

UDK 528.8.04:630*58:528.854
Pregledni znanstveni članak / Review

Pregled satelitskih misija i metoda klasifikacije šumskog pokrova primjenom satelitskih snimaka visoke rezolucije

Martina DEUR – Šibenik¹, Mateo GAŠPAROVIĆ,
Ivan BALENOVIĆ – Zagreb²

SAŽETAK. Napredak u području tehnologija daljinskih istraživanja omogućava sve veća dostignuća na području klasifikacije vrsta drveća. Posljednjih godina postignut je znatan tehnološki napredak i unapređenje značajki optičkih senzora omogućujući tako poboljšanu razlučivost detalja na satelitskim snimkama (prostorna, spektralna i radiometrijska rezolucija). Povećanje prostorne rezolucije imalo je znatan utjecaj na razvoj tehnika i metoda daljinskih istraživanja. Nova generacija satelitskih snimaka vrlo visoke rezolucije omogućuje istraživanje na lokalnim i regionalnim razinama te je vrlo bitan izvor informacija u šumarstvu. Cilj je ovog rada pružiti pregled globalnih satelitskih misija visoke i vrlo visoke rezolucije, kao i metoda analize i obrade u postupku klasifikacije šumskog pokrova. U kombinaciji s algoritmima strojnog učenja, primjenom satelitskih snimaka visoke i vrlo visoke rezolucije smanjuje se potreba za radno intenzivnim i dugotrajnim tradicionalnim terenskim metodama uz povećanje kvantitativne i kvalitativne vrijednosti dobivenih informacija u šumarstvu.

Ključne riječi: daljinska istraživanja, satelitske snimke visoke rezolucije, klasifikacija šumskog pokrova.

¹ Martina Deur, dipl. ing. geod., Zavod za prostorno uređenje Šibensko-kninske županije, Vladimira Nazora 1/IV, HR-22000 Šibenik, Hrvatska, e-mail: martina.deur@zpu-skz.hr

² doc. dr. sc. Mateo Gašparović, Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, HR-10000 Zagreb, Hrvatska, e-mail: mateo.gasparovic@geof.unizg.hr
dr. sc. Ivan Balenović, Hrvatski šumarski institut, Trnjanska cesta 35, HR-10000 Zagreb, Hrvatska, e-mail: ivanb@sumins.hr

1. Uvod

S ukupno 31% Zemljine kopnene površine, šume su najrasprostranjeniji kopneni ekosustav koji pruža mnogo direktnih i indirektnih dobrobiti čovječanstvu (FAO i UNEP 2020). Šume su značajni ponori atmosferskog ugljika (Nabuurs i dr. 2013) te stoga imaju važnu ulogu u globalnom kruženju ugljika i regulaciji klime, odnosno ublažavanju klimatskih promjena (Randerson i dr. 1997). Uz čitav niz općekorisnih funkcija, šume u prvom redu osiguravaju potrebu čovječanstva za energijom (Fisher i dr. 2008). Potrajno gospodarenje šumama zahtijeva prostorne i vremenske određene informacije koje se još uvijek u mnogim zemljama, uključujući i Hrvatsku, uglavnom prikupljaju tradicionalnim (terenskim) metodama. Prikupljanje podataka o šumama na tradicionalni način, terenskom izmjerom, pruža točne informacije, ali zahtijeva dugotrajan i intenzivan rad, a u pojedinim je slučajevima pristup određenim šumskim područjima otežan ili čak nemoguć. Stoga je u šumarskoj znanosti odavno prepoznat potencijal primjene metoda daljinskih istraživanja kao dodatnog izvora korisnih informacija koji može znatno olakšati i unaprijediti postojeće terenske metode. Između različitih metoda i vrsta podataka daljinskih istraživanja vrlo velik interes u svijetu, ali i u Hrvatskoj, zauzimaju satelitske snimke (Seletković i dr. 2008, Seletković i dr. 2011, Deur i dr. 2020, Pilaš i dr. 2020), koje mogu biti različitih prostornih, radiometrijskih, spektralnih i vremenskih rezolucija te stoga primjenjive u različite svrhe i potrebe šumarstva.


Općenito, daljinska su istraživanja znanost i tehnologija prikupljanja, obrade i analize snimki, povezano s ostalim fizikalnim podacima o Zemlji i ostalim planetima, a pomoću senzora u svemiru, zraku i na Zemlji (ISPRS 2016), a temelje se na interakciji zračenja upadnog elektromagnetskog vala (svjetla) na promatrani objekt. Pri tome se obično može razdvojiti na sedam sastavnih dijelova (Oštir i Mulahusić 2014):

- izvor elektromagnetskog zračenja
- putovanje kroz atmosferu
- interakcija s površinom
- zapisivanje valova sensorom
- prijenos, prijem i obrada
- interpretacija i analiza
- korištenje.

Pri proučavanju šumskog pokrova daljinska istraživanja imaju određene prednosti nad klasičnim metodama, među kojima se ističu (Olujić 2001):

- sinoptičko pokrivanje golemih područja
- sinoptičko opserviranje
- ponavljano sustavno snimanje istih područja
- dostupnost svih područja na Zemljinoj površini
- ažurni podaci: monitoring i inventarizacija.

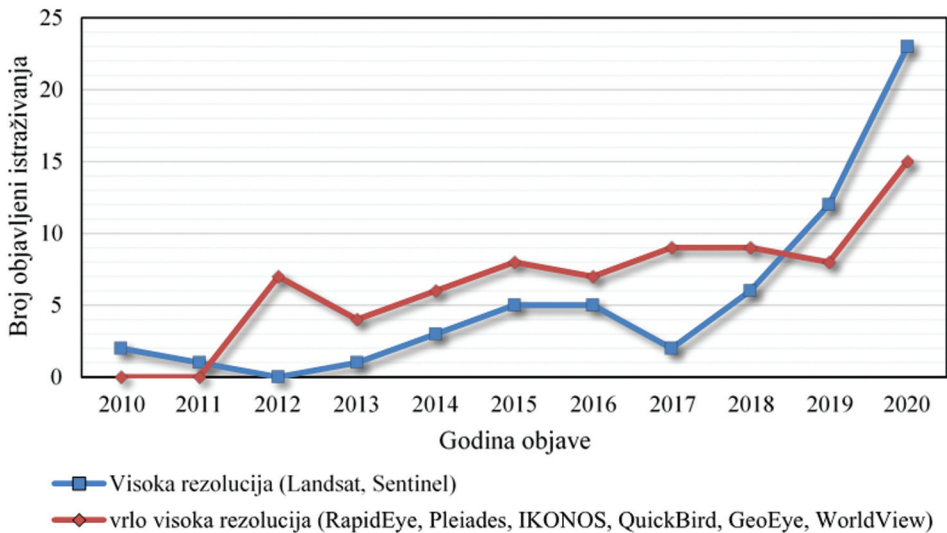
Cilj je daljinskih istraživanja brzo i ekonomično dobivanje podataka i informacija zadovoljavajuće preciznosti, ponajprije relativno velikih područja (Oluić 2001). Broj studija koje se bave klasifikacijom vrsta drveća posljednjih je desetljeća u znatnom porastu (Soleimannejad i dr. 2019, Majid i dr. 2016, Cho i dr. 2015, Cho i dr. 2012) (slika 1).



Slika 1. Ukupan godišnji broj znanstvenih istraživanja objavljenih u bazi Web of Science Core Collection (WoSCC) u razdoblju od 2010. do 2020., s temama "tree species" ili "forest" dopunjeno s "remote sensing".

Analiza baze podataka Web of Science Core Collection (WoSCC) o broju znanstvenih istraživanja s temama "tree species" ili "forest" dopunjeno s "remote sensing" u razdoblju od 2010. do 2020. godine potvrdila je zapažanje široke upotrebe globalnih satelitskih misija visoke i vrlo visoke rezolucije u klasifikaciji šumskog pokrova. Satelitske misije visoke rezolucije otvorenog pristupa Landsat i Sentinel 2018. godine naglo su stekle popularnost u usporedbi s komercijalnim satelitskim misijama vrlo visoke rezolucije (RapidEye, Pleiades, IKONOS, QuickBird, GeoEye, WorldView) (slika 2). Razlog tome možemo pronaći u otvorenom pristupu te vrlo visokoj vremenskoj rezoluciji Landsat i Sentinel snimki.

Iako je broj studija u porastu, istraživanja od posljednjih nekoliko godina u većini su se slučajeva provodila na satelitskim snimkama otvorenog pristupa, s nižim prostornim rezolucijama u odnosu na komercijalne satelitske misije.



Slika 2. Godišnji broj znanstvenih istraživanja koja su se služila satelitskim snimkama visoke i vrlo visoke rezolucije (objavljeni u bazi Web of Science Core Collection (WoSCC) u razdoblju od 2010. do 2020., s temama “tree species” ili “forest” dopunjeno s “remote sensing”).

Cilj je ovog rada pružiti pregled najvažnijih globalnih satelitskih misija i metoda za klasifikaciju drveća iz satelitskih snimaka visoke i vrlo visoke rezolucije. U prvom dijelu je pregled sustava daljinskih istraživanja i tehnologija prikladnih za praćenje šumskog pokrova, dok su u drugom dijelu opisane metodologije daljinskih istraživanja za klasifikaciju šumskog pokrova, s naglaskom na primjene satelitskih snimaka visoke i vrlo visoke rezolucije.


2. Sustavi daljinskih istraživanja za praćenje šumskog pokrova

Prije nego li se pristupi postupku klasifikacije vrsta drveća potrebno je odgovoriti na dva osnovna pitanja koja se odnose na mjerilo: koja je prostorna jedinica te koja je optimalna gustoća uzoraka za pojedini senzor na temelju koje se može dobiti informacija o vrsti (Fassnacht i dr. 2016).

Većina optičkih senzora korištena je za otkrivanje promjena vegetacije (Chen i dr. 2019). Obično je potrebno postići kompromis između prostorne i vremenske rezolucije. Prema prostornoj rezoluciji, kao važnom čimbeniku koji treba uzeti u obzir, satelitske se misije opažanja Zemlje dijele (Gašparović 2019):

- na srednje rezolucije (100–1000 m): MERIS, MODIS, AVHRR/2 NOAA
- na visoke rezolucije (10–100 m): Hyperion, ASTER, Sentinel-2, Landsat 1–8
- na vrlo visoke rezolucije (<10 m): WorldView 2–4, GeoEye 1, QuickBird, IKONOS, PlanetScope, RapidEye 1–5.

Satelitski senzori visoke i vrlo visoke rezolucije imaju široku primjenu pri praćenju šumskog pokrova. Senzori veće prostorne rezolucije u pravilu mogu s većom točnošću otkriti promjene vegetacije, ali njihova je vremenska rezolucija obično niža, što ometa intenzivno vremensko praćenje. Satelitske snimke vrlo visoke prostorne rezolucije kao nedostatak obično imaju problem s obradom zbog potrebe za snažnijim hardverskim sustavom i duljim razdobljem obrade podataka. Također im je nedostatak problem sa sjenama kao i problem dostupnosti zbog cijene, a često arhivske satelitske snimke vrlo visoke rezolucije nisu ni dostupne za određeno područje (Gašparović i dr. 2018a). Prema tome, zbog tehničkih i financijskih ograničenja, ne postoje idealne satelitske snimke te je ključno odabrati satelitske snimke s odgovarajućom prostornom, vremenskom, spektralnom i radiometrijskom rezolucijom u skladu sa svojstvima objekta klasifikacije. Odabir satelitske misije, odnosno satelitskih snimaka odgovarajuće prostorne rezolucije u skladu je s minimalnom veličinom objekta koji se želi detektirati. Prostorna rezolucija, komparativno prikazana na slici 3, ima znatan utjecaj na rezultate klasifikacije. Satelitska snimka veće prostorne rezolucije uvelike smanjuje problem s miješanim pikselima, a ujedno predstavlja veliki potencijal za dobivanje velikog broja detaljnijih informacija (Suwanprasit i Srichai 2012, Fisher i dr. 2018).



Slika 3. Usporedba prostorne rezolucije različitih multispektralnih satelitskih misija (WorldView-3, PlanetScope, Sentinel-2 i Landsat 8) snimljene na bliski datum.

2.1. Satelitski sustavi visoke i vrlo visoke rezolucije

2.1.1. Landsat, Sentinel-2

Landsat je jedna od najdugovječnijih i najuspješnijih satelitskih misija u povijesti, nastala suradnjom američke svemirske agencije (NASA) i američke geološke službe (USGS). Prvi satelit Landsat 1 lansiran je 23. lipnja 1972. Danas se Landsat program sastoji od niza satelitskih misija (Landsat 1 – Landsat 8) koje se kontinuirano unaprjeđuju. Zanimljivo je kako je satelit Landsat-5 ušao u Guinnessovu knjigu rekorda kao najdugovječniji operativni satelit u povijesti (URL 1). Landsat-8, najnoviji Landsatov satelit, lansiran je 11. veljače 2013. godine (URL 2). Prostorne rezolucije Landsat senzora postupno su poboljšavane s 80 m za MSS senzore (engl. Multispectral Scanner) na 30 m (15 m za pankromatske snimke) za TM senzore (engl. Thematic Mapper) (Chen i dr. 2019). Rezolucije na toj razini prikladne su za praćenje dinamike gotovo svih vrsta vegetacije te su kao takvi jedan od najznačajnijih globalnih izvora kronoloških podataka (Gutman i Masek 2012). Posljednjih godina arhivi snimki postali su besplatni i javno dostupni na USGS portalu (<https://earthexplorer.usgs.gov>) što je znatno intenziviralo upotrebu satelitskih snimki Landsat.

Kao znatan doprinos pozitivnom trendu globalnih opažanja, Europska svemirska agencija (ESA) je 2012. godine uspostavila novi sustav optičkih satelitskih opažanja nazvan Sentinel-2. Sentinel sustav sastoji se od dva identična satelita, Sentinel-2a (lansiran 23. lipnja 2015. godine) i Sentinel-2b (lansiran 7. ožujka 2017. godine) (URL 3). Dva satelita rade istovremeno, fazno su međusobno usmjereni na 180°, u orbiti na srednjoj nadmorskoj visini od 786 km. Uz globalnu pokrivenost Zemljine površine kroz 10 dana s jednim satelitom i 5 dana s dva satelita, Sentinel-2 pruža visoku razinu kvalitetne multispektralne slike s prostornim rezolucijama u rasponu od 10 m do 60 m (URL 4). ESA je omogućila besplatan pristup i korištenje Sentinel proizvoda na web portalu: <https://scihub.copernicus.eu/>.

Za razliku od navedenih javno dostupnih, trenutačno se u orbiti nalazi i niz komercijalnih satelita sa sensorima visoke (10–100 m) i vrlo visoke rezolucije (<10 m) (tablica 1). Prvi komercijalni satelit vrlo visoke rezolucije, IKONOS, lansiran je 24. rujna 1999. godine (URL 5). Od tada pa do danas, tehnološkim napretkom optičkih senzora omogućeno je vrlo precizno razlučivanje vegetacije na snimkama.

Tablica 1. *Satelitske snimke vrlo visoke rezolucije (Gomes i Maillard 2016, Chen i dr. 2019), s prostornim rezolucijama i spektralnim kanalima.*

Satelit	Datum lansiranja	Px rezolucija* (m)	Mx rezolucija* (m)	Multispektralni kanali
Ikonos II	24.09.1999.	0,82	3,2	Blue, Green, Red, Near IR
QuickBird	18.10.2001.	0,65	2,62	Blue, Green, Red, Near IR
WorldView-1	18.09.2007.	0,46	–	–
Geoeye-1	06.09.2008.	0,46	1,84	Blue, Green, Red, Near IR
RapidEye	29.08.2008.	5,00	5,0	Blue, Green, Red, Red Edge, Near IR
WorldView-2	08.10.2009	0,46	1,85	Coastal, Blue, Green, Yellow, Red, Red Edge, Near IR, Near IR2
Pleiades 1A	17.12.2011	0,50	2,0	Blue, Green, Red, Near IR
Pleiades 1B	02.12.2012.	0,50	2,0	Blue, Green, Red, Near IR
Kompsat-3	17.05.2012.	0,70	2,8	Blue, Green, Red, Near IR
Ziyuan III-01	09.01.2012.	2,10	2,5	Blue, Green, Red, Near IR
SkySat-1	21.11.2013.	0,90	2,0	Blue, Green, Red, Near IR
Gaofen 1–7	26.04.2013. –03.11.2019.	2,0	8,0	Blue, Green, Red, Near IR
WorldView-3	13.08.2014.	0,31	1,24	Coastal, Blue, Green, Yellow, Red, Red Edge, Near IR, Near IR2
SkySat-2	08.06.2014.	0,9	2,0	Blue, Green, Red, Near IR
PlanetScope	09.01.2014.	3,0	3,0	Blue, Green, Red, Near IR
Kompsat-3A	25.03.2015.	0,55	2,2	Blue, Green, Red, Near IR
WorldView-4	11.11.2016.	0,34	1,36	Blue, Green, Red, Near IR
* Pankromatska (Px) i Multispektralna (Mx) rezolucija u nadiru.				

2.1.2. WorldView, PlanetScope

DigitalGlobe (<https://www.digitalglobe.com>) osnovan je kao WorldView Imaging Corporation 1992. godine. Tvrtka je pokrenula svoj prvi komercijalni satelit za promatranje Zemlje EarlyBird-1 1997. godine. Godine 1999. pokrenut je Ikonos, QuickBird 2001., WorldView-1 2007., GeoEye-1 2008., WorldView-2 2009., WorldView-3 2014. i WorldView-4 2016 (tablica 1). Najnoviji, WorldView-4 pruža visoku razinu kvalitete s prostornim rezolucijama u rasponu od 31 cm za pankromatske te 1,24 m za multispektralne snimke. WorldView-4 senzor sastoji se od četiri spektralna kanala od kojih su tri u vidljivom (plavi 450–510 nm, zeleni 510–580 nm i crveni 655–690 nm) i jedan u blizu infracrvenom (NIR 780–920 nm) dijelu spektra.

Planet (<https://www.planet.com>), tvrtka koja je osmislila i pokrenula seriju mikrosatelita nazvanih “Doves” ili PlanetScope čini najveću konstelaciju satelita za snimanje Zemlje. Prva su dva satelita (Dove 3 i Dove 4) lansirana 21. studenoga 2013. Danas se sastoji od 180+ PlanetScope i 21 SkySat u orbiti (URL 6). PlanetScope se sastoji od pet spektralnih kanala (plavi 455–515 nm, zeleni 500–590 nm, crveni 590–670 nm, rubno crveni 733–748 nm, blizu infracrveni 780–860 nm) te svakodnevno prikuplja informacije u rezoluciji 3–5 m. SkySat konstelacija satelita operativna je od 2013. godine te omogućuje dobivanje snimaka Zemljine površine sa 450 km visine u prostornoj rezoluciji od 0,86 m za pankromatske i 1,0 m za multispektralne snimke. SkySat senzor sastoji se od četiri spektralna kanala od kojih su tri u vidljivom (plavi 450–515 nm, zeleni 515–595 nm i crveni 605–695 nm), a jedan u blizu infracrvenom (NIR 740–900 nm) dijelu spektra.

U srpnju 2015. Planet je kupio tvrtku Blackbridge Geospatial, koja je vlasnik 5 satelita RapidEye. Prvi satelit RapidEye lansiran je 29. kolovoza 2008. godine. Konstelacija od 5 satelita omogućuje dobivanje snimaka Zemljine površine sa 630 km visine na dnevnoj frekvenciji opažanja u prostornoj rezoluciji od 5,0 m. RapidEye senzor sastoji se od 5 spektralnih kanala od kojih su tri u vidljivom (plavi 440–510 nm, zeleni 520–590 nm i crveni 630–685 nm), jedan u prijelaznom (tzv. Red Edge 690–730 nm) i jedan u blizu infracrvenom (NIR 760–850 nm) dijelu spektra.

Pleiades su također sateliti vrlo visoke rezolucije: Pleiades-1A lansiran 17. veljače 2011. i Pleiades-1B lansiran 2. prosinca 2012. godine. Po prostornoj rezoluciji je sličan GeoEye satelitima (0,5 m za pankromatske i 2,0 m za multispektralne snimke). Pleiades omogućuje, u samo jednom prolazu, prikupljanje stereosnimaka velike površine (1000 km x 1000 km) u vrlo visokoj rezoluciji. Satelit se sastoji od četiri spektralna kanala od kojih su tri u vidljivom (plavi 430–550 nm, zeleni 490–610 nm i crveni 600–720 nm), a jedan u blizu infracrvenom (NIR 750–950 nm) dijelu spektra. Budući da je satelit dizajniran za provedbe hitnih zadataka, snimke su dostupne u razdoblju od šest sati. Zbog toga su neprocjenjiv izvor informacija pri praćenju kriznih situacija (Oštir i Mulahusić 2014).

Drugi su bitan izvor senzora visoke rezolucije kineski sateliti Ziyuan III (ili ZY-3) u prostornoj rezoluciji od 2,1 m za pankromatske i 3,5 m za multispektralne snimke te Gaofen (GF) s 2,0 m za pankromatske i 8,0 m za multispektralne snimke.

Satelit ZY-3-01 lansiran je 9. siječnja 2012., a ZY-3-02 30. svibnja 2016. godine. Zajedno, dva satelita imaju ponovni ciklus oko tri dana. Upotrebljavaju se za nadzor uporabe zemljišta i u ekologiji, u urbanističkom planiranju te za upravljanje katastrofama. GF-1 prvi je u nizu od sedam optičkih satelita visokih rezolucija za promatranje Zemlje kineskog National Space Administration. Analogan je europskom programu Copernicus. Ti sateliti prikupljaju različite vrste podataka o okolišu, uključujući radarske snimke i atmosferska mjerenja te pružaju informacije gotovo u stvarnom vremenu. Upotrebljavaju se za prevenciju i pomoć pri katastrofama, praćenje klimatskih promjena, geografsko mapiranje, kao i za potporu u poljoprivredi. Međutim, nedostatak je otežan pristup podacima za korisnike izvan Kine.

3. Metode obrade i analize satelitskih snimaka

Obrada i analiza podataka prikupljenih jednom od prethodno opisanih satelitskih misija općenito se može svrstati u tri skupine: vizualna, kvantitativna i kvalitativna (Radočaj i dr. 2020). Predobrada satelitske snimke preduvjet je za obradu i analizu bilo kojom metodom (Phiri i dr. 2018). Postupak predobrade sastoji se od niza korekcija specifičnih za svaku pojedinačnu satelitsku misiju. Vizualna je analiza najjednostavnija i ima relativno ograničene mogućnosti pri interpretaciji podataka daljinskih istraživanja. Obično se primjenjuje pri identifikaciji i praćenju generaliziranih klasa zemljišnog pokrova (Ban i dr. 2017). Vizualna interpretacija primjenjiva je na multispektralnim snimkama pri čemu se upotrebljavaju RGB kompozicije različitih spektralnih kombinacija koje najbolje prikazuju specifičnosti klasificiranog područja.

Kvantitativni pristup pretežno se temelji na primjeni multispektralnih snimaka, pri čemu se kombiniraju vrijednosti piksela nekoliko različitih spektralnih kanala. Određeno svojstvo promatranog područja kvantificira se primjenom spektralnih indeksa, na način da je vrijednost određenog svojstva proporcionalna vrijednosti izračunatog spektralnog indeksa (Tran i dr. 2018).

Kvalitativna evaluacija određenog područja zasniva se na klasifikaciji spektralnih vrijednosti piksela ili objekata u skladu s prethodno definiranim brojem klasa (Radočaj i dr. 2020). Takav je pristup fleksibilan u smislu odabira spektralnih vrijednosti kao ulazne komponente klasifikacije. Pri klasifikaciji šumskog pokrova, različite vrste drveća daju različite spektralne zapise multispektralnih snimaka. U krošnjama drveća količina zračenja koja se odbija u pojasevima različitih valnih duljina povezana je s biljnim kemijskim svojstvima tkiva, morfologijom listova kao i strukturom (Clark i dr. 2005, Leckie i dr. 2005). Različite studije govore o važnosti pojedinih kanala pri klasifikaciji pojedinih vrsta drveća (Immitzer i dr. 2012, Waser i dr. 2014). Tako su određene studije naglasile posebnu važnost područja plave valne duljine (Key i dr. 2001, Waser i dr. 2014, Peerbhay i dr. 2014), dok su studije Adelabu i dr. (2013) i Peerbhay i dr. (2014) pokazale manju važnost rubnoga crvenog kanala multispektralne snimke.

Postupak klasifikacije satelitske snimke može se podijeliti na nekoliko koraka (Bakker i dr. 2004):

- odabir i predobrada satelitske snimke
- priprema područja za trening
- odabir algoritma za klasifikaciju
- provedba klasifikacije
- prepoznavanje klasa
- ocjena točnosti klasifikacije.

3.1. Predobrada satelitskih snimaka

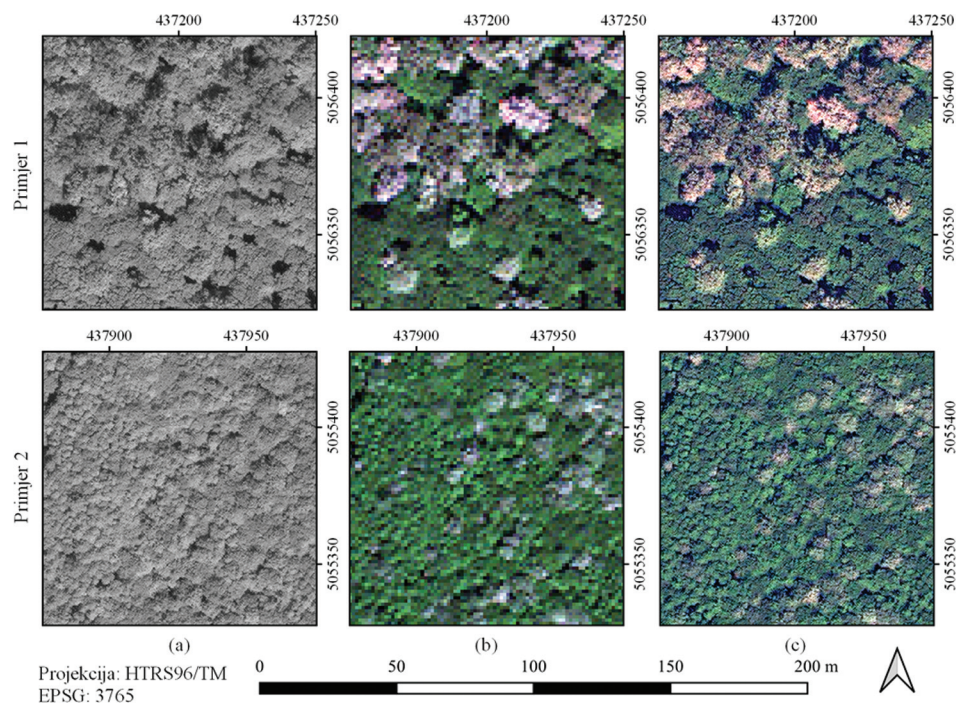
Nakon odabira odgovarajućih satelitskih snimaka, slijedi postupak predobrade snimaka. Predobrada može biti podijeljena na četiri dijela (Gašparović 2020): uklanjanje šuma, radiometrijska i geometrijska korekcija, te fuzija (odnosno izoštravanje, engl. pansharpening). Satelitske snimke, posebno vrlo visoke rezolucije, imaju uobičajenu pojavu šuma. Šum na satelitskim snimkama može se pojaviti u vrijeme promatranja, digitalizacije signala ili u procesu prijenosa podataka. Također, šum može uzrokovati neispravnost uređaja satelita ili satelitskog senzora.

Radiometrijska korekcija važan je korak u predobradi satelitskih snimaka budući da se klasifikacija obavlja na temelju radiometrijskih vrijednosti. Radiometrijska korekcija uključuje: atmosfersku korekciju, korekciju visine sunca i korekciju udaljenosti Zemlja–Sunce, kao i radiometrijsku normalizaciju i izjednačenje histograma. Jedan od osnovnih procesa radiometrijske korekcije jest transformacija satelitskih snimaka u vrijednosti refleksije na vrhu atmosfere (engl. Top of Atmosphere Reflectance – TOA) odnosno atmosferska korekcija. Transformacija snimaka iz digitalnog broja (engl. Digital Number – DN) u vrijednosti refleksije TOA obavlja se pomoću parametara dostavljenih zajedno sa satelitskim snimkama (različito za svaki kanal). Atmosferska korekcija nužan je proces ako se upotrebljavaju podaci više različitih platformi (npr. kombinacija Landsat-5, 7, 8 i Sentinel-2) (Gašparović 2020) ili se podaci satelitskih mjerenja direktno uspoređuju s fizičkim mjerenjima na Zemlji (Lillesand i dr. 2015). Pri klasifikaciji vrsta drveća metodama daljinskih istraživanja teorijski važnu ulogu ima atmosferska korekcija posebice ako su snimke prikupljane kroz duže vremensko razdoblje i za veće geografsko područje. U oba slučaja pretpostavka je da atmosferski uvjeti neće biti isti za sve snimke. Brojne studije koje se bave istraživanjem klasifikacije vrsta drveća primjenjuju atmosferske korekcije, međutim samo rijetke (Pu i dr. 2015, Korpela i dr. 2014) istražuju utjecaj korekcije na dobivene rezultate. Pu i dr. (2015) u svome su radu usporedili tri metode atmosferskih korekcija pri klasifikaciji sedam vrsta drveća iz WorldView-2 snimaka. Zaključili su da ni jedan od algoritama atmosferske korekcije ne poboljšava točnost klasifikacije. Slično tome, Korpela i dr. (2014) zaključuju da

refleksijska kalibracija snimaka ima jako malen utjecaj na točnost klasifikacije vrsta drveća. Međutim, obje studije ističu da su ti rezultati vjerojatno slijed razmjerno malih skupova podataka koji su se sastojali od pojedinačne snimke (Pu i dr. 2015) ili su prikupljeni tijekom relativno kratkog vremenskog razdoblja (Korpela i dr. 2014).

Satelitske snimke također zahtijevaju određene geometrijske korekcije prije nego li se pristupi postupku mapiranja terena, posebice ako se rade prostorno-vremenske analize. Osnovni postupak geometrijske predobrade podataka bilo kojih satelitskih platformi jest rezanje (engl. clipping) snimaka prema području interesa. Budući da se satelitske snimke isporučuju uglavnom u WGS84 ili WGS84/UTM (engl. World Geodetic System/Universal Transverse Mercator) projekcijskom koordinatnom sustavu, nužna je i transformacija u odabrani koordinatni sustav, tj. HTRS (Hrvatski Terestrički Referentni Sustav). Geometrijske distorzije mogu biti uzrokovane različitim čimbenicima kao što su: zakrivljenost Zemlje, topografija terena ili korekcija terena (Richter 1998). Radi eliminacije utjecaja terena na satelitsku snimku nužno je provesti proces ortorektifikacije snimaka, kojim se izvorna snimka iz centralne projekcije transformira u ortogonalnu projekciju (Gašparović i dr. 2019). Procesom ortorektifikacije smanjuje se topografski utjecaj terena te se ostvaruje bolja geometrijska povezanost između točaka na terenu i njihova položaja na pripadajućoj snimci (Campbell i Wynne 2011).

Radi poboljšanja prostorne rezolucije satelitskih snimaka danas se često primjenjuje postupak fuzije ili izoštravanja (engl. pansharpening). Satelitski senzori prikupljaju pankromatske snimke (PAN) s boljom prostornom rezolucijom i multispektralne snimke (MS) s lošijom prostornom, ali boljom spektralnom rezolucijom. Fuzijom se prostorna rezolucija snimke (multispektralni kanal) povećava matematičkim metodama uz pomoć snimaka veće prostorne rezolucije (pankromatski kanal). Posljednjih godina razvile su se različite metode fuzije koje se mogu podijeliti na dvije skupine: metode supstitucije komponenta i metode analize s više rezolucija (Li i dr. 2017). Razvija se i nova generacija metoda zasnovanih na dubokom strojnom učenju. Iako postoji mnogo različitih algoritama fuzije, nisu svi prikladni za kvantitativne analize (Gilbertson i dr. 2017). Budući da se neka spektralna svojstva izvornih multispektralnih informacija mogu izgubiti tijekom postupka fuzije, pojedini su algoritmi dizajnirani tako da maksimaliziraju spektralno očuvanje. Prema Ghosh i Joshi (2013), odabir odgovarajuće fuzijske metode ovisi: o korisničkom iskustvu, algoritmi-ma, izboru parametara i području istraživanja. Također, fuzijske metode se mogu primijeniti i na kombinaciju podataka s različitih satelita (Gašparović i dr. 2018b). Spektralni, radiometrijski i prostorni integritet fuzioniranih snimaka ključni su u klasifikaciji vrsta drveća. Slika 4 daje dva primjera unutar istog područja istraživanja u pankromatskom i multispektralnom prikazu.



Slika 4. Fuzija satelitskih snimaka vrlo visoke rezolucije WorldView-3 (na dan 12.06.2017) u svrhu klasifikacije šumskog pokrova. (a) originalni pankromatski kanal u 0,5 m prostornoj rezoluciji, (b) true-color kompozit originalnih multispektralnih kanala (RGB, 5-3-2) u 2,0 m prostornoj rezoluciji i (c) fuzionirani kompozit u 0,5 m prostornoj rezoluciji.

3.2. Klasifikacija satelitskih snimaka

Glavni je cilj klasifikacije grupiranje svih pikseli satelitske snimke u određenu klasu. Može se izvoditi na temelju podataka iz samo jednoga spektralnog kanala ili uporabom više kanala (Olujić 2001).

S obzirom na minimalnu veličinu objekta klasifikacije postoje dva pristupa:


- klasifikacija zasnovana na pikselima (engl. Pixel-based classification)
- objektna klasifikacija (engl. Object-based classification).

Klasifikacija zasnovana na pikselima temelji se na principu da, u skladu sa spektralnim svojstvima, svaki piksel predstavlja jednu od klasa. U klasifikaciji šumskog pokrova, spektralne klase odgovaraju klasama vrste vegetacije i

izravno su povezane sa spektralnim kanalima koji se upotrebljavaju u klasifikaciji. Nedostatak klasifikacije zasnovane na pikselima jest činjenica da se svakom pojedinom pikselu dodjeljuje jedna klasa, dok u stvarnosti takva jedna ćelija piksela može predstavljati nekoliko različitih klasa. Jedna klasa može biti predstavljena s više različitih uzoraka za trening zbog čega se javlja varijabilnost spektralnih odziva unutar same spektralne klase. U tom slučaju će se vrijednost piksela računati na osnovi različitih spektralnih vrijednosti klasa što je uzrok nastanka “miješanih” piksela. Miješani pikseli najčešće se pojavljuju na rubovima pojedinih objekata ili uzduž linearnih objekata (prometnice i sl.) i kao takvi izvor su pogrešaka u procesu klasifikacije (Bakker i dr. 2004). Osim toga, klasifikaciju zasnovanu na pikselima obično karakterizira šum “salt-and-paper”, koji je posebno izražen u klasifikaciji satelitskih snimaka vrlo visoke rezolucije (slika 5).

Primjenom objektno orijentiranog pristupa, analiza snimke provodi se u domeni objekata, a ne više u domeni piksela. Proces objektno orijentirane klasifikacije započinje razlaganjem digitalne snimke na manje homogenizirane dijelove (objekte) sličnih karakteristika, tj. postupkom segmentacije. Kreirani novonastali objekti potom se klasificiraju u određen broj klasa primjenom neke od metoda klasifikacije.

Segmentacijom se satelitska snimka razlaže na spektralno homogene segmente koji odgovaraju stvarnim objektima u prirodi. Takvi objekti tvore entitete koji mogu imati različite statističke pokazatelje, kao što su standardna devijacija, maksimum, minimum i dr., što kod analize pojedinačnih piksela nije moguće (Campbell i Wynne 2011). Osim radiometrijskih svojstava segmentacija se fokusira i na semantička svojstva svakog segmenta, na strukturu slike te na druge pozadinske informacije čije vrijednosti opisuju povezanost susjednih piksela (boja, intenzitet, tekstura, oblik, kontekst, dimenzionalni odnosi i položaj) (De Luca i dr. 2019). Odabirom odgovarajućih parametara, dobro definirana segmentacija ključ je dobre klasifikacije. Budući da do danas još uvijek ne postoji metoda ni unaprijed definirani parametri segmentacije, vizualna je interpretacija jedina preporučena metoda za ocjenu kvalitete segmentacije (Drăguț i dr. 2014, Clinton i dr. 2010, Prošek i Šimová 2019). U odnosu na klasifikaciju zasnovanu na pikselima, objektno orijentirani pristup prikladniji je za snimke visoke i vrlo visoke prostorne rezolucije (Blaschke 2010, Benz i dr. 2004). Mnogi su autori radili direktne usporedbe za oba navedena pristupa pri čemu je, za područja kompleksnih šumskih struktura, objektno orijentirani pristup rezultirao većom klasifikacijskom točnošću (Immitzer i dr. 2016, Clark i Roberts 2012, Feret i Asner 2013). Međutim, oba pristupa imaju svoje prednosti i nedostatke (Ibarrola-Ulzurrun i dr. 2017). U postupku klasifikacije zasnovane na pikselima, bolja je kvaliteta podataka koji ulaze u klasifikaciju, te se kao rezultat dobije raster čiji svaki piksel predstavlja jednu od klasa, pri čemu su klase ograničene samo na spektralna svojstva. Također, nedostatak su miješani pikseli koji se javljaju na rubovima klasa. S druge strane, točnost objektno orijentirane klasifikacije uvelike ovisi o točnosti segmentacije. Slika 5 daje komparativan prikaz dvaju primjera klasifikacije zasnovane na pikselima i objektno orijentirane klasifikacije satelitske snimke WorldView-3 primjenom klasifikatora Random Forest (RF).



Slika 5. Klasifikacija šumskog pokrova primjenom satelitskih snimaka vrlo visoke rezolucije WorldView-3 (na dan 12.06.2017) (a) fuzionirani kompozit (RGB, 5-3-2) u 0,5 m prostornoj rezoluciji, (b) RF klasifikacija zasnovana na pikselima, (c) objektno orijentirana RF klasifikacija.

Oba navedena pristupa, i klasifikacija zasnovana na pikselima i klasifikacija zasnovana na objektima, mogu se grupirati na (Abburu i Golla 2015, Lillesand i dr. 2015):

- nadzirane (poluautomatske) klasifikacijske metode
- nenadzirane (automatske) klasifikacijske metode
- hibridne klasifikacijske metode.

3.2.1. Nenadzirana klasifikacija

Nenadzirana klasifikacija automatizirana je klasifikacija zasnovana na definiranom broju klasa. Nije potrebno poznavanje klasificiranog područja ni definiranje uzoraka. Algoritam automatski klasificira cijelu satelitsku snimku grupirajući piksele na temelju radiometrijskih svojstava. Takav oblik

klasifikacije odvija se potpuno automatski i isključuje bilo kakav manualni rad (npr. definiranje uzoraka). Postupak nenadzirane klasifikacije dijeli se na (Oštir i Mulahusić 2014):

- grupiranje (udruživanje u klase)
- prepoznavanje klasa.

Grupiranjem se višedimenzionalni podaci udružuju u skupine i grupe, dok se prepoznavanjem klasa određuje koje se klase nalaze na snimci i dodjeljuju im se odgovarajuće oznake.

Prednosti nenadzirane klasifikacije u odnosu na nadziranu (Campbell i Wynne 2011):

- ne zahtijeva prethodno poznavanje terena
- mogućnost interpretatorove pogreške je minimalna
- neke jedinstvene klase prepoznaju se kao zasebne jedinice (klase malih površina neće ostati neprepoznate).

Nedostaci nenadzirane klasifikacije:

- ograničena kontrola interpretatora
- spektralna će se svojstva pojedinih klasa mijenjati tijekom vremena
- razvrstavanje snimke u previše ili premalo klasa.

Danas postoje mnogobrojni algoritmi nenadzirane klasifikacije među kojima su najčešće korišteni ISODATA (Arockiaraj i dr. 2015) i *k*-means (Saha i dr. 2020).

3.2.2. Nadzirana klasifikacija

Nadzirana klasifikacija zahtijeva aktivnu ulogu interpretatora te podrazumijeva upotrebu njegovih znanja i iskustava prilikom definiranja uzoraka. Postupak nadzirane klasifikacije dijeli se na (Oštir i Mulahusić 2014):

- stvaranje i uređivanje uzoraka
- razvrstavanje u klase (klasifikacija).

U nadziranoj klasifikaciji prvi je i najvažniji korak kvalitetan odabir uzoraka za trening koji će predstavljati pojedine klase. Uzorci za trening i testiranje moraju zadovoljiti određene uvjete (Belgiu i Drăguț 2016):

- statističku neovisnost

- ravnomjernu raspoređenost uzoraka unutar klasa
- svaki uzorak mora reprezentativno predstavljati klasu kojoj pripada
- dovoljnu veličinu uzorka u skladu s povećanim brojem različitih dimenzija podataka.

Nadzirana metoda klasifikacije u pravilu daje točnije rezultate u odnosu na nenadziranu metodu. Danas postoje mnogobrojni algoritmi nadzirane klasifikacije. Neke su od tradicionalnih metoda (Gašparović 2020) klasifikacija s maksimalnom sličnošću (engl. Maximum likelihood classification) i metoda minimalne udaljenosti (engl. Minimum-distance to means classification), dok se u novije vrijeme upotrebljavaju napredniji modeli zasnovani na metodi strojnog učenja: metoda temeljena na neuronskim mrežama (eng. Artificial Neural Network – ANN), metoda potpornih vektora (engl. Support Vector Machines – SVM) i metoda slučajnih šuma (engl. Random Forest – RF).

3.2.3. Hibridna metoda klasifikacije

Hibridne metode (Gašparović 2020) kombinacija su nadziranih i nenadziranih metoda. Nakon što se provede nadzirana klasifikacija, neke klase moguće je dodatno produbiti, tj. klasificirati algoritmima nenadzirane klasifikacije. Ta se metoda često primjenjuje kada operater nije u mogućnosti jasno definirati razlike između vrsta podrazreda. Jedna od hibridnih metoda jest klasifikacija zasnovana na pravilima (engl. Rule-based classification). Nadzirana klasifikacija temeljena na pravilima u većini slučajeva se upotrebljava pri objektu orijentiranoj analizi snimke. Proučavanjem odnosa između svojstva objekata i potencijalnih klasa konstruira se model stabla temeljen na pravilima (Cohen i Shoshany 2002).

3.3. Algoritmi klasifikacije

Točnost klasifikacije može ovisiti o mnogobrojnim različitim parametrima među kojima je i izbor odgovarajućeg algoritma klasifikacije (Lu i Weng 2007). Među najčešćima su algoritam slučajnih šuma (engl. Random Forest – RF) i metoda potpornih vektora (engl. Support Vector Machine – SVM) u nadziranim metodama te algoritam k -sredine (engl. k -means) u nenadziranim metodama.

Random Forest (RF) je algoritam automatskog učenja što ga je uveo Breiman (2001) i poslije unaprijedila Adele Cutler (2007). Nadzirana RF klasifikacija pokazala se vrlo važnom u razdvajanju klasa na temelju spektralnih svojstava prilikom klasifikacije vrsta drveća. RF metoda temelji se na izgradnji stabla odluke (engl. decision tree). Iz trening podataka nasumično se uzimaju uzorci na temelju kojih algoritam gradi “šumu” stabala pri čemu svako stablo ovisi

o slučajno kreiranom podskupu ulaznih varijabli kako bi se odredilo mjesto grananja. Tijekom postupka klasifikacije svako će pojedino stablo dati “glas” jednoj od klasa unutar skupa (Breiman 2001). Rezultat je klasa s najviše “glasova”. Mnogobrojna su se istraživanja bavila usporedbom i analizom točnosti metode Random Forest s drugim metodama pri čemu je zaključeno da metoda RF daje bolje rezultate klasifikacije pri radu s višedimenzionalnim podacima.

Immtzer i dr. (2016) utvrdio je da zadane vrijednosti parametara Orfeo Tool-Box (OTB) za procese treninga pružaju optimalne rezultate. Prema Belgiju i Drăguț (2016), mnogobrojna su istraživanja proučavala utjecaj parametara nTree i Mtry na točnost RF klasifikatora. Najčešća je preporuka da se za vrijednost parametra broj stabala (nTree) odabere 500, te za Mtry da se odabere kvadratni korijen broja ulaznih varijabli.

SVM algoritam razvili su Cortes i Vapnik (1995). Zasnovan na temelju statističke teorije učenja, SVM algoritam definira hiperravninu koja klasificira sve vektore iz trening podataka u dvije ili više klasa. Budući da granica navedene ravnine između zadanih klasa nije linearna, upotrebljava se pristup jezgre (engl. kernel). Jezgra, odnosno funkcija K , zamjenjuje unutarnje produkte koji se pojavljuju prilikom računanja (Dobrinić i dr. 2019). Najčešće su korištene jezgre: linearna, polinomna i radijalna. Usporedbom i analizom točnosti SVM metode s drugim metodama pokazalo se da je SVM neosjetljiv na visoku dimenzionalnost podataka i robusan u pogledu malih veličina uzoraka.

Nenadzirana metoda k -means analizira ulazne rastere radi dijeljenja n podataka na k grupa pri čemu se svaki podatak pridružuje najbližem centroidu (središtu klasa) koji predstavlja određenu grupu. Algoritam k -means je iterativan. Pikseli se iterativno pridružuju najbližoj klasi, nakon čega se računaju novi centriodi. Novi centroid je točka koja minimizira zbroj kvadrata udaljenosti između piksela u klasi i centroidu. Centroid se iterativno pomiče što utječe na daljnje pridruživanje piksela nekoj klasi. Proces se zaustavlja kad pomaci centroida postanu manji od unaprijed definiranog praga ili ako je postignut maksimalan broj iteracija.

3.4. Ocjena točnosti klasifikacije

Nakon provedene klasifikacije satelitske snimke, utvrđuje se njezina točnost. Ocjena točnosti provodi se na temelju testnih uzoraka koji predstavljaju referentne podatke.

Matrica konfuzije ili matrica pogrešaka, kao jedan od najčešće korištenih načina ocjene točnosti klasifikacije, uspoređuje klasificirani raster s referentnim podacima te za svaku od klasa daje broj ispravno i pogrešno klasificiranih piksela. Podaci na dijagonalama ispravno su klasificirani pikseli, dok su pikseli izvan dijagonale predstavljaju pogrešno klasificirani pikseli.

Ukupna točnost klasifikacije definirana je kao omjer ispravno klasificiranih dijagonalnih piksela naspram ukupnog broja piksela. Osim ukupne točnosti, matrica konfuzije omogućava ocjenu točnosti po klasama i utvrđivanje pogrešaka gubljenja (engl. Omission error) i pogrešaka dodavanja (engl. Commission error).

error). Pogreška gubljenja nastaje kada se dio uzoraka promatrane klase raspodijeli u druge klase, a pogreška dodavanja kada se dio uzoraka drugih klasa raspodijeli u promatranu klasu. Točnost proizvođača (engl. Producers accuracy) i točnost korisnika (engl. Users accuracy) također omogućuju ocjenu točnosti po klasama. Izračunati su dijeljenjem broja ispravno klasificiranih piksela u svakoj kategoriji s ukupnim brojem piksela u odgovarajućem stupcu (točnost proizvođača) ili retku (točnost korisnika). Osim matrice konfuzije, točnost između referentnih i testnih podataka može se dati i statističkim pokazateljem kappa, detaljno izloženim u radu Cohen (1960). Kappa računa slaganje u oznakama dvaju označivača, ali korigirano s obzirom na vjerojatnost slučajnog slaganja (engl. Chance-corrected agreement). Prikazan je izrazom (Cohen 1960):

$$k = \frac{p_0 - p_e}{1 - p_e}, \quad (1)$$

gdje je p_0 ostvareno slaganje i p_e očekivano slaganje. Autori Viera i Garrett (2005) prema vrijednosti kappa koeficijenta definiraju različite razine točnosti. Tako su vrijednosti između 0,41 i 0,60 umjerena točnost, vrijednosti između 0,61 i 0,80 visoka točnost, dok su vrijednosti veće od 0,80 vrlo visoka točnost klasifikacije. Međutim, zbog određenih ograničenja kappa koeficijenta neki od autora predlažu upotrebu faktora kakvoće (engl. Figure of Merit) detaljno izložen u radu Pontius i Millones (2011), a prikazan izrazom:

$$FoM = \frac{OA}{OA + O + C}, \quad (2)$$

gdje je OA ukupna točnost, O je pogreška gubljenja i C pogreška dodavanja.

4. Zaključak

Metode i tehnike daljinskih istraživanja te uporaba snimaka visokih prostornih rezolucija omogućuju automatsku segmentaciju i klasifikaciju šumskog pokrova vrlo visoke točnosti. Tijekom posljednjih nekoliko desetljeća razvijene su mnogobrojne javno dostupne i komercijalne satelitske misije koje pružaju velike količine podataka različitih prostornih, spektralnih, radiometrijskih i vremenskih rezolucija. U skladu sa svojstvima objekta klasifikacije ključno je odabrati satelitske snimke s odgovarajućom rezolucijom. Prema prethodnim istraživanjima koja su analizirala utjecaj promjene prostorne rezolucije, veća prostorna rezolucija pruža veću točnost rezultata klasifikacije. Brzi razvoj različitih senzora daljinskog istraživanja rezultirao je razvojem različitih metoda i tehnika za klasifikaciju različitih vrsta šumskih podataka iz satelitskih snimaka. Razvoj novih metoda klasifikacija omogućuje povećanje kvantitativne i kvalitativne vrijednosti dobivenih informacija u šumarstvu. Ključni

je doprinos razvoj automatskih metoda baziranih na hibridnom principu, tj. kombinacija nadzirane i nenadzirane klasifikacije s mogućnošću automatskog određivanja uzoraka za provođenje nadziranih klasifikacija. Navedene tehnike i metode mogu se primijeniti u mnogim drugim geoznanostima i ostalim područjima poput ekologije, hidrologije, poljoprivrede i dr.

ZAHVALA. Ovaj je rad nastao u sklopu istraživanja koje je financirala Hrvatska zaklada za znanost projektom IP-2016-06-7686 "Uporaba podataka daljinskih istraživanja dobivenih različitim 3D optičkim izvorima u izmjeri šuma (3D-FORINVENT)" i Sveučilište u Zagrebu projektom "Napredne metode fotogrametrije i daljinskih istraživanja za praćenje promjena u okolišu (RS4ENVIRO)".

Literatura

- Abburu, S., Golla, S. B. (2015): Satellite image classification methods and techniques: a review, *International Journal of Computer Applications*, 119, 8.
- Adelabu, S., Mutanga, O., Adam, E., Cho, M. A. (2013): Exploiting machine learning algorithms for tree species classification in a semiarid woodland using RapidEye image, *Journal of Applied Remote Sensing*, 7, 1, 073480.
- Arockiaraj, S., Kumar, A., Hoda, N., Jeyaseelan, A. T. (2015): Identification and quantification of tree species in open mixed forests using high resolution QuickBird satellite imagery, *Journal of Tropical Forestry and Environment*, 5, 2, 40–53.
- Bakker, W. H., Grabmaier, K. A., Hunneman, G. C., Van Der Meer, F. D., Prakash, A., Tempfli, K., Reeves, C. V. (2004): Principles of remote sensing, an introductory textbook, The international institute for geo-informational science and earth observation, Enschede, the Netherlands.
- Ban, H.-J., Kwon, Y.-J., Shin, H., Ryu, H.-S., Hong, S. (2017): Flood Monitoring Using Satellite-Based RGB Composite Imagery and Refractive Index Retrieval in Visible and Near-Infrared Bands, *Remote Sensing*, 9, 313.
- Belgiu, M., Drăguț, L. (2016): Random forest in remote sensing: A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M. (2004): Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry and Remote Sensing*, 58, 3–4, 239–258.
- Blaschke, T. (2010): Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 2–16.
- Breiman, L. (2001): Random Forests, *Machine Learning*, 45, 1, 5–32.
- Campbell, J. B., Wynne, R. H. (2011): Introduction to remote sensing, The Guilford Press, New York, London.

- Chen, Y., Guerschman, J. P., Cheng, Z., Guo, L. (2019): Remote sensing for vegetation monitoring in carbon capture storage regions: A review, *Applied energy*, 240, 312–326.
- Cho, M. A., Mathieu, R., Asner, G. P., Naidoo, L., Aardt, J., Ramoelo, A., Debba, P., Wessels, K., Main, R., Smit, I. P. J., Erasmus, B. (2012): Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system, *Remote Sensing of Environment*, 125, 214–226.
- Cho, M. A., Malahlela, O., Ramoelo, A. (2015): Assessing the utility WorldView-2 imagery for tree species mapping in South African subtropical humid forest and the conservation implications: Dukuduku forest patch as case study, *International Journal of Applied Earth Observation and Geoinformation*, 38, 349–357.
- Clark, M. L., Roberts, D. A. (2012): Species-level differences in hyperspectral metrics among tropical rainforest trees as determined by a tree-based classifier, *Remote Sensing*, 4, 1820–1855.
- Clark, M. L., Roberts, D. A., Clark, D. B. (2005): Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales, *Remote Sensing of Environment*, 96, 3–4, 375–398.
- Clinton, N., Holt, A., Scarborough, J., Yan, L. I., Gong, P. (2010): Accuracy assessment measures for object-based image segmentation goodness, *Photogrammetric Engineering & Remote Sensing*, 76, 289–299.
- Cohen, J. A. (1960): Coefficient of Agreement for Nominal Scales, *Educational and Psychological Measurement*, 20, 37–46.
- Cohen, Y., Shoshany, M. (2002): A National Knowledge – Based Crop Recognition in Mediterranean Environment, *International Journal of Applied Earth Observation and Geoinformation*, 4, 75–87.
- Cortes, C., Vapnik, V. (1995): Support vector network, *Machine Learning*, 3, 273–297.
- Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., Lawler, J. J. (2007): Random Forests for Classification in Ecology, *Ecology*, 88, 2783–2792.
- De Luca, G., Silva, J. M. N., Cerasoli, S., Araújo, J., Campos, J., Di Fazio, S., Modica, G. (2019): Object-Based Land Cover Classification of Cork Oak Woodlands using UAV Imagery and Orfeo Toolbox, *Remote Sensing*, 11, 1238.
- Deur, M., Gašparović, M., Balenović, I. (2020): Tree Species Classification in Mixed Deciduous Forests Using Very High Spatial Resolution Satellite Imagery and Machine Learning Methods, *Remote Sensing*, 12, 3926.
- Dobričić, D., Medak, D., Katanec, A. (2019): Klasifikacija zemljišnog pokrova iz podataka Sentinel satelitskih misija, *Zbornik radova – 12. simpozij ovlaštenih inženjera geodezije, Opatija, 18.–20. listopada 2019.*, 50–55.
- Drăguț, 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.

- FAO and UNEP (2020): *The State of the World's Forests 2020, Forests, biodiversity and people*, Rome.
- Fassnacht, F. E., Latifi, H., Sterenczak, K., Modzelewska, A., Lefsky, M., Wasser, L. T., Straub, C., Ghosh, A. (2016): Review of studies on tree species classification from remotely sensed data, *Remote Sensing Environment*, 186, 64–87.
- Feret, J.-B., Asner, G. P. (2013): Tree Species Discrimination in Tropical Forests Using Airborne Imaging Spectroscopy, *IEEE Transactions on Geoscience and Remote Sensing*, 51, 73–84.
- Fisher, B., Turner, R. K., Morling, P. (2008): Defining and classifying ecosystem services for decision making, *Ecological Economics*, 68, 3, 643–653.
- Fisher, J. R., Acosta, E. A., Dennedy-Frank, P. J., Kroeger, T., Boucher, T. M. (2018): Impact of satellite imagery spatial resolution on land use classification accuracy and modeled water quality, *Remote Sensing in Ecology and Conservation*, 4, 2, 137–149.
- Gašparović, M. (2019): Praćenje urbanizacije u Republici Hrvatskoj metodama daljinskih istraživanja, 11. Dani infrastruktura prostornih podataka, 13.–14. studenoga 2019., Split.
- Gašparović, M. (2020): Urban growth pattern detection and analysis, In *Urban Ecology*, Elsevier, 35–48.
- Gašparović, M., Dobrinić, D., Medak, D. (2018a): Urban vegetation detection based on the land-cover classification of PlanetScope, RapidEye and WorldView-2 Satellite Imagery, In *Proceedings of the 18th International Multidisciplinary Scientific Geo-Conference SGEM2018*, Albena, Bulgaria, 249–256.
- Gašparović, M., Medak, D., Pilaš, I., Jurjević, L., Balenović, I. (2018b): Fusion of Sentinel-2 and PlanetScope imagery for vegetation detection and monitoring, *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 41, 1, 155–160.
- Gašparović, M., Dobrinić, D., Medak, D. (2019): Geometric accuracy improvement of WorldView-2 imagery using freely available DEM data, *The Photogrammetric Record*, 34,167, 266–281.
- Ghosh, A., Joshi, P. K. (2013): Assessment of pan-sharpened very high-resolution WorldView-2 images, *International journal of remote sensing*, 34, 23, 8336–8359.
- Gilbertson, J., Kemp, J., Van Niekerk, A. (2017): Effect of pan-sharpening multi-temporal Landsat 8 imagery for crop type differentiation using different classification techniques, *Computers and Electronics in Agriculture*, 134, 151–159.
- Gomes, M. F., Maillard, P. (2016): Detection of tree crowns in very high spatial resolution images, In *Environmental Applications of Remote Sensing*, Marghany, M. (Ed.), IntechOpen, London, 41–71.
- Gutman, G., Masek, J. G. (2012): Long-term time series of the Earth's land-surface observations from space, *International Journal of Remote Sensing*, 33, 15, 4700–4719.

- Ibarrola-Ulzurrun, E., Gonzalo-Martín, C., Marcello, J. (2017): Influence of Pansharpening in Obtaining Accurate Vegetation Maps, *Canadian Journal of Remote Sensing*, 43, 6, 528–544.
- Immitzer, M., Atzberger, C., Koukal, T. (2012): Suitability of WorldView-2 data for tree species classification with special emphasis on the four new spectral bands, *Photogrammetrie, Fernerkundung, Geoinformation*, 5, 573–588.
- Immitzer, M., Vuolo, F., Atzberger, C. (2016): First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe, *Remote Sensing*, 8, 3, 166.
- ISPRS (2016): Statutes, International society for photogrammetry and remote sensing, Prague, Czech Republic.
- Key, T., Warner, T. A., McGraw, J. B., Fajvan, M. A. (2001): A comparison of multispectral and multitemporal information in high spatial resolution imagery for classification of individual tree species in a temperate hardwood forest, *Remote Sensing of Environment*, 75, 100–112.
- Korpela, I., Mehtätalo, L., Markelin, L., Seppänen, A., Kangas, A. (2014): Tree species identification in aerial image data using directional reflectance signatures, *Silva Fennica*, 48, 3, 1–20.
- Leckie, D. G., Tinis, S., Nelson, T., Burnett, C., Gougeon, F. A., Cloney, E., Paradine, D. (2005): Issues in species classification of trees in old growth conifer stands, *Canadian Journal of Remote Sensing*, 31, 2, 175–190.
- Li, H., Jing, L., Tang, Y. (2017): Assessment of Pansharpening Methods Applied to WorldView-2 Imagery Fusion, *Sensors*, 17, 89.
- Lillesand, T., Kiefer, R. W., Chipman, J. (2015): Remote sensing and image interpretation, John Wiley & Sons, Hoboken, NJ.
- Lu, D., Weng, Q. (2007): A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28, 823–870.
- Majid, I. A., Latif, Z. A., Adnan, N. A. (2016): Tree Species Classification Using WorldView-3 Data, *IEEE 7th Control and System Graduate Research Colloquium*, 73–76.
- Nabuurs, G.-J., Lindner, M., Verkerk, P. J., Gunia, K., Deda, P., Michalak, R., Grassi, G. (2013): First signs of carbon sink saturation in European forest biomass, *Nature Climate Change*, 3, 792–796.
- Olujić, M. (2001): Snimanje i istraživanje Zemlje iz svemira, Hrvatska akademija znanosti i umjetnosti, Zagreb.
- Oštir, K., Mulahusić, A. (2014): Daljinska istraživanja, Građevinski fakultet, Univerzitet u Sarajevu, Sarajevo.
- Peerbhay, K. Y., Mutanga, O., Ismail, R. (2014): Investigating the capability of few strategically placed WorldView-2 multispectral bands to discriminate forest species in KwaZulu-Natal, South Africa, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 1, 307–316.
- Phiri, D., Morgenroth, J., Xu, C., Hermosilla, T. (2018): Effects of pre-processing methods on Landsat OLI-8 land cover classification using OBIA and

- random forests classifier, *International Journal of Applied Earth Observation and Geoinformation*, 73, 170–178.
- Pilaš, I., Gašparović, M., Novkinić, A., Klobučar, D. (2020): Mapping of the Canopy Openings in Mixed Beech–Fir Forest at Sentinel-2 Subpixel Level Using UAV and Machine Learning Approach, *Remote Sensing*, 12, 3925.
- Pontius, R. G., Millones, M. (2011): Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment, *International Journal of Remote Sensing*, 32, 4407–4429.
- Prošek, J., Šimová, P. (2019): UAV for mapping shrubland vegetation: Does fusion of spectral and vertical information derived from a single sensor increase the classification accuracy? *International Journal of Applied Earth Observation and Geoinformation*, 75, 151–162.
- Pu, R., Landry, S., Zhang, J. (2015): Evaluation of atmospheric correction methods in identifying urban tree species with WorldView-2 imagery, *IEEE Journal of selected topics in applied earth observation and remote sensing*, 8, 5, 1886–1897.
- Radočaj, D., Obhodaš, J., Jurišić, M., Gašparović, M. (2020): Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: A Review, *Land*, 9, 402.
- Randerson, J. T., Thompson, M. V., Conway, T. J., Fung, I. Y., Field, C. B. (1997): The contribution of terrestrial sources and sinks to trends in the seasonal cycle of atmospheric carbon dioxide, *Global Biogeochemical Cycles*, 11, 4, 535–560.
- Richter, R. (1998): Correction of satellite imagery over mountainous terrain, *Applied optics*, 37, 18, 4004–4015.
- Saha, A., Sastry, S., Dave, V. A., Ghosh, R. (2020): Evaluation of Tree Species Classification Methods using Multi-Temporal Satellite Images, 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS), Santiago, Chile, 40–43.
- Seletković, A., Pernar, R., Jazbec, A., Ančić, M. (2008): Točnost klasifikacije satelitske snimke visoke prostorne rezolucije IKONOS za potrebe šumarstva, *Šumarski list*, 9–10, 393–404.
- Seletković, A., Pernar, R., Ančić, M., Sučić, J. (2011): Procjena strukturnih elemenata sastojine na temelju vrijednosti spektralnoga odbijanja satelitskoga snimka IKONOS (Assessment of Stand Structural Elements on the Basis of Spectral Reflectance Values of an IKONOS Satellite Image), *Croatian Journal of Forest Engineering*, 32, 1, 329–343.
- Soleimannejad, L., Ullah, S., Abedi, R., Dees, M., Koch, B. (2019): Evaluating the potential of sentinel-2, landsat-8, and irs satellite images in tree species classification of hyrcanian forest of iran using random forest, *Journal of Sustainable Forestry*, 38, 7, 615–628.
- Suwanpravit, C., Srichai, N. (2012): Impacts of spatial resolution on land cover classification, *Proceedings of the Asia-Pacific Advanced Network*, 33, 39.
- Tran, B. N., Tanase, M. A., Bennett, L. T., Aponte, C. (2018): Evaluation of Spectral Indices for Assessing Fire Severity in Australian Temperate For-

ests, *Remote Sensing*, 10, 1680.

Viera, A. J., Garrett, J. M. (2005): Understanding Interobserver Agreement: The Kappa Statistic, *Family Medicine*, 37, 5, 360–363.

Waser, L. T., Kuchler, M., Jütte, K., Stampfer, T. (2014): Evaluating the potential of WorldView-2 data to classify tree species and different levels of ash mortality, *Remote Sensing*, 6, 5, 4515–4545.

Mrežne adrese

URL 1: NASA, https://www.nasa.gov/mission_pages/landsat/news/landsat5-guinness.html, (5.3.2021.).

URL 2: USS science for changing world,
https://www.usgs.gov/core-science-systems/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con, (8.3.2021.).

URL 3: The European Space Agency, http://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2, (8.3.2021.).

URL 4: ESA Earth online,
<https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2>, (8.3.2021.).

URL 5: Satellite imaging corporation,
<https://www.satimagingcorp.com/satellite-sensors/ikonos/>, (8.3.2021.).

URL 6: Planet, <https://www.planet.com/products/planet-imagery/>, (9.3.2021.).

A Review of Satellite Missions and Forest Cover Classification Methods Using High Resolution Satellite Imagery

ABSTRACT. Advances in remote sensing technologies enables increasing achievements in the field of tree species classification. In recent years, significant technological progress and improvements in the characteristics of optical sensors have been made, thus enabling improved resolution of details on satellite imagery (spatial, spectral and radiometric resolution). The increase in spatial resolution had a significant impact on the development of remote sensing techniques and methods. A new generation of very high resolution satellite imagery enables research at local and regional levels and represent a important source of forestry information. The aim of this paper is to provide an overview of global high and very high resolution satellite missions, as well as analysis and processing methodology in forest cover classification. In combination with machine learning algorithms, the application of high and very high resolution satellite imageries reduces the need for labor-intensive and time-consuming traditional field methods while increasing the quantitative and qualitative value of the information obtained in forestry.

Keywords: remote sensing, high resolution satellite imagery, forest cover classification.

Primljeno / Received: 2021-03-15

Prihvaćeno / Accepted: 2021-05-06