

Geoprostorne tehnologije u analizi vegetacijskih indeksa na primjeru krošanja Lunjskih maslinika

Marinović, Rajko

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:162:333496>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-01-10**



Sveučilište u Zadru
Universitas Studiorum
Jadertina | 1396 | 2002 |

Repository / Repozitorij:

[University of Zadar Institutional Repository](#)



zir.nsk.hr



DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJ

Sveučilište u Zadru

Odjel za geografiju

Diplomski jednopredmetni sveučilišni studij primijenjene geografije

Rajko Marinović

Geoprostorne tehnologije u analizi vegetacijskih indeksa na primjeru krošanja Lunjskih maslinika

Diplomski rad

Zadar, 2022.

Sveučilište u Zadru

Odjel za geografiju

Diplomski jednopredmetni sveučilišni studij primijenjene geografije

Geoprostorne tehnologije u analizi vegetacijskih indeksa na primjeru
krošanja Lunjskih maslinika

Diplomski rad

Student/ica:
Rajko Marinović

Mentor/ica:
izv. prof. dr. sc. Ante Šiljeg

Zadar, 2022.



Izjava o akademskoj čestitosti

Ja, **Rajko Marinović**, ovime izjavljujem da je moj **diplomski** rad pod naslovom **Geoprostorne tehnologije u analizi vegetacijskih indeksa na primjeru krošanja Lunjskih maslinika** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 20. veljače 2022.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zadru

Odjel za geografiju

Diplomski rad

GEOPROSTORNE TEHNOLOGIJE U ANALIZI VEGETACIJSKIH INDEKSA NA PRIMJERU KROŠANJA LUNJSKIH MASLINIKA

Rajko Marinović

Izvadak

Geoprostorne tehnologije omogućuju primjenu novih metoda i tehnika koje rezultiraju suvremenijim i drugačijim idejama u pogledu rješavanja istraživačkih pitanja, poglavito u preciznoj poljoprivredi gdje je njihova primjena široko obuhvatna. Stoga je glavni cilj rada usporedba dva pristupa (geografski objektno-orijentirani (GEOBIA) i vegetacijski indeksi) u procesu kartiranja krošanja maslina. Područje istraživanja je testna ploha unutar vrtova Lunjskih maslina, otok Pag. Prilikom aerofotogrametrijskog snimanja korištena je bespilotna letjelica *Trinity F90+*, opremljena s multispektralnim senzorom *MicaSense RedEdge-MX Dual* i RGB senzorom *Sony RX1R II*. Multispektralni senzor korišten je za potrebe generiranja multispektralnog modela vrlo visoke prostorne rezolucije na kojem je provedena većina istraživanja, dok je druga misija obavljena u svrhu izrade DOF-a vrlo visoke rezolucije. Prilikom provođenja GEOBIA pristupa u izdvajanju krošanja maslina, ispitani su i optimizirani korisničko-definirani parametri, kao i korišteni klasifikacijski algoritmi za procjenu točnosti, a model algoritma *RT* odabran kao najbolji. Drugi pristup temeljen je na odabranim vegetacijskim indeksima, koji su optimizirani pomoću izrađenog alata *VITO*. Provjerom točnosti pomoću mjere *AUC*-a, model *NDRE* indeksa odabran je kao najbolji. Modeli dvaju pristupa uspoređeni su pomoću pet mjera za procjenu točnosti, što je rezultiralo odabirom vegetacijskih indeksa kao točnijim pristupom u kartiranju krošanja maslina. Varijabilnosti vegetacijskih indeksa unutar krošnji maslina, ukazuju na mogućnost primjene vegetacijskih indeksa i geoprostornih tehnologija u maslinarstvu s ciljem suzbijanja štetnika i očuvanja zdravih maslina.

Ključne riječi: geoprostorne tehnologije; vrtovi Lunjskih maslinika; aerofotogrametrija; multispektralni snimci; modeli vrlo visoke rezolucije; GEOBIA; vegetacijski indeksi

Voditelj: izv. prof. dr. sc. Ante Šiljeg

Povjerenstvo: doc. dr. sc. Ivan Marić; izv. prof. dr. sc. Ante Šiljeg; dr. sc. Fran Domazetović

BASIC DOCUMENTATION CARD

University of Zadar

Department of Geography

Graduation thesis

GEOSPATIAL TECHNOLOGIES IN THE ANALYSIS OF VEGETATION INDICES ON THE EXAMPLE OF THE CANOPY OF LUN OLIVE GROVES

Rajko Marinović

Abstract

Geospatial technologies enable the application of new methods and techniques that result in modern and different ideas in terms of solving research issues. Therefore, the main goal is to compare two approaches (GEOBIA and vegetation indices) in the process of mapping olive tree canopy. The research area is a small test area within the gardens of Lun's olives, on the island of Pag. The *Trinity F90* + UAV, equipped with a *MicaSense RedEdge-MX Dual* multispectral sensor and RGB sensor *Sony RX1R II*, was used for aerial photogrammetry. The MS sensor was used for the purpose of generating a very high spatial resolution multispectral model on which most of the research was conducted, while another mission was performed for the purpose of making a very high resolution DOP. When implementing the GEOBIA approach in the isolation of olive canopy, user-defined parameters were tested and optimized, as well as the classification algorithms *SVM*, *ML* and *RT* were used, of which according to the measures (*UA*, *PA*, *OA* and *KC*) for accuracy assessment, *RT* algorithm model selected as the best. The second approach is based on selected vegetation indices (*NDVI*, *NDRE*, *GNDVI*, *MCARI2* and *RDVI2*) which are optimized using the developed VITO tool. The *NDRE* index model was selected as the best, according to *AUC* accuracy measure. Models of the two approaches were compared using five measures to assess accuracy, which resulted in the selection of vegetation indices as more accurate approach in olive canopy mapping. The variability of vegetation indices within olive canopies indicates the possibility of applying vegetation indices and geospatial technologies in olive growing with the aim of controlling and preserving healthy olives.

Keywords: geospatial technologies; Lun olive groves; aerial photogrammetry; multispectral images; very high resolution models; GEOBIA; vegetation indices

Supervisor: Associate Professor Ante Šiljeg, PhD

Reviewers: Assistant Professor Ivan Marić; Associate Professor Ante Šiljeg, PhD; Assistant Fran Domazetović, PhD

Sadržaj

Predgovor	7
1. Uvod	8
1.1. Objekt, svrha i ciljevi istraživanja	9
1.2. Hipoteze.....	10
1.3. Pregled dosadašnjih istraživanja.....	11
2. Područje istraživanja	16
3. Teorijska osnova.....	17
3.1. Geoprostorne tehnologije	17
3.1.1. Bepilotne letjelice	17
3.1.2. Izravno georeferenciranje	18
3.1.3. Multispektralni senzori	18
3.1.4. RGB senzori	19
3.2. Geografski objektno-orijentirane analize (GEOBIA)	19
3.3. Vegetacijski indeksi.....	20
3.3.1. Vrste vegetacijskih indeksa	21
3.3.1.1. NDVI vegetacijski indeks.....	22
3.3.1.2. NDRE vegetacijski indeks.....	23
3.3.1.3. GNDVI vegetacijski indeks.....	24
3.3.1.4. MCARI2 vegetacijski indeks	25
3.3.1.5. RDVI2 vegetacijski indeks.....	25
3.4. Primjena geoprostornih tehnologija u analizi vegetacijskih indeksa	26
4. Metodologija istraživanja	27
4.1. Prikupljanje podataka	27
4.1.1. Korištene geoprostorne tehnologije.....	29
4.1.1.1. Bepilotna letjelica <i>Trinity F90+</i>	29
4.1.1.2. Bazna stanica <i>iBase</i>	30

4.1.1.3. Multispektralni senzor <i>MicaSense RedEdge-MX Dual Camera</i>	31
4.1.1.4. RGB senzor <i>Sony RX1R II</i>	32
4.1.1.5. RTK-GNSS <i>Trimble R8s</i>	33
4.1.1.6. Softver za planiranje i upravljanje misijama <i>QBase 3D</i>	33
4.1.2. Označavanje i prikupljanje točaka lokalne geodetske osnove.....	34
4.1.2.1. Označavanje i prikupljanje kontrolnih točaka	34
4.1.2.2. Referentna točka i postavljanje bazne stanice	36
4.1.3. Kalibracija bespilotne letjelice i MS senzora	37
4.1.4. Aerofotogrametrijsko snimanje područja istraživanja.....	38
4.1.4.1. Planiranje misija	38
4.1.4.2. Provođenje misija	39
4.2. Obrada prikupljenih podataka	41
4.2.1. Kopiranje <i>Flylog</i> zapisa i georeferenciranje fotografija.....	42
4.2.2. Proces obrade zračnih snimaka u <i>Agisoft Metashape Professional 1.5.1</i> ..	43
4.3. Ispitivanje točnosti izravnog georeferenciranja.....	44
4.4. GEOBIA pristup u kartiranju krošanja maslina	45
4.4.1. Odabir optimalnog rasporeda spektralnih kanala	46
4.4.2. Segmentacija.....	47
4.4.3. Dodavanje testnih uzoraka	48
4.4.4. Klasifikacija.....	49
4.4.5. Reklasifikacija	52
4.4.6. Provjera točnosti klasifikacijskih algoritama	52
4.4.6.1. Mjere provjere točnosti.....	52
4.4.6.2. Koraci provjere točnosti	53
4.5. Pristup temeljen na vegetacijskim indeksima u kartiranju krošanja maslina	55
4.5.1. Generiranje odabranih vegetacijskih indeksa	56
4.5.2. Izdvajanje krošanja maslina pomoću alata VITO	57

4.5.3. Provjera točnosti vegetacijskih indeksa.....	59
4.6. Usporedba korištenih pristupa u kartiranju krošanja maslina	60
4.7. Istraživanje varijabilnosti vegetacijskih indeksa unutar krošnje	61
5. Rezultati i rasprava	62
5.1. Prikupljene fotografije MS i RGB senzora	62
5.2. Rezultati obrade podataka u <i>Agisoft Metashape Professional</i>	63
5.2.1. Rijetki oblak točaka.....	63
5.2.2. Gusti oblak točaka	63
5.2.3. Poligonalna i teksturirana poligonalna mreža	64
5.2.4. Multispektralni model vrlo visoke rezolucije.....	65
5.3. Točnost izravnog georeferenciranja	66
5.4. Digitalni ortofoto (DOF) vrlo visoke rezolucije.....	68
5.5. Rezultati GEOBIA pristupa kartiranja krošanja maslina	69
5.5.1. Optimalan raspored spektralnih kanala	69
5.5.2. Segmentirani MS model	69
5.5.3. Prikupljeni testni uzorci.....	70
5.5.4. Izvedene klasifikacije MS modela.....	71
5.5.5. Reklasificirani MS modeli.....	72
5.5.6. Točnost klasifikacijskih algoritama.....	74
5.5.7. Odabrani model GEOBIA pristupa	75
5.6. Rezultati kartiranja krošanja maslina korištenjem vegetacijskih indeksa	76
5.6.1. Izvedeni modeli vegetacijskih indeksa	76
5.6.2. Izlazni rezultati alata VITO	78
5.6.3. Točnost modela vegetacijskih indeksa	79
5.6.4. Odabrani model pristupa temeljenog na vegetacijskim indeksima	80
5.7. Rezultati usporedbe dvaju pristupa	80
5.8. Varijabilnosti vegetacijskih indeksa unutar krošanja maslina.....	83

6. Zaključak	86
Literatura	88
Izvori.....	99
Popis grafičkih priloga	100
Popis tabličnih priloga.....	103
Sažetak.....	104
Summary.....	105

Predgovor

Nove tehnike, alati i vještine unutar interdisciplinarnog područja geografije, omogućuju modernija i preciznija istraživanja različitih geografskih fenomena i problemskih pitanja. Dostupnost i korištenje geoprostornih tehnologija iz dana u dan sve je veća, a primjenjivost sve šira. Velik broj gospodarskih djelatnosti danas je teško zamisliv bez upotrebe određenog tipa geoprostorne tehnologije. Unutar precizne poljoprivrede, geoprostorne tehnologije neophodne su u smislu postizanja napretka u proizvodnji i praćenja suvremenih europskih trendova. Maslinarstvo kao grana poljoprivrede, vrlo česta u primorskih krajevima Republike Hrvatske, rijetko je povezana s tehnološkim postignućima u preciznoj poljoprivredi. Stoga je potrebno poticati korištenje geoprostornih tehnologija u maslinarstvu, ponajprije zbog očuvanja ovog jedinstvenog mediteranskog simbola. Glavi geografski zadatak je na što bolji način iskoristiti postojeće geoprostorne tehnologije s ciljem poboljšanja znanstvenih spoznaja o području koje nas okružuje.

Ovaj rad je izrađen u sklopu projekta Hrvatske zaklade za znanost (UIP-2017-05-2694) pod vodstvom izv. prof. dr. sc. Ante Šiljega.

Ovim putem želio bih zahvaliti svom mentoru izv. prof. dr. sc. Anti Šiljegu na ukazanom povjerenju, ustrajnosti, prenošenju znanja i iskustva, ali i učestalom poticanju i motivaciji tijekom trajanja studija, koji su uvelike olakšali pisanje ovog diplomskog rada i potaknuli želju za daljnim napredovanjem u GIS okruženju. Veliko hvala članovima stručnog povjerenstva doc. dr. sc. Ivanu Mariću i dr. sc. Franu Domazetoviću, na savjetima i konstruktivnim kritikama koje su značajno doprinjele kvaliteti rada. Veliko hvala i mag.geogr. Lovri Pandi koji me upoznao i pripremio za cjelokupni proces završetka studija te tako uvelike olakšao put ka diplomi. Hvala svim kolegama koji su bili uz mene svih ovih godina, poglavito u pogledu bezbrojnih ispijanja kava i druženja kojih ćemo se uvijek rado sjećati. Veliko hvala mojoj djevojci Mihaeli, koja me tijekom pisanja diplomskog rada oslobodila obveze obavljanja svih kućanskih poslova i na taj način značajno doprinjela brzini i kvaliteti pisanja. Na posljetku, najveće zahvale upućene su mojim roditeljima Renati i Stanku koji su svojim radom i zalaganjem zapravo omogućili moj odlazak i boravak u Zadru tijekom trajanja studija, i bez čije ljubavi i potpore ništa ne bi bilo isto.

1. Uvod

Maslina je jedna od najstarijih vrsta na području Mediterana (Besnard i dr., 2011; Díez i dr., 2011; Kostelenos i dr., 2017) koja se tijekom povijesti rasprostranila i oblikovala prepoznatljiv mediteranski krajolik (Potts i dr., 2006; Serra i dr., 2008). Otpornost na ekstremne klimatološke prilike i prilagodljivost različitom tipu slabo plodnih tala, osigurava maslini društvenu, ekološku i gospodarsku korist (Rodríguez Sousa i dr., 2020; Fraga i dr., 2021). Očuvanje masline kao temeljnog identiteta mediteranskog područja (Loumou i Giourga, 2003) zbog čestih utjecaja raznovrsnih gospodarskih djelatnosti poput industrije (Belletti i dr., 2015) i turizma (Čurović i dr., 2019; Hernández-Mogollón i dr., 2021), najviše ovisi o održivom upravljanju okolišem temeljenom na metodologiji precizne poljoprivrede (Solano i dr., 2019; Jurišić i dr., 2021). Razvoj suvremenih geoprostornih tehnologija implementirao je preciznu poljoprivredu u sektor maslinarstva i omogućio precizno kartiranje krošanja u svrhu upravljanja (Rosell i Sanz, 2012), nadzora (Fernández i dr., 2016; Šiljeg i dr., 2020), procjene kvalitete uroda (Stateras i Kalivas, 2020) detekcije bolesti (Nolè i dr., 2018) i preventivnih djelovanja (Martinelli i dr., 2015). Geoprostorne tehnologije imaju važnu ulogu u promatranju i analizi raznovrsnih procesa smještenih na površini Zemlje (Bodzin i Cirucci, 2009; Jackson i dr., 2009; Bishop i dr., 2012; Šiljeg i dr., 2018; Marqures i dr., 2019). Razvoj i upotreba bespilotnih letjelica, postali su ravnopravni u usporedbi sa satelitskim sustavima prilikom faze prikupljanja podataka, a prednjače u boljoj prostorno-vremenskoj rezoluciji i fleksibilnosti (Adão i dr., 2017). Bespilotne letjelice definiraju se kao objekti kojima se može upravljati na daljinu ili unaprijed zadati programirani plan leta (Sullivan, 2006; Ozdemir i dr., 2014), te je njihova glavna prednost mogućnost prikupljanja podataka vrlo visoke prostorne rezolucije (Jenkins i Vasigh 2013; Emillien i dr., 2021; Sozzi i dr., 2021). Korištenje bespilotnih letjelica i mogućnost postavljanja različitih vrsta senzora olakšava i omogućuje učestaliju upotrebu geoprostornih tehnologija prilikom provođenja istraživanja (Jenkins i Vasigh, 2013; Pádua i dr., 2017). U procesu daljinskih istraživanja multispektralni senzori jedan su od najmoćnijih alata u smislu boljeg razumijevanja okolišnih procesa (Stow i dr., 1996). Također, jedni su od najkorištenijih senzora, na što je prvenstveno utjecala njihova izuzetna primjenjivost u šumarstvu, preciznoj poljoprivredi i drugim gospodarskim djelatnostima koje su u bliskoj vezi s vegetacijom (Pádua i dr., 2017). Multispektralni senzori pružaju uvid u ljudskom oku nevidljivi dio elektromagnetskog spektra, te u smislu daljinskih istraživanja predstavljaju značajan doprinos s ciljem boljeg razumijevanja okolišnih procesa (Stow i dr., 1996; Iqbal i dr.,

2018). Multispektralni senzori vodeću ulogu imaju u preciznoj poljoprivredi i analizi vegetacijskih površina, posebice zbog mogućnosti izdvajanja vegetacijskih indeksa (Avola i dr. 2019). Vegetacijski indeksi jedni su od korištenijih pokazatelja unutar geoprostornih analiza i precizne poljoprivrede (Heute, 2012; Solano i dr., 2019; Messina i dr., 2020), te se definiraju kao rezultat kombinacije dvaju ili više spektralnih kanala (Perry Jr. i Lautenschlager, 1984; Jackson i Heute, 1991; Bannari i dr. 1995). Analize vegetacijskih indeksa gotovo su nemoguće bez upotrebe multispektralnih senzora koji omogućuju klasifikaciju istraživanog prostora na temelju spektralnih karakteristika (Baret i Guyot 1990; Xue i Su, 2017). Prvenstveno se koriste u svrhu izdvajanja promatranih usjeva ili analiziranja krošnji raznovrsnih biljaka (Candiago i dr., 2015; Jurišić i dr., 2021). Klasifikacije promatranih površina provode se na različite načine, a osim novijeg pristupa temeljenog na vegetacijskim indeksima, najkorišteniji pristup vezan je uz geografski objektno-orijentirane analize (Blaschke i dr., 2014; Chen i dr., 2018). GEOBIA se definira kao poddisciplina geografskih informacijskih sustava usmjerena na obradu i analizu rasterskih podataka (Hay i Castilla, 2008). Za razliku od pikseli-orijentiranih analiza, GEOBIA grupira piksele u smislene homogene cjeline prema njihovim spektralnim karakteristikama (Blaschke i dr., 2014). Usporedba i ocjena točnosti kartiranja krošanja maslina pristupom temeljenim na vegetacijskim indeksima i GEOBIA pristupom, nužna je s ciljem unaprjeđenja održivog upravljanja nasadima maslina i drugih biljaka sličnih karakteristika.

1.1. Objekt, svrha i ciljevi istraživanja

Objekt istraživanja su krošnje maslina unutar odabranog područja vrtova Lunjskih maslinika na otoku Pagu.

Svrha ovog diplomskog rada je ispitivanje točnosti dvaju korištenih pristupa (GEOBIA i odabrani vegetacijski indeksi) te istraživanje mogućnosti primjene vegetacijskih indeksa u procesu kartiranja krošanja maslina na temelju multispektralnih snimki vrlo visoke prostorne rezolucije. Rezultati i spoznaje koji će se dobiti u provedenim analizama unutar diplomskog rada, pomoći će donositeljima odluka u detektiranju promjena, upravljanju okolišem, zoniranju, ali i određivanju smjernica u preciznoj poljoprivredi.

Ciljevi istraživanja su definirani s obzirom na svrhu i korištene metode:

C1 - Izraditi i utvrditi pozicijsku točnost multispektralnog modela vrlo visoke rezolucije dobivenog procesom direktnog georeferenciranja.

C2 - Utvrditi koji od testiranih klasifikacijskih algoritama (*SVM - Support Vector Machine, ML - Maximum Likelihood, RT - Random Trees*) najtočnije izdvaja krošnje maslina.

C3 - Optimizirati vrijednosti pragova vegetacijskih indeksa s ciljem točnijeg kartiranja krošanja maslina.

C4 - Utvrditi koji od testiranih vegetacijskih indeksa (*NDVI, NDRE, GNDVI, MCARI2, RDVI2*) najtočnije kartira krošnje maslina.

C5 - Testirati točnost kartiranja krošanja maslina dva pristupa (*GEOBIA* i vegetacijski indeksi) pomoću mjera za procjenu točnosti *PA - Producer Accuracy, UA - User Accuracy, OA - Overall Accuracy, KC - Kappa Coefficient* i *AUC - Area Under Curve*.

C6 - Usporediti rezultate dobivene vegetacijskim indeksima i *GEOBIA* pristupom.

C7 - Identificirati varijabilnosti vegetacijskih indeksa unutar krošanja maslina.

1.2. Hipoteze

Iz postavljenih ciljeva istraživanja, korištenih geoprostornih tehnologija, njihovih specifikacija, korištenih metodologija i proučavanja prethodnih istraživanja postavljene su sljedeće hipoteze:

H1 - Ukupna pogreška testirane opcije PPK pozicioniranja VTOL sustava bespilotne letjelice *Trinity F90+* na visini leta od 100m u izmjerenim kontrolnim točkama (KT) bit će centimetarska (<10 cm).

H2 - Klasifikacijski algoritam SVM pokazat će najbolje rezultate u *GEOBIA* pristupu kod izdvajanja krošnji maslina prema mjeri ukupne točnosti.

H3 - Točnost modela krošnji maslina izdvojenih *NDRE (Normalized Difference Red Edge)* vegetacijskim indeksom iskazana vrijednostima *AUC*-a bit će iznad 0,85.

H4 - Pristup temeljen na vegetacijskim indeksima točnije će izdvojiti krošnje maslina od *GEOBIA* pristupa prema mjeri ukupne točnosti.

H5 - Varijabilnost vegetacijskih indeksa unutar krošanja maslina omogućit će detekciju suhih ili nezdravih dijelova krošnje.

1.3. Pregled dosadašnjih istraživanja

Pregled dosadašnjih istraživanja metodološki je podijeljen u tri grupe:

(1) Multispektralni snimci vrlo visoke rezolucije - proučeni su znanstveni radovi koji prikazuju proces izrade multispektralnih snimaka vrlo visoke rezolucije s naglaskom na primjenu u detektiranju krošanja maslina ili drugih vegetacijskih vrsta sličnih spektralnih karakteristika.

Aasen i dr. (2018) navode kako je razvoj tehnologije daljinskih istraživanja doveo do revolucije prikupljanja podataka vrlo visoke prostorne rezolucije. U fazi prikupljanja podataka koriste VTOL bespilotnu *TerraLuma*. Točnost pozicioniranja multispektralnog modela ispitana je pomoću GNSS uređaja i iznosi od 4 do 6 cm na visini leta od 50 m. U radu uspoređuju različite načine prikupljanja i obrade prostornih podataka te u zaključku navode kako u budućnosti treba težiti ka standardiziranju procedura izrade multispektralnih modela.

Di Nisio i dr. (2020) predlažu korištenje multispektralnih snimki vrlo visoke rezolucije dobivene iz bespilotne letjelice u svrhu istraživanja i kartiranja krošanja maslina koje su zaražene bakterijskim biljnim patogenom. Korištene geoprostorne tehnologije uključuju VTOL tip bespilotne letjelice *Italdron 4HSE* opremljenu s multispektralnim senzorom *MicaSense RedEdge-M* koji područje snima s pet spektralnih kanala i RGB fotoaparatom *Sony a7r*. Koriste direktno georeferenciranje sustava bespilotne letjelice za pozicioniranje multispektralnog modela. Istraživanjem pokazuju opravdanost korištenja ulaznih podataka što potkrepljuju vrijednostima različitih mjera točnosti izračunatih pomoću kreirane konfuzijske matrice.

Maes i Steppe (2019) u preglednom radu pišu o različitim mogućnostima primjene bespilotnih letjelica unutar područja precizne poljoprivrede. Ističu važnosti korištenja multispektralnih senzora s većim brojem kanala namijenjenih snimanju u rubnom crvenom i infracrvenom dijelu elektromagnetskog spektra. U zaključku navode kako je primjenjivost multispektralnih modela vrlo visoke rezolucije velika, poglavito u preciznoj poljoprivredi.

Melville i dr. (2019) koriste multispektralne modele vrlo visoke rezolucije izrađene uz pomoć korištenja multi-rotor VTOL tipa bespilotne letjelice *DJI S1000* i multispektralnog senzora *PhontonFocus MVI*. Prostorna rezolucija modela koji je izrađen unutar softvera *AgiSoft Metashape* iznosila je 15 cm, dok je pozicijska točnost od 5 do 10 cm utvrđena pomoću GNSS uređaja prikupljanjem orijentacijskih i kontrolnih točaka. Koriste klasifikacijski algoritam *Random Trees* unutar softvera *eCognition* kako bi klasificirali tipove travnatih

zemljišta unutar područja istraživanja i naglašavaju primjenjivost korištene metodologije u drugim istraživanjima unutar kojih je objekt istraživanja određeni tip vegetacije.

Sankaran i dr. (2015) istraživanje temelje na analizi dostupnih tehnologija i pristupa u procesu izrade multispektralnog modela i kartiranja vegetacije sa svrhom poboljšanja otpornosti usjeva na određene bolesti. Uspoređuju različite vrste bespilotnih letjelica (*VTOL, Fixed-wing, Hybrid VTOL*) navodeći glavne prednosti i mane unutar precizne poljoprivrede. Također, uspoređuju i različite dostupne senzore (*RGB, multispektralne, termalne, LIDAR*) te ističu kako je s obzirom na uloženo, primjenjivost multispektralnih senzora najveća.

Šiljeg i dr. (2022) uspoređuju pikselni i GEOBIA pristup u kartiranju krošanja maslina pomoću multispektralnog modela vrlo visoke rezolucije. U fazi prikupljanja podataka koriste multi-rotor VTOL bespilotnu letjelicu *DJI Matrice 600 Pro*, multispektralni senzor *Micasense RedEdge-MX* s ukupno pet kanala i *RTK-GPS Stonex S10* za prikupljanje orijentacijskih i kontrolnih točaka. Podatke prikupljaju s prosječne visine od oko 260 m i obrađuju u softveru *Agisoft MetaShape Professional 1.5.1*. Zatim unutar dvaju pristupa, uspoređuju klasifikacijske algoritme *SVM* i *ML*, od kojih se prema mjerama točnosti (*TA - Total Accuracy, PA, UA, OA, AUC*), GEOBIA - *SVM* pokazao kao najtočniji s vrijednošću *AUC*-a 0,929.

Zhou i dr. (2017) koriste multi-rotor VTOL bespilotnu letjelicu *MK-Oktokopter* i multispektralni senzor *Mini-MCA6* sa šest spektralnih kanala, u procesu generiranja modela vrlo visokih prostorno-vremenskih rezolucija na lokalnoj razini. Orijetacijske točke označene su i prikupljene na terenu, te je uz pomoć njih model georeferenciran tijekom procesa obrade podataka u softveru *Agisoft PhotoScan*. U ovoj studiji, istraživani je prinos zrna riže pomoću, a zaključno je utvrđeno kako ulazni podaci i multispektralni modeli vrlo visoke rezolucije mogu biti vrlo pouzdani u predviđanju prinosa zrna riže.

(2) GEOBIA pristup u kartiranju krošanja maslina - znanstveni radovi prikazuju faze, utjecaj korisničko-definiranih parametara i primjenu GEOBIA pristupa u procesu izdvajanja krošanja maslina ili slične vegetacije.

Alganci i dr. (2018) provode istraživanje koje za cilj ima odrediti prostornu distribuciju stabala maslina na razini parcele korištenjem GEOBIA pristupa i satelitskih snimaka visoke rezolucije. U istraživanju je korišten *RT* klasifikacijski algoritam čiji su rezultati provjereni pomoću tri mjere točnosti (*UA, PA, KC*). Konfuzijska matrica izrađena je na temelju 100

nasumično raspoređenih točaka, te je dobivenim rezultatima pokazana opravdanost korištenja GEOBIA pristupa.

Gašparović i Dobrinić (2020) upotrebljavaju satelitske podatke *Sentinel-1* u svrhu usporedbe klasifikacijskih algoritama (*RT, SVM, XGB - Extreme Gradient Boosting, ELM - Extreme Machine Learning*) i kartiranja zelenih površina unutar urbanih gradskih područja. Na temelju četiri mjere za procjenu točnosti (*PA, UA, OA, KC*), *SVM* algoritam odabran je kao najtočniji, no rezultati se razlikuju ovisno o istraživanom području.

Modica i dr. (2020) u istraživanju koriste multi-rotor VTOL tip bespilotne letjelice i multispektralni senzor sa šest kanala. Podaci su prikupljeni s prosječne visine od oko 80 m, a obrada je izvršena u softveru *Pix4Dmapper Pro* s izlaznim rezultatom u obliku multispektralnog modela vrlo visoke rezolucije. Korišteni klasifikacijski algoritmi (*SVM, RT, KNN - K-Nearest Neighbor, NB - Naive Bayes*) ispitani su pomoću 500 nasumično raspoređenih točaka i tri mjere točnosti (*Producer Accuracy, User Accuracy, Overall Accuracy*) izvedene unutar konfuzijske matrice.

Panda i dr. (2021) uspoređuju izabrane GEOBIA klasifikacijske algoritme (*Random Trees, Maximum Likelihood, Support Vector Machine*) s ciljem izdvajanja šuma primorskih četinjača na visoko-rezolucijskom *WorldView-3* snimku. Metodološki okvir istraživanja uključivao je niz koraka neophodnih u procesu GEOBIA klasifikacije odnosno segmentacije, dodavanja testnih uzoraka i reklasifikacije. Pomoću četiri mjere za ocjenjivanje točnosti (*COR - Correctness, COM - Completeness, OQ - Overall Quality, KC*) zaključuju kako je *Random Trees* najpouzdaniji klasifikacijski algoritam s točnošću od 87,38%, prema mjeri Kappa koeficijenta.

Šiljeg i dr. (2020) provode istraživanje na području Lunjskih maslinika s ciljem procijene točnosti digitalnog modela površina izvedenog iz *WorldView-3* satelitskih snimki. Spomenuta procjena temeljila na izdvajanju krošanja maslina GEOBIA pristupom uz pomoć klasifikacijskih algoritama *RT, ML i SVM*, čiji su rezultati uspoređeni mjerama *COM, COR i OQ*. Na temelju rezultata navedenih mjera, odabiru model klasifikacijskog algoritma *RT* kao najtočniji. U zaključku navode kako bi izrada modela vrlo visoke prostorne rezolucije omogućila učinkovito upravljanje i zaštitu ovog vrijednog poljoprivrednog i kulturnog resursa.

(3) Vegetacijski indeksi - znanstveni radovi se generalno odnose na proučavanje vegetacijskih indeksa, s posebnim naglaskom na primjenu u izdvajanju krošanja pojedine vegetacije.

Avola i dr. (2019) pišu o prednostima bespilotnih letjelica koje između ostalog omogućuju prikupljanje podataka visoke i vrlo visoke rezolucije. Istraživanje provode na krošnjama maslina koristeći 14 vegetacijskih indeksa (*NDVI, GNDVI, NDRE, GRVI, DVI, EVI...*) dobivenih iz podataka multispektralnog senzora i obrade unutar softvera *Agisoft Photoscan Professional*. Glavni cilj istraživanja odnosi se na određivanje sortimenta maslina, a rezultatima koji su provjereni pomoću statističkog pokazatelja *ANOVA*, utvrđeno je kako vegetacijski indeksi *NDVI* i *DVI* najbolje prepoznaju razlike u sortimentu maslina.

Candiago i dr. (2015) u istraživanju koriste tri vegetacijska indeksa (*GNDVI, NDVI, SAVI*) u svrhu praćenja vegetacijskih faza usjeva vinograda i rajčica. Pomoću VTOL bespilotne letjelice, multispektralnog senzora *Tetracam ADC* i softvera *Agisoft PhotoScan* izrađen je multispektralni model vrlo visoke rezolucije na temelju kojeg su unutar *ArcGis*-a izvedeni odabrani vegetacijski indeksi. Rezultatima statističkih pokazatelja *Mean i SD (Standard Deviation)* potvrđena je opravdanost korištenja odabranih indeksa.

Domazetović i dr. (2020) pišu o upotrebi vegetacijskih indeksa unutar područja istraživanja na prostoru Lunjskih maslinika. Dva testna mjesta odabrana su pristupom temeljenim na objektima, utvrđenim na osnovu spektralnih karakteristika odnosno izdvajanjem *NDVI* i *VARI* vegetacijskih indeksa. Predlažu korištenje *WorldView-3* satelitskih snimaka isključivo u analizi nepristupačnih većih šumskih područja, dok za manja površinom područja istraživanja preporučuju korištenje neke od terenskih geoprostornih tehnologije poput *LiDAR*-a ili bespilotnih letjelica.

Jurišić i dr. (2021) navode prednosti metoda daljinskih istraživanja koje su postale superiorne u usporedbi s konvencionalnim metodama. Pristup na mikro razini istraživanja temelje na bespilotnim letjelicama i multispektralnim sensorima. Naglasak postavljaju na vegetacijske indekse koji omogućuju određivanje količine dušika u odabranim usjevima. Posebno ističu vegetacijske indekse *NDVI* i *NDRE* koji imaju visoku korelaciju s udjelom dušika i omogućuju klasifikaciju usjeva.

Marques i dr. (2019) u istraživanju koriste bespilotnu letjelicu fiksiranih krila *eBee* i modificirani multispektralni senzor. Podatke obrađuju unutar softvera *Pix4Dmapper Pro* s ciljem generiranja visoko-rezolucijskog multispektralnog modela. Pomoću kontrolnih točaka prikupljenih s GNSS uređajem i provjere točnosti pomoću mjere *RMSE*, ispituju točnost izravnog georeferenciranja bespilotne letjelice koja ukupno u prosjeku iznosi 14 cm na visini

leta od 200 m. Koriste GEOBIA pristup i vegetacijske indekse (*NDVI*, *GNDVI*, *SAVI*, *BNDVI*, *GSAVI*) u svrhu kartiranja krošanja kestena. Rezultatima dobivenim iz mjera točnosti *PA*, *UA*, *OA*, *COR*, *COM* i *OQ* odabiru *GNDVI* ($OQ = 0,92$) indeks kao najtočniji u procesu kartiranja krošanja kestena.

Messina i dr. (2020) u svrhu precizne poljoprivrede izdvajaju tri vegetacijska indeksa (*NDVI*, *GNDVI* i *SAVI*) u analizi usjeva luka. U procesu prikupljanja podataka koriste bespilotnu letjelicu i multispektralni senzor *Sequoia Parrot*, opremljenu s pet spektralnih kanala. Proces kalibracije izveden je uz pomoć ploče s poznatom spektralnom refleksijom, a zatim je unutar softvera *AgiSoft Metashape Professional* izrađen visoko-rezolucijski multispektralni model. Odabrane vegetacijske indekse uspoređuju s GEOBIA pristupom, a dobiveni rezultati ukazuju na visoku korelaciju vrijednosti rezultata točnosti dvaju pristupa, kao i prilikom usporedbe izvedenih vegetacijskih indeksa.

Prada i dr. (2020) istraživanje provode u svrhu razumijevanja i proučavanja reakcije šumskih vegetacijskih vrsta na klimatske promjene. Cilj rada bio je pronalazak optimalnog vegetacijskog indeksa na temelju dostupnih satelitskih snimaka *Landsat 8* i *Sentinel 2*. Indeksi *NDVI*, *SAVI*, *MTVI*, *MCARI1* i *MCARI2* uspoređeni su pomoću metode *AUC*-a te je kao najtočniji odabran vegetacijski indeks *MCARI2*.

Solano i dr. (2019) kao ulazne podatke koriste visoko-rezolucijske *WorldView-3* snimke koje obrađuju unutar softvera *Erdas Imagine*. Pomoću GEOBIA pristupa, izdvajaju krošnje maslina unutar kojih analiziraju vegetacijske indekse *NDVI*, *NDRE*, *MSAVI2* i *MCARI2*. Nakon usporedbe, navode kako *NDRE* indeks i drugi vegetacijski indeksi koji koriste rubni dio crvenog spektra u formuli za izračun, pokazuju bolje rezultate u odnosu na druge indekse u procesu kartiranja krošanja maslina i uočavanja varijabilnosti unutar krošnji. Detaljnom analizom svakog od osam korištenih spektralnih kanala, pomoću različitih statističkih testova (*Shapiro-Wilk*, *Kruskal-Wallis*) utvrđeno je kako najveću korelaciju s krošnjama maslina posjeduju infracrveni i kanali u rubnom crvenom dijelu elektromagnetskog spektra. U zaključku predlažu korištenje navedene metodologije u svrhu ranog otkrivanja suhih dijelova krošnje s ciljem sprječavanja širenja štetnih nametnika i očuvanja maslina.

2. Područje istraživanja

Područje istraživanja ovog diplomskog rada nalazi se na najsjevernijem dijelu otoka Paga u neposrednoj blizini naselja Lun. Za potrebe istraživanja odabrana je manja testna ploha unutar vrtova Lunjskih maslinika (Slika 1).

Vrtovi Lunjskih maslinika jedan su od najvrjednijih prirodnih fenomena otoka Paga, te je područje 1963. godine upisano u registar zaštićenih objekata prirode i proglašeno botaničkim rezervatom (Milotić, 2013). Samonikle tisućljetne masline unutar istraživanih područja, dio su ekološke mreže „Natura 2000“. Više od 80 tisuća stabala, prostire se na oko 24 hektara što predstavlja vrlo rijetko viđenu pojavu u svijetu, budući da se tisućljetne masline uglavnom pronalaze usamljene ili u manjim skupinama (Kale, 2016). Područjem Lunjskih maslinika dominira sorta masline „Oblica“ (Lodeta i dr, 2018), koja je ujedno i najrasprostranjenija u Hrvatskoj (Gugić i dr., 2007). Prednosti sorte su veličina ploda i količina dobivenog ulja, dok je glavna mana neredovita rodost (Bakarić, 2005).



Slika 1. Područje istraživanja (DGU, 2020 - DOF)

3. Teorijska osnova

3.1. Geoprostorne tehnologije

Geoprostorne tehnologije i njihovi proizvod postali su lako dostupni i široko pristupačni u svakodnevnom životu što je unaprijedilo i ubrzalo njihovu upotrebu u različitim istraživanjima (Bodzin i Cirucci, 2009; Jackson i dr., 2009; Bishop i dr., 2012; Marques i dr., 2019). Iako su mogućnosti primjene ograničene samo maštom osobe koja ih koristi, treba pripaziti na njihovo pravilno korištenje u procesu digitalnog modeliranja (Bishop i dr., 2012; Šiljeg i dr., 2018). Prostorno planiranje i upravljanje uključuje niz potrebnih znanja i vještina kojima geoprostorne tehnologije pružaju i omogućuju alternativan pristup u vizualizaciji, analizi, obradi i rješavanju istraživačkog pitanja (Bishop i dr., 2012).

Jedno od područja s intenzivnom upotrebom geoprostornih tehnologija je precizna poljoprivreda, koju poljoprivrednici razvijenih zemalja redovito primjenjuju, a upravo geoprostorne tehnologije u poljoprivredi imaju široku primjenu i za očekivati je njihovu daljnju implementaciju u ovaj bitan sektor (Avola i dr., 2019; Marić i dr., 2019; Solano i dr., 2019).

3.1.1. Bepilotne letjelice

Korištenje bepilotnih letjelica postalo je neophodno kod većine znanstvenika u smislu prikupljanja preciznih podataka potrebnih za provođenje raznovrsnih istraživanja (Watts i Ambrosia, 2012; Pádua i dr., 2017; Delavarpour i dr., 2021). Bepilotne letjelice se definiraju kao leteće naprave bez posade u samoj letjelici kojima se može upravljati na daljinu pomoću složenih autonomnih dinamičkih sustava ili upotrebom programiranog plana leta, unaprijed planiranog u odgovarajućem računalnom programu (Sullivan, 2006).

Glavne prednosti bepilotnih letjelica naspram satelitskih sustava su zacijelo ekonomičnost upotrebe i pružanje izlaznih rezultata vrlo visoke prostorne rezolucije. Prije provođenja analiza potrebno poznavati područje istraživanja i ciljeve rada u svrhu pravilnog odabira potrebne tehnologije (Emillien i dr., 2021; Sozzi i dr., 2021). Bepilotne letjelice dijele se u dvije osnovne kategorije. VTOL (*Vertical TakeOff and Landing*) tip s rotor motorima i tip bepilotne letjelice s fiksiranim krilima koji zahtjeva korištenje uzletne piste, ali omogućuje dulje vrijeme letenja (Tsouros i Sarigiannidis, 2019). VTOL sustav postao je neizostavan kod većine bepilotnih letjelica koje se koriste prilikom složenih vojnih i civilnih operacija. Naime, spomenuti sustav omogućuje vertikalno polijetanje i slijetanje namijenjeno istraživanjima ili

operacijama koje se provode u ograničenom području (McGilvray i Tayebi, 2006). Postoji više vrsta VTOL sustava, od kojih je hibridni VTOL postao vrlo popularan u posljednje vrijeme. Naime, hibridni VTOL koristi kombinaciju fiksiranih krila i rotor-motora koji zajednički osiguravaju veću autonomiju i duljinu leta (Ozdemir i dr., 2014).

Rapidni razvoj bespilotnih letjelica danas omogućuje akviziciju raznovrsnih senzora i dulje vrijeme letenja, što je vrlo bitno jer se kontrolna stanica može pozicionirati na određenoj udaljenosti od istraživanog područja. Danas se bespilotne letjelice najviše primjenjuju u područjima precizne poljoprivrede i opće sigurnosti (Jenkins i Vasigh, 2013; Emillien i dr. 2021).

3.1.2. Izravno georeferenciranje

Izravno georeferenciranje najnoviji je pristup u aerofotogrametriji. Temelji se na inercijalnom navigacijskom sustavu bespilotne letjelice koji se sastoji od senzora inercijalne mjerne jedinice i GNSS prijemnika. Provodi se mjerenje šest vanjskih parametara vanjske orijentacije, s pomoću kojih se određuje položaj X, Y i Z koordinata, a istodobno inercijalna mjerna jedinica, određuje tri parametra orijentacije odnosno nagibe korištenog senzora (Mian i dr., 2015). Metoda izravnog georeferenciranja omogućuje provođenje istraživanja bez potrebe za označavanjem i prikupljanjem točaka lokalne geodetske osnove odnosno orijentacijskih i kontrolnih točaka (Oniga i dr., 2018).

3.1.3. Multispektralni senzori

U procesu daljinskih istraživanja, multispektralni senzori jedan su od najmoćnijih alata u smislu boljeg razumijevanja okolišnih procesa (Stow i dr., 1996). Jedni su od najkorištenijih senzora, na što je prvenstveno utjecala njihova izuzetna primjenjivost u šumarstvu, preciznoj poljoprivredi i drugim gospodarskim djelatnostima koje su u bliskoj vezi s vegetacijom. Do prije nekoliko godina, multispektralne kamere smatrale su se preteškima za komercijalne bespilotne letjelice, te su se često umjesto multispektralnih, koristile modificirane RGB kamere s nadogradnjom za dobivanje infracrvenog spektra elektromagnetskog zračenja. ultispektralne kamere postale su široko dostupne tek posljednjih nekoliko godina, od kada omogućuju značajno bolje rezultate, poglavito kada je riječ o vegetacijskim analizama (Páuda i dr., 2017; Iqbal i dr., 2018).

Multispektralni senzori pružaju uvid u ljudskom oku nevidljivi pojas elektromagnetskog zračenja čime omogućuju istraživanja koja su do tada bila nezamisliva. Naime, stvari iz okoliša u nekoj određenoj mjeri, pri različitim valnim duljinama emitiraju ili reflektiraju specifičan spektralni popis, po čijim se karakteristikama pojedini objekti unutar promatranog područja mogu prepoznati i izdvojiti (Stow i dr., 1996). Povećanjem integriranih kanala multispektralne kamere, raste spektralna rezolucija senzora, te je promatrano područje moguće kvalitetnije analizirati. Također, vrlo bitna je i radiometrijska rezolucija koja određuje raspon vrijednosti unutar kojeg će intenzitet reflektiranog zračenja biti zabilježen (Vrabel, 1996; Stengel i dr., 2020).

3.1.4. RGB senzori

Snimke dobivene iz RGB (*Red, Green, Blue*) senzora služe za jednostavne geoprostorne analize i ovisno o visini leta, pružaju pouzdane rezultate vrlo visoke prostorne rezolucije (Bendig i dr., 2014; Onishi i Ise, 2021). U daljinskim istraživanjima ponekad se upotrebljavaju za izradu referentnih modela s kojima će se ispitivati točnosti provedenih metoda i tehnika, a upravo za taj segment je izrazito bitna vrlo visoka prostorna rezolucija (Görlich i dr., 2021). RGB senzori se nalaze među brojnim sensorima koje bespilotne letjelice mogu nositi, a glavne prednosti upotrebe istih su brzina generiranja podataka, isplativost i jednostavna interpretacija izlaznih rezultata (Diez i dr., 2021; Parra i dr., 2021).

Primjena RGB senzora je široko obuhvatna, no u pogledu daljinskih istraživanja najčešće se koriste u svrhu fotogrametrije (Jorge i dr., 2019). RGB senzori svrstavaju se u pasivne senzore budući da ne emitiraju vlastito zračenje već detektiraju reflektirano prirodno zračenje od objekta čiji je najčešći izvor sunčeva radijacija (Zollhöfer, 2019).

3.2. Geografski objektno-orijentirane analize (GEOBIA)

Geografski objektno orijentirane analize (GEOBIA), mogu se definirati kao jedna od metoda kartiranja zemljišnog pokrova, a odnose se na proučavanje geografskih entiteta ili fenomena pomoću objekata, a ne pojedinačnih piksela (Hay i Castilla, 2008; Blaschke i dr., 2014; Chen i dr., 2018). Pristup temeljen na pikselima bio je dominantan sve do 2000-tih godina, međutim tada dolazi do pojave prvih komercijalnih softvera za analizu slikovnih objekata, te počinje napredak analiza koje se na njima temelje (Blaschke i dr., 2014). GEOBIA se definira kao poddisciplina GIS-a usmjerena na obradu i analizu rasterskih podataka, koja za

cilj ima generiranje geografskih informacija iz kojih se mogu donijeti novi prostorni zaključci (Hay i Castilla, 2008).

Prvi i osnovni korak u procesu analiza koje se temelje na objektima je segmentacija snimka. Segmentacija je postupak podjele promatranog snimka na manje međusobno odvojene dijelove ili skupine piksela koji se međusobno ne preklapaju. Zasebni dijelovi kreiraju se na temelju sličnih spektralnih, geometrijskih i prostornih značajki tvoreći novonastale segmente (Blaschke i dr., 2014). Odabir optimalnih korisničko-definiranih parametara kod provođenja segmentacije snimka, ključno je za cjelokupan proces geografski objektno orijentiranih analiza jer će generirani segmentirani snimak služiti u daljnjim koracima analize i tako potencijalno utjecati na izlazne rezultate (Chen i dr., 2018). Budući da je savršena segmentacija gotovo nemoguća, na korisniku je da odabere optimalne parametre ovisno o ciljevima i svrsi istraživanja, jer će upravo o tim parametrima ovisiti rezultati metoda klasifikacije (Kucharczyk i dr., 2020).

Klasifikacija snimka sastoji se od više povezanih koraka koji na koncu tvore klasificirani snimak. Dodavanje testnih uzoraka, prvi je od njih, a mnogi autori predlažu minimalno 50 uzoraka po klasi (Francisco i Almeida, 2012; Ma i dr., 2017; Kucharczyk i dr., 2020). Pri dodavanju samih uzoraka, potrebno je pripaziti na ravnotežu među klasama, odnosno svaka klasa bi trebala imati podjednaki broj uzoraka jer u protivnom može doći do pogrešne klasifikacije. Nadalje, testni uzorci za svaku pojedinu klasu trebaju pozicijski gledano biti što više raspršeni unutar promatranog područja, umanjujući na taj način potencijalne spektralne razlike unutar iste klase. Jednom kada su svi testni uzorci spremni, moguće je nastaviti GEOBIA proces odabirom optimalnog klasifikacijskog algoritma. Unutar klasifikacijske strukture neovisno o odabranom algoritmu, prostorni entitet može klasificirati isključivo u jednu klasu (Kucharczyk i dr., 2020). Kod nadzirane klasifikacije, među korištenijim klasifikacijskim algoritmima su *Support Vector Machine*, *Random Forest* i *Maximum Likelihood Classification* (Ma i dr., 2017).

3.3. Vegetacijski indeksi

U području primjene daljinskih istraživanja, znanstvenici su razvili vegetacijske indekse u svrhu kvalitativne i kvantitativne analize vegetacijskih pokrova pomoću spektralnih karakteristika. Uspješna uporaba ovih indeksa zahtjeva poznavanje jedinica ulaznih vrijednosti koje se koriste za formiranje istih, dok s druge strane treba razumjeti načine utjecaja vanjskog

antropogenog okoliša i prostorno-vremenske varijacije atmosfere na konačne vrijednosti indeksa (Jackson i Heute, 1991; Bannari i dr., 1995; Haboudane i dr., 2004; Heute, 2012). Niti jedan vegetacijski indeks u praksi nije idealan za promatranje određene pojave, no prilikom odabira najboljeg, potrebno je obratiti pozornost na osjetljivost izdvajanja vegetacijskog pokrova. S druge strane, vegetacijski indeksi moraju biti što manje osjetljivi na svjetlinu tla, utjecaje atmosfere i okoliš, koji mogu rezultirati neispravnim modelima. Vegetacijski indeksi uspješno se primjenjuju kod klasifikacije vegetacije na velikim površinama, praćenja gustoće vegetacijskog pokrova, nadzora i navodnjavanja poljoprivrednih usjeva, praćenja evaporacije i transpiracije biljaka, a tijekom godina razvilo se mnoštvo brojnih indeksa koji ovisno o tipu istraživanja imaju različitu namjenu (Xue i Su, 2017).


Od lansiranja prvog satelita 1972. godine, jedan od fokusa znanstvenika bio je uspostava bliske veze između spektralnih karakteristika i vegetacijskog pokrova. Izvedene su brojne formule za razumijevanje vrijednosti generiranih od strane multispektralnih senzora u svrhu kreiranja jedne korisniku razumljive vrijednosti, odnosno vegetacijskog indeksa, pogodnog za predviđanje i procjenu karakteristika promatrane vegetacije (Heute, 2012; Xue i Su, 2017).

3.3.1. Vrste vegetacijskih indeksa

Većina znanstvenika se slaže u činjenici da korištenje vegetacijskih indeksa pokazuje značajno bolje rezultate u detekciji vegetacijskih površina naspram vrijednosti individualnih spektralnih kanala dobivenih iz multispektralnih senzora, a odabir potrebnog vegetacijskog indeksa ponajviše ovisi o promatranom objektu, ciljevima i svrsi istraživanja (Xue i Su, 2017). U području daljinskih istraživanja razvijeno je nekoliko desetaka vegetacijskih indeksa koji svaki na svoj način nastoje umanjiti utjecaj atmosferskih i antropogenih faktora na izlazne rezultate (Bannari i dr., 1995; Haboudane i dr., 2004; Heute, 2012). Prva faza, u povijesti razvoja vegetacijskih indeksa, temelji se isključivo na linearnim kombinacijama spektralnih kanala, bez uzimanja u obzir utjecaj vanjskih čimbenika. Druga faza, vezana je uz poznavanje fizikalnih karakteristika koje objašnjavaju interakcije između elektromagnetskog zračenja i utjecaja spomenutih vanjskih čimbenika kako bi se umanjio utjecaj istih (Bannari i dr., 1995; Xue i Su, 2017).

Većina vegetacijskih indeksa kombinira informacije o crvenom i infracrvenom spektralnom kanalu (Baret i Guyot, 1990; Heute, 2012; Xue i Su, 2017). Razlog tomu krije se u sposobnosti vegetacije da veći dio vidljivog elektromagnetskog spektra apsorbira, dok se

ljudskom oku nevidljive infracrvene valne duljine u značajnoj mjeri reflektiraju od površine biljaka (Slika 2.) (Jackson i Heute, 1991). Upravo to reflektirano infracrveno zračenje, ima ključnu ulogu u provođenju analiza povezanih s vegetacijom, a svaki vegetacijski indeks ima svoju prikladnost za specifične namjene i ograničavajuće čimbenike. Refleksija svjetlosnih spektara ovisi o karakteristikama biljke, a određena je kemijskim ili morfološkim karakteristikama površine organa ili lišća promatrane biljke (Xue i Su, 2017).



Slika 2. Način reflektiranja elektromagnetskog zračenja kod biljaka različitog zdravstvenog stanja (prema: URL 2)

Tijekom godina razvio se velik broj vegetacijskih indeksa s različitim namjenom i primjenom, a odabrani vegetacijski indeksi (*NDVI*, *NDRE*, *GNDVI*, *MCARI2* i *RDVI2*) najčešće su korišteni unutar sličnim istraživanja u kojima su kartirane krošnje maslina ili druga vegetacija sličnih spektralnih karakteristika (Avola i dr., 2019; Marques i dr., 2019, Solano i dr., 2019)

3.3.1.1. NDVI vegetacijski indeks

NDVI (*Normalized Difference Vegetation Index*) jedan je od najčešće korištenih vegetacijskih indeksa (Gitelson i dr., 1996; Pettorelli i dr., 2005; Patón, 2020; Huang i dr., 2021). NDVI kvantificira vegetaciju mjerenjem razlike između vidljivog dijela crvenog spektra

koje vegetacija u većoj mjeri apsorbira i infracrvenog dijela elektromagnetskog spektra kojeg vegetacija snažno reflektira. Navedeno se može iščitati iz formule koja glasi:

$$NDVI = \frac{NIR - R}{NIR + R}$$

gdje simbol R (*Red*) predstavlja prosječnu refleksiju od promatrane površine u crvenom spektru, dok se simbol NIR (*Near-InfraRed*) odnosi na infracrveni dio. Rezultati izdavanja ovog indeksa prikazuju se na skali od -1 do 1 pri čemu negativne vrijednosti ukazuju na nepostojanje vegetacijskog pokrivača kao što su obrađene površine ili vodene površine, dok se pozitivne vrijednosti odnose na postojanje vegetacijskog pokrivača (Rouse i dr., 1974).

Zbog svoje sposobnosti brzog prepoznavanja vegetacije, NDVI indeks počeo se značajno koristiti u znanstvenim krugovima već krajem 1970-ih godina, a podatci iz satelita koji su tih godina kružili u orbiti Zemlje, većinom su bili namijenjeni za izračun globalnih NDVI indeksa. Osnovna svrha korištenja NDVI vegetacijskog indeksa je poboljšanje analiza vezanih uz vegetaciju na temelju podataka dobivenih daljinskim istraživanjima (Tucker i dr., 2001). Različite studije pokazuju kako je NDVI indeks vrlo učinkovit za razlikovanje gustih šuma (Matushita i dr., 2007), prepoznavanje poljoprivrednih polja, određivanje zim zelenih šuma u odnosu na listopadne vrste šuma i druge aktivnosti vezane uz šumarstvo, granu djelatnosti na koju otpada čak trećina istraživanja vezanih uz korištenje NDVI indeksa (Huang i dr., 2021). S druge strane, u preciznoj poljoprivredi NDVI je značajan za procjenu različitih svojstava usjeva, pa se između ostalog koristi i za procjenu biomase, analizu koncentracije klorofila, otkrivanje produktivnosti i procjenu zdravstvenog stanja poljoprivrednih usjeva (Pettorelli i dr., 2005; Huang i dr., 2021). Unatoč brojnim prednostima, NDVI nije uvijek najtočniji indeks za otkrivanje anomalija u vegetaciji, osobito ako postoje detaljni podaci u rubnom dijelu crvenog spektra koji je vrlo osjetljiv na promjene u svojstvima promatrane vegetacije (Jorge i dr., 2019).

3.3.1.2. NDRE vegetacijski indeks

NDRE (*Normalized Difference Red Edge vegetation index*) vegetacijski indeks često je korišten kod daljinskih istraživanja, poglavito u granama precizne poljoprivrede, šumarstva i nadziranja zdravlja vegetacije (Eitel i dr., 2011; Jorge i dr., 2019). Formula za generiranje NDRE indeksa je sljedeća:

$$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}$$

gdje se NIR odnosi na infracrveni, a *RedEdge* za rubni dio crvenog dijela spektra (Barnes i dr., 2000). Upravo je korištenje rubnog dijela crvenog spektra glavna prednost NDRE vegetacijskog indeksa. Naime, navedeni dio spektra se nalazi u zoni koja je izrazito pogodna za detaljnu analizu apsorpcije klorofila, što omogućava prepoznavanje heterogenosti vegetacije unutar promatranog područja (Jorge i dr., 2019). NDRE se često upotrebljava u procjeni zdravstvenog stanja biljaka čiji je važan pokazatelj upravo količina sadržanog klorofila. Vrijednosti NDRE indeksa se, također kao i kod NDVI indeksa, prikazuju na ljestvici od -1 do 1, gdje više vrijednosti predstavljaju zdravu vegetaciju s najviše udjela klorofila, dok se one niže odnose na područja bez vegetacije. Najbolje vrijeme primjene NDRE vegetacijskog indeksa je u vrijeme zrelosti biljaka jer u tom razdoblju NDRE pokazuje najstabilnije rezultate u odnosu na druge vegetacijske indekse. Mnogi znanstvenici (Barnes i dr., 2000; Marx i Kleinschmit, 2017; Boiarskii i Hasegawa, 2019; Jorge i dr., 2019; Morlin-Carneiro i dr., 2020) smatraju kako NDRE pokazuje bolje rezultate u odnosu na mnoge druge vegetacijske indekse i preporučuju učestaliju upotrebu navedenog indeksa.

3.3.1.3. GNDVI vegetacijski indeks

Vegetacijski indeks GNDVI (*Green Normalized Difference Vegetation Index*) često je korišten od strane znanstvenika koji proučavaju različite tipove vegetacije (Shanahan i dr., 2001; Bell i dr., 2004; Wang i dr., 2007; Candiago i dr., 2015; Safonova i dr., 2021). Formula za izračun koristi infracrveni (NIR) i zeleni (G) dio spektra:

$$GNDVI = \frac{NIR - G}{NIR + G}$$

Dobivene vrijednosti su značajno osjetljivije na razlike u karakteristikama vegetacije u odnosu na NDVI indeks (Gitelson i dr., 1996). Uporabom zelenog dijela spektra smanjuje se efekt zasićenja vegetacije, zbog čega je GNDVI koristan u razlikovanju nezdrave i starije vegetacije. Također, koristi se za određivanje unosa količine vode i dušika u krošnju biljke, što doprinosi ranoj prevenciji štetnih nametnika (Shanahan i dr., 2001). Vrijednosti GNDVI indeksa, variraju na ljestvici od -1 do 1, gdje više vrijednosti predstavljaju vegetaciju, dok se one niže odnose na područja bez vegetacije (Gitelson i dr., 1996). Prednost GNDVI indeksa je i sposobnost razlikovanja različitih sorti vegetacije unutar promatranog područja, što je vrlo

bitno kod poljoprivrednih površina s različitim sortama iste vegetacijske vrste (Candiago i dr., 2015).

3.3.1.4. MCARI2 vegetacijski indeks

MCARI2 (*Modified Chlorophyll Absorption Ratio Improved vegetation indeks 2*) druga je po redoslijedu modifikacija originalnog CARI (*Chlorophyll Absorption Ratio Index*) (Kim i dr., 1994) vegetacijskog indeksa. Prvenstveno je modificiran i pretvoren u MCARI (Daughtry i dr., 2000) koji je razvijen u svrhu boljeg prepoznavanja klorofila, ali za izračun nije korišten bliski infracrveni dio spektra. Naposljetku je uslijedila završna modifikacija i indeks je pretvoren u MCARI2, za kojeg glasi sljedeća formula:

$$MCARI2 = 1.5 \frac{2.5 (NIR - R) - 1.3 (NIR - G)}{\sqrt{(2 NIR + 1)^2 - (6 NIR - 5\sqrt{R})} - 0.5}$$

koja uključuje korištenje bliskog infracrvenog (NIR), crvenog (R) i zelenog (G) dijela elektromagnetskog spektra i kombinaciju različitih koeficijenata koji za cilj imaju umanjivanje atmosferskog utjecaja (Haboudane i dr., 2004). MCARI2 znatno je osjetljiviji na prepoznavanje vegetacijskih površina i identificiranje relativne količine klorofila unutar promatrane krošnje, a vrijednosti variraju na ljestvici od -1 do 1 (Solano i dr., 2019). Niske vrijednosti odgovaraju površinama bez vegetacije, dok se više vrijednosti odnose na područja s vegetacijom. Mnogi znanstvenici (Eitel i dr., 2011; Bagheri i dr., 2013; Tahir i dr., 2018; Solano i dr., 2019) preporučuju upotrebu MCARI2 indeksa, poglavito u istraživanjima koja koriste bespilotne letjelice i multispektralne modele vrlo visoke rezolucije, koji omogućuju klasificiranje prostornih razlika u sadržaju klorofila, odnosno vrsta vegetacija na promatranom području.

3.3.1.5. RDVI2 vegetacijski indeks

Vegetacijski indeks RDVI2 (*Renormalized Difference Vegetation Index 2*) modifikacija je postojećeg RDVI vegetacijskog indeksa. Originalni RDVI indeks u svojoj formuli koristi bliski infracrveni i crveni dio spektra (Roujean i Breon, 1995), dok se kod RDVI2 indeksa umjesto crvenog, koristi rubni dio crvenog dijela elektromagnetskog spektra (*RedEdge*):

$$RDVI2 = \frac{NIR - RedEdge}{\sqrt{NIR + RedEdge}}$$

Rubni dio crvenog spektra omogućuje razlikovanje vrsta vegetacije unutar promatranog područja te zajedno s kombinacijom bliskog infracrvenog dijela, omogućuje izdvajanje određene vrste unutar heterogenog vegetacijskog područja. RDVI2 kao i RDVI minimalizira utjecaj reflektiranja okolnih površina na izdvajanje vegetacije, a to ponajprije ovisi o karakteristikama korištenog multispektralnog senzora (Haboudane i dr., 2004) i načinu upotrebe bespilotnih letjelica prilikom prikupljanja podataka (Naqvi i dr., 2021).

3.4. Primjena geoprostornih tehnologija u analizi vegetacijskih indeksa

Sve veća dostupnost satelitskih snimaka u posljednjih nekoliko desetljeća rezultirala je i većom dostupnošću podataka potrebnih za provođenje analiza uz pomoć vegetacijskih indeksa, pa tako i brojem znanstvenika koji spomenute indekse koriste u svojim istraživanjima. No, satelitski snimci su često kontaminirani zbog poremećaja atmosferskih uvjeta, naoblake i kapaciteta senzora, odnosno provođenje analiza na koncu bi moglo dovesti do pogrešnih zaključaka. Napretkom geoprostornih tehnologija, posebice pojavom bespilotnih letjelica, podaci potrebni za analize i istraživanja postali su sve dostupniji, a na popularnosti dobiva i upotreba vegetacijskih indeksa. Naročito se navedeno odnosi na precizna istraživanja, odnosno istraživanja koja za potrebu imaju korištenje podataka visoke prostorne rezolucija, koja bi bez korištenja bespilotnih letjelica bila teško ostvariva (Pauda i dr., 2017).

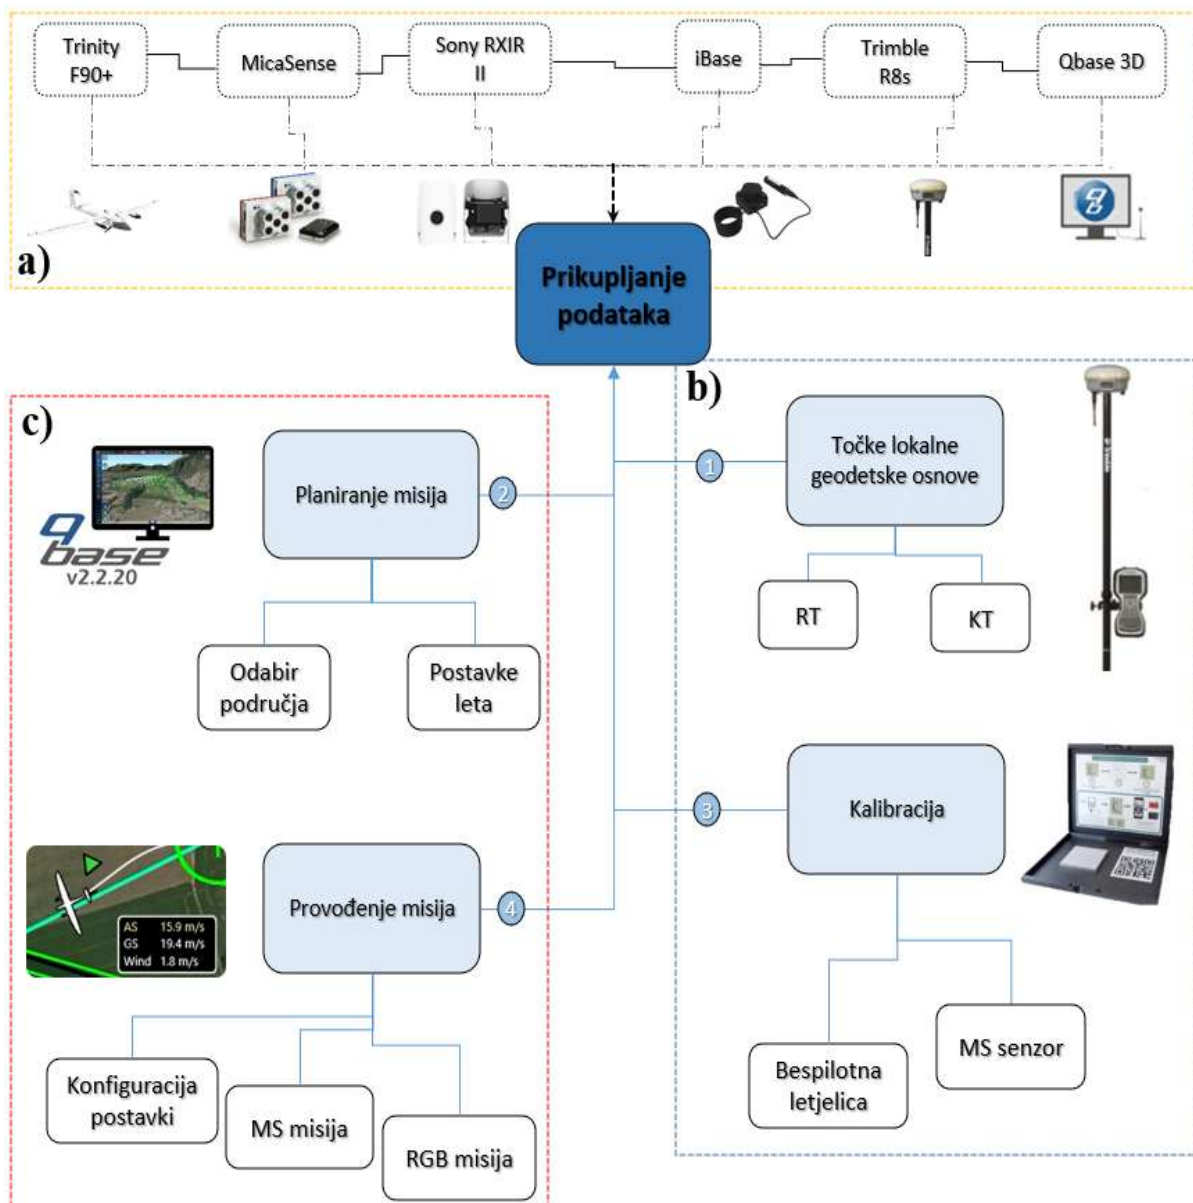
Geoprostorne tehnologije su neophodne u provođenju analiza temeljenih na vegetacijskim indeksima (Heute, 2012; Xue i Su, 2017). Sateliti i/ili bespilotne letjelice pružaju platforme za postavljanje odgovarajućih, u ovom slučaju RGB ili multispektralnih senzora, potrebnih za fazu prikupljanja podataka. U sljedećoj fazi obrade preuzetih ili na terenu prikupljenih podataka, poznavanje mogućnosti koje nude određeni softveri za geoprostorne analize ključno je prilikom generiranja izlaznih rezultata, uz pravilan odabir korisničko-definiranih parametara o kojima će ovisiti točnost spomenutih izlaznih rezultata (Bodzin i Cirucci, 2009; Jackson i dr., 2009).

4. Metodologija istraživanja

4.1. Prikupljanje podataka

Prikupljanje podataka u vrtovima Lunjskih maslinika izvršeno je 19. listopada 2021. Snimanje je provedeno u listopadu jer u tom razdoblju masline ulaze u fazu zrelosti prilikom koje sve grane unutar krošnje imaju sličnu refleksiju (Connor i Fereres, 2010). Drugi razlog za snimanje u ranoj jeseni vezan je uz rezidbu krošnja koja se u maslinarstvu najčešće odvija zimi. U procesu prikupljanja podataka korištene su različite geoprostorne tehnologije i procesi (Slika 3a) koji na određen način doprinose konačnoj svrsi i ciljevima istraživanja. Aerofotogrametrijsko snimanje promatranog područja izvedeno je koristeći bespilotnu letjelicu *Trinity F90+*, multispektralni senzor *MicaSense RedEdge-MX Dual Camera Imaging System* i RGB senzor *Sony RX1R II – High resolution*. Prikupljanje referentne točke na kojoj se nalazila bazna stanica *iBase* i kontrolnih točaka izvršeno je uz pomoć GNSS prijemnika *Trimble R8s*, dok su sve misije letenja planirane u softveru *Qbase 3D*, koji je tijekom izvođenja misija služio kao kontrolna stanica.

Prikupljanje podataka podijeljeno je u dvije faze. Prva faza odnosi se na postupke koji provedbu zahtijevaju prije snimanja područja, odnosno označavanje i prikupljanje točaka lokalne geodetske osnove i proces kalibracije (Slika 3b), dok se druga faza odnosi na planiranje i provođenje misija aerofotogrametrijskog snimanja (Slika 3c).



Slika 3. Shema prikupljanja podataka: a) korištene geoprostorne tehnologije, b) prva faza, c) druga faza

4.1.1. Korištene geoprostorne tehnologije

4.1.1.1. Bepilotna letjelica *Trinity F90+*

Aerofotogrametrijsko snimanje odabranog područja unutar Lunjskih maslinika izvršeno je uz pomoć bespilotne letjelice *Trinity F90+* (Slika 4) njemačke tvrtke *Quantum-Systems GmbH* sa sjedištem u Gilchingu (URL3).



Slika 4. Bepilotna letjelica *Trinity F90+*

Bespilotna letjelica teži 5 kg, kombinira letenje s rotor-motorima i fiksiranim krilima (*Hybrid VTOL*) raspona 2,4 m (Tablica 1), a upravo je to jedan od najvažnijih razloga koji ističu ovu bespilotnu letjelicu od drugih dostupnih letjelica. Naime, *Trinity F90+* koristi tri rotor-motora koji omogućuju vertikalno polijetanje i slijetanje (*VTOL*) prikladno za područja s visokom vegetacijom. Time se isključuje potreba za korištenjem uzletne piste, što uvelike olakšava uporabu letjelice, poglavito u morfološki raščlanjenim područjima i područjima s visokom vegetacijom. Nakon dostizanja odabrane visine vertikalnim kretanjem uz pomoć potiska triju motora, letjelica dolazi u kratku fazu transformacije, prilikom koje se motori naginju prema naprijed i omogućuju horizontalno krstarenje zrakom. Dostizanjem zadane visine na kojoj će se prikupljati podaci, prednji motori se privremeno isključuju, dok se rad stražnjeg motora smanjuje na 30% koliko je i potrebno za sigurno krstarenje. Na taj način, značajno se smanjuje potrošnja baterije i omogućava duže vrijeme trajanja misije od čak 90

minuta, što je najveća prednost bespilotne letjelice. Za izvođenje misije u trajanju od 90 minuta atmosferski uvjeti trebaju biti odgovarajući te tada letjelica može prijeći i do 100 kilometara prilikom jednog polijetanja (URL4).

Tablica 1. *Specifikacije bespilotne letjelice Trinity F90+*

Naziv bespilotne letjelice	Trinity F90+
Maksimalna masa pri polijetanju	5 kg
Raspon krila	2,394 m
Dužina trupa	1,48 m
Maksimalno vrijeme leta	90 min
Maksimalna duljina (površina) leta	100 km (700 ha)
Maksimalna visina leta	4500 m
Optimalna brzina leta	17 m/s
Otpornost na vjetar (polijetanje)	9 m/s (do 1500m) 7 m/s (1500 - 3000m) 5 m/s (3000 - 4500m)
Otpornost na vjetar (krstarenje)	12 m/s
Težina baterije	1,5 kg
Radna temperatura	-12°C do 50°C

Izvor: URL3

4.1.1.2. Bazna stanica *iBase*

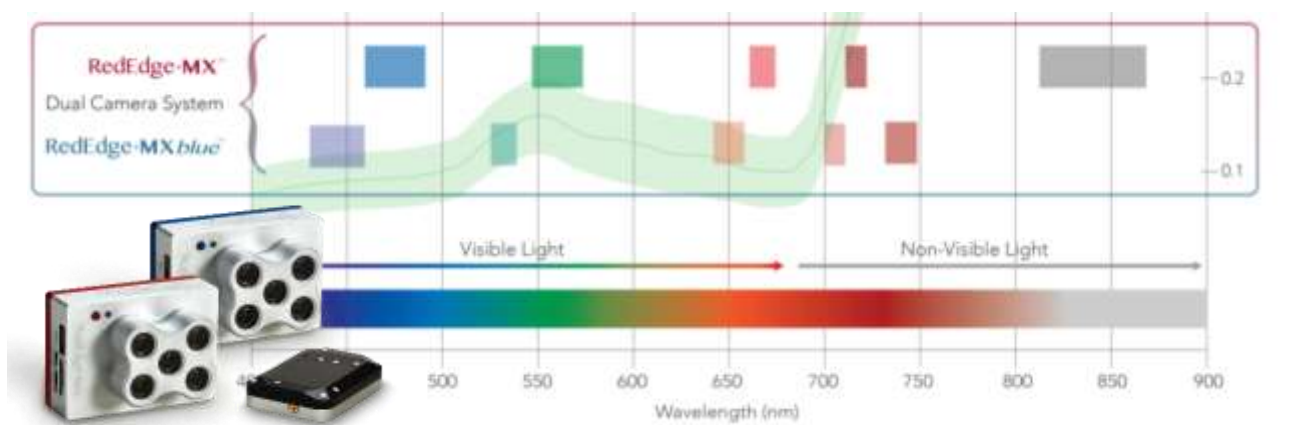
Bazna stanica *iBase* (Slika 5) dio je kompleta bespilotne letjelice *Trinity F90+* i predstavlja novu generaciju određivanja položaja bespilotne letjelice tijekom snimanja. U realnom vremenu zapisuje GNSS (engl. *Global navigation satellite system*) referentne položajne podatke i sprema na SD memorijsku karticu. Zapis omogućuje PPK (*Post-Processing Kinematic*) proces prikupljenih podataka i pruža relativnu položajnu preciznost od 2 do 5 centimetara (URL4). PPK koristi podatke iz statične bazne stanice (*iBase*) i pomičnog prijemnika na bespilotnoj letjelici (*Rover*) koji se zajedno korigiraju nakon obavljene misije kako bi se anulirala većina GNSS pogrešaka i dobila očekivana centimetarska točnost generiranih modela. PPK metoda široko je primijenjena kod bespilotnih letjelica, ponajviše u istraživanjima koja zahtijevaju visoku pozicijsku točnosti prikupljenih podataka (Pardo i dr., 2019; Taddia i dr., 2020).



Slika 5. GNSS bazna stanica *iBase* s pripadajućom *Rugged IP67* GNSS antenom i prijenosnom baterijom (URL3)

4.1.1.3. Multispektralni senzor *MicaSense RedEdge-MX Dual Camera*

Multispektralni senzor korišten za potrebe prikupljanja podataka, proizvod je američke tvrtke *AnEagle Aerial Systems Inc. (MicaSense Inc.)* sa sjedištem u Seattleu, SAD. *MicaSense RedEdge-MX Dual Camera* sastoji se od dvije međusobno povezane kamere *RedEdge-MX* i *RedEdge-MX Blue* koje zajedno predstavljaju sinkroniziranu funkcionalnu cjelinu. Svaka od navedenih kamera područje snima s pet senzora tvoreći zapis od ukupno deset spektralnih kanala (Tablica 2) koji se u realnom vremenu sprema na SD memorijsku karticu (Slika 6). U odnosu na prethodne verzije, ovaj kompaktni uređaj ima dvostruko više spektralnih kanala, što uvećava mogućnost analitičkih operacija, posebno u izdvajanju i analizi vegetacijskih indeksa. Tri spektralna kanala koja se nalaze u infracrvenom dijelu elektromagnetskog spektra, omogućuju detaljniji uvid i analizu pojedinih karakteristika unutar promatrane vegetacije (URL5).



Slika 6. *MicaSense RedEdge-MX Dual Camera* i valne duljine spektralnih kanala (URL6)

Tablica 2. *Specifikacije multispektralnog senzora MicaSense RedEdge-MX Dual Camera*

Naziv senzora	MicaSense RedEdge-MX Dual
Tip senzora	Multispektralni
Težina	0,508 kg
Broj spektralnih kanala	10
Vrste spektralnih kanala (valne duljine)	1.) Svijetlo plavi (444 nm), 2.) Plavi (475 nm), 3.) Zeleni (531 nm), 4.) Zeleni 2 (560 nm), 5.) Crveni (650 nm), 6.) Crveni 2 (668 nm), 7.) Rubni crveni (705 nm), 8.) Rubni crveni 2 (717 nm), 9.) Rubni crveni 3 (740 nm), 10.) Infracrveni (842 nm)
Prostorna rezolucija (visina snimanja)	8 cm/piksel (120 m)
Polje pogleda	47,2°
Radna temperatura	0°C do 40°C

Izvor: URL5

4.1.1.4. RGB senzor *Sony RX1R II*

Zahvaljujući 35 mm (*Full Frame*) senzoru s vrlo visokom razlučivosti (42,2 Mpx), *Sony RX1R II* (Slika 7) pruža odličan izvor podataka potrebnih za preciznu fotogrametriju. Opremljen novim inovativnim tehnologijama, senzor nudi mogućnost prikupljanja fotografija s GSD-om (engl. *Ground Sampling Distance*) od 1,29 cm, prilikom snimanja s visine od 100 metara (URL7). Fotografije vrlo visoke rezolucije, izvrstan su izvor podataka za izradu visoko rezolucijskog DOF-a koji će u nastavku istraživanja poslužiti kao referentni model u procesu izdvajanja krošanja maslina.



Slika 7. *Sony RX1R II* fotoaparata u kućištu spremnom za postavljanje na bespilotnu letjelicu (URL8)

4.1.1.5. RTK-GNSS *Trimble R8s*

RTK (*Real-Time Kinematic*) - GNSS prijemnik *Trimble R8s* s integriranom naprednom tehnologijom novije generacije pruža maksimalnu točnost i produktivnost korištenjem integriranih 440 kanala (Tablica 3). Inovacijama poput *Trimble 360* tehnologije, prijamnik proširuje domet i omogućava prikupljanje podataka na mjestima koja su prije bila nedostupna (URL9). U istraživanju je korišten za potrebe prikupljanja kontrolnih točaka i referentne točke (Slika 8).

Tablica 3. *Specifikacije Trimble R8s*

Naziv uređaja	Trimble R8s prijamnik
Kanali	440
Praćeni sateliti	GPS, GLONASS, Galileo, BeiDou, QZSS
Stopa pozicije	1,2,5,10 i 20 Hz
Visoko precizna statička izmjera (<i>Long time observation</i>)	Horizontalno 3 mm + 0,1 ppm RMS Vertikalno 3,5 mm + 0,4 ppm RMS
Real time kinematic (< 30 km)	Fiksirano RTK horizontalno 8 mm + 1 ppm RMS Fiksirano RTK vertikalno 15 mm + 1 ppm RMS
Težina	1,52 kg



Izvor: URL9

Slika 8. *Trimble R8s* (URL9)

4.1.1.6. Softver za planiranje i upravljanje misijama *QBase 3D*

Softver *QBase 3D* (Slika 9) predstavlja najpouzdaniju platformu za planiranje misija, kontrolu i upravljanje bespilotnim letjelicama tvrtke *Quantum-Systems* (URL 10). Proces planiranja misija znatno je unaprijeđen da korisniku bude što jednostavniji i razumljiviji. Naime, korisnik označava područje istraživanja i softver automatski generira predloženi način snimanja koji je ovisno o svrsi istraživanja podložan promjenama. Nadalje, informacije o nadmorskoj visini, brzini, statusu misije i stanju baterije prikazane su u realnom vremenu na platformi kako bi se osiguralo sigurno letenje i uspješno provela svaka misija. U pogledu opće sigurnosti, jedna od opcija koje nudi softver je praćenje trenutnog stanja u zračnom prometu (URL 10). Nakon završetka misije, softver nudi mogućnost prvotne obrade prikupljenih

fotografija odnosno georeferenciranja, kako bi fotografije bile spremne za daljnje korištenje u programima za obradu fotografija.



Slika 9. Sučelje *QBase 3D* programa

4.1.2. Označavanje i prikupljanje točaka lokalne geodetske osnove

Točke lokalne geodetske osnove potrebne za provođenje istraživanja podijeljene su na kontrolne točke (KT) i referentnu točku (RT). KT će poslužiti za ispitivanje pozicijske točnosti VTOL sustava bespilotne letjelice, dok će RT biti potrebna u procesu georeferenciranja fotografija.

4.1.2.1. Označavanje i prikupljanje kontrolnih točaka

Proces prikupljanja podataka započeo je s označavanjem i prikupljanjem točaka lokalne geodetske osnove. Kontrolne točke (KT) mogu se identificirati na izrađenim snimcima, a budući da imaju poznate (X,Y i Z) koordinate specifičnog koordinatnog sustava, poslužit će za provjeru točnosti sustava direktnog georeferenciranja bespilotne letjelice. Prilikom označavanja KT-a trebalo je pripaziti na odgovarajuću veličinu točaka i što bolje uočavanje u odnosu na podlogu, zbog čega je za označavanje korištena žarko crvena boja (Slika 10).



Slika 10. Označavanje i prikupljanje kontrolnih točaka

Ukupno je prikupljeno 7 kontrolnih točaka (KT1-7) koje su unutar područja istraživanja raspoređene prema temeljnim načelima fotogrametrije (Slika 11) i postavljene na mjesta bez potencijalnog antropogenog utjecaja s ciljem što veće otvorenosti horizonta iznad svake pojedine KT-e (Šiljeg i dr., 2022). Također, pozornost je usmjerena i na sjene krošanja stabala koje mogu uzrokovati slabiju vidljivost KT-a pri daljnjoj obradi podataka, budući da je terensko prikupljanje podataka trajalo nekoliko sati. Koordinate kontrolnih točaka prikupljene su u pet epoha (ponovljenih mjerenja) na temelju kojih su izračunate srednje vrijednosti (X, Y i Z) za svaku KT-u. Točke su prikupljene u HTRS96/TM, službenom projekcijskom koordinatnom sustavu Republike Hrvatske (Tablica 4).

Tablica 4. Koordinate kontrolnih točaka

Naziv	X	Y	Z	Tip točke
KT1	360410,5	4951541,1	42,906	Kontrolna
KT2	360401,5	4951388,0	35,765	Kontrolna
KT3	360419,9	4951359,8	38,682	Kontrolna
KT4	360563,8	4951261,5	48,038	Kontrolna
KT5	360575,0	4951250,1	46,587	Kontrolna
KT6	360686,7	4951208,9	55,592	Kontrolna
KT7	360606,6	4951110,1	41,339	Kontrolna



Slika 11. Prostorni raspored kontrolnih točaka i lokacija referentne točke

4.1.2.2. Referentna točka i postavljanje bazne stanice

Koordinate RT (Tablica 5) prikupljene su točno na mjestu predviđenom za postavljanje bazne stanice sustava bespilotne letjelice (Slika 12). Prilikom određivanja mjesta na kojem će biti postavljena bazna stanica *iBase*, trebalo je pripaziti na udaljenost elektroničkih naprava u blizini koje bi mogle ometati kvalitetu signala. Prikupljanje koordinata RT-e izvršeno je u deset epoha prije snimanja i deset epoha poslije snimanja, na temelju kojih su izračunate srednje vrijednosti za svaku koordinatnu os referentne točke.

Tablica 5. Koordinate referentne točke

Naziv	X	Y	Z	Tip točke
RT	360434,7	4951382,2	38,719	Referentna

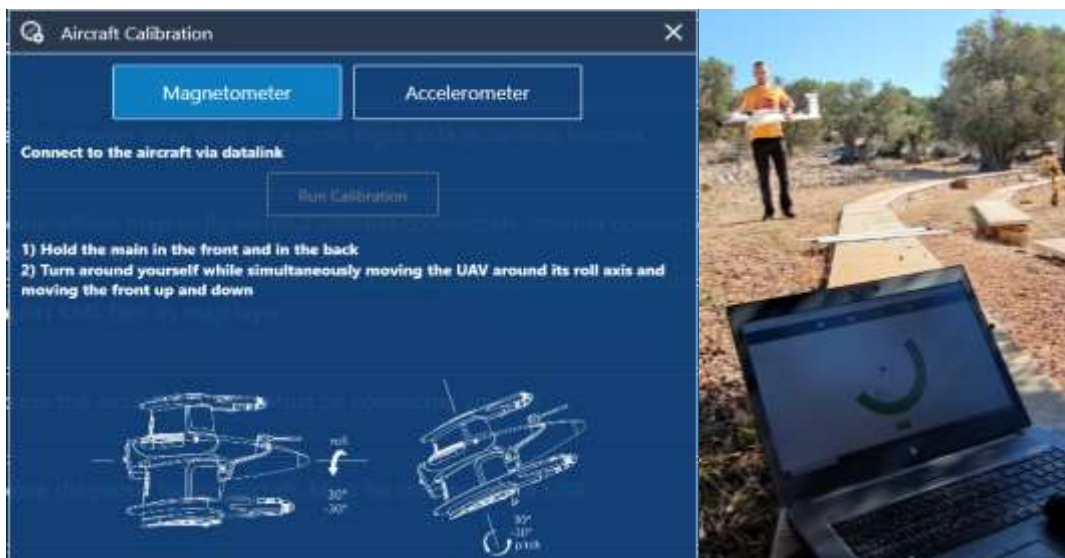


Slika 12. Referentna točka i bazna stanica *iBase*

4.1.3. Kalibracija bespilotne letjelice i MS senzora

Neophodan korak prije izvođenja misija i procesa prikupljanja podataka predstavlja kalibracija korištenih tehnologija. Proces kalibracije izuzetno je bitan i njegovo učestalo provođenje je nužno kako bi prikupljeni podaci što više odgovarali stvarnom stanju na terenu (Carbonneau i dr., 2006; Aasen i dr., 2018) Točnost prikupljenih podataka jedan je od najvažnijih segmenata svakog istraživanja, stoga je kalibraciju potrebno izvršiti i više puta, ako je tijekom jednog istraživanja došlo do promjene određenih atmosferskih uvjeta (Dinguirard i Slater, 1999; Aasen i dr., 2018).

Kalibracija bespilotne letjelice *Trinity F90+* sastojala se od dva dijela. Prvi dio se odnosio na kalibraciju magnetometra, senzora magnetske indukcije koji omogućava ispravno navođenje i praćenje zadanog zračnog koridora. Navedeni proces proveden je prije sastavljanja dijelova zrakoplova, kako bi se olakšalo uzastopno rotiranje i ubrzano vertikalno pomicanje bespilotne letjelice. Drugi dio kalibracijskog procesa vezan je uz kalibraciju (akcelerometra) tri rotacijska parametra (*Yaw, Pitch, Roll*) koji opisuju kutnu rotaciju bespilotne letjelice u odnosu na poznati koordinatni sustav. Slično kao i kod kalibracije magnetometra, bespilotna letjelica je nekoliko puta rotirana oko tri glavne osi rotacije (Slika 13), sve do potvrde o uspješnosti procesa izaslane na kontrolnoj stanici.



Slika 13. Kalibracija bespilotne letjelice *Trinity F90+*

Zatim je uslijedila radiometrijska kalibracija multispektralnog senzora, izvršena uz pomoć kalibracijskog panela koji posjeduje unaprijed izmjerene vrijednosti refleksije i

predstavlja poznatu referentnu točku. MS senzor podignut je na visinu od jednog metra s ciljem da postavljeni panel bude cijeli unutar objektiva senzora (Slika 14). Proces je osim prije leta, ponovljen i nakon odrađene misije, kako bi se utvrdile eventualne promjene u osvjetljenju tijekom trajanja leta.



Slika 14. Kalibracija postavljenog MS senzora pomoću kalibracijskog referentnog panela

4.1.4. Aerofotogrametrijsko snimanje područja istraživanja

4.1.4.1. Planiranje misija

Većina procesa planiranja misija bespilotne letjelice *Trinity F90+* izvedena je prije odlaska na terenski dio istraživanja, u softveru *QBase 3D*. Prvi korak vezan je uz pronalazak područja istraživanja na temelju dostupnih predložaka korištenog softvera. Zatim je uslijedio odabir modela bespilotne letjelice koji će se koristiti u istraživanju, kao i tip senzora integriran u bespilotnu letjelicu (Slika 15).



Slika 15. Odabir tipa bespilotne letjelice i vrste senzora

Urtavanjem vektorskog poligona preko područja istraživanja, program automatski nudi predloženi plan letenja. Dodatno je moguće podesiti parametre poput visine leta ili prostorne rezolucije kako bi oni odgovarali svrsi istraživanja, a moguće je mijenjati i postotak preklapanja između fotografija. Softver *QBase 3D* pruža uvid u parametre koji pomažu pri boljoj organizaciji vremena potrebnog za snimanje, poput ukupnog vremena letenja i ukupne duljine letenja (Slika 17). Valja napomenuti i predviđanje postotka potrošnje baterije tijekom obavljanja misije, što olakšava pripremu količine baterija potrebnih prilikom boravka na terenskom istraživanju.

4.1.4.2. Provođenje misija

Dolaskom na područje istraživanja podešeni su parametri leta i napravljene određene korekcije planiranih misija s obzirom na atmosferske prilike. Na odabir lokacije pogodne za polijetanje (označene simbolom zelene kuće na slici Slika 18.), utjecala je udaljenost od visokih vertikalnih objekata i krošnji stabala kako bi bespilotna letjelica mogla sigurno i nesmetano krenuti u planiranu misiju. Neposredno prije polijetanja provjereni su smjer i jačina vjetra, parametri koji značajno utječu na performanse bespilotne letjelice. Naime, bespilotna letjelica *Trinity F90+* krila koristi za ostvarivanje potiska putem strujanja zraka, stoga je prilikom polijetanja okrenuta u smjer puhanja vjetra (Slika 16).



Slika 16. Lokacija i smjer bespilotne letjelice prilikom polijetanja

Prva misija letenja uključivala je korištenje multispektralnog senzora. Visina leta postavljena je na 100 m, s koje je predviđeno kako će GSD iznositi 6,94 cm po pikselu. Postotak prednjeg i bočnog preklapanja postavljen je na 70%. Spomenuta preklapanja sugeriraju kako je u snimanju korištena misija *Double Grid Mission* (Slika 17) koja osigurava potrebnu gustoću preklapanja, optimalnu za daljnju obradu prikupljenih fotografija. Let je ukupno trajao 22 minute i 5 sekundi, s ukupnom prijeđenom duljinom od 22,6 km, a površina snimljenog područja iznosila je 11,3 hektara.



Slika 17. Plan i postavke misije s multispektralnim senzorom

Druga misija odnosi se na snimanje područja istraživanja uz pomoć RGB senzora koji je na kontrolnoj stanici postavljen kao zadani senzor. Napravljene su preinake smjera


polijetanja zbog promjene smjera i jačine vjetra, podešena je visina snimanja, tip misije i područje snimanja. Postavljena je visina od 140 m, a predviđeni GSD je iznosio 1,81 cm. Zbog sigurnosti, visina do koje će se bespilotna letjelica prilikom polijetanja vertikalno kretati postavljena je na 15 m, nakon čega počinje postepeno uspinjanje u duljini od 1,2 km, do zadane visine s koje će se prikupljati podaci odnosno snimati fotografije. Vrijeme leta prilikom faze prikupljanja podataka iznosilo je 37 minuta i 45 sekundi, a bespilotna letjelica je ukupno prevalila udaljenost od 38,9 km, primjenjujući *Grid Mission* tip misije. Posljednja faza leta odnosi se na putovanje do visine od 30 m iznad mjesta predviđenog za slijetanje, nakon čega se bespilotna letjelica vertikalno spušta do podloge. Ukupno je tijekom izvođenja druge misije potrošeno 30% korištene baterije, a snimljeno je područje veličine 86,9 hektara (Slika 18).



Slika 18. Plan i postavke misije s RGB senzorom

4.2 Obrada prikupljenih podataka

U procesu obrade prikupljenih zračnih fotografija prvotno je korišten program *QBase 3D*, u kojem su fotografije pripremljene za daljnju obradu. Napredni računalni program za obradu digitalnih fotografija *Agisoft Metashape Professional 1.5.1* poslužio je za daljnji tijek procesa koji je za cilj imao generiranje multispektralnog modela vrlo visoke rezolucije (Slika 19).



Slika 19. Shema obrade podataka

4.2.1. Kopiranje *Flylog* zapisa i georeferenciranje fotografija

Neposredno nakon završenog snimanja, *Flylog* zapis koji se nalazi na SD memorijskoj kartici bespilotne letjelice kopiran je na prijenosno računalo. Spomenuti zapis stvara se u realnom vremenu tijekom obavljanja misije i sadrži koordinate svih prikupljenih fotografija. Također je potrebno prebaciti podatke *iBase* bazne stanice koji se nalaze na mikro SD memorijskoj kartici unutar uređaja.

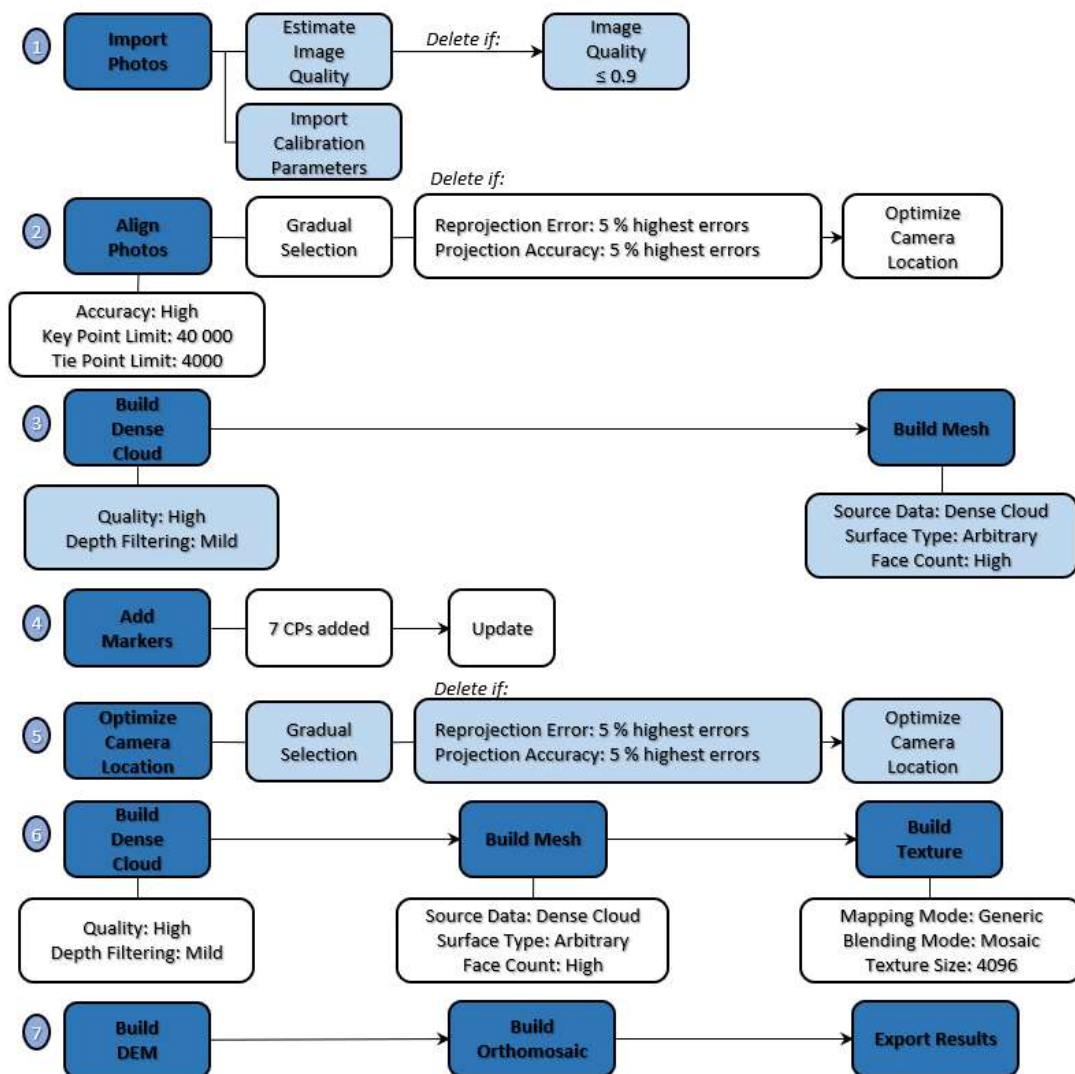
Sve fotografije s korištenih senzora koje se nalaze na mikro SD memorijskim karticama svakog pojedinog uređaja, također su prebačene na prijenosno računalo. Nakon prijenosa svih potrebnih datoteka uslijedilo je georeferenciranje fotografija odabirom direktorija u kojem se

podaci odnosno fotografije nalaze. Posljednji korak procesa georeferenciranja fotografija predstavlja dodavanje datoteke koja sadrži koordinate referentne točke, prikupljene GNSS uređajem. Proces *post-processing* u programu *QBase 3D* je kompletiran i fotografije su spremne za daljnju obradu.

4.2.2. Proces obrade zračnih snimaka u *Agisoft Metashape Professional 1.5.1*

Agisoft Metashape Professional 1.5.1 napredni je softver specijaliziran za obradu digitalnih fotografija. Softver primjenjuje *SfM (Structure from Motion)* metodu koja omogućuje obradu većeg broja snimki. Pristupi koje navedeni softver nudi uglavnom su automatizirani i jednostavni za korištenje te kao takvi pružaju prednost prilikom upotrebe, za razliku od drugih tehničkih pristupa koji zahtijevaju specijalizirano znanje ili dodatne softvere (Howland i dr., 2022).

Proces obrade fotografija (Slika 20) započeo je s fazom filtracije (*Estimate Image Quality*) prikupljenih snimki gdje su loše fokusirane ili zamućene fotografije s vrijednošću manjom od 0,9 uklonjene. Druga faza odnosi se na orijentaciju i spajanje preostalih snimki. Orijehtacija (*Align Photos*) se izvršava uz pomoć poznatih *xyz* lokacija kamere, odnosno prikupljenih fotografija. Softver automatski prepoznaje i povezuje snimke te izrađuje rijetki oblak točaka za čiju je preciznost parametar postavljen na vrijednost *high*. Uslijedila je faza izrade gustog oblaka točaka (*Build Dense Cloud*) unutar koje program automatski iz ranije izrađene geometrije i orijentacije snimaka izračunava dubinsku informaciju za svaku pojedinu fotografiju. Kvaliteta izlaznih rezultata uvelike ovisi o korisničko-definiranom parametru unutar varijable *Quality*, čija je vrijednost postavljena na *high*. Zbog izrade modela visoke točnosti, poželjno je odabrati što veću vrijednost varijable *Quality* u skladu s radnim mogućnostima korištenog računala. Parametar dubinskog filtriranja (*Depth Filtering*) postavljen je na opciju *mild*, koja se mijenja ovisno o značajkama istraživanog terena. Temeljni parametar (*Face Count*) prilikom faze generiranja 3D poligonalne mreže (*Build Mesh*) također je postavljen na *high*, što je rezultiralo izradom 2 591 358 međusobno povezanih poligona. Definirani su i parametri *Source Data* koji se odnose na izrađeni gusti oblak točaka pomoću kojega će se poligoni izraditi, te parametar *Surface type* kojim se određuje tip površine. Posljednja faza vezana je uz izradu teksture modela (*Build Texture*). Parametar *Mapping Mode* ovisi o različitim tipovima modelirane površine i postavljen je na opciju *generic*, dok je za način kartiranja (*Blending Mode*) postavljena opcija *mosaic*.



Slika 20. Shema procesa i zadani parametri prilikom obrade podataka u *Agisoft Metashape*

1.5.1

4.3. Ispitivanje točnosti izravnog georeferenciranja

Ispitivanje točnosti direktnog georeferenciranja VTOL sustava bespilotne letjelice na visini leta od 100 m provedeno je koristeći se softverom *Agisoft Metashape Professional 1.5.1*. Za provedbu ispitivanja točnosti, pridodano je 7 kontrolnih točaka prikupljenih terenskim istraživanjem, pomoću kojih je izračunata točnost izvedenog multispektralnog modela.

Točnost i preciznost najčešće su uvjetovane određenim čimbenicima poput postavki snimanja (Watts i Ambrosia, 2012), površine snimanog područja (McRoberts i dr., 2013) i učestalosti provođenja kalibracijskog procesa (Aasen i dr., 2018). Za izračun je korišten

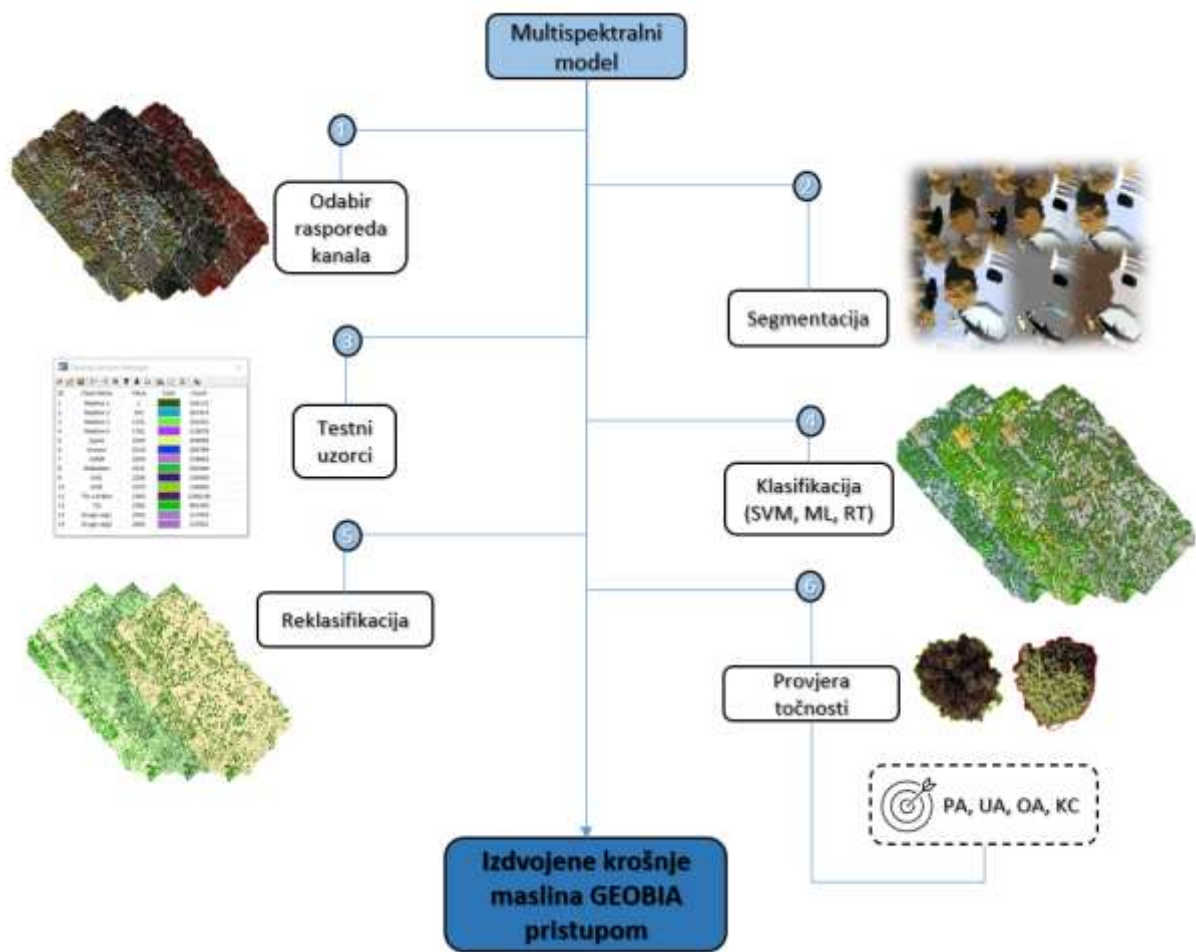
statistički pokazatelj srednje kvadratne pogreške (*Root Mean Square Error - RMSE*) koji se često upotrebljava prilikom provjera točnosti različitih modela (Chai i Draxler, 2014). Formula statističkog pokazatelja glasi:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$$

Gdje vrijedi da je n broj točaka, dok e predstavlja pogreške dobivene razlikom reziduala (Chai i Draxler, 2014). Nakon procesa korigiranja kontrolnih točaka, spomenuti softver pogrešku prikazuje u obliku tablice unutar kreiranog izvješća obrade podataka.

4.4. GEOBIA pristup u kartiranju krošanja maslina

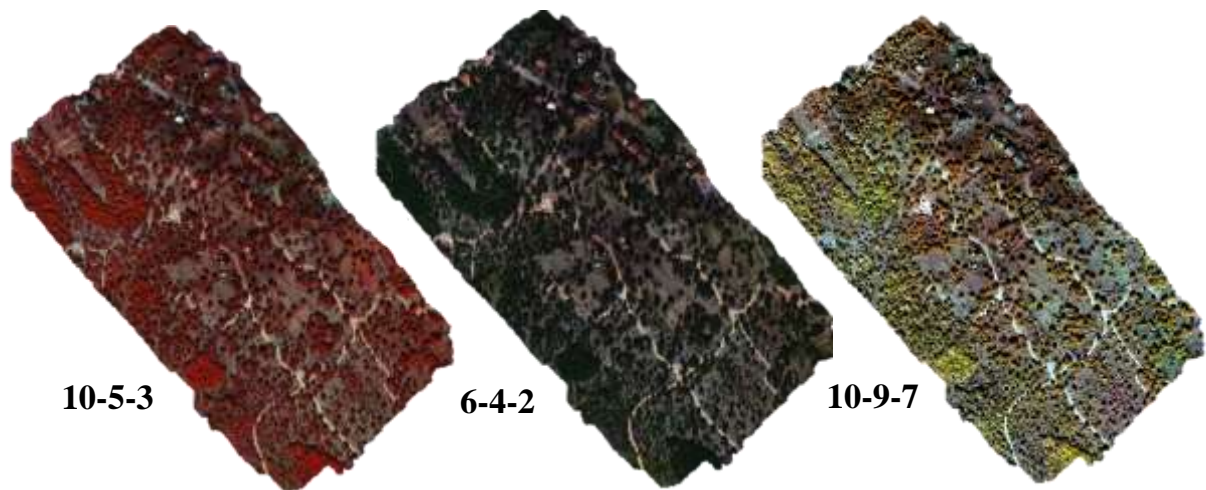
Izdvajanje krošanja maslina korištenjem geografskih objektno orijentiranih analiza, zahtjeva provođenje temeljnih koraka (Slika 21). Šest koraka koji čine GEOBIA pristup su: (1) odabir optimalnog rasporeda kanala, (2) segmentacija multispektralnog modela, (3) dodavanje testnih uzoraka, (4) testiranje klasifikacijskih algoritama, (5) reklasifikacija multispektralnog modela i (6) provjera točnosti. GEOBIA pristup proveden je korištenjem različitih alata i tehnika integriranih unutar programa *ArcMap 10.4*, američke kompanije *ESRI*.



Slika 21. Koraci GEOBIA pristupa

4.4.1. Odabir optimalnog rasporeda spektralnih kanala


Odabir rasporeda kanala ovisi o vrsti i karakteristikama vegetacije koja se izdvaja (Solano i dr., 2019). Budući da su objekt istraživanja krošnje maslina, odabir rasporeda kanala uvjetovan je spektralnom refleksijom maslina. Stoga su se prilikom odabira rasporeda uglavnom koristile kombinacije koje su uključivale kanale u rubnom crvenom i infracrvenom dijelu spektra, a za bolju vizualizaciju prikazane su i druge kombinacije (Slika 22).



Slika 22. Različite kombinacije rasporeda spektralnih kanala


4.4.2. Segmentacija

Vrijednosti koje se mogu mijenjati unutar alata *Segment Mean Shift* (Slika 23) su spektralna detaljnost, prostorna detaljnost i minimalna veličina segmenta. Spektralna detaljnost uvjetovana je spektralnom rezolucijom korištenog MS senzora i omogućuje odvajanje krošnja maslina od ostale vegetacije. Važnost blizine značajki u promatranom modelu utvrđuje prostorna detaljnost, čije veće vrijednosti omogućuju izdvajanje detaljnih karakteristika, potrebnih za izdvajanje maslina u odnosu na drugu vegetaciju. S druge strane, jako niske vrijednosti značajnije generaliziraju snimak, stoga je potrebno pronaći optimalnu vrijednost. Vrijednost minimalne veličine segmenta odnosi se na broj spektralno sličnih piksela koji kao cjelina mogu biti zasebno segmentirani (URL 16).



Slika 23. Alat *Segment Mean Shift*

Kako bi se pronašla najbolja kombinacija navedenih korisničko-definiranih parametara, izvedena su i uspoređena 42 segmentacijska modela. (Slika 24).



Slika 24. Usporedba različitih parametara prilikom procesa segmentacije

4.4.3. Dodavanje testnih uzoraka

Jedan od najvažnijih koraka prilikom provođenja GEOBIA pristupa u izdvajanju krošanja maslina predstavlja dodavanje testnih uzoraka. Dodavanje reprezentativnog broja uzoraka za svaku klasu od iznimne je važnosti, budući da odabrani klasifikacijski algoritmi segmentirani model klasificiraju po testnim uzorcima zadanim od strane korisnika (Kucharczyk i dr., 2020; Modica i dr., 2020). Označavanje uzoraka izvršeno je pomoću alata *Select Segment* unutar *Training Sample Manager*-a. Prilikom označavanja optimiziran je odgovarajući broj klasa koje će predstavljati objekt istraživanja, ali i broj drugih klasa unutar promatranog područja. Objekt istraživanja, odnosno krošnje maslina prikupljene su unutar četiriju klasa (Slika 25), ponajviše zbog morfologije terena i kuta upada sunčevih zraka koji uzrokuju razlike u spektralnoj refleksiji unutar krošanja.




Slika 25. Proces dodavanja testnih uzoraka

4.4.4. Klasifikacija


Klasificiranje segmentiranog snimka izvedeno je pomoću tri algoritama koji se najčešće koriste prilikom GEOBIA procesa: (1) *Support Vector Machine - SVM*, (2) *Maximum Likelihood - ML* i (3) *Random Trees - RT* (Ma i dr., 2017; Šiljeg i dr., 2020; Panđa i dr., 2021)

(1) SVM klasifikacijski algoritam uključuje niz tehnika koje predstavljaju značajan alat daljinskih istraživanja temeljen na principu minimalizacije strukturnog rizika (Cortes i Vapnik, 1995). Algoritam definira ravninu koja klasificira sve testne uzorke u prethodno zadani broj klasa, a od ostalih klasifikacijskih algoritama razlikuje se zbog načina odabira spomenute ravnine. Još jedna od prednosti je i tolerantnost prema klasama s manjim brojem testnih uzoraka ili neuravnoteženošću između klasa (Cortes i Vapnik, 1995; Heumann, 2011). Za segmentirane rastere, algoritam unutar alata *Train Support Vector Machine Classifier* (Slika 26) izračunava indeksnu sliku i povezane atribute segmenta u svrhu kreiranja SVM klasifikacijske datoteke. Korisničko-definirani parametar *Max Number Of Samples Per Class* postavljen je na vrijednost 50, a odnosi se na maksimalan broj uzoraka za definiranje klasa na temelju prikupljenih uzoraka. Parametar može imati vrijednost od 0 do 100, pri čemu vrijednosti manje ili jednake 0 označavaju korištenje svih testnih uzoraka za generiranje klasifikacijskog dokumenta (URL 12).



Slika 26. Alat *Train Support Vector Machine Classifier*

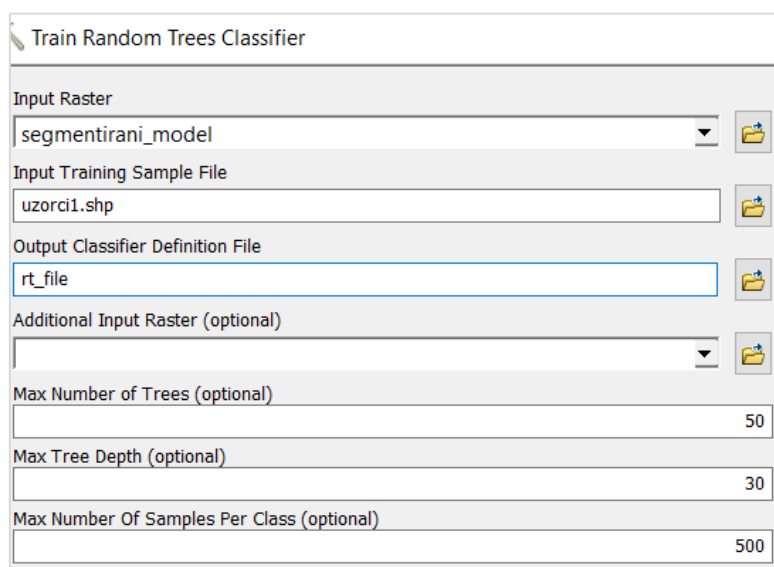
(2) ML jedan je od korištenijih algoritama za klasifikaciju segmentiranih multispektralnih snimki. U spomenutom algoritmu, distribucije vjerojatnosti za svaku od klasa razgraničene su korištenjem matrice varijance i kovarijance pomoću dostatnog broja testnih uzoraka na temelju čega algoritam za svaki segment modela dodjeljuje pripadnost određenoj klasi (Otukei i Blaschke, 2010). Klase se generiraju na temelju najveće vjerojatnosti, a ML klasifikacijska datoteka s potrebnim informacijama kreirana je uz pomoć alata *Train Maximum Likelihood Classifier* (Slika 27), koji osim osnovnih, nema druge dodatne parametre (URL 13).



Slika 27. Alat *Train Maximum Likelihood Classifier*


(3) RT klasifikacijski algoritam učinkovito djeluje prilikom rada s velikim bazama podataka, a sastoji se od kombinacije raznih klasifikacijskih algoritama koji svakom testnom uzorku, na temelju ukupnog rezultata, određuju pripadnost određenoj klasi (Breiman, 2001). Takav skup algoritama postiže veću stabilnost RT klasifikacijskog algoritma, za razliku od drugih. Također, algoritam pruža procjenu relativne važnosti različitih značajki ili varijabli tijekom procesa klasifikacije, što ga čini korisnim prilikom provođenja istraživanja u kojima je heterogenost podataka vrlo visoka (Rodriguez-Galiano i dr., 2012). *Train Random Trees*

Classifier alat (Slika 28) poslužio je za generiranje RT klasifikacijske datoteke. Kod spomenutog alata, parametar *Max Number Of Samples Per Class* postavljen je na 500, budući da vrijednosti variraju od 0 do 1000, s jednakim značenjem raspona vrijednosti kao kod alata SVM algoritma. Pored navedenog, RT klasifikacijski algoritam koristi još dva korisničko-definirana parametra. Prvi se odnosi na vrijednost maksimalnog broja stabala (*Maximum Number of Trees*), koji s povećanjem vrijednosti dovodi do većih stopa preciznosti, ali i duljeg vremena obrade. Drugi parametar vezan je uz maksimalnu dubinu stabala (*Max Tree Depth*) i predstavlja drugi način određivanja pravila alata u svrhu generiranja izlaznih rezultata. Prvi parametar postavljen je na vrijednost 50, dok je za drugi vrijednost iznosila 30.



Slika 28. Alat *Train Random Trees Classifier*

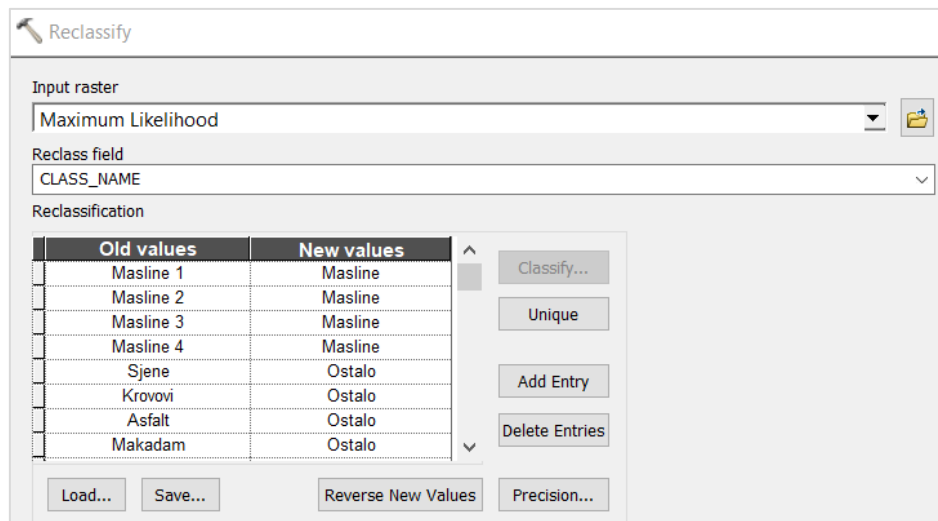
Nakon generiranja klasifikacijskih (.ecd) datoteka korištenjem alata integriranih unutar programa *ArcMap 10.4*, uslijedila je klasifikacija rastera (*Classify Raster*), koja je uz pomoć ulaznih podataka odnosno segmentiranog snimka i klasifikacijskih datoteka (Slika 29), za cilj imala generiranje klasificiranih modela.



Slika 29. Alat *Classify Raster*

4.4.5. Reklasifikacija

Proces reklasifikacije važan je prilikom provođenja istraživanja. Reklasifikacija ovisi o svrsi istraživanja odnosno o promatranom objektu koji se istražuje i omogućuje razdiobu područja istraživanja na dio koji se promatra i preostali dio. Budući da su objekt ovog istraživanja krošnje maslina, prvotnih 14 klasa reklasificirano je u klasu „Masline“ i klasu „Ostalo“ (Slika 30). Klasa „Masline“ u daljnjem procesu poprimila je vrijednost 1, dok je klasi „Ostalo“ pridodana vrijednost 0.



Slika 30. Alat *Reclassify*

4.4.6. Provjera točnosti klasifikacijskih algoritama

Provjera točnosti ključan je korak GEOBIA pristupa kojim se odabire najbolji model koji će se koristiti kao reprezentativan u svrhu vizualizacije izlaznih rezultata i za potrebe daljnjih istraživanja (Liu i dr., 2007; Wickham i dr., 2021).

4.4.6.1. Mjere provjere točnosti

Podloga provjere točnosti GEOBIA klasifikacijskih algoritama najčešće je konfuzijska matrica pogrešaka, unutar koje je moguće izračunati sljedeće korištene mjere za procjenu točnosti: (1) *Producer Accuracy* - PA, (2) *User Accuracy* - UA, (3) *Overall Accuracy* - OA i (4) *Kappa Coefficient* - KC (Deur i dr., 2021).

(1) PA izračunava se dijeljenjem broja ispravno klasificiranih uzoraka s ukupnim brojem uzoraka koji su trebali biti razvrstani u tu klasu (*False negative* tip pogreške) (Oštir i Mulahusić, 2014). Određuje se prema sljedećoj formuli (Story i Congalton, 1986):

$$PA_i = \frac{P_{ii}}{P + i}$$

(2) UA se izračunava dijeljenjem broja ispravno klasificiranih uzoraka s ukupnim brojem uzoraka koji su prepoznati u toj klasi (*False positive* tip pogreške) (Oštir i Mulahusić, 2014) Formula za izračun je sljedeća (Story i Congalton, 1986):

$$UA_i = \frac{P_{ii}}{P_i +}$$

(3) OA se izračunava zbrajanjem točno klasificiranih uzoraka koji se dijele s ukupnim brojem uzoraka (URL15). Formula prema kojoj se određuje glasi (Story i Congalton, 1986):

$$OA = \sum_{i=1}^m P_{ii}$$

(4) KC predstavlja mjeru odnosa između klasificiranih i referentnih podataka, prikazanu glavnom dijagonalom matrice konfuzije, te slučajnim podudaranjem kojeg predstavljaju zbrojevi stupaca i redaka matrice. Mjera procjenjuje točnost klasifikacije na ljestvici od -1 do 1, gdje se veće vrijednosti odnose na točnije modele (URL 15). Korištenje KC ispravlja slučajno dobivene visoke točnosti prilikom izvođenja jednostavnih klasifikacija (Cohen, 1960). KC se izračunava po sljedećoj formuli (Story i Congalton, 1986):

$$K = \frac{N \sum_{i=1}^r P_{ii} - \sum_{i=1}^r (p_{i+} * p_{+i})}{N^2 - \sum_{i=1}^r (p_{i+} * p_{+i})}$$


U navedenim formulama, simbol r predstavlja broj redaka odnosno stupaca u matrici konfuzije, N se odnosi na ukupan broj uzoraka, P_{ii} na glavni dijagonalni element za klasu i , P_{i+} na ukupan broj uzoraka u retku, dok se P_{+i} odnosi na ukupan broj uzoraka u stupcu za klasu i .

4.4.6.2. Koraci provjere točnosti

Provjera točnosti izvedena je uz pomoć slojeva pravilno raspoređenih točaka generiranih unutar poligona koji predstavljaju referentne i lažne objekte. Ovaj način provjere

točnosti osigurava stotine tisuća uzoraka koji će biti pozicionirani unutar referentnih i lažnih maslina kako bi rezultati točnosti bili što ispravniji (Ghorbanzadeh i dr., 2019; Šiljeg i dr., 2022). Spomenuti način, bitno se razlikuje od načina u kojem rezultati točnosti ovise o nekoliko stotina nasumično raspoređenih točaka (Stehman i Czaplewski, 1998).


Kako bi se provele spomenute mjere procjene točnosti i izradila konfuzijska matrica, prvi korak uključivao je vektorizaciju devet referentnih maslina (RM) koje predstavljaju stvarne masline na terenu (Slika 31a). Prilikom odabira RM, ciljane su masline čija je krošnja samostalna odnosno nije povezana s drugim krošnjama, te je osigurana optimalna prostorna distribucija uzoraka. Sve RM-e generirane su pomoću DOF-a vrlo visoke rezolucije. S druge strane, pridodano je i devet lažnih maslina (LM) koje značajno utječu na krajnji odabir najboljeg klasifikacijskog algoritma (Slika 31b). Prije dodavanja LM, uočeno je kako se lažno klasificirane masline kod sva tri klasifikacijska algoritma ponajprije pojavljuju u klasama koje se odnose na drugu vegetaciju i sjene. Glavni uzrok tome su slične spektralne karakteristike navedenih klasa s klasom maslina, te su zbog toga poligoni LM pridodani unutar klase koja predstavlja krošnje drugih vegetacijskih vrsta.



Slika 31. a) Poligon referentne masline, b) Poligon lažne masline

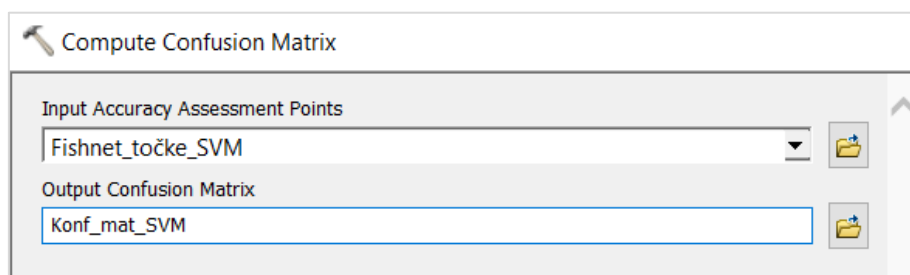
Sljedeći korak uključivao je izradu točkastog sloja za svaki pojedini piksel unutar RM i LM. Navedeni proces proveden je uz pomoć alata *Create Fishnet* koji za svaki piksel pridodaje odgovarajuću točku na temelju rasterske strukture izrađenog DOF-a vrlo visoke rezolucije (Slika 32a). Nadalje, za svaku točku pridodan je atribut *GrndTruth* unutar atributne tablice koji se odnosi na stvarnu vrijednost točke na terenu. Za sve točke koje se nalaze unutar poligona

RM pridodane su vrijednosti 1 , dok su za točke unutar poligona LM, pridodane vrijednosti 0. Za atribut *Classified*, pridodane su vrijednosti 0 ili 1 ovisno o tome nalazi li se točka unutar klasificirane klase masline ili ne. Vrijednosti 1 pridodane su za točke unutar klase maslina, dok su vrijednosti 0 pridodane točkama koje se ne nalaze u klasi maslina, odnosno nalaze se u klasi ostalo (Slika 32b).



Slika 32. a) *Fishnet* točaka unutar RM-e, b) Atributna tablica RM-a

Budući da su prilikom klasifikacije korištena tri klasifikacijska algoritma, proces pridodavanja vrijednosti atributa ponovljen je za svaki algoritam, te su pomoću alata *Compute Confusion Matrix* (Slika 33) kreirane konfuzijske matrice potrebne za izračun navedenih mjera. Točnost je ispitana na temelju ukupno 1 929 547 točaka.




Slika 33. Alat *Compute Confusion Matrix*

4.5. Pristup temeljen na vegetacijskim indeksima u kartiranju krošanja maslina

Proces izdvajanja krošanja maslina uz pomoć vegetacijskih indeksa podijeljen je u četiri temeljna koraka: (1) odabir vegetacijskih indeksa, (2) izdvajanje vegetacijskih indeksa, (3)

razvoj alata za optimizaciju praga vegetacijskih indeksa u procesu kartiranja krošanja maslina (VITO) i (4) provjera točnosti (Slika 34). Cjelokupni proces proveden je korištenjem alata i tehnika integriranih unutar programa *ArcMap 10.4*.



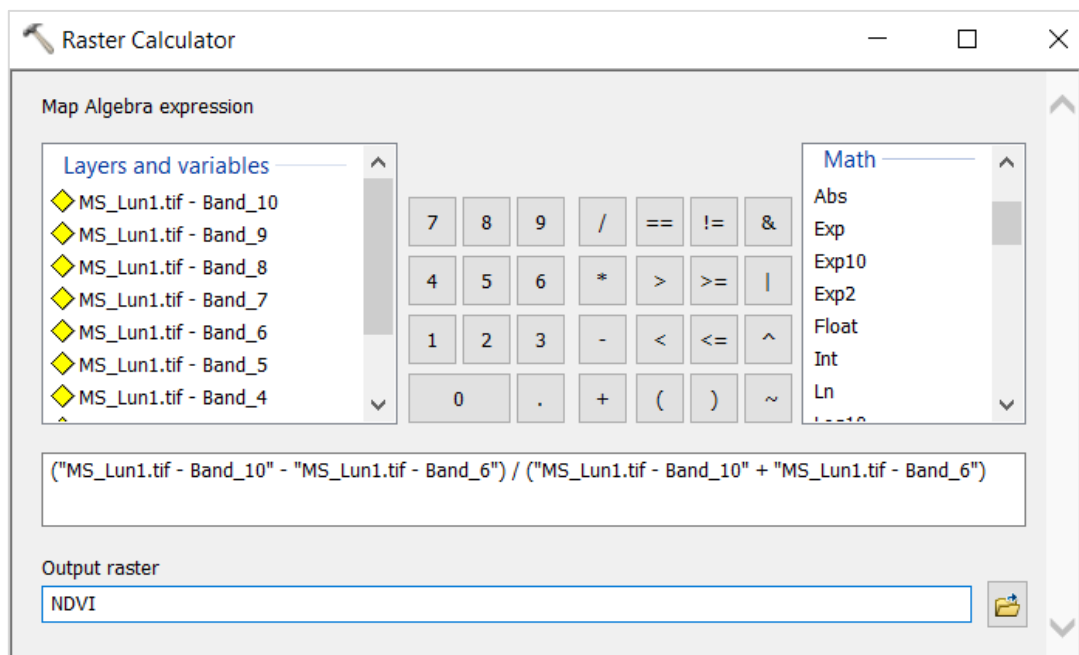
Slika 34. Shema procesa izdvajanja krošanja maslina korištenjem vegetacijskih indeksa

4.5.1. Generiranje odabranih vegetacijskih indeksa

Vegetacijski indeksi nastaju kombinacijom multispektralnih kanala korištenog senzora, koji se unutar *ArcMap 10.4* mogu izdvojiti uz pomoć različitih alata. Jedan od tih alata je *Raster Calculator* koji omogućuje stvaranje i izvršavanje različitih naredbi i varijabli koje postojeće rasterske slojeve pretvaraju u nove rasterske modele vegetacijskih indeksa. Brojčane vrijednosti i matematički operatori mogu se dodati klikom na adekvatne gumbe u dijaloškom okviru alata

čime se tvori odgovarajuća formula, pri čemu treba pripaziti na pravilan redoslijed operatora, kao i ispravno korištenje zagrada za izradu složenijih formula (URL11).

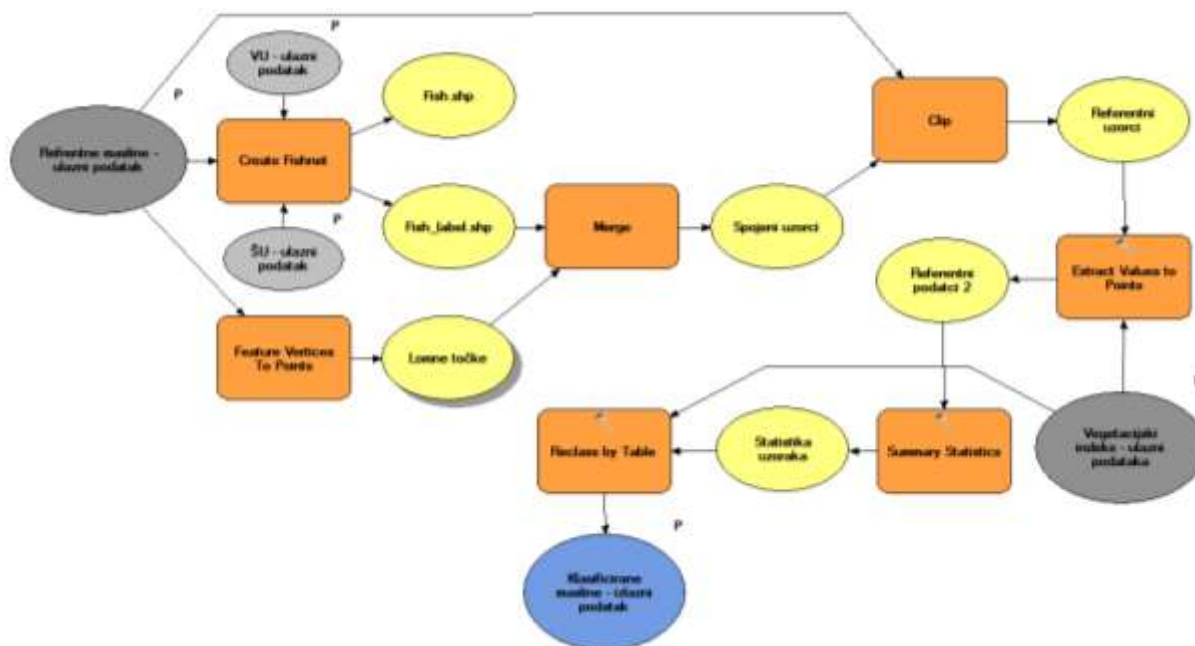
Kod vegetacijskih indeksa, uporaba alata *Raster Calculator* omogućuje odabir spektralnih kanala u unaprijed zadanu formulu i generaciju izlaznog rezultata, odnosno modela odabranog vegetacijskog indeksa (Slika 35). Ukupno je uz pomoć *Raster Calculator*-a izvedeno 16 vegetacijskih indeksa, od kojih je prema metodi vizualne interpretacije, pet indeksa (*NDVI*, *NDRE*, *GNDVI*, *MCARI2* i *RDVI2*) odabrano za daljnji tijek istraživanja.



Slika 35. Alat *Raster Calculator*

4.5.2. Izdvajanje krošanja maslina pomoću alata VITO

Alat VITO (*Vegetation Index Threshold Optimizer*) (Slika 36) izrađen je s ciljem automatiziranja procesa u svrhu izdvajanja maslina uz pomoć odabranih vegetacijskih indeksa. Alat je izrađen unutar *Model Buildera*, aplikacije koja služi za stvaranje, uređivanje i upravljanje radnim tokovima nizova alata unutar *ArcMap*-a.



Slika 36. Shema alata VITO unutar *Model Builder*-a (Šiljeg, 2022)

Alat VITO kao ulazni podatak koristi vektorizirani sloj referentnih krošanja maslina. Zatim se na temelju ulaznog podatka, alat grana u tri smjera. Prvi od triju smjerova, vezan je uz alat *Feature Vertices To Points* koji izdvaja lomne točke oblikovane prilikom izrade poligona. Drugi smjer se odnosi na alat *Create Fishnet* koji služi za kreiranje pravilne mreže točaka unutar svakog poligona. Parametri širine uzorka (ŠU) i veličine uzorka (VU) ključni su u spomenutom alatu zbog čega su postavljeni kao izdvojeni parametri koje je moguće mijenjati ovisno o svrsi. Izlazni rezultat *Create Fishnet* alata je vektorski sloj pravilno raspoređenih točaka koji se u sljedećem koraku pomoću alata *Merge*, spaja s vektorskim slojem lomnih točaka iz prvog smjera. Treći smjer vezan je uz alat *Clip* kojem su ulazni podaci spojene točke iz prva dva smjera i prvotni poligoni referentnih maslina, a izlazni referentni uzorci.

U drugom dijelu alata VITO, nalazi se drugi ulazni podatak odnosno odabrani vegetacijski indeks na temelju kojeg se vrši optimizacija vrijednosti raspona indeksa potrebnog za izdvajanje krošanja maslina. Spomenuti referentni uzorci i vegetacijski indeks, služe kao ulazni podaci za alat *Extract Values to Points* uz pomoć kojeg se svakoj referentnoj točki pridodaje odgovarajuća vrijednost rasterskog sloja, koja se u atributnoj tablici zapisuje u obliku novog atributa naziva *RasterValue*. Sloj referentnih uzoraka sadrži sve informacije potrebne za kreiranje statistike uzoraka. Statistika referentnih uzoraka izrađena je unutar alata *Summary Statistics* koji izlazne rezultate prikazuje u obliku tablice. U završnoj fazi alata VITO, koristi se

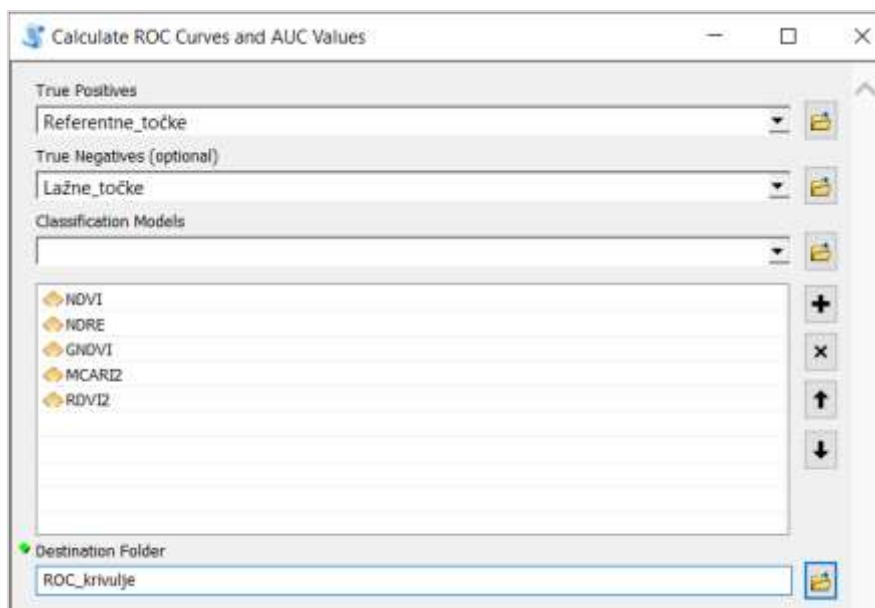
alat *Reclass by Table* koji uz pomoć statistike generira izlazne rezultate u obliku klasificiranih krošanja maslina.

4.5.3. Provjera točnosti vegetacijskih indeksa

Točnost izlaznih rezultata korištenog alata VITO provjerena je uz pomoć vrijednosti AUC-a (*Area Under Curve*) dobivenih iz ROC (*Receiver Operating Characteristic*) krivulja. ROC krivulja i vrijednosti AUC-a često su korišteni u istraživanjima mnogih znanstvenika (Bradley, 1997; Avand i dr., 2021; Tavakkoli-Piralilou i dr., 2022) u svrhu provjere točnosti kreiranih modela. ROC krivulja je grafički dijagram koji ilustrira dijagnostičku sposobnost sustava određenog klasifikatora, a stvara se pomoću TRP (*True Positive Rate*) i FPR (*False Positive Rate*) vrijednosti promatranog modela (Krzanowski i Hand, 2009).

Najbitniji pokazatelj ROC krivulje je AUC čije se vrijednosti rangiraju na ljestvici od 0 do 1, pri čemu modeli veće točnosti imaju vrijednosti bliže 1 (Hanley i McNeil, 1982). Vrijednosti od 0,6 do 0,7 predstavljaju modele loše točnosti, vrijednosti od 0,7 do 0,8 modele prosječne točnosti, vrijednosti 0,8 do 0,9 modele vrlo dobre točnosti, dok vrijednosti veće od 0,9 predstavljaju modele izvrsne točnosti (Rahmati i dr., 2017; Costache i dr., 2020).


Izrada ROC krivulja i AUC vrijednosti u potpunosti je automatizirana korištenjem alata *Calculate ROC Curves and AUC Value* (Slika 37), koji je u *ArcMap* naknadno integriran unutar seta alata *ArcSDM Tools*. Alat kao ulazne podatke koristi već od prije kreiran sloj pravilno raspoređenih točaka unutar referentnih (*True Positives*) i lažnih (*True Negatives*) maslina, te modele odabranih vegetacijskih indeksa (*Classification Models*) na temelju kojih se krivulja izrađuje.



Slika 37. Alat *Calculate ROC Curves and AUC Values*

4.6. Usporedba korištenih pristupa u kartiranju krošanja maslina

Odabrani modeli dvaju pristupa u kartiranju krošanja maslina uspoređeni su pomoću pet mjera točnosti (PA, UA, OA, KC i AUC) kako bi se odabrao najbolji pristup. Prvi način provedbe mjera točnosti uključivao je slojeve pravilnog rasporeda točaka (*fishnet*) unutar poligona referentnih i lažnih maslina (Slika 38). Poligoni maslina vektorizirani su pomoću referentnog DOF-a i predstavljaju stvarno stanje na terenu. Alatima *Compute Confusion Matrix* i *Calculate ROC Curves and AUC Values* unutar *ArcMap*-a kreirane su konfuzijske matrice i ROC krivulje za svaki od dvaju pristupa.



Slika 38. Prostorni raspored poligona referentnih i lažnih maslina

Drugi način usporedbe dvaju pristupa proveden je uz pomoć sloja tisuću nasumično raspoređenih točaka (Slika 39) kreiranih pomoću alata *Create Accuracy Assessment Points*. Za svaku točku je na temelju referentnog DOF-a, pridodan atribut koji označava stvarnu pripadnost klasi u prostoru, odnosno 0 za klasu ostalo i vrijednost 1 ako se točka na području istraživanja nalazi unutar krošnje masline. Korištenjem identičnih alata kao i u prvom načinu usporedbe, kreirane su konfuzijske matrice i ROC krivulje unutar kojih se nalaze rezultati korištenih mjera točnosti.



Slika 39. Prostorni raspored nasumično raspoređenih točaka

4.7. Istraživanje varijabilnosti vegetacijskih indeksa unutar krošnje


Varijabilnosti vegetacijskih indeksa unutar krošanja maslina vrlo su bitne u svrhu upravljanja (Rosell i Sanz, 2012), nadzora (Fernández i dr., 2016; Šiljeg i dr., 2020), procjene kvalitete uroda (Stateras i Kalivas, 2020) detekcije bolesti (Nolè i dr., 2018) i preventivnih djelovanja (Martinelli i dr., 2015). Razne štetne i invazivne vrste parazitiraju maslinu, uzrokuju bolesti i narušavaju normalan rast i razvoj, što rezultira oštećenim i nezdravim dijelovima krošnje (Pelicarić i dr., 2005; Barić i dr., 2014). Rano uočavanje i prevencija štetnih nametnika od ključne je važnosti, a upravo tu mogućnost nudi korištenje vegetacijskih indeksa i geoprostornih tehnologija.

Varijabilnosti vegetacijskih indeksa istraživane su pomoću NDRE i NDVI indeksa koji su najkorišteniji u radovima sa sličnom tematikom (Avola i dr., 2019; Solano i dr., 2019). Kako bi se utvrdile varijabilnosti, vegetacijski indeksi su pomoću alata *Clip*, izdvojeni samo unutar krošnji maslina.

5. Rezultati i rasprava


5.1. Prikupljene fotografije MS i RGB senzora

Multispektralnim senzorom ukupno je prikupljeno 4 840 fotografija. Fotografije su prikupljene s 484 lokacije, s obzirom da senzor *MicaSense RedEdge-MX Dual Camera* s jedne lokacije područje snima istodobno s deset različitih spektralnih kanala (Slika 40a,b). Prosječna visina s koje su fotografije snimljene iznosi 121 m, a snimljeno je područje površine 23,4 hektara.



Slika 40.a) Lokacije MS fotografija i broj preklapanja, b) *Image residuals* za NIR kanal (5,5mm)

RGB senzorom prikupljeno je ukupno 927 fotografija s isto toliko lokacija snimanja. Fotografije su snimljene s prosječne visine leta od 149 m, a površina snimljenog područja iznosi 114 hektara (Slika 41a,b).



Slika 41. a) Lokacije RGB fotografija i broj preklapanja, b) *Image residuals* (35 mm)

5.2. Rezultati obrade podataka u *Agisoft Metashape Professional*

5.2.1. Rijetki oblak točaka

Nakon procesa orijentacije snimki, generiran je rijetki oblak točaka s ukupno 1 213 547 točaka. Također, izračunate su i lokacije prikupljenih fotografija (Slika 42).



Slika 42. Rijetki oblak točaka s lokacijama prikupljenih fotografija

5.2.2. Gusti oblak točaka


Generirani gusti oblak točaka nastao je kao proizvod koraka radnog tijeka korištenjem prikupljenih multispektralnih fotografija i sastoji se od 13 588 875 točaka (Slika 43).



Slika 43. Gusti oblak točaka područja istraživanja


5.2.3. Poligonalna i teksturirana poligonalna mreža

Poligonalna mreža sastoji se od 2 591 358 međusobno povezanih poligona (Slika 44).



Slika 44. Poligonalna mreža područja istraživanja

Nakon izrade poligonalne mreže, ista je teksturirana (Slika 45) kako bi se mogao generirati završni rezultat, odnosno multispektralni model područja istraživanja.



Slika 45. Teksturirana poligonalna mreža područja istraživanja

5.2.4. Multispektralni model vrlo visoke rezolucije

MS model vrlo visoke prostorne rezolucije od 4,14 cm, izveden je kao rezultat provedenog aerofotogrametrijskog snimanja pomoću multispektralnog senzora i procesa obrade podataka. Dobivena vrlo visoka prostorna rezolucija predstavlja ključ u provođenju istraživanja i omogućuje donošenje novih spoznaja i zaključaka. Model se sastoji od deset zasebnih spektralnih snimki koje je moguće i samostalno analizirati u svrhu odabira najreprezentativnijeg kanala za istraživani objekt. Multispektralni model ukupno zauzima 5,43 GB memorijskog prostora. Spajanjem i kombiniranjem različitih spektralnih kanala, multispektralni model se vizualizira ovisno o željama i potrebama korisnika (Slika 46).




Slika 46. MS model vrlo visoke prostorne rezolucije

Avola i dr., 2019. podatke prikupljaju s visine od 25 m i generiraju model čija prostorna rezolucija iznosi 2 cm, dok Marques i dr., 2019. s visine od 200 m generiraju multispektralni model prostorne rezolucije 16 cm. Navedena istraživanja pokazuju kako generirani multispektralni model ima i više nego potrebnu razinu detaljnosti za kartiranje vegetacije.

5.3. Točnost izravnog georeferenciranja

Proces prikupljanja podataka prvom misijom bespilotne letjelice i obrade prikupljenih podataka, rezultirao je fotografijama s poznatom X,Y,Z lokacijom i pripadajućom relativnom pogreškom za svaku od triju navedenih koordinata (Slika 47).



Slika 47. Procijenjene pogreške pozicioniranja kamera

Ukupna pozicijska točnost multispektralnog modela vrlo visoke rezolucije dobivena procesom izravnog georeferenciranja iznosi 3,4804 cm. Vrijednosti pogrešaka variraju prema koordinatnim osima, točnost za os X iznosi 1,3976 cm, za os Y 1,1179 cm, dok je za Z os pogreška najveća u iznosu od 2,9851 cm (Tablica 6). Postignute vrijednosti ukazuju na vrlo visoku preciznost PPK pozicioniranja VTOL sustava bespilotne letjelice na visini leta od 100 m, čime su se ostvarila očekivanja postavljena prije početka istraživanja.

Tablica 6. Ukupna točnost izvedena iz kontrolnih točaka


Count	X error (cm)	Y error (cm)	Z error (cm)	Total error (cm)
7	1,3976	1,1179	2,9851	3,4804

Vrijednosti pogrešaka neznatno se razlikuju između dodanih KT-a. Najmanju ukupnu pogrešku ima KT3 koja se nalazi u središnjem dijelu područja istraživanja, a najveću pogrešku ima KT2 koja, iako također smještena u središnjem dijelu istraživanog područja, najveću

pogrešku ima zbog blizine visoke vegetacije odnosno utjecaja sjena na označenu točku (Tablica 7). Na slici Slika 48., X i Y pogreške predstavljene su uz pomoć geometrijskog oblika elipse, dok je Z pogreška predstavljena bojom elipse.

Tablica 7. Točnost po kontrolnim točkama

Label	X error (cm)	Y error (cm)	Z error (cm)	Total error (cm)	Image (pix.)
KT1	0,3533	0,6091	3,9495	4,0118	0,205 (235)
KT2	2,8075	1,2788	4,6782	5,6038	0,076 (271)
KT3	0,8426	-0,0541	1,1615	1,4359	0,107 (270)
KT4	1,2261	2,1397	-0,6058	2,5395	0,053 (272)
KT5	0,8057	1,1692	2,0062	2,4578	0,076 (259)
KT6	-1,4185	-0,7291	1,7128	2,3404	0,105 (219)
KT7	0,8891	0,5115	4,0267	4,1553	0,077 (263)
RMSE	1,3976	1,1179	2,9851	3,4804	0,108



Slika 48. X, Y i Z pogreške kontrolnih točaka

5.4. Digitalni ortofoto (DOF) vrlo visoke rezolucije

DOF je konačni rezultat druge misije aerofotogrametrijskog snimanja prilikom kojeg je korišten RGB senzor. Parametri koraka radnog tijeka obrade RGB fotografija, postavljeni su na *Ultra High*, a gusti oblak točaka ukupno se sastoji od 5 203 602 784 točaka. Nakon izrade DMR-a, generiran je DOF ukupne veličine 21,37 GB s prostornom rezolucijom 1,88 cm (Slika 49). Kao i MS snimak, nalazi se u službenom projekcijskom koordinatnom sustavu HTRS96/TM. Vrlo visoka prostorna rezolucija od iznimnog je značaja jer je kreirani DOF korišten kao referentni model u svrhu procjene točnosti korištenih klasifikacijskih algoritama i vegetacijskih indeksa.



Slika 49. DOF snimak vrlo visoke rezolucije

Prilikom istraživanja koje za cilj ima usporediti različite pristupe kartiranja krošanja vegetacije, Šiljeg i dr., 2022. također koriste DOF prostorne rezolucije 5 cm, što pokazuje opravdanost korištenja generiranog DOF-a.

5.5. Rezultati GEOBIA pristupa kartiranja krošanja maslina

5.5.1. Optimalan raspored spektralnih kanala

Vizualnom analizom pomoću alata *Symbology* kao optimalna je odabrana kombinacija 10-9-8 (*NIR*, *RedEdge 740*, *RedEdge*) zbog mogućnosti vrlo dobrog razlikovanja krošanja maslina u odnosu na drugu vegetaciju (Slika 50).



Slika 50. MS model s rasporedom kanala 10-9-8

Vrlo sličan raspored kanala koristili su Panda i dr., 2020. u istraživanju kartiranja šuma primorskih četinjača.

5.5.2. Segmentirani MS model

Proučavanjem dostupne literature sličnih istraživanja i vizualnom interpretacijom generiranih modela, odabran je model s vrijednostima spektralne detaljnosti 18, prostorne detaljnosti 11 i minimalne veličine segmenta 15 (Slika 51). Navedene vrijednosti slične su vrijednostima korištenim u istraživanjima unutar kojih je primijenjen GEOBIA pristup kartiranja vegetacije (Solano i dr., 2019; Panda i dr., 2020; Šiljeg i dr., 2022).



Slika 51. Segmentirani MS model

5.5.3. Prikupljeni testni uzorci

Ukupno je označeno 2 946 uzoraka prikupljenih unutar 14 klasa (Slika 52). Osim četiriju klasa koje se odnose na krošnje maslina, testni uzorci pridodani su i za klasu sjena, klase antropogenih objekata poput krovova kuća, makadamskih i asfaltiranih površina, klase površinskog krškog područja i tla s kršem i klase koje se odnose na krošnje drugih vegetacijskih vrsta.


ID	Class Name	Value	Color	Count
1	Masline 1	1		234172
2	Masline 2	342		367414
3	Masline 3	1331		161601
4	Masline 4	1761		119076
5	Sjene	2204		349095
6	Krovovi	2219		269789
7	Asfalt	2240		318862
8	Makadam	2241		552466
9	Krš1	2256		150400
10	Krš2	2275		146600
11	Tlo s kršem	2363		1256126
12	Tlo	2392		991405
13	Druga veg1	2402		117443
14	Druga veg2	2692		133551

Slika 52. Klase testnih uzoraka u *Training Sample Manager*-u

5.5.4. Izvedene klasifikacije MS modela


Rezultati korištenih klasifikacijskih algoritama razlikuju se u prostornoj distribuciji i udjelima 14 klasa generiranih na temelju prikupljenih testnih uzoraka.

Klasifikacijski algoritam SVM, vrlo dobro izdvaja klasu krošanja maslina prikazanu na slici Slika 53. tamno zelenom bojom. Većina maslina unutar istraživanog područja vrlo je dobro prepoznata u odnosu na okolinu. Međutim, postoje i određeni nedostaci koji se pojavljuju kod klase druge vegetacije (klasa svijetlo zelene boje), gdje su u određenim dijelovima, površine koje spadaju u klasu druge vegetacije, neispravno klasificirane kao masline. Također, obujam krošnji maslina u određenim dijelovima smanjen je zbog velikog utjecaja sjena (klasa crne boje), poglavito pri osojnoj strani krošnje.




Slika 53. Klasificirani model - SVM

Rezultati klasifikacije pomoću ML algoritma su vrlo slični prethodnom algoritmu. Ipak, na temelju vizualne interpretacije, ML znatno bolje klasificira i razlikuje klasu sjena od klase krošanja maslina. S druge strane, algoritam lošije prepoznaje razlike između klase masline i druge vegetacije, odnosno češće klasificira masline pod klasu druge vegetacije (Slika 54).



Slika 54. Klasificirani model - ML

Klasa krošnja maslina vrlo je dobro kartirana i pokazuje najmanje nedostataka u odnosu na rezultate prethodno navedenih klasifikacijskih algoritama. RT lošije razlikuje prostorni raspored klasa unutar područja istraživanja. Naime, sjene su vrlo slabo prepoznate, dok su površine prekrivene kršem (siva klasa) vrlo često svrstane pod klasu tlo (narančasta klasa). Budući da su objekt istraživanja krošnje maslina, RT u konačnici pokazuje vrlo dobre rezultate (Slika 55).




Slika 55. Klasificirani model - RT

5.5.5. Reklasificirani MS modeli

Reklasifikacijom su krošnje maslina kao objekt istraživanja, izdvojene u odnosu na preostale klase. Reklasifikacija je izvedena za sva tri klasifikacijska algoritma, a potom su reklasificirani rasterski modeli pretvoreni u poligonske vektorske slojeve, potrebne za

vizualizaciju izdvojenih krošanja maslina i provedbu mjera procjene točnosti. Površina klase krošanja maslina za klasifikacijski algoritam SVM iznosi 63 100 m², za ML 63 152 m² i za RT 65 743 m². Razlike između izdvojenih klasa maslina nisu značajne, ali ipak postoje. Testni uzorci i struktura rada klasifikacijskih algoritama uvjetovali su razlike u oblicima i veličini klase maslina (Slika 56).



Slika 56. Reklasificirani modeli: a) SVM, b) ML, c) RT

5.5.6. Točnost klasifikacijskih algoritama

Prema korištenim mjerama za procjenu točnosti čije se vrijednosti neznatno razlikuju između tri korištena algoritma, može se zaključiti kako korišteni klasifikacijski algoritmi pouzdano kartiraju krošnje maslina, ali s druge strane, nedostatke pokazuju u razlikovanju druge prisutne vegetacije u odnosu na masline. Sve mjere izračunate su pomoću točaka s pridodanim atributima, kreiranim unutar referentnih i lažnih maslina.

Kao najpouzdaniji klasifikacijski algoritam pokazao se RT (Slika 57). Vrijednosti RT (Tablica 8) pokazuju najbolje rezultate u tri od četiriju korištenih mjera. Najbolji rezultati postignuti su kod UA (0,8113 i 0,7378), OA (0,7565) i Kappa koeficijenta (KC = 0,4615).

Tablica 8. Mjere točnosti - RT

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC
Ostalo	399250	92865	492115	0,8113		
Masline	376937	1060495	1437432	0,7378		
Ukupno	776187	1153360	1929547			
PA	0,5144	0,9195				
OA					0,7565	
KC						0,4615

Klasifikacijski algoritam ML u svim korištenim mjerama pokazuje nešto lošije rezultate u odnosu na RT (Tablica 9). Najlošije rezultate ML pokazuje u mjerama PA (0,5071), UA (0,7306) i KC (0,4311), dok prema mjeri OA (0,7418), ML je ipak pouzdaniji od klasifikacijskog algoritma SVM.

Tablica 9. Mjere točnosti - ML

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC
Ostalo	393605	115654	509259	0,7729		
Masline	382582	1037706	1420288	0,7306		
Ukupno	776187	1153360	1929547			
PA	0,5071	0,8997				
OA					0,7418	
KC						0,4311

SVM klasifikacijski algoritam najlošije rezultate pokazuje prema mjeri OA (0,7403), dok su najbolje vrijednosti vezane uz mjeru PA (0,5302). Rezultati mjera procjene točnosti UA (0,7511 i 0,7361) i KC (0,4328) nalaze se u sredini između rezultata dvaju prije spomenutih algoritama (Tablica 10).

Tablica 10. *Mjere točnosti - SVM*

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC
Ostalo	411533	136373	547906	0,7511		
Masline	364654	1016987	1381641	0,7361		
Ukupno	776187	1153360	1929547			
PA	0,5302	0,8818				
OA					0,7403	
KC						0,4328

Niske vrijednosti korištenih mjera za procjenu točnosti, rezultat su vektorizacije poligona lažnih uzoraka samo u klasi druga vegetacija, jer se u toj klasi nalazi najviše neispravno klasificiranih maslina.

Panda i dr. u radu iz 2020. godine, uspoređuju GEOBIA klasifikacijske algoritme u izdvajanju šuma primorskih četinjača i prema metričkim pokazateljima (*COR, COM, OQ* i *Kappa*) zaključuju kako je RT najpouzdaniji klasifikacijski algoritam. Rodriguez-Galiano i dr., 2012, Ma i dr., 2017. i Gašparović i Dobrinić 2020. također istražuju i preporučuju korištenje RT klasifikacijskog algoritma u svrhu izdvajanja različitih vegetacijskih vrsta, što potvrđuje odabir navedenog algoritma kao najboljeg unutar GEOBIA pristupa.

5.5.7. Odabrani model GEOBIA pristupa

Kao reprezentativan model GEOBIA pristupa u kartiranju krošanja maslina odabran je model klasifikacijskog algoritma RT, koji se prema korištenim mjerama pokazao kao najtočniji. Površina klase maslina odabranog modela iznosi 65 743 m². Krošnje maslina na modelu označene su tamno zelenom bojom (Slika 57).

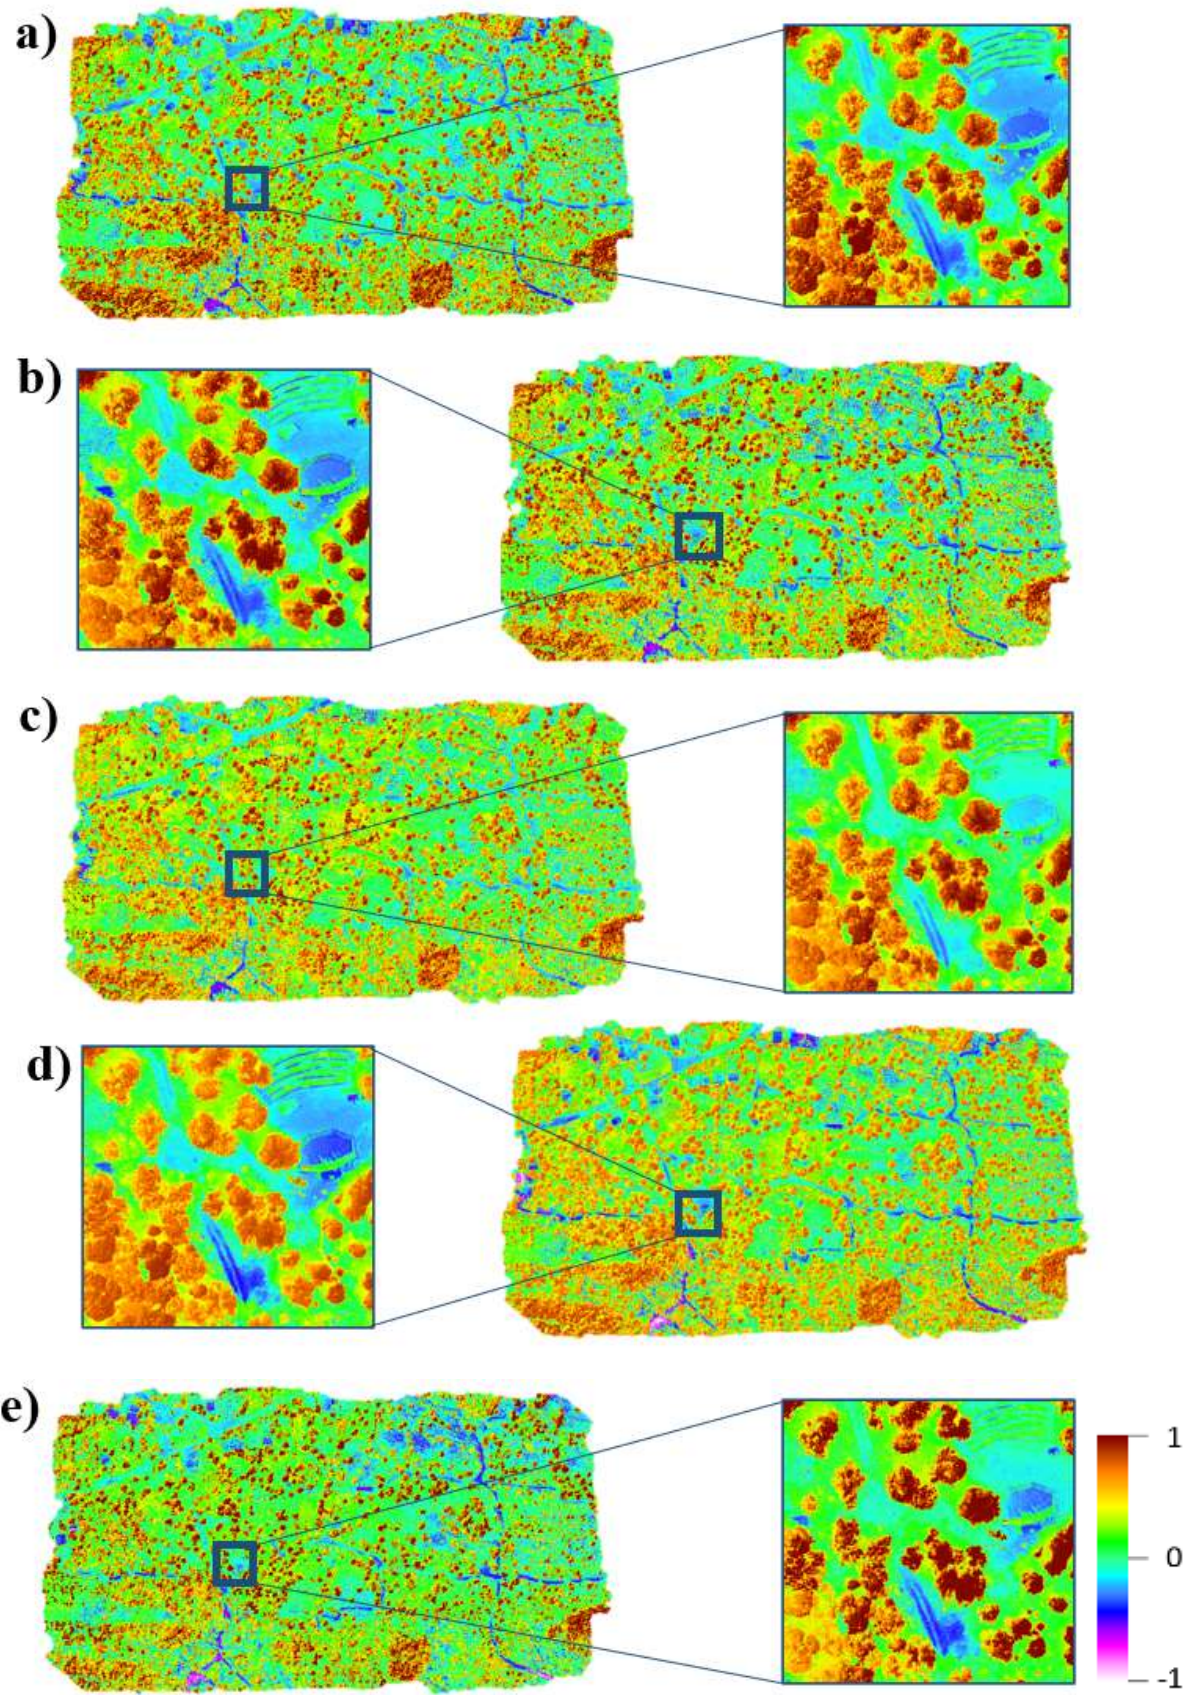


Slika 57. Odabrani model - GEOBIA pristup

5.6. Rezultati kartiranja krošanja maslina korištenjem vegetacijskih indeksa

5.6.1. Izvedeni modeli vegetacijskih indeksa


Prvi i najkorišteniji NDVI indeks (Slika 58a), kvalitetno izdvaja površine pod vegetacijom, no nedostatke pokazuje kod razlikovanja vrsta krošanja. Model NDRE vegetacijskog indeksa (Slika 58b) s velikom pouzdanošću izdvaja vegetaciju i prikazuje krošnje maslina. GNDVI indeks (Slika 58c) odabran je zbog sposobnosti razlikovanja vrsta vegetacije unutar područja istraživanja, dok MCARI2 indeks (Slika 58d) vjerodostojno izdvaja vegetacijske površine. Posljednji izvedeni model RDVI2 indeksa (Slika 58e) odabran je zbog sposobnosti prepoznavanja krošanja maslina u odnosu na drugu vegetaciju.




Slika 58. Modeli vegetacijskih indeksa: a) *NDVI*, b) *NDRE*, c) *GNDVI*, d) *MCARI2*, e) *RDVI2*

5.6.2. Izlazni rezultati alata VITO

Korištenjem alata VITO izdvojene su krošnje maslina pet odabranih vegetacijskih indeksa. Modeli su klasificirani u klasu krošanja maslina i klasu ostalo (Slika 59). Razlike u veličini i prostornom rasporedu površina klase krošanja maslina variraju između vegetacijskih indeksa, što je očekivano s obzirom na različite formule i spektralne kanale korištene prilikom generiranja indeksa.






Slika 59. Klasificirane krošnje maslina a) *NDVI*, b) *NDRE*, c) *GNDVI*, d) *MCARI2*, e) *RDVI2*

5.6.3. Točnost modela vegetacijskih indeksa

Prema korištenoj mjeri za provjeru točnosti, najbolje rezultate pokazuje vegetacijski indeks *NDRE*, dok svi ostali modeli pokazuju osjetno lošije rezultate. Vrijednost *AUC*-a za *NDRE* indeks iznosi 0,888, za *RDVI2* vrijednost je 0,766, *GNDVI* pokazuje točnost od 0,7, *MCARI2* 0,623, dok je točnost *NDVI* indeksa 0,619 (Slika 60).



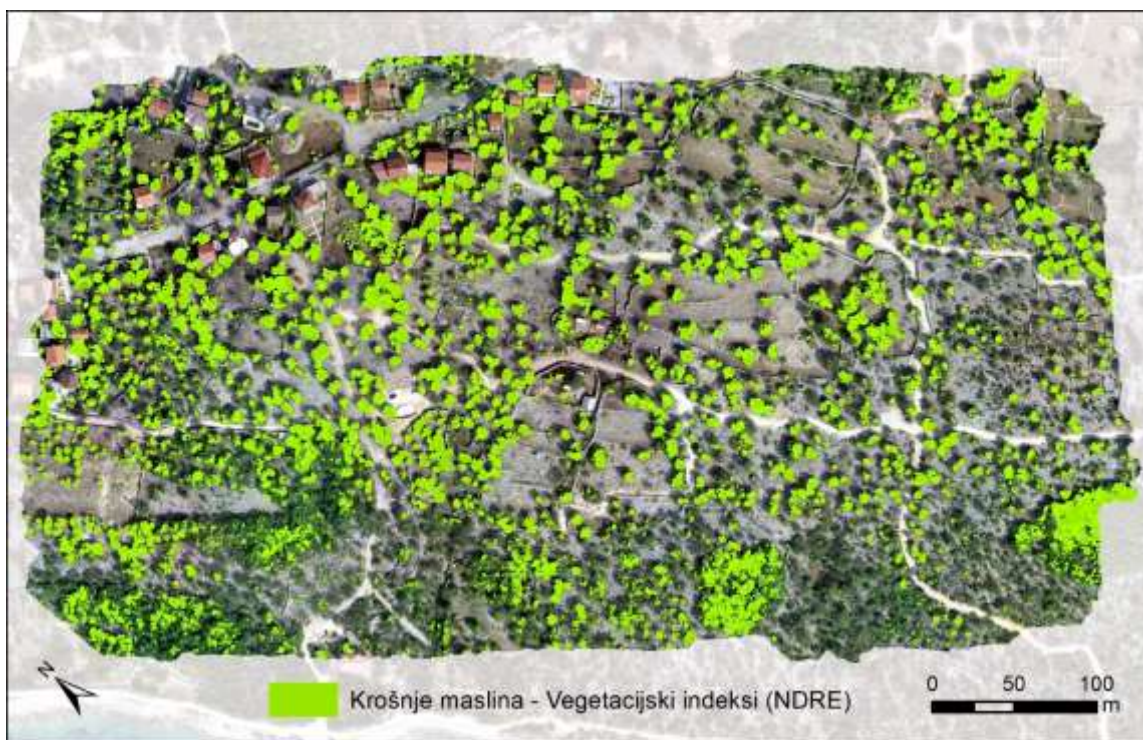
Slika 60. ROC krivulje i vrijednosti *AUC*-a za modele odabranih vegetacijskih indeksa

Modeli izvedeni uz pomoć *NDRE* vegetacijskog indeksa često su u različitim istraživanjima povezani s kartiranjem određenog tipa vegetacije, te su pomoću mjera za procjenu točnosti odabrani kao najbolji modeli (Zhou i dr., 2017; Avola i dr., 2019, Jorge i dr.,

2019; Solano i dr., 2019; Morlin-Carneiro i dr., 2020), što potvrđuje dobivene rezultate i odabir modela NDRE vegetacijskog indeksa.

5.6.4. Odabrani model pristupa temeljenog na vegetacijskim indeksima


Reprezentativan model pristupa temeljenog na vegetacijskim indeksima je model vegetacijskog indeksa NDRE (Slika 61), koji je prema korištenoj mjeri za provjeru točnosti pokazao najbolji rezultat. Površina klase maslina prikazane svijetlo zelenom bojom iznosi 21 986 m².



Slika 61. Odabrani model - pristup temeljen na vegetacijskim indeksima

5.7. Rezultati usporedbe dvaju pristupa

Pristup temeljen na vegetacijskim indeksima bolje kartira krošnje maslina na istraživanom području u odnosu na GEOBIA pristup prema pet mjera provjere točnosti. Metodom ispitivanja točnosti s korištenim pravilnim rasporedom točaka unutar referentnih i lažnih poligona, vegetacijski indeksi pokazuju bolje rezultate u četiri od pet korištenih mjera. Prema mjerama AUC-a (Slika 62), PA, UA i KC-a točniji je pristup temeljen na vegetacijskim indeksima, dok je GEOBIA pristup, neznatno bolje rezultate pokazao samo u mjeri OA (Tablica 11 i Tablica 12).



Slika 62. ROC krivulje i vrijednosti AUC-a za korištene pristupe


Tablica 11. Konfuzijska matrica i rezultati mjera točnosti - Vegetacijski indeks NDRE

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC	AUC
Ostalo	729148	431689	1160837	0,6281			0,888
Masline	47039	721671	768710	0,9388			
Ukupno	776187	1153360	1929547				
PA	0,9394	0,6257					
OA					0,7519		
KC						0,5228	
AUC							

Tablica 12. Konfuzijska matrica i rezultati mjera točnosti - GEOBIA RT

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC	AUC
Ostalo	399250	92865	492115	0,8113			0,880
Masline	376937	1060495	1437432	0,7378			
Ukupno	776187	1153360	1929547				
PA	0,5144	0,9195					
OA					0,7565		
KC						0,4615	
AUC							

Druga metoda provjere točnosti temeljena na sloju tisuću nasumično raspoređenih točaka potvrđuje rezultate dobivene prvom metodom. Rezultati svih pet korištenih mjera točnosti ukazuju na odabir pristupa temeljenog na vegetacijskim indeksima kao točnijeg u kartiranju krošanja maslina od GEOBIA pristupa (Slika 63) (Tablica 13 Tablica 14).



Slika 63. ROC krivulje i vrijednosti AUC-a za korištene pristupe - druga metoda provjere

Tablica 13. Konfuzijska matrica i rezultati mjera točnosti za vegetacijski indeks NDRE - druga metoda provjere


Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC	AUC
Ostalo	833	73	906	0,9194			0,870
Masline	9	85	94	0,9043			
Ukupno	842	158	1000				
PA	0,9893	0,5380					
OA					0,9180		
KC						0,6311	
AUC							

Tablica 14. Konfuzijska matrica i rezultati mjera točnosti za GEOBIA (RT) - druga metoda provjere

Klasa/Mjera	Ostalo	Masline	Ukupno	UA	OA	KC	AUC
Ostalo	685	26	711	0,9634			0,841
Masline	157	132	289	0,4567			
Ukupno	842	158	1000				
PA	0,8135	0,8354					
OA					0,8170		
KC						0,4855	
AUC							

5.8. Varijabilnosti vegetacijskih indeksa unutar krošanja maslina

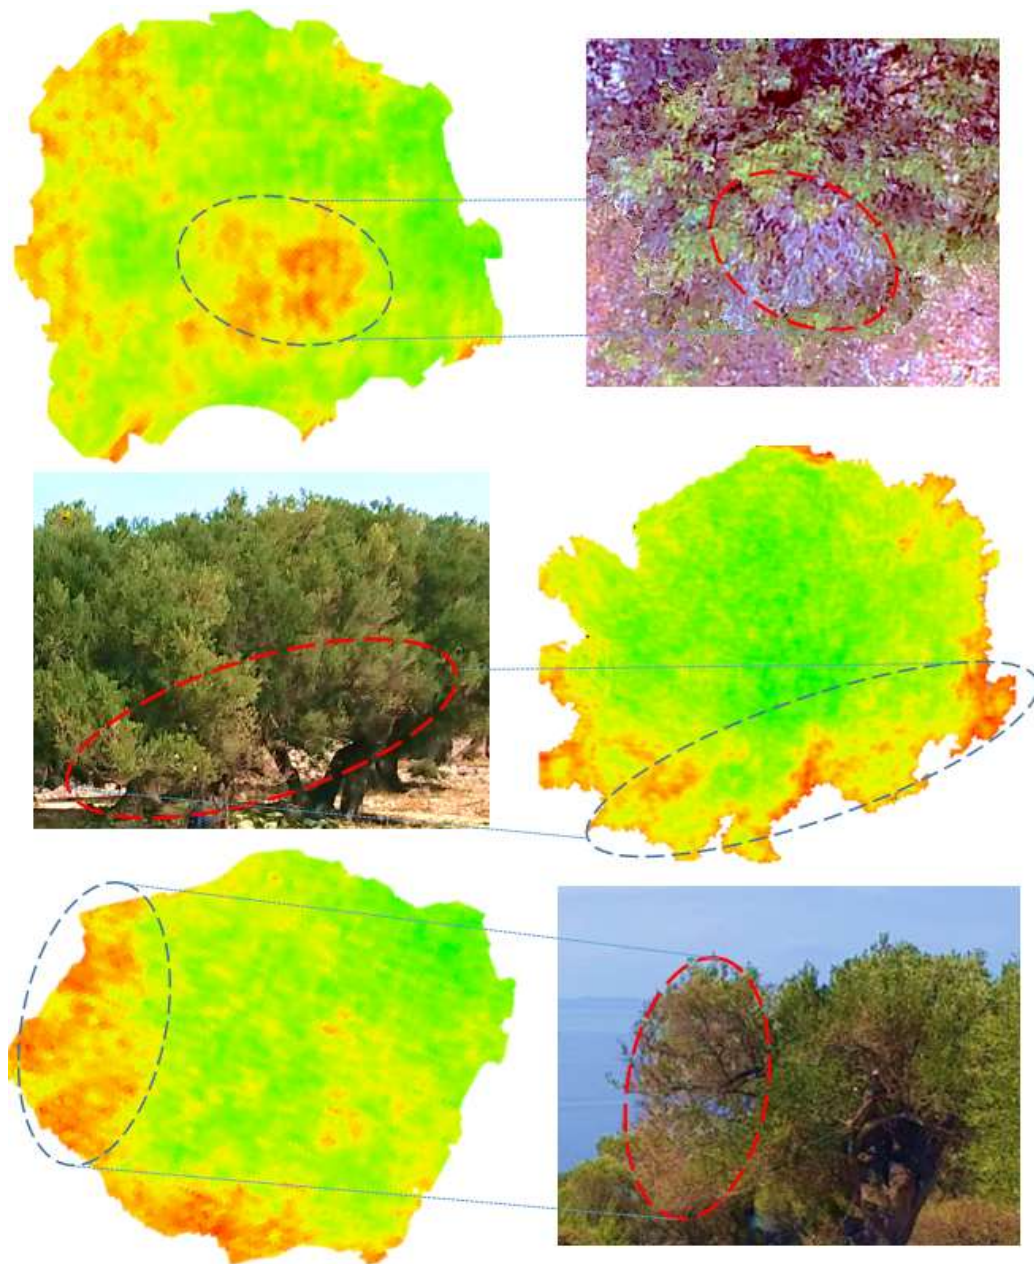
Varijabilnosti vegetacijskih indeksa prikazane su unutar izdvojenih krošanja maslina GEOBIA pristupom (Slika 64).



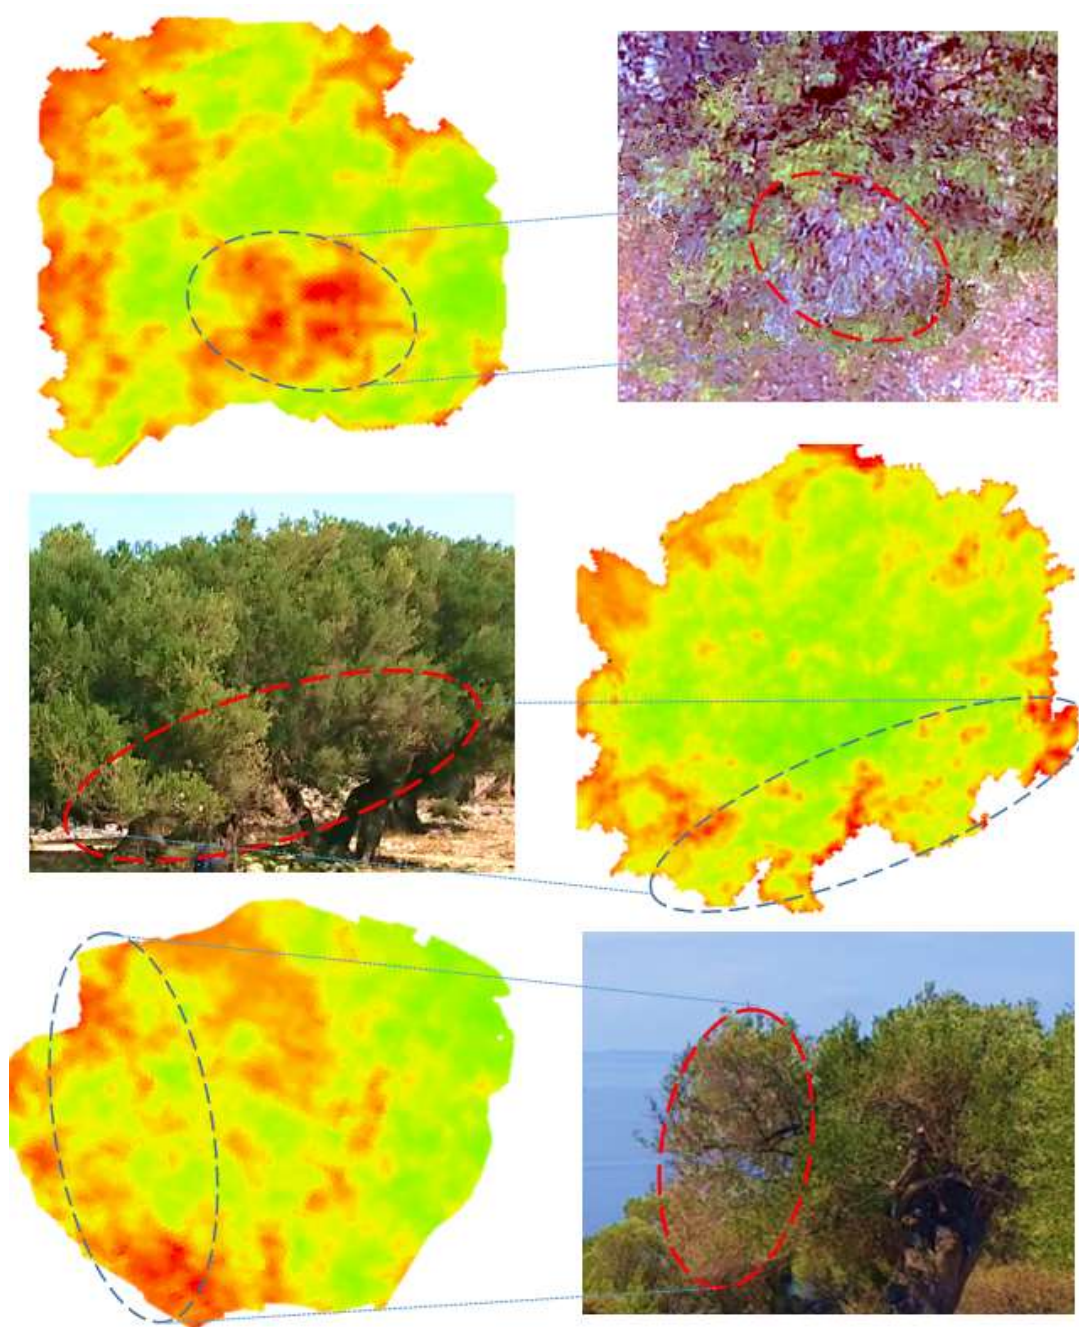
Slika 64. Varijabilnosti unutar krošanja maslina vegetacijskih indeksa: a) NDRE, b) NDVI

Vrijednosti NDRE indeksa raspoređene su od 0 do 0,64, dok se vrijednosti NDVI indeksa nalaze na ljestvici od 0 do 0,98. Veće vrijednosti odnose se na masline u boljem zdravstvenom stanju, dok su niže vrijednosti povezane s maslinama ili dijelovima krošnje koji su osušeni.

Varijabilnosti vegetacijskih indeksa uočene na izvedenim modelima unutar krošanja maslina, potvrđene su egzaktnim dokazima s visoko rezolucijskog DOF-a ili fotografijama s područja istraživanja (Slika 65 Slika 66).



Slika 65. Varijabilnost NDRE indeksa unutar izdvojenih krošanja maslina



Slika 66. Varijabilnosti NDVI indeksa unutar izdvojenih krošanja maslina

Prikazane varijabilnosti vegetacijskih indeksa unutar krošnji maslina poklapaju se s priloženim dokazima, što pokazuje opravdanost korištenja vegetacijskih indeksa u svrhu pronalaska osušenih dijelova masline.

6. Zaključak

Provedenim istraživanjem na području vrtova Lunjskih maslinika prikazana je primjenjivost korištene metodologije u svrhu kartiranja i zaštite maslina. Različite geoprostorne tehnologije, metodološki pristupi, korištene tehnike i alati su na svoj način doprinijeli rješavanju postavljenih istraživačkih ciljeva i uspješnosti provedenog istraživanja. Po prvi put su u Republici Hrvatskoj misije aerofotogrametrijskog snimanja planirane u softveru *QBase 3D* i po prvi put su modeli temeljeni na vegetacijskim indeksima korišteni u svrhu kartiranja i uočavanja varijabilnosti krošanja maslina.

Pomoću bespilotne letjelice *Trinity F90+* i multispektralnog senzora *MicaSense RedEdge-MX Dual* izvršeno je aerofotogrametrijsko snimanje i prikupljeni su podaci, potrebni za proces obrade koji je rezultirao generacijom multispektralnog modela vrlo visoke rezolucije s pozicijskom točnošću od 3,48 cm. Točnost je izračunata metodom srednje kvadratne pogreške (*RMSE*), čime je potvrđena pretpostavka o centimetarskoj točnosti opcije PPK pozicioniranja sustava bespilotne letjelice na visini leta od 100 m. Dobiveni rezultati pokazuju mogućnost korištenja sustava pozicioniranja bespilotne letjelice za georeferenciranje modela, bez nužne potrebe za korištenjem dodatnih geoprostornih tehnologija poput GNSS uređaja, čime se smanjuje potrebna vremenska i financijska rezolucija budućih istraživanja.

Odabir optimalnog rasporeda spektralnih kanala, detaljna analiza korisničko-definiranih parametara segmentacije, dodavanje testnih uzoraka, izvođenje klasifikacija i reklasifikacija sastavni su koraci provedenog GEOBIA procesa koji je rezultirao usporedbom korištenih klasifikacijskih algoritama (*SVM, ML i RT*) pomoću četiri mjere za procjenu točnosti (*PA, UA, OA i KC*) i odabirom *RT* algoritma, kao najtočnijeg u procesu kartiranja krošanja maslina s vrijednošću ukupne točnosti 0,75. Iako je pretpostavljeno da će *SVM* algoritam pokazati najbolje rezultate, prema korištenim mjerama spomenuti algoritam se nalazi iza *RT* algoritma, odnosno na drugom mjestu. Dobiveni rezultati ukazuju na opravdanost korištenja *RT* klasifikacijskog algoritma u sličnim budućim istraživanjima.

Potvrđena je pretpostavka o točnosti modela krošnji maslina izdvojenih pomoću *NDRE* vegetacijskog indeksa u vrijednosti *AUC*-a od 0,85. Izvedeni su modeli pet vegetacijskih indeksa (*NDVI, NDRE, GNDVI, MCARI2, RDVI2*) koji su izabrani na temelju vizualne analize. Vrijednosti vegetacijskih indeksa optimizirane su korištenjem alata *VITO*, s ciljem izdvajanja krošanja maslina. Modeli izdvojenih maslina uspoređeni su pomoću *ROC* krivulja i vrijednosti

AUC-a na temelju kojih je kao najtočniji odabran model indeksa NDRE s vrijednošću AUC-a od 0,88.

Usporedba pristupa temeljenog na vegetacijskim indeksima i GEOBIA pristupa izvedena je uz pomoć dvije metode i pet mjera za procjenu točnosti. U prvoj metodi mjere točnosti izračunate su uz pomoć referentnih i lažnih poligona maslina unutar kojih je generiran sloj pravilno raspoređenih točaka. Druga metoda vezana je uz tisuću nasumično raspoređenih točaka unutar područja istraživanja. Rezultatima dviju metoda s pet mjera točnosti, potvrđena je pretpostavka o većoj točnosti modela vegetacijskih indeksa u odnosu na modele GEOBIA pristupa. Istraživanje pruža značajan doprinos unutar znanstvene zajednice jer dokazuje mogućnost korištenja vegetacijskih indeksa kao mnogo bržeg pristupa u kartiranju krošanja maslina od GEOBIA pristupa. Naravno, preporuka za buduća istraživanja je korištenje oba navedena pristupa.

Varijabilnosti vegetacijskih indeksa unutar krošnji maslina omogućile su detekciju suhih i nezdravih dijelova krošnji, što je u skladu s postavljenom pretpostavkom. Uočene varijabilnosti dokazane su egzaktnim primjerima s terena. Time se ukazuje na mogućnost korištenja vegetacijskih indeksa u svrhu dijagnoze stanja, ranog otkrivanja i prevencije krošanja maslina od raznih štetnih nametnika.

Budućim korištenjem detaljno opisane metodologije omogućit će se sustavno praćenje, nadzor i uočavanje prostorno-vremenskih promjena krošanja maslina u svrhu očuvanja i zaštite ovog vrijednog prirodnog i kulturnog dobra.

Literatura

1. Aasen, H., Honkavaara, E., Lucieer, A., Zarco-Tejada, P. J. (2018): Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. *Remote Sensing*, 10(7), 1091.
2. Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., Sousa, J. J. (2017): Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote sensing*, 9(11), 1110.
3. Alganci, U., Sertel, E., Kaya, S. (2018): Determination of the olive trees with object based classification of Pleiades satellite image. *International Journal of Environment and Geoinformatics*, 5(2), 132-139.
4. Avand, M., Moradi, H. R., Ramazanzadeh Lasbooye, M. (2021): Spatial prediction of future flood risk: an approach to the effects of climate change. *Geosciences*, 11(1), 25.
5. Avola, G., Di Gennaro, S. F., Cantini, C., Riggi, E., Muratore, F., Tornambè, C., & Matese, A. (2019): Remotely sensed vegetation indices to discriminate field-grown olive cultivars. *Remote Sensing*, 11(10), 1242.
6. Bagheri, N., Ahmadi, H., Alavipanah, S. K., Omid, M. (2013): Multispectral remote sensing for site-specific nitrogen fertilizer management. *Pesquisa Agropecuária Brasileira*, 48, 1394-1401.
7. Bakarić, P. (2005): Main olive varieties in the area of Dubrovnik-Neretva county with special reference to autochthonous varieties of the Pelješac peninsula. *Pomologia Croatica: Glasilo Hrvatskog agronomskog društva*, 11(1-2), 15-21.
8. Bannari, A., Morin, D., Bonn, F., Huete, A. (1995): A review of vegetation indices. *Remote sensing reviews*, 13(1-2), 95-120.
9. Baret, F., Guyot, G. (1991): Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote sensing of environment*, 35(2-3), 161-173
10. Barić, B., Pajač Živković, I., Žužić, I. (2014): Maslinov svrdlaš i opadanje plodova masline. *Glasilo biljne zaštite*, 14(4), 305-309.
11. Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., Moran, M. S. (2000): Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. *Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington*

12. Bell, G. E., Howell, B. M., Johnson, G. V., Raun, W. R., Solie, J. B., Stone, M. L. (2004): Optical sensing of turfgrass chlorophyll content and tissue nitrogen. *HortScience*, 39(5), 1130-1132.
13. Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., Bareth, G. (2014): Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote sensing*, 6(11), 10395-10412.
14. Besnard, G., Hernández, P., Khadari, B., Dorado, G., Savolainen, V. (2011): Genomic profiling of plastid DNA variation in the Mediterranean olive tree. *BMC plant biology*, 11(1), 1-12.
15. Bishop, M. P., James, L. A., Shroder Jr, J. F., Walsh, S. J. (2012): Geospatial technologies and digital geomorphological mapping: Concepts, issues and research. *Geomorphology*, 137(1), 5-26.
16. Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Tiede, D. (2014): Geographic object-based image analysis—towards a new paradigm. *ISPRS journal of photogrammetry and remote sensing*, 87, 180-191.
17. Bodzin, A. M., Cirucci, L. (2009): Integrating geospatial technologies to examine urban land use change: A design partnership. *Journal of Geography*, 108(4-5), 186-197.
18. Boiarskii, B., & Hasegawa, H. (2019): Comparison of NDVI and NDRE indices to detect differences in vegetation and chlorophyll content. *Journal of mechanics of continua and mathematical sciences*, 4, 20-29.
19. Bradley, A. P. (1997): The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern recognition*, 30(7), 1145-1159.
20. Breiman, L. (2001): Random forests. *Machine learning*, 45(1), 5-32.
21. Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., Gattelli, M. (2015): Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote sensing*, 7(4), 4026-4047.
22. Carbonneau, P. E., Lane, S. N., Bergeron, N. (2006): Feature based image processing methods applied to bathymetric measurements from airborne remote sensing in fluvial environments. *Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group*, 31(11), 1413-1423.
23. Chai, T., Draxler, R. R. (2014): Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.

24. Chen, G., Weng, Q., Hay, G. J., He, Y. (2018): Geographic object-based image analysis (GEOBIA): Emerging trends and future opportunities. *GIScience & Remote Sensing*, 55(2), 159-182.
25. Connor, D. J., Fereres, E. (2010): The physiology of adaptation and yield expression in olive. *Hortic. Rev*, 31, 155-229.
26. Cortes, C., Vapnik, V. (1995): Support-vector networks. *Machine learning*, 20(3), 273-297.
27. Costache, R., Pham, Q. B., Sharifi, E., Linh, N. T. T., Abba, S. I., Vojtek, M., Khoi, D. N. (2020): Flash-flood susceptibility assessment using multi-criteria decision making and machine learning supported by remote sensing and GIS techniques. *Remote Sensing*, 12(1), 106.
28. Čurović, Ž., Čurović, M., Spalević, V., Janic, M., Sestras, P., Popović, S. G. (2019): Identification and evaluation of landscape as a precondition for planning revitalization and development of mediterranean rural settlements—case study: Mrkovi Village, Bay of Kotor, Montenegro. *Sustainability*, 11(7), 2039.
29. Daughtry, C. S., Walthall, C. L., Kim, M. S., De Colstoun, E. B., McMurtrey Iii, J. E. (2000): Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote sensing of Environment*, 74(2), 229-239.
30. Delavarpour, N., Koparan, C., Nowatzki, J., Bajwa, S., Sun, X. (2021): A technical study on UAV characteristics for precision agriculture applications and associated practical challenges. *Remote Sensing*, 13(6), 1204.
31. Deur, M., Gašparović, M., Balenović, I. (2021): A Review of Satellite Missions and Forest Cover Classification Methods Using High Resolution Satellite Imagery. *Geodetski list*, 75(2), 143-168.
32. Díez, C. M., Trujillo, I., Barrio, E., Belaj, A., Barranco, D., Rallo, L. (2011): Centennial olive trees as a reservoir of genetic diversity. *Annals of Botany*, 108(5), 797-807.
33. Díez, Y., Kentsch, S., Fukuda, M., Cáceres, M. L. L., Moritake, K., Cabezas, M. (2021): Deep learning in forestry using uav-acquired rgb data: A practical review. *Remote Sensing*, 13(14), 2837.
34. Dinguirard, M., Slater, P. N. (1999): Calibration of space-multispectral imaging sensors: A review. *Remote Sensing of Environment*, 68(3), 194-205.

35. Di Nisio, A., Adamo, F., Acciani, G., Attivissimo, F. (2020): Fast Detection of Olive Trees Affected by *Xylella Fastidiosa* from UAVs Using Multispectral Imaging. *Sensors*, 20(17), 4915.
36. Domazetović, F., Šiljeg, A., Marić, I., Jurišić, M. (2020): Assessing the Vertical Accuracy of Worldview-3 Stereo-extracted Digital Surface Model over Olive Groves. *GISTAM* (pp. 246-253).
37. Eitel, J. U., Vierling, L. A., Litvak, M. E., Long, D. S., Stoscheck, L. (2011): Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. *Remote Sensing of Environment*, 115(12), 3640-3646.
38. Emilien, A. V., Thomas, C., Thomas, H. (2021): UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of Remote Sensing*, 100019.
39. Fraga, H., Moriondo, M., Leolini, L., Santos, J. A. (2021): Mediterranean olive orchards under climate change: A review of future impacts and adaptation strategies. *Agronomy*, 11(1), 56.
40. Francisco, C. N., Almeida, C. M. (2012): Data Mining Techniques and Geobia Applied to Land Cover Mapping. *Internacional Conference on Geographic Object-Based Image Analysis* (4), 89-94.
41. Gašparović, M., Dobrinić, D. (2020): Comparative assessment of machine learning methods for urban vegetation mapping using multitemporal sentinel-1 imagery. *Remote Sensing*, 12(12), 1952.
42. Gitelson, A. A., Kaufman, Y. J., Merzlyak, M. N. (1996): Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, 58(3), 289-298.
43. Gugić, J., Strikić, F., Perica, S., Čmelik, Z., Jukić, L. (2007): Proizvodnja sadnog materijala masline u Republici Hrvatskoj. *Pomologia Croatica: Glasilo Hrvatskog agronomskog društva*, 13(4), 229-250.
44. Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., Strachan, I. B. (2004): Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote sensing of environment*, 90(3), 337-352.
45. Hanley, J. A., McNeil, B. J. (1982): The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.

46. Hernández-Mogollón, J. M., Di-Clemente, E., Campón-Cerro, A. M., Folgado-Fernández, J. A. (2021): Olive Oil Tourism in the Euro-Mediterranean Area. *International Journal of Euro-Mediterranean Studies*, 14(1).
47. Heumann, B. W. (2011): An object-based classification of mangroves using a hybrid decision tree—Support vector machine approach. *Remote Sensing*, 3(11), 2440-2460.
48. Huang, S., Tang, L., Hupy, J. P., Wang, Y., Shao, G. (2021): A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32, 1-6.
49. Huete, A. R. (2012): Vegetation indices, remote sensing and forest monitoring. *Geography Compass*, 6(9), 513-532.
50. Howland, M. D., Tamberino, A., Liritzis, I., Levy, T. E. (2022): Digital Deforestation: Comparing Automated Approaches to the Production of Digital Terrain Models (DTMs) in Agisoft Metashape. *Quaternary*, 5(1), 5.
51. Iqbal, F., Lucieer, A., Barry, K. (2018): Simplified radiometric calibration for UAS-mounted multispectral sensor. *European Journal of Remote Sensing*, 51(1), 301-313.
52. Jackson, M., Schell, D., Taylor, D. F. (2009): The evolution of geospatial technology calls for changes in geospatial research, education and government management. *Directions Magazine*, 13.
53. Jackson, R. D., Huete, A. R. (1991): Interpreting vegetation indices. *Preventive veterinary medicine*, 11(3-4), 185-200.
54. Jenkins, D., Vasigh, B. (2013): The economic impact of unmanned aircraft systems integration in the United States. *Association for Unmanned Vehicle Systems International (AUVSI)*.
55. Jorge, J., Vallbé, M., Soler, J. A. (2019): Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. *European Journal of Remote Sensing*, 52(1), 169-177.
56. Jurišić, M., Radočaj, D., Šiljeg, A., Antonić, O., Živić, T. (2021): Current status and perspective of remote sensing application in crop management. *Journal of Central European Agriculture*, 22(1), 156-166.
57. Kim, M. S., Daughtry, C. S. T., Chappelle, E. W., McMurtrey, J. E., Walthall, C. L. (1994): The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (A par). *CNES, proceedings of 6th international symposium on physical measurements and signatures in remote sensing*.

58. Kostelenos, G., Kiritsakis, A., Shahidi, F. (2017): *Olive tree history and evolution*. Wiley: Oxford, Ujedinjeno Kraljevstvo
59. Krzanowski, W. J., Hand, D. J. (2009): *ROC curves for continuous data*. Chapman and Hall/CRC.
60. Kucharczyk, M., Hay, G. J., Ghaffarian, S., Hugenholtz, C. H. (2020): Geographic object-based image analysis: a primer and future directions. *Remote Sensing*, 12(12), 2012.
61. Liu, C., Frazier, P., Kumar, L. (2007): Comparative assessment of the measures of thematic classification accuracy. *Remote sensing of environment*, 107(4), 606-616.
62. Lodeta, K. B., Budimir, M., Grubišić, D., Vujić, L., Gadže, J., Mihovilović, A. B., Kereša, S. (2018): Pollen germination in vitro of Lun olives. 53. *hrvatski i 13. međunarodni simpozij agronoma, 18. do 23. veljače 2018., Vodice Hrvatska. Zbornik radova*, 481-485.
63. Loumou, A., Giourga, C. (2003): Olive groves: "The life and identity of the Mediterranean". *Agriculture and human values*, 20(1), 87-95.
64. Ma, L., Li, M., Ma, X., Cheng, L., Du, P., Liu, Y. (2017): A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277-293.
65. Marques, P., Pádua, L., Adão, T., Hruška, J., Peres, E., Sousa, A., Sousa, J. J. (2019): UAV-based automatic detection and monitoring of chestnut trees. *Remote Sensing*, 11(7), 855.
66. Martinelli, F., Scalenghe, R., Davino, S., Panno, S., Scuderi, G., Ruisi, P., Dandekar, A. M. (2015): Advanced methods of plant disease detection. A review. *Agronomy for Sustainable Development*, 35(1), 1-25.
67. Marx, A., Kleinschmit, B. (2017): Sensitivity analysis of RapidEye spectral bands and derived vegetation indices for insect defoliation detection in pure Scots pine stands. *iForest-Biogeosciences and Forestry*, 10(4), 659.
68. Matsushita, B., Yang, W., Chen, J., Onda, Y., Qiu, G. (2007): Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. *Sensors*, 7(11), 2636-2651.
69. McGilvray, S., Tayebi, A. (2006): Attitude stabilization of a VTOL quadrotor aircraft. *IEEE Transactions on control systems technology*, 14(3), 562-571.

70. McRoberts, R. E., Naesset, E., Gobakken, T. (2013): Accuracy and precision for remote sensing applications of nonlinear model-based inference. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(1), 27-34.
71. Melville, B., Fisher, A., Lucieer, A. (2019). Ultra-high spatial resolution fractional vegetation cover from unmanned aerial multispectral imagery. *International Journal of Applied Earth Observation and Geoinformation*, 78, 14-24.
72. Messina, G., Fiozzo, V., Praticò, S., Siciliani, B., Curcio, A., Di Fazio, S., Modica, G. (2020): Monitoring Onion Crops Using Multispectral Imagery from Unmanned Aerial Vehicle (UAV). *International symposium: New Metropolitan Perspectives* (pp. 1640-1649). Springer, Cham.
73. Mian, O., Lutes, J., Lipa, G., Hutton, J. J., Gavelle, E., & Borghini, S. (2015). Direct georeferencing on small unmanned aerial platforms for improved reliability and accuracy of mapping without the need for ground control points. *The international archives of photogrammetry, remote sensing and spatial information sciences*, 40(1), 397.
74. Mioltic, I. (2013): Ownership of Olive Trees in Lun (Island Pag) and the Principle Superficies Solo Credit. *Zbornik PFZ*, 63, 1319.
75. Modica, G., Messina, G., De Luca, G., Fiozzo, V., Praticò, S. (2020): Monitoring the vegetation vigor in heterogeneous citrus and olive orchards. A multiscale object-based approach to extract trees' crowns from UAV multispectral imagery. *Computers and Electronics in Agriculture*, 175, 105500.
76. Morlin Carneiro, F., Angeli Furlani, C. E., Zerbato, C., Candida de Menezes, P., da Silva Gírio, L. A., Freire de Oliveira, M. (2020): Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agriculture*, 21(5), 979-1007.
77. Naqvi, S. M. Z. A., Awais, M., Khan, F. S., Afzal, U., Naz, N., Khan, M. I. (2021): Unmanned air vehicle based high resolution imagery for chlorophyll estimation using spectrally modified vegetation indices in vertical hierarchy of citrus grove. *Remote Sensing Applications: Society and Environment*, 23, 100596.
78. Nolè, G., Pilogallo, A., Lanorte, A., De Santic, F. (2018): Remote sensing techniques in olive-growing: a review. *Current Investigations in Agriculture and Current Research*, 2(3), 205-208.

79. Oniga, V. E., Breaban, A. I., Stasescu, F. (2018): Determining the optimum number of ground control points for obtaining high precision results based on UAS images. In *multidisciplinary digital publishing institute proceedings* 2(7), 352.
80. Onishi, M., Ise, T. (2021): Explainable identification and mapping of trees using UAV RGB image and deep learning. *Scientific reports*, 11(1), 1-15.
81. Oštir, K., & Mulahusić, A. (2014). *Daljinska istraživanja*. Založba ZRC, Građevinski Fakultet Univerziteta u Sarajevu.
82. Otukey, J. R., Blaschke, T. (2010): Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12, S27-S31.
83. Ozdemir, U., Aktas, Y. O., Vuruskan, A., Dereli, Y., Tarhan, A. F., Demirbag, K., Inalhan, G. (2014): Design of a commercial hybrid VTOL UAV system. *Journal of Intelligent & Robotic Systems*, 74(1), 371-393.
84. Pádua, L., Vanko, J., Hruška, J., Adão, T., Sousa, J. J., Peres, E., Morais, R. (2017): UAS, sensors, and data processing in agroforestry: A review towards practical applications. *International journal of remote sensing*, 38(8-10), 2349-2391.
85. Panda, L., Šiljeg, A., Marić, I., Domazetović, F., Šiljeg, S., Milošević, R. (2021): Usporedba GEOBIA klasifikacijskih algoritama na temelju Worldview-3 snimaka u izdvajanju šuma primorskih četinjača. *Šumarski list*, 145(11-12), 535-544.
86. Padró, J. C., Muñoz, F. J., Planas, J., Pons, X. (2019): Comparison of four UAV georeferencing methods for environmental monitoring purposes focusing on the combined use with airborne and satellite remote sensing platforms. *International journal of applied earth observation and geoinformation*, 75, 130-140.
87. Parra, L., Mostaza-Colado, D., Yousfi, S., Marin, J. F., Mauri, P. V., Lloret, J. (2021): Drone RGB Images as a Reliable Information Source to Determine Legumes Establishment Success. *Drones*, 5(3), 79.
88. Patón, D. (2020): Normalized Difference Vegetation Index Determination in Urban Areas by Full-Spectrum Photography. *Ecologies*, 1(1), 22-35.
89. Pelicarić, V., Bjeliš, M., Radunić, D. (2005): Integrirana zaštita masline. *Pomologia Croatica*, 11, 43-46.
90. Perry Jr, C. R., Lautenschlager, L. F. (1984): Functional equivalence of spectral vegetation indices. *Remote sensing of environment*, 14(1-3), 169-182.

91. Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., Stenseth, N. C. (2005): Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in ecology & evolution*, 20(9), 503-510.
92. Potts, S. G., Petanidou, T., Roberts, S., O'Toole, C., Hulbert, A., Willmer, P. (2006): Plant-pollinator biodiversity and pollination services in a complex Mediterranean landscape. *Biological conservation*, 129(4), 519-529.
93. Prada, M., Cabo, C., Hernández-Clemente, R., Hornero, A., Majada, J., Martínez-Alonso, C. (2020): Assessing canopy responses to thinnings for sweet chestnut coppice with time-series vegetation indices derived from landsat-8 and sentinel-2 imagery. *Remote Sensing*, 12(18), 3068.
94. Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R., Feizizadeh, B. (2017): Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework. *Science of the Total Environment*, 579, 913-927.
95. Rodríguez Sousa, A. A., Barandica, J. M., Aguilera, P. A., Rescia, A. J. (2020): Examining potential environmental consequences of climate change and other driving forces on the sustainability of Spanish olive groves under a socio-ecological approach. *Agriculture*, 10(11), 509.
96. Roujean, J. L., Breon, F. M. (1995): Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote sensing of Environment*, 51(3), 375-384.
97. Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W. (1974): Monitoring vegetation systems in the Great Plains with ERTS. *NASA special publication*, 351, 309.
98. Sankaran, S., Khot, L. R., Espinoza, C. Z., Jarolmasjed, S., Sathuvalli, V. R., Vandemark, G. J., Pavek, M. J. (2015): Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy*, 70, 112-123.
99. Shanahan, J. F., Schepers, J. S., Francis, D. D., Varvel, G. E., Wilhelm, W. W., Tringe, J. M., Major, D. J. (2001): Use of remote-sensing imagery to estimate corn grain yield. *Agronomy Journal*, 93(3), 583-589.
100. Serra, P., Pons, X., Saurí, D. (2008): Land-cover and land-use change in a Mediterranean landscape: a spatial analysis of driving forces integrating biophysical and human factors. *Applied Geography*, 28(3), 189-209.

101. Stehman, S. V., Czaplewski, R. L. (1998): Design and analysis for thematic map accuracy assessment: fundamental principles. *Remote sensing of environment*, 64(3), 331-344.
102. Stengel, M., Stapelberg, S., Sus, O., Finkensieper, S., Würzler, B., Philipp, D., McGarragh, G. (2020): Advanced Very High Resolution Radiometer post meridiem dataset version 3: 35-year climatology of global cloud and radiation properties. *Earth System Science Data*, 12(1), 41-60.
103. Solano, F., Di Fazio, S., Modica, G. (2019): A methodology based on GEOBIA and WorldView-3 imagery to derive vegetation indices at tree crown detail in olive orchards. *International Journal of Applied Earth Observation and Geoinformation*, 83, 101912.
104. Sozzi, M., Kayad, A., Gobbo, S., Cogato, A., Sartori, L., Marinello, F. (2021): Economic comparison of satellite, plane and UAV-acquired NDVI images for site-specific nitrogen application: observations from Italy. *Agronomy*, 11(11), 2098.
105. Story, M., Congalton, R. G. (1986): Accuracy assessment: a user's perspective. *Photogrammetric Engineering and remote sensing*, 52(3), 397-399.
106. Stow, D., Hope, A., Nguyen, A. T., Phinn, S., Benkelman, C. A. (1996): Monitoring detailed land surface changes using an airborne multispectral digital camera system. *IEEE Transactions on Geoscience and Remote Sensing*, 34(5), 1191-1203.
107. Sullivan, J. M. (2006): Evolution or revolution? The rise of UAVs. *IEEE Technology and Society Magazine*, 25(3), 43-49.
108. Šiljeg, A., Barada, M., Marić, I. (2018): *Digital Terrain Modelling*. Zagreb: Alfa d.d. i Sveučilište u Zadru
109. Šiljeg, A., Domazetović, F., Marić, I., Panđa, L. (2020): Quality Assessment of Worldview-3 Stereo Imagery Derived Models Over Millennial Olive Groves. *International Conference on Geographical Information Systems Theory, Applications and Management* (pp. 66-84). Springer, Cham.
110. Šiljeg, A., Panđa, L., Domazetović, F., Marić, I., Gašparović, M., Borisov, M., Milošević, R. (2022): Comparative Assessment of Pixel and Object-Based Approaches for Mapping of Olive Tree Crowns Based on UAV Multispectral Imagery. *Remote Sensing*, 14(3), 757.
111. Taddia, Y., Stecchi, F., Pellegrinelli, A. (2020): Coastal mapping using DJI Phantom 4 RTK in post-processing kinematic mode. *Drones*, 4(2), 9.

112. Tahir, M. N., Naqvi, S. Z. A., Lan, Y., Zhang, Y., Wang, Y., Afzal, M., Amir, S. (2018): Real time estimation of chlorophyll content based on vegetation indices derived from multispectral UAV in the kinnow orchard. *International Journal of Precision Agricultural Aviation*, 1(1).
113. Tavakkoli Piralilou, S., Einali, G., Ghorbanzadeh, O., Nachappa, T. G., Gholamnia, K., Blaschke, T., Ghamisi, P. (2022): A Google Earth Engine Approach for Wildfire Susceptibility Prediction Fusion with Remote Sensing Data of Different Spatial Resolutions. *Remote Sensing*, 14(3), 672.
114. Tsouros, D. C., Bibi, S., Sarigiannidis, P. G. (2019): A review on UAV-based applications for precision agriculture. *Information*, 10(11), 349.
115. Tucker, C. J., Slayback, D. A., Pinzon, J. E., Los, S. O., Myneni, R. B., & Taylor, M. G. (2001): Higher northern latitude normalized difference vegetation index and growing season trends from 1982 to 1999. *International journal of biometeorology*, 45(4), 184-190.
116. Vrabel, J. (1996): Multispectral imagery band sharpening study. *Photogrammetric engineering and remote sensing*, 62(9), 1075-1084.
117. Wang, F. M., Huang, J. F., Tang, Y. L., Wang, X. Z. (2007): New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), 195-203.
118. Watts, A. C., Ambrosia, V. G., Hinkley, E. A. (2012): Unmanned aircraft systems in remote sensing and scientific research: Classification and considerations of use. *Remote Sensing*, 4(6), 1671-1692.
119. Wickham, J., Stehman, S. V., Sorenson, D. G., Gass, L., Dewitz, J. A. (2021): Thematic accuracy assessment of the NLCD 2016 land cover for the conterminous United States. *Remote Sensing of Environment*, 257, 112357.
120. Xue, J., Su, B. (2017): Significant remote sensing vegetation indices: A review of developments and applications. *Journal of sensors*, 2017.
121. Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., Tian, Y. C. (2017): Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255.
122. Zollhöfer, M. (2019): Commodity RGB-D sensors: Data acquisition. *RGB-D Image Analysis and Processing* (pp. 3-13). Springer, Cham.

Izvori

Državna geodetska uprava Republike Hrvatske, (2022): WMS server Republike Hrvatske: DOF 1:5000, HOK 1:5000 (geoportal.dgu.hr/wms)

URL1: <http://www.dgu.hr/> (27. prosinca, 2021)

URL2: <https://www.integraldrones.com.au/comparing-ndvi-mapping-systems/> (27. prosinca, 2021)

URL3: <https://www.quantum-systems.com/project/trinityf90plus-mapping-drone/> (5. siječnja, 2022)

URL4: https://geomatika-smolcak.hr/wp-content/uploads/2021/08/Quantum-Systems_Brochure_2021.pdf (6. siječnja, 2022)

URL5: <https://www.quantum-systems.com/project/micasense-dual-camera-system-payload/> (7. siječnja, 2022)

URL6: <https://micasense.com/dual-camera-system/> (7. siječnja, 2022)

URL7: <https://www.sony.com/za/electronics/cyber-shot-compact-cameras/dsc-rx1rm2> (8. siječnja, 2022)

URL8: <https://www.quantum-systems.com/project/sony-rx1r-ii/> (8. siječnja, 2022)

URL9: <https://geospatial.trimble.com/products-and-solutions/trimble-r8s> (10. siječnja, 2022)

URL10: <https://www.quantum-systems.com/qbase-3d/> (11. siječnja, 2022)

URL11: <https://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/raster-calculator.htm> (5. veljače, 2022)

URL12: <https://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/train-support-vector-machine-classifier.htm> (7. veljače, 2022)

URL13: <https://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/train-maximum-likelihood-classifier.htm> (7. veljače, 2022)

URL14: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/train-random-trees-classifier.htm> (8. veljače, 2022)

URL15: <https://www.l3harrisgeospatial.com/docs/calculatingconfusionmatrices.html> (10. veljače, 2022)

URL16: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/segment-mean-shift.htm> (11. veljače, 2022)

Popis grafičkih priloga

Slika 1. Područje istraživanja (DGU, 2020 - DOF)

Slika 2. Način reflektiranja elektromagnetskog zračenja kod biljaka različitog zdravstvenog stanja (prema: URL 2)

Slika 3. Shema prikupljanja podataka: a) korištene geoprostorne tehnologije, b) prva faza, c) druga faza

Slika 4. Bespilotna letjelica *Trinity F90+*

Slika 5. GNSS bazna stanica *iBase* s pripadajućom *Rugged IP67* GNSS antenom i prijenosnom baterijom (URL3)

Slika 6. *MicaSense RedEdge-MX Dual Camera* i valne duljine spektralnih kanala (URL6)

Slika 7. *Sony RX1R II* fotoaparat u kućištu spremnom za postavljanje na bespilotnu letjelicu (URL8)

Slika 8. *Trimble R8s*

Slika 9. Sučelje *QBase 3D* programa

Slika 10. Označavanje i prikupljanje kontrolnih točaka

Slika 11. Prostorni raspored kontrolnih točaka i lokacija referentne točke

Slika 12. Referentna točka i bazna stanica *iBase*

Slika 13. Kalibracija bespilotne letjelice *Trinity F90+*

Slika 14. Kalibracija postavljenog MS senzora pomoću kalibracijskog referentnog panela

Slika 15. Odabir tipa bespilotne letjelice i vrste senzora

Slika 16. Lokacija i smjer bespilotne letjelice prilikom polijetanja

Slika 17. Plan i postavke misije s multispektralnim senzorom

Slika 18. Plan i postavke misije s RGB senzorom

Slika 19. Shema obrade podataka

Slika 20. Shema procesa i zadani parametri prilikom obrade podataka u *Agisoft Metashape*

1.5.1

Slika 21. Koraci GEOBIA pristupa

Slika 22. Različite kombinacije rasporeda spektralnih kanala

Slika 23. Alat *Segment Mean Shift*

Slika 24. Usporedba različitih parametara prilikom procesa segmentacije

Slika 25. Proces dodavanja testnih uzoraka

Slika 26. Alat *Train Support Vector Machine Classifier*

Slika 27. Alat *Train Maximum Likelihood Classifier*

Slika 28. Alat *Train Random Trees Classifier*

Slika 29. Alat *Classify Raster*

Slika 30. Alat *Reclassify*

Slika 31. a) Poligon referentne masline, b) Poligon lažne masline

Slika 32. a) *Fishnet* točaka unutar RM-e, b) Atributna tablica RM-a

Slika 33. Alat *Compute Confusion Matrix*

Slika 34. Shema procesa izdvajanja krošanja maslina korištenjem vegetacijskih indeksa

Slika 35. Alat *Raster Calculator*

Slika 36. Shema alata VITO unutar *Model Builder*-a (Šiljeg, 2022)

Slika 37. Alat *Calculate ROC Curves and AUC Values*

Slika 38. Prostorni raspored poligona referentnih i lažnih maslina

Slika 39. Prostorni raspored nasumično raspoređenih točaka

Slika 40.a) Lokacije MS fotografija i broj preklapanja, b) *Image residuals* za NIR kanal (5,5mm)

Slika 41. a) Lokacije RGB fotografija i broj preklapanja, b) *Image residuals* (35 mm)

Slika 42. Rijetki oblak točaka s lokacijama prikupljenih fotografija

Slika 43. Gusti oblak točaka područja istraživanja

Slika 44. Poligonalna mreža područja istraživanja

Slika 45. Teksturirana poligonalna mreža područja istraživanja

Slika 46. MS model vrlo visoke prostorne rezolucije

Slika 47. Procijenjene pogreške pozicioniranja kamera

Slika 48. X,Y i Z pogreške kontrolnih točaka

Slika 49. DOF snimak vrlo visoke rezolucije

Slika 50. MS model s rasporedom kanala 10-9-8

Slika 51. Segmentirani MS model

Slika 52. Klase testnih uzoraka u *Training Sample Manager-u*

Slika 53. Klasificirani model - SVM

Slika 54. Klasificirani model - ML

Slika 55. Klasificirani model - RT

Slika 56. Reklasificirani modeli: a) SVM, b) ML, c) RT

Slika 57. Odabrani model - GEOBIA pristup

Slika 58. Modeli vegetacijskih indeksa: a) *NDVI*, b) *NDRE*, c) *GNDVI*, d) *MCARI2*, e) *RDVI2*

Slika 59. Klasificirane krošnje maslina a) *NDVI*, b) *NDRE*, c) *GNDVI*, d) *MCARI2*, e) *RDVI2*

Slika 60. ROC krivulje i vrijednosti AUC-a za modele odabranih vegetacijskih indeksa

Slika 61. Odabrani model - pristup temeljen na vegetacijskim indeksima

Slika 62. ROC krivulje i vrijednosti AUC-a za korištene pristupe

Slika 63. ROC krivulje i vrijednosti AUC-a za korištene pristupe - druga metoda provjere

Slika 64. Varijabilnosti unutar krošanja maslina vegetacijskih indeksa: a) *NDRE*, b) *NDVI*

Slika 65. Varijabilnost *NDRE* indeksa unutar izdvojenih krošanja maslina

Slika 66. Varijabilnosti *NDVI* indeksa unutar izdvojenih krošanja maslina

Popis tabličnih priloga

Tablica 1. Specifikacije bespilotne letjelice *Trinity F90+*

Tablica 2. Specifikacije multispektralnog senzora *MicaSense RedEdge-MX Dual Camera*

Tablica 3. Specifikacije *Trimble R8s*

Tablica 4. Koordinate kontrolnih točaka

Tablica 5. Koordinate referentne točke

Tablica 6. Ukupna točnost

Tablica 7. Točnost po kontrolnim točkama

Tablica 8. Mjere točnosti - *RT*

Tablica 9. Mjere točnosti - *ML*

Tablica 10. Mjere točnosti - *SVM*

Tablica 11. Konfuzijska matrica i rezultati mjera točnosti - Vegetacijski indeks *NDRE*

Tablica 12. Konfuzijska matrica i rezultati mjera točnosti - *GEOBIA RT*

Tablica 13. Konfuzijska matrica i rezultati mjera točnosti za vegetacijski indeks *NDRE* - druga metoda provjere

Tablica 14. Konfuzijska matrica i rezultati mjera točnosti za *GEOBIA (RT)* - druga metoda provjere

Sažetak

Održivost i zaštita masline kao jedne od najstarijih biljnih vrsta na Mediteranu od iznimne je važnosti. Posljednjih desetljeća razvoj metodologije precizne poljoprivrede i geoprostornih tehnologija omogućio je osiguravanje održivosti i u maslinarstvu. Geoprostorne tehnologije omogućuju kartiranje i analizu krošanja maslina u svrhu sprječavanja raznih štetnih nametnika i produljenja životnog vijeka. Područje istraživanja ovog diplomskog rada nalazi se na sjeveroistočnom dijelu otoka Paga, točnije unutar vrtova Lunjskih maslinika, u neposrednoj blizini naselja Lun. Ciljevi istraživanja su utvrđivanje pozicijske točnosti procesa georeferenciranja bespilotne letjelice, izrada multispektralnog modela vrlo visoke rezolucije, testiranje točnosti klasifikacijskih algoritama, analiza vegetacijskih indeksa i usporedba korištenih pristupa. Kao posljednji cilj, postavljeno je utvrđivanje varijabilnosti vegetacijskih indeksa unutar krošnji maslina. U svrhu aerofotogrametrijskog snimanja istraživanog područja, korištena je bespilotna letjelica *Trinity F90+*, a snimanje je izvršeno u dvije misije. Prva misija vezana je uz korištenje multispektralnog senzora *MicaSense RedEdge - MX Dual* vrlo visoke razlučivosti, dok je prilikom druge misije na bespilotnu letjelicu integriran *Sony RX1R II* u svrhu izrade DOF-a vrlo visoke rezolucije. Pomoću multispektralnog modela vrlo visoke prostorne rezolucije, provedeni su koraci GEOBIA pristupa, prilikom kojeg su uspoređeni svi korisničko-definirani parametri i odabrani najtočniji klasifikacijski algoritmi. Pristup temeljen na vegetacijskim indeksima omogućio je klasifikaciju krošnji ponajviše zbog ulaznih podataka koji uključuju kanale u rubnom crvenom i infracrvenom dijelu elektromagnetskog spektra. Krošnje maslina izdvojene su izrađenim alatom VITO, a zatim pomoću mjera za procjenu, ispitane su točnosti odabranih vegetacijskih indeksa. Dva korištena pristupa uspoređeni su uz pomoć pet mjera za procjenu točnosti. Posljednja faza istraživanja odnosi se na utvrđivanje varijabilnosti vegetacijskih indeksa unutar krošnji pojedinih maslina. Pozicijska točnost dobivenog multispektralnog snimka iznosi $< 3,5$ cm. Kao najbolji klasifikacijski algoritam u GEOBIA pristupu, pokazao se algoritam *Random Trees*. Nakon uspješne optimizacije vegetacijskih indeksa, *NDRE* indeks odabran je kao najtočniji i reprezentativni primjer. U usporedbi dvaju pristupa, pristup temeljen na vegetacijskim indeksima pokazao je bolje rezultate u dvije metode i svih pet mjera točnosti, te je odabran kao najbolji u kartiranju krošanja maslina. Uočene varijabilnosti vegetacijskih indeksa unutar krošnji ukazuju na mogućnost primjene navedene metodologije i predstavljaju temelj za buduća istraživanja u maslinarstvu.

Summary

The sustainability and protection of the olive trees is very important, as one of the oldest plant species in the Mediterranean. In recent decades, the development of precision agriculture methodology and geospatial technologies has made it possible to ensure sustainability in olive growing. Geospatial technologies enable the mapping and analysis of olive canopy in order to prevent various harmful pests and prolong lifetime. The research area of this graduation thesis is located in the northeastern part of the island of Pag, more precisely within the gardens of Lun olive groves, not far from the eponymous settlement Lun. The objectives of the research were to determine the positional accuracy of the UAV georeferencing process, to develop a multispectral model of very high resolution, to test the accuracy of classification algorithms, to analyze vegetation indices and to compare the approaches used. As a last goal, the variability of vegetation indices within olive canopies was determined. For the purpose of aerial photogrammetric recording of the investigated area, the *Trinity F90+* UAV was used, and the recording was performed in two missions. The first mission involved the use of a very high-resolution *MicaSense RedEdge-MX Dual* multispectral sensor, while the second mission involved the *Sony RX1R II* being attached to the drone to produce a very high-resolution DOP. Using multispectral models, the steps of the GEOBIA approach were performed, during which all user-defined parameters were compared and the most accurate classification algorithms were selected. The approach based on vegetation indices enabled the classification of canopies mainly due to the input data that include channels in the marginal red and infrared part of the electromagnetic spectrum. Olive canopies were selected using the VITO tool and then the accuracy of selected vegetation indices was examined using assessment measures. A comparison of the two approaches used was performed using five measures to assess accuracy. The last phase of the research was to determine the variability of vegetation indices within the canopy of individual olive trees. The positional accuracy of the obtained multispectral image is <3.5 cm. The Random Trees algorithm proved to be the best classification algorithm in the GEOBIA approach. After successful optimization of vegetation indices, the NDRE index was selected as the most accurate and representative example. Comparing the two approaches, the vegetation index-based approach showed better results in two methods and all five measures of accuracy, and was selected as the best in olive canopy mapping. Finally, the observed variability of vegetation indices within the canopy indicate the possibility of applying this methodology and represent the basis for future research in olive growing.