

Izvorni znanstveni članak
Original scientific paper

Ivan Balenović^{1*}, Luka Jurjević^{2*}, Krunoslav Indir¹, Jasnica Medak¹, Sanja Perić¹

GEOPROSTORNA ANALIZA STANJA PARK ŠUME MARJAN TEMELJENA NA FOTOGRAMETRIJSKIM PODACIMA BESPILOTNE LETJELICE

SAŽETAK

Tijekom 2017. godine u Park šumi Marjan zamijećeno je intenzivno sušenje stabala alepskog bora (*Pinus halepensis* Mill.) uzrokovano mediteranskim potkornjakom (*Orthotomicus erosus* Woll.) koje se je intenziviralo i kulminiralo u 2018. i 2019. godini. S ciljem uklanjanja suhih i zaraženih stabala te sprječavanja daljnjeg širenja uzročnika i propadanja stabala, tijekom 2019. godine provedena je sanitarna sječa. Kako bi se dobio brz i detaljan uvid u stanje vegetacije Park šume Marjan, neposredno nakon obavljenih sanitarnih sječa, provedeno je snimanje bespilotnom letjelicom korištenjem klasične fotogrametrijske kamere te multispektralne kamere. Glavni cilj je bio dobiti 'nulto stanje' vegetacije koje će predstavljati temelj za uspostavu daljnjeg monitoringa i izvođenje pravovremenih preventivnih stručnih aktivnosti, a u svrhu očuvanja Park šume Marjan. Na temelju snimaka bespilotne letjelice vrlo visoke prostorne i spektralne razlučivosti izrađen je niz fotogrametrijskih i geoinformacijskih proizvoda koji su korišteni za detaljne geoprostorne analize stanja šumskog pokrova Park šume Marjan nakon napada potkornjakom te provedenih zahvata sanitarne sječe. Istraživanje je potvrdilo veliki potencijal bespilotnih letjelica i korištenih senzora za dobivanje kvalitetnih i pouzdanih informacija o stanju šuma u vrlo kratkom vremenu s relativno malih površina. Utvrđena je da zadovoljavajuća pokrovnost površine Park šume Marjan s vegetacijom iznad 5 m visine (45%). Međutim, zabrinjavajuće je mali udio vegetacije u rasponu od 2 – 5 m visine, a koja bi u bliskoj budućnosti trebala preuzeti ulogu visoke vegetacije (nadstojne etaže). Nadalje, detektirane su i izdvojene dvije 'žarišne' površine (13,7 ha) koje imaju najveće udjele otvorenih površina (visinska kategorija <0,5, a koje stoga predstavljaju prioritetne dijelove Park šume Marjan za hitnu sanaciju (obnova, popunjavanje i njege). Na temelju rezultata izračunatog NDVI indeksa za promatrano područje (70,9 ha) utvrđeno je da je 95,5% površine pokriveno krošnjama odraslih stabala u vrijeme snimanja (kolovoz 2019. godine) bilo zadovoljavajućeg zdravstvenog stanja. Iz toga se može zaključiti da je provedenom sanitarnom sječom uklonjena većina suhih stabala. Vizualnom interpretacijom multispektralnih snimaka ukupno je detektirano 491 preostalo suho stablo (i stablo s manjkom klorofila), a koja su ujedno precizno prostorno definirano čime bi njihov pronalazak na terenu u svrhu daljnjeg uklanjanja sanitarnom sječom trebao biti značajno olakšan.

Ključne riječi: sušenje stabala, alepski bor (*Pinus halepensis*), mediteranski potkornjak (*Orthotomicus erosus*), daljinska istraživanja, fotogrametrija, bespilotne letjelice

¹ Hrvatski šumarski institut, Cvjetno naselje 41, 10450 Jastrebarsko

² Geo Unit d.o.o., Stanka Vraza 8, 23000 Zadar

* Kontakt autori: Ivan Balenović (ivanb@sumins.hr), Luka Jurjević (lukaj@sumins.hr)

UVOD

Klasične metode daljinskih istraživanja temeljene na satelitskim, avionskim ili helikopterskim platformama te pasivnim ili aktivnim senzorima u primjeni su već dugi niz godina te danas predstavljaju jedan od najvažnijih načina prikupljanja prostornih podataka u mnogim djelatnostima (Balenočić i sur. 2021). Konstantan napredak tehnologije, razvoj i minijaturizacija različitih vrsta senzora, u novije vrijeme je značajno utjecao i na razvoj tzv. blizupredmetnih daljinskih istraživanja (Colomina i Molina 2014). Razvoj bespilotnih letjelica omogućio je detaljno prikupljanje visoko preciznih prostornih podataka (Jurjević i sur. 2021). Naime, na bespilotne letjelice moguće je montirati različite vrste senzora te na taj način prikupiti vrijedne informacije o šumama vrlo visoke prostorne, spektralne i vremenske rezolucije (Miyoshi i sur. 2020, Nex i sur. 2022). Pri tome su u najčešćoj primjeni klasične fotogrametrijske kamere i multispektralne kamere, a u manjoj su primjeni hiperspektralne kamere i LiDAR (prema engl. Light Detection And Ranging), i to prije svega zbog njihove cijene (Torresan i sur. 2017, 2018).

Tijekom 2017. godine u Park šumi Marjan, smještenoj na krajnje zapadnom dijelu splitskog poluotoka, zamijećeno je intenzivno sušenje stabala alepskog bora (*Pinus halepensis* Mill.) (Pernek i sur. 2019a), glavne i dominantne vrsta drveća. Na temelju provedenog istraživanja znanstvenika Hrvatskog šumarskog instituta (Pernek i sur. 2019a), utvrđeno je da je uzročnik sušenja borova na Marjanu mediteranski potkornjak (*Orthotomicus erosus* Woll.), te da je sušenje započelo još 2016. godine s atipičnim simptomima za potkornjake, intenziviralo se u 2017. godini te kulminiralo u 2018. i 2019. godini (Pernek i sur. 2019a, 2019b). Prema Perneku i sur. (2019a), na uzorku od 1650 slučajno odabranih stabala na prethodno utvrđenim transektima uzorkovanja, u 2017. godini utvrđeno je 13% mrtvih i suhih (zaraženih) stabala, dok je u 2018. godini zabilježen porast na 17%, a u 2019. na 23%. Slijedom navedenih podataka i razmjera širenje sušenja stabala u Park šumi Marjan, tijekom 2019. godine provedena je sanitarna sječa u cilju uklanjanja suhih i zaraženih stabala te sprječavanja daljnjeg širenja uzročnika i propadanja stabala. Kako bi se dobio brz i detaljan uvid u stanje vegetacije Park šume Marjan, neposredno nakon obavljenih sanitarnih sječa, provedeno je snimanje bespilotnom letjelicom korištenjem klasične fotogrametrijske kamere te multispektralne kamere u okviru projekta „Geoprostorna analiza stanja šumskog pokrova Park šume Marjan korištenjem snimaka bespilotne letjelice“ kojeg je Hrvatski šumarski institut tijekom 2019. godine proveo za Grad Split. Glavni cilj projekta bio je dobiti ‘nulto stanje’ vegetacije koje će predstavljati temelj za uspostavu daljnjeg monitoringa (terenskim metodama i metodama daljinskih istraživa-

vanja) i donošenje pravovremenih stručnih aktivnosti (zaštita šuma, uzgojni zahvati), a u svrhu očuvanja Park šume Marjan.

Na temelju snimaka bespilotne letjelice vrlo visoke prostorne i spektralne razlučivosti izrađen je niz fotogrametrijskih i geoinformacijskih proizvoda koji su korišteni za detaljne geoprostorne analize stanja šumskog pokrova Park šume Marjan nakon napada potkornjakom te provedenih zahvata sanitarne sječe.

Ovaj rad ima za cilj prikazati prvi dio provedenih analiza i dobivenih rezultata:

- 1) Detaljna klasifikacija šumskog pokrova po visinskim klasama;
- 2) Analiza nastalih promjena u sastojinskom sklopu;
- 3) Detekcija ‘žarišnih’ područja koja zahtijevaju hitnu sanaciju;
- 4) Detekcija suhih stabala i generalni uvid u stanje vegetacije.

MATERIJALI I METODE

Istraživanje je provedeno kroz niz terenskih i uredskih aktivnosti. Terenski dio istraživanja sastojao se od snimanja bespilotnom letjelicom, izmjere kontrolnih terenskih točaka za orijentaciju snimaka te prikupljanja kontrolnih (referentnih) terenskih podataka. Uredski dio istraživanja sastojao se od fotogrametrijskog procesiranja podataka prikupljenih bespilotnom letjelicom i izrade niza fotogrametrijskih proizvoda na temelju kojih su provedene geoprostorne analize automatskom i vizualnom odnosno manualnom i interpretacijom.

PODRUČJE ISTRAŽIVANJA

Područje istraživanja je cjelokupni prostor Park šume Marjan, smještene na poluotoku zapadno od središta Grada Splita. Park šuma je proglašena 1964. godine te je prema aktu o ustanovljenju imala površinu od oko 350 ha. Današnja površina dobivena korištenjem GIS alata iznosi 297,11 ha (bioportal.hr/gis/). Istraživano područje proteže se od obale do 175 metara nad morem, dužine u smjeru istok-zapad 3,4 km, a širine u smjeru sjever-jug najviše 1,3 km. Izraženi greben koji se pruža u smjeru istok-zapad dijeli prostor na dva orografski različita dijela: sjeverne ekspozicije su blažih nagiba (do cca 25 stupnjeva), dok su južne strmije, a na manjem dijelu površine ima i litica. Prevladavajući tip tla na sjevernom dijelu poluotoka je smeđe tlo na vapnencima, a na vršnom grebenskom dijelu ima i crnice. Južni dio poluotoka je pretežno sastavljen od antropogenih tala na flišu. Ostali tipovi tla prisutni su fragmentarno. Na prostoru park šume prevladavaju umjetno podignute sastojine alepskog bora, nastale pošumljavanjima od kraja 19. do sredine 20. stoljeća (Vrdoljak 1996).



Slika 1. Park šuma Marjan.

SNIMANJE BESPILOTNOM LETJELICOM

Snimanje Park šume Marjan bespilotnom letjelicom provedeno je tijekom 4 dana u razdoblju od 10. – 13. kolovoza 2019. godine. Snimanje su proveli piloti na daljinu Hrvatske gorske službe spašavanja s letjelicom Matrice 200 DJI opremljenom klasičnom fotogrametrijskom kamerom Zenmuse x5 i multispektralnom kamerom Parrot Sequoia+. Kamera Zenmuse x5 korištena je za prikupljanje informacija u vidljivom dijelu spektra (crveni, zeleni, plavi kanali) odnosno RGB snimaka, dok je kamera Sequoia+ korištena za prikupljanje informacija u zelenom, crvenom, bliskom infracrvenom i rubnom crvenom dijelu spektra odnosno za prikupljanje multispektralnih (MS) snimaka. Tijekom 30 izvedenih letova prikupljeno je oko 9000 RGB i oko 60000 MS snimaka. Snimanje je provedeno na visini leta do maksimalno 100 m iznad tla, te s uzdužnim i poprečnim preklapom snimaka od 80%. Prostorna rezolucija (GSD - prema engl. *Ground Sample Distance*) RGB snimaka iznosila je $\approx 2,5$ cm, a MS snimaka ≈ 10 cm. Slika 2. prikazuje pozicije (plave točke) RGB snimaka u vrijeme snimanja. Također, na slici se mogu razlikovati i pojedinačni letovi.

MJERENJE ORIJENTACIJSKIH TOČAKA

U svrhu poboljšanja točnosti orijentacije snimaka provedena su dodatna terenska mjerenja orijentacijskih


točaka na tlu. Za mjerenje orijentacijskih točaka korišten je GNSS (prema engl. Global Navigation Satellite System) RTK (prema engl. *Real Time Kinematic*) uređaj povezan s CROPOS (prema engl. *CROatian POSitioning System*) pozicijskim sustavom, odnosno VPPS servisom deklarirane točnosti 2 cm u horizontalnom i 4 cm u vertikalnom smjeru. Orijetacijske točke mjerene su na detaljima terena koji su jasno vidljivi i na samim snimkama. Ukupno je izmjereno 28 kontrolnih terenskih točaka pravilno raspoređenih po čitavom području Park šume Marjan.

FOTOGRAMETRIJSKO PROCESIRANJE

Fotogrametrijsko procesiranje je provedeno na digitalnim fotogrametrijskim stanicama korištenjem fotogrametrijskog softvera Agisoft Metashape Version 1.6.5 (Agisoft LLC, St. Petersburg, Russia). Procesiranje je provedeno posebno na RGB, a posebno na MS snimkama, a sastojalo se od niza koraka.

FOTOGRAMETRIJSKO PROCESIRANJE RGB SNIMAKA

Nakon učitavanja snimaka slijedio je prvi korak orijentacije snimaka kojim je dobiven rijetki oblak točaka korištenih za povezivanje snimaka. Drugim riječima dobivene su vezne točke koje algoritam prepoznaje



Slika 2. Pozicije RGB snimaka u vrijeme snimanja bespilotnom letjelicom.

kao identične na područjima preklopa više različitih snimaka. Budući da je tako orijentirani blok snimaka dobiven na temelju pozicija snimaka tj. koordinata snimljenih GPS-om letjelice koji ima točnost $\approx \pm 5$ m, za dodatno poboljšanje orijentacije snimaka korištene su orijentacijske točke izmjerene GNSS RTK uređajem.

Izmjerene orijentacijske točke u kombinaciji s prethodno dobivenim veznim točkama te parametrima vanjske orijentacije snimaka korištene su potom za precizno georeferenciranje (pozicioniranje) modela rijetkog oblaka točaka u prostoru (s točnošću $< 0,5$ m). Daljnjim fotogrametrijskim procesiranjem precizno orijentiranog rijetkog oblaka točaka, izrađen je gusti oblak točaka prosječne gustoće od ≈ 510 točaka/m².

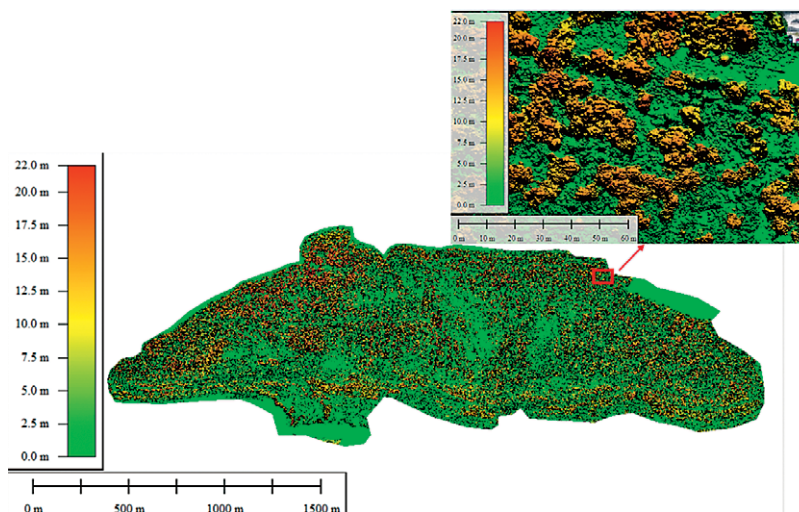
Interpolacijom gustog oblaka točaka izrađen je Digitalni Model Površine (DMP) u rasterskom formatu s veličinom piksela 5 cm \times 5 cm. DMP predstavlja matematički model Zemljine površine, uključujući izgrađene objekte i vegetaciju te prikazuje njihove vrijednosti u nadmorskim visinama.

Zatim je slijedila izrada Digitalnog Modela Reljefa (DMR). U prvom koraku, gusti oblak točaka je klasificiran na točke tla i točke vegetacije i objekata. Postupcima filtriranja iz gustog oblaka točaka uklonjene su točke klasificirane kao vegetacije i kao objekti. Napravljeno je i


uklanjanje točaka s grubim greškama pozicija, tzv. 'noise points' filtriranje. Naposljetku, dobiven je oblak točaka samog tla s gustoćom od 94 točaka/m². S obzirom da se radi o području s vegetacijom, radi poboljšanja točnosti fotogrametrijskog DMR-a korišteni su 3D vektorski podaci službenog DMR-a nabavljeni iz Državne Geodetske Uprave. Vektorske podatke sačinjavaju lomne linije terena (prijelomnice), linije oblika, markantne točke terena i mreža visinskih točaka. Kombinacijom oblaka točaka klasificiranog i filtriranog kao točke tla i podataka službenog DMR-a izrađen je finalni DMR u rasterskom obliku, veličine piksela 50 cm \times 50 cm.

Zatim je izrađen Digitalni Model Visina (DMV) krošanja odnosno sastojine i to preklapanjem DMR-a i DMP-a, odnosno oduzimanjem DMR-a od DMP-a. DMV je izrađen također u rasterskom obliku s veličinom piksela 8 cm \times 8 cm (Slika 3). Tako izrađeni DMV omogućuje očitavanje visina stabala i krošanja iznad tla.

Naposljetku, ortorektifikacijom RGB snimaka na DMP-u izrađen je digitalni ortofoto (DOF) veličine piksela 8 cm \times 8 cm (Slika 4). Vidljive razlike u boji nastale su zbog snimanja tijekom više dana i različitih doba dana. Povećanjem pogleda (zumiranjem) na ekranu vidljive razlike ne predstavljaju značaja problem u interpretaciji snimaka.



Slika 3. Digitalni Model Visina (DMV) stabala i krošanja (osjenčani).




Slika 4. Digitalni ortofoto (DOF) izrađen iz RGB snimaka.

FOTOGRAMETRIJSKO PROCESIRANJE MULTISPEKTRALNIH (MS) SNIMAKA

Fotogrametrijsko procesiranje, tj. orijentacija oko 60000 MS snimaka provedeno je korištenjem fotogrametrijskog softvera Agisoft Metashape na isti način kao i klasičnih RGB snimaka. Nakon orijentacije MS snimaka izrađen je DOF, tj. kolor kompozit sastavljen od 4 spektralna kanala (zeleni, crveni, bliski infracrveni, rubni crveni) veličine piksela 15 cm × 15 cm (Slika 5), te je za svaki piksel izračunat NDVI (prema engl. Normalized Difference Vegetation Index) indeks (Slika 6).



Slika 5. Digitalni ortofoto (DOF) izrađen iz MS snimaka (kolor kompozit)



Slika 6. NDVI indeks izračunat iz MS snimaka

GEOPROSTORNE ANALIZE (VIZUALNA I AUTOMATSKA INTERPRETACIJA I KLASIFIKACIJA)


Korištenjem izrađenih fotogrametrijskih proizvoda (DMV, DOF-ovi, NDVI indeks) provedeno je niz geoprostornih analiza, a kako bi se zadovoljili postavljeni ciljevi istraživanja.

Klasifikacija vegetacije odnosno šumskog pokrova po visinskim kategorijama provedena je korištenjem prethodno izrađenog DMV iz RGB snimaka (Slika 7). Za potrebe automatizirane klasifikacije testirani su razni algoritmi (softveri), te je naposljetku odabran QGIS 3.4.13 softver. Za daljnje GIS analize u svrhu detekcija nastalih promjena u sastojinskom sklopu te detekcije 'žarišnih' područja koja zahtijevaju hitnu sanaciju korišten je Global Mapper 19 softver.


Prije same klasifikacije definirane su visinske kategorije po kojima je potom klasifikacija i napravljena. Ukupno su definirane 4 visinske kategorije vegetacije:

- >5 m - odrasla stabla nadstojne etaže i njihove krošnje (uglavnom stabla alepskog bora uz sporadičnu pojavu čempresa, crnike i parkovnih vrsta drveća);
- 2–5 m - podstojna etaža glavnih i sporednih vrsta drveća (alepski bor, čempres, zelenika, pojedinačno alohtone vrste). U ovu kategoriju u određenoj mjeri ulaze i niži dijelovi krošanja stabala >5 m;
- 0,5–2 m - sloj grmlja (npr. mirta, lemrika, tršlja, zelenika) i mladi urast glavnih i sporednih vrsta drveća;
- <0,5 m – „otvorene površine“ bez vegetacije ili s niskom, travnatom vegetacijom, korovskom vegetacijom, zeljastim biljkama, mladim biljkama glavnih vrsta drveća, kameni i stjenoviti dijelovi (rezultat već postojećeg stanja, tj. prije nepogode te rezultat radova na sječi i izradi).

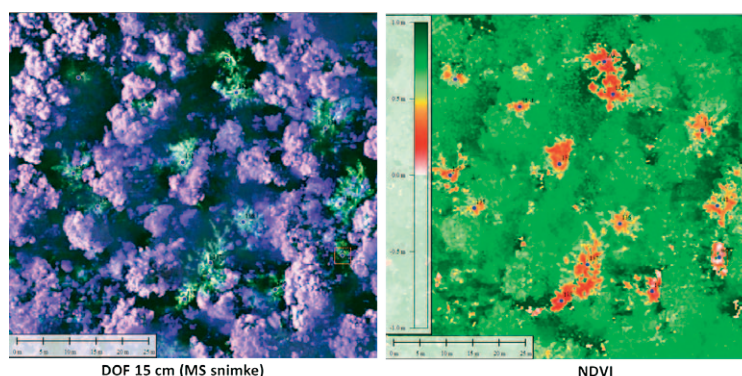
Detekcija suhih stabala provedena je vizualnom interpretacijom na DOF izrađenom iz MS snimaka,



Slika 7. Lijevo: Digitalni Model Visina (DMV) korišten za automatiziranu klasifikaciju vegetacije; Desno: Digitalni ortofoto (DOF). Na prikazanom dijelu površine vidljivo je kako DMV detaljno i precizno opisuje vegetaciju



Slika 8. Detekcija suhih stabala i stabala s manjkom klorofila. Usporedba 'razlučivosti' suhih stabala na DOF-u izrađenom iz MS snimaka (lijevo), i DOF-u izrađenom iz RGB snimaka (desno).




Slika 9. Detekcija suhih stabala i stabala s manjkom klorofila. Lijevo: DOF izrađenom iz MS snimaka, Desno: NDVI indeks.

korištenjem kolorkompozita sastavljenog od bliskog infracrvenog (IC) i drugih spektralnih kanala (zeleni, crveni, rubni crveni). Za manje područje PŠ Marjan koje je bilo nepokriveno MS snimkama (zbog tehničkih smetnji s MS kamerom tijekom snimanja) prilikom vizualne interpretacije korišten je DOF izrađen iz RGB snimaka (Slika 8).

Kako bi se dobio uvid u stanje vegetacije na području PŠ Marjan, iz MS snimaka te korištenjem vrijednosti infracrvenog (IC) i crvenog (C) spektralnog kanala izračunat je NDVI indeks prema formuli:

$$NDVI = (IC - C) / (IC + C)$$

NDVI indeks označava odnos između kanala u crvenom i infracrvenom dijelu spektra (osjetljiv je na sadržaj klorofila u lisnoj masi i količini lisne mase). Vrijednosti NDVI indeksa kreću se od -1 do 1. Primjerice, zdrava vegetacija (klorofil) reflektira veću količinu IC zračenja, a apsorbira crveni kanal što rezultira s višim NDVI iznosima (\approx iznad 0,4). S druge strane, suha stabla reflektiraju manju količinu IC zračenja, a veću količinu zračenja crvenog kanala što rezultira s višim NDVI iznosima (\approx ispod 0,4). Međutim, granice između zdravih i stabala narušenog zdravstvenog stanja nisu jasno definirane (ovise o nizu faktora te o vrsti drveća). Tlo i područje bez vegetacije daju NDVI iznose oko 0 (\approx 0-0,2), kao i vodene površine ($<$ 0,1).



Slika 10. Gore: DOF; Dolje: Rezultati automatizirane klasifikacije na manjem području.

Izračunati NDVI indeks korišten je kao dodatna informacija kod detekcije suhih stabala (potvrda detekciji) (Slika 9), ali prvenstveno za uvid u stanje vegetacije na području PŠ Marjan.

REZULTATI I DISKUSIJA

DETALJNA KLASIFIKACIJA ŠUMSKOG POKROVA PO VISINSKIM KATEGORIJAMA

Nakon provedene automatizirane klasifikacije, rezultati su vizualno evaluirani. Iz primjera na slici 10,



Visinske kategorije:

- **>5 m** - odrasla stabla nadstojne etaže
- **2–5 m** - podstojna etaža glavnih i sporednih vrsta drveća, dijelovi krošanja stabala >5 m
- **0,5–2 m** - sloj grmlja i mladi urast glavnih i sporednih vrsta drveća
- **<0,5 m** - "otvorene površine" bez vegetacije ili s niskom vegetacijom

Slika 11. Rezultati automatizirane klasifikacija šumskog pokrova po visinskim kategorijama.

vidljivo je kako je automatizirana klasifikacija uspješno obavljena. Drugim riječima klasifikacija vegetacije u visinske kategorije odgovara stvarnom stanju odnosno stvarnim visinama vegetacije (Slika 10). Eventualne pogreške su zanemarive, a u usporedbi s manualnom (vizualnom) klasifikacijom, automatizirana klasifikacije je neusporedivo brža te objektivna.

Rezultati automatizirane klasifikacija šumskog pokrova po visinskim kategorijama prikazani su na slici 11 i u tablici 1. Ukupna površina PŠ Marjan obuhvaćena analizom iznosi 174,29 ha. Za manji dio površine PŠ Marjan nije provedena analiza (ceste, gospodarski objekti, odsjeci uređajnog razreda makije i neobraslo

visinskim kategorijama >5m (45%) te >2m (55%) je gledajući čitavu površinu PŠ Marjan zadovoljavajuća. Međutim, struktura pokrovnosti je na površini PŠ Marjan neujednačena, tj. ističu se veće ili manje površine koje imaju znatno manji udio „visoke“ (>5m) i „srednje visoke“ (2-5m) vegetacije, a znatno veći udio „niske“ vegetacije (grmlja, 0,5-2m) i „otvorenih“ površina bez vegetacije ili s niskom, travnatom vegetacijom (<0,5m). Također, zabrinjavajuća je mala pokrovnost kategorijom „srednje visoke“ vegetacije (2-5m=10%) koja bi u bliskoj budućnosti trebala preuzeti ulogu visoke vegetacije (nadstojne etaže); u velikoj mjeri u tu kategoriju ulaze i niži dijelovi krošanja stabala visinske kategorije > 5 m.

Tablica 1. Rezultati automatizirane klasifikacija šumskog pokrova po visinskim kategorijama.

Visinska kategorija	Opis	Površina (ha)	Udio u ukupnoj površini (%)
>5 m	odrasla stabla nadstojne etaže	78,04	45
2–5 m	podstojna etaža glavnih i sporednih vrsta drveća, dijelovi krošanja stabala >5 m	18,21	10
0,5–2 m	sloj grmlja i mladi urast glavnih i sporednih vrsta drveća	23,58	14
<0,5 m	„otvorene površine“ bez vegetacije ili s niskom vegetacijom	54,47	31
Ukupno		174,29	100

proizvodno tlo, te dijelovi dva odsjeka gdje snimanje bespilotnom letjelicom nije bilo dozvoljeno ili nije uspješno izvedeno).

Prije svega, potrebno je istaknuti da prilikom analiziranja dobivenih rezultata podataka treba imati na umu da u visinsku kategoriju <0,5 m ulaze i kamenite i stjenovite površine koje su takve bile i prije spomenutih nepogoda, te nisu rezultat provedenih sanitarnih sječa potkornjakom zaraženih stabala. Generalno, a s obzirom na napad potkornjaka te sječu zaraženih, suhih i bolesnih stabala, pokrovnost vegetacijom u

ANALIZA NASTALIH PROMJENA U SASTOJINSKOM SKLOPU

U ovom dijelu istraživanja, naglasak je prvenstveno na površinama s vegetacijom u visinskoj kategoriji <0,5 m, ali su dodatno analizirane i površine s vegetacijom u visinskoj kategoriji 0,5-2 m.

Kao što je već napomenuto, za površine s vegetacijom u visinskoj kategoriji <0,5 m koristi se termin „otvorene površine“. To su površine bez vegetacije ili s niskom, travnatom vegetacijom, korovskom vegetacijom, zeljastim biljkama, tek mladim biljkama glavnih vrsta

drveća. U visinsku kategoriju <0,5 m ulaze i kamenite i stjenovite površine koje su takve bile i prije spomenutih nepogoda, te nisu rezultat nedavnih sječa zaraženih stabala potkornjakom. Dakle, „otvorene površine“ dijelom su rezultat već postojećeg stanja, a dijelom su nastale kao posljedica sječa u 2019. g.

Površine s vegetacijom u visinskoj kategoriji od 0,5-2 m čini sloj grmlja (npr. mirta, lemprika, tršlja, zelenika), mladi urast glavnih i sporednih vrsta drveća, ali i korovska vegetacija, te invazivne vrste poput pajasena. Stoga su i te površine dodatno analizirane.

Obje visinske kategorije bile su predmet detaljnije GIS analize u okviru ovog istraživanja, i to na način da su sve površine manje od 0,02 ha isključene iz daljnje analize. Primjerice, površina manja od 0,02 ha ne čini dio neke veće suvise površine predstavlja uglavnom prostor između stabala za koji se ne može reći da je nastao sječom odraslog stabla. Prema tome, u spomenutim visinskim kategorijama ostavljene su samo suvise površine (cjeline) veće od 0,02 ha (Tablica 2). Ukupna površina promatranog dijela PŠ Marjan s visinskom kategorijom <0,5 m bez isključivanja malih površina (<0,02 ha) iznosi 54,47 ha ili 31% promatrane površine (174,29 ha). Kada se isključe male površine (<0,02 ha), ukupna površina s visinskom kategorijom <0,5 m iznosi 41,04 ha ili 23,5% promatrane površine (174,29 ha) (Slika 12). Ukupna površina visinskih kategorija <0,5 m i 0,5-2 m bez malih površina (<0,02 ha) iznosi 46,36 ha ili 26,6% promatrane površine (174,29 ha) (Slika 12). Ponavljamo, u navedene površine uključene su i kamenite i stjenovite površine.

U vrijeme provedbe ovog istraživanja, preporuka autora bila je kako prikazane površine (Tablica 2, Slika

12) trebaju bi biti obuhvaćene planom hitne sanacije i obnove. U slučaju izostanka navedenog, na navedenim površinama je potrebno provoditi intenzivan nadzor, a po potrebi i poduzimati zahvate njege poput uklanjanja korovske vegetacije i invazivnih vrsta (npr. pajasen) kako bi se potpomogao razvoj već postojeće mlade autohtone vegetacije.

DETEKCIJA ‘ŽARIŠNIH’ PODRUČJA KOJA ZAHTIJEVAJU HITNU SANACIJU

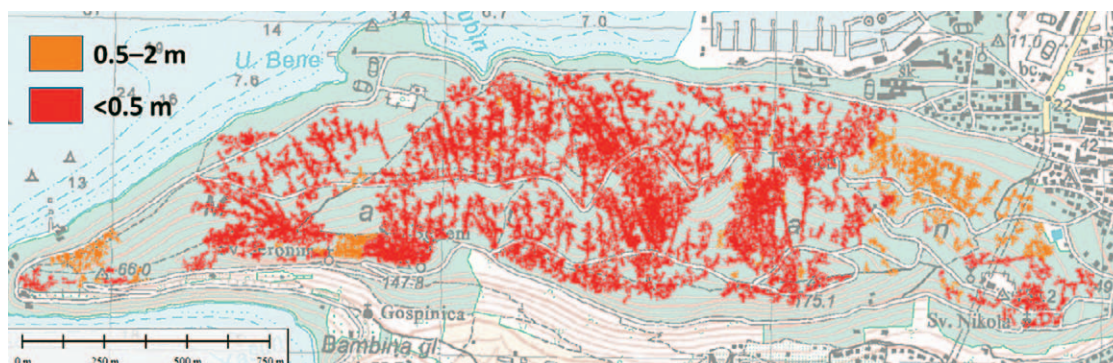
Detekcija ‘žarišnih’ područja koja zahtijevaju hitnu sanaciju provedena je korištenjem prethodno prikazanih materijala (klasificirane površine, DMV, DOF). Vizualnom interpretacijom spomenutih proizvoda manualno su izdvojene 4 potencijalne površine za hitnu sanaciju (Slika 13).

Svaka izdvojena površina detaljno je analizirana korištenjem DOF, rezultata klasificiranih visinskih kategorija, DMR-a, te je za svaku potencijalnu površinu izračunat i analiziran udio pojedine visinske kategorije vegetacije (Tablica 3).


Iz prikazanog (Tablica 3) je vidljivo da izdvojene površine P-2 i P-3 imaju najveće udjele „otvorenih površina“ tj. površina u visinskoj kategoriji <0,5. Također, u usporedbi s udjelom „otvorenih površina“ za čitavo područje PŠ Marjan (31%), udio „otvorenih površina“ za P-2 i P-3 je više nego dvostruko veći (66% i 69%). Nadalje, vidljiv je i znatno manji udio visinske kategorije >5m (odrasla stabla nadstojne etaže) na tim površinama nego što je to prosjek za čitavo područje PŠ Marjan. Takvi rezultati su i razumljivi jer je upravo na površinama P-2 i P-3 obavljena najintenzivnija sanitarna

Tablica 2. Udio „otvorenih površina“ i niske vegetacije (sloja grmlja, korovske vegetacije u ukupnoj promatranoj površini PŠ Marjan.

Visinska kategorija	Površina (ha)	Udio u ukupnoj promatranoj površini od 174,29 ha (%)
„otvorene površine“ (<0,5 m)	54,47	31,3
„otvorene površine“ (<0,5 m) bez površina manjih od <0,02 ha	41,04	23,5
„otvorene površine“ (<0,5 m) i sloj grmlja (0,5-2 m) bez površina manjih od <0,02	46,36	26,6



Slika 12. „Otvorene površine“ (<0,5 m) i sloj grmlja (0,5–2 m) bez površina manjih od <0,02



Slika 13. Potencijalne 'žarišne' površine za hitnu sanaciju i izdvojene površine P-2 i P-3 koje se predlažu kao prioritetne (žuti okvir)

Tablica 3. Površine pojedinih visinskih kategorija i njihovi postotni udjeli iskazani za cijelo promatrano područje PŠ Marjan i svaku izdvojenu potencijalnu 'žarišnu' površinu za hitnu sanaciju.

Visinska kategorija (m)	Površine (ha) i postotni udjeli (%)									
	PŠ Marjan		Područje 1 (P-1)		Područje 2 (P-2)		Područje 3 (P-3)		Područje 4 (P-4)	
	ha	%	ha	%	ha	%	ha	%	ha	%
>5	78,0	45	2,4	26	1,7	20	0,6	12	1,4	17
2-5	18,2	10	1,0	10	0,5	5	0,4	7	1,0	12
0,5-2	23,6	14	1,2	13	0,7	9	0,6	12	1,4	17
<0,5	54,5	31	4,9	51	5,7	66	3,5	69	4,4	54
Ukupno	174,3	100	9,5	100	8,6	100	5,1	100	8,2	100

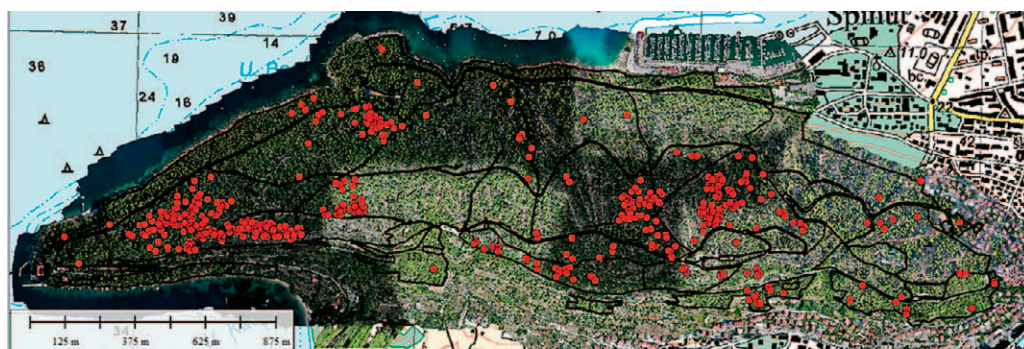
sječa tijekom 2019. g. Na temelju dobivenih rezultata, površine P-2 i P-3 predstavljaju prioritetne površine za hitnu sanaciju (obnova, popunjavanje i njege).

DETEKCIJA PREOSTALIH SUHIH STABLA I GENERALNI UVID U STANJE VEGETACIJE

Vizualnom interpretacijom na DOF-u izrađenom iz MS snimaka (i u manjoj mjeri na DOF-u izrađenom iz RGB) ukupno je detektirano 491 suho stablo (i stablo s manjkom klorofila). Kao dodatna informacija odnosno potvrda ispravnoj detekciji suhih stabala korišten je i NDVI indeks izračunat iz MS snimaka.

Na ovaj način svako stablo je precizno prostorno definirano (Slika 14), što bi trebalo značajno olakšati terenski rad kod traženja suhih stabala te njihovog uklanjanja sanitarnom sječom.

Da bi se dobio uvid u stanje vegetacije na području PŠ Marjan iz MS snimaka izračunat je NDVI indeks (Slika 15). Vrijednosti NDVI indeksa od -1 do 0 prikazane su bijelom bojom, vrijednosti od 0 prema 0,5 u crvenoj boji koja s povećanjem iznosa prelazi prema narandžastoj i žutoj. Daljnjim porastom, vrijednosti NDVI indeksa od 0,5 prema 1 prikazane su od svijetlo zelene do tamno zelene boje. Za analizu stanja vegetacije odabrana su



● suha stabla (i stabla s manjkom klorofila)

Slika 14. Prostorni raspored vizualnom interpretacijom detektiranih suhih stabala.


samo površine klasificirane s visinskom kategorijom vegetacije >5 m, dok je ostali dio PŠ Marjan bio isključen (zamaskiran) iz analize (Slika 16). Na taj način su iz analize izuzete ceste, kameni i stjenoviti dijelovi, te travnata i niska vegetacija, a obuhvaćena su samo stabla alepskog bora i sporednih vrsta drveća (čempres, crnika). Analizom je obuhvaćena površina od 70,9 ha od ukupno 78,0 ha klasificirano kao visinska kategorija >5 m. Naime, zbog već navedenih tehničkih smetnji tijekom snimanja MS snimke za pojedine dijelove PŠ Marjan nisu bile uporabljive.

Rezultati NDVI indeksa za promatrano područje (70,9 ha) prikazani su na slici 17. Iz grafikona je vidljivo da 67,69 ha ili 95,5% promatrane površine ima NDVI indeks iznad 0,4. Stoga možemo zaključiti da je 95,5% površine pokriveno krošnjama odraslih stabala u vrijeme snimanja (kolovoz 2019. g.) bilo zadovoljavajućeg zdravstvenog stanja. Ostatak površine, točnije 4,5% promatrane površine pokriven je krošnjama suhih stabala.


Dobiveni rezultati ukazuju na uspješnost provedenih zahvata sanitarne sječe tijekom 2019. g. Nakon provedene sanitarne sječe nije ostavljen velik broj stabala koji bi bili izvorom zaraze potkornjaka te se može reći da su uklonjena većina fiziološki slabih stabla koja su uobičajena meta potkornjaka. Međutim, s obzirom na trajnu prisutnost i opasnost od gradacije potkornjaka i dalje treba pratiti njegovu dinamiku.

ZAKLJUČCI

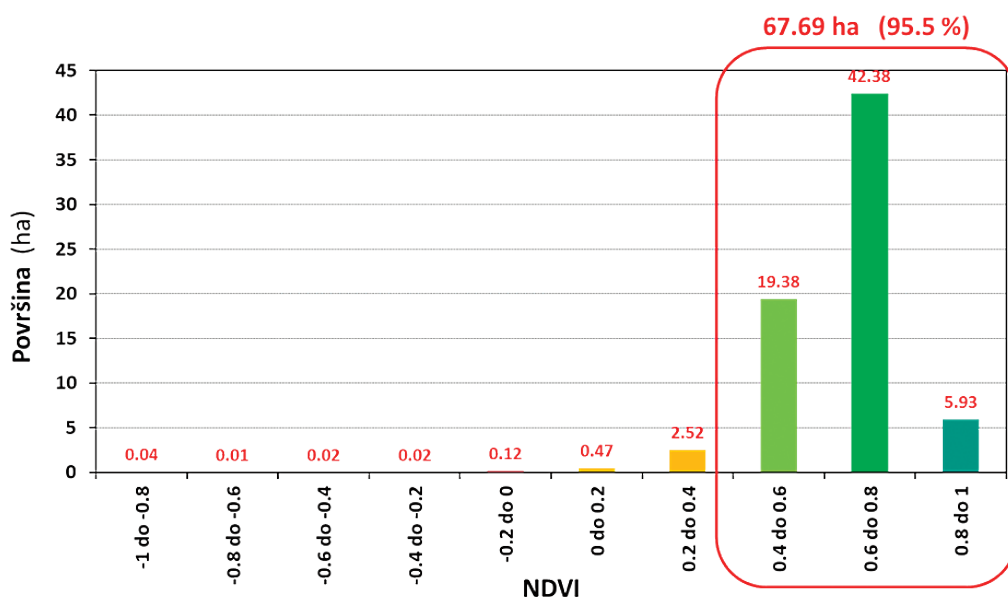
Ovim istraživanjem dobiveni su prostorno precizno određeni podaci o stanju vegetacije na području Park šume Marjan nakon provedenih sanitarnih sječa vrijeme snimanja bespilotnom letjelicom (kolovoz 2019. g.). Istraživanje je potvrdilo veliki potencijal bespilotnih letjelica i korištenih senzora (klasična fotogrametrijska kamera, multispektralna kamera) za dobivanje kvalitetnih i pouzdanih informacija o stanju šuma u vrlo



Slika 15. NDVI indeks korišten za uvid u stanje vegetacije na području PŠ Marjan.



Slika 16. NDVI indeks izračunat za područja s vegetacijom klasificiranom u visinsku kategoriju >5m.



Slika 17. NDVI indeks izračunat za područja (70,9 ha) s vegetacijom klasificiranom u visinsku kategoriju >5m.

kratkom vremenu s relativno malih površina. Na temelju niza izrađenih fotogrametrijskih i geoinformacijskih proizvoda provedene su detaljne geoprostorne analize. Utvrđeno je da pokrovnost površine Park šume Marjan s vegetacijom iznad 5 m visine iznosi 45%. Međutim, zabrinjavajuće je mali udio vegetacije u rasponu od 2 – 5 m visine, a koja bi u bliskoj budućnosti trebala preuzeti ulogu visoke vegetacije (nadstojne etaže). Nadalje, detektirane su i izdvojene dvije ‘žarišne’ površine (13,7 ha) koje imaju najveće udjele otvorenih površina (visinska kategorija <0,5, a koje stoga predstavljaju prioritete dijelove Park šume Marjan za hitnu sanaciju (obnova, popunjavanje i njege). Na temelju rezultata izračunatog NDVI indeksa za promatrano područje (70,9 ha) utvrđeno je da je 95,5% površine pokriveno krošnjama odraslih stabala u vrijeme snimanja (kolovoz 2019. godine) bilo zadovoljavajućeg zdravstvenog stanja. Iz toga se može zaključiti da je provedenom sanitarnom sječom uklonjena većina suhih stabala. Vizualnom interpretacijom multispektralnih snimaka ukupno je detektirano 491 preostalo suho stablo (i stablo s manjkom klorofila), a koja su ujedno precizno prostorno definirano čime bi njihov pronalazak na terenu u svrhu daljnjeg uklanjanja sanitarnom sječom trebao biti značajno olakšan. Dobiveni podaci trebali bi poslužiti kao temelj za uspostavu daljnjeg monitoringa (terenskim metodama i metodama daljinskih istraživanja) i izvođenja pravovremenih preventivnih stručnih aktivnosti na području Park šume Marjan.

FINANCIRANJE

Ovo istraživanje financirano od strane Grada Splita je kroz projekt “Geoprostorna analiza stanja šumskog pokrova Park šume Marjan korištenjem snimaka bespilotne letjelice”.

SUKOB INTERESA

Autori nemaju sukob interesa za prijaviti.

LITERATURA

- Balenović, I., Jurjević, L., Indir, K., Seletković, A., 2021. Fotogrametrijska procjena volumena u sastojinama hrasta lužnjaka pokupskog bazena. Šumarski list, 145(11-12): 578-579. <https://doi.org/10.31298/sl.145.11-12.6>
- Colomina, I., Molina, P., 2014. Unmanned aerial systems for photogrammetry and remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing, 92: 79-97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>.
- Jurjević, L., Gašparović, M., Liang, X., Balenović, I., 2021. Assessment of Close-Range Remote Sensing Methods for DTM Estimation in a Lowland Deciduous Forest. Remote Sensing, 13(11): 2063. <https://doi.org/10.3390/rs13112063>.
- Miyoshi, G. T., Imai, N. N., Tommaselli, A. M. G., Honkavaara, E., 2020. Spectral Differences Of Tree Species Belonging To Atlantic Forest Obtained From Uav Hyperspectral Images. Zbornik radova: 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS), 60-65. <https://doi.org/10.1109/LAGIRS48042.2020.9165616>.
- Nex, F., Armenakis, C., Cramer, M., Cucci, D. A., Gerke, M., Honkavaara, E., Kukko, A., Persello, C., Skaloud, J., 2022. UAV in the advent of the twenties: Where we stand and what is next. ISPRS Journal of Photogrammetry and Remote Sensing, 184: 215-242. <https://doi.org/10.1016/j.isprsjprs.2021.12.006>.

Pernek, M., Zorić, N., Matek, M., Lukić, I., Agbaba, S.N., Liović, B., Mihaljević, I., Lacković, N., 2019a. Sušenje alepskog bora i gradacija potkornjaka *Orthotomicus erosus* u park šumi Marjan. *Radovi*, 46(1): 1-18.

Pernek, M., Lacković, N., Lukić, I., Zorić, N., Matošević, D., 2019b. Outbreak of *Orthotomicus erosus* (Coleoptera, Curculionidae) on Aleppo Pine in the Mediterranean Region in Croatia. *South-east European forestry*, 10(1): 19-27. <https://doi.org/10.15177/seeфор.19-05>.

Torresan, C., Berton, A., Carotenuto, F., Di Gennaro, S. F., Gioli, B., Matese, A., Miglietta, F., Vagnoli, C., Zaldei, A., Wallace, L., 2017. Forestry applications of UAVs in Europe: A review. *International Journal of Remote Sensing*, 38 (8-10): 2427-2447. <https://doi.org/10.1080/01431161.2016.1252477>.

Torresan, C., Berton, A., Carotenuto, F., Chiavetta, U., Miglietta, F., Zaldei, A., Gioli, B., 2018. Development and performance assessment of a low-cost UAV laser scanner system (LasUAV). *Remote Sensing*, 10(7):1094. <https://doi.org/10.3390/rs10071094>.

Vrdoljak, Ž., 1996. Park šuma Marjan, razvoj, sadašnje stanje i smjernice za budući tretman. *Šumarski list*, 120(7-8): 307-318.

GEOSPATIAL ANALYSIS OF THE STATE OF THE MARJAN FOREST PARK BASED ON PHOTOGRAMMETRIC DATA OF THE UNMANNED AERIAL VEHICLE

SUMMARY

In 2017, an intensive wilting and drying of Aleppo pine trees caused by Mediterranean pine engraver (*Orthotomicus erosus* Woll.) was reported in Marjan Forest Park (Split, Croatia) which intensified and culminated in 2018 and 2019. To prevent further spread of pathogen and decay of trees, sanitary felling of dry and infected trees was conducted in 2019. In order to get a quick and detailed insight into the state of vegetation of the Marjan Forest Parka unmanned aerial vehicle (UAV) survey was conducted using a classic photogrammetric and multispectral cameras immediately after the sanitary felling. The main goal was to obtain a current state of vegetation, which will be the basis for the establishment of further monitoring and adoption of timely management activities with the aim to preserve the Marjan Forest Park. Based on UAV data of a very high spatial and spectral resolution, a number of photogrammetric and geoinformation products were created and used for detailed geospatial analyzes of the forest cover of the Marjan Forest Park. This research confirmed the great potential of UAV and used sensors for obtaining quality and reliable information on forests' state from relatively small areas in a very short time. The results revealed that Marjan Forest Park has satisfactory surface coverage (45%) with vegetation above 5 m in height. However, the surface coverage with vegetation in the range of 2 - 5 m in height is not satisfactory. In the near future this vegetation should take the role of high vegetation (dominant and co-dominant forest layer). Furthermore, two critical areas (13.7 ha) with the highest shares of open areas (areas without vegetation and with low vegetation below <5 m in height) were detected. These two areas, therefore, present priority parts of the Marjan Park Forest for rehabilitation and regeneration. Based on calculated NDVI index, it was revealed that 95.5% of canopies of trees above in 5 m in height had satisfactory health condition (NDVI>0.4) in time of UAV survey (August 2019). Visual interpretation of multispectral images revealed a total of 491 remaining dry and chlorophyll-deficient trees. Since these trees are precisely spatially defined, they should be easily find in the field and removed by sanitary felling.

Keywords: tree dieback, Aleppo pine (*Pinus halepensis*), Mediterranean pine engraver (*Orthotomicus erosus*), remote sensing, photogrammetry, unmanned aerial vehicle (UAV)