ukupne podjele. Prema pristupu obradi podataka ta se skupina može dodatno podijeliti na: metode izrastanja područja (engl. *region growing*) i metode dijeljenja i stapanja područja (engl. *region splitting and merging*). Metode segmentacije pomoću algoritma za izrastanje područja upotrebljavaju pojedine piksele kao početne točke (engl. *seed points*), odnosno ishodišta segmentacije. Područja ili regije slike izrast će oko početnih točaka ili piksela ako susjedni pikseli zadovoljavaju zadane kriterije, odnosno imaju dovoljno slična svojstva izražena brojčanim vrijednostima (engl. *digital number*, krat. *DN*). Primjenom metoda dijeljenja i stapanja područja, segmentacija se izvršava upotrebom postupaka za inicijalnu ili početnu arbitrarnu razdiobu slike na područja koja se zatim daljnjom obradom spajaju ili nastavljaju dodatno dijeliti prema zadanim kriterijima (sličnosti) njihovih svojstava (Gonzalez i Woods, 2002; Navulur, 2006; Sonka i dr., 2007).

Digitalne slikovne datoteke mogu se također promatrati kao svojevrsni modeli reljefa jer se brojčane vrijednosti piksela mogu prikazati kao mjera visine, te se na njima može primijeniti tzv. metoda slijeva (engl. *watershed*). Popunjavanjem ili plavljenjem slike od manjih prema većim vrijednostima, mogu se izdvojiti područja poput sljevova i razvodnice među njima koji onda ujedno čine regije slike i njihove granice (Gonzalez i Woods, 2002; Navulur, 2006; Sonka i dr., 2007).

Iako neki autori (Blaschke i dr., 2010) koji objavljuju radove na engleskom jeziku smatraju da je termin objektno orijentirana analiza slika najprikladniji za opis željenog pojma (engl. *object-oriented image analysis*), u znanstvenoj i stručnoj zajednici se ustalio termin na engleskom jeziku *object-based image analysis* i njegova kratica *OBIA* (hrv. analiza slika na temelju objekata). Termin *objektno orijentirana*, uglavnom se izbjegava kako ne bi došlo do zabune i miješanja ove vrste analize i obrade digitalnih slikovnih datoteka s pojmom objektno orijentiranog programiranja koji ima posve drugačije značenje. S manjim izmjenama terminologije, tj. dodavanjem riječi geografska ili prefiksa geo ispred navedenih pojmova (engl. *Geographic Object-Based Image Analysis*, krat. *GEOBIA*) preciznije je definirana relativno nova poddisciplina geoinformatike o kojoj će biti još riječi kasnije u tekstu (Hay i Castilla, 2008). Za ovaj doktorski rad odlučeno je da će se koristiti naziv objektno orijentirana analiza slika jer, u skladu s navedenom literaturom, preciznije opisuje pojam te zbog toga što se doima prikladnijim za hrvatski jezik. Također se predlaže kratica naziva na hrvatskom jeziku – OBORANS.

Razvoj računalnih metoda obrade, analize i segmentacije slika počeo je tijekom 1970-ih godina (Kettig i Landgrebe, 1976), a od tada se primjenjuju u brojnim znanstvenim disciplinama poput računalnog vida, medicine, astronomije i mikroskopije. Intenzivnija upotreba u geoinformatici i daljinskim istraživanjima započela je krajem 20. stoljeća nakon razvoja satelita velike površinske razlučivosti i njihovog sve češćeg korištenja u civilne svrhe, kao i jačanja te pojeftinjenja računalne opreme s jedne strane te pojave komercijalnog softvera za segmentaciju slika s druge strane općeg računalnog napretka. Vrlo pojednostavljeno rečeno, dotad su se znanstvenici u daljinskim istraživanjima orijentirali na analizu i obradu uglavnom rasterskih podataka, dok su se znanstvenici koji se bave geografskim informacijskim sustavima više usmjerili na rad s vektorskim podacima (Hay i Castilla, 2008). Upravo se objektno orijentirana analiza pokazala kao mosna disciplina između geoinformatike i daljinskih istraživanja jer se pomoću nje ulazne rasterske podatke poput satelitskih snimaka mogu podijeliti u jasno razdvojene objekte te pretvoriti u vektorske podatke koji se uobičajeno i pretežno koriste u geografskim informacijskim sustavima. S druge strane, vektorski podaci nastali upotrebom GIS-softvera također se mogu iskoristiti u računalnim programima za objektno orijentiranu analizu slika kao uvezeni tematski prostorni podaci.

Mogućnosti promatranja, analize i klasifikacije Zemljine površine pomoću daljinskih istraživanja u velikoj mjeri ovise o površinskoj razlučivosti instrumenata. Odnos veličine

objekata u prostoru i veličine snimljene površine koja je u slikovnoj datoteci predstavljena jednim slikovnim elementom – pikselom, uvjetuje sposobnosti ljudskih interpretatora i računalnih sustava da te objekte detektiraju, razlikuju i identificiraju. Tijekom razdoblja u povijesti daljinskih istraživanja u kojem su prevladavali podaci s razmjerno malom površinskom razlučivošću, pojedini su pikseli satelitskih snimaka prikazivali područja koja su površinom veća od zasebnih elemenata krajolika ili objekata koji se nalaze u njemu. Takve su snimke omogućavale prepoznavanje i mjerenje velikih geografskih entiteta poput šuma, travnjaka, jezera, izgrađenih gradskih područja ili većih prometnica, ali izdvajanje individualnih objekata poput kuća, stabala ili uskih putova uglavnom nije bilo izvedivo. Dakle, unutar jednog piksela često su bili pomiješani brojni objekti i različiti zemljišni pokrovi. Metode klasifikacije takvih podataka temeljile su se na zasebnim pikselima. Postupni razvoj tehnologije omogućio je povećanje površinske razlučivosti senzora, a posljedica toga bila je inverzija odnosa piksel-objekt. U satelitskim snimkama recentnijeg datuma objekti, entiteti ili pojave sa Zemljine površine detektirani su i zabilježeni u većem broju slikovnih elemenata. Taj je napredak doveo do novih izazova za obradu i analizu podataka prikupljenih daljinskim istraživanjima. Veća površinska razlučivost podrazumijeva veću količinu podataka, ali i veći šum unutar skupa podataka koji ometa postupke stvaranja smislenih informacija. S pojavom takve problematike intenziviraju se istraživanja metoda objektno orijentirane analize slika i postupaka segmentacije slika, odnosno satelitskih snimaka. Njihovom upotrebom omogućene su klasifikacije snimaka na temelju segmenata, odnosno skupina piksela objedinjenih na temelju određenog kriterija (Veljanovski i dr., 2011).

Zbog svojeg sintetičkog karaktera objektno orijentirana analiza slika pronalazi svoju primjenu u mnogim znanstvenim i stručnim djelatnostima, a među onima koje koriste geografske ili prostorne podatke mogu se izdvojiti daljinska istraživanja urbanog prostora (Hofmann, 2001; De Kok i dr., 2003; Yuan i Bauer, 2006; Hofmann i dr. 2008; Kampouraki i dr., 2008), klasifikacija zemljišnog pokrova i načina korištenja zemljišta (Kamagata i dr., 2006; 2008; Riedel i dr., 2008; Smith, 2008.), zaštita okoliša (Bock i dr., 2005; Varela i dr., 2008; Hese i Schmullius, 2008; Tuxen i Kelly, 2008), šumarstvo (Kim i dr., 2008; Thiel i dr., 2008; Wulder i dr., 2008). Upotreba objektno orijentirane analize slika očituje se u ovom istraživanju u primjeni algoritma za segmentaciju satelitskih snimaka i metodama klasifikacije koje se temelje na segmentima snimaka i njihovim svojstvima.

2.2. Klasifikacija zemljišnog pokrova

Klasifikacija zemljišnog pokrova je znanstveno-istraživački postupak sustavne i potpune podjele određenog dijela Zemljine površine u zadani broj skupova ili klasa čije se razlike temelje na biološkim i fizičkim svojstvima promatranih objekata. Klasifikacijski sustav može biti sastavljen od klasa zemljišnog pokrova podijeljenih u više razina, ali se skupovi iste razine ne smiju preklapati. Unutar takve strukture, neki geografski entitet, odnosno njegova reprezentacija u određenom modelu podataka, može biti klasificirana isključivo kao jedna klasa pokrova unutar jedne razine klasifikacije, ali može činiti dio neke šire definirane klase na višoj razini i sadržavati uže definirane klase na nižoj razini.

Pojam zemljišnog pokrova (engl. *land cover*) obilježava stvarnu, predmetnu, opipljivu, mjerljivu, fizičku prostornu pojavu koja pokriva, odnosno zauzima određeni dio Zemljine površine. Konkretni primjeri zemljišnog pokrova mogu obuhvaćati razne pojavnosti: vodenih površina poput zaljeva, rijeka, jezera, akumulacija, poplavljenih površina, bazena; izgrađenih površina kao što su zgrade, cestovne prometnice, ostale umjetne nepropusne površine poput sportskih terena s tvrdom podlogom; površina pokrivenih biljnim raslinjem za koje se mogu navesti primjeri šuma, travnjaka, usjeva; golih tala ili stjenovitih površina neovisno o tome jesu li prirodno ili umjetno ogoljene površine, odnosno jesu li oranica, gradilište ili pustinja; snijegom i ledom pokrivene površine itd. Klasifikacija zemljišnog pokrova ovisi o fizičkim obilježjima stvarnog geografskog prostora, ali i o cilju i svrsi samog postupka klasifikacije na temelju kojeg će se vršiti diobe i spajanja pojedinih klasa pokrova u klase višeg i nižeg reda.

Prema tumačenju pojma zemljišnog pokrova navedenoj u dokumentaciji hrvatske Agencije za zaštitu okoliša, u čijoj je nadležnosti CORINE program (engl. *Coordination of information on the environment*, krat. *CORINE*), ono podrazumijeva podatak koji govori s čime je zemljište pokriveno, a taj je pokrov posljedica biofizičkih obilježja promatranog prostora te se često povezuje s njegovim ekosustavima (AZO, 2010).

Valja napomenuti da se uz termin *zemljišni pokrov*, u Hrvatskoj usporedno upotrebljava termin *pokrov zemljišta*. Taj istoznačni termin upotrebljava se češće od termina zemljišni pokrov, a za njegovu veću zastupljenost u hrvatskom jeziku u ovom trenutku zaslužne su ponajprije publikacije i baze podataka spomenutog CORINE programa. Potpuni historijski pregled pojma zemljišni pokrov i s njim povezane terminologije te argumentaciju za upotrebu

upravo termina *zemljišni pokrov* kao i termina *način korištenja zemljišta* izložio je Cvitanović (2014) u svojem doktorskom radu.

Prema tumačenju informacijskih znanosti, poimanje klasifikacije kao procesa podrazumijeva aktivnost razvrstavanja entiteta unutar podjele nekog klasifikacijskog sustava. Podjela entiteta u klase provodi se sustavno i prema određenim zakonitostima, što znači postojanu primjenu predodređenih principa koji čine temelj strukture klasa i njihovih međusobnih odnosa. Klasifikacijski sustav može činiti klasifikacijska shema, odnosno hijerarhijski skup međusobno isključivih i nepreklapajućih klasa. Klasifikacijska shema je posve umjetno i arbitrarno definirano sredstvo koje se upotrebljava s ciljem uspostave smislene organizacije odabranih entiteta prema kriterijima zadanim unutar jedne određene domene istraživanja (Jacob, 2004).

U geografiji se često koristi termin tipologija koji također podrazumijeva podjelu istraživane prostorne pojave u određene tipove, odnosno skupove tih pojava objedinjenih prema zadanim znanstvenim kriterijima. Kao recentni primjer tipologije u geografiji može se navesti Lukićeva (2009) vrlo iscrpna i sveobuhvatna tipologija ruralnih naselja Republike Hrvatske provedena na temelju multifaktorske analize socioekonomskih podataka i podataka o funkcijama naselja.

Klasifikacija zemljišnog pokrova može se provesti prema zahtjevima različitih znanstvenih disciplina ili pojedinačnih naručitelja, kao što su državne službe ili privatna poduzeća, te se može provesti na temelju različitih izvora podataka, ali je svima zajednička upotreba geografskih podataka, odnosno položajem, smještajem i veličinom definiranog entiteta na Zemljinoj površini.

Reprezentativan primjer provedene klasifikacije zemljišnog pokrova koji se u Republici Hrvatskoj često upotrebljava u upravne, službene i znanstvene svrhe jest, u tekstu prije navedeni program CORINE. Odluku o pokretanju tog projekta donijela je Europska komisija 1985. godine s ciljem prikupljanja podataka o stanju okoliša u tadašnjoj Europskoj zajednici (85/338/EEC). Jedan od razloga za uspostavu takvog projekta bilo je usklađivanje brojnih i vrlo različitih nacionalnih sustava za klasifikaciju zemljišnog pokrova i načina korištenja zemljišta. Kako bi se omogućila usporedivost i dosljednost podataka među državama članicama zajednice izrađena je jedinstvena klasifikacijska shema i metodologija prikupljanja podataka o zemljišnom pokrovu, odnosno pokrovu zemljišta prema terminologiji hrvatske sastavnice

CORINE projekta. Dodatna je prednost CORINE-a vremensko trajanje samog programa i ažuriranje baza podataka o zemljišnom pokrovu, na temelju kojih se mogu pratiti promjene okoliša. Izvor podataka za klasifikaciju su satelitske snimke, a s vremenom se mijenjala upotreba pojedinih satelitskih sustava. Podaci iz baze CLC1990 temelje se na snimkama Landsata-5, iz baze CLC2000 na Landsatu-7, iz baze CLC2006 na satelitima SPOT 4/5 i IRS P6 te naposljetku iz baze CLC2012 na satelitima IRS P6 i RapidEye (Copernicus, 2014). Dakle, za izradu svih baza podataka upotrijebljeni su sateliti sa senzorima za multispektralno snimanje Zemljine površine. Podaci o zemljišnom pokrovu dobivaju se vizualnom interpretacijom satelitskih snimaka i njihovom digitalizacijom u računalnim programima za GIS. Tijekom cijelog trajanja programa primjenjuju se isti kriteriji za izradu prostornih podataka prema kojima je najmanja jedinca kartiranja (engl. *minimum mapping unit*, krat. *MMU*) površine 25 ha, a minimalna širina 100 m. U posljednjoj fazi CORINE klasifikacije zemljišnog pokrova sudjelovalo je 39 država. (AZO, 2010).

Daljinska istraživanja se već dugo vremena upotrebljavaju kao izvor podataka za klasifikaciju zemljišnog pokrova. Tradicionalnim metodama ljudske vizualne interpretacije zračnih snimaka s razvojem znanosti i tehnologije pridružile su se metode računalne obrade i klasifikacije digitalnih podataka dobivenih snimanjem Zemljine površine iz svemira. Bez obzira na specifičnu tehniku prikupljanja podataka, riječ je o snimanju elektromagnetskog zračenja pristiglog sa Zemljine površine na senzor. Suvremena klasifikacija zemljišnog pokrova na temelju takvih snimaka provodi se analizom i obradom digitalnih zapisa elektromagnetskog zračenja koji predstavljaju stvarne pojave sa Zemljine površine. Detekcija, identifikacija i klasifikacija određenih tvari i materijala iz uvjetno rečeno prirodnog i umjetnog okoliša, odnosno krajolika temelji se na njihovom jedinstvenom spektralnom potpisu (engl. *spectral signature*).

Prethodno navedene razlike klasifikacije zemljišnog pokrova i klasifikacije načina korištenja zemljišta povezane su s različitim značenjima koje se mogu pripisati analiziranim podacima. Pripisivanjem značenja, koje je proizvod ljudskih kognitivnih procesa – razumijevanja i interpretacije okoliša, tzv. spektralnim klasama detektiranima na snimci, stvaraju se informacijske klase kao konačne, smislene i razumljive klase zemljišnog pokrova. Taj postupak često predstavlja značajan izazov klasifikacijama zemljišnog pokrova i načina korištenja zemljišta jer su podaci dobiveni daljinskim istraživanjima zapravo surogat pravim traženim varijablama (Donnay i dr., 2001).

Tab. 1. Dio strukture tipova pokrova zemljišta prema CORINE programu (11 od ukupno 44 na Razini 3).

RAZINA 1		RAZINA 2		RAZINA 3	
Kod	Naziv	Kod	Naziv	Kod	Naziv
1	Čovjekom utjecane površine	11	Naseljena područja	111	Naselja (> 80% izgrađeno)
				112	Naselja (< 80% izgrađeno)
		12	Industrijske, poslovne i prometne površine	121	Industrijski ili poslovni prostori
				122	Prometnice s pripadajućim zemljištem
				123	Luke s pripadajućim zemljištem
				124	(Zračne luke) s pripadajućim zemljištem
		13	Rudokopi, odlagališta i gradilišta	131	Rudokopi
				132	Odlagališta otpada
				133	Gradilišta
		14	Umjetna, ne poljoprivredna vegetacija	141	Gradsko zelenilo
				142	Sportski i rekreacijski objekti

Izvor: AZO, 2010.

Dakle, znanstvene osnove za značajan dio mjerenja u daljinskim istraživanjima su spektrometrija (spektroskopija) i radiometrija. Za razliku od laboratorijskih mjerenja, instrumenti u daljinskim istraživanjima bilježe podatke o objektu proučavanja, kao što već sam naziv kaže, s određene veće udaljenosti. Nužno je dodatno naglasiti razliku klasifikacija zemljišnog pokrova i klasifikacija materijala ili tvari koji se mogu pronaći u urbanom prostoru. Materijali koji čine izgrađena urbana područja i tvari koje se mogu u njemu zateći, pojavljuju se u mnoštvu prerađenih oblika. Također, oni mijenjaju svoja spektralna svojstva s protokom vremena zbog trošenja uzrokovanog njihovom upotrebom ili klimatskim uvjetima. Vjerojatno najzorniji svakodnevni primjer su asfaltirane površine, čija je promjena boje zbog starenja materijala vrlo očita i ljudskom vidu. Jedna klasa zemljišnog pokrova može obuhvaćati vrlo različite materijale, ali isto tako slični se materijali mogu pronaći u vrlo različitim klasama zemljišnog pokrova. Zbog toga je moguća vrlo pogrešna klasifikacija zemljišnog pokrova uz istovremenu točnu klasifikaciju materijala prisutnih u okolišu (Herold i dr., 2003, 2004, 2006; Herold i Roberts, 2010).

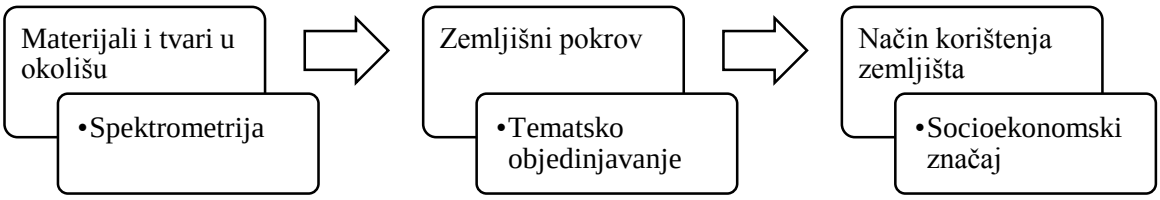

Sl. 1. Porast značenjske složenosti klasifikacije sadržaja Zemljine površine. Izvor: autor.

Važan čimbenik klasifikacije zemljišnog pokrova također je miješanje spektralnih potpisa koje ovisi o razini ili mjerilu istraživanja prostora (Price, 1997; Herold i dr., 2006). Najmanju jedinice promatranog prostora u slučaju satelitskih i zračnih snimaka čini najmanji element slike, odnosno piksel te se može pretpostaviti da će s povećanjem njegovih dimenzija porasti i mogućnost miješanja spektralnih uzoraka različitih tvari prisutnih na većem području koje on prikazuje.

Zbog brojnosti različitih metoda klasifikacija podataka prikupljenih daljinskim istraživanjima, njihov pregled i opis nadilazi opseg ovog rada. Detaljnu kategorizaciju metoda klasifikacija slikovnih podataka koje se primjenjuju u daljinskim istraživanjima nude Lu i Weng

(2007) i Weng (2010). Za potrebe ovog istraživanja dovoljno je podijeliti metode klasifikacija u tipove nadzirane i nenadzirane klasifikacije, prema uključenosti operatera klasifikacije u postupak obrade i analize snimke, te prema elementima digitalne slike koji čine osnovne jedinice klasifikacije.

Prema prvoj podjeli, klasifikacije se mogu definirati kao nadzirane i nenadzirane. Nadzirani tip klasifikacije (engl. *supervised classification*) podrazumijeva primjenu ljudskog znanja i tumačenja spektralnih i prostornih informacija od samog početka postupka klasifikacije, a ona se najčešće očituju prilikom odabira uzoraka pojedinih klasa. Primjenom nenadziranih metoda klasifikacija (engl. *unsupervised classification*), inicijalna podjela podataka u klase prepušta se računalnim algoritmima, a njihova analiza, sinteza i upotreba ovisit će o daljnjoj ljudskoj interpretaciji informacija (Lillesand i dr., 2004; Campbell i Wynne, 2011; Richards, 2013).

Druga podjela metoda klasifikacija u daljinskim istraživanjima u tipove moguća je na temelju pristupa osnovnoj jedinici klasifikacije. Slikovni elementi ili pikseli čine osnovnu jedinicu digitalne slikovne datoteke. Tradicionalni i najčešće korišteni tip klasifikacije provodi se na osnovi brojčanih vrijednosti zapisanih u svakom pojedinom pikselu. Unutar granica svakog piksela prisutno je miješanje spektralnih potpisa tvari koje se nalaze na području koje on prikazuje. Osim o samoj heterogenosti snimljene površine, spektralno će miješanje ovisiti o površinskoj razlučivosti snimke, odnosno o veličini površine koju pojedini piksel predstavlja. Budući da je tijekom povijesti daljinskih istraživanja odnos ciljanog predmeta istraživanja i površinske razlučivosti često bio nepovoljan, razvijene su metode klasifikacije koje nastoje uzeti u obzir sastav pojedinih piksela te na taj način omogućiti analizu ispod razine jednog piksela snimke (engl. *subpixel based classification*). Heterogenost prostora proučavanja je često bila razlog za objedinjavanje piksela u skupine ili polja (engl. *per-field classification*), a za granice tih polja upotrebljavani su vektorski slojevi podataka, odnosno pomoćni podaci iz geografskih informacijskih sustava. S druge strane, s razvojem instrumenata velike površinske razlučivosti, tendencija znanstvenih istraživanja bila je usmjerena na razvoj novih metoda klasifikacije na temelju skupina piksela. Algoritmi za segmentaciju digitalnih slika omogućili su podjelu snimaka na segmente ili relativno homogene skupine piksela. Podjela piksela snimke u segmente, odnosno objekte (engl. *object-oriented classification*), može se izvršiti na osnovi brojčanih vrijednosti piksela, bez upotrebe pomoćnih podataka (Lu i Weng, 2007; Weng, 2010).

Ovisno o instrumentu za daljinska istraživanja, ta se mjerenja elektromagnetskog zračenja u suvremenim sustavima bilježe kao digitalni podaci u više slojeva snimaka, odnosno kanala. Arbitrarno dodijeljeno nazivlje takvih snimaka označava brojnost spektralnih kanala. Pankromatska snimka podrazumijeva jedan kanal, multispektralna ili višespektralna više od jednog kanala, a hiperspektralna više desetaka kanala.

2.3. Multispektralne satelitske snimke

Termin multispektralne ili višespektralne satelitske snimke upotrebljava se za vrstu slikovnih podataka nastalih primjenom daljinskih istraživanja površine planeta iz njegove orbite. Satelit koji služi kao platforma za mjerne instrumente, kruži ili je stacionarno postavljen na određenoj udaljenosti iznad površine planeta te na taj način pruža mogućnost snimanja manjih područja ili cijele hemisfere. Multispektralnim senzorima prikupljaju se podaci o promatranom prostoru iz više odvojenih dijelova spektra elektromagnetskog zračenja te se zatim spremaju u digitalnom obliku u više kanala ili slojeva slikovne datoteke. Mogućnosti detekcije i identifikacije pojedinih tvari pomoću daljinskih istraživanja ovisit će o tehničkim značajkama senzora koji određuju broj snimljenih dijelova spektra, raspon valnih duljina obuhvaćenih pojedinim kanalom snimke, raspon brojčanih vrijednosti koje se mogu dodijeliti slikovnim elementima ili pikselima te minimalne dimenzije područja, odnosno snimljene površine koju može biti obuhvaćena u okviru jednog piksela.

Zbog različitog međudjelovanja energije i materije, pri različitim valnim duljinama elektromagnetskog zračenja, tvari iz okoliša u nekoj određenoj mjeri reflektiraju ili emitiraju zračenje. Prema takvoj njihovom specifičnom svojstvu, odnosno spektralnom potpisu, materijali ili tvari mogu se prepoznati i izdvojiti unutar promatranog okoliša. Na temelju znanja i informacija o spektralnim značajkama pojedinih objekata ili geografskih entiteta provodi se vizualna interpretacija satelitskih snimaka ili njihova računalna obrada i analiza.

S povećanjem broja kanala ili slojeva snimke moguće je promatrati prostor u više zasebnih dijelova spektra i to bi svojstvo senzora trebalo doprinijeti kvalitetnijoj analizi zabilježenih podataka. Veličina razreda određenog kanala snimke definirana valnom duljinom ili frekvencijom elektromagnetskog zračenja povezana je s njihovom brojnošću. Prema tome, s povećanjem spektralne razlučivosti raste broja kanala, elektromagnetski spektar se dijeli u

manje razrede ili pojednostavljeno rečeno, kanali snimke se sužavaju. Budući da se signal iz senzora pretvara u digitalnu slikovnu datoteku, bitno svojstvo multispektralnih snimaka je broj digitalnih podatkovnih jedinca – bita, s kojima se raspolaže. Veći broj bita, odnosno veća radiometrijska razlučivost, omogućuje veći raspon vrijednosti unutar kojih je moguće zabilježiti izmjereno zračenje. Logična pretpostavka je da se s povećanjem tog raspona povećava kvaliteta snimaka i mogućnosti njihove računalne obrade. Naposljetku, ljudskom oku najočitije svojstvo satelitskih snimaka i digitalnih slikovnih datoteka općenito jest dvodimenzionalna prostorna razlučivost ili površinska razlučivost koja uvjetuje razinu ili prag minimalne veličine objekata koja je nužna za njihovo izdvajanje na slici. Svaki piksel unutar snimke predstavlja određenu mjeru stvarne snimljene površine te je unutar tako definiranih njegovih dimenzija i kanala snimke u kojem se nalazi zabilježena cjelokupna složenost elektromagnetskog zračenja uvjetovana heterogenošću trodimenzionalnog prostora koji se nalazi između senzora i objekta istraživanja. Pri tome valja imati na umu ne samo na različitosti Zemljine površine unutar određene prostorne jedinice, već i sve ostale čimbenike koji utječu na odnos signala i šuma, među kojima se posebno može istaknuti vrlo značajan atmosferski utjecaj na daljinska istraživanja.

2.4. Prostorni obuhvat – Grad Zagreb

Istraživanje je provedeno za područje upravne jedinice Grada Zagreba. Posebnost te upravno-teritorijalne jedinice jest ta što se ona može istraživati usporedno na razinama županija te općina i gradova Republike Hrvatske. Prema oblicima mjesne samouprave, Grad Zagreb može se podijeliti na gradske četvrti i mjesne odbore. Gradske četvrti Grada Zagreba predstavljaju posebnost u upravnoj podjeli Republike Hrvatske. Ukupno 17 gradskih četvrti i 218 mjesnih odbora čini teritorij Grada Zagreba s površinom 641,32 km^2 (GUKGP, 2013; SLjZ, 2013, 30, 46; Zagreb.hr, 2014). Područja mjesnih odbora mogu se objediniti u gradske četvrti, odnosno granice njihovih područja se podudaraju. U odnosu na gradske četvrti oni čine drugu razinu mjesne samouprave. Mjesna samoupravna podjela Grada Zagreba i granice samoupravnih područja temelje se na Statutu Grada Zagreba i odlukama Gradske skupštine Grada Zagreba (SGGZ, 07/09). Kronološki pregled suvremenog ustrojstva Grada Zagreba od 1990. godine može se pronaći u Statističkom ljetopisu Grada Zagreba (SLjZ, 2013, 43).

Druge podjele Grada Zagreba moguće su prema ostalim tipovima jedinica iz registra prostornih jedinica, koji osim upravo spomenutih upravnih oblika, navodi još: naselja, katastarske općine, statističke i popisne krugove, ulice i trgove te kućne brojeve. Podaci su određeni Zakonom o državnoj izmjeri i katastru nekretnina (NN 16/07; NN 124/10) i Pravilnikom o registru prostornih jedinica (NN 37/08). Za ovo istraživanje upotrijebljeni su još podaci o prostornim jedinicama na razini naselja. Prema Pravilniku o registru prostornih jedinica, naselja se definiraju kao „prostorne antropogeografske jedinice koje se sastoje od građevinskog područja i područja za druge namjene." Prostorne jedinice u registru se dijele na normativne ili institucionalne te stručne ili funkcionalne ili tehničke. Gradske četvrti i mjesni odbori spadaju u prvu skupinu, dok naselja spadaju u drugu skupinu prostornih jedinica prema takvoj podjeli. Područje Grada Zagreba tvori 70 naselja (SLjZ, 2013, 48).

Grad Zagreb smješten je u rubnom jugozapadnom dijelu Panonske zavale. Dva osnovna tektonska pravca koja se križaju i na taj način reljefno definiraju prostor Grada Zagreba su žumberačko-medvedničko-kalnički, koji se pruža u smjeru jugozapad-sjeveroistok, te savski koji se pruža u smjeru sjeverozapad-jugoistok. Prostor Grada Zagreba čine većinom nizinski krajevi do 200 m nadmorske visine. Ipak, njegov sjeverni dio čini brdski i gorski reljef Medvednice, s najvišom točkom Sljeme koja se nalazi na 1035 m nadmorske visine (SLjZ, 2013, 30). Valja napomenuti da se sjeverna granica upravnog područja Grada Zagreba nalazi upravo na glavnom grebenu Medvednice. Promatrajući prostor od grebena Medvednice do rijeke Save, u njemu su zastupljene strme padine, valovito visogorje raščlanjeno dolinama gorskih protoka, terasne uzvisine te naposljetku prostrana aluvijalna nizina. Na jugu Grada Zagreb, reljefno se mogu izdvojiti Vukomeričke gorice s njihovim brežuljkastim prostorom. Zagreb se smatra izrazito nizinskim gradskim naseljem jer se najveći dio urbaniziranog područja nalazi na nadmorskim visinama od 110 do 125 m. Akumulacijskom i denudacijskom aktivnošću vodotoka nastale su naplavne nizine s polojima i riječne terase, među kojima se ističu savska naplavna ravan te veća terasna nizina južno od rijeke Save, izdužena u prostoru od Samobora do Siska. Brdska područja Grada Zagreba čine predgorska stepenica i pobrđe Medvednice na kojem se izmjenjuju usporedna uzvišenja i potočne doline (Bognar, 1992; Bertić, 1994). Nagibi padina i smjer njihovog pružanja utječu na zemljišni pokrov analiziranog područja, ali i na mjerenja elektromagnetskog zračenja dobivenih daljinskim istraživanjima.

Tab. 2. Udjeli visinskih razreda u ukupnoj površini Grada Zagreba.

Nadmorske visine (m)	≤ 200	201-300	301-400	401-500	501-600	601-700	701-800	801-900	901-1000	≥ 1001
Površinski udio (%)	68	14	7,14	4,11	2,44	1,81	1,30	0,87	0,32	0,02

Izvor: DMR, 2012.

Svi vodotoci koji se nalaze na području Grada Zagreba pripadaju porječju rijeke Save. Uzvodno i nedaleko od Grada Zagreba, rijeka Sava poprima obilježja nizinske rijeke. Prema režimu protjecanja vode kroz područje Grada Zagreba, rijeka Sava pripada snježno-kišnom tipu. Minimum protjecanja traje od srpnja do rujna te je posljedica ljetnih suša. Niski vodostaj rijeke Save vidljiv je na satelitskim snimkama upotrijebljenim u ovom istraživanju te se on bez sumnje odrazio na konačni rezultat klasifikacije zemljišnog pokrova. Prema hidrološkom izvještaju za 18. rujna 2011. (DHMZ, 2011), dva dana nakon nastanka upotrijebljenih snimaka, zabilježen je dotad najniži apsolutni vodostaj na hidrološkoj stanici Rugvica (-242 cm), a u stanicama Zagreb i Podsused su također zabilježeni niski vodostaji (-291 i -241 cm). Većina naseljenog i izgrađenog područja u Gradu Zagrebu nalazi se sjeverno od rijeke Save. Tok rijeke Save kroz Grad Zagreb reguliran je, a neposredni prostor oko korita rijeke čini inundacijski pojas koji nije naseljen, niti u njemu ima izgrađenih područja. Značajne oscilacije vodostaja i prostrana nizinska područja s obje strane rijeke bila su prije regulacije toka i izgradnje nasipa uzrokom čestih poplava. Dio zagrebačkog sustava za zaštitu od poplava čini i odvodni ili odteretni kanal Sava-Odra. Navedeni hidrotehnički zahvati u prostoru omogućili su daljnju plansku izgradnju naselja u Gradu Zagrebu uz smanjenu bojazan od katastrofalnih poplava, ali su ujedno i uvjetovali daljnje formiranje morfološko-fizionomske strukture grada. Među hidrografskim posebnostima Grada Zagreba valja spomenuti gorske potoke koji teku s Medvednice prema Savi koji svojim naglim bujanjem i izlijevanjem iz korita mogu prouzročiti štetu u susjednom naseljenom području. Iako je prostor Zagreba ispresijecan brojnim potocima, većina njih ne dolazi jasno do izražaja u gradskom krajoliku jer su prekriveni izgrađenim površinama ili im je tok do rijeke Save kanaliziran. Među stajaćim površinskim vodama prevladavaju vode nastale ljudski djelovanjem, poput šljunčara i umjetnih jezera (Bertić, 1994: SLjZ, 2013, 64).

Klima Grada Zagreba je umjereno kontinentalna. Zimsko tmurno vrijeme posljedica je anticiklona koje se razvijaju nad kontinentom, a vremenske promjene s obilnim padalinama

uzrokovane su općenito južnim i jugozapadnim zračnim masama (Bertić, 1994). Ukupni zbroj mjesečnih vrijednosti trajanja osunčavanja za postaju Maksimir u razdoblju 1949.-2013. jest 1919,6 sati. Broj vedrih dana u godini za istu postaju i isto razdoblje jest 49. Snijeg je kao padalina uobičajena pojava u Gradu Zagrebu, a postaja Maksimir za navedeno razdoblje zabilježila zbroj mjesečnih vrijednosti od 22 dana sa snijegom. Postaja Grič u razdoblju 1861.-2013. zabilježila je podatke: 1851 sati trajanja osunčavanja, 58 vedrih dana i 23 dana sa snijegom (Klima.hr, 2014). Spomenute bi klimatske podatke trebalo uzeti u obzir kad je riječ o razmatranju mogućnosti upotrebe daljinskih istraživanja za opetovano ili redovito praćenje i analizu zadanog područja te njihovu praktičnu primjenu.

U svojem izvornom prirodnom obliku područje Grada Zagreba vegetacijski šumskoj zoni te pripada eurosibirskoj-sjevernoameričkoj šumskoj regiji (Enciklopedija.hr). Zbog izgradnje naselja i poljoprivrednih djelatnosti veći je dio šumskih površina iskrčen. Ako šumski pokrov nisu zamijenile izgrađene ili nepropusne površine, na njihovom su mjestu sada kultivirane nešumske površine ili staništa s korovnom i ruderalnom vegetacijom (DZZP, 2013). Najveći dio očuvanih prirodnih šumskih zajednica nalazi se unutar područja Parka prirode „Medvednica“, osnovanog 1981. godine, koji zauzima središnje i zapadno područje gore (Valožić i Cvitanović, 2011). Brežuljkasta područja pokrivena su šumama hrasta kitnjaka i običnog graba koje u cijelom podnožju okružuju Medvednicu. Iznad 300 m nadmorske visine rastu šume hrasta kitnjaka i pitomog kestena, a na prisojnim stranama uzvišenja pojavljuju se šume hrasta kitnjaka s runjikom. U području iznad šuma kitnjaka pojavljuju se šume bukve koje imaju najveći površinski udio na Medvednici. Miješana šuma bukve i jele dolazi do izražaja na nadmorskim visinama iznad 800 m. Na manjim vlažnim i hladnim područjima vršnog pojasa mjestimično se pojavljuje šuma gorskog javora i običnog jasena. Na nekoliko lokacija na vapnenačkoj podlozi prisutna je reliktna šumska zajednica lipe i tise. Na karbonatnoj podlozi južnih padina rastu šume hrasta medunca i crnog jasena kao i hrasta kitnjaka s crnim grahorom (Bertić, 1994; PP-Medvednica.hr, 2014).

Za ovo istraživanje upotrijebljeni su podaci o gradskim četvrtima, mjesnim odborima i naseljima Grada Zagreba. Treba napomenuti da se područja tih različitih razina ne mogu jednostavno objedinjavati na temelju hijerarhijskih odnosa jer se njihove granice ne podudaraju. Drugim riječima, granice naselja dijele područja nekih gradskih četvrti ili mjesnih odbora u više dijelova (Zagreb.hr, 2014).

Budući da je jedna od namjera ovog istraživanja bila povezivanje podataka prikupljenih daljinskim istraživanjima s podacima o stanovništvu dobivenih Popisom stanovništva 2011., potrebno je navesti neke od demografskih podataka o Gradu Zagrebu iz 2011. godine. Prema navedenom popisu stanovništva, Grad Zagreb je imao 790.017 stanovnika, 303.441 kućanstava i 384.333 stanova. Naselje Zagreb koje je čini dio upravne jedince Grad Zagreb, najmnogoljudnije je sa svojih 688.163 stanovnika. Drugu krajnost predstavlja naselje Botinec sa samo 9 stanovnika, ali pri tome treba obratiti pozornost na granice područja prostorne jedinice naselja na koje se taj broj stanovnika odnosi. Promatrano na razini gradskih četvrti, mogu se izdvojiti gradske četvrti s najvećim i najmanjim brojem stanovnika, Sesvete s 70.009 i Brezovica s 12.030. Među mjesnim odborima također se mogu naglasiti razlike u naseljenosti ako se spomenu Prečko s 13.695 i Havidići sa samo 53 stanovnika. Potpuni podaci o točnom broju stanovnika ostalih naselja kao i gradskih četvrti te mjesnih odbora priloženi su u tabličnom obliku (GUSPRG, 2014).

Tab. 3. Broj stanovnika, površine i gustoće naseljenosti gradskih četvrti Grada Zagreba 2011. godine.

Gradska četvrt		Broj stanovnika	Površina (km^2)	Gustoća naseljenosti (stan./km^2)
I.	Donji Grad	37024	3,02	12259,60
II.	Gornji Grad-Medveščak	30962	10,19	3038,47
III.	Trnje	42282	7,36	5744,84
IV.	Maksimir	48902	14,97	3266,67
V.	Pešćenica-Žitnjak	56487	35,3	1600,20
VI.	Novi Zagreb-istok	59055	16,54	3570,44
VII.	Novi Zagreb-zapad	58103	62,64	927,57
VIII.	Trešnjevka-sjever	55425	5,81	9539,59
IX.	Trešnjevka-jug	66674	9,84	6775,81
X.	Črnomerec	38546	24,23	1590,84
XI.	Gornja Dubrava	61841	40,26	1536,04
XII.	Donja Dubrava	36363	10,81	3363,83
XIII.	Stenjevec	51390	12,18	4219,21
XIV.	Podsused-Vrapče	45759	36,16	1265,46
XV.	Podsljeme	19165	59,43	322,48
XVI.	Sesvete	70009	165,25	423,66
XVII.	Brezovica	12030	127,33	94,48

Izvor: GUSPRG, 2014.

U prostoru obuhvaćenim ovim istraživanjem nalaze se brojne, prema fizičkim svojstvima različite i složene klase zemljišnog pokrova. Današnja izgrađena područja rezultat su višestoljetne izgradnje naselja. Tijekom te izgradnje upotrebljavane su različite biljne i mineralne sirovine te metalni i sintetički materijali. Prirodne površine mogu biti jednako tako složene jer se unutar određenog promatranog područja mogu miješati različiti zemljišni pokrovi poput fotosintetske i nefotosintetske vegetacije, voda ili tala različitog sastava i vlažnosti.

Tab. 4. Broj stanovnika, površine i gustoće naseljenosti naselja Grada Zagreba 2011. godine.

Naselje	Broj stanovnika	Površina (km^2)	Gustoća naseljenosti (stan./km^2)
Adamovec	975	7,78	125,32
Belovar	378	3,58	105,59
Blaguša	594	5,80	102,41
Botinec	9	0,35	25,71
Brebernica	49	2,52	19,44
Brezovica	594	4,50	132,00
Budenec	323	2,83	114,13
Buzin	1055	3,22	327,64
Cerje	398	1,21	328,93
Demerje	721	10,23	70,48
Desprim	377	0,50	754,00
Dobrodol	1203	4,32	278,47
Donji Čehi	232	1,72	134,88
Donji Dragonožec	577	3,35	172,24
Donji Trpuci	428	10,01	42,76
Drenčec	131	2,09	62,68
Drežnik Brezovički	656	0,70	937,14
Dumovec	903	3,27	276,15
Đurđekovec	778	2,80	277,86
Gajec	311	2,40	129,58
Glavnica Donja	544	6,84	79,53
Glavnica Gornja	226	1,59	142,14
Glavničica	229	4,31	53,13
Goli Breg	406	2,09	194,26
Goranec	449	3,29	136,47
Gornji Čehi	363	2,15	168,84
Gornji Dragonožec	295	3,11	94,86
Gornji Trpuci	87	3,62	24,03
Grančari	221	0,94	235,11
Havidić Selo	53	1,95	27,18
Horvati	1490	20,77	71,74
Hrašće Turopoljsko	1202	2,74	438,69
Hrvatski Leskovac	2687	3,33	806,91

Naselje	Broj stanovnika	Površina (km^2)	Gustoća naseljenosti (stan./km^2)
Hudi Bitek	441	1,93	228,50
Ivanja Reka	1800	3,37	534,12
Jesenovec	460	2,72	169,12
Ježdovec	1728	7,71	224,12
Kašina	1548	8,37	184,95
Kašinska Sopnica	245	2,15	113,95
Kučilovina	219	2,46	89,02
Kućanec	228	0,22	1036,36
Kupinečki Kraljevec	1957	26,02	75,21
Lipnica	207	3,53	58,64
Lučko	3010	2,58	1166,67
Lužan	719	7,32	98,22
Mala Mlaka	636	3,98	159,80
Markovo Polje	425	2,35	180,85
Moravče	663	6,91	95,95
Odra	1866	13,11	142,33
Odranski Obrež	1578	10,91	144,64
Paruževina	632	3,80	166,32
Planina Donja	554	4,86	113,99
Planina Gornja	247	6,82	36,22
Popovec	937	2,59	361,78
Prekvršje	809	2,51	322,31
Prepuštovec	332	2,17	153,00
Sesvete	54085	36,19	1494,47
Soblinec	978	2,58	379,07
Starjak	227	2,15	105,58
Strmec	645	13,26	48,64
Šašinovec	678	10,16	66,73
Šimunčevec	271	2,00	135,50
Veliko Polje	1668	1,23	1356,10
Vuger Selo	273	1,43	190,91
Vugrovec Donji	442	0,49	902,04
Vugrovec Gornji	357	2,08	171,63
Vurnovec	201	0,95	211,58
Zadvorsko	1288	2,12	607,55
Zagreb	688163	305,96	2249,19
Žerjavinec	556	2,42	229,75

Izvor: GUSPRG, 2014.

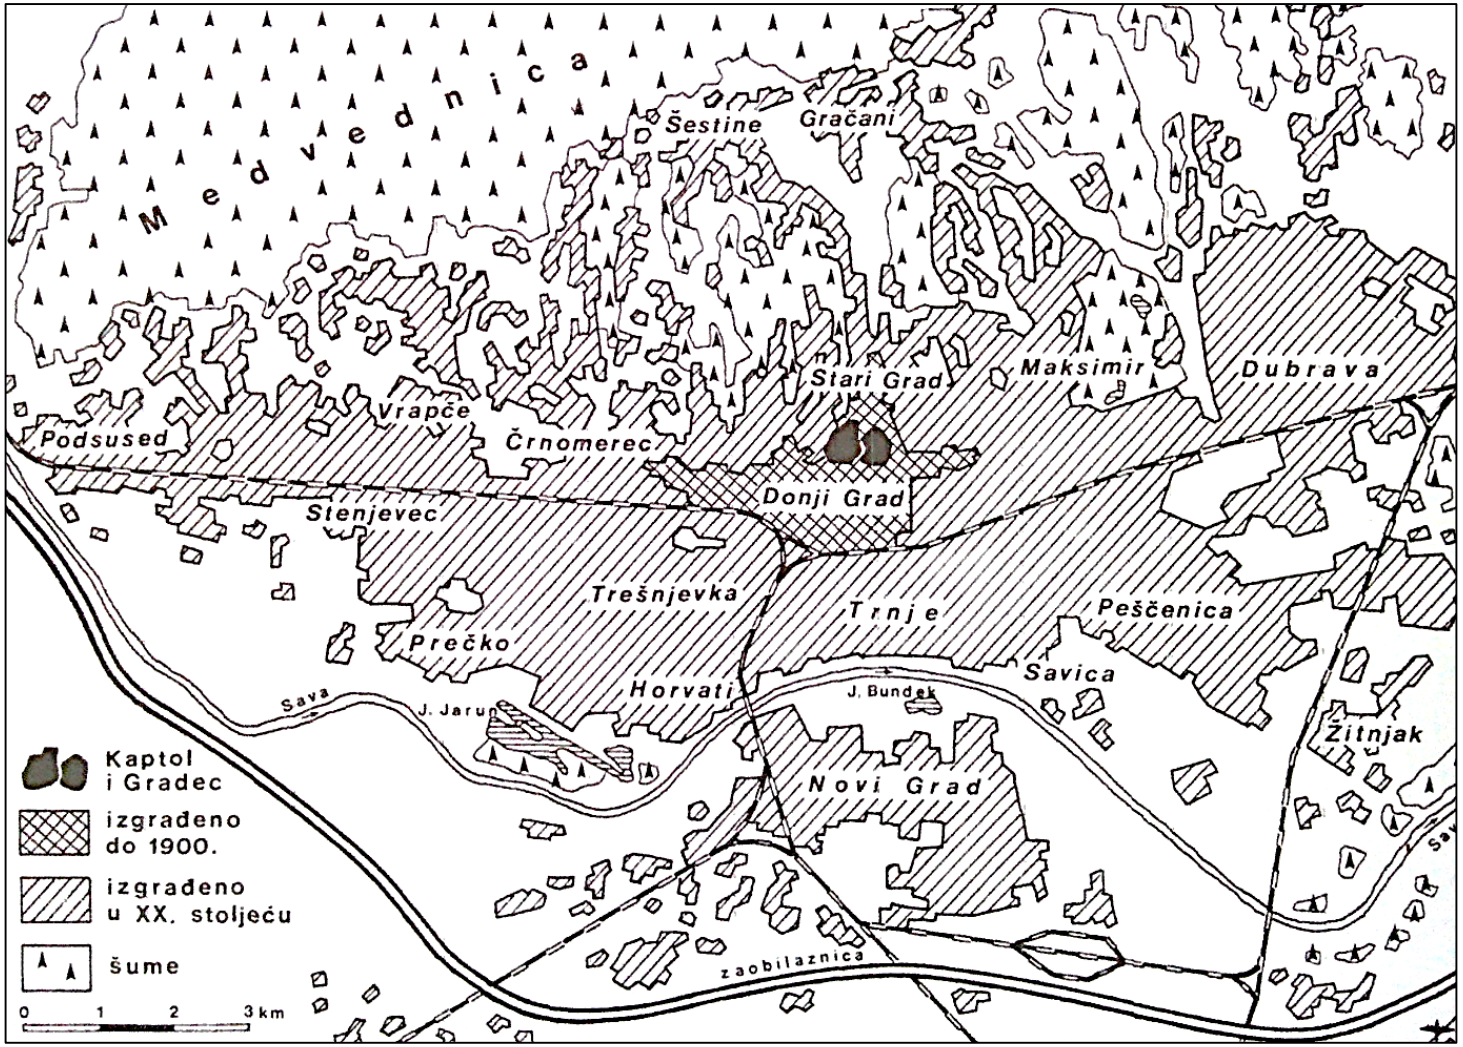

Sl. 2. Faze širenja izgrađenih površina u Zagrebu. Izvor: Bertić, 1994, 10.

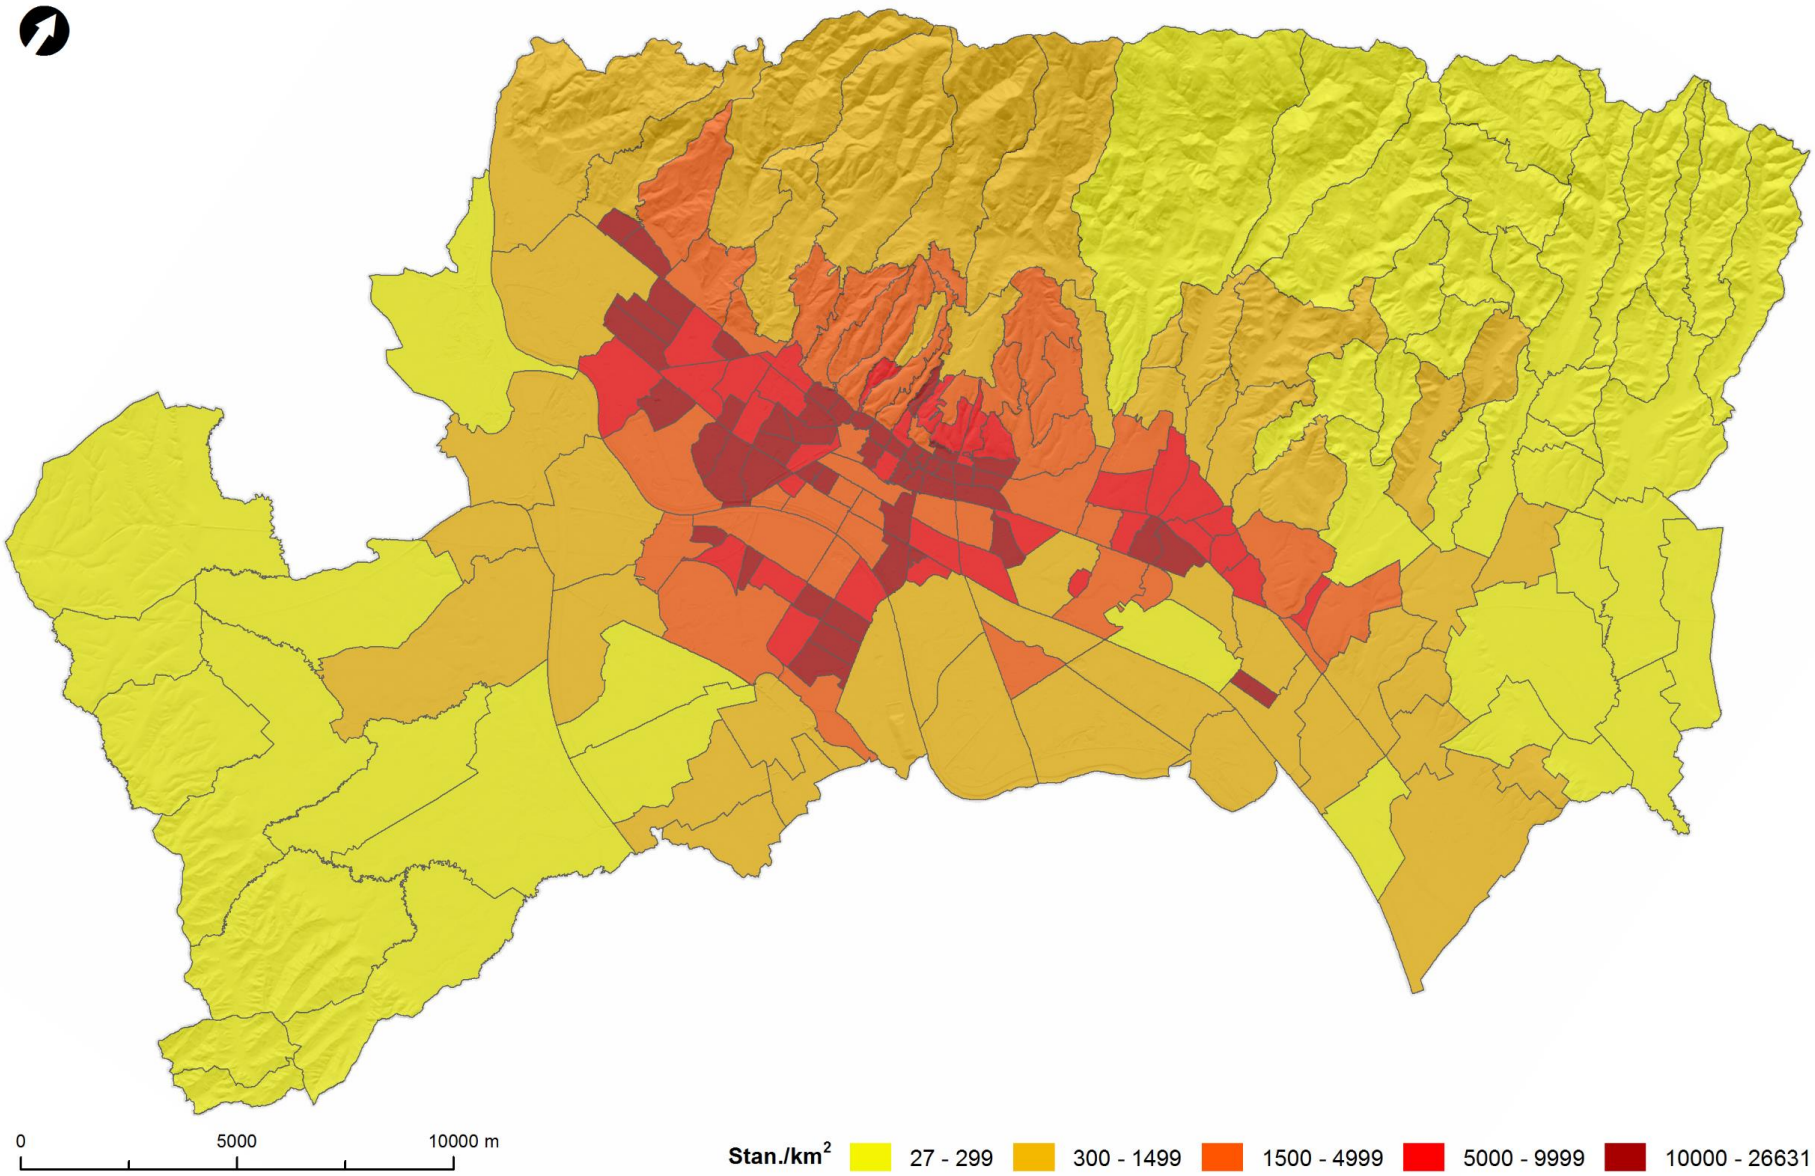

Sl. 3. Gustoća naseljenosti Grada Zagreba na razini mjesnih odbora prema Popisu stanovništva 2011. godine.
Izvor: autor na temelju podataka: RPJ, 2011; DMR, 2012; GUSPRG, 2014.

3. CILJEVI I HIPOTEZA ISTRAŽIVANJA

3.1. Ciljevi istraživanja

Glavni cilj istraživanja je dokazivanje mogućnosti provođenja uspješne klasifikacije zemljišnog pokrova urbanog i periurbanog područja upravne prostorne jedinice Grada Zagreba. Uspješnost klasifikacije definirana je minimalnom ukupnom točnošću klasifikacije od 85%. Točnost klasifikacije ocjenjuje se pomoću matrice pogrešaka u kojoj se uspoređuju klasificirani i referentni podaci.

Ciljana minimalna ukupna točnost klasifikacije od 85 do 90% jedan je od kriterija koji se navode u Andersonovom radu o klasifikacijskim shemama za klasifikaciju načina korištenja zemljišta upotrebom daljinskih istraživanja (Anderson, 1971). Kako bi metode klasifikacije pomoću daljinskih istraživanja i klasifikacijske sheme upotrijebljene u tu svrhu mogle uopće biti uspoređivane s tadašnjim standardiziranim metodama inventarizacije prostora, trebalo se približiti njihovim razinama točnosti od 90 do 95%. Konkretno, u navedenom je radu riječ o točnosti ondašnjih podataka o načinu korištenja zemljišta koje je popisivanjem svakih pet godina prikupljao američki Popisni ured za potrebe objavljivanja Popisa poljoprivrede. Klasifikacijske sheme u kontekstu tog rada trebale su poslužiti za potrebe Sjedinjenih Američkih Država u kartografskim mjerilima od 1:250.000 do 1:1.000.000. Taj je kriterij točnosti klasifikacije (> 85%) dio skupine kriterija za evaluaciju koji su tijekom 1970-ih trebali poslužiti kao smjernice budućeg razvoja civilnih daljinskih istraživanja. Ovdje treba napomenuti da je satelit Landsat-1 (ERTS-1) lansiran u orbitu 1972. godine (Kramer, 2002). Kriterij ili prag od 85% točnosti klasifikacije zemljišnog pokrova i tematskog kartiranja također se spominje u europskom CORINE programu kao pokazatelj kvalitete podataka (Copernicus, 2014).

Dakle, primarni je cilj istraživanja postizanje ukupne točnosti klasifikacije s minimalnom vrijednošću od 85%. Sekundarni cilj je uravnotežena točnost klasifikacije. Ona se očituje u malim razlikama točnosti klasifikacije za svaku pojedinu upotrijebljenu klasu zemljišnog pokrova. To je ujedno i drugi kriterij kojeg Anderson (1971) navodi za evaluaciju klasifikacijskih shema za klasifikaciju načina korištenja zemljišta.

Ciljane klase u klasifikaciji zemljišnog pokrova ovog istraživanja su: vegetacija, izgrađene površine, tla i vode. Sve podklase koje mogu nastati tijekom postupaka klasifikacije

objedinjuju se u prethodno navedene klase zemljišnog pokrova te se neće zasebno mjeriti i kartirati u ovom istraživanju. Takva je klasifikacija usklađena s V-I-S modelom za analizu urbanih ekosustava (Ridd, 1995). Taj model nudi mogućnost jednostavne usporedbe različitih prostornih jedinica na temelju apsolutnih vrijednosti površina pod određenim zemljišnim pokrovom ili udjela koje čine pojedini pokrovi u ukupnoj površini jedinice: vegetacije (engl. *vegetation*), nepropusnih površina (engl. *impervious surface*) i tla (engl. *soil*). Za potrebe ovog istraživanja pojam nepropusnih površina izjednačuje se s pojmom izgrađenih površina (engl. *built-up*). Izgrađene površine su iznimno složena klasa pokrova jer se mogu sastojati od brojnih i vrlo različitih materijala, a njihova količinska i morfološka zastupljenost u okolišu može jako varirati pod utjecajem prirodnih i društvenih čimbenika. Općenito, izgrađene ili nepropusne površine predstavljaju značajne modifikatore toka energije i vode u okolišu (Quattrochi i Ridd, 1994; Butler i Davies, 2004; Canters i dr., 2011; Wu i Yuan, 2011). Njihova je prisutnost u okolišu vjerojatno najjasniji indikator trajne prisutnosti ljudskih urbanih zajednica u nekom prostoru.

Iako se podjela scene u četiri klase zemljišnog pokrova doima kao jednostavan zadatak, ona često uključuje spajanja i razdvajanja vrlo različitih tzv. spektralnih klasa u informacijske klase višeg reda prema semantičkim obilježjima unaprijed zadanih klasa zemljišnog pokrova. Pravi izazov u metodama klasifikacija s upotrebom daljinskih istraživanja ne predstavlja statistička podjela podataka u skupine prema njihovim spektralnim svojstvima zabilježenim u brojčanim vrijednostima piksela, već svrstavanje tako dobivenih skupina podataka u klase definirane klasifikacijskom shemom. Pri tome su naglašene razlike ljudske percepcije ili tumačenja podataka i računalnih analiza podataka. Ta različita tumačenja prostora također mogu činiti razliku između klasifikacije materijala i tvari u promatranom okolišu, klasifikacije zemljišnog pokrova i klasifikacije načina korištenja zemljišta (Herold i dr., 2006).

Namjera izvršavanja postupaka klasifikacije s razmjerno malim brojem klasa zemljišnog pokrova je usmjeravanje daljnjeg istraživanja na suštinu odnosa urbano – ruralno te umjetno – prirodno, iako će u daljnjem tekstu biti naglašena diskutabilnost takvih dihotomnih diskursa. Kartiranjem i mjerenjem izgrađenih površina dobiva se najjasniji uvid u cjelovitu morfološko-fizionomsku strukturu naselja. Oblik izgrađenih površina ističe se kao cjelina u odnosu na pozadinu prema gestalt teoriji vizualne percepcije (Ipsen, 2009). Likovi naselja predstavljeni sjedinjenim strukturama umjetnih površina izdvajaju se iz prirodnog ili pseudo-prirodnog okruženja. Ipak, u slučaju prevage umjetnih površina u određenom promatranom

prostoru, druge klase zemljišnog pokrova poput vegetacije poprimaju jasan oblik ili postaju lik u odnosu na umjetnu izgrađenu površinu, odnosno grad. Promatranje prostora na taj način bilo bi znatno otežano kartiranjem i vizualizacijom većeg broja klasa.

Osim zadovoljavanja ovako definiranih zadataka i kriterija, opći cilj istraživanja je usavršavanje primijenjenih metoda radi postizanja što veće točnosti klasifikacije zemljišnog pokrova. Usavršavanje također podrazumijeva izradu jasnih i razumljivih istraživačkih postupaka te određeni stupanj automatizacije procesa klasifikacije tamo gdje je ona moguća. Postupci bi trebali biti prenosivi među različitim korisnicima, odnosno operaterima klasifikacije, a njihova bi primjenjivost trebala izlaziti van okvira satelitskih snimaka upotrijebljenih u istraživanju i datuma njihovog snimanja, makar na načelnoj, proceduralnoj ili konceptualnoj razini rada. Ipak, valja uzeti u obzir posebnosti geografskih obilježja svakog pojedinog prostora u određenom trenutku istraživanja i biti svjestan da i prividno male razlike mogu onemogućiti izravnu primjenjivost metode izvan područja Grada Zagreba ili u nekom drugom godišnjem dobu. Navedena problematika istražit će se u daljnjim istraživanjima.

Iz aspekta primjenjivosti podataka dobivenih klasifikacijom zemljišnog pokrova, postavljena su dva dodatna cilja istraživanja. Prvi cilj je ispitivanje mogućnosti dodatne diferencijacije naselja urbanih, periurbanih i ruralnih područja na temelju kvantitativnih podataka o izgrađenim površinama dobivenih u prvom dijelu istraživanja. Namjera tog dijela istraživanja je usporedba postojećih tipologija naselja, koje se zasnivaju na socioekonomskim statističkim pokazateljima, s udjelima izgrađenih površina u tim naseljima. U slučaju Grada Zagreba, moguća je usporedba s rezultatima recentnijih istraživanja Klempić (2008) i Lukić (2009). U hrvatskoj geografiji postoji duga tradicija podjele naselja u tipove prema demografskim i socioekonomskim podacima (Vresk, 2002), a u novije se vrijeme pažnja znanstvenih istraživanja usmjerava i na funkcije naselja (Lukić, 2009). Morfološko-fizionomski kriteriji za diferencijaciju naselja u Hrvatskoj nedostaju u dosad primjenjivanim modelima ili su predstavljeni statističkim socioekonomskim pokazateljima kao surogatima. Budući da je u urbanoj geografiji uobičajeno proučavanje trostruke strukture naselja: socioekonomske, funkcionalne i morfološko-fizionomske, modeli diferencijacije naselja koji se upotrebljavaju u Hrvatskoj često su suočeni s problematikom nezadovoljavajuće razlučivosti naselja u zadane tipove. Dakle, u ovom se istraživanju proučava mogućnost upotrebe podataka o izgrađenim površinama kao morfološko-fizionomskog obilježja i varijable za razvoj budućih modela za diferencijaciju naselja u Hrvatskoj.

Drugi cilj također uključuje upotrebu podataka o izgrađenim površinama. Izračunavanjem i kartiranjem gustoće naseljenosti na temelju prostornih podataka o izgrađenim područjima dobivaju se značajno drugačiji rezultati u odnosu na kartograme gustoće naseljenosti prema cjelokupnim upravnim područjima te se omogućava povezivanje podataka o gustoći naseljenosti prostora s morfološko-fizionomskom strukturom naselja.

Uobičajeni kartogrami i izračuni gustoće naseljenosti temelje se na vrijednostima ukupnog broja stanovnika i veličine površine cjelokupnih područja upravnih ili prostornih jedinica. Prema tom pristupu, fenomen naseljenosti predstavljen je više pojmom gustoće naseljenosti, nego pojmom razmještaja stanovništva. Kako bi se zornije predočio razmještaj stanovništva, ali i gustoća naseljenosti na izgrađenim područjima, cilj rada je izrada dazimetrijske karte Grada Zagreba.

3.2. Hipoteze istraživanja

Glavna hipoteza istraživanja tvrdi da se upotrebom pristupa objektno orijentirane analize slika na multispektralnim satelitskim snimkama RapidEye može postići zadovoljavajuća točnost klasifikacije zemljišnog pokrova.

Objektno orijentirana analiza slika u ovom istraživanju podrazumijeva upotrebu algoritma segmentacije digitalnih slikovnih datoteka pomoću kojih se satelitske snimke dijele u manje homogene skupine piksela. Klasifikacije zemljišnog pokrova vrše se na temelju tako izrađenih segmenata ili objekata slike. Za segmentaciju satelitskih snimaka RapidEye koriste se raspoloživi algoritmi iz računalnog programa Trimble eCognition 9.0. Postupci klasifikacije uključuju i metode računalne predobrade i analize satelitskih snimaka.

Mogućnosti objektno orijentirane analize slika i klasifikacije zemljišnog pokrova uvjetovane su i svojstvima ili tehničkim značajkama samih obrađenih podataka. Pretpostavlja se da površinska, radiometrijska i spektralna razlučivost te geometrijska točnost podataka iz upotrijebljenih RapidEye snimaka područja Grada Zagreba mogu u određenoj mjeri, neutvrđenoj u ovom istraživanju, utjecati na rezultate i ishode istraživanja.

Točnom klasifikacijom za potrebe ovog istraživanja smatra se ona koja zadovoljava evaluacijski kriterij točnosti, odnosno prelazi vrijednosti praga minimalne ukupne točnosti klasifikacije koji iznosi 85%.

Procjena točnosti podataka dobivenih klasifikacijom izračunava se njihovom usporedbom s referentnim podacima. Referentni podaci upotrijebljeni u ovom istraživanju čine zamjenu za podatke o stvarnom stanju Zemljine površine koji se dobivaju terenskim radom (engl. *ground truth*). Surogat za podatke o stvarnom stanju na terenu, odnosno referentne podatke u ovom istraživanju čine zračne i satelitske snimke područja Grada Zagreba veće površinske razlučivosti (0,25-0,55 m) od klasificiranih satelitskih snimaka (5 m) (DigitalGlobe, 2011; CDOF, 2012).

Usporedba klasificiranih i referentnih podataka vrši se upotrebom matrice pogrešaka. Matrica pogrešaka za potrebe ovog istraživanja izrađuje se na temelju stratificiranog slučajnog statističkog uzorka. Osim ukupne točnosti dodatne pokazatelje kvalitete provedene klasifikacije zemljišnog pokrova čine točnost proizvođača i točnost korisnika klasifikacije pojedinih klasa te kapa koeficijent kao dodatna mjera točnosti, odnosno mjera podudaranja klasificiranih i referentnih podataka.

Druga hipoteza odnosi se na primjenjivost informacija dobivenih klasifikacijom zemljišnog pokrova. Hipoteza tvrdi da se podaci o udjelima izgrađenih površina u statističkim prostornim jedinicama naselja, smještenih u okolicama većih gradova, mogu upotrijebiti kao dodatno obilježje za diferencijaciju urbanih, periurbanih i ruralnih naselja, te na taj način mogu doprinijeti tipologiji naselja.

Socioekonomski i ostali statistički pokazatelji mogu do određene mjere poslužiti za podjelu naselja u tipove unutar urbano-ruralnog kontinuuma. Smatra se da takvi podaci u nekim slučajevima analize prostornih jedinica nisu dovoljni za postizanje željene kvalitete razlučivanja složene geografske stvarnosti u klase zadane nekim klasifikacijskim sustavom. Stoga je nužno istraživanje potencijalnih dodatnih varijabli koje bi omogućile osnaživanje postojećih ili razvoj posve novih modela za tipologiju ili klasifikaciju naselja. Ovaj dio istraživanja vodi se pod pretpostavkom da bi se podatak o udjelu izgrađenih površina dobiven klasifikacijom zemljišnog pokrova iz satelitskih snimaka, mogao upotrijebiti kao dodatna varijabla za diferencijaciju naselja.

4. TEORIJSKI OKVIR ISTRAŽIVANJA

4.1. Daljinska istraživanja

Najjednostavnije i najšire definirano, daljinska istraživanja su aktivnost promatranja i proučavanja nekog objekta ili zadanog prostora i njegovog sadržaja, bez fizičkog doticaja, odnosno s određene udaljenosti (Fischer i dr., 1976; Lintz i Simonett, 1976). Prema takvoj uopćenog definiciji i ljudski vid bi se mogao pojmiti kao sustav za daljinska istraživanja (Schott, 2007). Iako je ljudski vid zaslužan za prikupljanje mnogobrojnih informacija iz čovjekove neposredne i vrlo udaljene okoline, daljinska istraživanja ipak podrazumijevaju upotrebu tehnologije za mjerenje fizičkih podataka iz okoliša (Barrett i Curtis, 1976).

U današnjim daljinskim istraživanjima prevladavaju sustavi za prikupljanje i obradu podataka nastalih mjerenjem elektromagnetskog zračenja ili energije (D. A. Landgrebe u Swain i Davis, 1978). Budući da elektromagnetski spektar čini niz vrlo različitih oblika zračenja, ključno sredstvo za izvršavanje zadataka daljinskog istraživanja je senzor ili osjetnik, koji najviše određuje granice mogućnosti nekog sustava za prikupljanje informacija na daljinu. U skladu s mogućnostima tog tehničkog uređaja bilježi se mjera zračenja u jednom ili više, užih ili širih dijelova elektromagnetskog spektra. Senzori se koriste za snimanje zračenja vidljivog ljudskim okom te za zračenja iz drugih dijelova elektromagnetskog spektra, poput bliskog infracrvenog, dugovalnog infracrvenog, mikrovalnog, ultraljubičastog, područja X-zraka itd. Senzori mogu biti usmjereni na mjerenje reflektiranog ili emitiranog zračenja s objekta, a pritom mogu biti ovisni o vanjskim izvorima elektromagnetske energije ili je aktivno odašiljati prema željenom objektu s ciljem mjerenja povratne energije (White, 1977).

Na temelju takvih podataka o zračenju, pristiglih na senzor s nekog objekta ili iz nekog prostora, stvaraju se informacije o svojstvima promatranog objekta ili prostora. Zadaća većine sustava za daljinska istraživanja je prikupljanje informacija o Zemljinim kopnenim i vodenim površinama te stanju atmosfere (Campbell i Wynne, 2011). Promatranje Zemljine površine u daljinskim istraživanjima odvija se s pogledom odozgo, odnosno iz ptičje perspektive. Dakle, prema već navedenom daljinska istraživanja bi se mogla definirati kao znanstvena disciplina koja objedinjuje metode prikupljanja podataka o objektima promatranim s razmjerno velike udaljenosti pomoću instrumenata te metode obrade i analize tih podataka radi dobivanja smislenih i upotrebljivih informacija o zadanom objektu proučavanja (National Academy of Sciences, 1970; White, 1977; D. A. Landgrebe u Swain i Davis, 1978). Ovdje navedena

tumačenja daljinskih istraživanja dio su šireg pregleda definicija kojeg u svojem radu nude Campbell i Wynne (2011).

Gledano iz aspekta povijesti znanosti i tehnologije, preduvjeti nužni za pojavu i razvoj daljinskih istraživanja bili su izumi koji su omogućili ljudski let i snimanje elektromagnetskog zračenja. Prvi uspješan ljudski let izveden je pomoću balona u Parizu 1783. godine, a prva fotografija snimljena je 1826. ili 1827. godine u Saint-Loupu de Varennesu, također u Francuskoj (Britannica, 2014). Zamisao kombiniranja tih dviju tehnologija formalizirana je gotovo trideset godina kasnije, točnije 1855. godine kada je fotograf Gaspard-Félix Tournachon patentirao ideju korištenja zračnih fotografija u geodeziji, a prvu je zračnu snimku načinio 1858. godine snimajući prostor ispod sebe iz gondole balona (Olsen, 2007).

Gotovo jedno stoljeće poslije tog događaja, 1957. godine u Zemljinu je orbitu lansiran prvi umjetni satelit Sputnik-1 koji je između niza zadaća istoimene misije sovjetskog svemirskog programa poslužio i za prikupljanje podataka o gustoći gornjih slojeva atmosfere. Prva fotografija Zemljine površine iz svemira snimljena je 1959. godine s američkog satelita Explorer-6. Tijekom svemirskih misija šezdesetih godina 20. stoljeća prikupljeno je mnoštvo fotografija koje su skrenule pozornost na potencijalne mogućnosti svemirskih daljinskih istraživanja. Inicijativa za uspostavu civilnog svemirskog sustava za promatranje Zemlje pokrenuta je 1966. u Washingtonu, a projekt je ostvaren 1972. lansiranjem satelita ERTS-1 (engl. *Earth Resources Technology Satellite*) kasnije preimenovanog u Landsat-1. Daljnji razvoj svemirskih letjelica pratio je i razvoj instrumenata koje su one prenosile u Zemljinu orbitu. Kroz sljedeća desetljeća usavršeni su senzori za daljinska istraživanja Zemljine površine iz svemira koji, promatrani zajedno, omogućavaju detekciju i mjerenje zračenja od vidljivog do mikrovalnog područja elektromagnetskog spektra. Podaci prikupljeni na taj način doprinjeli su napretku geoznanosti i srodnih znanstvenih disciplina. Osim za znanstveno-istraživačke svrhe, svemirski sustavi za daljinska istraživanja dokazali su svoju praktičnu primjenu u djelatnostima poput prognoze vremena ili upravljanje prirodnim resursima (Kramer, 2002).

Tijekom 1990-ih stvoreni su uvjeti za uspostavu cjelokupnih komercijalnih sustava za daljinska istraživanja iz svemira. Satelit IKONOS-2 lansiran 1999. godine, prvi je komercijalni sustav čije su snimke bila za javnu prodaju i distribuciju. Američki potpredsjednik Gore predstavio je 1998. godine koncept digitalne zemlje (engl. *Digital Earth*) – virtualnog globusa ili 3-D modela Zemlje pokrivenog sa satelitskim snimkama (Kramer, 2002). NASA je 2004.

godine javnosti predstavila *World Wind* koji internet korisnicima nudi dinamičan pregled i zumiranje georeferenciranih satelitskih snimaka koje pokrivaju cijelu kopnenu površinu 3-D modela Zemlje. Google je svoju inačicu internetskog virtualnog globusa sa satelitskim snimkama pod nazivom *Google Earth* objavio sljedeće, 2005. godine. Spomenuti programi samo su dva, vjerojatno najpopularnija, primjera virtualnih globusa koji su početkom 21. stoljeća značajno utjecali na popularizaciju daljinskih istraživanja, odnosno satelitskih snimaka, te otvaranje njihovog sadržaja milijunima korisnika interneta (Elvidge i Tuttle, 2008). Navedeni su događaji bili ključne tehnološke prekretnice za pojavu, razvoj i popularizaciju znanstvene discipline daljinskih istraživanja.

Kad je riječ o daljinskim istraživanjima urbanih prostora, zbog iznimne složenosti prostora proučavanja posebno se može izdvojiti poddisciplina urbanih daljinskih istraživanja. S pojavom i razvojem senzora koji omogućavaju prikupljanje snimaka velike prostorne razlučivosti, zadovoljen je osnovni preduvjet za dublje znanstveno istraživanje urbanih prostora, koje karakterizira velika heterogenost zemljišnog pokrova i načina korištenja zemljišta unutar okvira razmjerno malih područja. Zahtjevi koji se postavljaju za analizu i klasifikaciju objekata koji se nalaze u urbanim i periurbanim područjima doveli su do stanovite specijalizacije unutar znanstvene discipline daljinskih istraživanja koja se očituje u razvoju posebne metodologije i znanstvene literature (Donnay i dr., 2001; Weng i Quattrochi, 2006; Rashed i Yürgens, 2010; Yang, 2011). Dinamičnost i raznolikost urbanog okoliša predstavljaju izazov za daljinska istraživanja te se nameću, ne samo znanstveno-istraživačka pitanja, već i pitanja o granicama mogućnosti njihove praktične primjene u planiranju, upravljanju i gospodarenju prostorom. S druge strane, urbana daljinska istraživanja mogu biti dio rješenja suvremene problematike urbane geografije pred koju se često postavljaju zahtjevi definiranja obilježja urbanog prostora i njegovih jasnih granica u određenom proučavanom području. To je moguće zbog toga što satelitski sustavi za daljinska istraživanja nude konzistentno, redovito i standardizirano prikupljanje podataka o Zemljinoj površini na temelju kojih je moguće identificirati i razlučiti sastavnice urbanog prostora, a to podrazumijeva dva koraka. Prvi je prepoznavanje morfološko-fizionomske varijabilnosti naselja, a drugi je razgraničenje urbanih entiteta u skladu s nacionalnim i internacionalnim statističkim kriterijima radi njihove prostorno-vremenske usporedivosti (Donnay i dr., 2001). U sljedećem se poglavlju navodi izbor nekih od znanstvenih temelja daljinskih istraživanja.

4.1.1. Elektromagnetsko zračenje i spektralna svojstva tvari

Kao što je već prije navedeno, daljinskim istraživanjima bilježe se podaci o elektromagnetskom zračenju pristiglom na senzor s površine nekog objekta. Zračenje koje detektiraju senzori nastalo je interakcijom energije i materije. Ovisno o prirodi te interakcije, odnosno o masi i veličini čestica i vrsti njihovog gibanja, nastaju različiti oblici zračenja koji zajedno čine elektromagnetski spektar. Položaj unutar spektra ili neko područje elektromagnetskog spektra izražava se mjerama energije, valne duljine i frekvencije. Podjele elektromagnetskog spektra temelje se na arbitrarno određenim granicama razreda izraženih u jedinicama navedenih mjera. Valna duljina je linearna udaljenost između dvaju uzastopnih valnih minimuma ili maksimuma, a u daljinskim istraživanjima najčešće je izražena jedinicama duljine mikrometrima (μm = 10^{-6} m) ili nanometrima (nm = 10^{-9} m). Frekvencija se izražava jedinicom herc (Hz = s^{-1}), a energija u džulima (J) ili izvansustavnom jedinicom – elektronvoltima (eV =1,602176487·10^{-19} J), prikladnijom za upotrebu u atomskoj fizici (Clark i Rilee, 2010; Campbell i Wynne, 2011).

Tako se na primjer za vidljivi dio elektromagnetskog spektra, ovisno o literature, navode različite vrijednosti valnih duljina: 400-700, 350-650 ili 380-720 nm. Iako taj raspon čini vrlo maleni dio ukupnog elektromagnetskog spektra, njegova važnost za daljinska istraživanja i ljudski vid je velika. Unutar tog razreda nalazi se maksimum Sunčeve iradijancije ili ozračenja na Zemljinoj površini koja je u skladu sa Sunčevim idealnim crnim tijelom na temperaturi od 6000 K (Clark i Rilee, 2010). Newtonova istraživanja optičkih svojstava svjetlosti iz 17. stoljeća dovela su do zaključka da se korištenjem prizmi ona može podijeliti u tri segmenta ili aditivne primarne boje: plavu (400-500 nm), zelenu (500-600 nm) i crvenu (600-700 nm). Miješanjem tih boja u određenim omjerima dobivaju se sve ostale boje, a njihovim miješanjem u jednakim omjerima dobiva se bijela svjetlost (Campbell i Wynne, 2011).

Područje elektromagnetskog spektra koje se nalazi na valnim duljinama većim od onih vidljivog crvenog dijela spektra naziva se infracrvenim (krat. IC). W. F. Herschel je 1800. godine eksperimentom s prizmama i termometrima dokazao da uz crveni dio vidljivog spektra postoji zračenje koje nije vidljivo ljudskim okom, ali je mjerljivo instrumentima. Infracrveni dio elektromagnetskog spektra obuhvaća raspon valnih duljina od 720 nm do 1 mm te se može podijeliti na dva glavna dijela. Prvi dio obuhvaća zračenje manjih valnih duljina i karakteriziraju ga svojstva slična onima iz vidljivog dijela spektra. U kontekstu daljinskih

istraživanja, taj je dio infracrvenog spektra posljedica Sunčevog zračenja reflektiranog sa Zemljine površine. Drugi dio infracrvenog spektra, s puno većim valnim duljinama, odnosi se na primjerice na dugovalno zračenje koje emitira Zemlja.

Ultraljubičasti dio elektromagnetskog spektra također graniči s vidljivim dijelom spektra, ali ga definiraju manje valne duljine 10-400 nm (Hyperphysics, 2014). Ultraljubičasto ili ultravioletno zračenje (krat. UV) otkrio je 1801. godine J. W. Ritter uvidjevši da dio svjetlosti koji se nalazi uz ljubičasti dio spektra, ali je nevidljiv ljudskom oku, ima jak učinak na razlaganje srebrovog klorida na metalno srebro (Britannica, 2014). Čest uzrok fluorescencije, svojstva određenih tvari da emitiraju svjetlost pod utjecajem vanjskog čimbenika, upravo je ultraljubičasto zračenje. Ipak, zbog specifičnih svojstava Zemljine atmosfere koja u značajnoj mjeri sprječava prodiranje ultraljubičastog zračenja do površine, upotreba ovog dijela elektromagnetskog spektra je vrlo ograničena u daljinskim istraživanjima (Campbell i Wynne, 2011).

Mikrovalno područje je dio elektromagnetskog spektra koji često koristi u daljinskim istraživanjima, ali ga predstavljaju znatno veće valne duljine od prije navedenih (1-1000 mm). Među znanstvenicima zaslužnima za otkriće mikrovalnog dijela elektromagnetskog spektra mogu se posebno istaknuti Maxwell i Hertz (Campbell i Wynne, 2011). Čest način izražavanja mjera veličina zračenja za taj dio elektromagnetskog spektra je njezina frekvencija izražena jedinicama herca pa se primjerice za dio spektra između valnih duljina od 1 do 10 cm mogu upotrijebiti približne vrijednosti frekvencija od 30 do 3 GHz (Kramer, 2002; Richards, 2013).

Dvojna priroda svjetlosti zapažena u znanstvenim istraživanjima provođenima tijekom novovjekovne povijesti dovela je do razvoja dvije teorije. Huygensova istraživanja svjetlosti iz 17. i Youngova iz 19. stoljeća te njihove opservacije utrle su put k valnoj teoriji svjetlosti. Valna svojstva svjetlosti formalizirana su 1860-ih u Maxwellovim matematičkim jednadžbama i teoriji elektromagnetske energije (Maxwell, 1865; IEEE Spectrum, 2014). U daljinskim istraživanjima i radiometriji, energija i njezin prijenos često se objašnjavaju i drugim modelom. Prema kvantnoj teoriji energija se prenosi u obrocima ili kvantima. Nosioci energije svjetlosti su čestice zvane fotoni, a njihova je energija proporcionalna s frekvencijom, odnosno umnožak je Planckove konstante ($h = 6{,}62606896 \cdot 10^{-34}$ J s) i frekvencije (ν). Prema toj jednadžbi sa smanjenjem valne duljine povećava se energija fotona (Schott, 2007).

Valja spomenuti nekoliko pojmova bitnih za daljinska istraživanja i termina koji će se upotrebljavati u ovom radu. Jednadžbe navedene u tekstu izravno su preuzete iz Schottovog rada (2007), a upotrijebljena terminologija na hrvatskom jeziku usklađena je s hrvatskim strukovnim nazivljem objedinjenim u projektu Instituta za hrvatski jezik i jezikoslovlje, Hrvatskog zavoda za norme i Hrvatske zaklade za znanost (Struna, 2014).

Tok ili snaga zračenja ili radijacijski fluks (Φ) koji predstavlja omjer energije zračenja ili radijacijske energije (Q) i vremena, izražen je jedinicom vat (W).

$$\Phi = \frac{dQ}{dt}$$

Mjerna veličina toka zračenja na određenoj ploštini naziva se iradijancija ili ozračenje, a izražava se jedinicom vat po četvornome metru (W m^{-2}). Termin iradijancija (E) koristi se za tok zračenja koji dolazi na ploštinu, dok se za tok zračenja koji polazi s ploštine koristi termin radijacijska egzitancija ili odzračnost (M) za koju se koristi ista jedinica (W m^{-2}).

$$E = E(x, y) = \frac{d\Phi}{dA}$$

Mjernom veličinom jakosti zračenja ili radijacijskog intenziteta (I) opisuje se zračenje iz točkastog izvora te predstavlja omjer toka zračenja i prostornog kuta u koji se zrači, a njezina jedinica je vat po steradijanu (W sr^{-1}).

$$I = I(\theta, \varphi) = \frac{d\Phi}{d\Omega}$$

Za opisivanje toka zračenja koji dolazi na neku ploštinu, dolazi s nje ili kroz nju prolazi, koristi se mjerna veličina radijancije (L) izražena jedinicom vat po četvornome metru steradijanu (W m^{-2} sr^{-1}).

$$L = L(x, y, \theta, \varphi) = \frac{d^2\Phi}{dAcos\theta d\Omega} = \frac{dE}{d\Omega\cos\theta} = \frac{d\mathrm{I}}{dAcos\theta} = \frac{dM}{d\Omega os\theta}$$

Uzimanjem valne duljine u obzir, odnosno spektralnih svojstava zračenja dobivaju se zasebne mjerne veličine poput spektralne iradijancije (E_λ), spektralne radijancije (L_λ) itd. O spektralnom odzivu detektora (R) upotrijebljenog za daljinska istraživanja ovisit će efektivna spektralna radijancija izražena jedinicom W m^{-2} sr^{-1} nm^{-1} (Schott, 2007).

Dio daljinskih istraživanja posvećen je mjerenjima energije emitirane iz nekog objekta u svojstvu izvora zračenja ili zračila. Svi objekti s temperaturom iznad apsolutne nule (T = 0 K ili t = −273,15° C) emitiraju energiju. Prema Planckovom zakonu spektralna egzitancija zračenja (M_λ) idealnog crnog tijela ovisi o temperaturi objekta i valnoj duljini, a u jednadžbi za njezino izračunavanje koriste se prije navedena Planckova konstanta, brzina svjetlosti i Boltzmannova konstanta (k_B = 1,3806504·10^{-23} J K^{-1}). Idealno crno tijelo je hipotetski objekt koji apsorbira sveukupni upadni tok zračenja te ga savršeno emitira, bez ikakve refleksije zračenja. Ukupan tok zračenja idealnog crnog tijela može se izračunati uz pomoć Stefan-Boltzmannovog zakona i istoimene konstante (σ = 5,670·10^{-8} J K^{-4} m^{-2} s^{-1}). Za niz stalnih vrijednosti temperature mogu se izraditi krivulje idealnog crnog tijela na kojima se može očitati maksimum spektralne egzitancije u odnosu na valnu duljinu. Te krivulje zorno predočavaju fenomen prema kojem objekti s većim vrijednostima temperature imaju maksimume spektralne egzitancije pri manjim valnim duljinama. Wienov zakon pomaka dodatno određuje odnos valne duljine emitiranog zračenja i temperature crnog tijela za velike frekvencije, odnosno male valne duljine određivanjem konstante (2,8977721·10^{-3} m K). Budući da u prirodi ne postoje idealna crna tijela, već su svi objekti nesavršeni apsorberi ili upijači energije za opisivanje njihovog svojstva emitirane energije koristi se pojam emisivnost ili izračivost. Emisivnost (ε) je omjer spektralne egzitancije stvarnog objekta i spektralne egzitancije idealnog crnog tijela pri istoj temperaturi (Lillesand i dr., 2004; Schott, 2007; Campbell i Wynne, 2011).

Poput emisivnosti, treba navesti i ostala veličine koje opisuju interakciju materije i elektromagnetskog zračenja – transmitanciju, reflektanciju i apsorptanciju. Transmitancija ili faktor transmisije (τ) je omjer toka transmitiranog zračenja i ukupnog upadnog toka zračenja. Reflektancija ili faktor refleksije (ρ) je omjer toka reflektiranog zračenja i ukupnog upadnog toka zračenja. Apsorptancija ili faktor apsorpcije (α) je omjer toka apsorbiranoga zračenja i ukupnog upadnog toka zračenja. Načelo očuvanja energije zahtijeva da zbroj apsorpcije, refleksije ili transmisije odgovara veličini ukupnog upadnog toka zračenja, a u slučaju neprozirne tvari transmisija je jednaka nuli. U skladu s Kirchhoffovim zakonom koji tvrdi da je u termodinamičkom ekvilibriju emitirano zračenje jednako apsorbiranom zračenju, zbroj emisivnosti, transmitancije i reflektancije jednak je jedan, a u slučaju neprozirne tvari transmisitancija nije u sastavu tog odnosa (Konecny, 2002; Schott, 2007).

$$\varepsilon + \tau + \rho = 1 \qquad \text{i} \qquad \alpha + \tau + \rho = 1$$

Iznimno važnu ulogu za daljinska istraživanja Zemljine površine ima interakcija elektromagnetskog zračenja s atmosferom. Ta se interakcija može svesti na tri procesa: raspršenje, apsorpciju i refrakciju.

Raspršenje je proces promjene smjera upadnog zračenja zbog prisutnosti različitih čestica u atmosferi. Količina i način raspršenja ovise o brojnosti, obliku i veličini čestica, valnoj duljini zračenja i duljini puta zračenja kroz atmosferu. Različiti oblici raspršenja mogu se opisati pomoću tri primjera. Objašnjenje za dio raspršenja koji se zbiva u uvjetima relativno čiste atmosfere ponudio je fizičar J. W. S. Rayleigh 1871. godine (Britannica, 2014). Takvo raspršenje događa se uslijed međudjelovanja elektromagnetskog zračenja i čestica veličine manje od valne duljine tog zračenja, kao što su vrlo malene čestice prašine ili veće molekule poput molekula kisika i dušika. Prema njegovom zaključku, plinovi koji čine Zemljinu atmosferu uzrok su povećanja raspršenja svjetlosti sa smanjenjem valne duljine zračenja. Na temelju Rayleighovih otkrića mogu se objasniti plava boja neba pri velikom kutu upada Sunčevih zraka i crvena boja neba prilikom niskog kuta upada Sunčevih zraka. Opsežnije objašnjenje različitih oblika atmosferskog raspršenja objavio je fizičar G. Mie 1908. godine (Horvath, 2009). Njegove su analize uzele u obzir veće atmosferske čestice poput aerosola,

peludi i kapljica vode, koje mogu utjecati na veći raspon valnih duljina zračenja. Za razliku od raspršenja čiste atmosfere objašnjeno Rayleighovim radom koje se zbiva u sloju atmosfere do visine od 10 km, raspršenje uzrokovano većim česticama zbiva se u nižem sloju atmosfere do 5 km. Raspršenje svjetlosti koje se događa zbog prisutnosti još većih čestica u atmosferi, poput većih kapljica vode ili velikih čestica prašine, naziva se neselektivno raspršenje. Budući da se uslijed takvih atmosferskih uvjeta sve vidljive valne duljine zračenja podjednako raspršuju, ono se percipira kao bijela ili siva boja. Atmosfersko raspršenje značajno utječe na daljinska istraživanja jer do senzora, osim Sunčevog zračenja izravno reflektiranog sa Zemljine površine, pristiže zračenje raspršeno u atmosferi koje nije stiglo do Zemljine površine i zračenje koje je nakon reflektiranja sa Zemljine površine raspršeno u atmosferi prije nego je konačno stiglo do senzora (Kramer, 2002; Schott, 2007; Campbell i Wynne, 2011).

Refrakcija je promjena smjera svjetlosnih zraka pri prijelazu iz jednoga optičkog sredstva, odnosno tvari koje ima svojstvo transmisije, u drugo sredstvo. U kontekstu interakcije svjetlosti i atmosfere, refrakcija se događa prilikom prolaska svjetlosnih zraka kroz dijelove atmosfere različite temperature i relativne vlažnosti koji utječu na gustoću atmosfere kao sredstva transmisije (Campbell i Wynne, 2011).

Apsorpcijom atmosfere uklanja se dio energije ili fotona iz nadolazećih Sunčevih zraka te se odvija promjena elektromagnetske energije u obliku povećanja valne duljine zračenja. Plinovi koji sačinjavaju Zemljinu atmosferu svojom interakcijom s elektromagnetskim zračenjem, odnosno apsorpcijom zračenja određenih valnih duljina utječu na transmitanciju zračenja. Posljedica toga su tzv. atmosferski prozori – razredi elektromagnetskog spektra unutar kojih određeni veći dio zračenja dospijeva do Zemljine površine. S druge strane, elektromagnetsko zračenje valnih duljina izvan tih razreda ne dospijeva do Zemljine površine. Iz navedenog proizlaze mogućnosti i ograničenja daljinskih istraživanja površine našeg planeta (Konecny, 2002; Campbell i Wynne, 2011).

Prilikom kontakta elektromagnetskog zračenja sa Zemljinom površinom također se odvijaju procesi reflektiranja, apsorpcije i transmisije uvjetovani svojstvima tvari koje se na njoj nalaze. Vrsta reflektiranja zračenja ovisit će o svojstvima površine na koju ona dolazi. Spekularno reflektiranje zračenja događa se ako je ploha relativno glatka u odnosu na valnu duljinu zračenja. U slučaju da zračenje dolazi na površinu koja je relativno hrapava ili neravna u odnosu na valnu duljinu zračenja, reflektiranje je difuzno. Idealizirani koncept površine koja

savršeno difuzno ili izotropno reflektira zračenje naziva se Lambertova površina. Na temelju istraživanja svjetlosti J. H. Lamberta, u 18. je stoljeću izveden zaključak da je percipirana radijancija proporcionalna kosinusu kuta na normalu površine i smjera prema izvoru zračenja. Uz Lambertovu površinu i kosinusni zakon, među radiometrijskim konceptima upotrebljava se i zakon inverznog kvadrata prema kojem se iradijancija iz točkastog izvora smanjuje s kvadratom udaljenosti. Budući da idealizirani koncept Lambertove površine ne može primijeniti na većini površina u prirodi za objašnjenje i opisivanje interakcije svjetlosti sa stvarnim površinama čest se koristi funkcija razdiobe dvosmjerne refleksije (engl. *bidirectional reflectance-distribution function*, krat. BRDF). Faktor refleksije uvjetovan je osvjetljenjem ili iluminacijom te geometrijskim odnosima senzora i površine promatranog objekta (Nicodemus i dr., 1977; Herald i dr., 2007; Schott, 2007; Campbell i Wynne, 2011).

U konačnici se u daljinskim istraživanjima za diferencijaciju svjetlinu promatrane Zemljine površine često primjenjuje reflektancija koja je omjer egzitancije i iradijancije za određene valne duljine elektromagnetskog zračenja, izražen vrijednošću između 0 i 1 ili postocima, bez mjerne jedinice. Reflektancija tvari ili materijala ovisit će i o njegovoj apsorptanciji i transmitanciji. Dodatna svojstva tvari vezana su uz polarizaciju elektromagnetskog vala i fluorescenciju. Polarizacija elektromagnetskog vala definira se orijentacijom ravnine u kojoj titra električno polje vala. Fluorescencija je pojava emisije svjetlosti koja nastaje kao reakcija tvari na vanjsku pobudu (Struna, 2014).

Mjerenjem reflektiranog ili emitiranog zračenja s određenog promatranog objekta, unutar pojedinih razreda elektromagnetskog spektra definiranih valnom duljinom zračenja, dobivaju se podaci koji mogu postati smislene informacije ako se uzme u obzir pretpostavka da sve tvari u prirodi posjeduju jedinstvena svojstva refleksije, apsorpcije ili transmisije koja čine njihov spektralni potpis. Na taj se način ciljani objekti istraživanja mogu detektirati, a sadržaj promatranog prostora može diferencirati, identificirati i kvantificirati. Klasifikacija zemljišnog pokrova pomoću daljinskih istraživanja temelji se na toj pretpostavci.

Spektralni potpis određene tvari posljedica je jedinstvene interakcije elektromagnetskog zračenja i materije. Proces apsorpcije energije elektromagnetskog zračenja manjih valnih duljina ili veće frekvencije u materiji pobuđuje elektrone u elektronskom omotaču atoma. Pri većim valnim duljinama i manjoj frekvenciji elektromagnetskog zračenja odvija se vibracijska

apsorpcija jer energija fotona odgovara frekvenciji vibracija molekularnih veza (Herold i dr. 2006; Clark i Rilee, 2010).

Faktor refleksije zračenja različitih tvari i materijala u okolišu u određenom dijelu elektromagnetskog spektra povezan je s njihovim apsorpcijskim svojstvima. Na temelju laboratorijske i terenske spektrometrije moguće je detaljno mjerenje reflektancije tvari u velikom rasponu valnih duljina. Podaci dobiveni mjerenjem reflektancije pojedinih uzoraka mogu se grafički prikazati krivuljama na dijagramima.

Za potrebe provedenog istraživanja nužno je spomenuti neka svojstva upotrijebljenih klasa zemljišnog pokrova urbanog i periurbanog prostora. Karakteristični spektralni potpis zelene vegetacije uzrokovan prisustvom klorofila u biljkama, može se opisati malim faktorom refleksije zračenja u vidljivom dijelu elektromagnetskog spektra i velikim faktorom refleksije u bliskom infracrvenom dijelu. Posebno do izražaja dolazi nagli porast reflektancije u crvenom rubu (engl. *red edge*), dijelu spektra na prijelazu iz vidljivog crvenog u blisko infracrveno područje. U vidljivom dijelu spektra može se istaknuti veća reflektancija zračenja valne duljine oko 550 nm zbog kojeg ljudski vid percipira zelenu boju fotosintetskih dijelova biljaka. Vibracijska apsorpcija vode u biljkama uzrokuje smanjenu reflektanciju zračenja pri valnim duljinama od 980, 1200, 1400 i 1900 nm. Nefotosintetski dijelovi biljaka i nefotosintetska vegetacija (engl. *nonphotosynthetic vegetation – NPV*) posjeduju drugačija spektralna svojstva jer sadrže manje količine klorofila, a apsorpcija uzrokovana prisustvom lignoceluloze na temelju koje se ovakav pokrov može identificirati kao vegetacija, zbiva se pri većim valnim duljinama, oko 2100 i 2300 nm. Nagli porast faktora refleksije u području crvenog ruba ne postoji (Roberts, 1993; Herold i dr., 2004).

Izgrađene gradske površine su vrlo složena fizičkogeografska pojava i materijali koji ih tvore mogu imati vrlo različite spektralne potpise te ih je nemoguće pojednostavljeno opisati. Općenito se na njima može očitati blaži ili nagliji rast reflektancije s porastom valne duljine, barem u vidljivom i bliskom infracrvenom dijelu spektra. Materijali koji se koriste za izgradnju gradskih ili općenito naseljenih površina mogu se prema primjerima Herolda i dr. (2006) podijeliti na temelju njihovih prevladavajućih sastojaka u skupinu u kojoj do izražaja najviše dolaze spektralna svojstva minerala te u drugu skupinu u kojoj do izražaja najviše dolaze svojstva ugljikovodika. Mineralni sastojci posebno dolaze do izražaja u cementnim i betonskim

površinama, crijepovima i ciglama te određenim tipovima šindre, a ugljikovodici dominiraju u umjetnim bojama, katranu i asfaltiranim površinama.

Apsorpcijska svojstva u vidljivom i bliskom infracrvenom dijelu spektra kod prve skupine materijala uzrokovana su prisustvom oksida željeza. Često ih ta svojstva čine vrlo sličnima neizgrađenim površinama bez vegetacije koja se pojednostavljeno mogu pojmiti kao golo tlo ili gole stijene. Budući da značajan dio građevinskog materijala nastaje eksploatacijom mineralnih sirovina iz prirode, nije slučajno da se te dvije klase zemljišnog pokrova često krivo klasificiraju. Ipak, osim mineralnog sastava bitna je i industrijska obrada materijala pa se tako faktori refleksije glina i opeka značajno razlikuju pri većim valnim duljinama zbog termičke obrade opeka i posljedičnog uklanjanja vode iz njih (Herold i dr., 2006).

Ugljikovodična spektralna svojstva uočljiva su kod građevinskih sirovina i materijala nastalih rafiniranjem nafte. Njih karakterizira jaka apsorpcija zračenja u ultraljubičastom i vidljivom dijelu spektra s maksimumom oko 350 nm te linearno slabljenje apsorpcijskih svojstava prema većim valnim duljinama. Asfalt, bitumen, katran, kompozitne šindre i slični materijali imaju mali faktor refleksije te ih je zbog toga teško međusobno razlikovati što stvara probleme prilikom klasifikacije zemljišnog pokrova ili načina korištenja zemljišta i razdvajanja npr. klasa zgrada od klase cestovnih prometnica (Herold i dr., 2003, 2006).

Spektralni potpis vode uvjetovan je njezinim jakim apsorpcijskim svojstvima zračenja svih valnih duljina. Određeni se maksimum reflektancije nalazi u vidljivom, zelenom dijelu spektra. Klasifikacija vodenih površina u prirodi ovisi jako o dubini i čistoći vode. Zbog naziranja dna vodenog tijela ili onečišćenja organskim i anorganskim tvarima, voda može značajno promijeniti svoj spektralni potpis.

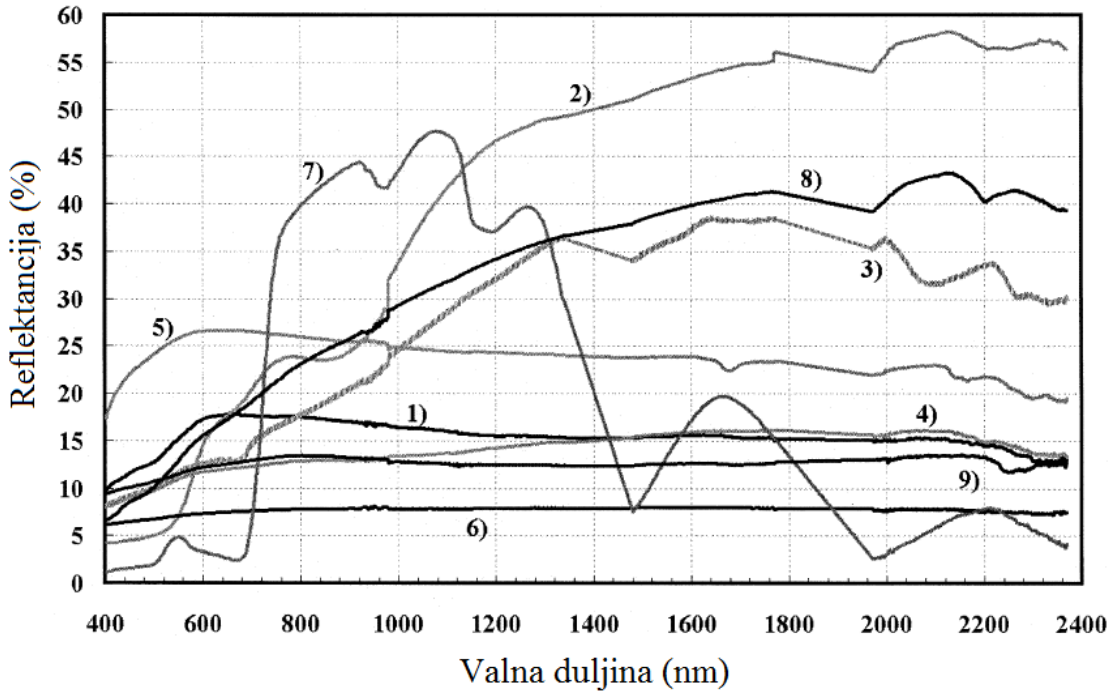

Sl. 4. Primjeri spektralnih potpisa prikupljenih terenskim radom: 1) svijetlosmeđa kompozitna šindra, 2) crveni crijep, 3) drvena šindra, 4) asfaltna cesta, 5) betonska cesta, 6) parkiralište, 7) zelena vegetacija – travnjak, 8) golo tlo – gradilište, 9) sivo-smeđi crijep.

Izvor: Herold i dr., 2003, 1910, sl. 2.

4.1.2. Senzori u daljinskim istraživanjima

Senzori u daljinskim istraživanjima tehnički su instrumenti za detekciju, mjerenje i bilježenje elektromagnetskog zračenja. Senzori korišteni u daljinskim istraživanjima mnogobrojni su i mogu se jako razlikovati prema svojim tehničkim karakteristikama. Ovisno o potrebama njihove kategorizacije, mogu se razvrstati na temelju više kriterija. Podjele senzora učestale u znanstvenoj literaturi temelje se na njihovoj: konkretnoj svrsi ili primjeni, sposobnosti detekcije zračenja određenog dijela elektromagnetskog spektra definiranog valnom duljinom ili frekvencijom, tehničkim i fizičkim principima rada instrumenta, mogućnosti senzorskog mehanizma da koristi vlastiti ili isključivo vanjski izvor energije za prikupljanje podataka, te preciznosti mjerenja koja se može izraziti višeznačnom razlučivošću (Kramer, 2002). Vrlo praktična podjela senzora može se izvršiti na temelju triju osnovnih skupina

informacija koje senzori prikupljaju: prostorne informacije, spektralne informacije i informacije o intenzitetu (Elachi, 1987; Kramer 2002).

Za potrebe ovog rada bit će dovoljno opisati samo neke od spomenutih kriterija za kategorizaciju senzora za daljinska istraživanja. Prva mogućnost podjele senzora, na aktivne i pasivne, temelji se na sposobnosti uređaja da prikupljaju podatke iz okoliša na temelju vlastitog izvora zračenja ili njihovoj ovisnosti o vanjskom izvoru zračenja, poput Sunca ili Zemlje. Aktivni senzori, npr. radar i lidar (engl. *radio/light detection and ranging*), prikupljaju podatke tako što odašilju zračenje i mjere njegov povrat, dok pasivni, npr. Landsatov multispektralni skener (engl. *multispectral* scanner, krat. *MSS*) bilježe isključivo reflektirano ili emitirano zračenje iz okoliša.

Druga podjela moguća je na temelju sposobnosti senzora da vrši mjerenja zračenja određenog dijela elektromagnetskog spektra. Iako je već ranije naglašeno da su sve podjele elektromagnetskog spektra arbitrarne i aproksimativne, optičkim dijelom može se smatrati područje s valnim duljinama od 10 nm do 1.000.000 nm, a mikrovalnim od 1 mm (10^6 nm) do 1 m. Unutar optičkog dijela spektra nalaze se ultraljubičasto, vidljivo i infracrveno područje zračenja.

Budući da su u ovom radu upotrijebljeni podaci iz pasivnog optičkog senzora, treba posebno izdvojiti nekoliko različitih tehničkih načina rada instrumenata. Osim, povijesno gledano, vrlo *zrelih* tehnologija fotografije na filmu, te TV kamera, za suvremeno pasivno optičko promatranje Zemljine površine najviše se upotrebljavaju digitalni optičko-mehanički i optičko-elektronički senzori. U optičko-mehaničkim instrumentima oscilirajuće ili rotirajuće zrcalo usmjerava nadolazeće fotone kroz prizmu ili optičku rešetku na silicijeve fotodetektore. Prema tom principu rada (engl. *whisk broom* ili *across-track scanning*), promatrana površina skenira se u linijama – ćeliju po ćeliju, okomito na putanju senzorske platforme, odnosno letjelice. Optičko-elektronički uređaji skeniraju promatranu površinu uzduž smjera leta (engl. *push broom* ili *along-track scanning*) u cjelovitim linijskim zapisima pomoću usporednih nizova fotodetektora (Oštir, 2006). U njima se za fotodetektore u najvećoj mjeri primjenjuje tehnologija nabojski vezanih elemenata (engl. *charge-coupled device*, krat. *CCD*) s kojom je od izuma 1969. godine potaknut razvoj digitalne fotografije.

Preciznost slikovnih senzora (engl. *imager*) za daljinska istraživanja može se očitati u njihovoj sposobnosti razlučivanja površinskih, spektralnih i radiometrijskih jedinica mjerenja.

Pojam površinske razlučivosti opisuje dvodimenzionalni odnos osnovnog slikovnog elementa – piksela, te stvarne snimljene površine. Za mjeru površinske razlučivosti često se upotrebljava vrijednost koja označava udaljenost između centara dvaju susjednih piksela na Zemljinoj površini (engl. *ground sampling distance*). S povećanjem površinske razlučivosti na snimkama, moguće je detektirati sve manje objekte (Navulur, 2006; Oštir, 2006).

Spektralna razlučivost senzora predstavlja svojstvo senzora da mjeri elektromagnetsko zračenje unutar određenog broja razreda elektromagnetskog spektra podijeljenog prema valnoj duljini te veličinu, odnosno raspon tih razreda. Povećanjem broja razreda i smanjivanjem veličine razreda valne duljine povećava se spektralna rezolucija instrumenta za daljinska istraživanja (Navulur, 2006; Oštir, 2006).

Različite vrijednosti radiometrijske razlučivosti među senzorima ukazuju na podatkovnu kvalitetu zapisa mjerenja elektromagnetskog zračenja. U digitalnim podacima ona se izražava brojem bita, a u slikovnim datotekama ona se očituje u broju sivih nijansi (engl. *grayscale*) koje se mogu prikazati u svakom pojedinom pikselu. S jednim bitom podataka moguće je prikazati samo binarne vrijednosti – 0-1, da-ne, crno-bijelo, a s primjerice 8 bita može se prikazati 256 brojčanih vrijednosti (2^8) ili sivih nijansi slike. S povećanjem radiometrijske razlučivosti, mogu se detaljnije prikazati razlike u energiji zračenja (Navulur, 2006; Oštir, 2006; Campbell i Wynne, 2011).

Bitno je napomenuti da su tri navedene razlučivosti negativno korelirane, odnosno da porast jedne razlučivosti uvjetuje pad druge. Prema tome, s porastom prostorne razlučivosti nužno opadaju radiometrijska i spektralna razlučivost. Da bi se povećala radiometrijska razlučivost, mjerenje se vrši unutar širih područja elektromagnetskog spektra i veće površinske jedinice, a to podrazumijeva opadanje spektralne i površinske razlučivosti. Dakle, izbor senzora i njegovih karakteristika ovisit će o znanstveno-istraživačkim ili praktičnim potrebama korisnika (Oštir, 2006).

Ta problematika dovodi do znanstvene diskusije o prikladnosti određenih senzora i njihovih podataka za urbana daljinska istraživanja. Razvoj senzora tijekom druge polovice 20. stoljeća, sa sve većom površinskom razlučivošću potaknuo je razvoj te poddiscipline jer je omogućio uvid u prostor koji je prije bio uprosječen u *velikim* pikselima i zbog toga neistraživ. Mesev (2010) ipak upozorava da se s povećanjem površinske razlučivosti javlja problem spektralnog šuma i s njim povezane nepotrebne veće ili manje razlike unutar tematskih klasa te

da često upravo uprosječene vrijednosti većih površinskih jedinca mogu pomoći u postupku klasifikacije. Također svrće pozornost na smanjenje radiometrijske razlučivosti kao negativnu posljedicu povećanja površinske razlučivosti. Navulur (2006) navodi da se povećanje radiometrijske razlučivosti snimke općenito može promatrati kao povećanje njezinog informacijskog sadržaja. Myint (2006) naglašava presudnu važnost površinske razlučivosti za urbana daljinska istraživanja. Pozivajući se na Jensena i Cowena (1999) navodi razlučivost u rasponu od 0,25 do 5 m, nužnu za identifikaciju zasebnih građevina. Također napominje da povećanje radiometrijske razlučivosti ne jamči veći informacijski sadržaj o manjim objektima i entitetima. Herold i dr. (2006) prema Swayzeu i dr. (2003) hipotetski predstavljaju idealan instrument za daljinska istraživanja kao radiometrijski stabilan senzor s velikom vrijednošću omjera signal-šum (engl. *signal to noise ratio*) te mogućnošću kvantificiranja sitnih razlika u reflektanciji među objektima.

4.1.3. Satelitski sustav RapidEye

Satelitski sustav RapidEye je komercijalni sustav za daljinska istraživanja te je dio međunarodne korporacije Blackbridge Group. Središte RapidEye-a je u Berlinu u Njemačkoj dok su ostali segmenti Blackbridge grupe smješteni u Lethbridgeu u Alberti u Kanadi (BlackBridge RapidEye, 2014).

Svemirski dio sustava RapidEye sastoji se od pet satelita u Zemljinoj orbiti na visini od 630 km, lansiranih 2008. godine. Svemirske letjelice SSTL-150 izrađene su u engleskom poduzeću Surrey Satellite Technology, manje su od jednog kubnog metra i teže 150 kg. Njihova je orbita sinkronizirana sa Suncem, a vrijeme preleta ekvatora je oko 11:00 sati. Vrijeme potrebno za ponovno snimanje nekog područja u nadiru je 5,5 dana, a pod određenim kutom (koji nikad nije veći od 20°) moguće je svakodnevno snimanje. Udio snimaka napravljenih pod kutom ±10° u odnosu na nadir jest 70%. Širina zahvata snimanja (engl. *swath*) je 77 km. Snimljeni podaci pohranjuju se u satelitima te se odašilju zemaljskom segmentu sustava tijekom njihovog preleta postaje na Svalbardu u Norveškoj. Satelitski sustav omogućuje dnevno snimanje do 5.000.000 km^2 te preko milijardu četvornih kilometara godišnje (BlackBridge RapidEye, 2014).

Sustav RapidEye upotrebljava pasivni optičko-elektronički multispektralni senzor JSS 56, njemačkog poduzeća Jena-Optronik. Senzor omogućava snimanje Zemljine površine uzduž leta platforme, u pet dijelova vidljivog i bliskog infracrvenog područja elektromagnetskog spektra. Površinska razlučivost snimanja (GSD) je 6,5 m, a radiometrijska 12 bita (BlackBridge RapidEye, 2014).

U usporedbi s ostalim trenutno aktivnim satelitskim sustavima za daljinska istraživanja, sustav RapidEye može se istaknuti kombinacijom razmjerno velike površinske razlučivosti i velike vremenske razlučivosti – odnosno vremenskog razmaka između dva snimanja istog područja. To znači da se u optimalnim sinoptičkim uvjetima s malo naoblake cjelokupne površine regija ili pojedinih države mogu vrlo brzo snimiti. Karakteristike multispektralnog senzora odgovaraju prvenstveno za upotrebu u poljoprivredi, šumarstvu i zaštiti okoliša.

Tab. 5. Svojstva multispektralnih satelitskih sustava aktivnih 2011. godine (primjeri).

Satelitski sustav	Površinska razlučivost (*GSD*)		Broj kanala (bez pan.)	Radiometrijska razlučivost (bit)	Širina zahvata (km)
	Pankromatska	Multispektralna			
ASTER	-	15-90	14	8-12	60
Geoeye-1	0,41	1,65	4	11	15,2
IKONOS	0,82	3,2	4	11	11,3
Landsat 7	15	30-90	7	8	185
Quickbird	0,65	2,62	4	11	16,8
RapidEye	-	6,5	5	12	77
SPOT 5	2,5	10-20	4	8	60
WorldView-2	0,46	1,84	8	11	16,4

Izvor: Navulur, 2006; Satimagingcorp.com, 2014; Geoimage.com.au, 2014.

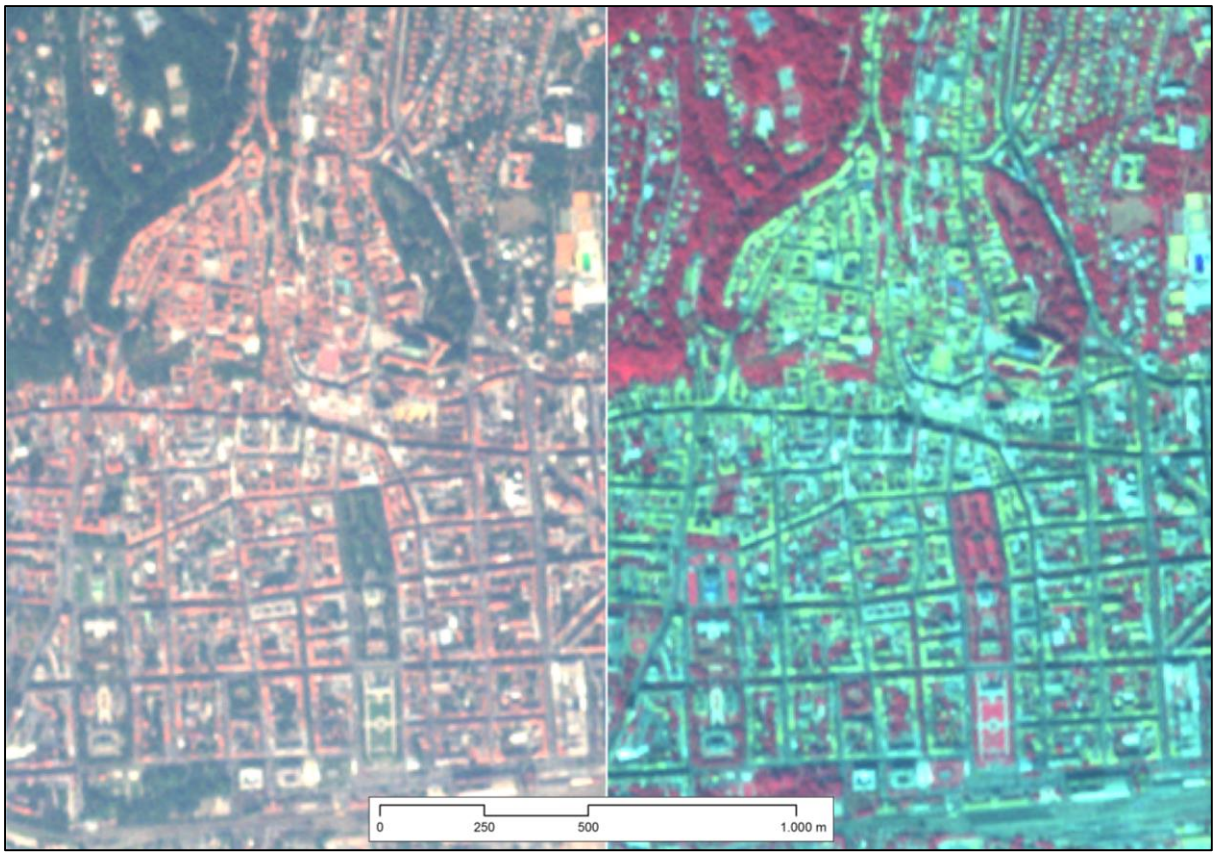

Sl. 5. Središte Zagreba na RapidEye snimci, uobičajeni RGB prikaz i IC pseudokolor. Izvor: autor na temelju: RapidEye, 2011.

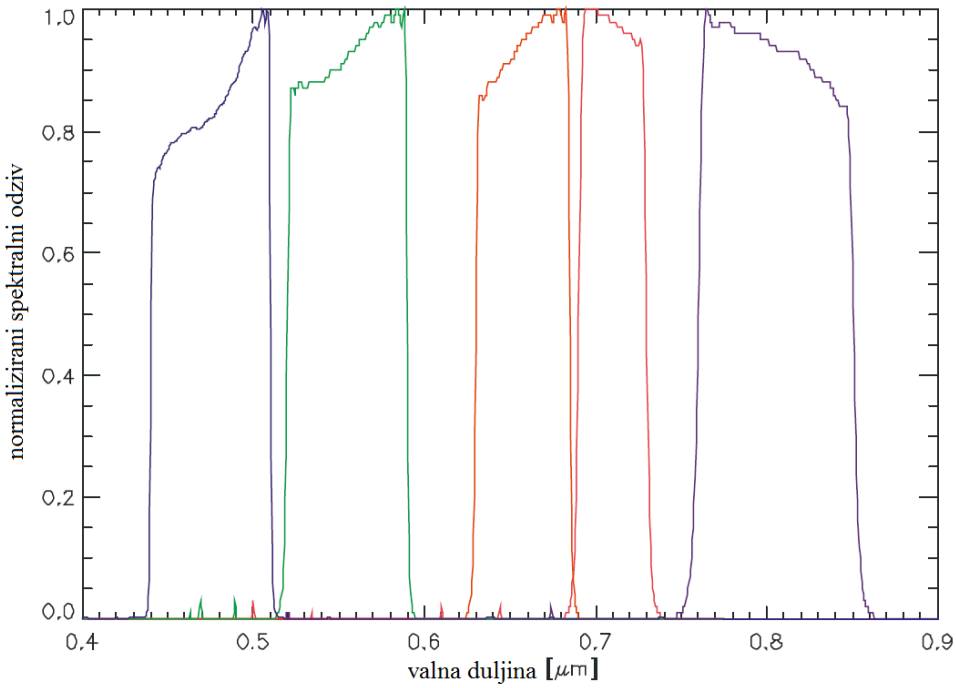

Sl. 6. Dijagram spektralnog odziva senzora RapidEye. Izvor: RapidEye, 2012, 3.

4.2. Geoinformatika

Geoinformatika je znanstvena disciplina koja objedinjuje metode prikupljanja geografskih informacija i njihovog pretvaranja u digitalni oblik, pohranjivanja u bazama podataka, te računalne obrade, analize, modeliranja i vizualizacije. U ovom se radu termin geoinformatika izjednačuje s terminom na njemačkom jeziku *Geoinformatik*, ali i s terminom na engleskom jeziku *geographic information science*. Pri tome treba naglasiti da je njemački termin *Informatik* istovjetan engleskom terminu *computer science* i hrvatskom terminu računarstvo, dok je engleski termin *information science* istovjetan hrvatskom terminu informacijske znanosti.

Termin *geographical information science* prvi je 1992. predložio Goodchild kako bi naglasio istinski opseg znanstvene složenosti i problematike stvaranja, pohranjivanja, uređivanja i korištenja geografskih informacija. Prema njegovom tumačenju, „geografska informacijska znanost je multidisciplinarno istraživanje prirode geografskih informacija i primjene geoprostornih tehnologija za temeljna znanstvena pitanja“ (Goodchild, 1992; UCGIS, 2006, str. 5). Termin *geographic information science* često se skraćuje u *GI Science* ili samo *GISci*, odnosno *GISc*.

U literaturi i nazivima studija također se pojavljuje termin na engleskom jeziku *geoinformatics*, ali njegova upotreba prevladava izvan engleskog govornog područja. Termin geomatika (engl. *geomatics*) uvriježen je u suvremenoj geodeziji i podrazumijeva integrirani pristup prikupljanju i obradi prostornih podataka (Longley i dr., 2005; Frančula i Lapaine, 2008). Neovisno o razlikama nazivlja i njihovoj upotrebi u pojedinim jezicima i strukama, svi ti termini podrazumijevaju pojam znanstvenog promišljanja temeljne problematike vezane uz pojavu i razvoj geografskih informacijskih sustava i srodnih tehnologija (Longley i dr., 2005).

U skladu s time Fotheringham i Wilson (2008, str. 1) definiraju *GI Science* kao „bilo koji aspekt prikupljanja, pohranjivanja, integracije, upravljanja, dobavljanja, prikaza, analize i modeliranja prostornih podataka.“ Chrismanova sveobuhvatna definicija geografskih informacijskih sustava (Chrisman, 2003; Longley i dr., 2005) postavlja objekt proučavanja geoinformatike u društveni kontekst naglašavajući uzajamnu zavisnost aktivnosti mjerenja, analize, pohranjivanja i prikazivanja prostornih podataka s institucionalnim i društvenim okvirima unutar kojih se te aktivnosti provode.

Sveučilišni konzorcij za geografsku informacijsku znanost (engl. *University Consortium for Geographic Information Science* – UCGIS) iz Sjedinjenih Američkih Država sastavio je vjerojatno najiscrpniji i najsvestraniji popis znanja potrebnih za istraživanje geografskih informacija i primjenu tehnologija koje to omogućuju. Inicijativa UCGIS-a objavljena 2006. pod nazivom „*Geographic Information Science and Technology Body of Knowledge*“, pokrenuta je s ciljem sistematizacije znanja i kompetencija potrebnih za obrazovanje i osposobljavanje stručne radne snage u geografskoj informacijskoj znanosti i tehnologiji (engl. krat. *GIS&T*). Znanja su podijeljena na područja: analitičke metode, konceptualne osnove, kartografija i vizualizacija, aspekti projektiranja, modeliranje podataka, upravljanje podacima, geokomputacija (georačunanje), geoprostorni podaci, *GIS&T* i društvo te organizacijski i institucijski aspekti. Svako od tih područja dijeli se na jedinice, a jedinice sadrže popise tema (UCGIS, 2006).

Geoinformatika se odlikuje visokim stupnjem interdisciplinarnosti jer se u njoj isprepliću znanja i metode proizišle iz znanosti računarstva, geografije, geodezije, matematike, statistike, psihologije, filozofije, a njezina primjenjivost, koja se prvenstveno provodi u djelo pomoću geografskih informacijskih sustava, povezuje ju s brojnim znanstvenim istraživanjima u geologiji, znanostima o okolišu, prometnim znanostima, epidemiologiji, arheologiji, hidrologiji, meteorologiji i klimatologiji, povijesti, sociologiji, marketingu, agronomiji i mnogim drugim znanstvenim disciplinama koje prepoznaju važnost geografskih i prostornih informacija.

Ubrzo nakon prvog zamaha razvoja računalne moći procesiranja podataka tijekom sredine 20. stoljeća, pojavile su se prve zamisli upotrebe računala za pohranjivanje i obradu prostornih podataka. Politička i gospodarska važnost geografskih informacija utjecala je na razvoj prvih inicijativa za inventarizaciju prirodnih izvora bogatstva i državne imovine u obliku prostornih baza podataka te analize istih, uglavnom u obliku mjerenja veličina popisanih objekata.

Kao prvi geografski informacijski sustav navodi se (Longley i dr., 2005) *Canada Geographic Information System* (CGIS) koji je nastao nakon stvaranja niza ključnih poslovnih veza između geodetske i kartografske tvrtke *Spartan Air Services* i računalne tvrtke IBM te kanadskih javnih službi, *Canadian Land Inventory* (CLI) i *Agricultural Rehabilitation and Development Administration* (ARDA). Na temelju njihove suradnje definirani su zahtjevi i

potrebe računalnog sustava za geografske podatke te su izrađena konkretna i upotrebljiva računalna softverska i hardverska rješenja (ArcNews, 2012). Među znanstvenicima koji su radili na stvaranju CGIS-a ističe se geograf Tomlinson koji je svoj rad pod nazivom „*Computer Mapping: An Introduction to the Use of Electronic Computers in the Storage, Compilation and Assessment of Natural and Economic Data for the Evaluation of Marginal Lands*“ 1962. godine predstavio ARDA-i i time značajno doprinio uspostavi CGIS-a. Termin geografski informacijski sustav prvi je put objavljen 1968. godine u Tomlinsonovom radu naslovljenom „*A Geographic Information System for Regional Planning*“.

Iako danas geoinformatika predstavlja znanstvene temelje rada s geografskim informacijskim sustavima te se kao takva i definira (Frančula i Lapaine, 2008), promatrano iz povijesnog aspekta, sustav znanja koji ona predstavlja izgrađivan je postepeno, prateći razvoj konkretnih tehnologija objedinjenih unutar geografskih informacijskih sustava.

4.2.1. Geografski informacijski sustavi

Osim što je predmet proučavanja geoinformatike, geografski informacijski sustav ili skraćeno GIS, je praktična i fizička manifestacija geoinformatičkih teoretskih znanja. Iako je prije navedeno tumačenje GIS-a unutar šireg društvenog okvira, u ovom će se istraživanju GIS smatrati sustavom koji objedinjuje računalne programe, računalnu opremu, prostorne podatke te operatera koji njima upravlja. Termin GIS se u najužem smislu koristi za određeni računalni program ili softverski paket za pohranjivanje, prikazivanje i analizu prostornih podataka (Fotheringham i Wilson, 2008). Prema tom tumačenju, GIS je istraživački i analitički softverski alat, a zajedno s računalnim hardverom za korisnika predstavljaju sredstva za istraživanje geografskih i prostornih informacija.

Geografski ili prostorni podaci mogu se izdvojiti kao posebna sastavnica geografskih informacijskih sustava jer predstavljaju sadržaj koji se u njima pohranjuje te jasno određeni predmet istraživanja koji se pomoću GIS-a analizira i vizualizira. Preduvjet korištenja podataka u GIS-u su je postojanje svojstva prostornosti. Upravo se na tome temelji razlika geografskog informacijskog sustava od bilo kojeg drugog informacijskog sustava.

Prostornost podataka definirana je njihovim lokacijama te geometrijskim i topološkim svojstvima. Ako je porijeklo prostornih podataka i informacija geografska stvarnost, odnosno ako su njihove prostorne reference povezane sa Zemljinom površinom, onda je riječ o geografskim podacima i geografskim informacijama ili geoinformacijama.

Postupak pripisivanja eksplicitno definirane geografske ili prostorne reference podacima radi njihovog pohranjivanja ili analize unutar GIS-a naziva se georeferenciranje ili geokodiranje. U najširem smislu riječi georeference podataka i informacija o objektima, pojavama i procesima sa Zemljine površine mogu biti iskazane bilo kojim načinom izražavanja njihovog položaja i smještaja.

Uzimajući to u obzir, georeferenca objekta definirana njegovim relativnim položajem može poslužiti za njegovo iskorištavanje unutar GIS-a, ali samo ako se ona u konačnici može prevesti, odnosno povezati s apsolutnim lokacijama navedenih jedinicama određenog prostornog referentnog sustava. Pri tome do izražaja dolaze kartografske osnove GIS-a jer temelje prostornih referentnih sustava čine geodetski datumi, kartografske projekcije i koordinatni sustavi. Tako se primjerice geografska referenca ovog rada, činjenica da je on napisan u Hrvatskoj ili Zagrebu, može upotrijebiti u GIS-u kao geoinformacija samo ako su unutar tog istog sustava jasno prostorno definirani Hrvatska ili Zagreb. Čak se i poštanska adresa, koja u svakodnevnom građanskom životu predstavlja posve jasno određenu lokaciju, mora pretvoriti u apsolutni položaj ili lokaciju navedenu *x* i *y* (i *z*) koordinatama ili stupnjevima geografske širine i dužine (Kemp, 2008).

Za predočavanje prostornih podataka u GIS-u koriste se dva temeljna modela podataka: vektorski i rasterski. Vektorski model podataka omogućava ustroj prostornih podataka u skladu s konceptualnim modelom odvojenih objekata. Prema tom konceptualnom modelu, geografski se prostor tumači kao skup objekata jasno definiranih granica okruženih praznim prostorom. Kako bi se taj koncept primijenio u GIS-u, vektorskim modelom podataka sve se geografske pojave predstavljaju geometrijskim elementima točke, linije i poligona smještenima u prazan koordinatni sustav (Longley i dr., 2005).

Točka je definirana samo svojim koordinatama, primjerice *x* i *y* u dvodimenzionalnom koordinatnom sustavu, te je njezina prostornost opisana samo apsolutnim položajem bez dimenzija. Iako pojave iz geografskog prostora imaju dimenzije duljine, širine i visine, za predočavanje mnoštva objekata iz stvarnosti koriste se upravo točke. Ovisno o prostornoj razini

istraživanja ili vizualizacije podataka u GIS-u, odnosno mjerila ako se želimo poslužiti klasičnim kartografskim pojmom, točke se mogu upotrijebiti za kartiranje i prostornu analizu pojedinih stabala, ali i višemilijunskih gradova. Na sličan način, linije koje tvore skupovi povezanih koordinata i koje sadrže jednu dimenziju – duljinu, mogu služiti za predočavanje vodova, ali i najširih svjetskih rijeka, opet ovisno o mjerilu projekta koji korisnik izrađuje u GIS-u. Poligon ili mnogokut, kao dio ravnine omeđen konačnim brojem dužina također definiranih koordinatama primijenjenog referentnog sustava, ima dužinu i širinu, pokriva određeno područje te se može koristit modele svih prostornih objekata kojima se te dimenzije žele predočiti. Vektorski podaci koriste se u GIS-u radi njihove preciznosti, učinkovitog računalnog pohranjivanja, grafičke kartografske kvalitete i mogućnosti njihovog kartografskog projiciranja, prekapanja slojeva i prostornih analiza (Longley i dr., 2005; Kemp, 2008; Frančula i Lapaine, 2008).

U rasterskom modelu podataka geografski je prostor prikazan nizom ćelija s pripisanim stanovitim obilježjima tog prostora. Iako rasterske datoteke mogu sadržavati više kategorija atributivnih informacija, unutar jedne kategorije određenog obilježja svaka ćelija ima pripisanu samo jednu vrijednost. Zbog toga je za rasterske podatke iznimno bitna veličina ćelija ili piksela (engl. *pixel = picture element*) jer se za cijelo područje predstavljeno jednim najčešće kvadratnim pikselom vezuje samo jedna vrijednost nekog obilježja.

S podjelom prostora u mrežu ćelija zadane veličine može se očekivati zahvaćanje dvaju ili više različitih objekata ili prostornih pojava unutar dimenzija jedne ćelije. U nekim je slučajevima moguće primijeniti pravila na temelju kojih se unaprijed određuje koja će vrijednost biti dodijeljena takvoj rasterskoj ćeliji, poput većinskog površinskog udjela neke pojave unutar ćelije ili njezine pojave u središnjoj točki ćelije. Rasterski model podataka se koristi u GIS-u kao jedan od načina rješavanja problema predočavanja koncepta kontinuiranih ili neprekinutih polja kao vrste poimanja geografskog prostora i pojava u njemu. Prema tom konceptu geografska se stvarnost promatra kao konačni broj varijabli mjerljivih na svim lokacijama (Longley i dr., 2005). Intenzitet neke pojave prikazuje se vrijednostima zabilježenim u rasterskim ćelijama, a gradijent promjene neke pojave kvantificirane u takvom modelu, osim o svojstvu stvarnog prostora, ovisi i o veličini ćelija, odnosno prostornoj razlučivosti.

Glavna odlika GIS-a je preklapanje slojeva prostornih podataka. Slojevi GIS podataka mogu se shvatiti kao tematske karte – modeli stvarnosti koji predočavaju tematske geografske

cjeline. Preklapanje GIS slojeva je moguće ako su im usklađeni koordinatni sustavi te ako njihovi prostorni obuhvati u određenoj mjeri prikazuju isto područje. Istraživanje prostora, prostorne analize i stvaranje novih prostornih informacija pomoću GIS-a uvelike proizlazi upravo iz mogućnosti preklapanja brojnih slojeva iz prostorne baze podataka.

Značajan izvor podataka za GIS su daljinska istraživanja, odnosno podaci prikupljeni metodama daljinskih istraživanja i rezultati obrada tih podataka. Podaci iz daljinskih istraživanja uvoze se u GIS uglavnom u obliku snimaka, odnosno slikovnih datoteka koje spadaju pod rasterski model podataka. Mjerenje senzora za daljinska istraživanja raspoređeno je u ćelije rasterske datoteke. Kako bi se te datoteke mogle upotrijebiti u GIS-u, one trebaju biti georeferencirane i rektificirane. Postupkom georeferenciranja svakom pikselu digitalne snimke dodjeljuju se prostorne koordinate na osnovi referentnog koordinatnog sustava. Budući da snimke sadrže geometrijske deformacije uzrokovane gibanjem platforme na kojoj se nalazi senzor, nužno je provesti postupak rektifikacije kako bi se te deformacije uklonile. Za mjerenje i analizu geografskih podataka nekog prostora često se koristi više snimaka iz različitih izvora i u tom je slučaju iznimno važno da se slikovne datoteke i njihove ćelije točno preklapaju. Postupak usklađivanja više snimaka naziva se registracija ili georegistracija (Kemp, 2008, Frančula i Lapaine, 2008).

Prema Wilkinsonovim (1996) predviđanjima s kraja 20. stoljeća, očekivano povezivanje GIS-a i daljinskih istraživanja može se promatrati na tri načina. Jedan od njih podrazumijeva daljinska istraživanja kao alat za prikupljanje podataka za GIS. Zatim, slojevi GIS podataka koji se upotrebljavaju kao pomoćni ili dodatni podaci za poboljšanje informacija dobivenih daljinskim istraživanjima. Naposljetku, integrirano korištenje daljinskih istraživanja i GIS-a za analizu podataka i izradu modela (Donnay i dr., 2001).

4.2.2. Geografska objektno orijentirana analiza slika

Kao posebna disciplina u sklopu geoinformatike izdvaja se geografska objektno orijentirana analiza slika, odnosno prema terminu na engleskom jeziku i njegovom akronimu *geographic object-based image analysis – GEOBIA*. Geografska objektno orijentirana analiza slika znanstvena je disciplina koja se bavi razdiobom snimaka nastalih daljinskim istraživanjem Zemljine površine u smislene slikovne objekte i procjenom njihovih spektralnih, prostornih i

vremenskih svojstava s ciljem stvaranja novih geografskih informacija spremnih za korištenje u geografskim informacijskim sustavima (Hay i Castilla, 2008).

Termin je skovao Hay 2006. godine nakon akademskih diskusija održanih tijekom *OBIA* konferencije u Salzburgu (*1st International Conference on Object-based Image Analysis*) i prijedloga postavljenih na otvoreni web-site Sveučilišta u Calgaryju (WikiCalgary, 2014). Umjesto engleskog akronima *GEOBIA* predlaže se akronim termina prevedenog na hrvatski jezik – GEOBORANS. U trenutku pisanja ovog rada, takav akronim ili riječ nije bio povezan s niti jednim rezultatom Googleove internetske tražilice pa je razumno za pretpostaviti da se ona još ne koristi.

Geografska objektno orijentirana analiza slika izdvaja se kao posebna disciplina u odnosu na objektno orijentiranu analizu slika, koja je primjenjiva u istraživanjima drugih znanosti poput medicine i astronomije, zbog složenosti i posebnosti problematike prikupljanja i obrade geografskih informacija pomoću daljinskih istraživanja i GIS-a. Znanstveno istraživanje Zemljine površine sa svrhom stvaranja geografskih informacija zahtjeva povezivanje znanja i primjenu metoda iz brojnih znanstvenih disciplina. Osnovna poveznica između daljinskih istraživanja i GIS-a temelji se na pretvaranju klasificiranih slikovnih objekata iz rasterskog modela podataka u poligone u vektorskom modelu podataka koji predstavljaju geografske objekte (Castilla i Hay, 2008).

GEOBIA je razmjerno mlada disciplina geoinformatike te je dosad održano pet međunarodnih konferencija, od kojih je posljednja organizirana 2014. godine u Thessalonikiju, Grčkoj (5th GEOBIA, 2014). Aktualne teme znanstvenih istraživanja i rasprava su metode klasifikacije, multitemporalnih analiza i detekcija promjena, analiza urbanih prostora, provjera točnosti, segmentacija, primjena podataka prikupljenih novim senzorima, automatizacija postupaka, kartiranja pomoću GIS-a, zatim ontološka i metodološka pitanja, te primjena u znanostima o okolišu, šumarstvu i upravljanju kriznim situacijama.

4.3. Geografija

Ishodišna točka i konačni cilj ovog istraživanja nalaze se unutar teorijskog okvira geografije. Dok je velika pažnja usmjerena na proučavanje mogućnosti niza znanstveno transdisciplinarnih metoda i postupaka za uspješno provođenje klasifikacije zemljišnog pokrova, u samom temelju rada je promišljanje geografske problematike zadanog prostora.

Složenost odabranog prostora istraživanja – Grada Zagreba, očituje se u potpunoj međusobnoj prožetosti prirodne osnove i ljudske zajednice kao dvaju aspekata objekta proučavanja znanosti geografije. Fizičkogeografska obilježja prostora Grada Zagreba trajno su i nepovratno izmijenjena ljudskim djelovanjem ili su pod njegovim kontinuiranim utjecajem. Posljedica prisutnosti gradskog naselja u prostoru kao mega-staništa ljudske vrste su reduciranost raznolikosti i promjena brojnosti populacija biljnih i životinjskih vrsta, preoblikovanje kopnenih voda i reljefa, te izmjena klime.

Kopnene vode na području Grada Zagreba u velikoj su mjeri izmijenjene ljudskom intervencijom u okolišu ili su u potpunosti antropogene, odnosno uopće ne bi postojale bez ljudskog djelovanja. Gotovo cijeli tok rijeke Save u području istraživanja ovog rada reguliran je hidrotehničkim zahvatom čija je izgradnja započeta na prijelazu iz 19. u 20. stoljeće (Slukan Altić, 2010; Matković i Obad Šćitaroci, 2012). Pritoci rijeke Save koji se slijevaju s obronaka Medvednice također su regulirani (kanalizirani) ili u potpunosti prekriveni. Osim nekoliko mrtvaja rijeke Save, zagrebačke stajaće vode su šljunčare – posljedica eksploatacije mineralnih sirovina, zatim planski izrađena rekreativna jezera ili povremene akumulacije na preljevu odteretnog kanala Sava-Odra (SLjZ, 2013, str. 64).

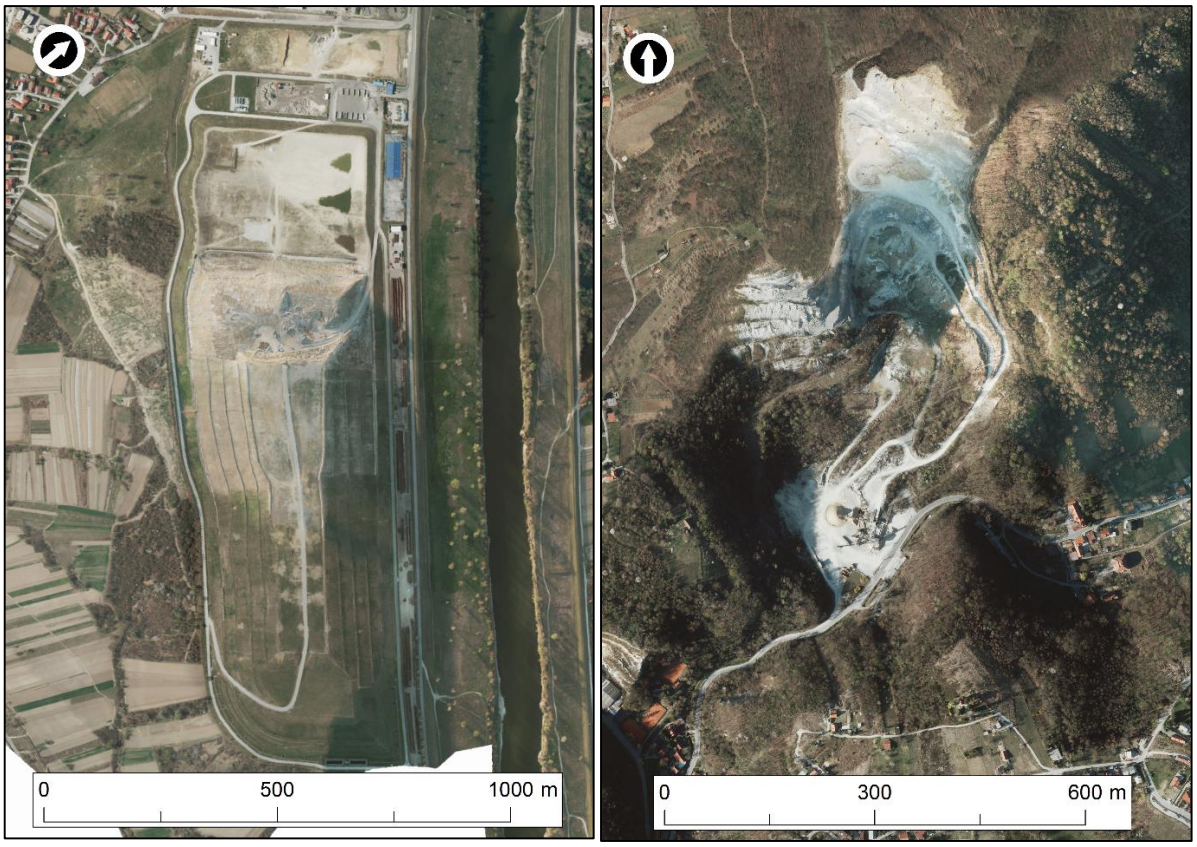

Sl. 7. Primjeri ljudske izmjene reljefa: odlagalište otpada Jakuševac i kamenolom kod Sutinskih vrela. Izvor: autor na temelju: CDOF, 2012.

Ljudskim izmjenama reljefa, na temelju kojih su nastala spomenuta umjetna vodena tijela, mogu se pridružiti kamenolomi poput onih u Markuševcu i Bizeku. Općenito, iskorištavanjem mineralnih sirovina i širenjem građevinskog područja nanosi se neobnovljiva šteta georaznolikosti prostora (Buzjak, 2011; DZZP, 2013). Iako se odlagalište otpada Jakuševac prije svega može pojmiti kao specifična građevinska struktura, ono bi se zbog svojih dimenzija i jedinstvene funkcije moglo također promatrati i kao antropogeni reljef.

Osim što se pod pojmom izgrađenih površina podrazumijeva gotovo potpuno odsustvo vegetacije, valja napomenuti da se izravni ljudski utjecaj proteže i na područja s vegetacijskim pokrovom. Vegetacija na području Grada Zagreba može se podijeliti na šume i kultivirane nešumske površine te staništa s korovnom i ruderalnom vegetacijom (DZZP, 2013). Zapravo se sa svom vegetacijom u tom prostoru gospodari te intenzitet njezine eksploatacije ovisi o načinu korištenja i namjeni određene površine (Hrsume.hr, 2014). Čak se odluke i mjere zaštite prirodnih šumskih zajednica mogu smatrati oblikom aktivnog gospodarenja ili upravljanja prirodnim resursima. Park prirode Medvednica (PP-Medvednica.hr, 2014) je primjer javne

ustanove čija je „djelatnost uključuje zaštitu, održavanje i promicanje Parka prirode Medvednica u cilju zaštite i očuvanja izvornosti prirode, osiguravanje neometanog odvijanja prirodnih procesa i održivog korištenja prirodnih dobara, nadziranje provođenja uvjeta i mjera zaštite prirode na području kojim upravljaju te sudjelovanje u prikupljanju podataka u svrhu praćenja stanja očuvanosti prirode.“

Utjecaj grada na klimu također je vrlo složen. Vjerojatno najpoznatiji primjer utjecaja gradskih područja na klimu je tzv. toplinski otok (engl. *urban heat island*), koji nastaje zbog velike koncentracije zemljišnog pokrova izgrađenih površina na određenom području (Šegota, 1989; Quattrochi i Ridd, 1994; Babić i dr., 2012).

S druge strane, koliko god ljudsko djelovanje na Zemljinoj površini tumačili kao destruktivno ili dominantno, ono ne može u potpunosti poništiti ili negirati postojanje prirodne osnove ili prirodnih uvjeta u kojima obitava neka ljudska zajednica. Složenost te interakcije dovodi u pitanje poimanje prostora na temelju dihotomije prirodni okoliš – čovjek ili divljina – kultivirani krajolik. Čovjek i prirodni okoliš doista jesu dvije sastavnice istog sustava. Oni predstavljaju krajnosti jednog kontinuuma te na taj način stvaraju privid dihotomije (Nir, 1990). Grad je modificirani ekosustav u kojem čovjek predstavlja biološku vrstu koja ima iznimno jak utjecaj na organske i anorganske sastavnice tog ekosustava te mijenja, primjerice protok energije i prehrambene mreže (Vresk, 1996).

Čak i kad ljudsko djelovanje na okoliš nije očito i jasno vidljivo, krajolici nigdje nisu izolirani od čovjekovog utjecaja jer se on ne svodi samo na ljudsku fizičku prisutnost i primjenu ljudskih tehnologija, već se očituje i u društvenim ili civilizacijskim konceptima poput vlasništva (Ipsen, 2009).

Drugi aspekt složenosti geografskog prostora koji se u svakodnevnom laičkom, ali često i u akademskom diskursu maksimalno pojednostavljuje na razinu dihotomije je podjela prostora na urbani i ruralni. Iako većina ljudi smatra da ima jasnu predodžbu tih dvaju pojmova te na temelju njega može razlikovati jedan vid stvarnog prostora od drugog, oni su predmet vrlo značajne rasprave u geografiji, osobitu u njezinim disciplinama: urbanoj i ruralnoj geografiji.

Suvremeni procesi urbanizacije, suburbanizacije, deagrarizacije, deruralizacije, i općenito razvoja ili propadanja nekog prostora, dovode u pitanje dihotomijsko poimanje tipova naselja. Novi oblici naseljenosti često nisu urbani, niti ruralni, a društvene znanosti ih tumače

na brojne načine te različito nazivaju. Samo pregled nekih termina koji se koriste za opis krajolika upućuje na zaključak da je suvremena ekumena vrlo kompleksna te da se zbivaju procesi uzajamne hibridizacije prostora: megaurbani, posturbani, postsuburbani, multifunkcionalni, periurbani, rurbani, *middle landscape* (engl.), *fringe* (engl.), *sprawl* (engl.), *desakota* ili *kotadesasi* (indonez.) i dr. (McGee, 1987; Fishman, 1990; Soja, 1990; Rowe, 1991; Tacoli, 1998; Eeckhout i Jacobs, 2009; Ipsen, 2009).

Na pitanja koja prate znanstvene i filozofske definicije pojmova urbano i ruralno, grad i selo, nadovezuju se još složeniji zadaci diferenciranja i razgraničavanja njihovih pojava u stvarnom prostoru, na Zemljinoj površini, za službene statističke i administrativne potrebe . Čak i ako se prepoznaju ključne varijable za određivanje gradskih naselja poput kompaktnosti izgrađenog prostora, veličine i centralnosti naselja te gradskog načina života u naselju (Bobek, 1927, 1938; Klöper 1956 u Vresk 2002), zbog izrazite različitosti pojavnosti naselja kao fizičkog artefakta i društvenog fenomena, vrlo je teško postaviti granične vrijednosti tih varijabli (Vresk, 2002). Parametri tih varijabli, odnosno modeli diferenciranja gradskih naselja razlikuju se prostorno i vremenski, među državama i u različitim povijesnim trenucima tih država.

Tab. 6. Model izdvajanja gradskih naselja u Hrvatskoj 1961. i 1971. godine.

Broj stanovnika	Udio nepoljoprivrednog stanovništva
2000 – 2999	≥ 90 %
3000 – 9999	≥ 70 %
10.000 – 14.999	≥ 40 %
≥ 15.000	≥ 30 %

Izvor: Vresk, 2002, 5.

Tab. 7. Model izdvajanja gradskih naselja u Hrvatskoj 1981. i 1991. godine.

Broj stanovnika	Poljoprivredno stanovništvo	Udio radnika u mjestu stanovanja	Udio domaćinstava bez poljoprivrednog gospodarstva
2000 – 4999	≤ 10 %	≥ 50 %	≥ 50 %
5000 – 9999	≤ 10 %	≥ 50 %	-
≥ 10.000	-	-	-

Izvor: Vresk, 2002, 6.

Tab. 8. Model izdvajanja gradskih naselja u Hrvatskoj 2001. godine.

Broj stanovnika	Udio nepoljoprivrednih kućanstava	Udio zaposlenih u naselju stanovanja (osim aktivnoga poljoprivrednog stanovništva)	Stupanj centraliteta
< 2000	≥ 50 %	≥ 25 %	subregionalni centar
2000 – 4999	≥ 50 %	≥ 25 %	-
5000 – 9999	-	≥ 25 %	-
≥ 10.000	-	-	-

Izvor: Vresk, 2008; Lukić, 2009; DZS, 2011b, 17.

Takvi se modeli, s većim ili manjim brojem varijabli, koriste u službene statističke i upravne svrhe za klasifikaciju naselja u svega dva ili tri tipa: gradska, seoska i mješovita, odnosno klasifikaciju prostora u urbani, ruralni i prijelazni.

U Hrvatskoj su tijekom 20. stoljeća za diferencijaciju urbanih i ruralnih naselja upotrebljavana demografska, socioekonomska i funkcionalna obilježja naselja: broj stanovnika, udio nepoljoprivrednog stanovništva, udio zaposlenih u mjestu stanovanja, udio migranata, te upravni status (Vresk, 1986, 2002). Za izradu proširenih modela tipologije naselja provedene su dublje analize funkcija i sadržaja naselja (Lukić, 2010). Ipak, morfološko-fizionomska

sastavnica prostorne strukture naselja nije definirana varijablama postojećih modela ili se na nju ukazuje posredno, preko statističkih podataka o udjelu nepoljoprivrednih kućanstava (DZS, 2011b).

Morfološka struktura naselja je čest predmet istraživanja u geografiji i ostalim znanostima koje se bave urbanim prostorom. Osim prostornog rasporeda i međusobnog odnosa zgrada i prometnica, istraživanja morfologije naselja mogu obuhvaćati i način korištenja zemljišta i vlasničke odnose u prostoru (Vresk, 2002). Istraživanju se može pristupiti iz aspekta fizičkogeografskih ili sociogeografskih čimbenika morfološke strukture naselja, a proučavanje određenog prostora može biti ograničeno na analizu njegovog momentalnog stanja ili historijsko-geografskog razvoja. Morfološka obilježja naselja znanstveno se proučavaju u Hrvatskoj na svim razinama, od arhitektonskih i urbanističkih elemenata građevinskih jedinica, preko prostornog rasporeda elemenata izgrađenog prostora u naseljima ili njihovim pojedinim dijelovima, do veličine i oblika cjelokupnih naseljenih područja (Grgurević, 1984; Biškup, 2002; Crljenko, 2012; Njegač i dr., 2012). Usprkos navedenom, rezultati i saznanja proizišla iz takvih istraživanja ne primjenjuju se izravno u upravnim i statističkim modelima diferencijacije naselja.

U internacionalnim znanstvenim istraživanjima morfologije naselja, često se primjenjuju podaci i metode iz daljinskih istraživanja. Unutar poddiscipline urbanih daljinskih istraživanja, razina ili mjerilo proučavanja morfoloških struktura gradova uvjetovat će nužne tehničke karakteristike sustava za daljinska istraživanja i konkretne metode obrade i analize podataka. Donnay i dr. (2001) smatraju urbana daljinska istraživanja vrlo geografskom disciplinom jer zahtijevaju interdisciplinarnost prirodnih i društvenih znanosti kao i usporednu upotrebu geografskih informacijskih sustava i daljinskih istraživanja. Autori naglašavaju vrijednost daljinskih istraživanja kao izvora informacija na temelju kojih se mogu analizirati i tematski vizualizirati prostorne strukture urbanih područja.

Obrada podataka prikupljenih pomoću daljinskih istraživanja i klasifikacija spektralnih karakteristika promatranog područja te njihovo konačno pretvaranje u razumljive geografske informacije u obliku klasa zemljišnog pokrova, omogućavaju izradu jednostavnih, široko primjenjivih i usporedivih mjera prividne dihotomije prirodnog okoliša i umjetnog antropogenog prostora, odnosno krajnjih točaka urbano-ruralnog kontinuuma (Besussi i dr., 2010).

Mjerenja i procjene veličine i fizionomsko-morfološke strukture naselja mogu se temeljiti na indikatorima proizišlim iz statističke klasifikacije obilježja i prostorne analize geometrije i topologije jedinica zemljišnog pokrova (Batty i Longley, 1994).

Povećanje prostorne razlučivosti snimaka daljinskih istraživanja pruža priliku za nadopunjavanje i promjenu sad već ustaljenog tematskog kartografskog prikazivanja distribucije socijalno-geografskih pojava analiziranog prostora pomoću GIS-a (Harris i Longley, 2000). One više ne moraju biti ograničene okvirima uobičajene vizualizacije geografskih informacija pomoću kartograma izrađenih na temelju poligona administrativnih jedinica i sličnih vektorskih podataka.

U urbanoj geografiji i ostalim znanstvenim disciplinama koje se bave istraživanjem urbanog prostora i urbanizacije često se koristi termin nekontroliranog širenja grada (engl. *urban sprawl*). Iako se taj pojam tumači na brojne načine, od dovođenja u pitanje ili negiranja postojanja takve pojave do njegove upotrebe za sve oblike fizičkog horizontalnog rasta urbanog naselja, te se njegov karakter ocjenjuje kao vrlo negativan ili posve neutralan, on se svejedno znanstveno proučava, mjeri i sistematizira.

Tipologija oblika prostornog širenja gradova ili *sprawla* prema Galsteru i dr. (2001) temelji se na osam obilježja: gustoći, koncentraciji, grupiranju, centralitetu, jezgrenosti, načinu korištenja zemljišta te blizini. Pomoću tih mjera rast i razvoj određenog urbanog prostora može se npr. opisati kao kompaktni, disperzni, linearni, polinukleusni, skokoviti itd. Brojnost i raznolikost takvih oblika i česte nejasne granice morfoloških struktura u prostoru predstavljaju izazov za urbana daljinska istraživanja (Besussi i dr., 2010).

5. PODACI I METODOLOGIJA ISTRAŽIVANJA

5.1. Podaci

5.1.1. Multispektralne satelitske snimke sustava RapidEye

Podaci koji čine osnovu ovog istraživanja prikupljeni su satelitskim sustavom tvrtke BlackBridge RapidEye. Klasifikacija zemljišnog pokrova izvršena je na multispektralnim satelitskim snimkama. Područje upravne jedinice Grada Zagreba, obrađene u ovom istraživanju, podijeljeno je unutar pet scena. Pet kanala satelitske snimke RapidEye radi lakšeg poimanja predstavljeni su nazivima boja, a obuhvaćaju sljedeće valne duljine elektromagnetskog spektra: plavi (440 – 510 nm), zeleni (520 – 590 nm), crveni (630 – 685 nm), crveni rub (690 – 730 nm) te bliski infracrveni (760 – 850 nm). Veličina piksela, odnosno površinska razlučivost u korištenoj preuzorkovanoj ortorektificiranoj snimci kategorije 3A jest pet metara. Podaci u takvim isporučenim datotekama su 16-bitni, cijelih brojeva bez predznaka. Veličina scene je 5000 puta 5000 piksela ili 25 puta 25 km, odnosno prikazuje područje površine 625 km^2 (BlackBridge RapidEye, 2014). Prema narudžbi je iz pet satelitskih scena izdvojeno područje nešto šire od područja Grada Zagreba.

Razlozi za odabir satelitskih snimaka sustava RapidEye su višestruki. Prije svega, istraživanje je zahtijevalo multispektralne snimke područja Grada Zagreba. Područje istraživanja je trebalo biti podijeljeno u što manji broj odvojenih satelitskih snimaka. Ako je područje prikazano u više scena, one su trebale biti vremenski što usklađenije, odnosno snimljene istog datuma ako okolnosti to dopuštaju. Zbog ciljeva istraživanja naoblaka je trebala biti svedena na minimum. Također, snimke su trebale biti vremenski usklađene s Popisom stanovništva 2011. i njegovim kritičnim trenutkom 31.ožujka 2011. – drugim ključnim izvorom podataka za ovo istraživanje. Površinska razlučivost je trebala biti dovoljno velika za opravdanu upotrebu metoda objektno orijentirane klasifikacije, ali i razmjerno mala kako bi se uklonio problem viška nepotrebnih podataka, koji mogu predstavljati smetnju prilikom klasifikacije zemljišnog pokrova. Prema navedenom, među dostupnim izvorima podataka odabran je satelitski sustav RapidEye. Njegove dodatne pogodnosti i prednosti su radiometrijska razlučivost, spektralno područje crvenog ruba te naposljetku povoljna cijena podataka.

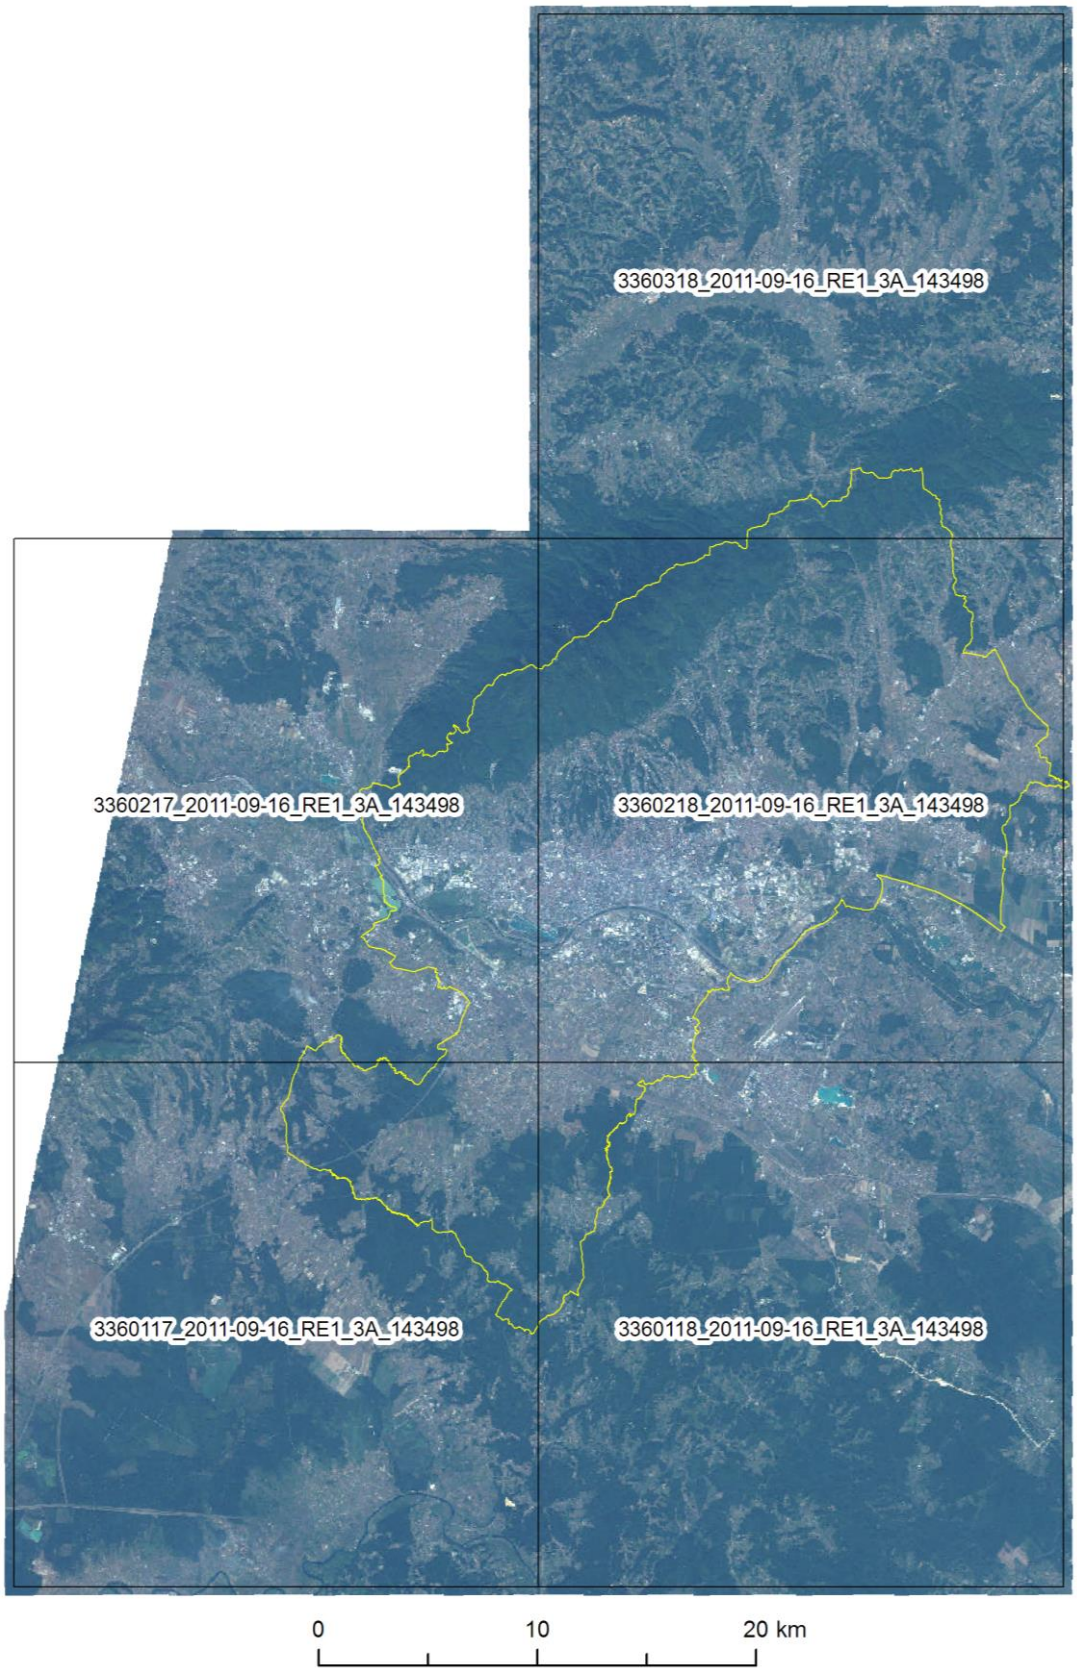

Sl. 8. Nazivi, prostorni raspored i veličina upotrijebljenih satelitskih snimaka RapidEye i granica upravne jedinice Grada Zagrebam. Izvor: autor na temelju: RapidEye, 2011; RPJ, 2011.

Između ostalih zadataka, u okviru istraživanja ispitana je smislenost objektno orijentirane klasifikacije zemljišnog pokrova na snimkama ove površinske razlučivosti, odnosno veličine piksela 5 m. Promatrajući ulogu objektno orijentirane klasifikacije u daljinskim istraživanjima, njihov značaj je porastao s pojavom satelitskih snimaka visoke i vrlo visoke razlučivosti koje karakteriziraju objekti veći od veličine zasebnih piksela (Veljanovski i dr., 2011).

S druge strane, metode segmentacije imaju smisla ako se pomoću njih mogu izdvojiti objekti prema zadanim kriterijima koji zanimaju istraživača. Dokle god se taj zadatak može uspješno izvršiti, površinska razlučivost ne bi trebala predstavljati ograničavajući čimbenik za objektno orijentiranu klasifikaciju.

Površinska razlučivost se navodi kao vrlo bitno svojstvo snimaka kad je riječ o urbanim daljinskim istraživanjima. Upravo se razlučivost od 5 m navodi kao gornja granica za uspješno ili dovoljno točno kartiranje pokrova poput zgrada, prometnica i manjih gradskih zelenih površina (Welch, 1982; Woodcock i Strahler, 1987; Herold i dr., 2007).

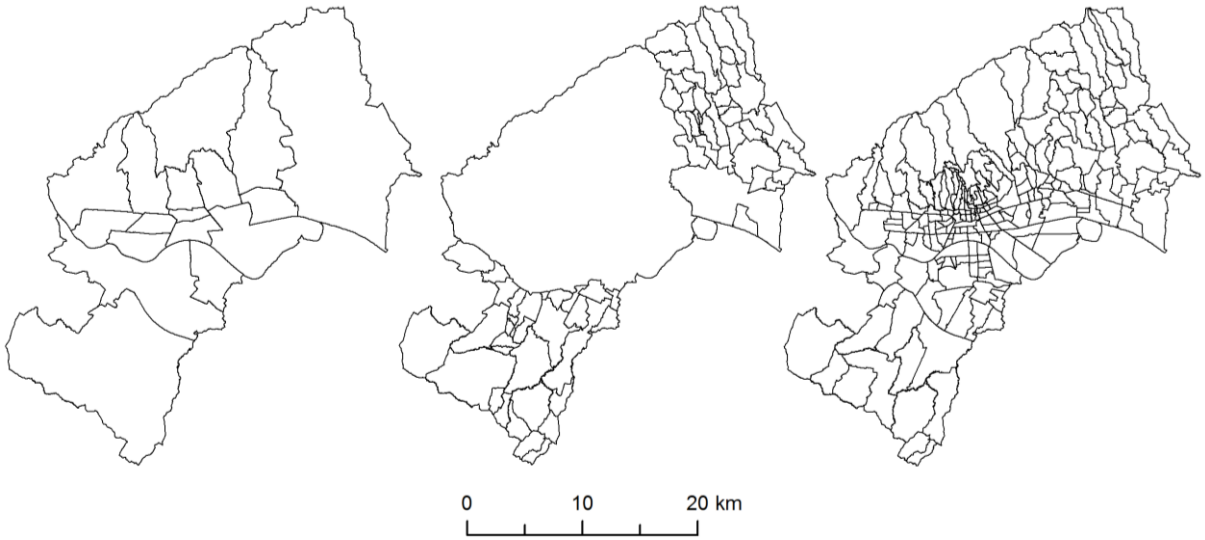

Sl. 9. Prostorne jedinice Grada Zagreba upotrijebljene u istraživanju: gradske četvrti (17), naselja (70), mjesni odbori (218). Izvor: autor na temlju: RPJ, 2011.

5.1.2. Vektorski podaci u GIS-u

Vektorski podaci upotrijebljeni u istraživanju predstavljaju područja i granice dviju razina upravnih jedinica Grada Zagreba i jednu razinu prostorno-statističke jedinice. Kako bi se planirane višestruke računalne operacije preklapanja podataka mogle provesti, upotrijebljeni su poligonski slojevi mjesnih odbora, naselja, gradskih četvrti i cjelokupnog područja Grada Zagreba. Ti su slojevi bili nužni za definiranje granica skupa podataka dobivenih daljinskim istraživanjima, te za mjerenje i analizu rezultata klasifikacije zemljišnog pokrova prema određenoj službenoj ili statističkoj podjeli istraženog prostora. Izvor podataka je hrvatski Registar prostornih jedinica sa stanjem iz 2011. godine.

5.1.3. Referentni podaci za provjeru točnosti klasifikacije

Za referentne podatke, odnosno podatke pomoću kojih se može vršiti odabir uzoraka za nadziranu klasifikaciju zemljišnog pokrova ili provjeravati točnost izvršenih klasifikacija, upotrijebljene su zračne i satelitske snimke veće površinske razlučivosti od satelitskih snimaka RapidEye. Te su snimke upotrijebljene kao izvor atributivnih podataka, odnosno kao slikovna podloga iz koje se mogu prikupiti podaci o zemljišnom pokrovu. Oni su pripisani vektorskom sloju podataka pomoću kojeg je u konačnici izvršena provjera točnosti klasifikacije. Ti su atributivni podaci dobiveni ljudskom vizualnom interpretacijom referentnih snimaka.

Upotrijebljene referentne snimke su: digitalni ortofoto područja Grada Zagreba iz 2012. godine te satelitske snimke tvrtke DigitalGlobe iz 2011. godine. Digitalni ortofoto (DOF) čine ortorektificirane zračne snimke u boji pohranjene u obliku digitalnih rasterskih datoteka. Površinska razlučivost tih snimaka je 0,25 m, a aerofotogrametrijsko snimanje Grada Zagreba izvršeno je 26. ožujka 2012 (CDOF, 2012). Upotrijebljene satelitske snimke tvrtke DigitalGlobe prikupljene su satelitima GeoEye-1, WorldView-1 i WorldView-2 tijekom srpnja i kolovoza 2011. godine. Površinska razlučivost tih snimaka je u rasponu od 0,45 do 0,55 m (DigitalGlobe, 2011).

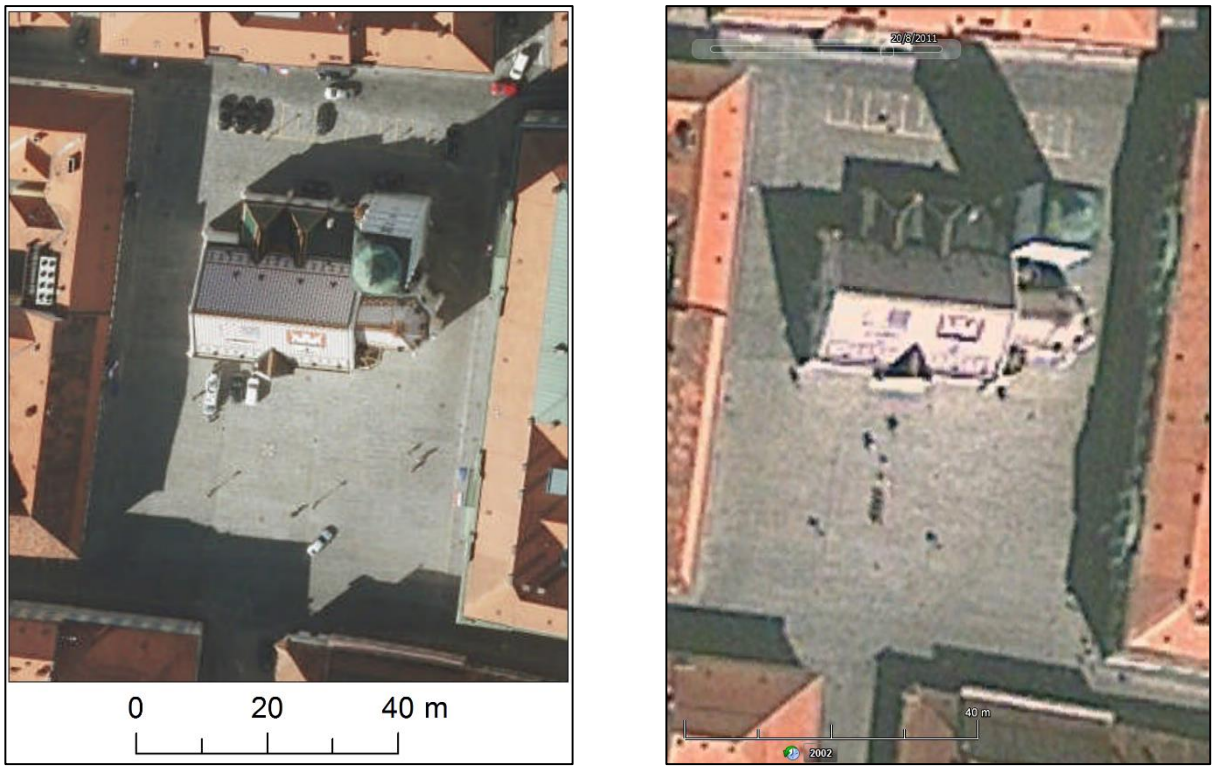

Sl. 10. Detalji s referentnih snimaka upotrijebljenih u istraživanju: Digitalni ortofoto s Geoportala Zagrebačke infrastrukture prostornih podataka i satelitska snimka GeoEye-1 s Google Earth-a. Izvor: CDOF, 2012; DigitalGlobe, 2011.

Navedene zračne i satelitske snimke javno su dostupne korisnicima putem interneta na Geoportalu Zagrebačke infrastrukture prostornih podataka te na Google Earthu, među arhivskim snimkama područja Grada Zagreba. Za ovo je istraživanje bilo vrlo bitno pronaći referentne podatke veće površinske razlučivosti od obrađenih RapidEye satelitskih snimaka koji se s njom što bolje vremenski podudaraju, kako bi zamijenili terenski rad i provjeru stanja zemljišnog pokrova u stvarnom geografskom prostoru. Smislenost prikupljanja referentnih podataka terenskim radom, dovedeno je u pitanje zbog vremenskog razmaka između datuma nastanka satelitskih snimaka na kojima je izvršena klasifikacija zemljišnog pokrova i početka istraživanja. U tom su se razdoblju dogodile brojne promjene u zadanom prostoru proučavanja.

Ipak, prilikom korištenja drugih satelitskih ili zračnih snimaka kao referentnih podataka treba biti posebno oprezan jer zbog krive interpretacije zemljišnog pokrova može doći do značajnog neslaganja stvarne kvalitete izvedene klasifikacije te lošijih pokazatelja točnosti

klasifikacije dobivenih izradom matrice pogrešaka (Congalton i Green, 2009). Pretpostavlja se da bi glavni uzrok mogućih neslaganja referentnih i klasificiranih snimaka upotrijebljenih u istraživanju moglo biti njihovo vremensko nepodudaranje, odnosno različiti datumi snimanja područja Grada Zagreba. Snimke s Google Eartha prethode, a DOF slijedi nakon datuma nastanka snimaka RapidEye. Vremenske razlike referentnih snimaka i klasificiranih RapidEye snimaka sežu od -71 dan do +192 dana. Unutar tih razdoblja uočljive su određene promjene u okolišu.

Razlog kombiniranog korištenja DOF-a i Google Earth snimaka jest manjkavost jednog i drugog izvora podataka. Prostorna ili geometrijska točnost mozaika satelitskih snimaka koji čine Google Earth virtualni globus je manja od ortofoto snimaka Zagreba. S druge strane, javno dostupno izdanje DOF-a Grada Zagreba putem interneta sadrži namjerno izmijenjene snimke na područjima vojnih i ostalih strateških objekata, poput vojarne Croatia, vojnih objekata uz uzletno-sletnu stazu u Lučkom ili zgrade Hrvatske radio televizije. Uobičajena praksa je promjena tih dijelova snimaka u vegetacijski pokrov.

5.1.4. Popis stanovništva 2011.

Popis stanovništva 2011. proveden je u razdoblju od 1. do 28. travnja 2011., a dan 31. ožujka 2011. u 24 sata smatra se kritičnim trenutkom Popisa. Svi podaci odnose se na teritorijalni ustroj Republike Hrvatske na dan 31. ožujka 2011. godine i stanju tehničke dokumentacije Državne geodetske uprave, odnosno prema službenom Registru prostornih jedinica. „Zakonom je propisano da se tehnička dokumentacija sastoji od popisa prostornih jedinica, preglednih kartografskih prikaza, skica statističkih i popisnih krugova te obrazaca PK - Podaci o popisnom krugu za sve prostorne jedinice relevantne za provođenje Popisa (država - ujedno i statistička prostorna jedinica 1. razine, statističke prostorne jedinice 2. razine, županije i Grad Zagreb - statističke prostorne jedinice 3. razine, gradove i općine, jedinice mjesne samouprave – gradski kotari, gradske četvrti i područja mjesnih odbora, naselje, statistički krug, popisni krug, ulica i trg te zgrada s pripadajućim kućnim brojevima)“ (DZS, 2011a). Za potrebe ovog istraživanja upotrijebljeni su podaci o ukupnom broju stanovnika prostornih jedinica na razini gradskih četvrti, naselja i mjesnih odbora Grada Zagreba.

5.2. Metodologija

5.2.1. Predobrada podataka

Područje Grada Zagreba pokriveno je s pet snimaka satelitskog sustava RapidEye. Iako su snimke georeferencirane i rektificirane, uočeno je razmjerno maleno, ali vidljivo prostorno nepoklapanje s referentnim podacima za provjeru točnosti te vektorskim slojevima podataka iz Registra prostornih jedinica. Ustanovljene razlike položaja izvornih slojeva podataka izmjerene su kako bi se nakon postupka klasifikacije dobiveni rezultati, u obliku novih slojeva podataka, mogli koregistrirati s referentnim snimkama. Budući da je planirana klasifikacija samo na temelju RapidEye snimaka i slojeva podataka proizišlih iz njihove obrade, korekcije položaja snimaka prije postupka klasifikacije nisu bile nužne. Utvrđena je razlika RapidEye snimaka u odnosu na referentne snimke iznosila 10 m po osi x i 17 m po osi y.

Spajanje satelitskih snimaka Grada Zagreba nije provedeno prije postupka segmentacije i klasifikacije zbog dva razloga. Postupak spajanja snimaka podrazumijeva obradu podataka čija je posljedica određena izmjena vrijednosti piksela. Susjedne scene RapidEye snimaka preklapaju se na svojim rubnim dijelovima u zoni širine 500 m. U tom području pikseli različitih, ali susjednih scena predočuju isti dio Zemljine površine. Kod takvih piksela u upotrijebljenim snimkama uočene su male razlike brojčanih vrijednosti (engl. *digital number*, krat. *DN*). Budući da se podaci u potpunosti ne podudaraju, mozaiciranje bi podrazumijevalo prevagu određenog skupa podataka ili usklađivanje uprosječivanjem. Usklađivanje odvojenih scena radi njihovog spajanja u jednu cjelovitu datoteku operateru klasifikacije znatno bi olakšalo rad, ali ono znači određene promjene izvornih podataka koje se u ovom istraživanju htjelo u najvećoj mogućoj mjeri izbjeći jer bi se one mogle odraziti na sam postupak klasifikacije zemljišnog pokrova. Spajanje više scena u jednu bi također rezultiralo stvaranjem jedne velike datoteke koja bi znatno usporila rad računala prilikom provođenja postupaka segmentacije i klasifikacije ili bilo koje druge računalne obrade. Kako bi se uštedjelo vrijeme prilikom istraživanja brojnih i često računalno zahtjevnih metoda obrade i analize velikih datoteka poput satelitskih snimaka preporuča se odabir manjih podskupova (engl. *subset*) podataka (Trimble, 2014b). Zaključci i rezultati istraživanja na takvim manjim uzorcima podataka zatim se primjenjuju na cjelokupnoj sceni. Za ovo istraživanje nisu izdvajani manji podskupovi podataka već je među pet scena koje pokrivaju dijelove Grada Zagreba odabrana ona za koju je, nakon inicijalnog vizualnog pregleda snimaka, utvrđeno da sadrži sve tražene

klase zemljišnog pokrova te je ujedno što manja, promatrano iz aspekta računalne memorije. Osim toga za temeljito ispitivanje mogućnosti metoda analize i klasifikacije bilo je nužno odabrati snimku koja obuhvaća složeni ili heterogeni geografski prostor. Ta se složenost očituje u geomorfološkim, biogeografskim i hidrogeografskim razlikama te različitostima prostora promatranog kroz koncept urbano-ruralnog kontinuuma. Odabrana snimka 3360217, koja je poslužila za početne faze istraživanja, pokriva dio Grada Zagreba u kojem se nalazi gorski prostor Medvednice i nizinski prostor Posavske ravnice, gusto izgrađeno gradsko područje i manja naselja na rubovima administrativne jedinice, velike međugradske prometnice i uske ulice ili lokalne ceste, velike supermarkete i hipermarkete te obiteljske kuće, crnogorične i bjelogorične šume, tekućice i stajaće vode, šljunčare, rekreativna jezera i bare.

Drugi razlog za odvojenu klasifikaciju svih pet scena je upravo istraživanje mogućnosti metoda i postupaka klasifikacije na različitim satelitskim snimkama koje prikazuju odvojene dijelove Zemljine površine, odnosno različita urbana i periurbana područja. Jedan od zahtjeva koji se postavlja prilikom istraživanja metoda klasifikacije zemljišnog pokrova i načina korištenja zemljišta je mogućnost njihove primjene na različitim područjima i u različitim vremenima (Anderson, 1971, 1976). Područja Grada Zagreba, podijeljena u satelitskim snimkama RapidEye upotrijebljenih za istraživanje, razlikuju se geografski po primjerice reljefnim obilježjima ili stupnju izgrađenosti prostora te udjelom različitih zemljišnih pokrova u pojedinoj sceni. Razlike brojčanih vrijednosti zabilježenih u pikselima istog položaja, odnosno koordinata, ustanovljene su na područjima preklapanja satelitskih snimaka. Jedan od zadatka istraživanja je izrada postupaka ili algoritma za klasifikaciju koji će se moći primijeniti na svim scenama. Odvojene klasificirane scene bi se potom trebale spojiti u jedan jedinstveni skup podataka, odnosno u jednu datoteku.

Prema mišljenju mnogih znanstvenika, brojčana vrijednost piksela slikovnih datoteka satelitskih snimaka ne predstavljaju fizička svojstva (Campbell i Wynne, 2011), već su obrađeni niz podataka koji u svakom kanalu te datoteke predstavljaju vrijednost svjetline (engl. *brightness*) prikazane sivom ljestvicom (engl. *grayscale*). Za brojčane vrijednosti piksela izraženih cijelim brojevima u rasponima od primjerice 256, 1024, 2048, 4096 ili 65536, u datotekama od 8, 10, 11, 12 ili 16 bita, često se navodi nužnost preračunavanja u vrijednost reflektancije koja numerički može biti izražena koeficijentom ili postotkom. Da bi se to preračunavanje moglo provesti, nužni su detaljni metapodaci o satelitskim snimkama, zatim podatak o udaljenosti Sunca i Zemlje na datum snimanja i dodatni podaci o senzoru. Za

korekcije atmosferskog utjecaja na snimke potrebne su dodatne računske operacije. Navedeni bi postupak trebao omogućiti učinkovitiju usporedbu odvojenih skupova podataka, odnosno različitih satelitskih snimaka. Pokušaji takve pretvorbe podataka u ovom istraživanju nisu doveli do zadovoljavajućih rezultata jer su novonastali 32-bitni podaci s decimalnim vrijednostima bili uzrok problema u kasnijim postupcima segmentacije slikovnih datoteka. Pritom se nameće rješenje u obliku još jednog dodatnog pretvaranja podataka, no ovaj put u datoteke s manje bita i s cijelim brojevima. Budući da se sa svakom novom izmjenom podataka mogu gomilati i greške u njima, odlučeno je da će se problematika pretvaranja brojčanih vrijednosti piksela u vrijednosti reflektancije podrobnije proučiti u daljnjim istraživanjima.

Podaci iz satelitskih snimaka, na kojima su provedeni postupci segmentacije i klasifikacije primijenjeni u ovom istraživanju, predstavljaju vrijednosti radijancije na senzoru ($W\ m^{-2}\ sr^{-1}$) pomnožene s faktorom 100 i pohranjene u 16-bitne datoteke (RapidEye, 2013). Sve izvršene aritmetičke operacije i obrade podataka izvedene za potrebe ovog istraživanja temelje se na tim brojčanim vrijednostima (DN).

Na temelju tih vrijednosti podaci iz multispektralnih satelitskih snimaka mogu se vizualizirati na različite načine, ali prilagođene ljudskom oku, ovisno o tome koji će spektralni dio snimke biti predstavljen kao crveni, zeleni ili plavi kanal u RGB formatu digitalne slike. O tom odabiru i poretku spektra snimaka u kanalima boja vidljivim ljudskom oku ovisi hoće li na zaslonu računala biti prikazana npr. uobičajena slika poput onih nastalih pomoću sveprisutnih digitalnih fotoaparata ili slika nastala lažnim kombiniranjem boja (engl. *false color composite*) na kojoj mogu biti vidljiva svojstva okoliša snimljena u dijelovima elektromagnetskog spektra, poput bliskog infracrvenog, koji inače nisu vidljivi ljudskim okom. Upotrijebljeni računalni program eCognition nudi vrlo pregledne i lako upravljive mogućnosti vizualizacije različitih slojeva ili spektra snimaka u RGB kanalima slike te su one u istraživanju upotrijebljene u svim fazama rada – inicijalnom pregledu, vizualnoj interpretaciji, odabiru uzoraka za klasifikaciju, odabiru ključnih obilježja za klasifikaciju te tijekom provjere točnosti klasifikacije.

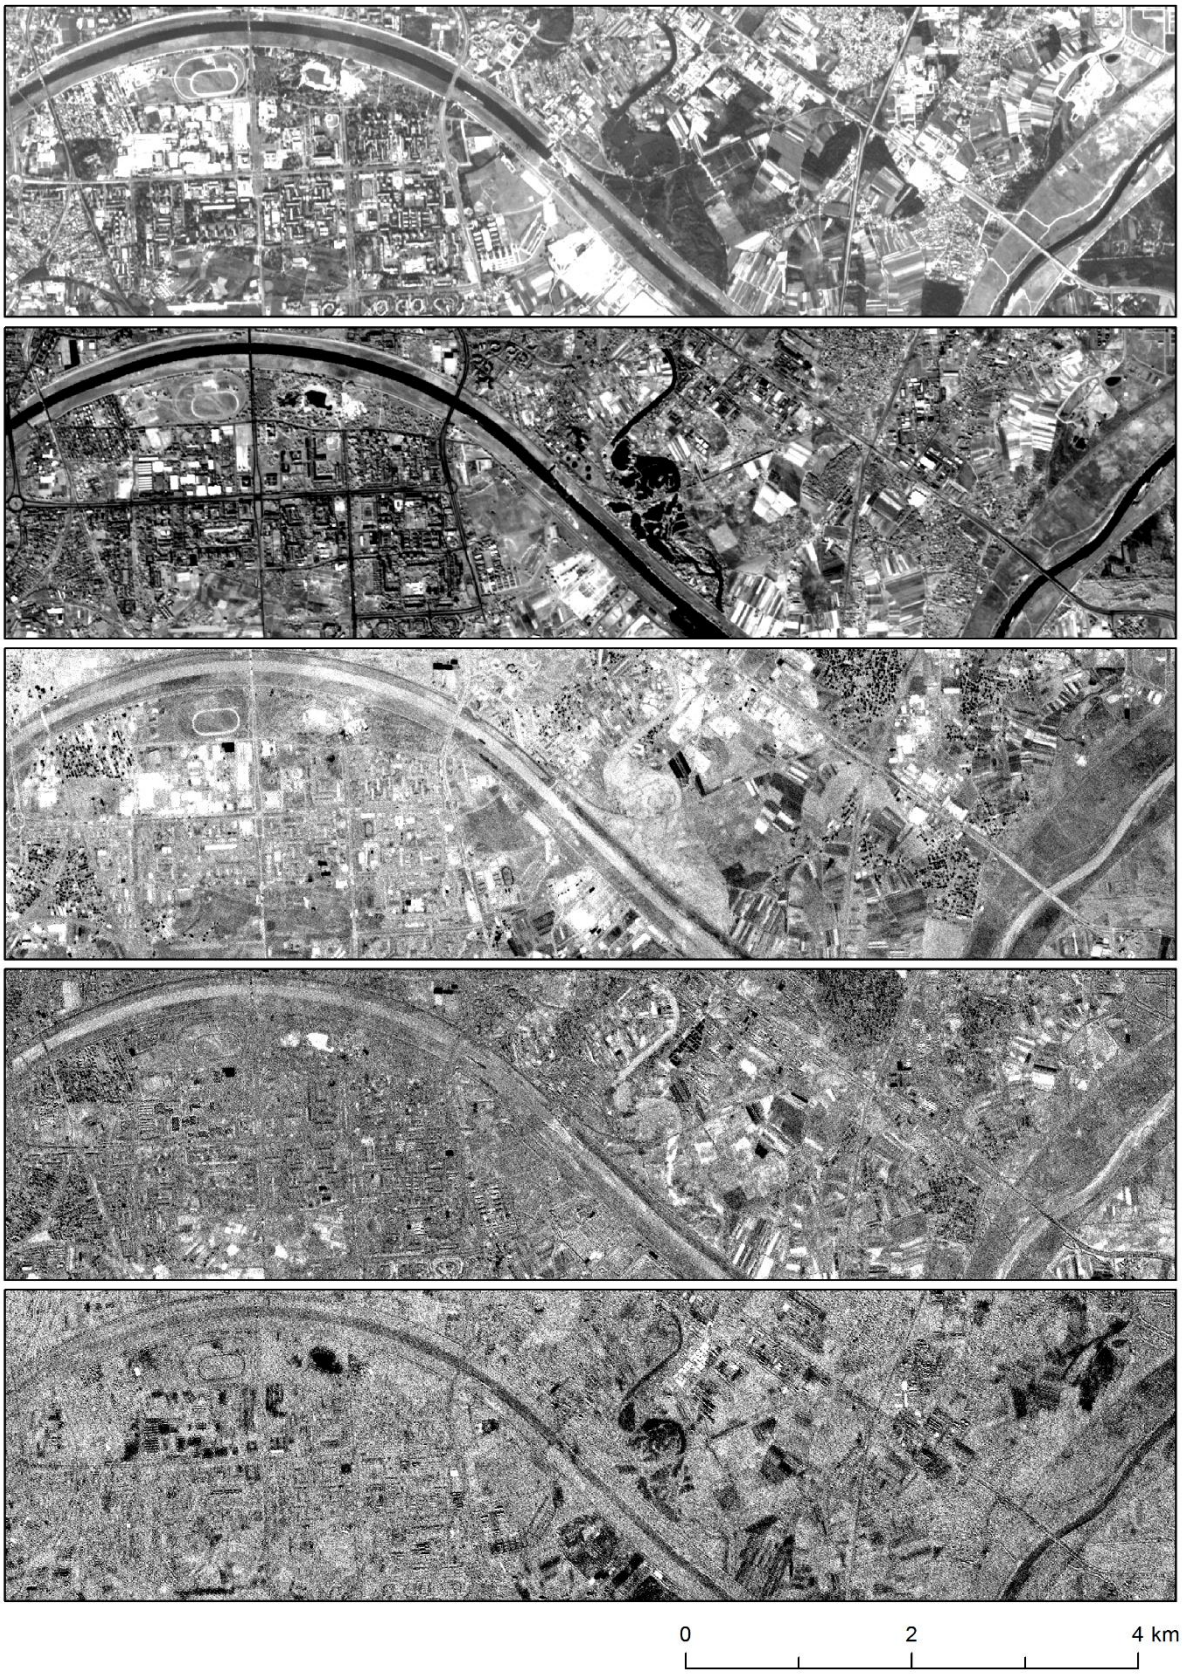

Sl. 11. Rasterske datoteke dobivene analizom glavnih komponenata (detalj snimke 3360218). Izvor: autor na temelju: obrađeni podaci RapidEye, 2011.

Dio istraživanja usmjeren je na ispitivanje mogućnosti upotrebe metode analize glavnih komponenata u svrhu klasifikacije zemljišnog pokrova. Analize glavnih komponenata koriste se u daljinskim istraživanjima u više svrha. Često se upotrebljavaju kako bi se smanjila brojnost, odnosno multidimenzionalnost podataka. Analizom korelacije među slojevima podataka snimke, osim brojčanih pokazatelja, svojstvenih vektora (engl. *eigenvectors*) i svojstvenih vrijednosti (engl. *eigenvalues*) stvaraju se nove rasterske datoteke čije vrijednosti predstavljaju varijabilnost unutar jedne komponente podataka. Iz određenog broja slojeva podataka nastoji se dobiti što veća varijabilnost podataka i što manja korelacija među njima kako bi se objekti na slikama što bolje međusobno razlikovali. Budući da prva komponenta sadrži veliku većinu varijabilnosti podataka potrebne za diferenciranje pojava u prostoru, na taj se način višeslojni podaci ili višespektralne snimke mogu reducirati u manji skup. Prednosti takve upotrebe metode glavnih komponenata dolaze do izražaja kod velikih skupova podataka poput onih koji se stvaraju hiperspektralnim daljinskim istraživanjima. Hiperspektralnim snimanjem Zemljine površine nastaje zapis elektromagnetskog zračenja u velikom broju uskih spektralnih kanala koji se nadovezuju jedan na drugi. Druga upotreba metode glavnih komponenata u daljinskim istraživanjima je ispitivanje mogućnosti isticanja određenih prostornih pojava ili značajki Zemljine površine u odnosu na ostatak okoliša. Različiti objekti i prostorne pojave ili konkretno u ovom istraživanju klase zemljišnog pokrova, mogu doći do izražaja u pojedinim novim slojevima podataka nastalih primjenom analize glavnih komponenata. Metoda glavnih komponenata primijenjena je u ovom istraživanju prema tom principu, kao pomagalo za naglašavanje i izdvajanje određenih zemljišnih pokrova, a ne za reduciranje skupa podataka. Broj komponenata jednak je broju izvornih slojeva snimke pa je iz jedne multispektralne satelitske snimke RapidEye analizom glavnih komponenata moguće stvoriti pet novih slojeva podataka. Detaljan pregled svih slojeva datoteka nastalih tom metodom obrade podataka nužan je kako bi se mogla procijeniti njihova potencijalna primjena u klasifikaciji zemljišnog pokrova. Upravo se u posljednjim komponentama često *skrivaju* neki geografski entiteti i objekti koji nedovoljno dolaze do izražaja na izvornim snimkama i brojčanim vrijednostima njihovih piksela.

Za analizu glavnih komponenata i stvaranje novih slojeva podataka upotrijebljen je računalni program ArcGIS 10. Za svaku od pet scena koje pokrivaju područje Grada Zagreba izračunato je i izrađeno pet komponenata. Rezultat obrade podataka su 32-bitne datoteke s cijelim brojevima.

Datoteke za rad u GIS-u, u ESRI-jevom *shapefile* formatu, upotrjebljene u ovom istraživanju izvorno su bile prilagođene za rad u 5. zoni Gauss-Krügerove projekcije te je transformacija podataka bila nužna kako bi se one mogle upotrebljavati s ostalim slojevima podataka. Hrvatski državni koordinatni sustav 1901 trebalo je zamijeniti s koordinatnim sustavom WGS 1984 (engl. *World Geodetic System 1984*) i na taj način podatke prilagoditi za rad sa satelitskim snimkama u 33. zoni UTM projekcije (engl. *Universal Transverse Mercator*). Za usklađivanje podataka upotrijebljena je 7-parametarska transformacija (EPSG kod 3964).

5.2.2. Multirezolucijska segmentacija snimaka

Tijekom posljednjeg desetljeća u mnogobrojnim su se istraživanjima objektno orijentirane analize slika i klasifikacije zemljišnog pokrova ili načina korištenja zemljišta upotrebljavali računalni programi iz komercijalnog softverskog paketa eCognition (Hofmann, 2001; Repaka i dr., 2004; Bock i dr., 2005; Lewinski, 2005; Moeller i Blaschke, 2005; Yuan i Bauer, 2006; Lewinski i Bochenek, 2008; Chen i dr., 2009; Bhaskaran, 2010; Dinis i dr., 2010, Uddin i Gurung, 2010; Taubenböck i dr., 2011; Dupuy i dr., 2012; Tormos i dr., 2012; Thu i dr., 2013). Uz velik broj alata za obradu i analizu slikovnih datoteka, ovaj računalni program nudi algoritme za segmentaciju koji se mogu podijeliti u dvije skupine prema načinu podjele slike: algoritmi za segmentaciju odozgo prema dolje (engl. *top-down*) i algoritmi za segmentaciju odozdo prema gore (engl. *bottom-up*). Prema navodu proizvođača softvera, metode segmentacije unutar računalnog programa eCognition ne obuhvaćaju samo postupke dijeljenja digitalne slike na manje dijelove, nego i postupke spajanja manjih segmenata u veće te postupke prekrajanja njihovih granica (Trimble, 2014b).

Prva skupina algoritama za segmentaciju započinje podjelu s razine cjelokupne slike te ju nastavlja prema nižim razinama prema zadanim parametrima. U tu skupinu spadaju segmentacije na temelju algoritma: šahovnice (engl. *chessboard segmentation*), kvadrantnog stabla (engl. *quadtree-based segmentation*), kontrastnog filtra (engl. *contrast filter segmentation*), kontrastne podjele (engl. *contrast split segmentation*) (Pierzchalski, 2013; Trimble 2014b).

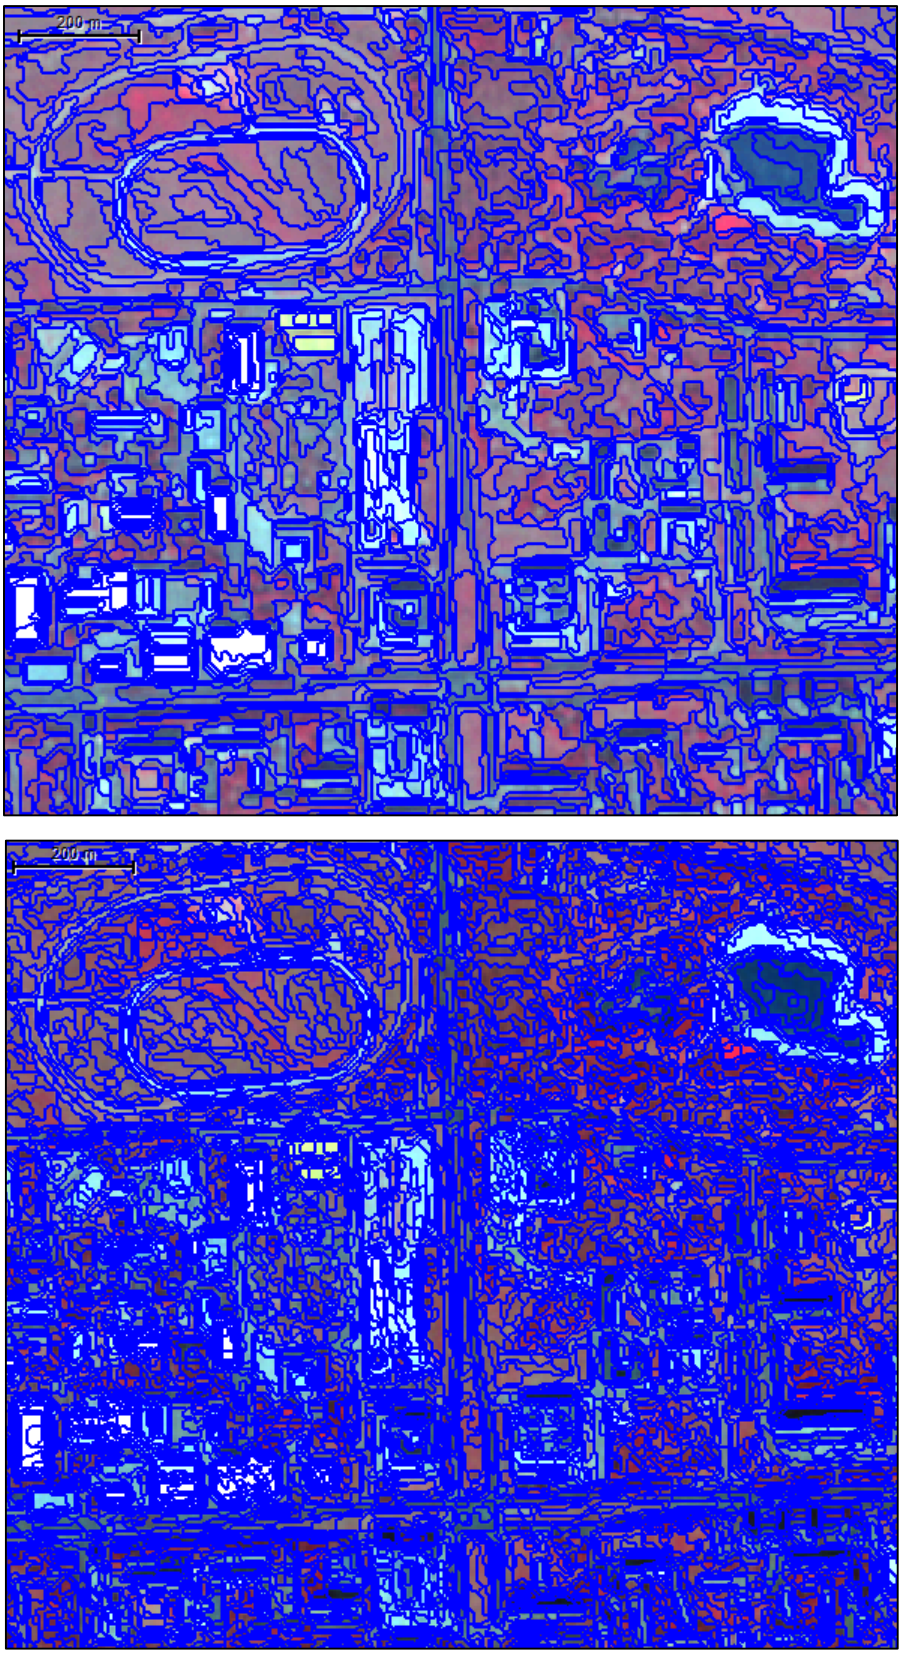

Sl. 12. Segmenti snimke RapidEye stvoreni algoritmom multirezolucijske segmentacije u računalnom programu eCognition, s mjerilom 75 i 30. Izvor: autor na temelju: RapidEye, 2011.

Multirezolucijska segmentacija (engl. *multiresolution segmentation*) i segmentacija na temelju klasifikacije (engl. *classification-based segmentation*), primjeri su algoritma za segmentaciju, dostupnih u softveru eCognition, koji upotrebljavaju računalnu strategiju prema kojoj se slika dijeli odozdo prema gore, odnosno od manjih elemenata prema cjelini (Benz i dr., 2004; Trimble, 2014b).

Za sve segmentacije snimaka u ovom istraživanju upotrijebljen je algoritam multirezolucijske segmentacije. Prilikom objektno orijentirane analize slika teži se objedinjavanju piksela u što veće skupine ili objekte kako bi svaka daljnja obrada podataka iziskivala što manju uporabu računalnih resursa te kako bi oni zaista predstavljali objekte iz stvarnog geografskog prostora bez suvišnog razlamanja u manje dijelove ili pojedine piksele. S druge strane, klasifikacija zemljišnog pokrova bila bi znatno otežana ako bi se unutar pojedinih objekata nalazio previše heterogen prostor, odnosno ako bi oni objedinjavali suviše različite piksele. Parametri kojima se upravlja segmentacijom unutar spomenutog računalnog algoritma, odnose se na raspon vrijednosti kojima se određuje heterogenost objekata te omjeri pomoću kojih se utječe na značaj spektralnih svojstava ili morfologiju prilikom izdvajanja objekata. Povećanjem vrijednosti tzv. mjerila segmentacije (engl. *scale*), slika se dijeli na manji broj objekata većih dimenzija. Ako ta slika, poput ovdje obrađene satelitske snimke, predstavlja Zemljinu površinu, onda to znači podjelu prostora u manji broj površinom većih i relativno heterogenih područja. Podešavanjem omjera između tzv. boje (engl. *colour*) i oblika (engl. *shape*) daje se manja ili veća važnost spektralnim svojstvima piksela u odnosu na geometrijska svojstva. Na kompaktnost (engl. *compactness*) ili zaglađenost (engl. *smoothness*) segmenata, odnosno oblik njihovih granica također se može utjecati namještanjem odvojenog parametra (Navulur, 2006; Trimble 2014b).

5.2.3. Nadzirana klasifikacija zemljišnog pokrova

Prvi tip klasifikacije zemljišnog pokrova Grada Zagreba upotrijebljen u ovom radu nadzirana je klasifikacija. Cilj ovog dijela istraživanja bilo je ispitivanje mogućnosti softverskih alata prilikom provedbe postupka nadzirane klasifikacije. Segmentacija je izvršena na temelju brojčanih vrijednosti pohranjenih u izvornih pet kanala satelitskih snimaka RapidEye, a za klasifikaciju su upotrijebljene brojne aritmetičke, statističke i teksturalne značajke podataka dostupne u računalnom programu eCognition 9.0.

Nadzirana klasifikacija zemljišnog pokrova zahtjeva aktivnu ulogu ljudskog operatera klasifikacije snimke i podrazumijeva upotrebu *a priori* znanja, iskustva ili razumijevanja promatranog prostora. Pozornim odabirom pojedinih dijelova slike i određivanjem njihove klase, korisnik nastoji usmjeriti računalo na daljnju klasifikaciju cjelokupne satelitske snimke, odnosno scene (Lillesand i dr., 2004; Richards i Jia, 2006; Campbell i Wynne, 2011).

Različite kombinacije tzv. lažnog kombiniranja boja (engl. *false color composite*) u RGB formatu slike (npr. bliski infracrveni, crveni i zeleni kanal) pomažu u prepoznavanju i odabiru uzoraka koji jasno predstavljaju željene klase zemljišnog pokrova (Campbell i Wynne, 2011). Segmenti slike stvoreni segmentacijom multispektralne satelitske snimke poslužili su kao jedinice uzoraka zemljišnih pokrova.

Nakon ispitivanja mogućnosti multirezolucijske segmentacije i utjecaja njezinih parametara na segmentaciju RapidEye snimaka, uočeno je da se s mjerilom segmentacije vrijednosti 75 postiže zadovoljavajući rezultat. Dodijeljena je prednost spektralnim karakteristikama slike prilikom segmentacije u odnosu na oblikovna svojstva slike (*Shape* = 0,1), a odnos kompaktnost-zaglađenost namješten je na polovicu raspona (*Compactness* = 0,5).

Na temelju inicijalnog skupa uzoraka segmenata istražena je važnost pojedinih kanala RapidEye snimaka za izdvajanje željenih klasa zemljišnog pokrova. Pomoću alata za optimizaciju prostora značajki dobivene su vrijednosti separabilnosti klasa za svaki pojedini kanal snimke (Navulur, 2006). Na temelju tih vrijednosti odlučeno je da će se za novi postupak segmentacije kanalima crvenog ruba i bliskog infracrvenog dijela elektromagnetskog spektra dodijeliti dvostruko veći ponder, odnosno težinski faktor (*Weight* = 2).

Za novu i izmijenjenu razinu segmentacije izračunate su aritmetičke i statističke značajke ili varijable (engl. *features*): prosječna vrijednost kanala snimke u segmentima slike (engl. *mean*), svjetlina (engl. *brightness*), najveća apsolutna razlika (engl. *maximum difference*), standardna devijacija kanala snimke u segmentima, udio kanala snimke u ukupnoj svjetlini segmenata (engl. *ratio*), omjeri parova kanala snimaka, vegetacijski indeksi, te su izrađeni slojevi tekstura svih kanala snimaka prema Haralicku. Primjenom eCognition alata na svih pet slojeva RapidEye snimke nastaje ukupno 38 značajki ili varijabli koje se namjeravaju upotrijebiti za nadziranu klasifikaciju (Trimble, 2014a).

Tab. 9. Popisi varijabli dobiveni primjenom alata za optimizaciju prostora značajki prema pojedinim upotrijebljenim snimkama. Varijable odabrane za klasifikaciju otisnute su podebljanim slovima.

Kratice: C = crveni, Z = zeleni, P = plavi, CR = crveni rub, BIC = bliski infracrveni, t- = GLCM teksture, SD = standardna devijacija, / = postupak dijeljenja s kanalima snimaka.

Snimka 3360117	Snimka 3360118	Snimka 3360217	Snimka 3360218	Snimka 3360318
Prosjek Z	CR/P	Udio CR	Udio CR	Udio Z
BNDVI	Prosjek P	Udio Z	Udio Z	SD P
SD P	Udio BIC	**t-Različitost**	**t-Entropija**	Prosjek C
Svjetlina	Svjetlina	**Z/P**	**SD BIC**	**t-Različitost**
NDWI	SD CR	**t-Entropija**	**t-Homogenost**	**CR/Z**
t-Homogenost	**t-Korelacija**	Svjetlina	**Z/P**	SD CR
NDVI	BNDVI	SD CR	**t-Različitost**	**Z/P**
SD CR	Prosjek Z	**t-Prosjek**	**t-Prosjek**	Prosjek P
Prosjek CR	**SD Z**	**CR/Z**	**CR/Z**	**SD Z**
CR/Z	Prosjek BIC	**t-Homogenost**	**t-Korelacija**	**t-Korelacija**
Prosjek P	**t-Homogenost**	**SD BIC**	SD C	SD C
GNDVI	SD C	**Udio P**	NDWI	Prosjek CR
Udio BIC	Prosjek CR	**t-Korelacija**	**SD Z**	**t-Homogenost**
t-Različitost	SD P	GNDVI	**Udio P**	C/P
CR/P	Prosjek C	SD P	GNDVI	CR/P
Prosjek C	**CR/Z**	**SD Z**	NDVI (BIC,CR)	**SD BIC**
Z/P	**t-Entropija**	CR/P		**t-Entropija**
BIC/P	**Z/P**	NDWI		Prosjek Z
SD C	**SD BIC**			BNDVI
t-Entropija	**t-Prosjek**			C/Z
NDVI (BIC,CR)	**t-Različitost**			**t-Prosjek**
Udio CR	C/P			Svjetlina
t-Prosjek	**Udio P**			**Udio P**
SD BIC	Udio CR			
SD Z				
C/P				
t-Korelacija				
Udio Z				
Udio P				
Prosjek BIC				

Izračunati su normalizirani vegetacijski indeksi (Rouse i dr., 1974) u kojima su upotrijebljene vrijednosti razlike bliskog infracrvenog kanala snimke s *vidljivim* kanalima, crevnim, zelenim i plavim, te crvenim rubom. Također je upotrijebljen sličan indeks NDWI (engl. *normalized difference water index*) (McFeeters, 1996).

Među varijablama može se posebno izdvojiti tekstura slike. Teksture se opisuju kao vizualni dojam hrapavosti ili glatkoće objekata uzrokovan varijabilnošću nijansi ili boja digitalne slike (Avery i Berlin, 1992). Iako ljudski vid ima prirodnu sposobnost vrlo dobre interpretacije tekstura, iznimno je teško prenijeti to biološki urođeno razumijevanje tekstura u računalnu obradu i analizu slike (Haralick, 1973; Myint, 2006). Za potrebe ovog istraživanja kao varijable su upotrijebljene Haralickove matrice tekstura (engl. *gray level co-occurrence matrix*, krat. *GLCM*).

Ponovna optimizacija prostora značajki dala je uvid u skupove optimalnih varijabli za svaku od pet scena koje prikazuju područje Grada Zagreba. Iz tih različitih skupova odabrane su one koje se ponavljaju u svim skupovima, odnosno zajedničke su svim scenama. Na taj je način inicijalni broj varijabli smanjen s 38 na 10. Njima je pridružen vegetacijski indeks SAVI (engl. *soil adjusted vegetation index*) pa je za klasifikaciju naposljetku upotrijebljeno 11 varijabli (Huete, 1988).

Odabrani uzorci klasa i dodijeljene im značajke su ulazni podaci za algoritam najbližih susjeda (engl. *nearest neighbor*) pomoću kojeg se u korištenom softveru može provesti nadzirana klasifikacija. Prema tom algoritmu objekti ili pikseli neke slike klasificiraju se prema najbližem zadanom uzorku u prostoru značajki (engl. *feature space*) ili n-dimenzionalnom prostoru (Landgrebe, 2003; Richards i Jia, 2006; Campbell i Wynne, 2011). Navedena je jednadžba za izračunavanje udaljenosti među objektima, pri čemu je d distanca između uzorka s i određenog objekta o, $v_f(s)$ je vrijednost značajke f za uzorak, $v_f(o)$ je vrijednost značajke f za određeni objekt, a σ_f je standardna devijacija značajke f (Trimble, 2014b).

$$d = \sqrt{\sum_f \left(\frac{v_f(s) - v_f(o)}{\sigma_f} \right)^2}$$

Na temelju udaljenosti *d* izračunava se multidimenzionalna eksponencijalna funkcija pripadnosti *z(d)*. Parametar *k* određuje pad funkcije (Trimble, 2014b).

$$d(z) = e^{-kd^2}$$

$$k = \ln(1/functionslope)$$

Unutar korištenog računalnog programa prije provođenja postupka klasifikacije moguće je odrediti dva parametra koji utječu na pripadnost pojedinog objekta nekoj klasi. Korisnik može unijeti vrijednost kojom se utječe na nagib (engl. *function slope*) funkcije pripadnosti (engl. *membership function*), a samim time i na mogućnost zahvaćanja nekog objekta u određenu klasu. Drugi parametar je minimalna vrijednost pripadnosti (engl. *membership value*) koja predstavlja prag između klasifikacije objekta u neku od zadanih klasa i označavanja objekta kao neklasificiranog (Trimble, 2014b). Upotrijebljene su postavke: 0,2 za varijablu rasta funkcije te 0,2 za minimalnu vrijednost pripadnosti. Tim postupkom svaki objekt slike dobiva vrijednosti između 0 i 1 koje ukazuju na stupanj pripadnosti svakoj od klasa prema teoriji neizrazitih skupova (Zadeh, 1965). Na temelju najviše izračunate vrijednosti, objektu se pripisuje određena klasa zemljišnog pokrova.

5.2.4. Klasifikacija zemljišnog pokrova na temelju skupa pravila

Drugi postupak klasifikacije zemljišnog pokrova primijenjen u ovom radu temelji se na skupu pravila (engl. *rule based*) pomoću kojih se cjelokupna scena dijeli u zadane klase ovog istraživanja: vegetaciju, izgrađene površine, gola tla i vodene površine. Osnovu tih pravila čini znanje (engl. *knowledge based*), a njegov izvor može se podijeliti na znanje stručnjaka i informacije dobivene istraživanjem zadanih podataka. Struktura pravila upotrijebljenih u ovom istraživanju može se opisati kao stupnjevita (engl. *stepwise classification*) te kao razmjerno jednostavno stablo odluka (engl. *decision tree*) (Zhu, 2008; Uddin i Gurung, 2010; Abelen i dr., 2011).

Za razliku od prije primijenjene nadzirane klasifikacije u kojoj su korištena logika neizrazitih skupova, u ovom su dijelu istraživanja ispitane mogućnosti tvrde (engl. *hard* ili *crisp classification*) klasifikacije koja tijekom svoje provedbe raspoređuje segmente satelitske snimke u isključivo jednu klasu zemljišnog pokrova, dakle bez izračunavanja različitih stupnjeva pripadnosti pojedinim klasama s rasponom vrijednosti od 0 do 1 (Robinson, 2008). Određivanjem kriterija za klasifikaciju, segmenti ili objekti slike ili pripadaju ili ne pripadaju zadanoj klasi, odnosno njihova se pripadnost može opisati kao binarna vrijednost.

Metoda klasifikacije primijenjena u ovom dijelu istraživanja temelji se na određivanju pragova (engl. *thresholding*) vrijednosti neke značajke ili varijable za koju je odlučeno da će se upotrijebiti kao kriterij unutar pravila klasifikacije. Bitno je naglasiti da se sve značajke (engl. *features*) mogu brojčano izraziti i da se istinitost tvrdnje da neki segment slike pripada nekoj klasi može izraziti funkcijom određene značajke (Zhu, 2008). Postavljanjem vrijednosti praga definira se brojčani raspon unutar kojeg vrijedi istinitost tvrdnje. Moguća je upotreba više značajki, a širi skupovi podataka definirani samo jednom varijablom, mogu se postepeno reducirati drugim ograničenjima, odnosno varijablama.

Isti je skup pravila upotrijebljen na svim snimkama, ali uz manje izmjene vrijednosti pragova određenih značajki koje se razlikuju među scenama kako bi se postigla što veća točnost klasifikacije. Snimke se razlikuju po apsolutnom rasponu zabilježenih vrijednosti zračenja i po zastupljenosti traženih zemljišnih pokrova. Kao primjer može se navesti snimka 3360318 u kojoj nisu zamijećene vodene površine. Iste klase zemljišnih pokrova razlikuju se među snimkama po brojnosti i raznovrsnosti materijala i tvari ili bioloških vrsta koje se mogu svrstati u njih. Razlike u reljefu među snimkama – nadmorska visina, nagib i smjer pružanja padina, koje utječu na razliku u zabilježenim vrijednostima radijancije također se trebaju uzeti u obzir tijekom definiranja pragova za klasifikaciju zemljišnog pokrova.

U odnosu na prethodnu metodu klasifikacije, segmentacija je provedena s identičnim ponderima slojeva snimaka, ali je upotrijebljen manji parametar mjerila kako bi se dobili manji segmenti. Razlog za to je pretpostavka da će se s manjim segmentima kvalitetnije upravljati jer bi potencijalno spajanje suviše različitih područja scene u veće jedinice za klasifikaciju (engl. *undersegmentation*) moglo predstavljati veći problem za raspoznavanje klasa zemljišnog pokrova od prevelikog broja segmenata (engl. *oversegmentation*) (Veljanovski i dr., 2011). Ispravnom se pokazala pretpostavka da brojnost segmenata ne bi trebala predstavljati poteškoće

za računalnu obradu podataka prilikom upotrebe ove metode klasifikacije jer se primjenjuju relativno jednostavne naredbe za raspodjelu podataka prema pragovima numeričkih vrijednosti i operatorima usporedbe (npr. > ili <).

Osim pragova, odnosno graničnih vrijednosti pojedinih značajki, na temelju koji se svrstava segmente slike u određene klase, iznimno je bitan i redoslijed naredbi koje čine skup pravila (engl. *ruleset*). S klasifikacijom svake pojedine klase zemljišnog pokrova, one se eliminiraju iz svih sljedećih naredbi koje čine algoritam te se na taj način mogu očuvati do kraja postupka klasifikacije. Osiguravanjem stabilnosti pojedine klase ona se upotrebljava kao maska za daljnju klasifikaciju preostalih klasa te se nadolazeći procesi, odnosno naredbe provode isključivo na još neklasificiranim podacima. S obzirom na upotrijebljene podatke i klasifikacijsku shemu, pojedine klase zemljišnog pokrova relativno se lakše izdvajaju iz cjelokupne scene u odnosu na druge. Spektralni potpisi tvari i materijala koji u objedinjenom sastavu čine klase zemljišnog pokrova čine temelj njihove međusobne diferencijacije. Već je prije navedeno, svojstvo neke materije da u različitoj mjeri reflektira ili apsorbira elektromagnetsko zračenje određenih valnih duljina pruža mogućnost njezine detekcije i identifikacije pomoću senzora za daljinska istraživanja. Cilj ovog dijela istraživanja bio je razrađivanje strategije ili niza postupaka za klasifikaciju zemljišnog pokrova koji čini skup jasno i precizno definiranih pravila. Jasnoća tih pravila očituje se u postavljanju tvrdih granica među klasama unutar vrijednosti odabranih značajki segmenata slike.

Klasifikacija na temelju skupa pravila primijenjena u istraživanju temelji se na sljedećim pretpostavkama:

- klasu vegetacije i klasu vode relativno je lakše i brže identificirati i izdvojiti iz scene od klase izgrađene površine i klase golog tla, zbog lako prepoznatljivih spektralnih svojstava
- klasu izgrađenih površina karakterizira najveća sadržajna heterogenost ili složenost jer se sastoji od brojnih podklasa s vrlo različitim spektralnim značajkama,
- klasu golog tla čine sve one površine koje se u konačnici mogu karakterizirati odsustvom ostalih klasa zemljišnog pokrova, ali je tijekom same klasifikacije moguće nepoželjno miješanje s drugim klasama.

Pregledom i ispitivanjem značajki nastojalo se suziti izbor na one kod kojih bi se definiranjem praga moglo postići izdvajanje jedne klase ili koje bi u kombinaciji s dodatnim pravilom inicijalni veliki skup obuhvaćenih podataka mogle značajno reducirati.

Već je spomenuto da je prije segmentacije snimaka i njihove klasifikacije provedena analiza glavnih komponenata pomoću koje su stvoreni novi slojevi podataka za koje se pretpostavljalo da bi mogli pomoći u klasifikaciji zemljišnog pokrova. Vizualnom je interpretacijom na istovjetnim glavnim komponentama svih scena potvrđeno isticanje istih pojava, odnosno klasa zemljišnog pokrova.

Cjelokupni izrađeni skup pravila može se podijeliti na tri osnovna dijela:

- segmentaciju snimke,
- klasifikaciju snimke na temelju spektralnih vrijednosti i njihovih transformacija,
- oblikovanje konačnih informacijskih klasa zemljišnog pokrova.

Segmentacija snimaka provedena je s parametrima mjerila 30, oblika 0,1 i kompaktnosti 0,5. Za segmentaciju je upotrijebljeno pet izvornih slojeva snimaka, a težinski faktor 2 postavljen je na kanale crvenog ruba i bliskog infracrvenog dijela spektra. Slojevi podataka nastali analizom glavnih komponenata nisu korišteni u postupku segmentacije, ali će njihova moguća upotreba u tu svrhu i potencijalni utjecaj na ishod segmentacije biti ispitani u daljnjim istraživanjima.

Drugi je dio postupka započet s klasifikacijom vegetacije. Vegetacija je klasificirana u dvije odvojene faze pomoću vegetacijskog indeksa SAVI (Huete, 1988). Budući da je snimka nastala 16. rujna 2011. godine, trebao je biti primijenjen prikladan vegetacijski indeks koji će dovesti do izražaja svu šumsku, travnjačku, parkovnu i poljoprivrednu vegetaciju bez obzira na njezinu senescenciju, odnosno oštećenost. Kako bi se ublažio spektralni potpis tala pomiješan sa sasušenom vegetacijom upotrijebljen je upravo navedeni vegetacijski indeks. U prvo je fazi postavljena veća vrijednost indeksa (0,25), a u drugoj, kasnijoj fazi klasifikacije manja vrijednost (0,15) koji je omogućio dodatno izdvajanje vegetacijskog pokrova u reduciranom skupu neklasificiranih podataka.

Vodene su površine klasificirane na temelju malih vrijednosti refleksije bliskog infracrvenog dijela spektra. Pretpostavka je da u tom dijelu spektra, voda apsorbira značajnu

količinu zračenja te je zbog toga posebno prepoznatljiva na multispektralnim satelitskim snimkama. Ipak, primjena takvog pravila rezultira i izdvajanjem velikog broja pokrova sa sjenama, asfaltom, katranom, bitumenom ili pepelom, koji se mogu pronaći u zagrebačkom urbanom i periurbanom području. Značajan dio takve pogrešne klasifikacije moguće je donekle eliminirati iz takvog skupa primjenom praga vrijednosti indeksa NDWI (McFeeters, 1996) i BNDVI (Yang i dr., 2004), odnosno NDVI indeksa (Rouse i dr., 1974) s primjenom plavog umjesto crvenog kanala snimke. Klasifikacija voda na snimkama upotrijebljenim u ovom radu dodatno je otežana zbog vrlo niskog vodostaja na taj datum (DHMZ, 2011) i općenito zbog onečišćenosti gradskih vodenih površina, odnosno prisutnosti različitih organskih i mineralnih tvari u njima. Navedeni su se indeksi pokazali neiskoristivi u pojedinim scenama, a kod drugih su bile potrebne korekcije praga. Također treba napomenuti da vodene površine nisu pronađene i klasificirane u dijelu scene 3360318 koji pripada upravnom području Grada Zagreba.

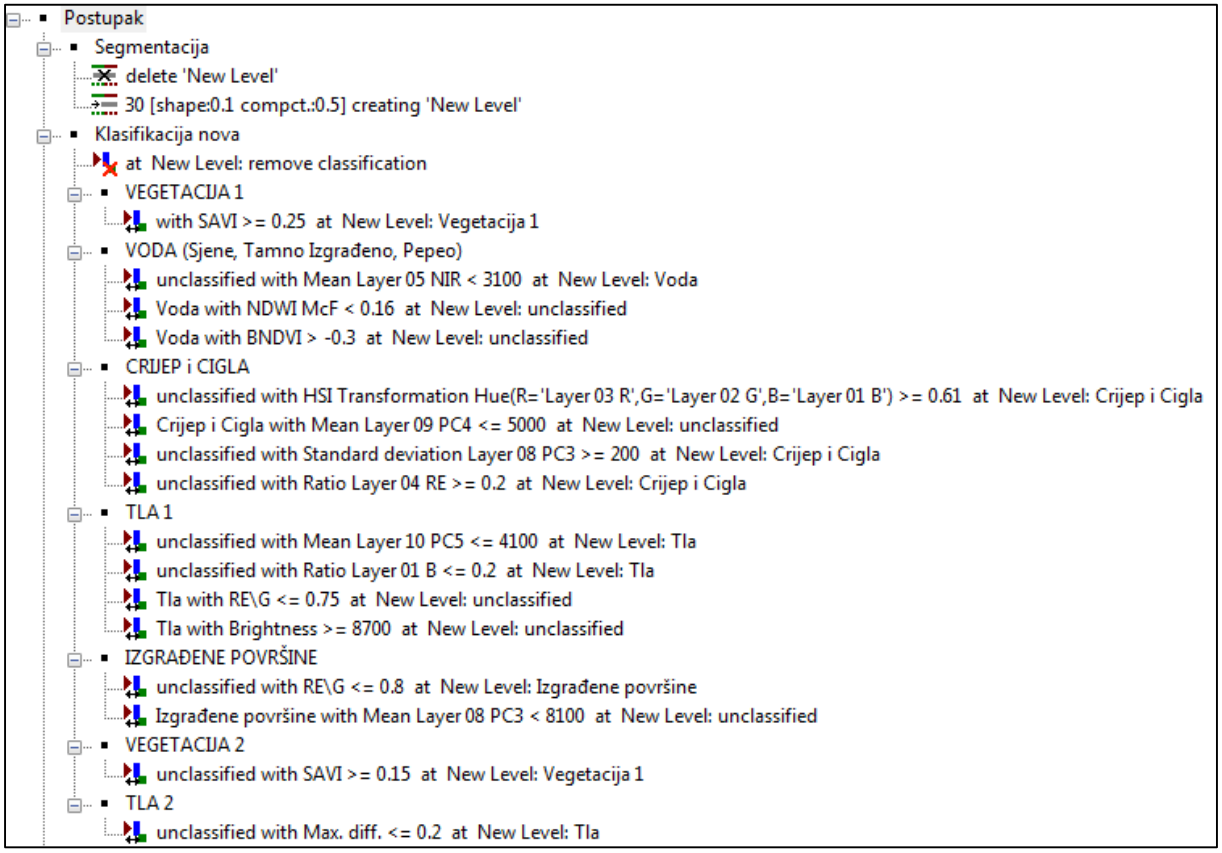

Sl. 13. Prva dva dijela primijenjenog postupka klasifikacije na temelju skupa pravila za snimku 3360217 prikazana u tzv. *process tree*, dijelu grafičkog korisničkog sučelja računalnog programa eCognition 9.0. Izvor: autor u Trimble eCognition 9.0.

Dio izgrađenih površina karakteriziraju slična spektralna svojstva kao i drugih klasa zemljišnog pokrova, posebice golog tla. Klasa izgrađenih površina obuhvaća vrlo različite materijale koji sadrže brojne minerale i ugljikovodike te sastojke biljnog podrijetla. Zbog toga je klasa izgrađenih površina također klasificirana u dvije odvojene faze. U prvoj su fazi izdvojene izgrađene površine koje čine krovne površine pokrivene crijepom i površine pokrivene ciglom, poput teniskih terena i atletskih staza u čijem se sastavu nalaze, između ostalog, granule opeka (tenisit). Tijekom istraživanja značajki segmenata snimaka, uočeno je da se transformacijom snimaka iz RGB modela (engl. *red, green, blue*) digitalne slike u HSI model (engl. *hue, saturation, intensity*), točnije promatranjem komponente nijanse boje (engl. *hue*), može odrediti prikladna vrijednost praga za izdvajanje zgrada s krovnim crijepom. Ipak, pomoću te značajke ili varijable, greškom se izdvajaju i tla slične boje. Kako bi se pokrov tla eliminirao iz željene klase, upotrijebljena je dodatna varijabla, odnosno prag prosječne vrijednosti rasterskog sloja četvrte glavne komponente. Spomenute značajke nisu bile dovoljne za klasificiranje traženog pokrova pa su još upotrijebljene standardna devijacija treće glavne komponente i udio kanala crvenog ruba u ukupnoj svjetlini segmenata slike. Druga faza klasifikacije izgrađenih površina izvršena je kasnije u postupku, nakon klasifikacije dijela golih tala, čije objašnjenje slijedi.

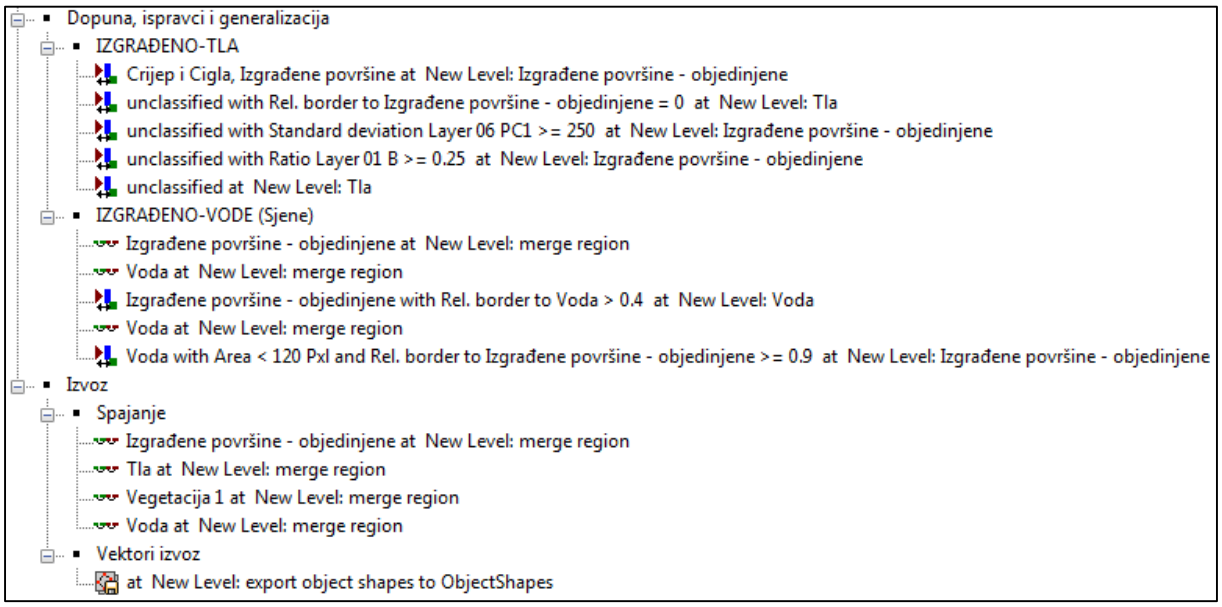

Sl. 14. Posljednji dio postupka klasifikacije na temelju skupa pravila na primjeru snimke 3360217. Izvor: autor u Trimble eCognition 9.0.

Prvi dio klasifikacije tala proveden je na temelju praga prosječne vrijednosti pete glavne komponente (PC5) u segmentima slike te udjela plavog kanala snimke u ukupnoj svjetlini slike. Određene izgrađene površine mogu upotrebom navedenih značajki greškom biti klasificirane kao tlo. Zbog toga su primijenjena dodatna eliminacijska pravila u obliku praga omjera kanala crvenog ruba i zelenog kanala snimke te ukupne svjetline slike.

Klasifikacija izgrađenih površina nastavljena je upotrebom spomenutog omjera kanala crvenog ruba i zelenog kanala. Vidljive pogreške nastale primjenom te varijable donekle su ispravljene primjenom praga za prosječnu vrijednost treće glavne komponente (PC3).

Među preostalim neklasificiranim dijelovima snimke nastavljena je klasifikacija vegetacije sa sniženim pragom vegetacijskog indeksa SAVI i klasifikacija golih tala pomoću varijable najvećih apsolutnih razlika svjetline u segmentima slike.

Završna raspodjela segmenata po klasama i njihovo objedinjavanje provedeno je na temelju pravila koja definiraju njihove prostorne odnose i veličine, točnije relativne vrijednosti duljine zajedničkih granica objekata i apsolutne vrijednosti površina izražene brojem piksela koji čine pojedine objekte.

5.2.5. Provjera točnosti klasifikacije

Točnost klasifikacije ocijenjena je pomoću matrice pogrešaka ili konfuzije (Story i Congalton, 1986; Congalton i Green, 2009). Na temelju novog izrađenog skupa uzoraka uspoređeni su rezultati klasifikacije s referentnim podacima. Za izradu tog skupa uzoraka upotrijebljen je računalni program ArcGIS 10. Kako bi se stvorio skup stratificiranih slučajnih uzoraka valjalo je upotrijebiti podatke dobivene klasifikacijom zemljišnog pokrova. Programskom je modulu zadana naredba za stvaranje vektorskog sloja podataka s unaprijed definiranim brojem nasumičnih točaka za svaku klasu pokrova s dodatnim uvjetom prema kojem točke ne smiju biti na međusobnoj udaljenosti manjoj od 20 m. Oko samih točaka napravljeni su *bufferi* od 2,5 m, odnosno krugovi promjera 5 m. Ti su podaci zatim poslužili za stvaranje kvadratnih okvira, odnosno poligona veličine istovjetne veličini piksela u izvornim satelitskim snimkama RapidEye. Skup takvih poligona reduciran je naredbom odabira prema lokaciji na one koji se u potpunosti nalaze unutar poligona odgovarajuće klase, odnosno ne

dotiču njegove granice. Posljednja navedena postavka uvjetovala je stvaranje nešto manjeg broja uzoraka od onog definiranog u atributivnoj tablici. Pregledom točnosti proizvođača (engl. *producer's accuracy*) i točnosti korisnika (engl. *user's accuracy*) detaljnije je proučena uspješnost klasifikacije (Story i Congalton, 1986).

Kao dodatna mjera točnosti klasifikacije provedena je kapa analiza, odnosno izračunat je kapa koeficijent koji predstavlja mjeru odnosa između podudaranja klasificiranih i referentnih podataka, prikazanu glavnom dijagonalom matrice pogrešaka, te slučajnim podudaranjem kojeg predstavljaju zbrojevi stupaca i redova matrice. Pomoću tog koeficijenta može se dodatno procijeniti kvaliteta klasifikacije. Na temelju ovdje izrađene matrice pogrešaka procijenjena je vrijednost kapa koeficijenta 0,89 što je relativno visoka vrijednosti koja znači jaku pozitivnu korelaciju, odnosno ukazuje na jako poklapanje klasificiranih s referentnim podacima (Landis i Koch, 1977; Congalton i Green, 2009).

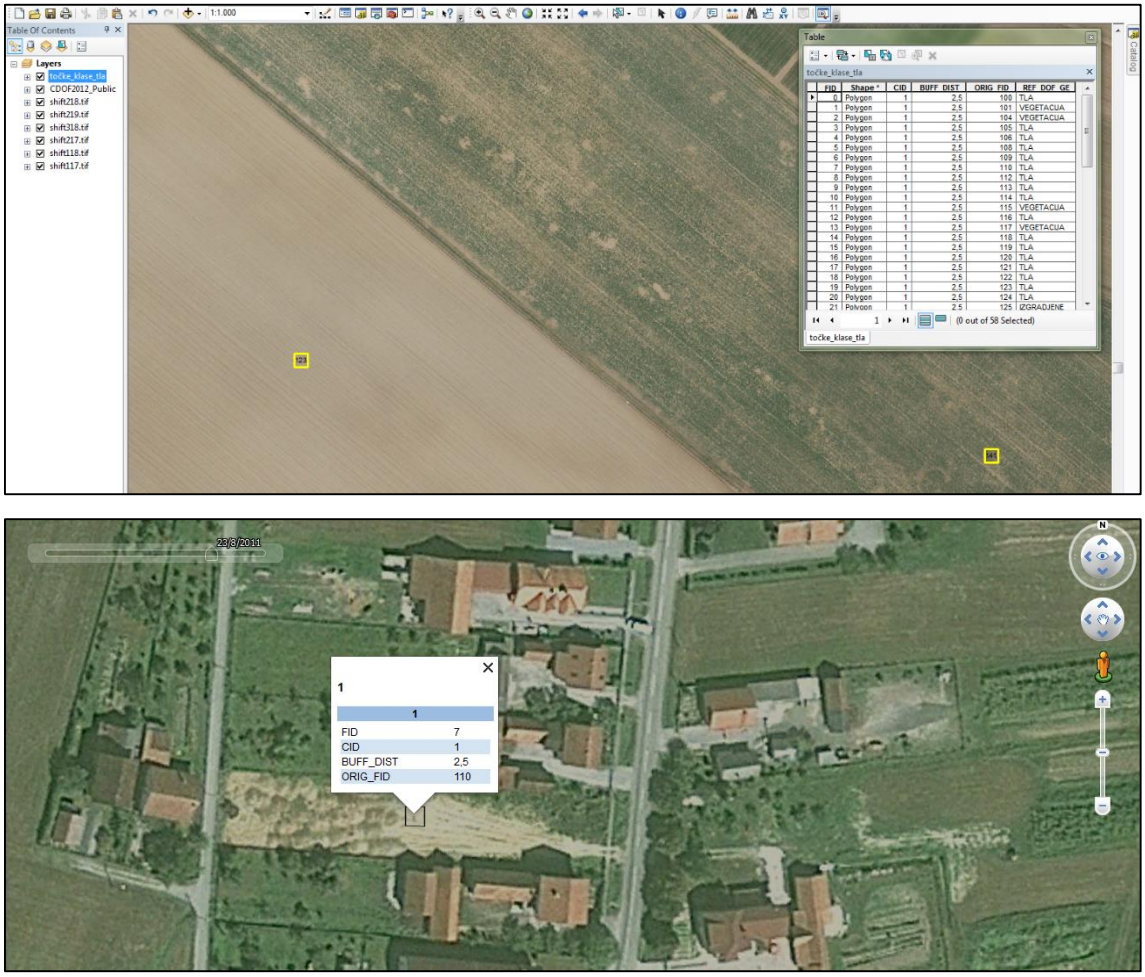

Sl. 15. Usporedbe referentnih i klasificiranih podataka u ArcMap-u i Google Earth-u. Izvor: autor u ESRI ArcGIS 10.0; Google Earth, na temelju: DigitalGlobe, 2011; CDOF, 2012.

Tab. 10. Matrica pogrešaka za klasifikaciju zemljišnog pokrova na temelju skupa pravila.

		Referentni podaci						
		Izgrađene površine	Gola tla	Vegetacija	Vodene površine	UKUPNO		
Klasificirani podaci	Izgrađene površine	**70**	4	4	0	78	89,74	Točnost korisnika (%)
	Gola tla	2	**52**	4	0	58	89,66	
	Vegetacija	2	1	**93**	0	96	96,88	
	Vodene površine	4	1	0	**40**	45	88,89	
	UKUPNO	78	58	101	40	**277**		
		89,74	89,66	92,08	100,00		**92,06**	
		Točnost proizvođača (%)					Ukupna točnost (%)	

5.2.6. Primjena obrađenih podataka

5.2.6.1. V-I-S model analize urbanih područja

V-I-S model analize urbanih ekosustava (Ridd, 1995) može se promatrati kao vrlo pojednostavljen koncept za klasifikaciju zemljišnog pokrova urbanih i periurbanih područja. Karakterizira ga puristički pristup analize zemljišnog pokrova (Mesev, 2010) jer se niti u najmanjoj mjeri ne koriste klase koje bi se mogle protumačiti kao način korištenja zemljišta. Njegova glavna svrha je mjerenje udjela temeljnih klasa zemljišnog pokrova, opisanih biofizičkim svojstvima koje su mjerljive daljinskim istraživanjima, u određenim prostornim jedinicama te usporedba podataka dobivenih analizom različitih područja ili vremenskih, odnosno povijesnih trenutaka. Pojednostavljenost okoliša u tri komponente predstavlja glavnu prednost za njegovu komparativnu primjenu.

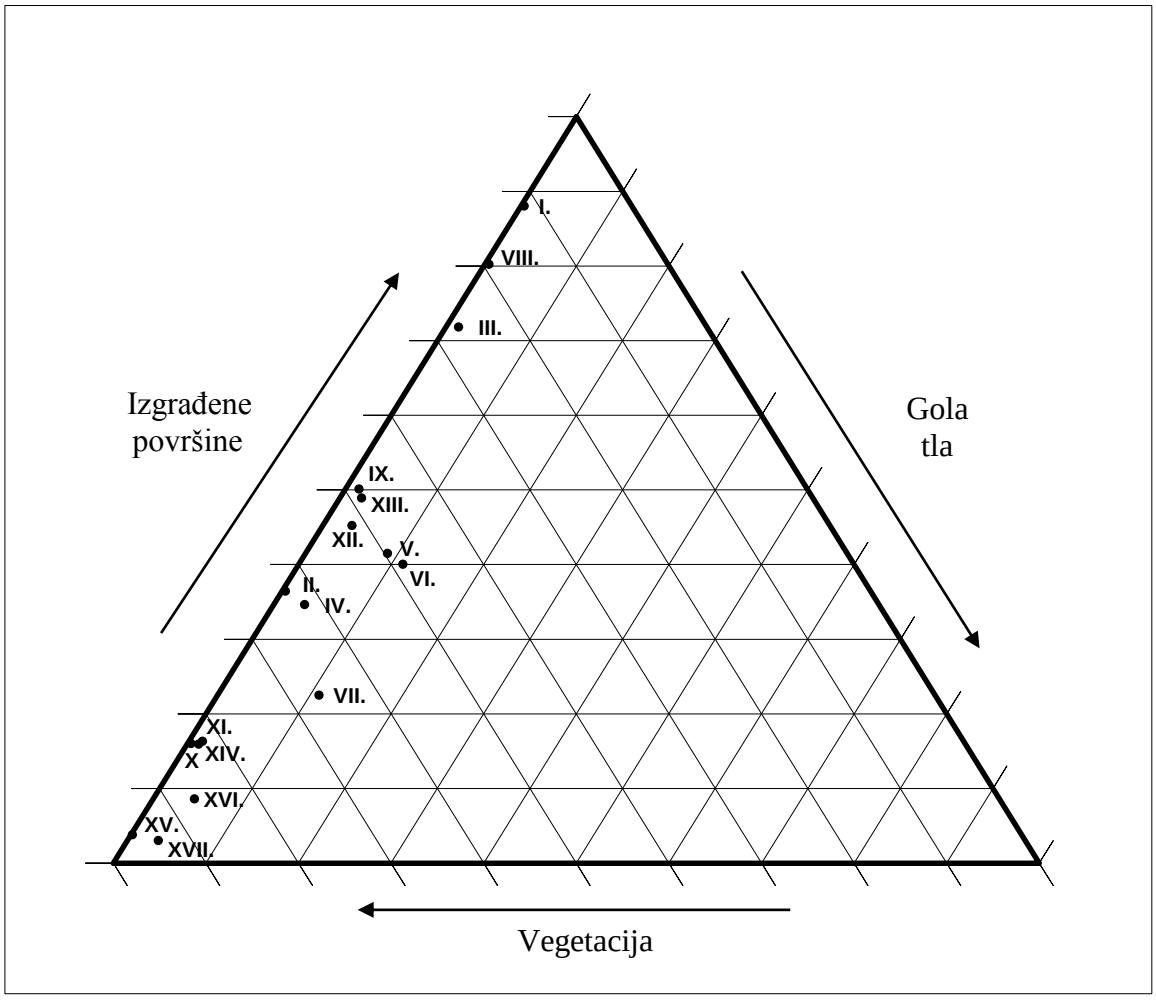

Sl. 16. Trokutni dijagram *V-I-S* modela s podacima za gradske četvrti Grada Zagreba. Izvor: autor.

Primjeri primjene VIS modela prema Weng i Lu (2006) za klasifikaciju zemljišnog pokrova ili praćenje promjena zemljišnog pokrova u urbanim područjima su Ward i dr. (2000), Madhavan i dr., (2001), Phinn i dr., (2002). Kao vrlo zanimljiv primjer praćenja promjena u okolišu ili urbanom prostoru pomoću V-I-S modela može se istaknuti istraživanje štete prouzročene potresom u Turskoj (Kaya i dr., 2004). Klasifikacijom zemljišnog pokrova prije i poslije potresa pomoću daljinskih istraživanja i usporedbom njihovih udjela u V-I-S dijagramu, moguće je jasno predočiti razmjere promjene zemljišnog pokrova uzrokane takvim događajem.

Rezultati klasifikacije zemljišnog pokrova dobiveni ovim istraživanjem upotrijebljeni su za izračunavanje udjela: površina s vegetacijskim pokrovom, površina s izgrađenim ili nepropusnim pokrovom, te površina s pokrovom golog tla, za prostorne jedinice na razini naselja i gradskih četvrti. Udjeli izgrađenih površina podijeljeni su u razrede koji bi trebali ukazivati na stupanj urbanizacije prostora, te su prikazani kartogramima i tablicama. Rezultati istraživanja na razini naselja uspoređeni su s recentnijim primjerima socioekonomske i funkcionalne tipologije naselja u zagrebačkoj regiji (Klempić, 2008; Lukić, 2010). Uspoređena tipologija temelji se na podacima iz Popisa stanovništva 2001. Svrha usporedbe bila je ispitivanje varijabli udjela zemljišnih pokrova u prostornim jedinicama na razini naselja kao pomoćne varijable za geografske tipologije naselja koje se temelje isključivo na demografskim i socioekonomskim statističkim pokazateljima. U pojedinim su primjerima, odnosno naseljima ustanovljene razlike koje se ističu primjenom socioekonomskih pokazatelja te primjenom udjela izgrađenih površina kao indikatora stupnja urbanizacije. Prema utvrđenim razlikama, moguće je podatke dobivene ovim istraživanjem pojmiti kao potencijalni modifikator metoda tipologije naselja koje se trenutno primjenjuju u Hrvatskoj.

Tab. 11. Usporedba udjela izgrađenih površina u naseljima Grada Zagreba s njihovim stupnjem urbanizacije prema Klempić, 2008.

Rang	Naselje	Stupanj urbanizacije	Udio izgrađenih površina (%)
1.	Hrvatski Leskovac	2	36,2
2.	Veliko Polje	2	35,6
3.	Lučko	2	33,5
4.	Zagreb	1	27,3
5.	Buzin	3	24,7
6.	Sesvete	1	24,3
7.	Ivanja Reka	2	20,1
8.	Vugrovec Donji	2	18,2
9.	Drežnik Brezovički	2	18,1
10.	Soblinec	2	17,1
11.	Hrašće Turopoljsko	3	17,1
12.	Zadvorsko	2	15,3
13.	Desprim	4	13,7
14.	Popovec	2	13,5
15.	Kućanec	2	12,9
16.	Ježdovec	2	11,2
17.	Đurđekovec	2	10,5
18.	Markovo Polje	2	9,9
19.	Žerjavinec	3	9,7
20.	Cerje	2	9,4
21.	Grančari	4	8,6
22.	Brezovica	2	8,3
23.	Goli Breg	2	8,2
24.	Hudi Bitek	2	7,6
25.	Gornji Čehi	2	7,0
26.	Belovar	2	6,5
27.	Dumovec	2	6,5
28.	Prekvršje	2	6,5
29.	Odranski Obrež	4	5,8
30.	Mala Mlaka	2	5,8
31.	Prepuštovec	2	5,8
32.	Gajec	2	5,6
33.	Lužan	4	5,4
34.	Odra	2	5,4
35.	Botinec	3	5,4
36.	Donji Čehi	2	5,4
37.	Dobrodol	2	5,2

Rang	Naselje	Stupanj urbanizacije	Udio izgrađenih površina (%)
38.	Paruževina	2	5,0
39.	Vurnovec	2	4,8
40.	Demerje	2	4,7
41.	Jesenovec	4	4,2
42.	Kašina	2	4,1
43.	Glavnica Gornja	3	4,0
44.	Šašinovec	3	3,9
45.	Budenec	3	3,9
46.	Adamovec	3	3,4
47.	Donji Dragonožec	2	3,0
48.	Glavničica	4	2,9
49.	Vuger Selo	2	2,7
50.	Moravče	4	2,4
51.	Kupinečki Kraljevec	4	2,4
52.	Drenčec	3	2,3
53.	Šimunčevec	3	2,1
54.	Horvati	3	2,1
55.	Planina Donja	2	2,1
56.	Gornji Dragonožec	3	2,0
57.	Strmec	4	1,9
58.	Vugrovec Gornji	2	1,9
59.	Glavnica Donja	3	1,7
60.	Blaguša	2	1,7
61.	Starjak	3	1,4
62.	Goranec	2	1,4
63.	Kučilovina	3	1,2
64.	Lipnica	3	0,8
65.	Kašinska Sopnica	2	0,8
66.	Donji Trpuci	3	0,8
67.	Gornji Trpuci	4	0,6
68.	Brebernica	3	0,5
69.	Planina Gornja	2	0,5
70.	Havidić Selo	3	0,4

5.2.6.2. Dazimetrijska karta

Za ovaj rad upotrijebljena je metoda binarnih dazimetrijskih karata pomoću koje se prostor proučavanja može unutar tematske karte podijeliti na naseljen i nenaseljen te na taj način vizualizirati razmještaj stanovništva i gustoću naseljenosti (Eicher i Brewer, 2001; Holt i Lu, 2011; Krahnen, 2012). U kategoriju nenaseljenog prostora mogu se svrstati sve one površine, odnosno klase zemljišnog pokrova za koje se smatra da ne mogu podržavati i sadržavati fenomen ljudske naseljenosti prostora. Očiti primjer su vodene površine, ali se naseljeni prostor može dodatno reducirati uklanjanjem svih površina koje nisu izgrađene, odnosno svih onih površina koje ne sadrže izgrađene objekte s funkcijama stanovanja, rada, prometa i rekreacije. Područja pokrivena vegetacijom, osobito šumom, kao i područja pokrivena golim tlima i stijenama, ukazuju na odsustvo ljudske naseljenosti.

Zbog praktičnosti kartografske vizualizacije prostornih podataka, njihove zornosti i jednostavnosti primjene, u geografiji se često upotrebljavaju kartogrami gustoće naseljenosti koji fenomen naseljenosti prikazuju cjelovitom površinom upravne ili statističke prostorne jedinice ili cijelih regija (Nejašmić i Toskić, 2000). To podrazumijeva da se za brojčani ili kartografski prikaz gustoće naseljenosti upotrebljavaju sve vrste zemljišnog pokrova koje se mogu pronaći unutar određene prostorne jedinice, uključujući i površine koje zauzimaju kopnene vode. U svrhu zornog predstavljanja problematike može se upotrijebiti sljedeća usporedba s prosječnom gustoćom naseljenosti Hrvatske na razini države. Za njezino računanje upotrebljava se kopnena površina Hrvatske, a zanemaruje se dio teritorija koji čine morske površine. To je općeprihvaćeno jer se smislenost takvog razmišljanja, da su morske površine nenaseljene – podrazumijeva. Ipak, daljnje izdvajanje naseljenog i nenaseljenog kopnenog područja nije česta praksa. Sveprisutnost GIS-alata u suvremenoj geografiji znatno je olakšala i ubrzala postupke koji su potrebni za izradu jednostavnih kartograma. Izračunavanje deskriptivne statistike skupa podataka je u velikoj mjeri automatizirano, podjela podataka u razrede je dinamična i fleksibilna, a za vizualizaciju se nude mnogobrojne boje, šrafure i simboli.

Za ovaj su dio istraživanja izdvojene izgrađene površine te su im dodijeljeni atributivni podaci o ukupnom broju stanovnika na upravnoj prostornoj razini mjesnih odbora Grada Zagreba prema Popisu stanovništva 2011. Budući da izgrađene površine mogu biti samo jednake ili manje od ukupne površine prostorne jedinice, podrazumijeva se veći broj stanovnika

na četvornome kilometru izgrađenih površina, nego na ukupnoj površini upravne jedinice. Razlike u takvim gustoćama naseljenosti ovisit će o stupnju izgrađenosti promatrane prostorne jedinice. Pregled preklopljenih podataka otkriva očite razlike, a one su najveće u mjesnim odborima koji imaju mali udio izgrađenih površina. Prikaz podataka pomoću dazimetrijskih karata nudi jasniji pregled gustoće naseljenosti i razmještaja stanovništva.

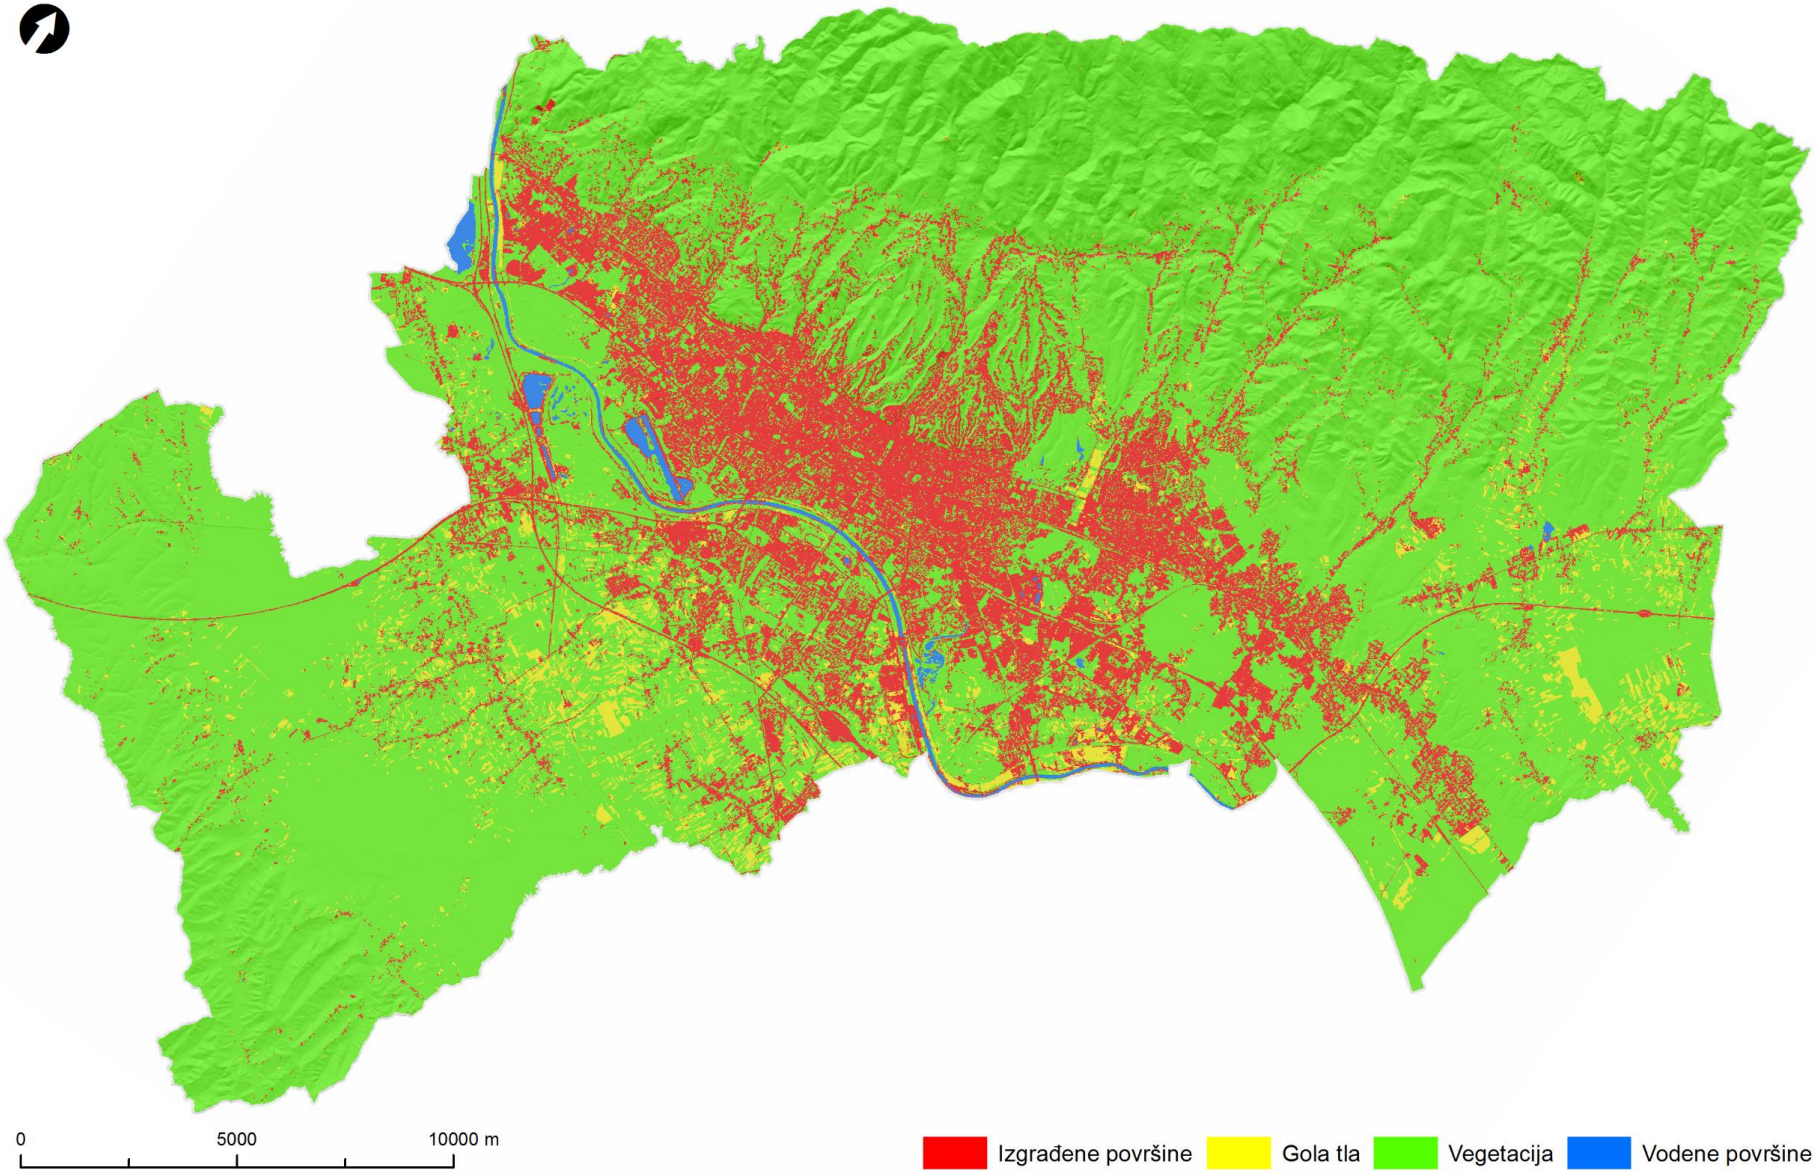

Sl. 17. Karta zemljišnog pokrova Grada Zagreba.
Izvor: autor na temelju podataka: RapidEye, 2011; RPJ, 2011; DMR, 2012.

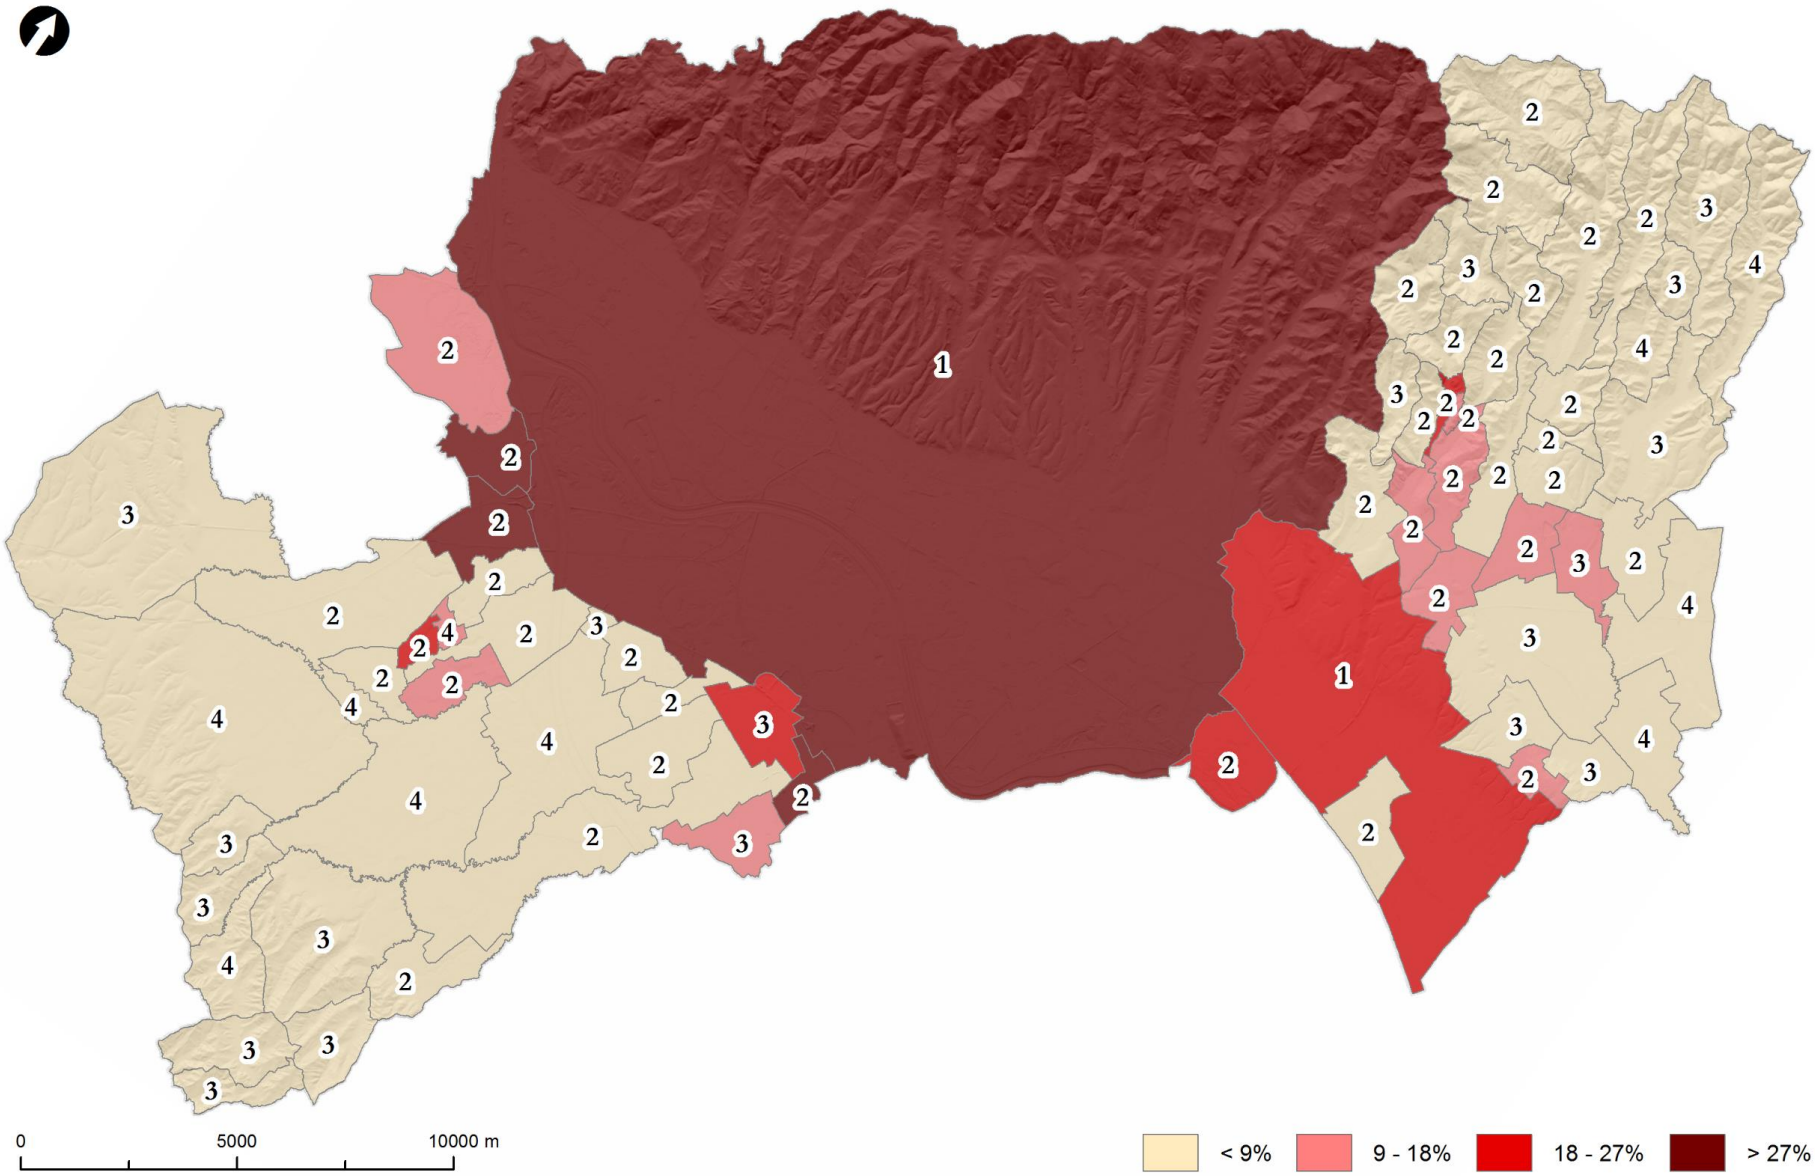

Sl. 18. Karta udjela izgrađenih površina u Gradu Zagrebu na razini prostornih jedinica naselja. Brojevi ukazuju na tipove naselja prema Klempić, 2008.
Izvor: autor na temelju podataka: Klempić, 2008; RapidEye, 2011; RPJ, 2011; DMR, 2012.

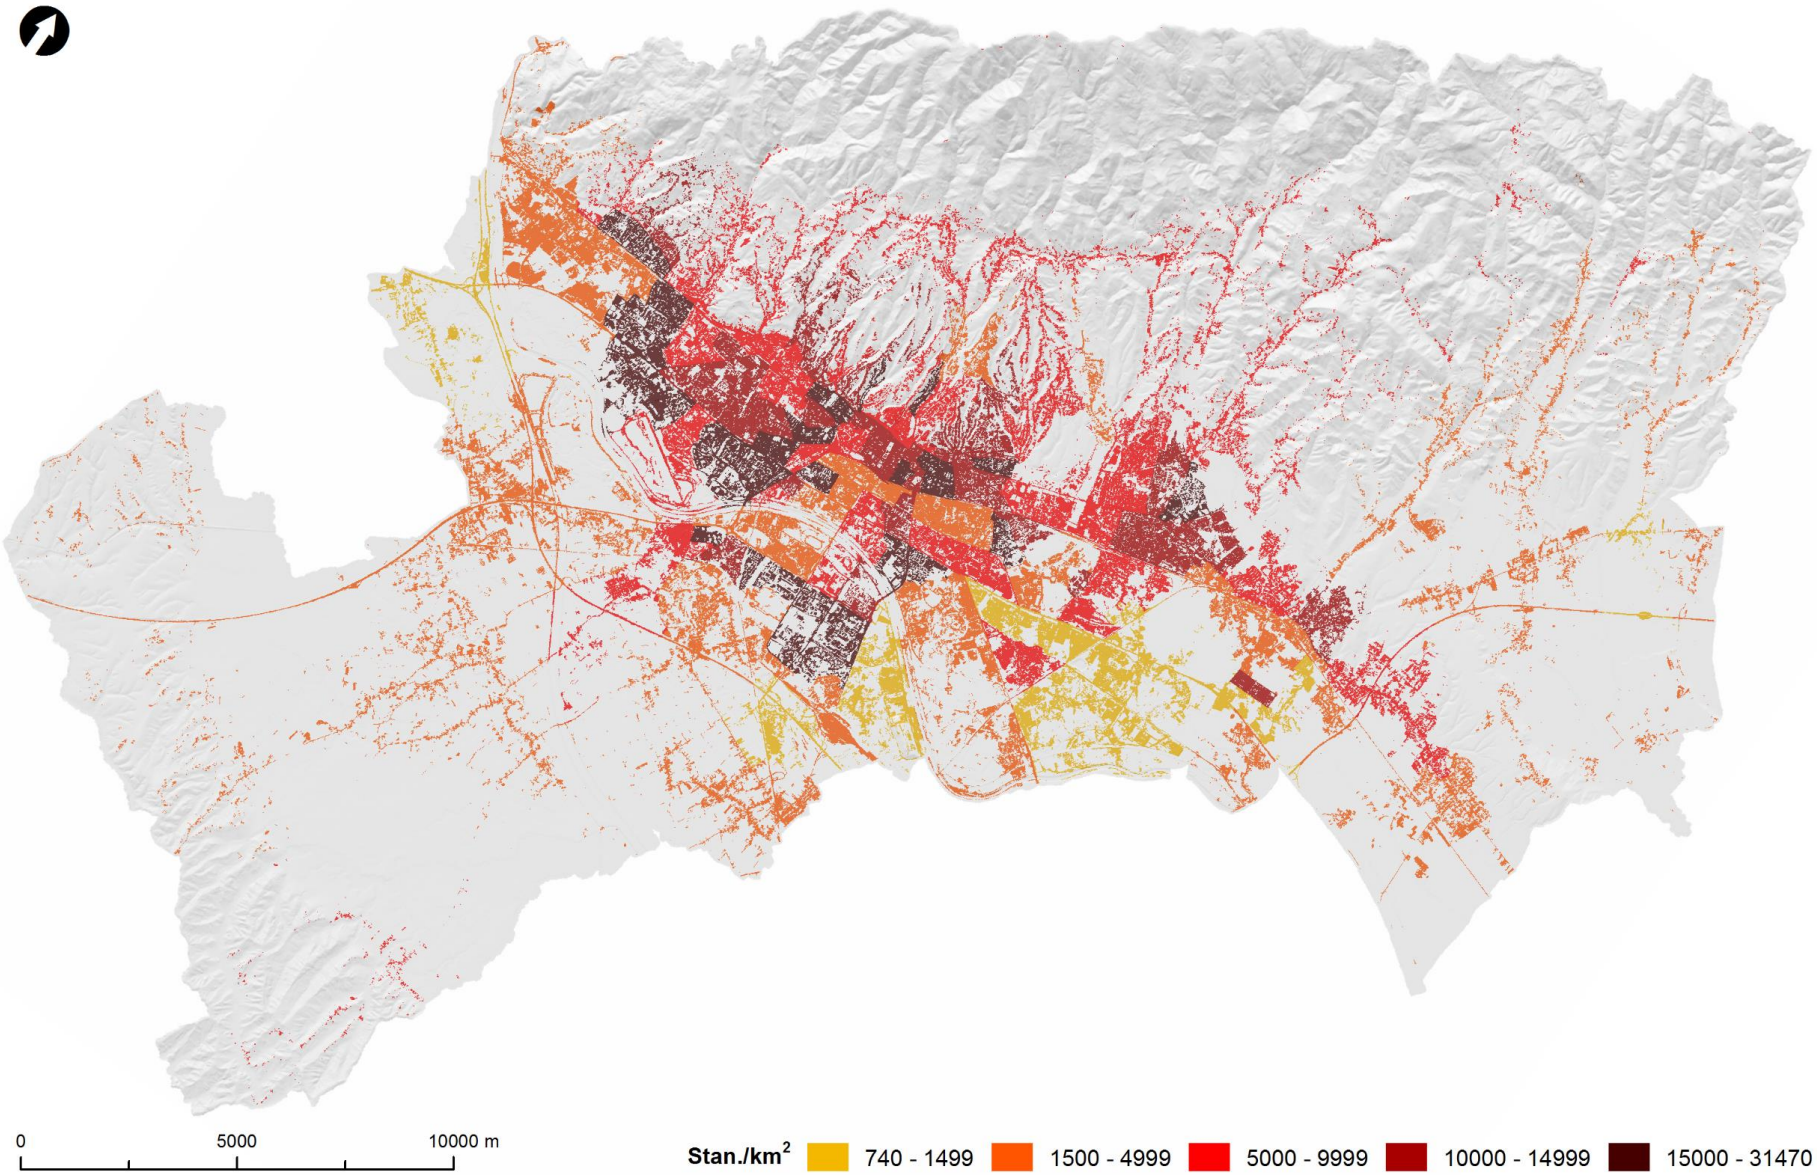

Sl. 19. Binarna dazimetrijska karta gustoće naseljenosti Grada Zagreba na razini mjesnih odbora prema Popisu stanovništva 2011. godine
Izvor: autor na temelju podataka: RapidEye, 2011; RPJ, 2011; DMR, 2012; GUSPRG, 2014.

6. REZULTATI ISTRAŽIVANJA I RASPRAVA

6.1. Tumačenje točnosti metoda klasifikacije

Prvi tip klasifikacije proveden u ovom istraživanju nije zadovoljio postavljene ciljeve. Strategija ili redoslijed postupaka uzrokovali su vidljiva nepodudaranja rezultata klasifikacija među različitim satelitskim snimkama te je odlučeno da se krajnji rezultati te klasifikacije neće upotrijebiti za izvršavanje daljnjih zadataka ovog rada. Uzrok neslaganja je vjerojatno upotreba suviše različitih uzoraka istih klasa zemljišnog pokrova za klasifikaciju odvojenih scena. Optimizacija prostora značajki je kod različitih scena i njihovih različitih uzoraka klasa zemljišnog pokrova dovela do različitih skupova optimalnih varijabli. Iako su usklađeni i reducirani skupovi varijabli zadani za klasifikaciju svih scena doveli su do naoko dobrih rezultata klasifikacije, spajanje podataka u GIS-u i detaljniji pregled otkrili su očita neslaganja među klasama na područjima preklapanja satelitskih snimaka. Dakle, rezultati tako provedene klasifikacije dovode do zaključka da bi ovakva metoda vjerojatno dovela do zadovoljavajuće razine točnosti klasifikacije za svaku pojedinačnu klasificiranu snimku ili za jednu datoteku koja je nastala spajanjem više satelitskih snimaka prije postupaka segmentacije i klasifikacije.

Pretpostavlja se da bi se negativne posljedice ovakve klasifikacije moglo izbjeći ili ublažiti s dvama postupcima predobrade snimaka. Jedan je spajanje svih scena koje pokrivaju područje Grada Zagreba u jednu datoteku koja bi se potom analizirala i klasificirala. Drugo moguće rješenje je pretvaranje brojčanih vrijednosti piksela (DN) u koeficijent ili postotak reflektancije. Taj bi postupak trebao doprinijeti usklađivanju snimaka. Pritom bi nužne pretvorbe datoteka iz npr. izvornih 16-bita u 32-bita s decimalnim vrijednostima, zatim u 8-bita s cijelim brojevima, promijenile podatkovni sadržaj datoteka, ali bi ih također uskladile. Navedene radnje i postupci bit će istražene u daljnjim istraživanjima.

Drugi upotrijebljeni tip klasifikacije doveo je do zadovoljavajućih rezultata. Prvim pregledom rezultata klasifikacije utvrđeno je da se odvojene scene mogu spajati u konačnu zajedničku vektorsku datoteku, spremnu za daljnju upotrebu u GIS-analizama zemljišnog pokrova.

Provjerom točnosti klasifikacije zemljišnog pokrova pomoću matrice konfuzije donesen je zaključak da je postignuta zadovoljavajuća točnost. Najbolji rezultati dobiveni su za klasifikaciju vegetacijskog pokrova, a uvjetno rečeno najlošiji za klasifikaciju vodenih

površina. Pretpostavlja se da su svojstva podataka nastalih radom senzora satelita RapidEye i primijenjeni vegetacijski indeks SAVI doprinijeli točnoj klasifikaciji vegetacije. Također se pretpostavlja da oslanjanje na vrijednosti zabilježene u bliskom infracrvenom dijelu spektra nije dovoljno za uspješno izdvajanje voda iz šireg skupa klasa sa sličnim spektralnim svojstvima u kojem se mogu posebno izdvojiti krovovi zgrada sa značajnim udjelom ugljikovodika, površine pod pepelom, sjene i određene asfaltirane površine. Ipak, treba spomenuti veliku raznolikost zagrebačkih vodenih površina te činjenicu da su snimke napravljene tijekom sušnog razdoblja godine. Prilikom klasifikacije izgrađenih površina, velike su pogreške učinjene s određenim tipovima tla, ali ipak najviše na područjima na kojima se voda prostorno isprepliće s drugim pokrovima ili elementima okoliša. Primjeri za to su vodena stepenica s brzacima na Savi i Malo Jezero parka Bundek. U prvom primjeru miješanje spektralnog potpisa vjerojatno uzrokuje kombinacija brze vode i stijena, a u drugom dolazi do miješanja vrlo plitkog vodenog tijela s vegetacijom i sjenama. Također treba napomenuti da i onečišćenja atmosfere mogu dovesti do velikih pogrešaka. Primjeri onečišćenja uzrokovani dimom sa zapaljenih poljoprivrednih površina vidljivi su na upotrijebljenim snimkama, kao i utjecaj koji takav dim ima na klasifikaciju zemljišnog pokrova.

Sl. 20. Prizor s Malog jezera na Bundeku – složeni pseudoprirodni zemljišni pokrov (16.11.2014.). Izvor: autor.

6.2. Primjenjivost podataka o zemljišnom pokrovu za diferencijaciju tipova naselja u urbanom i periurbanom prostoru

Usporedba podataka o udjelima izgrađenih površina u naseljima Grada Zagreba s postojeći tipologijama naselja pokazala je da se otvara nova mogućnost diferencijacije gradskih, urbaniziranih i ruralnih naselja u okolicama velikih gradova. Postojeći modeli upotrebljavaju demografske i socioekonomske podatke te podatke o određenim funkcijama naselja, ali izostaju varijable koje bi se osvrnule na morfološko-fizionomsku sastavnicu strukture naselja.

Lukićeva tipologija naselja (2009) izrađena je za cjelokupni teritorij Republike Hrvatske te se u području Grada Zagreba mogu izdvojiti tri tipa naselja: gradovi (Zagreb, Sesvete), zatim dinamična i strukturno jača naselja (Ježdovec, Lučko, Hrvatski Leskovac), te dostupnija i o cirkulaciji ovisna naselja (ostala naselja Grada Zagreba).

Podaci o stupnju izgrađenosti statističkih prostornih jedinica Grada Zagreba pokazali su da se na temelju njih mogu posebno izdvojiti naselja: Hrvatski Leskovac, Veliko Polje, Lučko i Buzin. Prema uspoređenoj tipologiji Klempić (2008) ta naselja spadaju u tipove jače i slabije urbaniziranih naselja u okolici Zagreba. Prema podacima o udjelu izgrađenih površina dobivenih ovim istraživanjem, ona su usporediva s gradskim naseljima, Zagrebom i Sesvetama.

Dodatni pregled teritorijalnog kontinuiteta i kontinuiteta izgrađenosti navedenih naselja upućuje na mogućnost promjene njihovog statusa unutar tipologije naselja. Pretpostavlja se da bi se ta naselja također mogla tumačiti kao gradska naselja. Uspoređeni skupovi podataka istraženi su i sa statističkim mjerama korelacije, ali valja uzeti u obzir da se spomenute tipologije naselja temelje na podacima iz Popisa stanovništva 2001. Smatra se da je za njihovu znanstveno opravdanu usporedbu koeficijentima korelacije nužno upotrijebiti ažurirane podatke i samim time tipologije naselja, ali one u trenutku pisanja ovog rada još nisu bile dostupne. U skladu s tim, nastavit će se i daljnje istraživanje navedene problematike.

6.3. Mogućnosti poboljšanja metodologije

Iako je postignuta zadovoljavajuća točnost zadane klasifikacije zemljišnog pokrova, moguća su određena poboljšanja ili proširenja metodologije. Upotrebom drugih izvora podataka osim onih prikupljenih daljinskim istraživanjima, poput statističkih podataka, podataka prostornih jedinica na nižim razinama i sl. mogli bi se poboljšati postupci segmentacije i klasifikacije.

Pretpostavlja se da bi fuzija upotrijebljenih multispektralnih satelitskih snimaka s drugim podacima nastalih daljinskim istraživanjima također dovela do povećanja kvalitete izlaznih prostornih podataka. Upotrebom digitalnog modela reljefa (DEM) ili površina (DSM) daljnje bi se istraživanje podiglo na novu razinu. Podaci dobiveni lidarskim daljinskim istraživanjima urbanog i periurbanog prostora nude mogućnosti klasifikacije koje nisu moguće u postupcima koji se temelje isključivo na satelitskim snimkama (Chen i dr., 2009; Dinis i dr., 2010).

Daljnje istraživanje bi također dobilo novu dimenziju upotrebom više snimaka različitog vremenskog datuma. Na taj bi se način osim klasifikacije zemljišnog pokrova omogućili praćenje i analize promjena u urbanom i periurbanom okolišu.

Budući da rezultati objektno orijentirane klasifikacije u velikoj mjeri ovise o postupcima segmentacije, u daljnjim istraživanjima valja intenzivnije ispitati mogućnosti i slabosti različitih metoda segmentacije, pojedinih parametara i težinskih faktora za slojeve podataka. Također treba istražiti alate za objektivizaciju, odnosno automatsku parametrizaciju postupka segmentacije (Dragut i dr., 2010, 2013).

7. ZAKLJUČAK

7.1. Znanstveno-istraživački doprinos istraživanja

Znanstveni doprinos istraživanja je izrada jasne i primjenjive procedure ili tijeka postupaka obrade i analize satelitskih snimaka RapidEye u računalnim programima eCognition i ArcGIS, potrebnih za uspješno klasificiranje zemljišnog pokrova urbanog i periurbanog prostora.

Konkretan doprinos je uspješno provedena klasifikacija zemljišnog pokrova cijelog područja upravne prostorne jedince Grada Zagreba, izrada novih vektorskih GIS slojeva podataka spremnih za upotrebu u daljnjim istraživanjima i distribuciju među znanstvenim djelatnicima te tematsko kartiranje klasa izgrađenih područja, vegetacije, golog tla i voda s najmanjom jedinicom kartiranja veličine 5 metara.

Rad također pruža prikaz teorijskih osnova geografije, geoinformatike i daljinskih istraživanja nužnih za provedeno istraživanje kao i primjenu stručnog nazivlja ili terminologije na hrvatskom jeziku. Terminologija iz navedenih znanstvenih disciplina nastavlja predstavljati izazov daljnjim radovima zbog nepovoljnog odnosa zastupljenosti literature na hrvatskom i stranim jezicima, prvenstveno engleskom jeziku.

Rezultati provedene klasifikacije na osnovi izrađene procedure doprinose jasnijem razgraničavanju urbanih, prijelaznih i ruralnih prostora kakve se zahtijevaju za potrebe upravnih i statističkih podjela prostora širom svijeta. Iako suvremena geografija ne tumači prostor kroz urbano-ruralnu dihotomiju, upravna tijela na najvišim nacionalnim i supranacionalnim razinama zahtijevaju upravo takvu podjelu zbog njezine praktičnosti i primjenjivosti kroz cijeli prostor njihove nadležnosti. Uloga i odgovornost znanosti po tom pitanju može biti takva da omogućuje što kvalitetniju diobu prostora u zadane tipove. Pojam klasifikacije podrazumijeva nepreklapajuće skupove informacija potrebnih za jasnu podjelu zadanog područja. Klasifikacija zemljišnog pokrova može ponuditi jednu ili više varijabli koje bi se mogle iskoristiti unutar potencijalnog nadopunjenog modela za diferencijaciju prostora. Proučeni odnosi postojećih tipologija naselja i podataka dobivenih ovim istraživanjem koji bi se mogli protumačiti kao morfološko-fizionomska obilježja naselja, upućuju na daljnja istraživanja s ciljem preciznog definiranja varijabli za proširene modele diferencijacije naselja prema stupnju urbanizacije u Hrvatskoj.

7.2. Doprinos istraživanja visokoškolskoj nastavi

Dva su aspekta mogućeg doprinosa provedenog istraživanja u visokoškolskoj nastavi: istraživački rad u računalnoj učionici i terenska nastava.

Postupci primijenjeni u ovom istraživanju dotiču sve faze znanstveno-istraživačkog rada koji se može izravno prenijeti na grupni ili samostalni rad studenata u računalnoj učionici te objedinjuje znanja i vještine iz geoinformatike i daljinskih istraživanja. Upotrijebljeni softver dostupan je studentima u računalnoj učionici Geografskog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu. Potencijalna primjena metoda istraživanja iz ovog rada u nastavi moguća je kroz njihovu integraciju u već postojeći studijski program i nastavne cjeline pojedinih kolegija, ali i stvaranje posve novih kolegija u budućnosti. Tu se posebno treba istaknuti smjer diplomskog studija – Geografski informacijski sustavi na kojem su daljinska istraživanja postala obavezni predmet.

Provjera točnosti metoda klasifikacije podataka dobivenih upotrebom daljinskih istraživanja vrši se pomoću referentnih podataka. Iako se kao referentni podaci često koriste digitalni izvori podataka poput katastra ili snimaka nastalih daljinskim istraživanjima, podaci prikupljeni terenskim radom čine najizravnije podatke o stvarnom stanju zemljišnog pokrova ili načina korištenja zemljišta (engl. *ground truth*). Prikupljanje takvih podataka prati posebna problematika te ono zahtjeva pažljivo planiranje terenskog rada, ali i intenzivan rad i suradnju na samom terenu. Visokoškolska nastava geografije poznata je po svojoj terenskoj nastavi, a daljinska istraživanja imaju veliki potencijal za povezivanje istraživačkog rada u računalnoj učionici ili laboratoriju s terenskom nastavom. Za pripremu i planiranje terenske nastave također se mogu iskoristiti računalni resursi Geografskog odsjeka, a GPS-uređaji i suvremene telekomunikacije i sveprisutni pametni telefoni pružaju mogućnosti za realizaciju terenske nastave kakve nisu bile na raspolaganju prije nekoliko godina.

LITERATURA

Abelen, S., Taubenböck, H., Stilla, U., 2011: Interactive Classification of Urban Areas Using Decision Trees, u: *JURSE 2011 – Joint Urban Remote Sensing Event* (ur. Stilla, U. i dr.), Munich, Germany, 11.-13. travnja 2011., 373-376.

Analiza stanja prirode u Republici Hrvatskoj za razdoblje od 2008. do 2012. godine (ur. Štrbenac, A.), Državni zavod za zaštitu prirode, Zagreb, 2014.

Anderson, J. R., 1971: Land-Use Classification Schemes, *Photogrammetric Engineering* 37 (4), 379-387.

Anderson, J. R., Hardy, E.E., Roach, J.T., Witmer, R.E., 1976: A land use and land cover classification system for use with remote sensor data, *US Geological Survey Professional Paper* 964, (28).

Avery, T. E., Berlin, G. L., 1992: *Fundamentals of Remote Sensing and Airphoto Interpretation*, Prentice Hall, New York.

Baatz, M., Hoffmann, C., Willhauck, G., 2008: Progressing from object-based to object-oriented image analysis, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 29-42.

Babić, S., Deluka-Tibljaš, A., Cuculić, M., Šurdonja, S. 2012: Analiza zagrijavanja kolničkih površina urbanih područja, *Građevinar* 64 (02), 125-132.

Barrett, E. C., Curtis, L. F., 1976: *Introduction to Environmental Remote Sensing*, Chapman and Hall, New York.

Batty, M., Longley, P. A., 1994: *Fractal Cities: A Geometry of Form and Function*, Academic Press, San Diego, London.

Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004: Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 239– 258.

Bertić, 1994: Zagreb – metropola Republike Hrvatske, *Geografski horizont* 40 (2), 1-17.

Besussi, E., Chin, N., Batty, M., Longley, P. A., 2010: The Structure and Form of Urban Settlements, u: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10* (ur. Rashed, T. i Jürgens, C.), Springer, Dordrecht, Heidelberg, London, New York, 13-31.

Bhaskaran, S., 2010: Improving classification accuracy of spectrally simlar urban classes by using object-oriented classification techniques: A case study of New York City, *ASPRS 2010*, San Diego, 26.-30. travnja 2010.

Biškup, Z., 2002: Transformacija gradske jezgre Bjelovara od njegova utemeljenja do danas *Hrvatski geografski glasnik* 64 (1), 55-72.

Blackbridge Rapid Eye Satellite Imagery Product Specifications, Version 6, 2013, http://blackbridge.com/rapideye/upload/RE_Product_Specifications_ENG.pdf (5.1.2015.)

Bobek, H. 1927: Grundfragen der Stadtgeographie, *Geographischer Anzeiger* 28, 213-224.

Bobek, H., 1938: Über einige funktionelle Stadttypen und ihre Beziehung zum Lande, *Comptes rendus du Congrès international de géographie*, International Geographical Union, Brill Archive, Amsterdam.

Bock, M., Xofis, P., Mitchley, J., Rossner, G., Wissen, M., 2005: Object-oriented methods for habitat mapping at multiple scales–Case studies from Northern Germany and Wye Downs, UK, *Journal for Nature Conservation* 13 (2), 75-89.

Bognar, A., 1992: Geomorfološke osobine Republike Hrvatske, *Geografski horizont* 38 (2), 16-25.

Bušljeta Vdović, S., 2006: Zračne snimke kao podloga za daljinska istraživanja u prostornom planiranju, *Prostor* 14 (2/32), 246-255.

Butler, D., Davies, J. W., 2004: *Urban Drainage*, SPON Press, London, New York.

Buzjak, N., 2011: Georaznolikost i geobaština – pojam i značenje, u: *5. hrvatski geografski kongres – Knjiga sažetaka* (ur. Prelogović, V. i Cvitanović, M.), Osijek, Hrvatska, 5.-8. 10. 2011. Hrvatsko geografsko društvo, Zagreb, 30.

Campbell, J. B., Wynne, R. H., 2011: *Introduction to Remote Sensing*, Guilford Press, New York.

Canters, F., Batelaan, O., de Voorde, T. V., Chormański, J., Verbeiren, B., 2011: Use of Impervious Surface Data Obtained from Remote Sensing in Distributed Hydrological Modeling of Urban Areas, u: *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment* (ur. Yang, X.), John Wiley & Sons, Chichester, 255-275.

Castells, M., 2010: *The rise of the network society: The information age: Economy, society, and culture, Vol. 1*, John Wiley & Sons, Chichester.

Castilla, G., Hay, G. J., 2008: Image objects and geographic objects, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 91-110.

Chen, Y., Su, W., Li, J., Sun, Z., 2009: Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas, *Advances in Space Research* 43 (7), 1101-1110.

Chrisman, N. R., 2003: *Exploring Geographical Information Systems* Wiley, Hoboken.

Clark, P. E., Rilee, M., 2010: *Remote Sensing Tools for Exploration: Observing and Interpreting the Electromagnetic Spectrum*, Springer, New York.

Congalton, R. G., Green, K., 2009: *Assessing the accuracy of remotely sensed data: principles and practices*. CRC Press, Boca Raton.

Corine Land Cover – Pokrov i namjena korištenja zemljišta u Republici Hrvatskoj – Stanje i trendovi, Agencija za zaštitu okoliša, Zagreb, 2010.

Council decision of 27 June 1985 on the adoption of the Commission work programme concerning an experimental project for gathering, coordinating and ensuring the consistency of information on the state of the environment and natural resources in the Community, 85/338/EEC.

Crljenko, I., 2012: Utjecaj nekih sociogeografskih čimbenika na morfogenezu zagrebačke Dubrave. *Hrvatski geografski glasnik* 74 (1), 111-139.

Cvitanović, M., 2014: *Promjene zemljišnog pokrova i načina korištenja zemljišta u Krapinsko-zagorskoj županiji od 1978. do 2011. godine*, doktorska disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek.

De Kok, R., Wever, T., Flockelmann, R., 2003: Analysis of urban structure and development applying procedures for automatic mapping of large area data, u: *Remote sensing of urban areas* (ur. Juergens, C.), u: *Proceedings of the 4th international symposium*, Regensburg, 27.-29. lipnja 2003., *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34 (7/W9), CD-ROM, 41–46.

DiBiase, David, DeMers, M., Johnson, A., Kemp, K., Luck, A.T., Plewe, B., i Wentz, E., 2006: *Geographic Information Science & Technology Body of Knowledge*, Association of American Geographers, Washington D.C.

Dinis, J., Navarro, A., Soares, F., Santos, T., Freire, S., Fonseca, A., Tenedório, J., 2010: Hierarchical object-based classification of dense urban areas by integrating high spatial resolution satellite images and lidar elevation data, *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38 (4/C7).

Donnay, J. P., Barnsley, M. J., Longley, P. A., 2003: Remote Sensing and Urban Analysis, u: *Remote Sensing and Urban Analysis: GISDATA 9* (ur. Donnay, J. P. i dr.), Taylor and Francis, New York, London, 2-14.

Drăguţ, L., Csillik, O., Eisank, C., Tiede, D., 2014: Automated parameterisation for multi-scale image segmentation on multiple layers, *ISPRS Journal of Photogrammetry and Remote Sensing* 88, 119-127.

Drăguţ, L., Tiede, D., Levick, S. R., 2010: ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data, *International Journal of Geographical Information Science* 24 (6), 859-871.

Dupuy, S., Barbe, E., Balestrat, M., 2012: An object-based image analysis method for monitoring land conversion by artificial sprawl use of RapidEye and IRS data, *Remote Sensing* 4 (2), 404-423.

Eicher, C. L., Brewer, C. A., 2001: Dasymetric mapping and areal interpolation: Implementation and evaluation, *Cartography and Geographic Information Science* 28 (2), 125-138.

Elachi, C., 1987: *Introduction to the Physics and Techniques of Remote Sensing*, Wiley, Chichester.

Elvidge, C. D., Tuttle, B. T., 2008: How virtual globes are revolutionizing earth observation data access and integration, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37, 137-139.

Encyclopedia Britannica, www.britannica.com (5.1.2015.)

ESRI, 2012: The 50th Anniversary of GIS, *ArcNews*, http://www.esri.com/news/arcnews/fall12articles/the-fiftieth-anniversary-of-gis.html (5.1.2015.)

feature extraction using high spatial resolution satellite data of urban areas, *Journal of Spatial Science*, 55 (1), 117-132.

Fischer, W. A., Hemphill, W. R., Kover, A., 1976: Progress in Remote Sensing, *Photogrammetria* 32, 33–72.

Fishman, R., 1990: America's new city, *The Wilson Quarterly* 14 (1), 24-55.

Fotheringham, A. S., Wilson, J. P., 2008: Geographical Information Science: An Introduction, u: *The handbook of geographic information science* (ur. Fotheringham, A. S. i Wilson, J. P.), Blackwell, Malden, Oxford, Carlton, 1-8.

Frančula, N., Lapaine, M., 2008: *Geodetsko-geoinformatički rječnik*, Državna geodetska uprava, Zagreb.

Galster, G., Hanson, R., Ratcliffe, M. R., Wolman, H., Coleman, S., Freihage, J., 2001: Wrestling sprawl to the ground: defining and measuring an elusive concept, *Housing policy debate* 12 (4), 681-717.

Getis, A., Getis, J., Fellmann, J. D., 2006: *Introduction to Geography*, McGraw-Hill, New York.

Gonzalez, R. C., Woods, R. E., 2002: *Digital image processing*, Prentice Hall, New Jersey.

Goodchild, M. F., 1992: Geographical information science, *International Journal of Geographical Information Systems* 6 (1), 31-45.

Grgurović, O., 1984: Funkcionalno-morfološka struktura suburbanog prostora, *Sociologija i prostor* 22 (83-86), 23-34.

Haralick, R. M., Shanmugam, K., Dinstein, I. H., 1973: Textural features for image classification, *Systems, Man and Cybernetics, IEEE Transactions on* 6, 610-621.

Hard, G.,1973: *Die Geographie: Eine Wissenschaftstheoretische Einführung*, Walter de Gruyter, Berlin.

Harris, R. J., Longley, P. A., 2000: New data and approaches for urban analysis: modelling residential densities, *Transactions in GIS* 4 (3), 217-234.

Hay, G. J., Castilla, G., 2008: Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 75-89.

Herold, M., Gardner, M. E., Roberts, D. A., 2003: Spectral resolution requirements for mapping urban areas, *Geoscience and Remote Sensing, IEEE Transactions on* 41 (9), 1907-1919.

Herold, M., Roberts, D. A., 2010: The spectral dimension in urban remote sensing, u: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10* (ur. Rashed, T. i Jürgens, C.), Springer, Dordrecht, Heidelberg, London, New York, 47-65.

Herold, M., Roberts, D. A., Gardner, M. E., Dennison, P. E., 2004: Spectrometry for urban area remote sensing—Development and analysis of a spectral library from 350 to 2400 nm, *Remote Sensing of Environment* 91, 304-319.

Herold, M., Schiefer, S., Hostert, P., Roberts, D. A., 2006: Applying imaging spectrometry in urban areas, u: *Urban remote sensing* (ur. Weng, Q. i Quattrochi, D. A.), CRC Press, Boca Raton, 137-161.

Hese, S., Schmullius, C., 2008: Object oriented oil spill contamination mapping in West Siberia with Quickbird data, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 367-382.

Hilbert, M., Lopez, P., 2011: The World's Technological Capacity to Store, Communicate, and Compute Information, *Science* 332 (6025), 60-65.

Hofmann P., 2001: Detecting Informal Settlements from IKONOS Image Data Using Methods of Object Oriented Image Analysis – An Example from Cape Town (South Africa), u: *Remote Sensing of Urban Areas* (ur. Jürgens, C), Regensburg: University Regensburg, Germany, 41-42.

Hofmann, P., Strobl, J., Blaschke, T., Kux, H., 2008: Detecting informal settlements from Quickbird data in Rio de Janeiro using an object based approach, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 531-553

Holt, J. B., Lu, H., 2011: Dasymetric mapping for population and sociodemographic data redistribution, u: *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment* (ur. Yang, X.), John Wiley & Sons, Chichester ,195-210.

Horvath, H., 2009: Gustav Mie and the scattering and absorption of light by particles: Historic developments and basics, *Journal of Quantitative Spectroscopy and Radiative Transfer* 110 (11), 787-799.

Hrvatska enciklopedija, Leksikografski zavod Miroslav Krleža, www.enciklopedija.hr, (5.1.2015.).

Huete, A. R., 1988: A soil-adjusted vegetation index (SAVI), *Remote sensing of environment* 25 (3), 295-309.

Ipsen, D. 2009: From Urban Growth to Mega Urban Landscape, u: *Multiple city: urban concepts 1908-2008* (ur. Wolfrum, S. i dr.), Jovis, Berlin,19-33.

Jacob, E. K., 2004: Classification and Categorization: A Difference that Makes a Difference, *Library trends* 52 (3), 515-540.

Jacobs, S., Eeckhout, B., 2009: (Dys)functionalism in a post(sub)urban landscape, u: *Multiple city: urban concepts 1908-2008* (ur. Wolfrum, S. i dr.), Jovis, Berlin, 34-37.

Jensen, J. R., Cowen, D. C., 1999: Remote sensing of urban/suburban infrastructure and socio-economic attributes, *Photogrammetric engineering and remote sensing* 65, 611-622.

Kamagata, N., Hara, K., Mori, M., Akamatsu, Y., Li, Y., Hoshino, Y., 2006: A new method of vegetation mapping by object-based classification using high resolution satellite data, u: *Proceedings of the 1st International Conference on Object-based Image Analysis*, 36 (4/C42).

Kamagata, N., Hara, K., Mori, M., Akamatsu, Y., Li, Y., Hoshino, Y., 2008: Object-based classification of IKONOS data for vegetation mapping in Central Japan, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 459-475.

Kampouraki, M., Wood, G. A., Brewer, T. R., 2008: Opportunities and limitations of object based image analysis for detecting urban impervious and vegetated surfaces using true-colour aerial photography, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 555-569.

Kaya, S., Llewellyn, G., Curran, P. J., 2004: Displaying Earthquake damage an Urban Area Using a Vegetation-Impervious-Soil Model and Remotely Sensed Data, u: *Proceedings of the XX congress international society of photogrammetry and remote sensing*, Istanbul, 12.-25. srpnja, 2004., 12-23.

Kemp, K. K., 2008: *Encyclopedia of Geographic Information Science*, Sage Publications, Thousad Oaks.

Kettig, R. L., Landgrebe, D. A., 1976: Classification of multispectral image data by extraction and classification of homogeneous objects, *IEEE Transactions on Geoscience Electronics* 14 (1), 19-26.

Kim, M., Madden, M., 2006: Determination of optimal scale parameter for alliance-level forest classification of multispectral IKONOS images, u: *Bridging Remote Sensing and GIS, 1st International Conference on Object-based Image Analysis* (ur. Lang, S. i dr.), 4.-5. srpnja 2006., Salzburg, u: *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4/C42).

Kim, M., Madden, M., Warner, T., 2008: Estimation of optimal image object size for the segmentation of forest stands with multispectral IKONOS imagery, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 291-307.

Klempić Bogadi, S., 2008: *Demogeografski Aspekti Suburbanisacije Hrvatske – Primjer Riječke Aglomeracije*, doktorska disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek.

Klöpper, R., 1956: Der geographische Stadtbegriff, *Geogr. Taschenbuch* 57, 453-461.

Konecny, G., 2002: *Geoinformation: remote sensing, photogrammetry and geographic information systems*, Taylor and Francis, London, New York.

Krahnen, A., 2012: *Cartographic visualization of Saskatchewan's population using dasymetric mapping*, Doctoral dissertation, Faculty of Graduate Studies and Research, University of Regina.

Kramer, H. J., 2002: *Observation of the Earth and its Environment: Survey of Missions and Sensors*, Springer, Berlin.

Kranzberg, M.,1985: The information age: Evolution or Revolution, u: *Information technologies and social transformation* (ur. Guile, B. R.), National Academy Press, Washington, 7-33.

Kuhn, T. S., 1962: *The structure of scientific revolutions*, University of Chicago press, Chicago.

Landgrebe, D. A., 2003: *Signal theory methods in multispectral remote sensing*, Wiley, Hoboken.

Landis, J., Koch, G., 1977: The measurement of observer agreement for categorical data, *Biometrics*, 33, 159-174.

Lewiński, S, Bochenek, Z., 2008: Rule-based classification of SPOT imagery using objectoriented approach for detailed land cover mapping, u: *Proccedings of the 28th EARSeL Symposium* (ur. Maktav, D.), Istanbul, 2.-5. lipnja 2008.

Lewiński, S., 2005: Land use classification of ASTER image–Legionowo test site, u: *Proccedings of the 25th EARSeL Symposium*, Porto, 6.-11. lipnja 2005.

Lillesand, T. M., Kiefer, R. W., Chipman, J. W., 2004: *Remote sensing and image interpretation*, Wiley, Hoboken.

Lintz, J., Simonett, D. S., 1976: *Remote Sensing of Environment*, Addison-Wesley, Reading.

Longley, P. A., Goodchild, M. F., Maguire, D. J., Rhind, D. W., 2005: *Geographic information systems and science*, Wiley, Chichester.

Lu, D., Weng, Q., 2007: A survey of image classification methods and techniques for improving classification performance, *International journal of Remote sensing* 28 (5), 823-870.

Lukić, A., 2009: *Tipologija ruralnih područja Hrvatske – geografski aspekt*, doktorska disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek.

Madhavan, B. B., Kubo, S., Kurisaki, N., Sivakumar, T. V. L. N., 2001: Appraising the anatomy and spatial growth of the Bangkok Metropolitan area using a vegetation-impervious-soil model through remote sensing, *International Journal of Remote Sensing* 22 (5), 789-806.

Matković, I., Obad Šćitaroci, M., 2012: Rijeka Sava s priobaljem u Zagrebu, *Prostor* 20 (1/43), 46-59.

Maxwell, J. C., 1865: A dynamical theory of the electromagnetic field, *Philosophical Transactions of the Royal Society of London* 155, 459-512.

McFeeters, S. K., 1996: The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International journal of remote sensing* 17 (7), 1425-1432.

McGee, T.G., 1987: Urbanization or Kotadesasi - The Emergence of New Regions of Economic Interaction in Asia, *Working paper* 87 (8), Environment and Policy Institute, Honolulu.

Mesev, V., 2010: Classification of urban areas: inferring land use from the interpretation of land cover, u: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10* (ur. Rashed, T. i Jürgens, C.), Springer, Dordrecht, Heidelberg, London, New York, 141-164.

Moeller, M. S., Blaschke, T. 2005: Monitoring LULC dynamics in the urban-rural fringe, *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, Goiânia, 16.-21. travnja 2005. INPE, 3821-3828.

Myint, S. W., 2006: Urban Mapping with Geospatial Algorithms. u: *Urban remote sensing* (ur. Weng, Q. i Quattrochi, D. A.), CRC Press, Boca Raton, 109-136.

Navulur, K., 2006: *Multispectral image analysis using the object-oriented paradigm*, CRC Press, Boca Raton.

Nejašmić, I., Toskić, A., 2000: Razmještaj stanovništva u Republici Hrvatskoj-dio općih demogrfskih i društveno-gospodarskih procesa, *Geoadria* 5 (1), 93-104.

Nicodemus, F., Richmond, J. C., Hsia, J., Ginsburg, I., Limperis, T. 1977: Geometrical Considerations and Nomenclature for Reflectance, Technical Report, *NBS Monograph* 160, US Department of Commerce, National Bureau of Standards; Washington, 1-52.

Nir, D., 1990: *Region as a Socio-environmental System*, Springer, Dordrecht.

Njegač, D., Gašparović, S., Stipešević, Z., 2012: Promjene u morfološkoj strukturi Osijeka nakon 1991. godine, *Acta Geographica Croatica* 38 (1), 59-74.

Olsen, R. C., 2007: *Remote Sensing from Air and Space*, SPIE Press, Bellingham, Washington.

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

Park prirode Medvedinca, Upravljanje, http://www.pp-medvednica.hr/o-nama/upravljanje/, (5.1.2015.).

Phinn, S., Stanford, M., Scarth, P., Murray, A. T., Shyy, P. T., 2002: Monitoring the composition of urban environments based on the vegetation-impervious surface-soil (VIS) model by subpixel analysis techniques, *International Journal of Remote Sensing* 23 (20), 4131-4153.

Pierzchalski, M., 2013: *Ocena typów segmentacji dostępnych w oprogramowaniu eCognition firmy TRIMBLE w analizie zobrazowań satelitarnych RapidEye*, diplomski rad, Uniwersytet Jagielloński w Krakowie, University of Salzburg.

Pravilnik o registru prostornih jedinica, Narodne novine 37/08

Price, J. C., 1997: Spectral band selection for visible-near infrared remote sensing: spectral-spatial resolution tradeoffs, *Geoscience and Remote Sensing, IEEE Transactions on* 35 (5), 1277-1285.

Quattrochi, D. A., Ridd, M. K., 1994: Measurement and analysis of thermal energy responses from discrete urban surfaces using remote sensing data, *International Journal of Remote Sensing* 15 (10), 1991-2022.

Rashed, T., Jürgens, C. (ur.), 2010: *Remote sensing of urban and suburban areas, Remote Sensing and Digital Image Processing 10*, Springer, Dordrecht, Heidelberg, London, New York.

Rautio, J. C., 2014: The Long Road to Maxwell's Equations: How four enthusiasts helped bring the theory of electromagnetism to light, IEEE Spectrum 2014 (12).

Remote Sensing with Special Reference to Agriculture and Forestry, National Academy of Sciences, Washington, 1970.

Repaka, S. R., Truax, D. D., Kolstad, E., O'Hara, C. G., 2004: Comparing spectral and object based approaches for classification and transportation feature extraction from high resolution multispectral imagery, u: *ASPRS Annual Conference Proceedings*, Denver, 23.-28. svibnja 2004.

Richards, J. A., Jia, X., 2006: *Remote Sensing Digital Image Analysis, An Introduction*, Springer, Berlin Heidelberg.

Richards, J. A., 2013: *Remote Sensing Digital Image Analysis, An Introduction*, Springer, Berlin Heidelberg.

Ridd, M. K., 1995: Exploring a VIS (vegetation-impervious surface-soil) model for urban ecosystem analysis through remote sensing: comparative anatomy for cities, *International Journal of Remote Sensing*, 16 (12), 2165-2185.

Riedel, T., Thiel, C., Schmullius, C. 2008: Fusion of multispectral optical and SAR images towards operational land cover mapping in Central Europe, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 493-511.

Roberts, D. A., Smith, M. O., Adams, J. B., 1993: Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data, *Remote Sensing of Environment*, 44 (2), 255-269.

Robinson, V. B., 2008: Fuzzy classification and mapping, u: *The handbook of geographic information science* (ur. Fotheringham, A. S. i Wilson, J. P.), Blackwell, Malden, Oxford, Carlton, 259-272.

Roglić, J., 1960: Neki osnovni problemi geografije, *Hrvatski geografski glasnik*, 22 (1), 9-14.

Rouse, J.W. Jr., Haas, R.H., Deering, D. W., Schell, J.A., Harlan, J. C., 1974: Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation, *NASA/GSFC Type III Final Report*, Greenbelt, MD.

Rowe, P. G. 1991: *Making a Middle Landscape*, MIT press, Cambridge.

Schott, J. R., 2007: *Remote Sensing: The Image Chain Approach*, Oxford University Press.

Slukan Altić, M., 2010: Povijest regulacije rijeke Save kod Zagreba i njezine posljedice na izgradnju grada, *Hrvatske vode* 18 (73), 205-212.

Smith, G. M., 2008: The development of integrated object-based analysis of EO data within UK national land cover products, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 513-528.

Soja, E. S., 1992: Inside exopolis: Scenes from Orange County, u: *Variations on a Theme Park* (ur. Sorkin, M.), Noonday Press, New York, 94-122.

Sonka, M., Hlavac, V., Boyle, R., 2007: *Image processing, analysis and computer vision*, Thomson, Toronto.

Story, M., Congalton, R. G., 1986: Accuracy assessment - A user's perspective, *Photogrammetric Engineering and remote sensing*, 52 (3), 397-399.

Struna – Hrvatsko strukovno nazivlje, http://struna.ihjj.hr/ (5.1.2015).

Swain, P. H., Davis, S. M., 1978: *Remote sensing: The Quantitative Approach*, McGraw-Hill, New York.

Swayze, G.A., Clark, R.N., Goetz, A.F.H., Chrien, T.G., Gorelick, N.S., 2003: Effects of spectrometer bandpass, sampling, and signal-to-noise ratio on spectral identification using the Tetracorder algorithm, *J Geophys Res* 108 (E9), 2-34.

Šegota, T., 1989: Temperatura zraka u Zagrebu u 21 sat, *Acta Geographica Croatica*, 24 (1), 1-17.

Tacoli, C., 1998: Rural-urban interactions; a guide to the literature, *Environment and Urbanization*, 10, 147-166.

Taubenböck, H., Esch, T., Wurm, M., Roth, A., Dech, S., 2010: Object-based

Thiel, C., Thiel, C., Riedel, T., i Schmullius, C., 2008: Object based classification of SAR data for the delineation of forest cover maps and the detection of deforestation–A viable procedure and its application in GSE Forest Monitoring,), u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 327-343.

Thiel, Ca., Thiel, Ch., Riedel, T., Schmullius, C., 2007: Analysis of ASAR APP Time Series over Siberia for Optimising Forest Cover Mapping - A GSE Forest Monitoring Study, u: *Proc. ENVISAT Symposium*, 23.-27. travnja 2007., Montreux, Švicarska.

Thu, T. T. H., Lan, P. T., Ai, T. T. H., 2013: Rule set of object-oriented classification using Landsat imagery in Donganh, Hanoi, Vietnam. *Journal of the Korean Society of Surveying Geodesy Photogrammetry and Cartography*, 31 (6/2), 521-527.

Tomlinson, R. F., 1962: Computer mapping: an introduction to the use of electronic computers in the storage, compilation and assessment of natural and economic data for the evaluation of marginal lands, u: *Proceedings of the National Land Capability Inventory Seminar*, Agricultural Rehabilitation and Development Administration of the Canada Department of Agriculture, 29-30. studenog 1962, Ottawa, Kanada.

Tomlinson, R. F., 1968: A geographic information system for regional planning, u: *Symposium on Land Evaluation* (ur. Stewart, G. A.), Commonwealth Scientific and Industrial Research Organization, MacMillan of Australia, Melbourne, 200-210.

Tormos, T., Dupuy, S., Van Looy, K., Barbe, E., Kosuth, P. 2012: An OBIA for fine-scale land cover spatial analysis over broad territories: demonstration through riparian corridor and artificial sprawl studies in France, u: *4th International Conference on Geographic Object-Based Image Analysis (GEOBIA)*, Rio de Janeiro 7-9. svibnja 2012.

Trimble eCognition Developer 9 Reference Book, 2014, Trimble Germany GmbH.

Trimble eCognition Developer 9 User Guide, 2014, Trimble Germany GmbH.

Tuxen, K., Kelly, M., 2008: Multi-scale functional mapping of tidal marsh vegetation using object-based image analysis, u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 415-442.

Uddin, K., Gurung, D. R., 2010: Land cover change in Bangladesh - a knowledge based classification approach, u: *Proceedings of the 10th International Symposium on High Mountain Remote Sensing Cartography, Grazer Schriften der Geographie und Raumforschung* (ur. Kaufmann, V. i Sulzer, W.), Institute of Geography and Regional Science, University of Graz, 41-46.

University of Calgary Wiki, OBIA, http://wiki.ucalgary.ca/page/OBIA (5.1.2015.).

Valožić, L., Cvitanović, M.. 2011: Mapping the forest change: using Landsat imagery in forest transition analysis within the Medvednica protected area, *Hrvatski geografski glasnik*, 73 (1), 245-255.

Varela, R. A. D., Rego, P. R., 2008: Classification of linear environmental impacts and habitat fragmentation by object oriented analysis of aerial photographs in Corrubedo National Park (NW Iberian Peninsula), u: *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 399-414.

Veljanovski, T., Kanjir, U., Oštir, K., 2011: Objektno umjerena analiza podatkov daljinskega zaznavanja, *Geodetski vestnik*, 55, 4, 641-664.

Vresk, M. 1997. Uvod u geografiju: razvoj, struktura, metodologija. *Zagreb, Školska knjiga*.

Vresk, M. 1986: Socioekonomske gradske regije Hrvatske, *Hrvatski geografski glasnik*, 48 (1), 73-82.

Vresk, M., 1991: Paradigme u geografiji, *Hrvatski geografski glasnik*, 53, 19-26.

Vresk, M., 1996: Grad kao prostorni sustav i ekosustav, u: *Grad kao složen sustav* (ur. Božičević, J.), Hrvatsko društvo za sustave, Nakladni zavod Matice hrvatske, Zagreb.

Vresk, M., 2002: *Grad i urbanizacija: osnove urbane geografije*, Školska knjiga, Zagreb.

Ward, D., Phinn, S. R. i Murray, A. T.,2000: Monitoring growth in rapidly urbanizing areas using remotely sensed data, *The Professional Geographer*, 52 (3), 371-386.

Welch, R., 1982: Spatial resolution requirements for urban studies, *International Journal of Remote Sensing*, 3 (2), 139-146.

Weng, Q., Lu, D., 2006: Subpixel analysis of urban landscapes, , u: *Urban remote sensing* (ur. Weng, Q. i Quattrochi, D. A.), CRC Press, Boca Raton, 71-90.

Weng, Q., Quattrochi, D. A. (ur.), 2006: *Urban remote sensing*, CRC Press, Boca Raton.

Weng, Q., 2010: *Remote sensing and GIS integration: theories, methods, and applications*, McGraw-Hill, New York.

White, L. P., 1977: *Aerial Photography and Remote Sensing for Soil Survey*, Clarendon Press, Oxford.

Wilkinson, G.G., 1996: A review of current issues in the integration of GIS and remote sensing data, *International Journal of Geographical Information Systems*10**,** 85–101.

Woodcock, C. E., Strahler, A. H., 1987: The factor of scale in remote sensing, *Remote sensing of Environment*, 21 (3), 311-332.

Wu, C., Yuan, F., 2011: Remote sensing of high resolution urban impervious surfaces, u: *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment* (ur. Yang, X.), John Wiley & Sons, Chichester, 238-253.

Wulder, M. A., White, J. C., Hay, G. J., i Castilla, G., 2008: Pixels to objects to information: Spatial context to aid in forest characterization with remote sensing, u: *Object-Based Image*

Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications (ur. Blaschke, T. i dr.), Springer, Berlin, Heidelberg, 345-363.

Yang, C., Everitt, J. H., Bradford, J. M., & Murden, D., 2004: Airborne hyperspectral imagery and yield monitor data for mapping cotton yield variability, *Precision Agriculture*, 5 (5), 445-461.

Yang, X. (ur.), 2011: *Urban remote sensing: Monitoring, synthesis and modeling in the urban environment*, John Wiley & Sons, Chichester.

Yuan, F., Bauer, M.E., 2006: Mapping Impervious Surface Area Using High Resolution Imagery: A Comparison of Object-Oriented Classification to Per-Pixel Classification, *Proceedings of ASPRS 2006 Annual Conference, Reno, NV, SAD, 1–5 svibnja 2006, 3*, 1667–1674.

Zadeh, L. A., 1965: Fuzzy sets, *Information and control*, 8 (3), 338-353.

Zakon o državnoj izmjeri i katastru nekretnina, Narodne novine 16/7

Zakon o izmjenama zakona o državnoj izmjeri i katastru nekretnina, Narodne novine 124/10

Zhu, A.X., 2008: Rule based mapping, u: *The handbook of geographic information science* (ur. Fotheringham, A. S. i Wilson, J. P.), Blackwell, Malden, Oxford, Carlton, 273-291.

IZVORI

5th GEOBIA, http://geobia2014.web.auth.gr/geobia14/ (5.1.2015.)

BlackBridge, RapidEye, The Space Segment, http://blackbridge.com/rapideye/about/satellites.htm (5.1.2015.).

Copernicus Land Monitoring Services, land.copernicus.eu/pan-european/corine-land-cover (5.1.2015.).

DigitalGlobe, https://browse.digitalglobe.com/imagefinder (5.1.2015.).

Digitalni model reljefa, Zagrebačka infrastruktura prostornih podataka, Gradski ured za strategijsko planiranje i razvoj grada, Zagreb, 2012.

Digitalni ortofoto 2012, Zagrebačka infrastruktura prostornih podataka, Gradski ured za strategijsko planiranje i razvoj grada, Zagreb, 2012.

Državni hidrometeorološki zavod – Klima Hrvatske – Srednje mjesečne vrijednosti, http://klima.hr/klima.php?id=k1&param=srednjak (5.1.2015.).

Državni zavod za statistiku – Popis stanovništva, kućanstava i stanova 2011. godine – Područno ustrojstvo Republike Hrvatske, http://www.dzs.hr/Hrv/censuses/census2011/results/censusterritory.htm (5.1.2015.).

Geoimage, http://www.geoimage.com.au/satellites/satellite-overview (5.1.2015.).

Grad Zagreb – Stanovništvo, kućanstva i stanovi – Popis 2011., Gradski ured za strategijsko planiranje i razvoj grada, Zagreb, 2014.

Hidrološki izvještaj – Hidrološka suša – 18. rujan 2011., Državni hidrometeorološki zavod, Zagreb, 2011.

Hrvatske šume – javni podaci, http://javni-podaci.hrsume.hr/ (5.1.2015).

HyperPhysics, http://hyperphysics.phy-astr.gsu.edu/hbase/ems3.html#c2 (5.1.2015.).

Model diferencijacije urbanih, ruralnih i prijelaznih naselja u Republici Hrvatskoj, Metodološke upute 67, Državni zavod za statistiku, Zagreb, 2011.

Odluka o granicama područja i sjedištima gradskih četvrti, Službeni glasnik Grada Zagreba, 07/09.

Odluka o osnivanju mjesnih odbora, Službeni glasnik Grada Zagreba, 07/09.

RapidEye satelitske snimke: 3360117_2011-09-16_RE1_3A_143498, 3360118_2011-09-16_RE1_3A_143498, 3360217_2011-09-16_RE1_3A_143498, 3360218_2011-09-16_RE1_3A_143498, 3360318_2011-09-16_RE1_3A_143498, BlackBridge, RapidEye, 2011.

Registar prostornih jedinica, Državna geodetska uprava, Zagreb, 2011.

Satellite imaging corporation, http://www.satimagingcorp.com/satellite-sensors/ (5.1.2015).

Službene stranice Grada Zagreba, www.zagreb.hr (5.1.2015.).

Spectral Response Curves of the RapidEye Sensor, BlackBridge, RapidEye, 2012.

Statistički ljetopis Grada Zagreba 2013., Gradski ured za strategijsko planiranje i razvoj grada, Zagreb, 2013.

PRILOG A

Popis slika

Sl. 1. Porast značenjske složenosti klasifikacije sadržaja Zemljine površine

Sl. 2. Faze širenja izgrađenih površina u Zagrebu

Sl. 3. Gustoća naseljenosti Grada Zagreba na razini mjesnih odbora prema Popisu stanovništva 2011. godine

Sl. 4. Primjeri spektralnih potpisa prikupljenih terenskim radom

Sl. 5. Središte Zagreba na RapidEye snimci – uobičajeni RGB prikaz i infracrveni pseudokolor

Sl. 6. Dijagram spektralnog odziva senzora RapidEye

Sl. 7. Primjeri ljudske izmjene reljefa: odlagalište otpada Jakuševac i kamenolom kod Sutinskih vrela

Sl. 8. Nazivi, prostorni raspored i veličina upotrijebljenih satelitskih snimaka RapidEye i granica upravne jedinice Grada Zagreba

Sl. 9. Prostorne jedinice Grada Zagreba upotrijebljene u istraživanju

Sl. 10. Detalji s referentnih snimaka upotrijebljenih u istraživanju

Sl. 11. Rasterske datoteke dobivene analizom glavnih komponenata

Sl. 12. Segmenti snimke RapidEye stvoreni algoritmom multirezolucijske segmentacije u računalnom programu eCognition, s mjerilima 75 i 30

Sl. 13. Prva dva dijela primijenjenog postupka klasifikacije na temelju skupa pravila

Sl. 14. Posljednji dio postupka klasifikacije na temelju skupa pravila

Sl.15. Usporedbe referentnih i klasificiranih podataka u ArcMap-u i Google Earth-u

Sl. 16. Trokutni dijagram V-I-S modela s podacima za gradske četvrti Grada Zagreba

Sl. 17. Karta zemljišnog pokrova Grada Zagreba

Sl. 18. Karta udjela izgrađenih površina u Gradu Zagrebu na razini prostornih jedinica naselja

Sl. 19. Binarna dazimetrijska karta gustoće naseljenosti Grada Zagreba na razini mjesnih odbora prema Popisu stanovništva 2011. godine

Sl. 20. Prizor s Malog jezera na Bundeku – složeni pseudoprirodni zemljišni pokrov

PRILOG B

Popis tablica

Tab. 1. Dio strukture tipova pokrova zemljišta prema CORINE programu

Tab. 2. Udjeli visinskih razreda u ukupnoj površini Grada Zagreba

Tab. 3. Broj stanovnika, površine i gustoće naseljenosti gradskih četvrti Grada Zagreba 2011. godine

Tab. 4. Broj stanovnika, površine i gustoće naseljenosti naselja Grada Zagreba 2011. godine

Tab. 5. Svojstva multispektralnih satelitskih sustava aktivnih 2011. godine (primjeri)

Tab .6. Model izdvajanja gradskih naselja u Hrvatskoj 1961. i 1971. godine

Tab. 7. Model izdvajanja gradskih naselja u Hrvatskoj 1981. i 1991. godine

Tab. 8. Model izdvajanja gradskih naselja u Hrvatskoj 2001. godine

Tab. 9. Popis varijabli dobivenih primjenom alata za optimizaciju prostora značajki prema pojedinim upotrijebljenim snimkama

Tab. 10. Matrica pogrešaka za klasifikaciju zemljišnog pokrova na temelju skupa pravila

Tab. 11. Usporedba udjela izgrađenih površina u naseljima Grada Zagreba s njihovim stupnjem urbanizacije prema Klempić (2008)

PRILOG C

Summary

The topic of the thesis is the object-oriented land cover classification based on computer processing and analysis of multispectral satellite imagery. Case study's area of interest is the administrative area of the City of Zagreb. Land cover classification has been carried out using RapidEye satellite imagery from 2011 in order to integrate land cover data with population data collected in Republic of Croatia's Census of Population, Households and Dwellings 2011. Three levels of total population data have been used for the research: City districts (17), Local committees (218), and Settlements (70). City districts and Local committees of the City of Zagreb are legal entities of self-government. Settlements are spatial units used for census and statistical research purposes.

The main aims of the research have been the successful performance of object-oriented classification of multispectral imagery and accurate results produced by the land cover classification. The evaluation criterion for the success of the land cover classification has been defined as the attainment of overall classification accuracy equal or more than 85 percent. Final dataset created by classification consists of four land cover classes: vegetation, impervious or built-up surfaces, bare soil, and water. Such classification scheme was based on V-I-S (vegetation – impervious surface – soil) model for urban ecosystem analysis. The V-I-S model has been applied in the land cover classification with the intention of further geographical research of apparent dichotomies of the urban versus rural, and man versus environment, or artificial versus natural.

Secondary research aims include comparison of existing geographical typologies of settlements with the land cover data acquired in the case study, and dasymetric mapping of population density of the City of Zagreb. The purpose of the former was to examine the possibilities of further development of more complex models for differentiation of urban, rural, and semi-urban settlements in Croatia. Traditional models for differentiation of settlements are based on demographic and socioeconomic variables but are deprived of suitable variables that describe the morphological and physiognomic characteristics of a settlement. The dasymetric mapping is this research has been focused on the mapping of population density restricted to the land cover class of impervious surfaces instead of total areas of administrative units. Such

thematic mapping offers more detailed insight in urban population densities as well as population distribution within urban and peri-urban areas.

The main hypothesis states that acceptable accuracy of land cover classification of multispectral satellite imagery can be achieved by using object-oriented image analysis methodology. As mentioned previously, acceptable accuracy in this research had been defined as minimum overall accuracy of 85 percent. Accuracy assessment was to be performed by means of error matrix and additional measurement of classification quality was to be observed through the Kappa statistic. Satellite and aerial imagery of higher spatial resolution were to be used as reference data for the creation of error matrix.

The second hypothesis states that the data on impervious surface area ratio could be used as an additional feature for differentiation of urban, peri-urban, and rural settlements. Geographical typologies of settlements in Croatia are often faced with problems of differentiating types of settlements that are located in the vicinity of larger cities. Impervious surface ratio could be used as a variable that describes morphological characteristics of a settlement. As a quantitative measurement such variable has a potential to improve the quality of existing models for the differentiation of settlement types.

Besides RapidEye multispectral satellite images, data used in the research include: GIS vector data on administrative and statistical spatial units of the City of Zagreb, Census 2011 data on the total population of the City of Zagreb Local committees, digital colour orthophoto imagery of City of Zagreb, and Digital Globe satellite imagery available in Google Earth.

Pre-processing of RapidEye satellite imagery was set to be minimal in order to avoid unnecessary data transformation. Remote sensing data had to be co-registered and coordinate systems had to be transformed in order to match the vector data. Principle component analysis was carried out on RapidEye imagery using ArcGIS 10.0 and the resulting raster data were to be used in the classification process. Classification was to be performed on five separate satellite image scenes that cover the area of interest.

Two types of land cover classifications were used in the research: a supervised object-oriented nearest neighbour classification and a rule-based classification. In the former type of classification an exponential membership function was applied in n-dimensional feature space in order to relate unclassified image segments to sample image segments. Such classification

resulted with fuzzy membership values assigned to each image segment or object. The latter type of classification was performed by a ruleset that is based on *a priori* knowledge as well as information derived by the examination of spatial data used in the research. Threshold values have been defined for numerous spectral and spatial object features as well as for data created by the principle components analysis. The executed ruleset has resulted with a hard or crisp classification of image segments.

Both types of classification were carried out by Trimble eCognition 9.0 and its multiresolution segmentation algorithm. Same segmentation parameters were used for both classification types, with the exception of the scale parameter. Selection of suitable object features or variables for the supervised classification relied on the use of the feature space optimization tool. Total of 11 object features were used for the classification: five texture after Haralick features, two customized arithmetic features, two standard deviation features, one ratio feature, and one vegetation index. Spatial relations of classified image objects were used to resolve the issues of unclassified data and temporary classes. Careful examination of supervised classification results showed that the differences between the land cover data in the overlapping regions of separate satellite images were far too great to continue research with such data. Therefore, that data was discarded.

The rule-based classification, similarly to supervised classification, was also based on range of statistical data on image objects, arithmetic features, vegetation indices, data acquired by principle component analysis, and spatial relations of image objects. Applied ruleset based on threshold values for selected features that result with binary membership value of image objects make the essential difference to supervised nearest neighbour classification. Initial visual inspection of classification results indicated that data produced by this method had the potential for further research.

Classification accuracy assessment was made by means of error matrix. Data for the error matrix has been collected by stratified random sampling. Overall accuracy of rule-based land cover classification assessed by the error matrix is 92.06%. Kappa statistic value of 0.89 was also calculated from the error matrix. The first hypothesis of the research has been verified by such figures.

Data on impervious surface land cover class derived from successfully performed classification has been compared with data from recent geographical typologies of settlements

in Croatia. Cross-examination of settlement types with impervious surface ratios of settlements in the City of Zagreb was made using tables and thematic maps. As expected, high values of impervious surface ratio have been measured for Zagreb (27.3%) and Sesvete (24.3%). According to existing typologies, these settlements are the only cities in the area of interest of the case study. Interestingly, certain urbanized settlements have similar or even higher impervious surface ratios. Their level of urbanization has been described as being higher or lower by the same typologies. Settlements Hrvatski Leskovac (36.2%), Veliko Polje (35.6%), Lučko (33.5%), and Buzin (24.7%) are all territorially and morphologically contiguous to the settlement Zagreb. Further research of correlation between the two datasets is hampered by the unavailability of more detailed data from the Croatian Census of Population, Households and Dwellings 2011. Nevertheless, examination of data offered by this research verifies the second hypothesis. Data on impervious surfaces of settlements adds another characteristic of settlements needed for their more detailed differentiation along the urban-rural continuum.

Land cover data on impervious surfaces was also used for the production of a thematic map of the population density of the City of Zagreb. A binary method was used for dasymetric mapping. Resulting map and data have shown higher values of population density and an improved visualization of population distribution in the area of interest.

The research resulted with the verifications of the hypotheses. Even though the high overall accuracy of classification has been achieved by object-oriented image analysis and rule-based classification of RapidEye multispectral satellite imagery, further extended research will offer the opportunities for methodological improvements which could resolve some of the issues encountered in this research. Scientific contributions made by this research are: the creation of the land cover classification ruleset and the production of the land cover map and land cover shapefiles for the area of the City of Zagreb with vegetation, impervious surfaces, bare soil, and water land cover classes. Minimum mapping unit of the land cover map is equal to the spatial resolution of used satellite imagery (5 m). Land cover map of such level of detail for the entire area of the City of Zagreb had not been published before this research. The research also proposed the use of the impervious surfaces ratio as an additional variable for the potential improvement of the existing models for the differentiation of settlement types. Scientific experience gained by this research will also help improve higher education geography studies at the Faculty of Science at the University of Zagreb.

PRILOG D

Životopis

Luka Valožić rođen je 1983. godine u Zagrebu. Diplomirao je 2007. na nastavničkom smjeru jednopredmetnog studija geografije na Geografskom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu. Upisan je na doktorski studij geografije od prosinca 2008. te je zaposlen na istom odsjeku kao znanstveni novak-asistent na projektu „Urbani sistemi u prostornom razvoju Hrvatske“. Dosad je sudjelovao u izvođenju praktičnog dijela nastave iz predmeta: Geoinformatika, Geografski informacijski sustavi, Analize u GIS-u, Vizualizacija prostornih podataka u GIS-u, Primjena računala u nastavi geografije i Daljinska istraživanja. Tijekom ljetnog semestra akademske godine 2009/10. boravio je u sklopu Erasmus programa u Njemačkoj na Institutu za geografiju Matematičko-prirodoslovnog fakulteta Sveučilišta u Potsdamu. Glavna područja djelovanja su geografski informacijski sustavi, geoinformatika i daljinska istraživanja. Specifične kompetencije uključuju georeferenciranje, obradu i analizu vektorskih i rasterskih prostornih podataka, vizualizaciju prostornih podataka, obradu i analizu multispektralnih snimaka prikupljenih putem daljinskih istraživanja. Od 2010. godine surađuje s Agencijom za odgoj i obrazovanje na državnom Natjecanju iz geografije i na stručnim skupovima za nastavnike geografije. Trenutno sudjeluje na istraživačkom projektu Croatian Rural Areas: Scenario-based Approach to Discuss Planning and Development pod vodstvom Aleksandra Lukića te uz potporu Hrvatske zaklade za znanost.

Popis objavljenih radova

Valožić, L., 2014: Klasifikacija zemljišnog pokrova urbanog i periurbanog prostora pomoću objektno orijentirane analize multispektralnih snimaka, *Hrvatski geografski glasnik*, prihvaćen za objavljivanje.

Valožić, L., Radeljak, P., Grbac Žiković, R., 2012: Prostorna analiza upisnih područja osnovnih škola u Gradu Zagrebu, *Hrvatski geografski glasnik*, 74 (2), 27-51.

Valožić, L., Cvitanović, M., 2011: Mapping the Forest Change: Using Landsat Imagery in Forest Transition Analysis within the Medvednica Protected Area, *Hrvatski geografski glasnik*, 73 (1), 245-255.