

Klasifikacija zemljишnog pokrova urbanog i periurbanog prostora pomoću objektno orijentirane analize multispektralnih snimaka

Luka Valožić

Upotrebom metode nadzirane klasifikacije primjenjuje se stečeno znanje, iskustvo i razumijevanje prostora kako bi se odabrali odgovarajući uzorci klase zemljишnog pokrova koji će usmjeriti algoritme računalnog programa na podjelu svih elemenata slike u zadani broj imenovanih razreda. Algoritmom multirezolucijske segmentacije koji uzima u obzir spektralna i geometrijska svojstva slike, satelitska se snimka prema zadanim parametrima dijeli u određeni broj homogenih skupina piksela. Na taj način stvoreni segmenti ili objekti slike upotrebljavaju se umjesto pojedinih piksela kao jedinice uzoraka klase zemljишnog pokrova. Za provjeru točnosti klasifikacije i izradu matrice pogrešaka koriste se prostorno nasumično raspoređeni uzorci referentnih i klasificiranih podataka stratificirani prema unaprijed definiranim klasama zemljишnog pokrova.

Na 32. međunarodnom geografskom kongresu održanom 2012. u Kölnu u Njemačkoj rad je predstavljen pod naslovom *Object-based LULC classification of urban and peri-urban areas*.

Ključne riječi: zemljinski pokrov, satelitske snimke, metoda nadzirane klasifikacije, segmentacija slike, matrica pogrešaka, V-I-S model

Land Cover Classification of Urban and Peri-urban Areas Using Object-oriented Analysis of Multispectral Imagery

Supervised classification of remote sensing imagery implies usage of *a priori* knowledge of analysed area of interest for proper selection of land cover classes' samples. Spectral and geometric properties of the satellite image were taken into account by parameters of the multiresolution segmentation algorithm that has been used to divide the selected subset of the scene into homogeneous groups of pixels. Such image segments were used as land cover samples for supervised classification. Accuracy assessment was performed by means of error matrix based on stratified random samples.

Key words: land cover, satellite images, method of supervised classification, image segmentation, error matrix, V-I-S model

Uvod

Za geografiju su, daljinska istraživanja prije svega bogat i izvrstan izvor podataka. Velika većina sustava za daljinska istraživanja usmjeren je na prikupljanje podataka sa Zemljine površine i zato privlače pozornost brojnih geografa i ostalih znanstvenika koji u svojem radu upotrebljavaju prostorne podatke (Donnay i dr., 2001; Rashed i Jürgens, 2010; Yang, 2011). Osim prikupljanja zapisa uglavnom reflektiranog elektromagnetskog zračenja s određene udaljenosti, daljinska istraživanja također podrazumijevaju mnogobrojne složene metode njihove obrade, interpretacije, analize i vizualizacije (Campbell i Wynne, 2011; Richards i Jia, 2006; Lillesand i dr., 2004). Metodologija daljinskih istraživanja sve se intenzivnije povezuje sa znanjima i vještinama iz drugih znanstvenih disciplina, među kojima je i geografija. U radu je predstavljen primjer nadzirane klasifikacije zemljишnog pokrova urbanog i periurbanog prostora prikazanih na multispektralnim satelitskim snimkama. Objekti stvoreni segmentacijom satelitske snimke u računalnom programu Definiens Professional 5 poslužili su, umjesto zasebnih piksela, kao temeljne jedinice klasifikacije. Cilj je rada ispitivanje ukupne točnosti klasifikacije zemljишnog pokrova, a prepostavka je mogućnost postizanja točnosti koja je veća od 85% (Anderson, 1971), odnosno što veće poklapanje podataka dobivenih klasifikacijom s referentnim podacima. Rezultat klasifikacije tematska je karta zemljишnog pokrova. Svrha je rada usmjeriti pozornost na spomenute izvore podataka, metode i alate njihove obrade, analize i provjere točnosti.

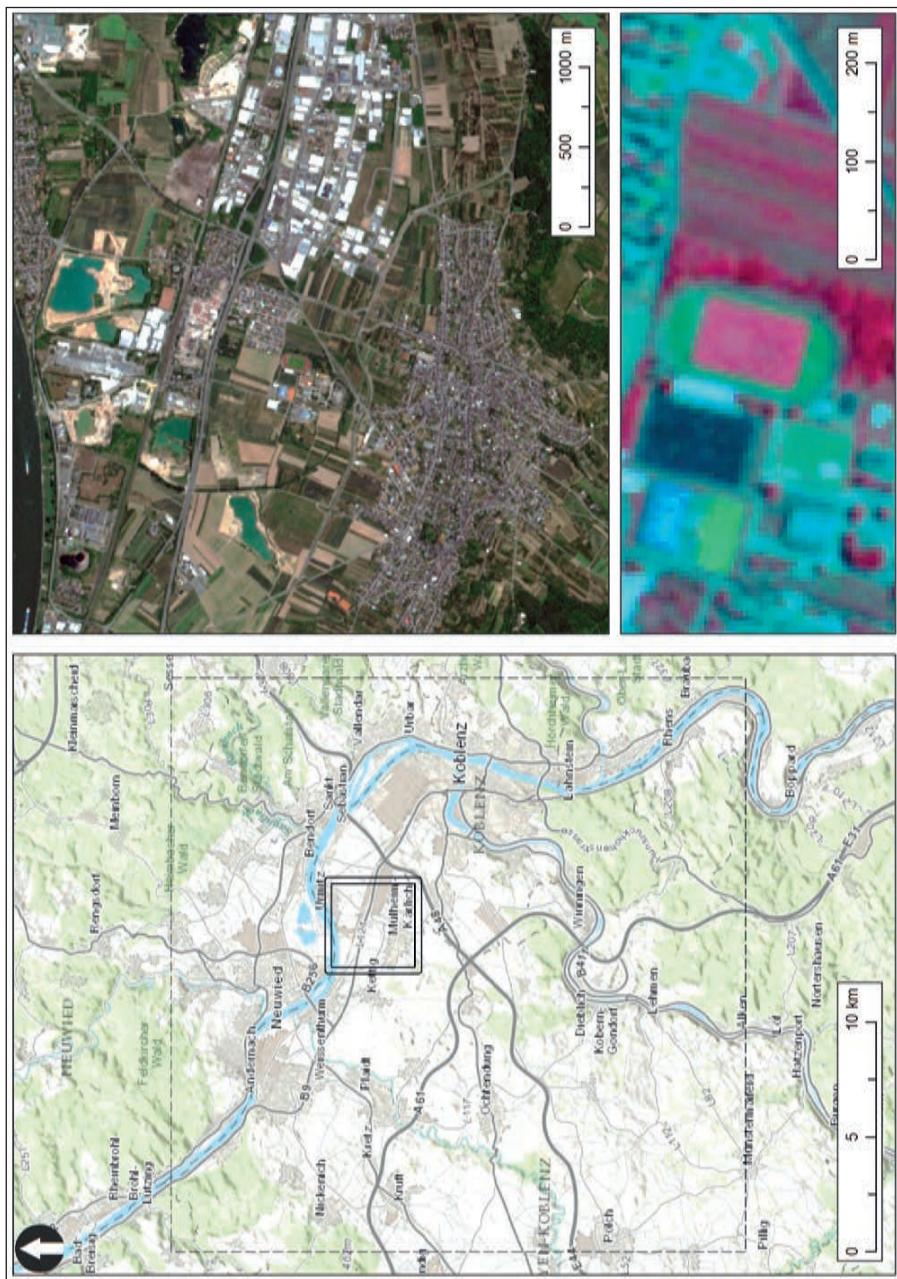
Podaci

Podaci upotrijebljeni kao temelj ovog istraživanja prikupljeni su satelitskim sustavom tvrtke BlackBridge RapidEye. Klasifikacija je provedena na multispektralnim snimkama koje su dostupne na internetu kao besplatni uzorci za registrirane korisnike. Pet kanala snimke RapidEye radi lakšeg poimanja predstavljeno je 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 u upotrijebljenoj preuzorkovanoj ortorektificiranoj snimci (kategorija 3A) jest pet metara. Podaci isporučeni u takvim snimkama su 16-bitni, cijelih brojeva bez predznaka. Veličina slike jest 5000 puta 5000 piksela, a na njoj je prikazano područje površine 625 km^2 (RapidEye, 2011).

Prostor zabilježen na snimci u potpunosti se nalazi unutar njemačke savezne pokrajine Rheinland-Pfalz, a najznačajnije je naselje obuhvaćeno snimkom grad Koblenz. Satelitska snimka nastala je 2. lipnja 2011. Za potrebe ovog rada napravljen je manji isječak izvorne snimke veličine 781 puta 781 piksel. Unutar njega obuhvaćeno je manje područje sjeverozapadno od grada Koblenza površine oko 15 km^2 . Odabrani dio snimke prikazuje urbani i periurbani prostor (Gallent i dr., 2006) za koji se temeljem inicijalne vizualne interpretacije prepostavlja da sadržava sve klase ili razrede zemljишnog pokrova u koje su klasificirani vektori piksela digitalnih snimaka u ovom radu.

Za referentne podatke, odnosno podatke pomoću kojih se provjerava točnost provedene klasifikacije zemljишnog pokrova upotrijebljene su satelitske snimke dostupne putem računalnog programa Google Earth. Za ovaj rad bitno je da su referentni podaci veće prostorne rezolucije ili razlučivosti od obrađene satelitske snimke RapidEye te da

Klasifikacija zemljišnog pokrova urbanog i periurbanog prostora pomoću objektno orijentirane analize multispektralnih snimaka



Sl. 1. Karta područja koje je zabilježeno na satelitskim snimkama i na odabranoj manjem isječku, prikaz obradjenog isječka satelitskih snimaka i detalj prikazan tzv. lažnim sastavljanjem boja (bliski infracrveni, crveni i zeleni kanal) Izvor: ESRI, RapidEye

Fig. 1 Map depicting dimensions and locations of the RapidEye image tile and the land cover classification area and the land cover composite image Source: ESRI, RapidEye

se s njom što bolje vremenski podudaraju kako bi zamijenili terenski rad i provjeru stanja zemljišnog pokrova u stvarnome geografskom prostoru. Prilikom upotrebe 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 dobivenih izradom matrice pogrešaka (Congalton i Green, 2009). Među arhivskim snimkama s Google Eartha ili tzv. povijesnim slikama odabrana je snimka prostorne rezolucije 0,49 metara snimljena 22. travnja 2010. pomoću satelita GeoEye-1 (DigitalGlobe, 2014). Zbog toga što je vremenski najbliskija klasificiranoj snimci te zbog njezine visoke prostorne razlučivosti, upravo je ta snimka poslužila za referentne podatke prilikom izrade matrice pogrešaka.

Metodologija

Kao što je prethodno spomenuto, iz originalne snimke koja predstavlja površinu 625 km^2 odabran je manji isječak površine oko 15 km^2 koji sadržava tražene zemljišne pokrove urbanog i periurbanog prostora. Takav podskup podataka prvo je segmentiran pomoću algoritma dostupnog u računalnom programu Definiens Professional 5, nazvanog multirezolucijska segmentacija, koji pristupom odozdo prema gore spaja zasebne piksele u regije (Benz i dr., 2004; Trimble, 2014). 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 stvarnoga geografskog prostora bez razlamanja u manje dijelove ili pojedine piksele. S druge strane, klasifikacija zemljišnog pokrova bila bi znatno otežana ako bi se u pojedinim objektima nalazio previše heterogen prostor, odnosno ako bi oni objedinjavali suviše različite piksele. Parametri kojima se upravlja segmentacijom unutar spomenutoga računalnog programa odnose se na raspon vrijednosti kojima se određuju heterogenost objekata te omjeri pomoću kojih se utječe na važnost spektralnih svojstava ili morfologiju prilikom izdvajanja objekata. Povećanjem vrijednosti tzv. mjerila segmentacije (engl. *scale*) slika se dijeli na sve manji broj većih objekata. Ako ta slika, poput ovdje obrađene sate-litske snimke, predstavlja Zemljinu površinu, onda to znači podjelu prostora u manji broj površinom većih i relativno heterogenih područja. Podešavanjem omjera između tzv. boje (engl. *color*) i oblika (engl. *shape*) daje se manja ili veća važnost spektralnim svojstvima piksela. Na kompaktnost (engl. *compactness*) ili glatkoću (engl. *smoothness*) segmentirana, odnosno njihovih granica također se može utjecati odabirom posebnog parametra (Navulur, 2007). Istraživanje načina na koji pojedine vrijednosti mjerila segmentacije utječu na podjelu odabranog isječka satelitske snimke rezultiralo je odabirom vrijednosti mjerila, koja za potrebe klasifikacije opisane u ovom radu iznosi 15. Kako bi se što veća važnost prilikom segmentacije dala spektralnim svojstvima piksela i na taj način iskoristili podaci dobiveni multispektralnim snimanjem Zemljine površine, tzv. boji dodijeljena je najveća moguća vrijednost od 0,9 u odnosu na oblik, koji je u skladu s tim dobio vrijednost 0,1. Za parametar kompaktnosti ili glatkoće određena je vrijednost 0,5, čime se postiže ravnoteža između te dvije krajnosti. Takav postupak segmentacije rezultirao je stvaranjem 241.408 objekata, što je 2,5 puta manje od broja piksela koji čine analiziranu scenu. Objekti nastali na spomenuti način poslužili su kao temelj za daljnju klasifikaciju zemljišnog pokrova.

Upotrijebljeni softver nudi razne mogućnosti upotrebe brojnih spektralnih, oblikovnih, hijerarhijskih te ostalih svojstava ili karakteristika objekata. Dinamičnim, usporednim i jednostavnim pregledom svojstava objekata unutar računalnog programa Definiens Professional 5 mogu se istražiti sličnosti i različitosti zemljišnih pokrova te na taj način pronaći odgovarajući postupak za njihovu diferencijaciju te u konačnici klasifikaciju. Za ovu klasifikaciju upotrijebljene su srednje vrijednosti svih pet kanala satelitske snimke RapidEye te dodatne značajke svjetline (engl. *brightness*) i najveće apsolutne razlike (engl. *maximum difference*, skraćeno *MaxDiff*) (Myint i Stow, 2011). Svjetlina objekata izračunava se iz vrijednosti intenziteta unaprijed određenih slojeva ili kanala snimke, dok se najveće razlike izračunavaju prema formuli koja uzima u obzir srednje vrijednosti intenziteta kanala snimke pojedinih objekata i vrijednosti njihove svjetline (Trimble, 2014).

$$\bar{c}(v) = \frac{1}{w^B} \sum_{k=1}^K w_k^B \bar{c}_k(v)$$

w_k^B težinski udio svjetline sloja (slike) k s $w_k^B = \begin{cases} 0 \\ 1 \end{cases}$

K broj slojeva k upotrijebljenih za izračun

w^B zbroj težinskih udjela svjetline svih slojeva k upotrijebljenih za izračun

$$w^B = \sum_{k=1}^K w_k^B$$

$\bar{c}_k(v)$ srednja vrijednost intenziteta sloja k objekta v

$$MaxDiff = \frac{\max_{i,j \in K_B} |\bar{c}_i(v) - \bar{c}_j(v)|}{\bar{c}(v)}$$

i, j slojevi slike

$\bar{c}(v)$ svjetlina objekta (slike) v

$\bar{c}_i(v)$ srednja vrijednost intenziteta sloja i objekta v

$\bar{c}_j(v)$ srednja vrijednost intenziteta sloja j objekta v

K_B slojevi slike pozitivnog težinskog udjela svjetline s $K_B = \{k \in K : w_k = 1\}$ pri čemu je w_k težinski udio sloja slike

Nadzirana klasifikacija zemljišnog pokrova zahtjeva aktivnu ulogu ljudskog interpretatora scene i podrazumijeva upotrebu njegovih znanja, iskustva ili razumijevanja promatranog prostora. Svesnim odabirom pojedinih dijelova slike i određivanjem njihove klase korisnik nastoji usmjeriti računalo na daljnju klasifikaciju cijele satelitske snimke (Richards i Jia, 2006). Različite kombinacije tzv. pseudokolora ili lažnog sastavljanja boja (engl. *false colour composite*) u RGB modelu slike (npr. IC, crveni i zeleni kanal) pomazuju u prepoznavanju i odabiru uzorka koji jasno predstavljaju željene klase zemljišnog pokrova. Objekti stvoreni segmentacijom multispektralne satelitske snimke poslužili su kao jedinice uzorka zemljišnih pokrova.

Za potrebe ovog rada cjelokupni zemljavični pokrov sveden je na pet klasa: vegetaciju, izgrađene ili nepropusne površine, tlo, vodu te sjene. Takav odabir temeljen je na proširenom V-I-S modelu (engl. *Vegetation – Impervious surface – Soil*) klasifikacije zemljavičnog pokrova čije su glavne prednosti jednostavnost i primjenjivost u različitim prostorima radi njihove međusobne usporedbe ili u različitim vremenima (trenucima) radi praćenja promjena jednoga promatranog prostora (Ridd, 1995; Gluch i Ridd, 2010). Ovisno o prosudbi interpretatora snimke, klasa sjena naknadno se može pridružiti nekoj od ostalih klasa zemljavičnog pokrova poput izgrađenih površina. Ukupno je 155 segmenata satelitske snimke odabrano za uzorke koji predstavljaju spomenutih pet klasa zemljavičnog pokrova.

Odabrani uzorci klasa i njihove značajke ulazni su podaci za algoritam najbližih susjeda (engl. *nearest neighbour*) pomoću kojeg se u upotrijebljenom softveru može provesti nadzirana klasifikacija. Prema tom algoritmu, objekti ili pikseli neke slike klasificiraju se prema najbližem uzorku u prostoru značajki (engl. *feature space*) ili n-dimenzionalnom prostoru (Landgrebe, 2003; Richards i Jia, 2006; Campbell i Wynne, 2011). Unutar upotrijebljenoga računalnog programa prije postupka ovog tipa klasifikacije moguće je odrediti dva parametra koja utječu na pripadnost pojedinog objekta nekoj klasi. Korisnik može unijeti vrijednost kojom se utječe na rast (engl. *function slope*) funkcije pripadnosti (engl. *membership function*), a samim time i na mogućnost zahvaćanja nekog objekta u određenu klasu. Drugi je parametar minimalna vrijednost pripadnosti (eng. *membership value*) koja predstavlja prag između klasifikacije objekta u neku od zadanih klasa i označivanja objekta kao neklasificiranoga (Trimble, 2014). Upotrijebljene su softverski zadane postavke: 0,2 za varijablu rasta funkcije te 0,1 za minimalnu vrijednost pripadnosti. Tim postupkom svaki objekt dobiva vrijednosti između 0 i 1 koje upućuju na stupanj pripadnosti svakoj od klasa prema teoriji neizrazitih skupova (Zadeh, 1965). Na temelju najviše izračunate vrijednosti objektu se pripisuje određena klasa zemljavičnog pokrova.

Rezultat klasifikacije rasterska je datoteka čije su celije podijeljene u pet klasa zemljavičnog pokrova. Prije izrade tematske karte podaci su generalizirani u računalnom programu ArcGIS Desktop 10 pomoću većinskog filtra veličine 3 puta 3 piksela. Pomoću tog alata manji objekti, neki veličine samo jednog piksela, pridruženi su prevladavajućim susjednim klasama zemljavičnog pokrova.

Točnost klasifikacije izražena je pomoću parametara matrice pogrešaka ili konfuzije (Story i Congalton, 1986; Congalton i Green, 2009). Na temelju novog skupa uzoraka uspoređeni su rezultati klasifikacije s referentnim podacima. Za izradu skupa uzoraka i njihovo uspoređivanje s podacima dostupnih putem Google Earth-a upotrijebljen je ArcGIS Desktop 10. Stvoren je skup nasumičnih stratificiranih uzoraka kojima su dodijeljene vrijednosti iz tematske karte nastale klasifikacijom. Računalu je zadano stvaranje 50 točaka nasumičnih koordinata za svaku od klasa zemljavičnog pokrova uz dodatni uvjet da točke ne smiju biti na međusobnoj udaljenosti manjoj od 20 metara. Navedena udaljenost upotrijebljena je kako se uzorci ne bi nalazili preblizu, također uzimajući u obzir prostornu razlučivost izvornih snimaka koja iznosi 5 metara. Na taj je način stvoreno 210 točaka, pri čemu treba naglasiti da je za klasu sjena stvoren samo 10 točaka jer je ona na tematskoj karti zastupljena malom površinom u odnosu na ostale klasе (vegetaciju, izgrađene površine, tlo i vodu).

Rezultati i diskusija

Prema matrici pogrešaka (tab. 1) ukupna točnost klasifikacije jest 93,3% i takva vrijednost može dovesti do zaključka kako se primjenom navedenih metoda i podataka ostvaruje vrlo dobar rezultat. Pregledom proizvodne (engl. *producer's accuracy*) i korisničke (engl. *user's accuracy*) točnosti može se detaljnije proučiti uspješnost klasifikacije (Story i Congalton, 1986). U ovom radu može se vidjeti da je primjerice klasificiranje površina u sjeni u odnosu na vodene površine donekle problematično. Prema uspoređenim uzorcima, 100% sjena uspješno je klasificirano kao sjena, ali su zato u samo 50% slučajeva sjene s tematske karte zaista bile sjene prema klasama interpretiranim s referentne snimke – ostatak se odnosio na vodene površine. S druge strane, vegetacija je vrlo dobro klasificirana, s točnostima 96,08% i 98%. Valja uzeti u obzir da prema tematskoj karti izrađenoj u ovom radu, vegetacija pokriva 59,28% površine i da je za tu klasu obradeno 50 uzoraka, dok sjene pokrivaju 0,14% površine i za njih je u matrici pogrešaka obrađeno 10 uzoraka (tab. 2).

Zbog pretpostavke da bi se i posve slučajnim određivanjem klase mogla postići određena točnost klasifikacije, provedena je kapa-analiza, odnosno izračunat je kapa-koefficijent koji predstavlja mjeru točnosti klasifikacije umanjenu za slučajna točna poklapanja podataka. Tim koeficijentom može se dodatno procijeniti kvaliteta klasifikacije. Na temelju ovdje izrađene matrice pogrešaka procijenjena je vrijednost kapa-koefficijenta 0,91, što je relativno visoka vrijednost koja znači jaku pozitivnu korelaciju, odnosno upućuje na jako poklapanje klasificiranih s referentnim podacima (Landis i Koch, 1977; Congalton i Green, 2009).

Tab. 1. Matrica pogrešaka

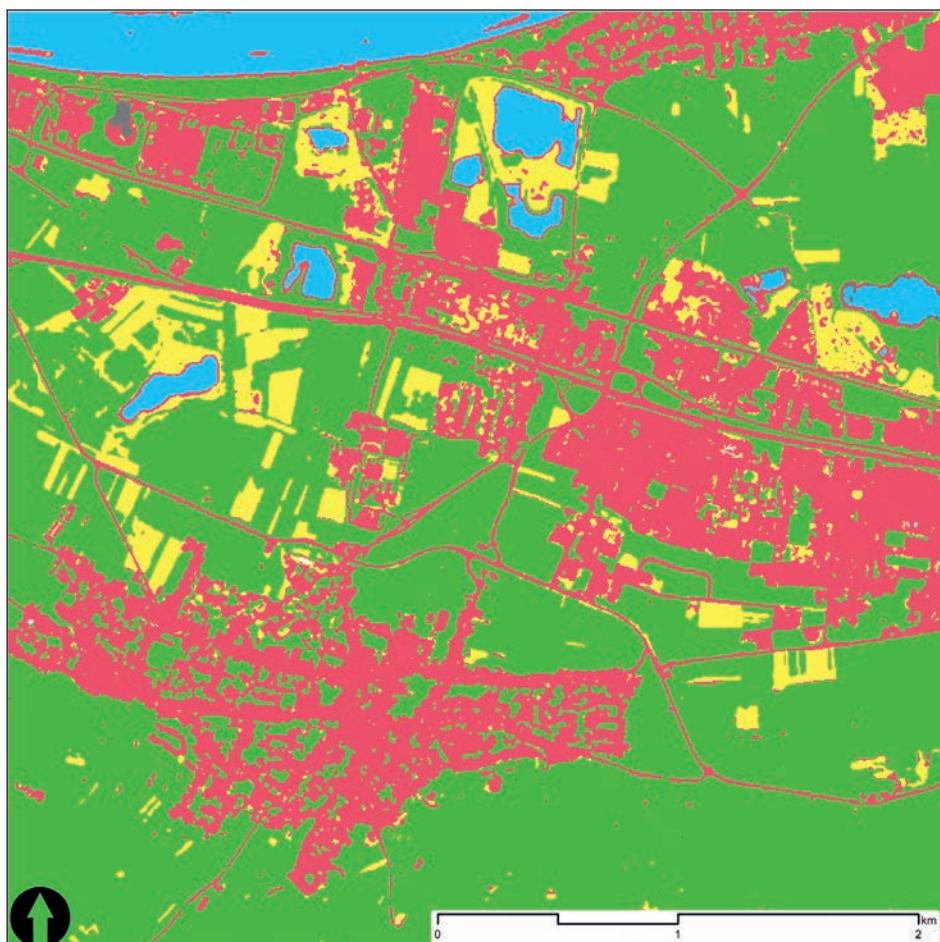
Tab. 1 Error matrix

		Referentni podaci					Korisnička točnost (%)
Klasificirani podaci	IZGRAD.	48	1	1	0	0	
	TLO	5	44	1	0	0	50
	VEGET.	0	1	49	0	0	50
	VODA	0	0	0	50	0	50
	SJENE	0	0	0	5	5	10
	UKUPNO	53	46	51	55	5	210

90,57	95,65	96,08	90,91	100	93,33
Proizvodna točnost (%)					Ukupna točnost (%)

Tab. 2. Zastupljenost klasa zemljišnog pokrova prema površinama
 Tab. 2 Land cover classes by area

KLASA	Površina (ha)	Površina udio (%)
Izgrađene površine	433,49	28,43
Sjene	2,08	0,14
Tlo	113,66	7,45
Neklasificirano	0,27	0,02
Vegetacija	904,02	59,28
Voda	71,38	4,68
UKUPNO	1524,90	100,00



Sl. 2. Tematska karta zemljišnog pokrova (zeleno = vegetacija, crveno = izgrađene površine, žuto = tlo, plavo = voda, sivo = sjene)

Fig. 2 Thematic map of land cover classes (green = vegetation, red = built-up, yellow = soil, blue = water, gray = shadows)

Osim točnosti ustanovljene pomoću matrice pogrešaka, uspešnost određene klasifikacije dodatno se može istražiti usporedbom rezultata različitih klasifikacija s izmjenjivim značajkama, parametrima ili cijelokupnom metodologijom rada. U upotrijebljenu softveru postoje još brojne značajke koje se mogu upotrijebiti za razdvajanje objekata u različite klase, a veliki potencijal leži u segmentaciji snimaka u više razina čiji su objekti povezani u hijerarhijsku mrežu (Benz i dr., 2004).

Klasifikacija korištenja zemljišta (engl. *land use*) na temelju podataka o zemljišnom pokrovu moguća je uz upotrebu dodatnih izvora podataka (Mesev, 2010). Iz prostornog rasporeda i geometrijskih obilježja pojedinih klasa analiziraju se primjerice morfologija naselja ili ostalih sastavnica krajolika, primjenjive u urbanoj i ruralnoj geografiji (Longley i Mesev, 2001). Podaci o zemljišnom pokrovu mogli bi se upotrijebiti za daljnju podjelu prostora u kategorije urbanoga, periurbanoga ili ruralnoga. Uzimanjem navedenoga u obzir moguće je razvoj novih modela diferencijacije urbanih, ruralnih i prijelaznih naselja (DZS, 2011). Na temelju usporedbe rezultata klasifikacija zemljišnog pokrova više vremenskih (povijesnih) trenutaka prate se promjene u prostoru te se može ustanoviti intenzitet tih promjena izražen konkretnim vrijednostima (Valožić i Cvitanović, 2011). Upotrijebljeni V-I-S model mjerena zastupljenosti triju glavnih klasa urbanog prostora iznimno je primjenjiv u istraživanjima promjena okoliša (Gluch i Ridd, 2010). Navedene mogućnosti znanstvenih istraživanja te primjene metoda i podataka samo su neke od mnogih omogućenih interdisciplinarnim radom u geografiji i daljinskim istraživanjima.

Zaključak

Opisano istraživanje predstavlja dio mogućnosti klasifikacije zemljišnog pokrova zasnovane na objektno orijentiranoj analizi multispektralnih satelitskih snimaka koje prikazuju urbani i periurbani prostor. Iako se na temelju vrijednosti dobivenih provjerom točnosti izvedene klasifikacije može zaključiti da je postignut vrlo dobar rezultat u obliku tematske karte zemljišnog pokrova, treba napomenuti kako je primijenjen samo jedan sustav parametara i postavki, od mnoštva dostupnih u računalnom programu eCognition, na razmjerno jednostavnom modelu podjele prostora u pet klasa pokrova. Daljnje istraživanje parametara segmentacije i varijabli za klasifikaciju trebalo bi omogućiti optimizaciju i djelomičnu automatizaciju cijelokupnog postupka. Optimizacija bi osim povećanja točnosti klasifikacije trebala omogućiti i složeniju klasifikacijsku shemu, no pretpostavlja se da bi za povećanje broja klasa trebalo primijeniti dodatne izvore podataka. Glavna prednost V-I-S modela upotrijebljenog u ovom istraživanju je njegova primjenjivost u usporedbi urbanog, periurbanog i ruralnog prostora geografski vrlo različitih područja, odnosno krajolika s različitim klimatskim, vegetacijskim i kulturnim obilježjima. Model se također upotrebljava za zorno prikazivanje intenziteta promjena u prostoru iskazanih omjerima njegovih sastavnica: vegetacije, izgrađenih površina i tala. Podaci proizlazi iz postupka klasifikacije zemljišnog pokrova primjenjuju se u geografiji kao temelj za inventarizaciju, deskripciju ili daljnju analizu zadanog prostora istraživanja. Apsolutne vrijednosti površina klasa ili njihovi udjeli unutar definiranih područja polazišna su točka za proučavanje stanja u prostoru.

LITERATURA

- Anderson, J. R., 1971: Land use classification schemes used in selected recent geographic applications of remote sensing, *Photogrammetric Engineering*, 37 (4), 379-387.
- 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.
- Campbell, J. B., Wynne, R. H., 2011: *Introduction to remote sensing*, The Guilford Press, New York, London.
- Congalton, R. G., Green, K., 2009: *Assessing the accuracy of remotely sensed data: principles and practices*, CRC Press, Boca Raton, London, New York.
- Donnay, J.-P., Barnsley, M. J., Longley, P. A., 2001: *Remote Sensing and Urban Analysis*, Taylor & Francis, London, New York.
- Gallent, N., Andersson, J., Bianconi, M., 2006: *Planning on the Edge: The context for planning at the rural-urban fringe*, Routledge, Abingdon, New York.
- Gluch, R. M., Ridd, M. K., 2010: The V-I-S Model: Quantifying the Urban Environment, in: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10* (eds. Rashed, T., Jürgens, C.), Springer, Dordrecht, Heidelberg, London, New York, 85-116.
- Landgrebe, D. A., 2003: *Signal Theory Methods in Multispectral Remote Sensing*, John Wiley & Sons, Hoboken.
- Landis, J., Koch, G., 1977: The measurement of observer agreement for categorical data, *Biometrics*, 33, 159-174.
- Lillesand, T. A., Kiefer, R. W., Chipman, J. W., 2004: *Remote Sensing and Image Interpretation*, John Wiley & Sons, Hoboken.
- Longley, P. A., Mesev, V., 2001: Measuring Urban Morphology using Remotely-Sensed Imagery, in: *Remote Sensing and Urban Analysis*, (eds. Donnay, J.-P., Barnsley, M. J., Longley, P. A.) Taylor & Francis, London, New York, 148-168.
- Mesev, V., 2010: Classification of Urban Areas: Inferring Land Use from the Interpretation of Land Cover, in: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10* (eds. Rashed, T., Jürgens, C.), Springer, Dordrecht, Heidelberg, London, New York, 141-164.
- Myint, S. W., Stow, D., 2011: An object-oriented pattern recognition approach for urban classification, in: *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment*, (eds. Yang, X.), John Wiley & Sons, Chichester, Oxford, Hoboken, 129-140.
- Navulur, K., 2007: *Multispectral image analysis using the object-oriented paradigm*, CRC Press, Boca Raton, London, New York.
- Rashed, T., Jürgens, C., 2010: *Remote Sensing of Urban and Suburban Areas, Remote Sensing and Digital Image Processing 10*, Springer, Dordrecht, Heidelberg, London, New York.
- Richards, J. A., Jia, X., 2006: *Remote Sensing Digital Image Analysis*, Springer, Berlin, Heidelberg.
- Ridd, M. K., 1995: Exploring a V-I-S (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.
- Story, M., Congalton, R., 1986: Accuracy assessment: A user's perspective, *Photogrammetric Engineering and Remote Sensing* 52 (3), 397-399.
- 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), 273-283.
- Yang, X., 2011: *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment*, John Wiley & Sons, Chichester, Oxford, Hoboken.

IZVORI

DigitalGlobe Catalog, [https://browse.digitalglobe.com/imagefinder/catalogListDisplay.
do?noCache=1412888627956](https://browse.digitalglobe.com/imagefinder/catalogListDisplay.do?noCache=1412888627956) (9. 10. 2014.).

ESRI ArcGIS World Topo Map (ArcGIS Desktop/Explorer URL), [http://services.arcgisonline.com/arcgis/
services](http://services.arcgisonline.com/arcgis/services) (9. 10. 2014.).

Model diferencijacije urbanih, ruralnih i prijelaznih naselja u Republici Hrvatskoj, Metodološke upute 67,
DZS, Zagreb, 2011.

RapidEye, Free Sample Data, <http://www.blackbridge.com/rapideye/myrapideye/myre.php> (9. 10. 2014.)

Trimble Documentation, 2014: eCognition Developer 9.0 User Guide, Trimble Germany, München

SUMMARY

Land Cover Classification of Urban and Peri-urban Areas Using Object-oriented Analysis of Multispectral Imagery

Luka Valožić

This article presents a case of land cover classification of urban and peri-urban areas. The main goal was to achieve high classification accuracy. Classification was based on the V-I-S model for urban ecosystem analysis with its three main land cover classes: vegetation, impervious surfaces, and soil, with the addition of two classes for water surfaces and shadows. RapidEye multispectral satellite image featuring part of Rheinland-Pfalz was used for classification. The GeoEye-1 satellite image available through Google Earth was used as the reference image. Image segmentation and supervised classification were performed in Definiens Professional 5, and tools from ArcGIS Desktop 10 were used for data generalization and stratified random sampling. Image segments or object-primitives were used as training sample units for supervised classification instead of individual pixels. Mean values of all five image bands as well as brightness and maximum difference were used as features for fuzzy nearest neighbour classification algorithm that assigns class membership values to each of image objects. Highest values determined the final objects' classes. A majority filter was applied to resulting raster image in order to generalize it by merging smaller image objects with more dominant neighbouring objects. Classification accuracy was assessed by error matrix and kappa statistic. Overall accuracy (93 %) and kappa coefficient (0.91) indicate that a relatively accurate and successful classification of land cover was performed.

Primljeno (Received): 12-10-2014

Prihvaćeno (Accepted): 27-11-2014

Luka Valožić, prof. geogr.
Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek
Marulićev trg 19/II, 10 000 Zagreb
lvalozic@geog.pmf.hr