

UPORABA SENTINEL 1 I SENTINEL 2 SNIMAKA U IDENTIFIKACIJI NESTALIH ŠUMSKIH POVRŠINA – STUDIJA SLUČAJA FRUŠKA GORA (SRBIJA)

DEFORESTATION MONITORING WITH SENTINEL 1 AND SENTINEL 2 IMAGES – THE CASE STUDY OF FRUSKA GORA (SERBIA)

Dušan JOVANOVIĆ¹, Milan GAVRILOVIĆ², Mirko BORISOV³, Miro GOVEDARICA⁴

SAŽETAK

Poznavanje točnih i ažurnih geoprostornih podataka o šumama i šumskim površinama dobivenih interpretiranjem podataka metodama daljinskih istraživanja, ima veliko značenje na pravovremenu intervenciju i upravljanje šumskim površinama, dok odluke temeljene na zastarjelim i nedovoljno preciznim podacima mogu imati vrlo negativne posljedice.

U ovome radu prezentirana je metoda analize radarskih Sentinel 1 SAR satelitskih snimaka, zajedno s kombinacijom multispektralnih Sentinel 2 snimaka, s ciljem identifikacije nestalih i novo nastalih šumskih površina, kao i ocjenom uporabljivosti besplatnih, svima dostupnih radarskih satelitskih snimaka za promatranje šumskih površina. Klasifikacija radarskih snimaka obavljena je pomoću *Random Forest* klasifikacijskog algoritma na *Cloud platformi*. Provedena studija pokazala je da je u svakom analiziranom periodu od 2016. do 2019. godine veća površina pod nestalom šumom u odnosu na novonastalu površinu pod šumama. Procjena točnosti klasifikacije za svaki promatrani period izvršena je računanjem matrice grešaka i *Kappa* statistike, a prosječna točnost klasifikacije je oko 97%. Vizualnom analizom i usporedbom dobivenih rezultata s povijesnim podacima potvrđena je visoka točnost identifikacije nestalih šumskih površina. Prezentirana metoda je pokazala da se vrlo brzo, na osnovi slobodno dostupnih satelitskih snimaka može doći do pouzdanih i ažurnih podataka zadovoljavajuće kvalitete.

KLJUČNE RIJEČI: SAR, Copernicus, Random forest klasifikacija, monitoring šuma, detekcija promjena

UVOD INTRODUCTION

Šumama je prekrivena gotovo trećina kopnene površine u svijetu pa one predstavljaju jedan od najvažnijih ekosustava na našoj planeti i jedan od osnovnih elementa za borbu protiv klimatskih promjena. Skladištenje i pretvaranje ugljičnog dioksida (CO₂) u kisik, smanjenje efekta erozije

zemljišta izazvane padalinama te prirodno stanište velikom broju vrsta biljnog i životinjskog svijeta, čine šume jednim od najbitnijih čimbenika u kopnenim ekosustavima. Osim toga, šume su najveće kopneno skladište ugljika koji čini oko 85% ukupne biomase kopnene vegetacije (Reay, 2008). Kao najveći rezervoar bioloških resursa, šume imaju nezamjenjivu ulogu u upravljanju ekosustavima u smanjenju

¹ Izv. prof. dr. Dušan Jovanović, dipl. inž. elektr. i računar., Univerzitet u Novom Sadu – Fakultet tehničkih nauka Novi Sad, Trg Dositeja Obradovića 6, 21 000 Novi Sad, Srbija, e-mail: dusanbuk@uns.ac.rs

² Milan Gavrilović, mast. inž. geod., Univerzitet u Novom Sadu – Fakultet tehničkih nauka Novi Sad, Trg Dositeja Obradovića 6, 21 000 Novi Sad, Srbija, e-mail: milangavrilovic@uns.ac.rs

³ Izv. prof. dr. Mirko Borisov, dipl. inž. geod., Univerzitet u Novom Sadu – Fakultet tehničkih nauka Novi Sad, Trg Dositeja Obradovića 6, 21 000 Novi Sad, Srbija, e-mail: mborisov@uns.ac.rs

⁴ Izv. prof. dr. Miro Govedarica, dipl. inž. geod., Univerzitet u Novom Sadu – Fakultet tehničkih nauka Novi Sad, Trg Dositeja Obradovića 6, 21 000 Novi Sad, Srbija, e-mail: miro@uns.ac.rs

utjecanja na klimatske promjene, zaštitu okoliša i poboljšanje ekološke sigurnosti (Woodwell i dr., 1978, Penman i dr., 2003, IPCC, 2006). Čest problem ublažavanja klimatskih promjena je smanjenje i oštećenje šuma, kao i povećanje šumskih resursa (Millar i dr., 2007).

Brzo krčenje šuma stvara veliku opasnost i povećava učinak klimatskih promjena. Svake godine se širom svijeta uklanjaju velike šumske površine i potrebno je precizno nadgledanje ovih aktivnosti da bi se smanjio njihov negativni utjecaj. Međutim, nije svako krčenje šume uništavanje prirode, već samo ono bez plana i suprotno propisima dok kontrolirano krčenje utječe pozitivno na životnu sredinu. Posljednjih desetak godina svjedoci smo dramatično ubrzane komercijalne eksploatacije šuma koja ima za cilj ponajprije pretvaranje šuma u drvenu masu za prodaju, što legalno, što nelegalno.

Dugogodišnje devastiranje Fruške gore te neorganizirana i neplanirana krčenja šuma imala su za posljedicu da su u ovom nacionalnom parku „rupe“ na mjestu nekadašnjih šuma postale vidljive i *golim okom* na satelitskim snimcima. U Vojvodini su 2016. godine šumokradice posjekle gotovo 1600 kubičnih metara drveta i to najviše u Šumskom gazdinstvu „Banat“ Pančevo. U Vojvodina šumama kažu da je samo od 2012. do 2016. godine iz ovog gazdinstva bespravno posječeno skoro 3800 kubičnih metara drva, a kao jedan od razloga navodi se blizina grada i velika razjedinjenost terena.

Tradicionalne metode nadgledanja šumskih površina podrazumijevaju primjenu različitih metoda uzorkovanja i terenskog istraživanja, što predstavlja zahtjevan i dugotrajan postupak (Li i dr., 2015, Chen i dr., 2017). U tom smislu, tehnologije daljinskih istraživanja se mogu koristiti za dobivanje informacija o šumama u teško pristupačnim područjima, nadopunjujući tradicionalne metode i smanjujući potrebe za odlaskom na teren. Program Copernicus (Copernicus, 2020), koji obuhvaća satelite sa različitim prostornim i vremenskim rezolucijama za promatranje planete Zemlje pruža priliku za brzo evidentiranje i kartiranje promjena šumskih površina i redovno ažuriranje stanja šuma. Primjena daljinskih istraživanja u šumarstvu uključuje:

- Izviđačko kartiranje (određivanje tipa šumskog pokrova te kartiranje poljoprivrednog zemljišta i šuma);
- Komercijalno šumarstvo (kartiranje izdvojenih dijelova šume, razgraničenje izgorjelih dijelova šuma, inventarizaciju vrsta šuma, računanje biomase i drugo);
- Nadgledanje životne sredine (krčenje, zaštita slivova, obala i zdravlje šuma) (Jovanović, 2010).

Daljinska istraživanja omogućavaju uporabu različitih alata, koji uz pomoć snimaka iz više razdoblja osiguravaju korisnicima identifikaciju promjena i kvantificiranje gubitaka

šumskih površina. Vremenske serije snimaka Copernicus satelita SAR Sentinel 1 (S-1) i optičkog Sentinel 2 (S-2), zbog svojih visokih prostornih (10 m) i vremenskih rezolucija (5 dana), pružaju sjajnu priliku za nadgledanje šumskih površina. Za razliku od većine SAR podataka (npr. RADAR-SAT-2 ili TerraSAR-X) i optičkih satelitskih platformi (npr. SPOT, Planet, WorldView 2,3) ovi podaci su slobodni i dostupni za korištenje.

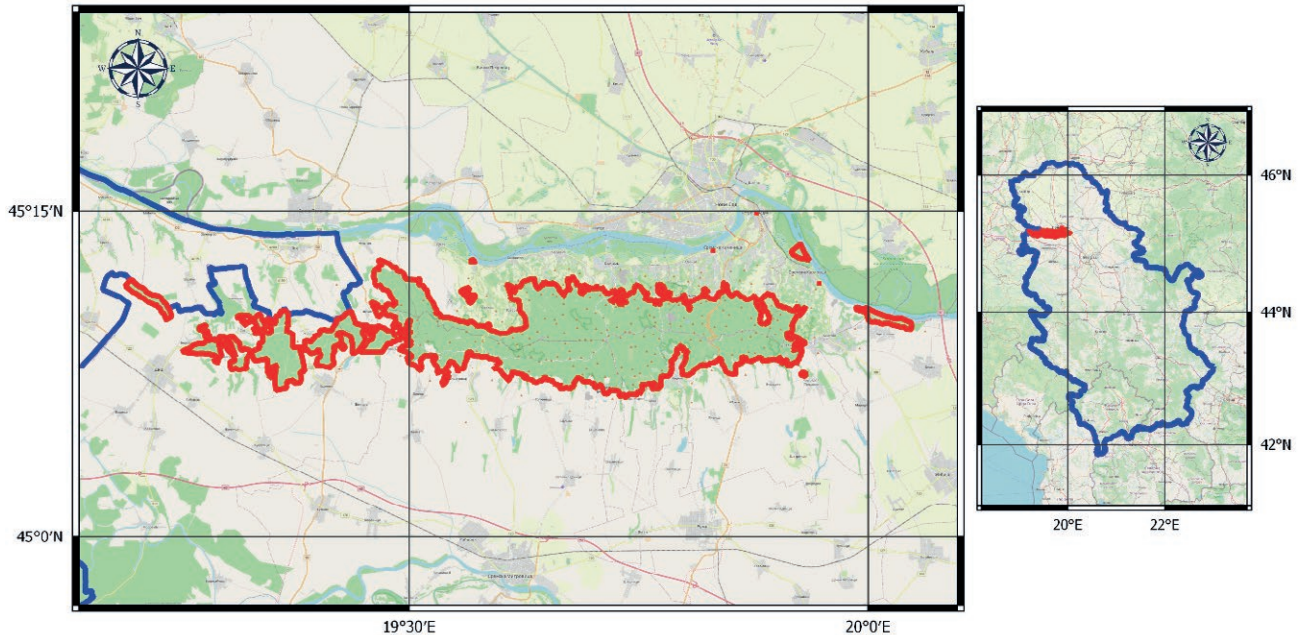
Studije koje koriste S-1 ili S-2 vremensku seriju obično su usmjerene na homogena poljoprivredna ili šumska područja i na klasifikacije nekoliko tipičnih klasa zemljišnog pokrivača (Belgiu i Csillik, 2018, Denize i dr., 2019, Puletti i dr., 2017, Tsai i dr., 2018). Druga grupa radova bavi se analizom kombinacija SAR snimaka, ponajprije S-1 podataka s optičkim snimcima kao što su Landsat snimci ili spomenuti S-2, a sve u cilju povećanja preciznosti klasifikacije (Reiche i dr., 2018), ali još uvijek je mali broj radova koji se bavi analizom vremenske serije samo S-1 snimaka za detekciju nestalih šumskih površina. Na kraju, tu je grupa radova koja se bavi uporabom Google Earth Engine zajedno sa S-1 i S-2 snimcima (Traganos i dr., 2018, Mahdianpari i dr., 2019).

Cilj ovoga rada je prikazati mogućnosti detekcije nestalih šumskih površina uz pomoć vremenskih serija satelitskih SAR S-1 snimaka uz podršku S-2 snimaka za područje nacionalnog parka Fruška gora. U okviru rada provedena je i studija na području Fruške gore u kojoj je prikazan način identifikacije nestalih površina pod šumama za razdoblja 2016, 2017, 2018 i 2019 godine.

MATERIJALI I METODE MATERIAL AND METHODS

Područje istraživanja – *Research area*

Područje Vojvodine, s manje od 6.50% njegove ukupne površine, jedno je od regija s najmanjim šumskim pokrivačem u Europi. Šume Vojvodine su neravnomjerno raspoređene i uglavnom smještene u uskim i širim predjelima uz rijeke, koje predstavljaju manje i veće šumske komplekse (Čortan, 2015). Fruška gora zauzima sjeverni dio Srijema (Slika 1), i proteže se u dužini od oko 75 km i širini od 12 do 15 km sa površinom od oko 255 km². Fruška gora je 1960. proglašena nacionalnim parkom i tako je postala prvi nacionalni park u Srbiji (Gavrilović i dr., 2014). To je niska planina, sa najvišim vrhom od 539 m (Crvena čot). Doline Fruške gore prekrivene su livadama, pašnjacima i poljima kukuruza, a padine su prekrivene voćnjacima i vinogradima. Pojedini dijelovi planina viši od 300 metara prekriveni su gustom listopadnom šumom. Fruška gora predstavlja područje s najvećom koncentracijom lipe u jugoistočnoj Europi, a uz nju se pojavljuju šume hrasta, bukve, graba, topole i vrbe kao monodominantne šume ili



Slika 1. Područje istraživanja: nacionalni park Fruška gora
Figure 1. Research area: national park Fruška gora

mješovite sastojine. Klima i tlo Fruške gore pogodno je za uzgoj vinove loze i voćnjaka, zbog čega su neki dijelovi Fruške gore poznata vinska regija u Srbiji (Jovanović, 2011).

Satelitski snimci – *Satellite images*

Za spomenuto pilot područje korišteni su dvostruko polarizirani C-band SAR podaci Sentinel 1 satelitske platforme. Obrada ovih podataka je obavljena je u Cloud platformi Google Earth Engine¹ (GEE), što znači da je korištena kolekcija podrazumijevala uporabu Ground Range Detected (GRD) scena, koji su već procesirani korištenjem Sentinel 1 alata za generiranje kalibriranih, orto-rectificiranih proizvoda. Svaka korištena S-1 scena ima jednu od tri rezolucije (10, 25 ili 40 metara), tri moda snimanja i 4 potencijalne kombinacije polarizacije (jedan opseg VV ili HH polarizacija, ili dva opsega sa VV+VH ili HH+HV polarizacijama).

Sve S-1 snimke korištene u ovoj studiji, prethodno su pripremljene (engl. Preprocessing data) i to na način da su: uklonjene termalne smetnje (engl. Thermal noise removal), obavljena radiometrijska kalibracija (engl. Radiometric calibration) i korekcija terena (engl. Terrain correction) korištenjem SRTM 30 DEM-a te su na kraju svi podaci pretvoreni u decibele logaritamskim skaliranjem.

Za prikupljanje reprezentativnih uzoraka za klasu šume, korišteni su multispektralni podaci sa Sentinel 2 satelitske

platforme. Ova platforma sadrži 13 spektralnih opsega različitih prostornih rezolucija (10, 20 i 60 metara), a podaci s iste su upotrijebljeni iz razloga što je prikupljanje trening uzoraka samo na osnovi radarskih snimaka kompleksno.

METODE METHODS


U okviru ove studije autori su dali prijedlog tijeka procesa identifikacije nastalih i nestalih šumskih površina na osnovi podataka nastalih na načelima daljinskih istraživanja. Predloženi koraci u ovom slučaju prikazani su na slici 2.

Postupak klasifikacije šumskih površina i detekcija nestalih i novonastalih površina pod šumama, u određenim dijelovima podrazumijeva iste postupke za serije vremenskih snimaka, bez obzira za koje razdoblje se odlučimo. Za potrebe ove studije slučaja, obavljena je analiza za četiri godine u periodu od 2016. do 2019. godine.

Prvi korak je preuzimanje radarskih snimaka² sa Sentinel 1 i optičkih snimaka sa Sentinel 2 platforme, nad kojima je izvršeno filtriranje po datumu i području interesa. Radarski snimci su posebno filtrirani i po načinu snimanja, gdje su korišteni snimci nastali u Interferometric Wide Swath režimu sa VH polarizacijom i po putanji satelita, da bi se sma-

¹ <https://code.earthengine.google.com/>

² Iako su u pitanju radarski snimci koji zahtijevaju da se nad njima izvrši odgovarajući pre-procesing, Google Earth Engine (GEE) isporučuje već prethodno obrađene snimke. Pre-procesing obuhvaća: primjenu fajla sa putanjom satelita, uklanjanje šuma na rubu snimaka, uklanjanje termalnog šuma, radiometrijsku kalibraciju i ortorektifikaciju.



Slika 2. Tijek procesa
Figure 2. Workflow

njio utjecaj sjena i gubitka informacija uslijed dijelova područja od interesa koji nisu osvijetljeni senzorom. U ovom slučaju su izabrani posebno snimci s padajućom (engl. ascending) i rastućom (engl. descending) putanjom satelita. Ove dvije vrste snimaka, s uzlaznom i silaznom putanjom su zatim presječene sa granicom nacionalnog parka Fruška gora. Zbog tipičnih karakteristika radarskih snimaka, kao što su mrlje, kao obavezni korak prije klasifikacije, provedeno je smanjenje utjecaja mrlja. Za ovo je korištena statistička metoda filtriranja, odnosno zaglađivanja slike (engl. Speckle Filtering) koje se obavljalo na svim vremenskim serijama radarskih snimaka. Kao što se vidi na slici 2, filtrirani snimci su zatim spajanjem pretvoreni u mozaik, gdje je za svaki piksel zadržana maksimalna vrijednost refleksije, na osnovi čega je dobiven jedan raster s jednim slojem na kojemu ne postoje radarske sjene.

Usporedo s ovim koracima, na osnovi Sentinel 2 snimaka kreirani su NDVI indeksi za svaki izabrani snimak. Prije samog postupka klasifikacije, napravljeni su i trening uzorci. Ovaj postupak svakako nije jednostavan ako se koriste samo radarske snimke, te je obavljeno kombiniranje radarskih i optičkih snimaka istog datuma za svaku godinu pojedinačno. Da bi sa sigurnošću tvrdili da su obuhvaćeni oni pikseli koji predstavljaju područja gdje je šuma i pod-

ručja gdje nije šuma, optički snimci vizualno su prikazani s različitim kombinacijama RGB prikaza vidljivih i infracrvenih opsega.

Za svaku godinu napravljeno je po trideset trening uzoraka, za područja gdje je šuma (klasa forest) i područja gdje nije bila šuma u promatranom trenutku vremena (klasa non_forest). Nakon ovoga izvršena je klasifikacija, uz oslonac na već implementirani Random Forest algoritma u okviru GEE. Argumenti Random Forest klasifikatora podešavaju se u iterativnom postupku koji se ponavlja dok se ne dobije zadovoljavajuća točnost klasifikacije. Tijekom ovog postupka, za svaki klasificiranu snimku potrebno je prilagoditi sljedeće parametre³:

- Broj stabala za svaku kreiranu klasu (numberOfTrees);
- Broj promjenjivih pri grananju (variablesPerSplit);
- Minimalnu veličinu terminalnog čvora (minLeafPopulation);
- Ulazni dio promjenjivih po drvetu (bagFraction) i
- Slučajni broj koji ako se podesi osigurava isti izlazni rezultat (seed).

Za svaku godinu od 2016. do 2019. dobiveni su rezultati klasifikacije promatranog područja u vidu tematske karte, odnosno rastera s vrijednostima 0 – nije šuma i 1 – šuma.

³ https://developers.google.com/earth-engine/api_docs#ee.classifier.randomforest

Tablica 1. Ocjena točnosti**Table 1.** Accuracy assessment

Godina	Ukupna točnost	Kappa statistika
2016	0.9734	0.93
2017	0.9810	0.96
2018	0.9900	0.98
2019	0.9732	0.95

Za svaki rezultat klasifikacije izvršena je i kontrola točnosti na osnovi matrice pogrešaka i Kappa statistike istih. Rezultati kontrole točnosti su prikazani u Tablici 1.

REZULTATI I DISKUSIJA RESULTS AND DISCUSSION

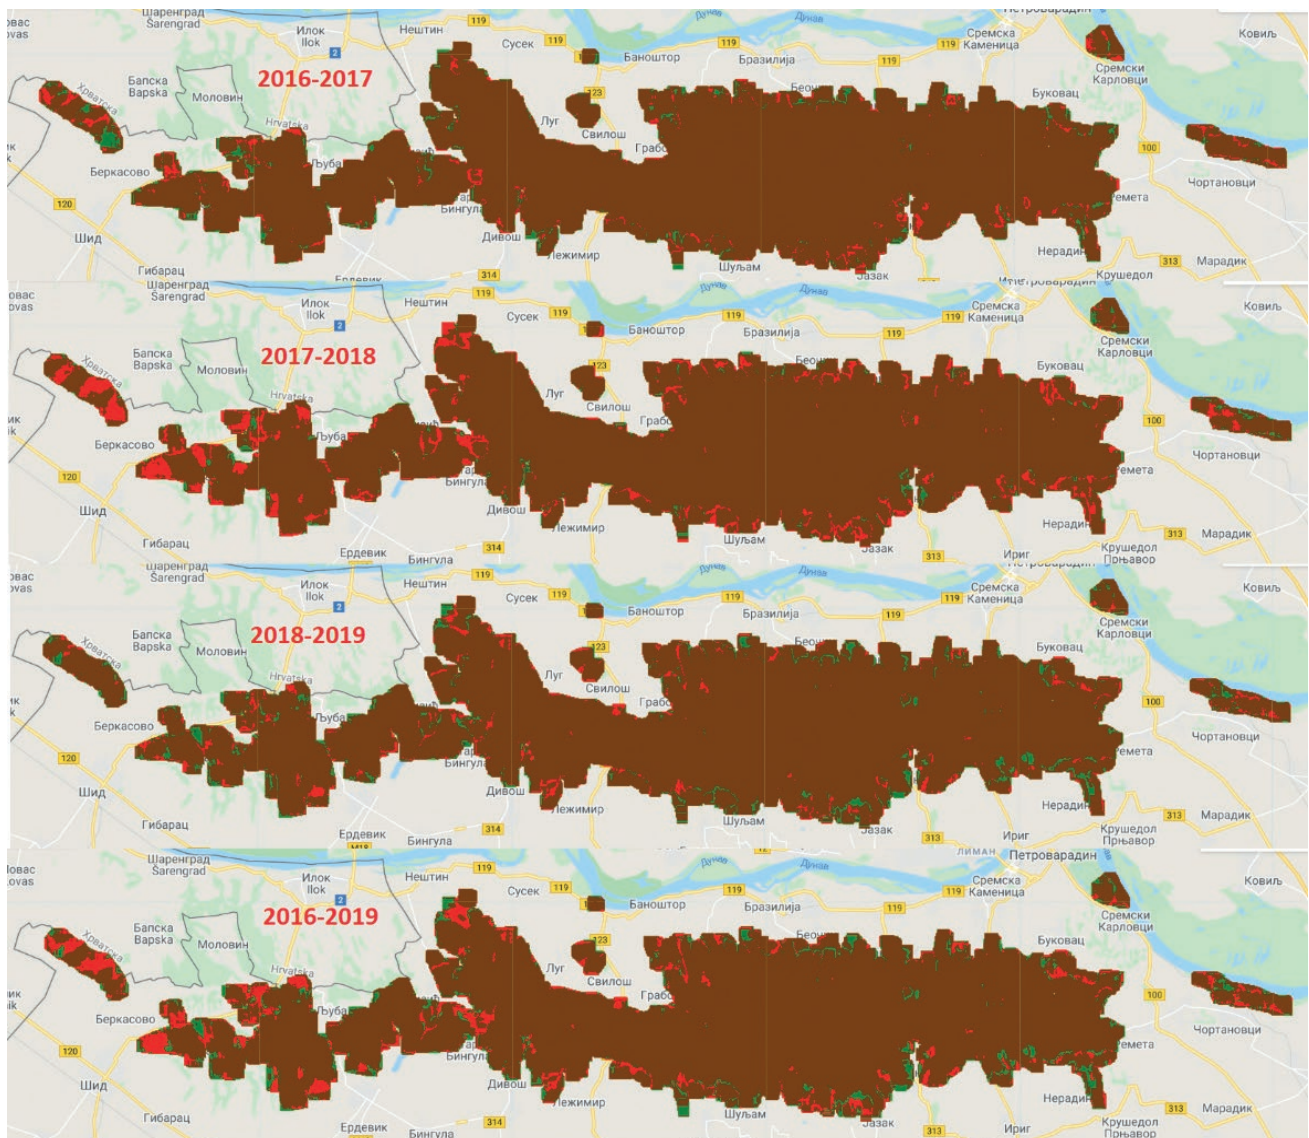
Nakon provedene klasifikacije, izvršena je analiza promjene šumskog pokrivača za različita razdoblja, i to 2016-2017,

2017-2018, 2018-2019, ali i analiza za razdoblje od tri godine, odnosno od 2016. do 2019. godine. Rezultat klasifikacije za svaku godinu predstavljen je rasterom s vrijednostima piksela 0 – nije šuma i 1 – šuma. Za svaki navedeni period, kreirani su novi rasteri oduzimanjem promatrane od prethodne godine (npr. 2017-2016).

Na slici 3 je prikazan rezultat ovako kreiranih rastera, za svaki odabrani period, koji može imati jednu od tri vrijednosti piksela i to:

- 1 (nastanak novog šumskog pokrova, zelena boja),
- 0 (nema promjene, smeđa boja), ili
- 1 (nestanak šumskog pokrova, crvena boja).

Kako bi bili sigurni da su rezultati analize za razdoblje 2016-2019 godine pouzdani, obavljena je i dodatna analiza. Rezultati za tri sukcesivna razdoblja od 2016. do 2019. godine su prikupljeni, a zbroj vrijednosti prethodno kreiranih ra-

**Slika 3.** Rezultati obrade za svako vremensko razdoblje i zbirni rezultat za period od 2016 do 2019 godine**Figure 3.** Results for each period and cumulative result for the period from 2016 to 2019

Tablica 2. Rezultati analize za promatrana razdoblja

Table 2. Results of analysis for the observed period

Vremensko razdoblje	2016-2017	2017-2018	2018-2019	2016-2019
nema promjene [km ²]	243.45	244.42	242.23	239.56
nova šuma [km ²]	3.56	4.27	6.21	7.29
nestala šuma [km ²]	6.50	7.16	6.89	10.59

stera je uspoređen i predstavljen u obliku novog rastera koji definira promjenu 2016-2019 godine (Slika 3). Nakon ove operacije, svaki piksel novog rastera, tj. rastera dobivenog sumiranjem, za period 2016-2019 može imati jednu od sljedećih vrijednosti:

- 3 (greška, nema promjena – smeđa boja),
- 1 (nestala šuma, crvena boja), ili
- -1 (novo nastala šuma, zelena boja).

Ukoliko se rezultati u rasteru koji predstavlja razliku između 2018. i 2019. godine, ali i u rezultatima za razdoblje 2016-2019 godine poklapaju, onda je promatrani piksel prihvaćen kao piksel na kojemu se dogodila jedna od promjena. Na ovaj način uspoređivanjem dva rezultata, može se smatrati da je lokacija o nestalim ili nastalim šumama pouzdana.


**Slika 4.** Dijagram promjena šumskog područja

Figure 4. Graph of forest area change

Dobiveni rezultati su preuzeti sa GEE i izvršena završna obrada u QGIS⁴ programu koja je uključivala vektorizaciju, analizu dobivenih rezultata i računanje nestalih i novo nastalih šumskih površina, a rezultati ove usporedne analize za navedena razdoblja, prikazani su u Tablici 2.

Na osnovi prikazanih rezultata može se uočiti da je u razdoblju od 2017. do 2018. godine došlo do najvećih gubitaka



**Slika 5.** Primjer rezultata nestale šumske površine za razdoblje od 2016. do 2019. godine u blizini naselja Vrdnik u južnim dijelovima nacionalnog parka Fruška gora

Figure 5. Example of deforested area for time period between 2016. and 2019. GEE, near city Vrdnik in south part of national park Fruška gora

⁴ <https://www.qgis.org/en/site/>



Slika 6. Primjer pogreške u osjenčanim dijelovima nacionalnog parka Fruška gora
Figure 6. Example of error in shadow area in national park Fruška gora

u šumskom pokrivaču na Fruškoj gori, dok je taj gubitak bio najmanji u razdoblju od 2016. do 2017. godine. Također, može se uočiti trend porasta novih šumskih površina, ali također i da je u svakom razdoblju ipak veća površina pod nestalom nego pod novonastalom šumom. Uz analize za svaku pojedinu godinu, izvršena je i trogodišnja analiza, u cilju pokušaja pronalaska lokacija na kojima je došlo do promjena u razdoblju od 2016. do 2019. godine, a rezultati su prikazani i na slici 4.

Dodatna provjera dobivenih rezultata je vršena uz pomoć Google Earth Pro⁵ aplikacije.

Preuzeti i obrađeni podaci provjeravani su vizualnom analizom u Google Earth. Jedan primjer provjere rezultata detekcije nestalih šumskih površina, za period od 2016. do 2019. godine, u blizini naselja Vrdnik na južnim padinama nacionalnog parka Fruška gora prikazan je na slici 5. Kako bi bili sigurni da su dobiveni rezultati točni prilikom vizualne analize u Google Earth, odabrane su snimke neposredno nakon akvizicije Sentinel 1 radarskih snimaka.

Analizirajući vrijednosti u Tablici 1, te imajući u vidu ukupnu točnost i Kappa statistiku klasifikacije za svaku godinu, može se zaključiti da će i sami rezultati detekcije nastalih i nestalih šuma također biti visoke točnosti. Također treba naglasiti da su nakon preuzimanja rezultata i dodatnom analizom rezultata u QGIS-u, uočeni problemi koji su najviše zastupljeni u usjecima ili dijelovima gdje prolaze putevi kroz nacionalni park Fruška gora (Slika 6). Iako je tijekom obrade radarskih snimaka, s ciljem eliminacije ovih grešaka korišten raster kreiran od snimka sa silaznom i uzlaznom putanjom, očigledno nije bilo moguće u potpunosti izbjeći utjecaj sjene na spomenutim područjima.

Shodno tomue, sva pogrešno detektirana područja, tj. poligoni nestalih šuma izazvani radarskom sjenom, uklonjeni

su ručno tijekom analize rezultata. Možemo zaključiti da postupci koji koriste samo SAR podatke za kartiranje nestalih i novonastalih šumskih područja još uvijek nisu dovoljno dobro razvijeni da bi se mogli samostalno koristiti te da bi se na osnovi njih mogla automatski ukloniti sva sjenama izazvana problematična područja. Međutim i uz ovaj nedostatak pri korištenju SAR snimaka, dobiveni su rezultati visoke točnosti.

ZAKLJUČCI CONCLUSIONS

U opisanom istraživanju pokazano je kako se klasifikacijom radarskih satelitskih snimaka mogu dobiti kvalitetni podaci koji predstavljaju granice područja nestalih ili novonastalih šumskih površina. Provjerom točnosti provedene klasifikacije te vizualnom analizom potvrđena je metoda identifikacije interpretiranih klasa. U radu je prikazana metodologija i prednosti primjene slobodnih satelitskih snimaka, ponajprije radarskih, ali i obrada u GEE platformi zasnovanoj na oblaku, uporaba arhiva javno dostupnih snimaka za cijelu planetu i na kraju uporaba slobodnih programa za post procesiranje/kodiranje kao što je QGIS.

Opisana metodologija se temelji na izboru područja od interesa, izboru radarskih snimaka za izabrani period, obradi snimaka, izboru i kombiniranjem radarskih i multispektralnih snimaka (Sentinel 1 i Sentinel 2). Nakon što su provedeni ovi koraci, prelazi se na klasifikaciju snimaka iz svakog perioda uz pomoć Random Forest algoritma, i na kraju, da bi se uočile nastale promjene, nakon klasifikacije kreirane su novi rasterski podaci koji mogu sadržavati samo dvije vrijednosti piksela. Razlika ovakva dva rastera na kraju ukazuje da li je došlo do promjene ili ne za promatrani period.

⁴ <https://www.google.com/earth/>

Ovakav pristup identifikaciji nestalih i novonastalih šumskih površina jednostavan je za implementaciju te ima niz prednosti u odnosu na tradicionalne terenske metode. Prednosti se ponajprije ogledaju u dostupnosti povijesnih podataka i mogućnosti da se analiziraju nepristupačna područja i velike površine nezavisno od vremenskih uvjeta i vremena akvizicije.

Na osnovi prikazanih rezultata, zaključuje se da klasifikacija SAR snimaka može poslužiti pri identifikaciji nastalih promjena u šumskom pokrovu. Također, uporaba GEE u daljinskim istraživanjima u području šumarstva, bez obzira da li se koriste radarske ili optičke snimke, može se smatrati izuzetno učinkovita i pouzdana. GEE ima primat u odnosu na ostale programe zbog obrade u oblaku koja ne zahtijeva posjedovanje računala s visokim performansama, ali je svakako još uvijek potrebno obaviti kontrolu, kao što je i pokazano kombinacijom vizualne analize i interpretacije satelitskih snimaka.

LITERATURA REFERENCES

- Belgiu, M., O. Csillik, 2018: Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis, *Remote Sensing Environment*, 204: 509–523.
- Gavrilović, B., B. Gavrilović, S. Čurčić, D. Stojanović, D. Savić, 2014: Leaf beetles (Coleoptera: Chrysomelidae) of mt. Fruška gora (Vojvodina province, northern Serbia) with an overview of host plants, *Šumarski list*, 138 (1-2): 29–41.
- Chen, X., S. Liang, Y. Cao, 2017: Sensitivity of summer drying to spring snow-albedo feedback throughout the Northern Hemisphere from satellite observations, *IEEE Geoscience Remote Sensing Letters*, 14: 2345–2349.
- Copernicus: <https://www.copernicus.eu/en>, (Pristupljeno: 15. 06. 2020.).
- Denize, J., Hubert-Moy, L., Betbeder, J., Corgne, S., Baudry, J., Pottier, E., 2019: Evaluation of Using Sentinel-1 and -2 Time-Series to Identify Winter Land Use in Agricultural Landscape, *Remote Sensing*, 11: 37-55.
- Čortan, D., B. Tubić, M. Šijačić-Nikolić, D. Borota, 2015: Variability of black poplar (*Populus nigra* L.) leaf morphology in Vojvodina, Serbia. *Šumarski list*, 139 (5-6): 245-252.
- IPCC, 2006: Intergovernmental Panel on Climate Change. 2006 IPCC Guidelines for National Greenhouse Gas Inventories, Intergovernmental Panel on Climate Change, IPCC Guidelines for National Greenhouse Gas Inventories.
- Jovanović, D., M. Govedarica, I. Badnjarević, V. Pajić, 2010: Object based image analysis in forestry change detection, *IEEE International Symposium On Intelligent Systems And Informatics*, Subotica: IEEE.
- Jovanović, D., M. Govedarica, I. Badnjarević: 2011: Presenting And Comparing The Object Based Image Analysis and Standard Image Analysis For Change Detection of Forest Areas, Using Low-Resolution Satellite Imagery, *The International Multidisciplinary Scientific GeoConference and Expo (Surveying Geology & mining Ecology Management)*, str. 2, 11, 329-336, Albena, Bulgaria: SGEM.
- Li, D., Y. Ke, H. Gong, X. Li, 2015: Object-based urban tree species classification using bi-temporal WORLDView-2 and WORLDView-3 images, *Remote Sensing*, 7: 16917–16937.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., Gill, E., 2019: The First Wetland Inventory Map of Newfoundland at a Spatial Resolution of 10 m Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform, *Remote Sensing*, 11: 1-43.
- Millar, C., N. Stephenson, S. Stephens, 2007: Climate change and forests of the future: Managing in the face of uncertainty, *Ecological Applications*, 17: 2145–2151.
- Penman, J., M. Gytarsky, T. Hiraishi, T. Krug, D. Kruger, R. Pipatti, L. Buendia, K. Miwa, T. Ngara, K. Tanabe, 2003: Good Practice Guidance for Land Use, Land-Use Change and Forestry; Intergovernmental Panel on Climate Change, National Greenhouse Gas Inventories Programme (IPCC-NGGIP), Hayama, Japan.
- Puletti, N., F. Chianucci, C. Castaldi, 2017: Use of Sentinel-2 for forest classification in Mediterranean environments, *Annals of Silvicultural Research*, 42 (1).
- Reay, D., 2008: Climate change for the masses, *Nature*, 452(31).
- Reiche, J., E. Hamunyela, J. Verbesselt, D. Hoekman, M. Herold, 2018: Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2, *Remote Sensing Environment*, 204: 147–161.
- Traganos, D., Aggarwal, B., Poursanidis, D., Topouzelis, K., Chrysoulakis, N., Reinartz, P., 2018: Towards Global-Scale Seagrass Mapping and Monitoring Using Sentinel-2 on Google Earth Engine: The Case Study of the Aegean and Ionian Seas, *Remote Sensing*, 10(8): 1227-1241.
- Tsai, Y.H., Stow, D., Chen, H.L., Lewison, R., An, L., Shi, L., 2018: Mapping Vegetation and Land Use Types in Fanjingshan National Nature Reserve Using Google Earth Engine, *Remote Sensing*, 10(6): 927-941.
- Woodwell, G., R. Whittaker, W. Reiners, G. Likens, C. Delwiche, D. Botkin, 1978: The biota and the world carbon budget. *Science*, 199: 141-146.

SUMMARY

Forest and forest ecosystems have a big importance for the whole living world on the earth. Rapid deforestation poses a great danger and increases the effects of climate change. Large forest areas are cut down every year around the world and these activities need to be closely monitored to reduce their negative impact. Knowledge of valid and current geospatial data on forests and forest areas, obtained by interpreting the data by remote sensing methods has great importance for rapid response and man-

agement of forest areas. Decisions that are based on outdated and insufficiently precise data can have negative consequences.

The researched area of Fruška gora is located in Vojvodina and occupies the northern part of Srem. Due to its natural properties, it enjoys the status of a special nature reserve. Pastures and fertile land, vineyards and orchards, decorate the slopes and lower parts of Fruška gora, while the areas above 300 meters above sea level are covered with dense, deciduous forests.

This paper presents a method of analysis of radar Sentinel 1 SAR satellite images, together with a combination of multispectral Sentinel 2 images, with the aim of identifying missing and newly formed forest areas, as well as assessing the usability of free, for everyone available radar satellite images for forest observation.

The described methodology is based on the selection of areas of interest, the selection of radar images for the chosen time epoch, image processing, the selection of training sets by combining radar and multispectral images. The classification of radar images was performed on the Cloud platform using the Random Forest classification algorithm. The study showed that in each analysed period from 2016 to 2019, the area under missing forest is larger in relation to the newly created area under forests, as well as the growing trend of new forest areas.

Estimation of classification accuracy for each observed time epoch was performed by calculating the error matrix and Kappa statistics, and the average classification accuracy was about 97%. Visual analysis and comparison of the obtained results with historical data confirmed the high accuracy of identification of missing forest areas.

The presented method showed that RF classification of free Sentinel 1 and 2 satellite images, can be used as a reliable and up-to-date data for forest monitoring with satisfactory quality and very quickly.

KEY WORDS: SAR, Copernicus, Random forest classification, forest monitoring, change detection