

USPOREDBA GEOBIA KLASIFIKACIJSKIH ALGORITAMA NA TEMELJU WORLDVIEW-3 SNIMAKA U IZDVAJANJU ŠUMA PRIMORSKIH ČETINJAČA

COMPARISON OF GEOBIA CLASSIFICATION ALGORITHMS BASED ON WORLDVIEW-3 IMAGERY IN THE EXTRACTION OF COASTAL CONIFEROUS FOREST

Lovre PANĐA¹, Ante ŠILJEG², Ivan MARIĆ³, Fran DOMAZETOVIĆ⁴, Silvija ŠILJEG⁵, Rina MILOŠEVIĆ⁶

SUMMARY

Šume primorskih četinjača, sa svojom ekološkom, ekonomskom, estetskom i društvenom funkcijom, predstavljaju važan dio europskih šumske zajednice. Osnovni cilj ovoga rada je usporediti najkorištenije GEOBIA (engl. *Geographic Object-Based Image Analysis*) klasifikacijske algoritme (engl. *Random Trees – RT*, *Maximum Likelihood – ML*, *Support Vector Machine – SVM*) s ciljem izdvajanja šuma primorskih četinjača na visoko-rezolucijskom *WorldView-3* snimku unutar topografskog slijevnog područja naselja Split. Metodološki okvir istraživanja uključuje (1) izvođenje izoštrenog multispektralnog snimka ($WV-3_{MS}$ -a); (2) testiranje segmentacijskih korisničko-definiranih parametara; (3) dodavanje testnih uzoraka; (4) klasifikaciju segmentiranog modela; (5) procjenu točnosti klasifikacijskih algoritama, te (6) procjenu točnosti završnog modela. RT se prema korištenim pokazateljima (*correctness – COR*, *completeness – COM* i *overall quality – OQ*) pokazao kao najbolji algoritam. Iterativno postavljanje segmentacijskih parametara omogućilo je detekciju najprikladnijih vrijednosti za generiranje segmentacijskog modela. Utvrđeno je da sjene mogu uzrokovati značajne probleme ako se klasificiranje vrši na visoko-rezolucijskim snimkama. Modificiranim *Cohen's kappa coefficient* (K) pokazateljem izračunata je točnost konačnog modela od 87,38%. $WV-3_{MS}$ se može smatrati kvalitetnim podatkom za detekciju šuma primorskih četinjača primjenom GEOBIA metode.

KLJUČNE RIJEČI: GEOBIA, WorldView-3, šuma primorskih četinjača, Random Trees, Maximum Likelihood, Support Vector Machine.

UVOD INTRODUCTION

Šume primorskih četinjača važan su dio europskih šumske zajednice s izrazitom ekološkom i socijalnom ulogom (Pernek i dr., 2012). Najčešće predstavljaju umjetno podignute nasade koji imaju protuerozijsku, hidrološku i vodozaštitnu

funkciju (Matić i dr., 2005; Pernek i dr., 2012). Šume primorskih četinjača priobalnog područja Hrvatske većinom sačinjavaju: alepski bor, dalmatinski crni bor, primorski bor, pinija, čempres, brucijski bor, himalajski cedar, libanonski cedar i dr. (Martinić i dr., 2008; Pernek i dr., 2012; Vrbek i dr., 2013; Šiljković i Mamut, 2016). Mnoge od ovih vrsta su

¹ Lovre Panda, mag. geogr., Sveučilište u Zadru, Odjel za geografiju, Trg kneza Višeslava 9, Zadar, lpanda@unizd.hr

² Izv. prof. dr. sc. Ante Šiljeg, Sveučilište u Zadru, Odjel za geografiju, Trg kneza Višeslava 9, Zadar, asiljeg@unizd.hr

³ Doc. dr. sc. Ivan Marić, Sveučilište u Zadru, Odjel za geografiju, Trg kneza Višeslava 9, Zadar, imaric1@unizd.hr

⁴ Dr. sc. Fran Domazetović, mag. geogr., Sveučilište u Zadru, Odjel za geografiju, Trg kneza Višeslava 9, Zadar, fdomazet@unizd.hr

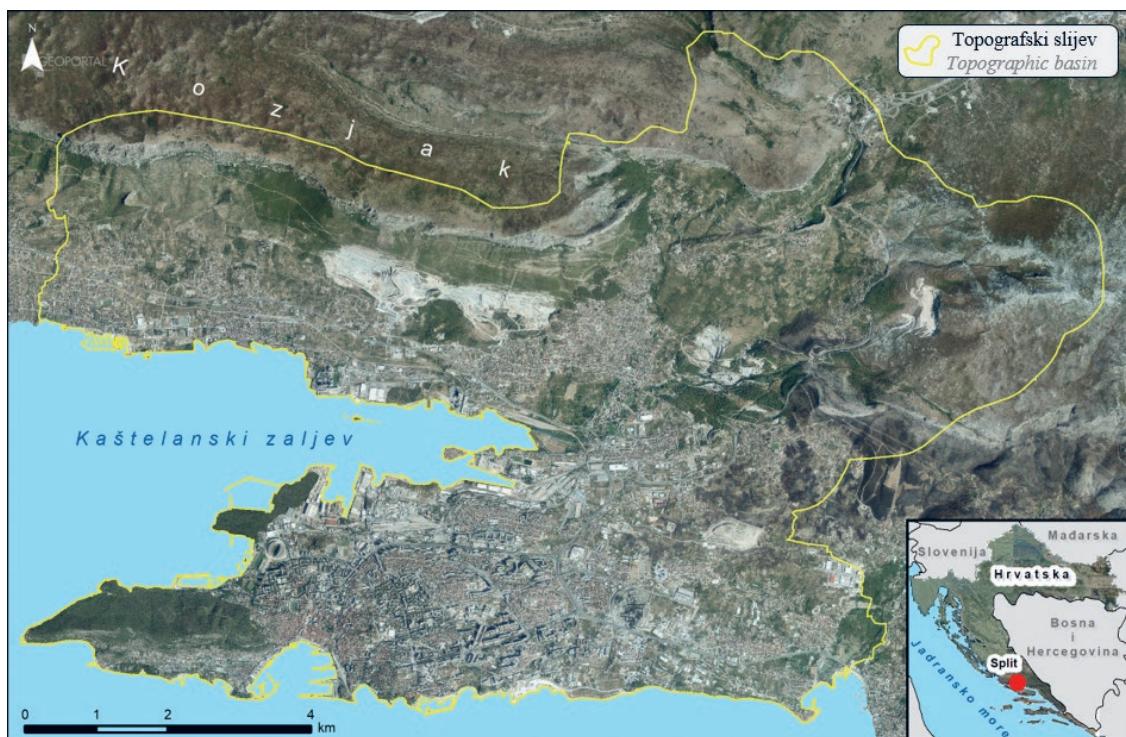
⁵ Doc. dr. sc. Silvija Šiljeg, Sveučilište u Zadru, Odjel za geografiju, Trg kneza Višeslava 9, Zadar, ssiljeg@unizd.hr

⁶ Rina Milošević, mag. geogr., Sveučilište u Zadru, Ured za znanost, projekte i transfer tehnologija, Trg kneza Višeslava 9, Zadar, rmilosevi@unizd.hr

alohtone, poput alepskog bora koji je najzastupljeniji (Nećeman i dr., 2004; Dubravac i dr., 2006; Tekić i dr., 2014). Njegova invazivnost, posebice na opožarenim područjima, ugrožava brojnu autohtonu klimazonalnu vegetaciju, posebno hrast crniku (*Quercus ilex L.*) (Dubravac i dr., 2006; Tekić i dr., 2014). Šume primorskih četinjača obilježava velika količina smole, naslage otpalih iglica i osušenih trava, što ih čini vrlo podložnom vegetacijom u izbijanju otvorenih požara (Nećeman i dr., 2004; Martinić i dr., 2008; Španjol i dr., 2008; Simeoni i dr., 2012). Nadalje, često su izložene vjetru što ubrzava širenje požara (Bodrožić i dr., 2005; Fernandes i dr., 2010; Šiljković i Mamut, 2016). U konačnici, šume primorskih četinjača na mediteranskom području, zbog velike frekvencije ljudi (turizam) i čestog neodržavanja (Španjol i dr., 2008; Mamut, 2011) spadaju u skupinu veoma i ekstremno zapaljive vegetacije (Španjol i dr., 2008). Razvoj suvremenih geoprostornih tehnologija omogućio je kartiranje primorskih četinjača (Jovanović i Župan, 2017; Bullock i dr., 2020), analize izbijanja, širenja i prevencije požara (Jovanović i Župan, 2017) te detekciju raznih bolesti i nametnika na njoj (Arellano i dr., 2015). Sateliti iz *WorldView* (WV) konstellacije značajno su unaprijedili prikupljanje multispektralnih i stereo satelitskih snimaka visoke prostorne rezolucije (< 1 m) (Aguilar i dr., 2014). *WorldView-3* (WV-3) pruža najveću komercijalno dostupnu prostornu razlučivost satelitskih snimaka s velikim dnevnim kapacitetom arealnog prikupljanja. Kratki vremenski interval prikupljanja snimaka povećava mogućnosti detekcije prostorno-vremenskih promjena. Iz obrađenih satelitskih snimaka

primjenom različitih metoda klasifikacije izdvajaju se specifični objekti (Weih i Riggan, 2010; Abburu i Golla, 2015). Generalno, metode klasifikacije se mogu podijeliti na nadzirane (polu-automatske), nenadzirane (automatske) i objektno-orientirane rasterske analize (OBIA) (Weih i Riggan, 2010). U geografskoj objektno-orientiranoj analizi koristi se akronim *GEOBIA* (Hay i Castilla, 2008). *GEOBIA* se definira kao poddisciplina GIS-a usmjerena na obradu i analizu rasterskih podataka (Hay i Castilla, 2008). Za razliku od pikselski-orientiranih analiza, *GEOBIA* grupira piksele u smislene homogene cjeline prema njihovim specifičnim značajkama (Weih i Riggan, 2010; Abburu i Golla, 2015). Tradicionalna klasifikacija rasterskih podataka određuje klasu zemljишnog pokrova isključivo za pojedinačni piksel te se u takvim analizama ne uključuje spoznaja o okružujućim pikselima. *GEOBIA* segmentira sliku grupirajući piksele sličnih spektralnih, prostornih i geometrijskih značajki u objekte (oblike), odnosno *super piksele* (Comanicu i Meer, 2002). Potom se na temelju označenih testnih uzoraka i odabranog klasifikacijskog algoritma generira model zemljишnog pokrova (Maxwell i dr., 2015).

Primarni cilj ovog istraživanja je izdvojiti šume primorskih četinjača na području topografskog slijeva naselja Split. Sekundarni cilj je pomoću odabranih metričkih pokazatelja (*correctness – COR*, *completeness – COM* i *overall quality – OQ*) utvrditi koji od odabrana tri klasifikacijska algoritma (*Random Trees – RT*, *Maximum Likelihood – ML*, *Support Vector Machine – SVM*) najtočnije izdvaja šume primorskih četinjača. Nadalje, u segmentacijskom procesu testirani su



Slika 1. Područje istraživanja – topografski slijev naselja Split
Figure 1. Research area – topographic basin of the Split settlement

korisničko-definirani parametri s ciljem odabira vrijednosti koje omogućuju najoptimalnije grupiranje piksela. U konačnici, pomoću modificiranog Cohen's kappa coefficient pokazatelja (K) testirana je točnost konačnog modela. Svrha rada je definirati metodološki okvir izdvajanja šuma pri-morskih četinjača iz WV-3 snimaka za potrebe dobivanja egzaktnih informacija o ukupnoj površini ove veoma zapa-ljive vegetacije.

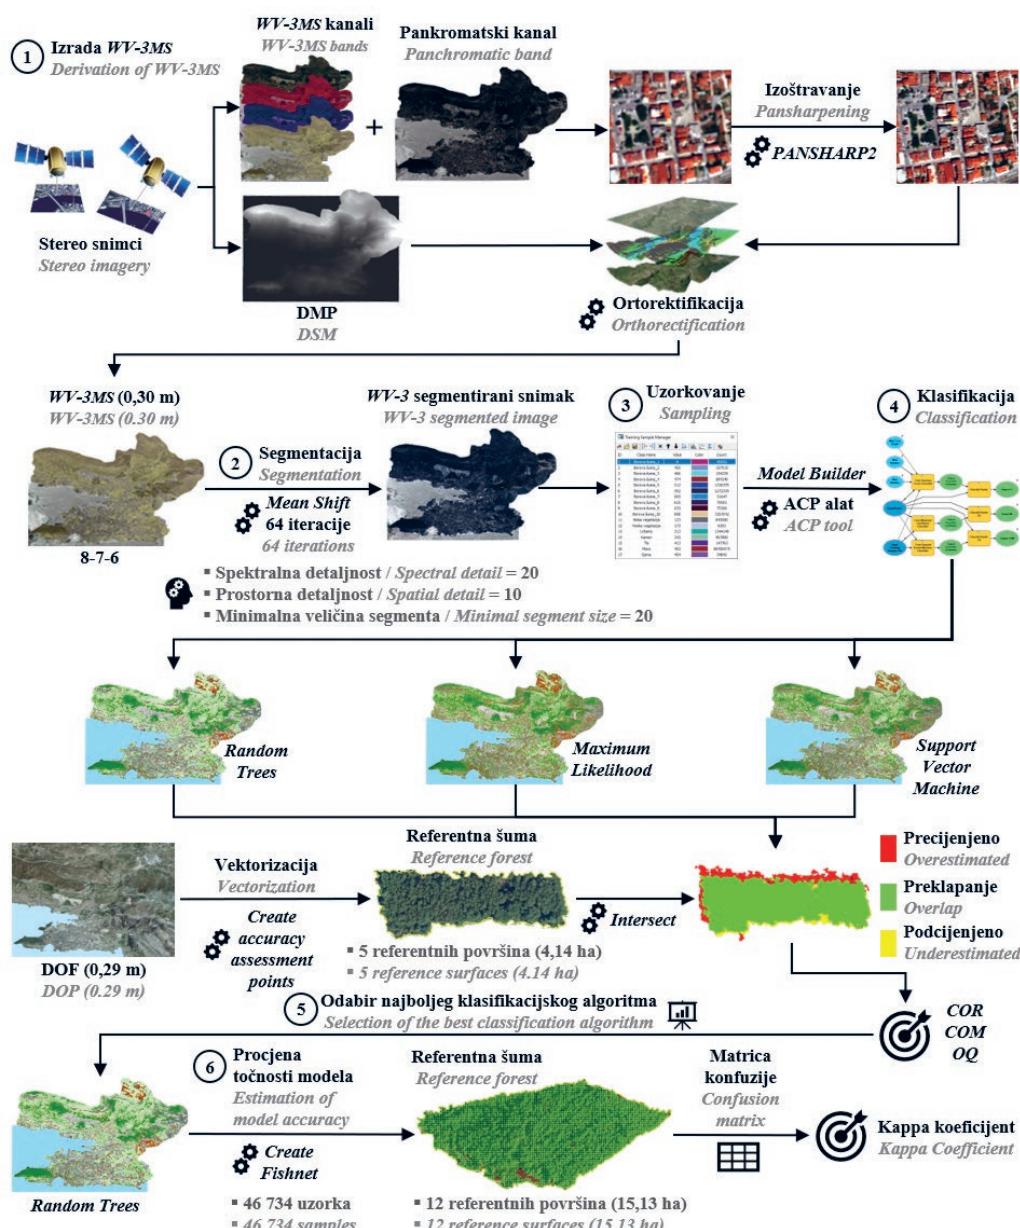
PODRUČJE ISTRAŽIVANJA RESEARCH AREA

Izdvajanje šuma izvršeno je na širem području naselja Split koje je definirano topografskim slijevom (TS) ($84,3 \text{ km}^2$) (Slika 1). Grad Split je administrativno sjedište Splitsko-

dalmatinske županije, požarima najugroženije županije u Republici Hrvatskoj (Netolicki i dr., 2012; Jovanović i Župan, 2017).

MATERIJALI I METODE MATERIALS AND METHODS

Izdvajanje i kartiranje borovih šuma iz WV-3 multispek-tralnog snimka (MS) izvedeno je GEOBIA metodom kori-steći ArcGIS softver. Metodologija je podijeljena na sljedeće korake: izrada WV-3_{MS}-a (1); segmentacija WV-3_{MS}-a (2); dodavanje testnih uzoraka (3); klasifikacija primjenom tri klasifikacijska algoritma (RT, ML, SVM) (4); procjena točnosti i odabir najboljeg klasifikacijskog algoritma (5); pro-cjena točnosti završnog modela (6), (Slika 2).



Slika 2. Shema metodološkog okvira istraživanja

Figure 2. Scheme of the methodological framework of the research

Prvi korak bila je izrada WV-3_{MS}-a (1) (Slika 3). WV-3 stereo snimci koji pokrivaju istraživano područje prikupljeni su 4. prosinca 2018. u idealnim uvjetima s 0 % naoblake i s optimalnim off-NADIR kutovima (< 30°) (Nemmaoui i dr., 2019), čime je postignuto 5 m CE90⁷/LE90⁸ absolutne horizontalne točnosti sa srednjom kvadratnom pogreškom od 2,3 m (RMSE⁹) (Maxar Technologies, 2019B). WV-3 stereo snimci ustupljeni su u sklopu financiranja zaklade Digital-Globe kao OrthoReady snimci (OR2A¹⁰). Prostorna rezolucija WV-3_{MS}-a unaprijeđena je PANSHARP2 tehnikom unutar softvera Geomatics 2018 korištenjem pankromatskog kanala (PCI Geomatica, 2013). OrthoEngine 2018 korišten je za izradu DSM-a. Generirani DSM_{WV3} primijenjen je u ortorektifikaciji izoštrenog 8-kanalnog WV-3_{MS}-a prostorne rezolucije 0,30 m (Domazetović i dr., 2020). Potom je u ArcGIS-u izvršena segmentacija WV-3_{MS}-a (2) temeljena na Mean Shift pristupu (Comaniciu i Meer, 2002). Obilježja segmentiranog modela ovise o tri parametra: spektralnoj detaljnosti, prostornoj detaljnosti i minimalnoj veličini segmenta. S ciljem pronalaska najoptimalnije kombinacije vrijednosti izvršen je iterativan proces (n=64) testiranja. Najoptimalnija kombinacija izvedena je na temelju vizualne interpretacije segmentiranih modela. Na segmentiranom modelu su potom označeni i dodani testni uzorci (3). Prikupljeni su uzorci za sljedeće klase: Šuma primorskih četinjača, Visoka vegetacija, Niska vegetacija, Tlo, Urbano, Kamnen, More, Sjena. Provjera prikupljenih testnih uzoraka izvedena je metodom unakrsnog vrednovanja. Označen je veći broj uzoraka zbog mogućih ulaznih distorzija izoštrenog multispektralnog snimka. U nastavku su testirana tri najčešće korištena GEOBIA klasifikacijska algoritma (RT, ML, SVM), (4) (Nitze i dr., 2012; Myburgh i Van Niekerk, 2013; Myburgh i Van Niekerk, 2014). S ciljem automatiziranja procesa, u Model Builder-u je izrađen alat pod nazivom Automated Classification Process (ACP) (Slika 2₄). ACP omogućava istovremeno generiranje izlaznih rezultata za sve korištene algoritme (RT, ML i SVM). Peti korak uključuje procjenu točnosti i odabir klasifikacijskog algoritma (5). Tri klasifikacijska algoritma uspoređena su na temelju odabranih metričkih pokazatelja (COR, COM, OQ) (Cai i dr., 2018). Time se kvantificira odnos između referentnih objekata i izvedenih objekata (GEOBIA šume - Gs) te ispituje točnost provedene segmentacije (Eisank i dr., 2014). Procjena točnosti provedena je na temelju pet uzoraka referentnih šuma (R_s) primorskih četinjača (R_{s1} – R_{s5}) (Slika 9). R_s su odabrane korištenjem alata Create accuracy assessment points. Šumske površine na kojima se našao piksel, ili im bio najbliže, izvektorizirane su u mjerilu 1:100 s DOF-

a iz 2019. godine prostorne rezolucije 0,29 m (DGU). Izračunato je područje preklopa (A_p) R_s i G_s, kao i precijenjeno (A_o) i podcijenjeno (A_u) područje. Vrijednosti su korištene za procjenu točnosti klasifikacijskih algoritama prema sljedećim formulama:

$$1) \quad COR = \frac{A_p}{A_{G_s}} \quad (\text{Cai i dr., 2018})$$

gdje je: A_p – područje preklopa referentne i klasificirane šume; A_{G_s} – ukupna površina GEOBIA šume

$$2) \quad COM = \frac{A_p}{A_{R_s}} \quad (\text{Cai i dr., 2018})$$

gdje je: A_p – područje preklopa referente i klasificirane šume; A_{R_s} – ukupna površina referentne šume

$$3) \quad OQ = \frac{A_p}{A_{R_s} + A_{G_s} + A_p} \quad (\text{Cai i dr., 2018})$$

gdje je: A_p – područje preklopa referentne i klasificirane šume; A_{R_s} – ukupna površina referentne šume; A_{G_s} – ukupna površina GEOBIA šume

Vrijednosti COR, COM i OQ indikatora variraju u rasponu 0 – 1. Veće vrijednosti ukazuju na veće podudaranje između referentnih i klasificiranih objekata, odnosno veću točnost klasifikacijskog algoritma (Whiteside i dr., 2014). U konačnici, izvedena je procjena točnosti najboljeg klasifikacijskog algoritma (6). Točnost je izračunata pomoću modificiranog Cohen's kappa coefficient (K) indikatora (Cohen, 1960) (4). Pontius i Millones (2011) i Foody (2020) u istraživanjima ističu nepouzdanost ovog pokazatelja, zbog čega je metoda unaprijeđena dodavanjem većeg broja uzoraka, pri čemu je udaljenost između svakog uzorka određena s obzirom na minimalnu jedinicu kartiranja (*Minimal Segment Size*). Procjena točnosti izvedena je na 46 734 uzorka unutar 12 R_s (R_{s1} – R_{s12}) (Slika 9). Alatom Create Fishnet generirana je mreža kvadrata 1,8 x 1,8 metra s centroidima koji predstavljaju uzorke na kojima će se ispitivati točnost konačnog modela. Model je reklassificiran tako da su sve klase osim Šuma primorskih četinjača spojene u jednu (*Ostalo*). Broj točaka unutar dviju generiranih klasa korišten je za procjenu točnosti klasifikacije prema sljedećoj formuli:

$$4) \quad K = \frac{M \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_i + x_{i+i}}{M^2 - \sum_{i=1}^r x_i + x_{i+i}} \quad (\text{Cohen, 1960})$$

gdje je: r – broj redaka u matrici konfuzije; x_{ii} – broj uzoraka u retku (i) i stupcu (i) (tj. dijagonalni elementi); M – ukupan broj uzoraka

⁷ CE90 - kružna pogreška na 90. percentilu, gdje minimalno 90 % izmjerjenih točaka ima vodoravnu pogrešku manju od navedene vrijednosti CE90.

⁸ LE90 - 90. percentil linearne pogreška, pri čemu najmanje 90 % vertikalnih pogrešaka spada u navedenu vrijednost LE90.

⁹ Root Mean Square Error

¹⁰ OR2A označava radiometrijski i senzorski ispravljen snimak, bez primijenjenih korekcija terena i kao takav je pogodan za daljnju ortorektifikaciju i ekstrakciju visina (Maxar Technologies, 2019B).

Vrijednosti K variraju u rasponu od -1 do +1 (Cohen, 1960; Foody, 2020). Vrijednosti < 0 predstavljaju slabo; 0 – 0,2 neznatno; 0,21 – 0,4 pošteno; 0,41 – 0,6 umjereni; 0,61 – 0,8 znatno; 0,81 – 1 skoro savršeno preklapanje referentnih i klasificiranih objekata (Landis i Koch 1977).

REZULTATI I RASPRAVA

RESULTS AND DISCUSSION

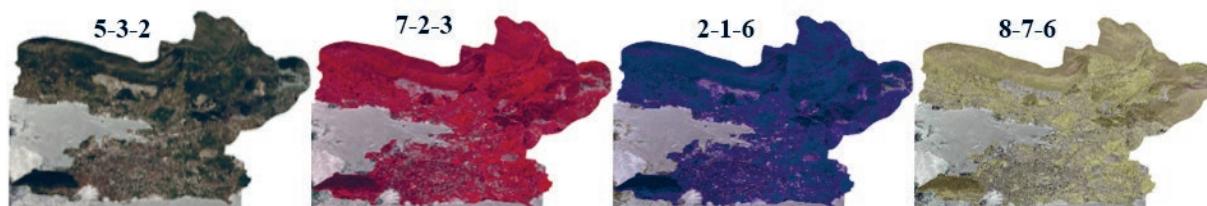
Izrada WV-3_{MS} / Derivation of WV-3_{MS}

Izoštravanje WV-3_{MS}-a unaprijedilo je prostornu rezoluciju s inicijalnih 1.2 m na 0.30 m, dok je ortorektifikacija izoštrenog WV-3_{MS}-a rezultirala geometrijski ispravljenim visokokvalitetnim modelom. Raspored kanala varira ovisno o vrsti vegetacije koja se izdvaja (Cross i dr., 2019; Solano i dr. 2019). Raspored kanala 8-7-6 (URL1), na kojem se najbolje ističu borove šume, poslužio je kao osnova za izdvajanje klase.

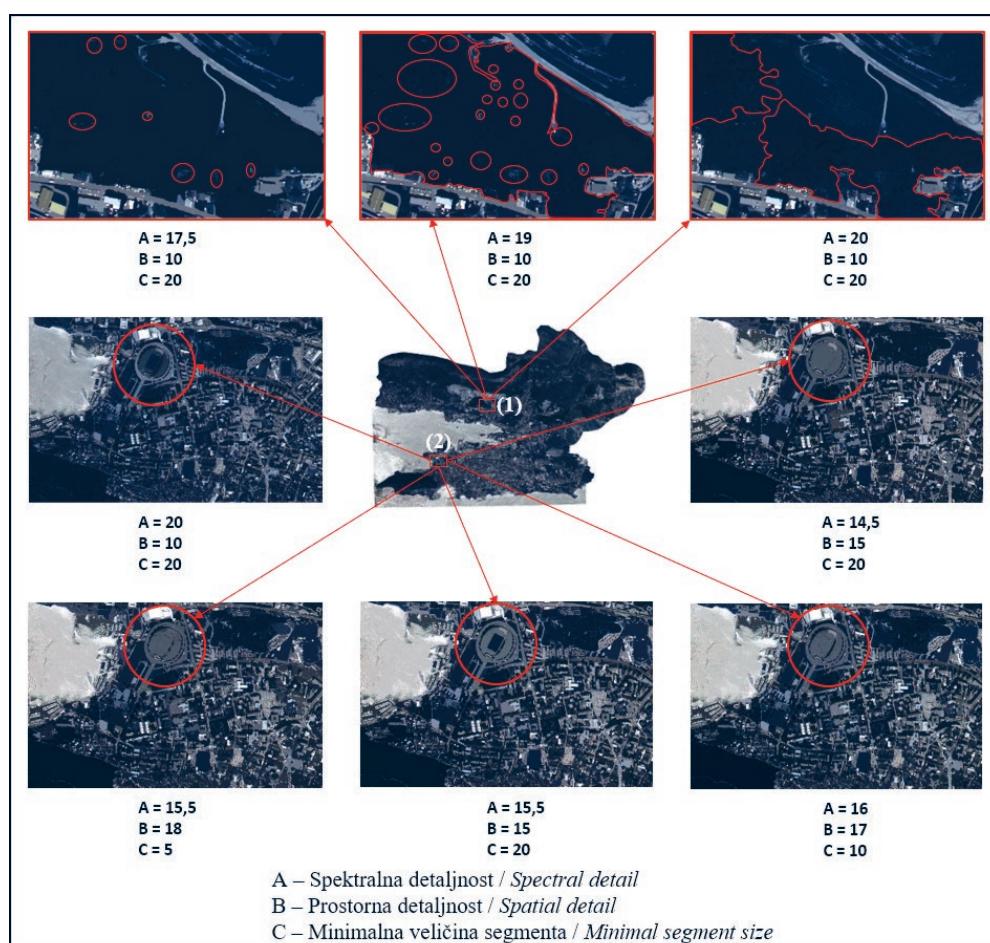
nog WV-3_{MS}-a rezultirala geometrijski ispravljenim visokokvalitetnim modelom. Raspored kanala varira ovisno o vrsti vegetacije koja se izdvaja (Cross i dr., 2019; Solano i dr. 2019). Raspored kanala 8-7-6 (URL1), na kojem se najbolje ističu borove šume, poslužio je kao osnova za izdvajanje klase.

Segmentacija WV-3_{MS} / Segmentation of WV-3_{MS}

S ciljem pronaleta najoptimalnije kombinacije vrijednosti segmentacijskih parametara izvršen je iterativan proces testiranja. Vizualnom interpretacijom, od izvedena 64 segmentacijske modela, odabrane su sljedeće vrijednosti parametara: (a) spektralna detaljnost = 20, (b) prostorna detaljnost = 10 i (c) minimalna veličina segmenta = 20.



Slika 3. Generirani WV-3_{MS} i neke kombinacije kanala
Figure 3. Generated WV-3_{MS} and some channel combinations



Slika 4. Primjeri utjecaja različitih kombinacija parametara segmentacije na izlazni rezultat
Figure 4. Influence of different parameters value on the segmentation output result



Slika 6. Izlazni rezultati testiranih klasifikacijskih algoritama (RT, ML i SVM)

Figure 6. Output results of three classification algorithms (RT, ML and SVM)

Spektralna detaljnost uvjetovana je spektralnom rezolucijom WV-3_{MS}-a (Satellite Imaging Corporation, 2021), koja utječe na diferencijaciju različitih vegetacijskih vrsta (Teillet i dr., 1997). Navedeno je omogućilo odvajanje sastojina primorskih četinjača od ostale vegetacije (Slika 4(,)). Prostorna detaljnost, koja utvrđuje važnost blizine značajki u multispektralnom modelu, je postavljena na vrijednost 10. Veća vrijednost omogućila bi izdvajanje pojedinih stabala unutar šume, a manja bi rezultirala prevelikom generalizacijom.

Minimalna veličina segmenta određuje minimalnu jedinicu kartiranja (20 piksela). Dakle, iz segmentiranog snimka moguće je izdvojiti sve površine prekrivene primorskim četinjačama koje su veće od 1,8 m².

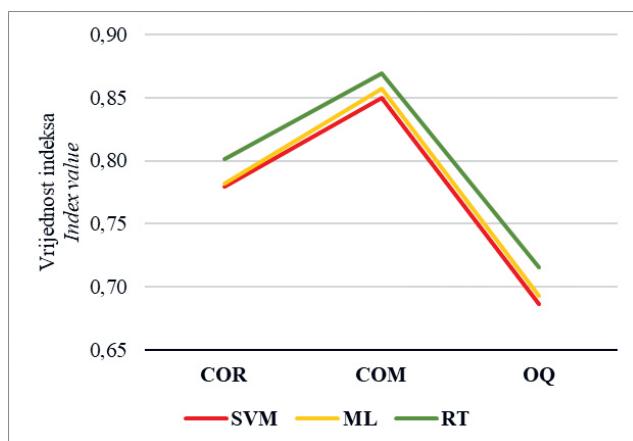
Dodavanje testnih uzoraka / Adding test samples

Ukupno je označeno 600 uzoraka unutar TS-a. Poznato je da širok spektar čimbenika može uzrokovati razlike u spektralnim značajkama elemenata iste klase unutar istog snimka. Oni uključuju: velik utjecaj sjena uzrokovani visokim zgradama ili morfologijom terena, kut upada sunčevih zraka, fiziologija borova, itd. (Fu i dr., 2020). Stoga su uzorci za klasu Šuma primorskih četinjača prikupljeni u 10 odvojenih klasa, uvažavajući različite lokacije na segmentiranom modelu i fiziološka obilježja sastojina. Naknadno je izvršena reklassifikacija.

Rezultati klasifikacijskih algoritama / Results of classification algorithms

Izrađeni alat ACP (Slika 5) omogućio je istovremeno generiranje izlaznih rezultata za tri odabrana klasifikacijska algoritma (RT, ML i SVM) (Slika 6). Najveća razlika između ML-a i SVM-a očituje se u slabom razlikovanju niske i visoke vegetacije, dok RT takvih problema nema.

Prema izvedenim metričkim pokazateljima RT je najpouzdanoji klasifikacijski algoritam za izdvajanje šuma primorskih četinjača (Tablica 1; Slika 7). Najmanje točan je SVM, dok se ML pokazao nešto boljim. Pokazatelji COR, COM i



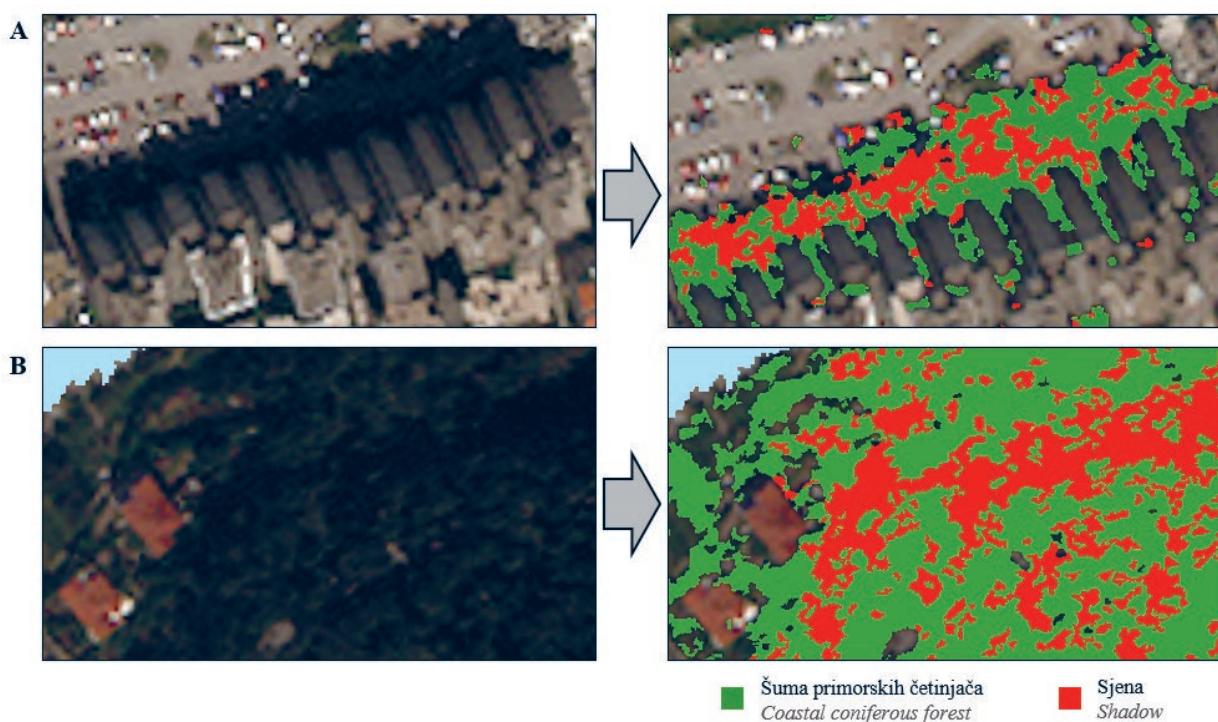
Slika 7. Grafički prikaz rezultata procjene točnosti klasifikacijskih algoritama COR, COM i OQ pokazateljima

Figure 7. Graphical display of the classification algorithms accuracy assessment results by COR, COM and OQ metric

Tablica 1. Rezultati procjene točnosti klasifikacijskih algoritama prema odabranim pokazateljima

Table 1. Results of the classification algorithms accuracy assessment by COR, COM and OQ metrics

Referentna šuma / Reference forest	COR	COM RT	OQ	COR	COM ML	OQ	COR	COM SVM	OQ
R _s 1	0.9565	0.8667	0.8338	0.9543	0.8695	0.8348	0.9524	0.8701	0.8338
R _s 2	0.8773	0.7091	0.6452	0.8417	0.7524	0.6591	0.8477	0.7047	0.6255
R _s 3	0.8743	0.8631	0.7678	0.8815	0.7309	0.6655	0.8660	0.7617	0.6814
R _s 4	0.8079	0.8777	0.7261	0.8007	0.8806	0.7223	0.7810	0.8890	0.7116
R _s 5	0.9481	0.7970	0.7637	0.9476	0.8054	0.7710	0.9519	0.8083	0.7766
Ukupno Total	0.8928	0.8227	0.7473	0.8852	0.8078	0.7306	0.8798	0.8068	0.7258



Slika 8. Problem koji stvaraju sjene prilikom klasifikacije
Figure 8. Errors in classification caused by shadows

Tablica 2. Matrica konfuzije (Kappa koeficijent)

Table 2. Error matrix (Kappa coefficient)

	Šuma primorskih četinjača Coastal coniferous forest	Ostalo Other	Ukupno (WV-3_RT) Total (WV-3_RT)
Šuma primorskih četinjača <i>Coastal coniferous forest</i>	43 786	2 948	46 734
Ostalo <i>Other</i>	2 948	43 786	46 734
Ukupno (DOF) <i>Total (DOP)</i>	46 734	46 734	93 468
Kappa		0,8738	

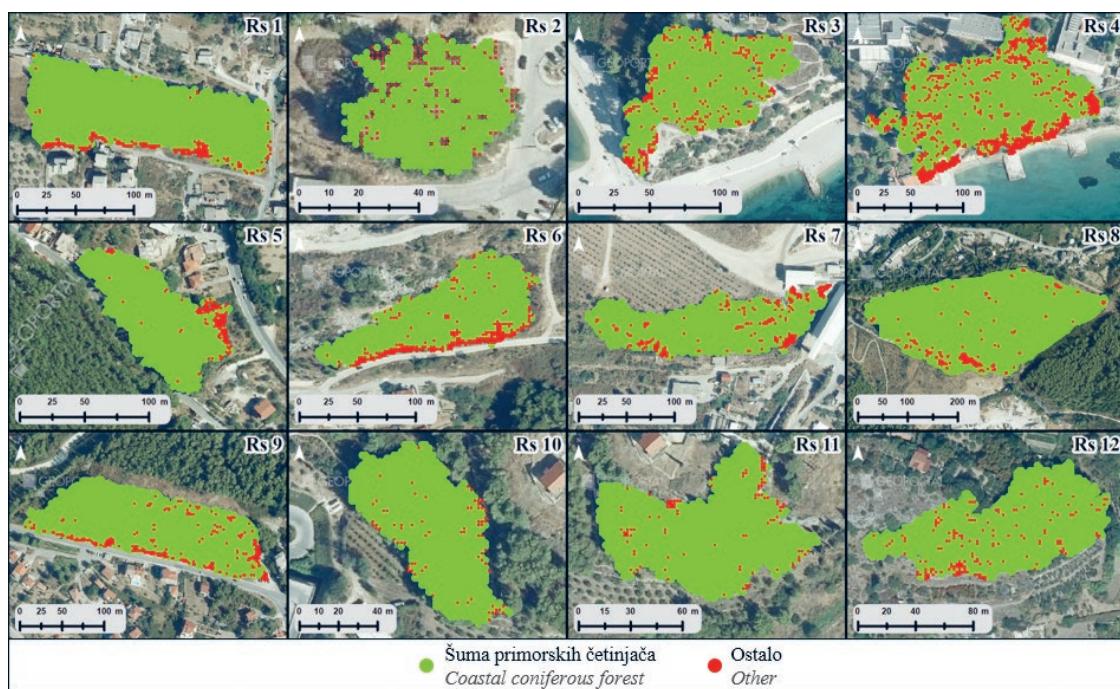
OQ izvedeni za pet R_s ukazuju na problem sjene koje, na štetu klase Šuma primorskih četinjača, zauzimaju velik udio, posebice za ML i SVM klasifikacijske algoritme. Drugim riječima, neki dijelovi šumskih sastojina u izvedenim modelima su svrstani u klasu Sjena. RT je također prepoznao sjene, ali su one prisutne u manjem udjelu. Dakle, na temelju rezultata točnosti procjene i vizualne analize, RT klasifikacijski algoritam je odabran kao najpouzdaniji.

Problem sjene može predstavljati značajnu prepreku u segmentaciji i klasifikaciji visoke vegetacije na snimkama vrlo visoke-rezolucije (Dare, 2005, Griffith i Hay, 2018, Kwan i dr., 2019). Na slici 8. prikazana su dva primjera utjecaja sjene na izlazni model. Na primjeru (A) visoke zgrade stvaraju sjene te su unutar tog zasjenjenog prostora svi klasifikacijski algoritmi na nekim dijelovima prepoznali „lažne“ borove. Na drugom primjeru (B) relativne razlike u visini

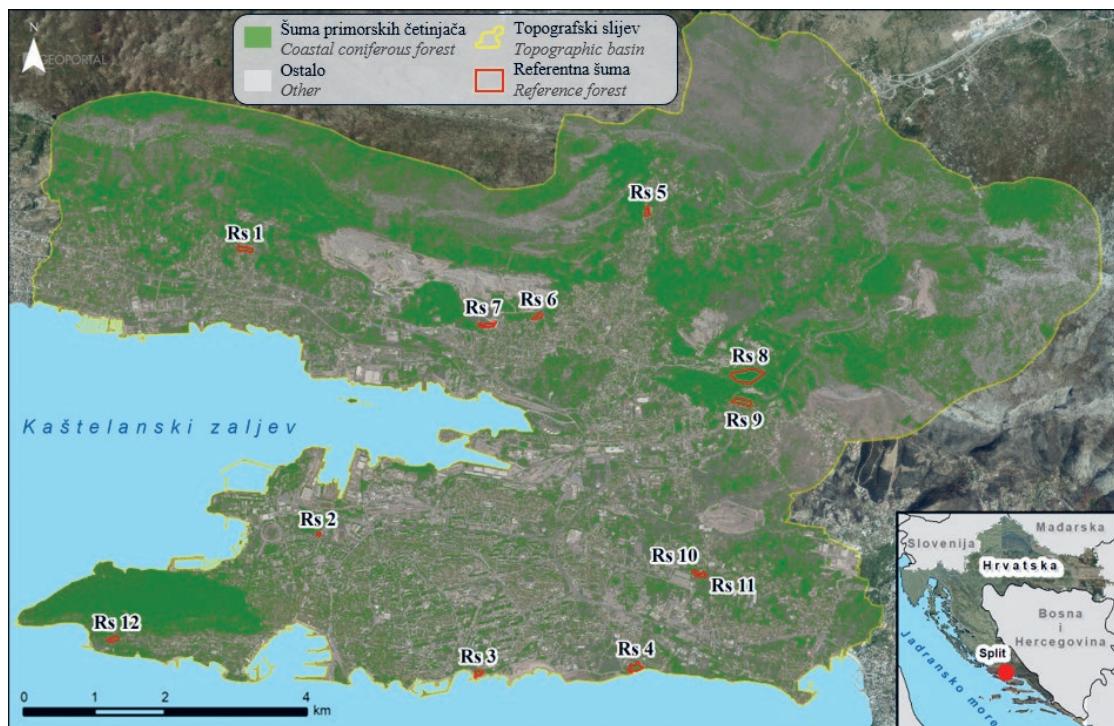
borova također generiraju klasu sjena. Ovaj problem se može riješiti dodavanjem većeg broja uzoraka uvažavajući način nastanka sjene. Naime, činjenica je da stupanj propusnosti svjetlosti do tla ovisi o prirodi same zapreke. Građevine uglavnom apsorbiraju ili odbijaju svu svjetlost unutar analiziranih kanala. Suprotno, drveće propušta malo NIR svjetlosti i nešto više vidljive svjetlosti. Stoga, zasjenjena područja bi se po vrsti sjene prema nekim vegetacijskim indeksima ipak trebala razlikovati.

Točnost završnog modela (RT) / Accuracy of final coniferous forest model (RT)

Točnost završnog modela izvedenog RT klasifikacijskim algoritmom procijenjena je modificiranim K pokazateljem. Točnost je ispitana za klasu Šuma primorskih četinjača. U matricu konfuzije uvrštena su 46 734 uzorka izvedena unu-



Slika 9. Analiza 46 734 uzorka unutar referentnih šuma
Figure 9. Analysis of 46,734 samples within reference forests



Slika 10. Konačni model šuma primorskih četinjača na području topografskog slijeva naselja Split
Figure 10. The final coastal coniferous forest model on the Split topographic basin

tar 12 R_s (Slika 9). Od navedenog broja, 43 786 uzoraka spada u klasu Šuma primorskih četinjača, dok 2 948 uzorka spada u klasu Ostalo. Dakle, prema odabranom pokazatelju točnost završnog modela iznosi 87,38 %. Ova vrijednost

prema Landis i Koch (1977) predstavlja skoro savršeno poklapanje referentnih i klasificiranih podataka.

Na slici 10. prikazan je konačni model šuma primorskih četinjača na području topografskog slijeva naselja Split. Pod

šumama primorskih četinjača je 2 643,43 ha TS-a što je oko 31% ukupne površine. Najveće šumske površine se nalaze na Marjanu, južnim padinama Kozjaka i zapadnim padinama Mosora uz poneke parkove idrvorede u samom gradu Splitu i okolnim naseljima.

ZAKLJUČAK CONCLUSION

Primjenom *GEOBIA* metodologije generiran je model zemljишnog pokrova na području topografskog slijeva naselja Split. Model je reklassificiran u dvije klase: Šuma primorskih četinjača i Ostalo. RT se prema odabranim indikatorima (COR, COM i OQ) pokazao kao pouzdaniji u izdvajanju šuma primorskih četinjača od ML i SVM klasifikacijskih algoritama. Nadalje, iterativno postavljanje segmentacijskih parametara omogućilo je detekciju najoptimalnijih vrijednosti za generiranje segmentacijskog modela. Utvrđeno je da sjene mogu uzrokovati značajne probleme prilikom klasificiranja šuma s visoko-rezolucijskog WV-3_{MS}-a. Rješenje može biti u prikupljanju većeg broja uzoraka na različitim područjima u svrhu detaljnije diferencijacije klasa. Modificiranim *K* pokazateljem izračunata je točnost konačnog modela od 87,38%. U konačnici WV-3_{MS} se s obzirom na komercijalnu dostupnost može smatrati primjerenim podatkom za detekciju šuma primorskih četinjača *GEOBIA* metodom. Prema izradenom modelu, 31,36% ukupne površine unutar topografskog slijeva naselja Split pokriva vrlo i ekstremno zapaljiva vegetacija.

ZAHVALA ACKNOWLEDGEMENT

Podaci u ovom istraživanju prikupljeni su u sklopu projekata PEPSEA Split i STREAM. Saznanja i rezultati iz ovoga rada će se koristiti za potrebe projekta STREAM (Strategic Development of Flood Management).

LITERATURA REFERENCES

- Abburu, S., S.B Golla, 2015: Satellite image classification methods and techniques: a review, International journal of computer applications, 119(8): 20.-25.
- Aguilar, M.A., F. Bianconi, FJ Aguilar, I. Fernández, 2014: Object-based greenhouse classification from GeoEye-1 and WorldView-2 stereo imagery, Remote sensing, 6(5): 3554.-3582.
- Arellano, P., K. Tansey, H. Balzter, D.S. Boyd, 2015: Detecting the effects of hydrocarbon pollution in the Amazon forest using hyperspectral satellite images, Environmental Pollution, 205: 225.-239.
- Bodrožić, L., J. Marasović, D. Stipaničev, 2005: Fire modeling in forest fire management, CEEPUS Spring School, Kielce, Poland.
- Bullock, E. L., C.E. Woodcock, Jr.C. Souza, P. Olofsson, 2020: Satellite-based estimates reveal widespread forest degradation in the Amazon, Global Change Biology, 26(5):2956-2969.
- Cai, L., W. Shi, Z. Miao, M. Hao, 2018: Accuracy assessment measures for object extraction from remote sensing images, Remote Sensing, 10(2): 303
- Cohen, J., 1960: A coefficient of agreement for nominal scales, Educational and psychological measurement, 20(1):37.-46.
- Comaniciu, D., P. Meer, 2002: Mean shift: A robust approach toward feature space analysis, IEEE Transactions on pattern analysis and machine intelligence, 24(5):603.-619.
- Cross, M. D., T. Scambos, F. Pacifici, W.E. Marshall 2019: Determining effective meter-scale image data and spectral vegetation indices for tropical forest tree species differentiation, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(8):2934-2943.
- Dare, P. M., 2005: Shadow analysis in high-resolution satellite imagery of urban areas, Photogrammetric Engineering & Remote Sensing, 71(2):169.-177.
- Domazetović, F., A. Šiljeg, I. Marić, M. Jurišić, 2020: Assessing the Vertical Accuracy of Worldview-3 Stereo-extracted Digital Surface Model over Olive Groves. In GISTAM 2020, 246.-253.
- Dubravac, T., B. Vrbek, Z. Lalić, 2006: Prirodna obnova u sastojinama alepskog bora (*Pinus halepensis* Mill.) nakon požara, Radovi, 9:37.-51.
- Eisank, C., M. Smith, J. Hillier, 2014: Assessment of multiresolution segmentation for delimiting drumlins in digital elevation models, Geomorphology, 214:452.-464.
- Fernandes, P.M., A. Luz, C. Loureiro, 2010: Changes in wildfire severity from maritime pine woodland to contiguous forest types in the mountains of northwestern Portugal, Forest Ecology and Management, 260(5):883.-892.
- Foody, G.M., 2020: Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification, Remote Sensing of Environment, 239.
- Fu, H., T. Zhou, C. Sun, 2020: Object-based shadow index via illumination intensity from high resolution satellite images over urban areas, Sensors, 20(4): 1077.
- Hay, G.J., G. Castilla, 2008: Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In Object-based image analysis, 75.-89. Springer, Berlin, Heidelberg.
- Jovanović, N., R. Župan, 2017: Analiza stanja vegetacije prije i nakon šumskih požara pomoću satelitskih snimaka Sentinel-2 na području Dalmacije, Geodetski list, 71(3):233-248.
- Kwan, C., L. Hagen, B. Chou, D. Perez, J. Li, Y. Shen, K. Koperski, 2020: Simple and effective cloud-and shadow-detection algorithms for Landsat and Worldview images, Signal, Image and Video Processing, 14(1):25.-133.
- Griffith, D.C., G.J. Hay, 2018: Integrating GEOBIA, Machine Learning, and Volunteered Geographic Information to Map Vegetation over Rooftops, ISPRS International Journal of Geo-Information, 7(12):462.
- Landis, J.R., G.G. Koch, 1977: The measurement of observer agreement for categorical data. biometrics, 159-174.
- Mamut, M., 2011: Ties between the geographical and social geographical features of dalmatia with the endangerment of forest fires; Šumarski list, 135(1-2):37.-49.

- Martinić, I., B. Hrašovec, Ž. Španjol, D. Diminić, I. Grginčić, 2008. Program gospodarenja za šume s posebnom namjenom – gospodarska jedinica "Park-šuma Marjan" i mjere zaštite i unapređenja ekološkog sustava za Park-šumu Marjan - Pregled mjera zaštite i sustav monitoringa, Šumarski fakultet Sveučilišta u Zagrebu, dostupno na: <http://drustvomarjan.hr/wp-content/uploads/2009/01/%C5%A0GP-3.pdf>
- Matić, S., I. Anić, M. Oršanić, 2005: Uzgojni zahvati u funkciji poboljšanja protuerozijske i vodozaštitne uloge šume, Šumarski list 129:17–30.
- Maxar Technologies, 2019b: Stereo Imagery datasheet. dostupno na: <https://www.digitalglobe.com/resources> (11. listopada 2020).
- Maxwell, A.E., T.A Warner, M.P Strager, J.F Conley, A.L Sharp, 2015. Assessing machine-learning algorithms and image-and lidar-derived variables for GEOBIA classification of mining and mine reclamation, International Journal of Remote Sensing, 36(4):954.-978.
- Myburgh, G., A. Van Niekerk, 2013: Effect of feature dimensionality on object-based land cover classification: A comparison of three classifiers; South African Journal of Geomatics, 2(1):13.-27.
- Myburgh, G., A. Van Niekerk, 2014: Impact of training set size on object-based land cover classification: A comparison of three classifiers, International Journal of Applied Geospatial Research (IJAGR), 5(3):49-67.
- Neéman, G., S. Goubitz, R. Nathan, 2004. Reproductive traits of *Pinus halepensis* in the light of fire—a critical review, Plant Ecology, 171(1-2): 69-79.
- Nemmaoui, A., F.J. Aguilar, M.A. Aguilar, R. Qin, 2019: DSM and DTM generation from VHR satellite stereo imagery over plastic covered greenhouse areas. Computers and Electronics in Agriculture, 164:104903.
- Netolicki, A., T. Blažević, A. Antolović, 2012: Višekriterijska analiza rizika od požara u Splitsko-dalmatinskoj županiji, Kartografija i geoinformacije, 11(17):5.-24.
- Nitze, I., U. Schulthess, H. Asche, 2012: Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. Proc. of the 4th GEOBIA, 35.
- PCI Geomatica, 2013: Pan-sharpening technical specification, Dostupno na: <https://www.pcigeomatics.com/pdf/geomatica/techspecs/2018/Pan-Sharpening.pdf>
- Pernek, M., S. Novak Agbaba, N. Lacković, N. Đođ, I. Lukić, S. Wirth, 2012. Uloga biotičkih čimbenika u sušenju borova (Pinus spp.) na području sjeverne Dalmacije, Šumarski list, 136(7-8):343.-353.
- Pontius Jr, R.G., M. Millones, 2011: Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment, International Journal of Remote Sensing, 32(15):4407.-4429.
- Satellite Imaging Corporation 2021: WorldView-3 Satellite Sensor (0.31m). Dostupno na: <https://www.satimagingcorp.com/satellite-sensors/worldview-3/>
- Simeoni, A., J.C. Thomas, P. Bartoli, P. Borowieck, P. Reszka, F. Colella, F. Santoni, J.L. Torero, 2012: Flammability studies for wildland and wildland–urban interface fires applied to pine needles and solid polymers, Fire Safety Journal, 54:203.-217.
- Solano, F., S. Di Fazio, G. Modica, 2019. A methodology based on GEOBIA and WorldView-3 imagery to derive vegetation indices at tree crown detail in olive orchards, International Journal of Applied Earth Observation and Geoinformation, 83:101912.
- Šiljković, Ž., M. Mamut, 2016. Forest fires in Dalmatia,Bulletin of Geography. Socio-economic Series, 32(32):117.-130.
- Španjol, Ž., K. Biljaković, R. Rosavec, D. Dominko, D. Barać, D. Starešinić, 2008: Šumski požari i fizikalni modeli, Šumarski list, 132(5-6):259-267.
- Teillet, P.M., K. Staenz, D.J. William, 1997: Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions, Remote Sensing of Environment, 61(1):139.-149.
- Tekić, I., B. Fuerst-Bjeliš, A. Durbešić, 2014: Rasprostranjenost alepskog bora (*Pinus halepensis* Mill.) i njegov utjecaj na vegetaciju i strukturu pejzaža šireg šibenskog područja, Šumarski list, 138(11-12):593.-600.
- Vrbek, B., M. Vrbek, I. Pilaš, J. Medak, 2013: Pedološko vegetacijske karakteristike park šume Marjan, 4. Hrvatski Botanički Simpozij s međunarodnim sudjelovanjem Split
- Weih, R.C., N.D. Riggan, 2010: Object-based classification vs. pixel-based classification: Comparative importance of multi-resolution imagery, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 38(4):C7.
- Whiteside, T.G., SW. Maier, G.S. Boggs, 2014: Area-based and location-based validation of classified image objects, International Journal of Applied Earth Observation and Geoinformation, 28:117.-130.
- URL1: http://www.geocarto.com.hk/edu/PJ-BCMBWV3G/main_BCW3.html

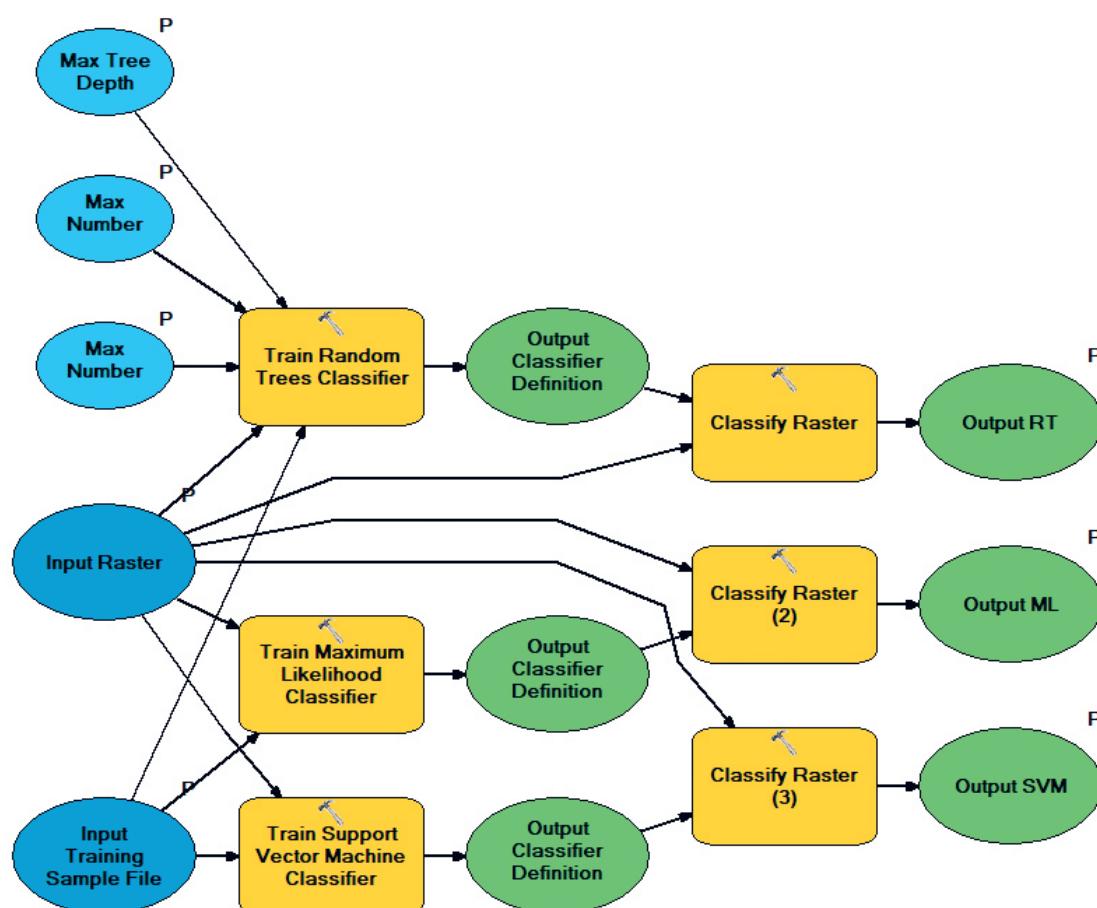
COMPARISON OF GEOBIA CLASSIFICATION ALGORITHMS BASED ON WORLDVIEW-3 IMAGERY IN THE EXTRACTION OF COASTAL CONIFEROUS FOREST

SUMMARY

With their ecological, economic, aesthetic, and social function, coniferous forests represent an important part of European forest communities. The main objective of this paper is to compare the most used GEOBIA (Geographic Object-Based Image Analysis) classification algorithms (Random Trees - RT, Maximum Likelihood - ML, Support Vector Machine - SVM) for the purposes of the coastal coniferous forest detection on a high-resolution WorldView-3 (WV-3) imagery on the topographic basin of the Split settlement (Figure 1). The methodological framework (Figure 2) includes: (1) deriva-

tion of a sharpened multispectral image (WV-3_{MS}) (Figure 3); (2) testing of the user-defined parameters in segmentation process (Figure 4); (3) marking of test samples (signatures); (4) classification of a segmented model; (5) accuracy assessment of the classification algorithms, and (6) accuracy assessment of the final model. The developed ACP tool (Automated Classification Process) (Supplement figure 5) for speeding up the entire classification process, enabled the simultaneous generation of output results for three selected classification algorithms (RT, ML and SVM) (Figure 6). Metric indicators (correctness - COR, completeness - COM, and overall quality - OQ) have shown that RT is the most accurate classification algorithm for the coastal coniferous forest detection (Table 1; Figure 7). The iterative setting of segmentation parameters enabled the detection of the most optimal values for generating a segmentation model. It is found that shadows can cause significant problems if classification is done on high-resolution images (Figure 8). The solution may be to collect a larger number of samples in different areas for the purpose of more detailed class differentiation. The modified Cohen's kappa coefficient (K) indicator shown the accuracy of the final model of 87.38% (Table 2; Figure 9). WV-3_{MS} can be considered as very good data for the detection of coniferous forests using the GEOBIA method (Figure 10). According to this research, 31.36% of the Split topographic basin is covered by highly and extremely flammable vegetation.

KEY WORDS: GEOBIA, WorldView-3, Coniferous Forest, Random Trees, Maximum Likelihood, Support Vector Machine.



Dodatna slika 5. Automated Classification Process (ACP) alat izrađen u Model Builder-u Supporting Information
Supplement figure 5. Automated Classification Process (ACP) tool created in Model Builder