# Primjena bespilotnih letjelica u poljoprivredi

**Krevh, Vedran**

**Master's thesis / Diplomski rad**

**2018**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:204:778632

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

*Download date / Datum preuzimanja:* **2024-03-28**



*Repository / Repozitorij:*

Repository Faculty of Agriculture University of Zagreb








SVEUČILIŠTE U ZAGREBU
**AGRONOMSKI FAKULTET**

# PRIMJENA BESPILOTNIH LETJELICA U POLJOPRIVREDI

DIPLOMSKI RAD

Vedran Krevh

Zagreb, siječanj, 2018.

SVEUČILIŠTE U ZAGREBU
**AGRONOMSKI FAKULTET**

Diplomski studij:
Melioracije

# PRIMJENA BESPILOTNIH LETJELICA U POLJOPRIVREDI

DIPLOMSKI RAD

Vedran Krevh

Mentor: doc. dr. sc. Igor Kovačev

Zagreb, siječanj, 2018.

SVEUČILIŠTE U ZAGREBU
**AGRONOMSKI FAKULTET**

## IZJAVA STUDENTA

O AKADEMSKOJ ČESTITOSTI

Ja, **Vedran Krevh**, JMBAG 0178090382, rođen dana 14.01.1993. u Zagrebu, izjavljujem da sam samostalno izradio diplomski rad pod naslovom:

**PRIMJENA BESPILOTNIH LETJELICA U POLJOPRIVREDI**

Svojim potpisom jamčim:

- da sam jedini autor ovoga diplomskog rada;
- da su svi korišteni izvori literature, kako objavljeni tako i neobjavljeni, adekvatno citirani ili parafrazirani, te popisani u literaturi na kraju rada;
- da ovaj diplomski rad ne sadrži dijelove radova predanih na Agronomskom fakultetu ili drugim ustanovama visokog obrazovanja radi završetka sveučilišnog ili stručnog studija;
- da je elektronička verzija ovoga diplomskog rada identična tiskanoj koju je odobrio mentor;
- da sam upoznat s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

U Zagrebu, dana _____ _____

*Potpis studenta*

SVEUČILIŠTE U ZAGREBU
**AGRONOMSKI FAKULTET**

**IZVJEŠĆE**

O OCJENI I OBRANI DIPLOMSKOG RADA

Diplomski rad studenta **Vedrana Krevha**, JMBAG 0178090382, naslova

**PRIMJENA BESPILOTNIH LETJELICA U POLJOPRIVREDI**

obranjen je i ocijenjen ocjenom _____ , dana _____ .

| Povjerenstvo: | | | potpisi: |
|---|---|---|---|
| 1. | doc. dr. sc. Igor Kovačev | mentor | _____ |
| 2. | prof. dr. sc. Stjepan Pliestić | član | _____ |
| 3. | doc. dr. sc. Krešimir Čopec | član | _____ |

# Zahvala

*Ovim putem želim se zahvaliti doc. dr. sc. Igoru Kovačevu na mentorstvu i podršci prilikom izrade rada. Veliko hvala prof. dr. sc. Stjepanu Pliestiću na motivaciji tijekom studija. Hvala doc. dr. sc. Krešimiru Čopecu na susretljivosti i kvalitetnom prijenosu informacija. Također, htio bih se zahvaliti prof. dr. sc. Silviu Košutiću što me uveo u svijet precizne poljoprivrede.*

*Hvala i svim članovima Agronomskog fakulteta u Zagrebu zbog velikog doprinosa mom obrazovanju. Također, hvala kolegama koji su me pratili tijekom studija i sa mnom dijelili studentske dane.*

*Rad je posvećen pokojnom ocu Ivanu, koji je prvi u meni pobudio tehnički način razmišljanja.*

# Sadržaj


1. Uvod ... 1

1.1. Cilj rada ... 1

1.2. Pregled literature ... 1

2. Precizna poljoprivreda ... 5

2.1. Ciljevi u preciznoj poljoprivredi ... 5

2.2. Prednosti precizne poljoprivrede ... 6

3. Daljinsko istraživanje ... 7

3.1. Metode daljinskih istraživanja ... 7

3.2. Ciljevi daljinskih istraživanja ... 8

3.3. Prednosti daljinskih istraživanja ... 8

3.4. Fotogrametrija ... 8

3.4.1. Satelitska fotogrametrija ... 9
3.4.2. Aerofotogrametrija ... 9

4. Kartografija ... 12

4.1. Digitalna kartografija ... 12

4.2. Digitalna karta ... 12

4.3. Vrste razlučivosti ... 13

4.4. Kartiranje i analiza snimaka u poljoprivredi ... 13

4.5. Digitalni model terena (DTM) ... 14

5. Geoinformacijski sustavi (GIS) ... 15

5.1. Vektorski i rasterski podaci ... 15

5.2. Slojevi ... 16

5.3. Prednosti GIS-a ... 17

5.4. Razlika geoinformacijskih i kartografskih sustava ... 17

6. Bespilotne letjelice ... 18

6.1. Povijesni razvoj bespilotnih letjelica ... 18

6.2. Primjene bespilotnih letjelica ..... 19

6.3. Primjena bespilotnih letjelica u poljoprivredi ..... 19

6.4. Podjela bespilotnih letjelica prema konstrukciji ..... 20

6.4.1. Letjelice s nepokretnim krilima ..... 20
6.4.2. Letjelice s pokretnim krilima ..... 20

6.5. Pozicioniranje, navigacija i kontrola leta ..... 21

6.5.1. Globalni navigacijski satelitski sustavi (GNSS) ..... 23
6.5.2. Globalni pozicijski sustav (GPS) ..... 23
6.5.3. Diferencijalni GPS (DGPS) ..... 25
6.5.4. CROPOS ..... 25

6.6. Snimanje bespilotnom letjelicom ..... 27

6.6.1. Elektromagnetsko zračenje ..... 27
6.6.2. Elektromagnetski spektar ..... 28
6.6.3. Svjetlost ..... 29
6.6.4. Fotometrija ..... 29
6.6.5. Interakcija Sunčeve energije sa Zemljom ..... 29
6.6.6. Uređaji za registriranje elektromagnetske energije ..... 34

7. Vegetacijski indeksi ..... 38

7.1. Vegetacijski indeks normalizirane razlike (NDVI) ..... 40

7.2. Zeleni vegetacijski indeks normalizirane razlike (GNDVI) ..... 42

7.3. Vodeni indeks normalizirane razlike (NDWI) ..... 42

7.4. Vegetacijski indeks prilagođen tlu (SAVI) ..... 42

7.5. Poboljšani vegetacijski indeks (EVI) ..... 43

7.6. Ostali vegetacijski indeksi ..... 43

8. Opis mogućnosti i značajki bespilotne letjelice Sensefly eBee ..... 45

8.1. Tehničke značajke ..... 45

8.2. Planiranje, kontrola i praćenje leta ..... 47

8.3. Mogućnosti snimanja ..... 52

8.4. Obrada podataka ..... 55

9. Nadležne institucije, propisi i zakonodavstvo ..... 62

9.1. Hrvatska agencija za civilno zrakoplovstvo (CCAA) ..... 62

9.1.1. Pravilnik o sustavima bespilotnih zrakoplova ..... 63

9.2. Hrvatska kontrola zračne plovidbe (HKZP) ..... 69

9.2.1. AMC Hrvatska ..... 69
9.2.2. AMC portal ..... 70

9.3. Državna geodetska uprava (DGU) ..... 70

9.3.1. Uredba o snimanju iz zraka ..... 70

10. Zaključak ..... 74

11. Literatura ..... 77

Životopis ..... 81

# Sažetak

Diplomskog rada studenta **Vedrana Krevha**, naslova

**PRIMJENA BESPILOTNIH LETJELICA U POLJOPRIVREDI**

Napretkom tehnologije bespilotnih letjelica (UAV), razvojem sve manjih senzora za snimanje i odgovarajućeg softvera, precizna poljoprivreda dobiva još jedan alat za donošenje odluka. U ovom radu definirane su mogućnosti primjene bespilotnih letjelica u sustavu precizne poljoprivrede. Uz opis daljinskog istraživanja, uspoređena su satelitska fotogrametrija i aerofotogrametrija. Objašnjene su digitalne karte i predmeti promatranja u poljoprivredi. Definirana je razlika između GIS-a i automatskih kartografskih sustava. Uspoređene su konstrukcije UAV-a. Obrađeno je izvođenje leta, definirajući sustave GNSS-a, GPS-a, DGPS-a i INS-a. Objašnjena je interakcija Sunčeve energije sa Zemljom te su definirani uređaji za snimanje. Definiran je pojam vegetacijskog indeksa te je objašnjeno nekoliko glavnih, uključujući NDVI. Opisane su mogućnosti UAV-a Sensefly eBee uključujući izvođenje leta, snimanje i obradu podataka. Definirane su institucije i organizacije te propisi po kojima se letovi i snimanja smiju provoditi u RH.

**Ključne riječi**: precizna poljoprivreda, kartografija, GIS, NDVI, zakonodavstvo

# Summary

Of the master's thesis - student **Vedran Krevh,** entitled

**UNMANNED AERIAL VEHICLES' UTILISATION IN AGRICULTURE**

With the development of unmanned aerial vehicles (UAVs), smaller sensors for image acquisition and support software, precision agriculture has gained an another decision making tool. This paper deals with the objectives and the benefits of UAVs application in precision agriculture. Remote sensing is explained, satellite photogrammetry and aerial photogrammetry are compared. Digital maps and objects of interest in agriculture are described. Difference between GIS and automated cartography systems is defined. Different types of UAVs are compared. Working principle of flight control is explained by defining GNSS, GPS, DGPS and INS. Interaction of sunlight with Earth is defined and various remote sensors are presented. Few examples of vegetation indices along with NDVI are defined. Characteristics of Sensefly eBee are explained, including flight performance, image acquisition and data processing. Institutions and regulations under which the flight and image capturing has to be conducted in Croatia is described.

**Keywords**: precision agriculture, mapping, GIS, NDVI, legislation

# 1. Uvod

Ključni zahtjev poljoprivredne proizvodnje, uz optimalnu kvalitetu proizvoda, jest racionalizacija proizvodnih procesa s ekonomskog i ekološkog aspekta, a upravo primjena bespilotnih letjelica (UAV) u poljoprivredi otvara nove mogućnosti racionalizacije. Kontinuiran nadzor proizvodnih površina i usjeva ključni je čimbenik u planiranju i provedbi većine agrotehničkih zahvata. Detaljna i redovito ažurirana dokumentacija pridonosi boljem planiranju radnih operacija, uštedi radnih sredstava i vremena, poboljšanoj kvaliteti proizvoda te smanjenju opterećenja okoliša.
Primjena bespilotnih letjelica koje su opremljene suvremenom opremom za snimanje usjeva ili nasada je relativno nova tehnologija čiji će daljnji razvoj pridonijeti učinkovitijem planiranju agrotehnike osnovom informacija o stanju usjeva, pojavi bolesti i štetnika, zakorovljenosti, sadržaju vode u tlu. U iznimno divergentnoj ponudi bespilotnih letjelica danas prisutnih na tržištu, njihova primjenjivost u poljoprivredi definirana je senzorskim sustavima sposobnim za detekciju navedenih osobina/pojava. Uz digitalni model terena, temeljni alat za razlikovanje i ocjenu stanja usjeva je vegetacijski indeks, koji je bezdimenzionalna veličina izračunata na temelju reflektiranog elektromagnetskog zračenja u različitim dijelovima spektra. Obradom prikupljenih podataka u prikladnom geoinformacijskom sustavu (GIS) omogućeno je kartiranje proizvodnih površina prema odabranim obilježjima, kao i donošenje odluka.
Za korisnike bespilotnih letjelica također je bitno upoznati se sa zakonskom regulativom koja može predstavljati ograničavajući faktor u njihovoj primjeni i korištenju prikupljenih podataka, te poznavati sigurnosne propise vezane za upravljanje bespilotnim letjelicama.

## 1.1. Cilj rada

Cilj ovog rada je dati pregled tehnološkog napretka na području razvoja bespilotnih letjelica za snimanje iz zraka i definirati mogućnosti mjerenja i kartiranja važnijih osobina vezanih za poljoprivrednu proizvodnju. Istaknut će se prednosti i nedostaci pojedinih UAV sustava koji se nalaze u primjeni s ciljem odabira optimalnih rješenja za primjenu u pojedinim granama poljoprivrede. Također će biti napravljen pregled zakonske regulative vezane uz korištenje bespilotnih letjelica u Republici Hrvatskoj, s naglaskom na moguća ograničenja primjene u poljoprivredi.

## 1.2. Pregled literature

Ostvarivanje sljedivosti, praćenje i dokumentiranje cijelog lanca proizvodnje uz proizvodnju zdravstveno sigurne i kvalitetne hrane postao je jedan od ključnih zahtjeva poljoprivrede (Jurišić i Plašćak 2009). Precizna poljoprivreda omogućuje optimalnu zaštitu svake pojedine biljke, a ne samo prosjek, odnosno cijelo polje. Jedan od glavnih benefita precizne poljoprivrede u zaštiti bilja je nizak rizik ulaganja (Jurišić i sur. 2015).

Upotreba resursa u preciznoj poljoprivredi, u odnosu na parcele, je optimizirana u proizvodnji visokokvalitetnih poljoprivrednih proizvoda. Sve stavke u preciznoj poljoprivredi zahtijevaju kontrolu protoka tvari i energije, to jest protoka informacija putem prikladne informacijske tehnologije.

Daljinska istraživanja danas nalaze široku primjenu u različitim disciplinama i znanstvenim područjima preko platformi poput zračnih i svemirskih letjelica. Prikupljeni podaci mogu iznositi veličinu od nekoliko centimetara, do tisuće kilometara u konačnici (Jurišić i Plašćak 2009).

Postupci u daljinskim istraživanjima su definiranje radnog zadatka, prikupljanje podataka daljinskim metodama, analiza podataka i interpretacija, verifikacija, informacija o rezultatima, mjere i aktivnosti na osnovi rezultata. Glavne prednosti daljinskih istraživanja pri istraživanju Zemlje i njenih resursa nad drugim metodama su sinoptički pregled, aspekt izvođenja, ušteda vremena i novaca, multidisciplinarna primjena te izvor podataka i informacija (Oluić 2001).

Princip fotogrametrije počiva na reflektiranju prirodne svjetlosti (sunčeve zrake) ili umjetnom zračenju (radar, zvuk) od pojedinih objekata (Jurišić i Plašćak 2009).

Dostupnost satelitskih snimki je u početku bila ograničena za vojne svrhe. Danas su one dostupne širem krugu korisnika, pa tako i civilnom sektoru. Određeni sateliti imaju upravo osnovnu funkciju za snimanje određenih područja na zahtjev civilnih korisnika. Zračne snimke se već dulje vrijeme koriste kao izvor informacija o prostoru. Neprestanim razvijanjem tehnologije, danas je moguće prilikom preleta, osim snimanja standardne fotografije, skenirati područje i drugačijim tipovima senzora (Bušljeta-Vdović 2006).

Razvojem tehnologije pozicioniranja, senzora i samih letjelica te sve veće ekonomske opravdanosti, odabir bespilotnih letjelica postaje popularan za fotogrametrijske potrebe (Kolarek 2010).

Pod kartom smatramo kodiranu sliku geografske stvarnosti koja prikazuje odabrane objekte ili svojstva. Ona nastaje stvaralačkim autorskim izborom, a upotrebljava se onda kada su najvažniji prostorni odnosi. Kartografija je disciplina koja se bavi zasnivanjem, izradom i proučavanjem karata (Lovrić 1988). Primjena računalne tehnologije u kartografiji se naziva digitalna kartografija. Digitalna karta je zapravo digitalna baza podataka koja se koristi kao medij za pohranu informacija (Robinson 1995).

Ljudsko oko je složen sustav koji vrlo dobro prepoznaje kontraste te fizičke karakteristike promatranog objekta. Međutim, digitalna analiza snimaka u poljoprivredi omogućuje mnoštvo informacija o pozicijama, veličini i međuvezama promatranih objekata koje je moguće prikazati u raznim kartama (Gnädinger i Schmidhalter 2017).

Geoinformacijski sustav (eng. geographic information system) možemo smatrati tehnologijom ili strategijom za obradu informacija. On sadrži cijeli niz alata za podršku opažanja, mjerenja, opisa, tumačenja, predviđanja i odlučivanja (Tutić i sur. 2002). Određena obilježja u GIS-u mogu biti prikazana u slojevima u vektorskom ili u rasterskom formatu, pri čemu su njihovi relativni prostorni odnosi određeni njihovom topologijom. S obzirom na to da GIS omogućuje dobru vizualizaciju podataka i međusobnih odnosa u prostoru, iste odluke je moguće planski i pouzdano donositi (Pribičević i Medak 2003).

Bespilotna letjelica je letjelica namijenjena izvođenju letova bez pilota, koji mogu biti: daljinski upravljani; samostalni - uporabom unaprijed programiranog plana leta; izvedeni pomoću autonomnih dinamičkih sustava; ostvareni kombinacijom navedenog. Kroz povijest, razvoj tehnologije utjecao je na promjenu uloge samih bespilotnih letjelica. Prvobitno su bile razmatrane isključivo kao napadačka i obrambena oružja. Kasnije, dobivaju ulogu potajnog nadzora, u izviđačkim misijama te misijama špijuniranja. U najnovijem dobu, one imaju i ulogu promatranja i nadziranja okoliša (Pavlik i sur. 2014).

Bespilotne letjelice nude novu generaciju tehnologije nadziranja i mogućnost prikupljanja prostornih podataka s terena koji su jako brzo nakon prikupljanja dostupni za obradu i analizu. Ova metoda je pogotovo korisna za veće površine, kao i za nepristupačna i udaljena područja (Sito i sur. 2015). Primjena bespilotnih letjelica predstavlja jedno od najkvalitetnijih mogućih rješenja u modernoj poljoprivrednoj proizvodnji (Sito 2016).

Prema konstrukciji, bespilotne letjelice se dijele na letjelice s nepokretnim krilima ili tzv. čvrstokrilne (eng. fixed wing) i letjelice s pokretnim krilima ili tzv. rotorima (eng. multi-rotor), od kojih svaka ima svoje prednosti i nedostatke (Kolarek 2010). Određivanje pozicije u svakom trenu leta je ključno za uspješnu navigaciju. Točna lokacija svakog snimka je potrebna kako bi se snimci mogli georeferencirati, neovisno o tome koji senzor za daljinsko istraživanje bespilotna letjelica koristi (Pavlik i sur. 2014 prema Molina i sur. 2008). Kontrola letjelice je ključan aspekt leta, pored pozicioniranja i navigacije. Za kontrolu leta se koriste prijenosne kontrolne stanice. Za bolje planiranje leta, koristi se i digitalni model terena. Plan leta se prenosi u bespilotnu letjelicu prije samog leta, kako bi se mogla samostalno vratiti u slučaju gubljenja radijske veze (Pavlik i sur. 2014).

U počecima razvoja bespilotnih letjelica za snimanje iz zraka, kamere koje su se koristile su bile analognog formata zapisa. Razvojem senzora za digitalnu registraciju snimaka, klasične analogne kamere zamijenjene su digitalnima. Unatoč tome, određena svojstva digitalnih kamera zadržana su iz analognog doba. Konstrukcijski zahtjevi kamere moraju ostati nepromijenjeni u različitim uvjetima (temperatura, atmosferski tlak, vlaga, vibracije i dr.) radi održavanja parametara unutarnje orijentacije (Kolarek 2010).

Elektromagnetsko zračenje se može objasniti kao energija koja se širi u obliku interakcije između električnog i magnetskog polja, koji definiraju elektromagnetski val. Refleksija je od posebne važnosti za dobivanje informacija u daljinskim istraživanjima. Ona je razmjerna upadajućem zračenju koje se reflektira od nekog objekta. Radi uspješne primjene metoda daljinskih istraživanja nužno je poznavanje osnovnih značajki refleksije pojedinih objekata u različitim intervalima elektromagnetskog spektra (Oluić 2001).

Uređaji za registriranje elektromagnetske energije dijele se prema različitim značajkama. S obzirom na izvore energije dijele se na pasivne i aktivne uređaje (Frančula 2004). Uređaji koji se koriste na bespilotnim letjelicama su fotografske kamere, multispektralne kamere, hiperspektralne kamere, termalne kamere i mikrovalne kamere.

Ljudsko oko detektira vidljivi dio spektra od 0,4 μm do 0,7 μm, koji u konačnici zauzima mali dio cjelokupnog spektra. Infracrveno područje dijelimo na reflektirani IR (0,7 – 3,0 μm) i na termalni IR (3,0 – 100 μm) (Vela 2016).

Vegetacijski indeksi su podaci izračunati iz različitih kanala snimki na temelju apsorpcije, transmisije i refleksije energije vegetacije u različitim dijelovima elektromagnetskog spektra. Njihova primarna funkcija jest biti grafički indikator procjene aktivnosti vegetacije na promatranom području. Područja s većom vegetacijom pokazuju veće vrijednosti i suprotno (Vela 2016 prema She i sur. 2015). Vegetacijski indeks normalizirane razlike uveo je Deering 1978. godine te on predstavlja omjer između razlike i zbroja blisko infracrvenog dijela spektra i crvenog dijela spektra (Vela 2017 prema Deering 1978). Zbog širokih potreba daljinskih istraživanja te velikog broja različitih biofizičkih svojstava vegetacije, u posljednjih pedeset godina razvijeno je više vegetacijskih indeksa (Sito i sur. 2015).

Snimanje iz zraka bespilotnim letjelicama na području Republike Hrvatske, kao i korištenje tako snimljenog materijala, zakonski je regulirano Pravilnikom o sustavima bespilotnih zrakoplova – NN 69/09, NN 84/11, NN 54/13, NN 127/13 i NN 92/14 i Uredbom o snimanju iz zraka – NN 73/13, NN 75/15 i NN 27/16.

# 2. Precizna poljoprivreda

Poljoprivredno inženjerstvo postalo je integralni dio tehnologije proizvodnje hrane, a ne samo sredstvo za ostvarenje te tehnologije, imajući udjela i u višim područjima kao što je i razvoj senzora. Tehnologija u poljoprivredi, zasnivajući se na postavljenim zahtjevima i istraživačko-razvojnim dostignućima, definira proizvode potrebne suvremenoj poljoprivredi.

Pojam precizna poljoprivreda obuhvaća pravovremeno obavljanje poljoprivrednih radova uz smanjen broj operacija, visoku produktivnost te najnižu cijenu rada (Jurišić i Plašćak 2009).

Dostupnost velikoga broja informacija na raspolaganju pri donošenju odluka je osnovna pretpostavka precizne poljoprivrede. Izravna usporedba višegodišnjih parametara rezultira argumentiranom i optimalnom uporabom sredstava za rad, što je poželjno s ekološkog stajališta.

Uporaba bespilotnih letjelica u daljinskim istraživanjima omogućuje pravovremeno i ekonomično dobivanje informacija i podataka zadovoljavajuće preciznosti, a primjenom suvremene tehnologije, poput Variable Rate Application (apliciranje promjenjivom količinom) moguće je regulirati količinu repromaterijala u prihrani i zaštiti usjeva (Jurišić i sur. 2015).

## 2.1. Ciljevi u preciznoj poljoprivredi

Opsežna obrada vrlo različitih informacija je temeljna stavka precizne poljoprivrede. Raznolikost i sveobuhvatnost informacija, specifičnih za određenu površinu, nadilazi dosadašnje znanje koje se temelji na iskustvu poljoprivrednika.

Dosadašnji pristupi u preciznoj poljoprivredi pokazuju slijed u odnosu na postupke. Prikupljanje informacija je prvi korak. Podaci koji proizlaze iz promatranja obilježja odmah se obrađuju. Ovdje se informacijski sadržaj obrađuje prema dosadašnjim saznanjima o uzgoju. Treći korak podrazumijeva prenošenje dobivenih podataka. Korištenje informacija i vremenskih odnosa, između dobivanja informacija i upravljanja s istima, razlikuje principe precizne poljoprivrede (Jurišić i Plašćak 2009).

## 2.2. Prednosti precizne poljoprivrede

Precizna poljoprivreda služi ekonomskim i ekološkim poboljšanjima, prije svega pri uštedi radnih sredstava, strojeva i radnog vremena, poboljšanju ostvarenja dobiti kroz veće prinose i bolju kvalitetu proizvoda, smanjenju opterećenja okoliša i poticanju prirodno prostornih uvjeta te poboljšanju dokumentacije procesa proizvodnje.

Za postizanje ovih ciljeva potrebna je opsežna obrada vrlo različitih informacija koja podrazumijeva prikupljanje podataka, obradu i primjenu istih te dokumentaciju.

Poljoprivreda se treba podjednako ravnati i prema ekonomskim i ekološkim zahtjevima, a neki od njih su: učinkovita upotreba sirovina (gnojiva, sredstava za zaštitu biljaka, itd.), smanjenje štetnog opterećenja ekosustava (nitrati, pesticidi, itd.), prikladan uzgoj životinja, stvaranje ciklusa recikliranja (prirodni plin i kompostiranje), proizvodnja obnovljivih nositelja energije (sadnja energetskih biljaka, biološka goriva), čuvanje okoliša (zaštita vrsta kroz povezivanje biotopa).

Precizna poljoprivreda podrazumijeva prostorno upravljanje repromaterijalima i sredstvima u cilju povećanja profita, prinosa i kvalitete proizvoda (Jurišić i Plašćak 2009).

# 3. Daljinsko istraživanje

Upotreba snimaka snimljenih iz daljine (iz zraka ili svemira) raznim tehnikama snimanja i mjerenja bez kontakta sa snimljenim objektom nazivamo daljinskim istraživanjem (eng. remote sensing) (Oluić 2001.). Prema Lapaine-u i Frančuli (2001) daljinsko istraživanje je metoda prikupljanja i interpretacije informacija o udaljenim objektima bez fizičkog dodira s objektom.

Za potrebe daljinskih istraživanja koriste se različite vrste snimaka: fotografske, termalne, radarske, itd. (Donassy i sur. 1983).

Mjernim senzorima registriramo elektromagnetske valove, koje objekti zrače ili reflektiraju. Količina propuštenih, reflektiranih ili apsorbiranih valova ovisi o svojstvima samog objekta. Razlikujemo dva osnovna sustava daljinskih istraživanja, s obzirom na primjenjive senzore, a to su pasivni i aktivni sustavi. U pasivnim sustavima se koristi prirodna reflektirana (sunčeva) ili emitirana (zemljina) zračenja, koja se događaju bez vlastite volje (refleksija, raspršivanje, fluorescentna emisija i sl.). Pri aktivnim sustavima generira se određena energija koja se odašilje do objekta, a reflektirani dio se uhvati i samim time registrira. Pomoću njega se mogu izrađivati određene snimke ili registrirati drugačiji oblici podataka (radar postupak).

Osnovni elementi koji povezuju sva daljinska istraživanja su izvor zračenja, put transmisije (medij kroz koji se reflektirani/emitirani valovi prenose), objekt istraživanja i senzor.

Princip daljinskog istraživanja uključuje sve aktivnosti, od snimanja, procesiranja, analiziranja, interpretacije. Održivo gospodarenje prirodnim resursima i praćenje trenutačnog stanja na površini Zemlje zahtijeva pouzdane informacije o aktualnom stanju i stvarnim promjenama koje svakodnevne mogu nastupiti (Jurišić i Plašćak 2009).

## 3.1. Metode daljinskih istraživanja

Postupci u daljinskim istraživanjima su sljedeći:
1) definiranje radnog zadatka,
2) prikupljanje podataka daljinskim metodama (uz konzultaciju podataka dobivenih drugim metodskim postupcima),
3) analiza podataka i interpretacija,
4) verifikacija dobivenih rezultata (terenska provjera),
5) informacija o rezultatima,
6) poduzimanje određenih mjera i aktivnosti na osnovi rezultata (Oluić 2001).

## 3.2. Ciljevi daljinskih istraživanja

Brzo i ekonomično dobivanje podataka i informacija, zadovoljavajuće preciznosti, na relativno velikim područjima je glavni cilj daljinskih istraživanja. Tehnikom daljinskog istraživanja, moguće je određeni dio Zemljine površine slikovito i topografski prikazati i ispitivati, a ponavljanim to jest sustavnim snimanjem je moguće registrirati i dnevne, sezonske i godišnje promjene.

Objekti daljinskih istraživanja su svi elementi Zemljine površine u vidnom polju senzora. Elektromagnetski valovi što ih objekti zrače ili reflektiraju registriraju se mjerenjima. Kolika će količina elektromagnetskih valova biti propuštena, reflektirana ili apsorbirana, prvenstveno ovisi o svojstvima objekta (Oluić 2001).

## 3.3. Prednosti daljinskih istraživanja

Glavne prednosti daljinskih istraživanja pri istraživanju Zemlje i njenih resursa nad drugim metodama su:

**Sinoptički pregled daljinskim istraživanjima** koji omogućuje proučavanje različitih prostornih objekata i njihovih međusobnih odnosa te identificiranje i klasificiranje.
**Aspekt izvođenja** se smatra drugom glavnom prednosti, zbog mogućnosti istraživanja teško pristupačnih ili gotovo nepristupačnih terena.
**Ušteda vremena i novaca** je velika prednost ovakvog tipa istraživanja. Istovremenim dobivanjem informacija o većem području, štedi se na vremenu i radnoj snazi, a time i na sredstvima.
**Multidisciplinarna primjena**. Daljinska istraživanja se primjenjuju u različitim geoznanstvenim, tehničkim i društvenim disciplinama, kao što su poljoprivreda, šumarstvo, geodezija, prostorno planiranje, zaštita okoliša, i dr.
**Izvor podataka i informacija.** Analizom snimaka i interpretacijom podataka dobivaju se novi podaci i informacije koji su važan input za geoinformacijske sustave (Oluić 2001).

## 3.4. Fotogrametrija

Fotogrametrija je tehnika mjerenja pomoću koje se iz fotografskih snimaka izvodi oblik, veličina i položaj snimljenog predmeta (Braum 1992). Jedna od sveobuhvatnih definicija jest da je fotogrametrija umjetnost, znanost i tehnologija dobivanja pouzdanih kvantitativnih informacija o fizičkim objektima i okolišu procesom zabilježbe, mjerenja i interpretacije fotografskih slika i scena elektromagnetskog zračenja dobivenih senzorskim sustavima (Donassy i sur. 1983).

**Prema stajalištu kamere** fotogrametrija se dijeli na terestričku fotogrametriju, satelitsku fotogrametriju, aerofotogrametriju.

**Prema položaju osi snimanja** dijeli se na okomitu, vodoravnu, blago nagnutu, kosu (Jurišić i Plašćak 2009).

### 3.4.1. Satelitska fotogrametrija

Satelitska fotogrametrija je naziv koji predstavlja uže područje daljinskog istraživanja, tj. prikupljanje informacija uređajima smještenim u satelitima u Zemljinoj orbiti te interpretaciju tih informacija. Površina Zemlje opservirana je preko satelita Landsat već od 1972. godine, nakon kojeg se pridružio veći broj drugih satelita, s istim ili sličnim zadacima. Razvoj tehnologije je omogućio značajna unaprjeđenja u kvaliteti satelitskih snimaka te korištenju istih (Jurišić i Plašćak 2009).

Napretkom tehnologije, uređaji koji snimaju mogu i bilježiti vrlo precizne informacije o svojoj poziciji, a samim time i poziciji snimke. Točnost položaja, bez obzira na udaljenost snimanja, mjerena je u centimetrima. Najnovije generacije satelita koriste posebne senzore koji snimanjem raznih valnih dužina proizvode višespektralne snimke. Kako bi se postigla zadovoljavajuća točnost, nakon snimanja potrebna je dodatna obrada snimki. Obrađeni podaci mogu biti izvor više vrsta informacija o istom području tj. prostoru. Prednost satelitske fotogrametrije je u tome da obuhvaća znatno veće površine (Bušljeta-Vdović 2006).

Osnovni nedostaci satelitske fotogrametrije su: zaostajanje za mogućnostima razlučivosti snimki koje pruža aerofotogrametrijsko snimanje; kompliciranimatematički modeli za korekciju deformacija (od platforme, senzora, reljefa, potreba za informacijama o putanjama satelita, itd.); mogućnost prikaza oblaka na snimkama (Jurišić i Plašćak 2009).

### 3.4.2. Aerofotogrametrija

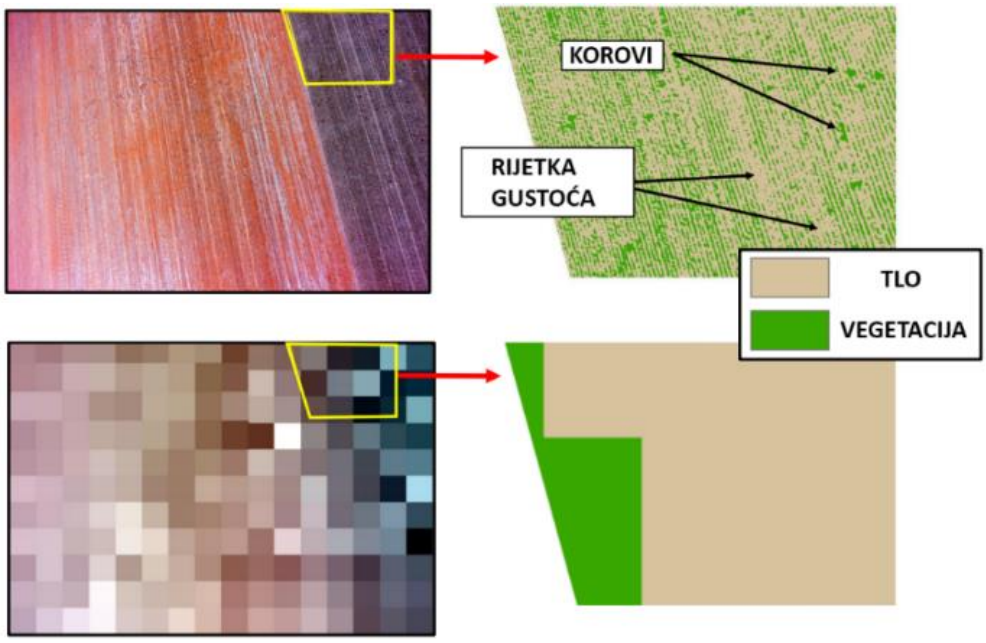
Aerofotogrametrija je dio fotogrametrije pri čemu se zemljište snima iz zraka, odnosno kad uređaj za snimanje nije u kontaktu s površinom Zemlje (Pahernik 2006).

Za potrebe kartiranja danas često služi aerofotogrametrijska metoda, pogotovo za veća područja. Prednost ove metode je u smanjenju rada na terenu, skraćenju vremena karata i smanjenju troškova. Aspekt snimanja je jedan od najvažnijih čimbenika ekonomičnosti aerofotogrametrijske metode. O kvaliteti snimaka ovisi točnost kartiranja, pa je potrebno napraviti snimanje uz najpovoljnije vremenske uvjete (Pribičević i Medak 2003).

U digitalnoj fotogrametriji, koristi se tehnika više snimaka s otklonom. Na ovaj način se pored karte područja, mogu dobiti i visinske razlike to jest u konačnici 3D modeli. Razvoj i povezanost tehnologija za snimanje i pozicioniranje omogućili su vrlo precizne snimke (Bušljeta-Vdović 2006).

Osnovna karakteristika avionskog snimanja je kamera smještena u trup posebno pripremljenog aviona. Prednost aviona kao letjelice za snimanje je u velikom radijusu kretanja, brzini, navigaciji te mogućnosti opterećenja, tj. nosivosti. Aerosnimke se dobivaju pomoću brzih aviona (200-400 km/h), ponekad s velikih visina kroz atmosferske slojeve. Pri ovakvom tipu snimanja, os snimanja je okomita ili gotovo okomita te je s obzirom na tako postavljenu os jednostavno odrediti mjerilo snimke (Jurišić i Plašćak 2009).

Osnovni zahtjevi bespilotnih letjelica namijenjenih ovim potrebama su mogućnost izvođenja plana leta s visokom točnošću, autonomija samog leta, mogućnost nosivosti opreme za snimanje i navigaciju te smanjenje vibracija i ostalih vanjskih utjecaja tijekom leta. Bitno je spomenuti i vremenski čimbenik snimanja podatka koji kod bespilotnih letjelica daje realniji prikaz stvarnog stanja na terenu s obzirom na satelitske snimke. Niža relativna visina leta eliminira prisustvo oblaka ili slabe magle na snimkama te omogućuje brzu reakciju i trenutno prikupljanje podataka (Kolarek 2010).



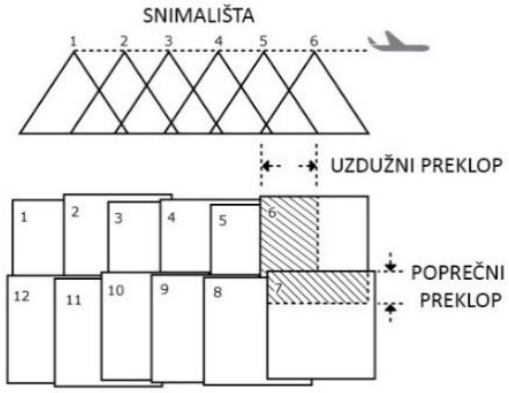

Slika 3.1. Usporedba u prepoznavanju različitih uzoraka – bespilotna letjelica / satelitska snimka (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)

**Stereofotogrametrija**

Fotogrametrija jedne snimke primjenjuje se isključivo na ravnim terenima. U tom slučaju se kod strogo vertikalne snimke dobije fotoplan. Fotogrametrija više snimki naziva se i stereofotogrametrija (Jurišić i Plašćak 2009).

U aerofotogrametriji, položaj s kojeg se snima željeno područje se zove snimalište. Na neravnim terenima primjenjuje se tehnika snimanja koja se naziva stereoskopsko snimanje. Takvo snimanje podrazumijeva snimanje s dva snimališta. Dobivena snimka se zove stereopar, a fotogrametrijska rekonstrukcija s pomoću stereopara predstavlja stereofotogrametriju (Braum 1992).

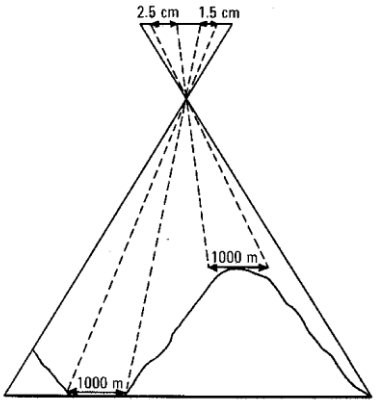



Slika 3.2. Prikaz stereoskopskog snimanja

Izvor:http://www.nrcan.gc.ca/sites/www.nrcan.gc.ca/files/earthsciences/images/photos101/images/E_T1609_image4.jpg (prilagodio autor)

**Perspektiva**

Snimak u svojoj aproksimaciji predstavlja centralnu projekciju. Kod centralne projekcije svaka se točka na objektu preslika na projekcijsku ravninu pomoću zrake, a sve te zrake prolaze kroz točku sjecišta, koja predstavlja centar projekcije (Donassy 1983).




Slika 3.3. Prikaz centralne projekcije

Izvor: http://www.fao.org/docrep/003/T0390E/T0390E50.gif

# 4. Kartografija

Prema engleskoj izreci, slika govori više od tisuću riječi. Ljudi sami po sebi posjeduju veliku sposobnost obrade informacija, to jest interpretaciji vizualnih prizora. Slike precizno prenose informaciju o pozicijama, veličinama i međuodnosima između različitih objekata koji se mogu interpretirati na više razina (Campbell 2007).

## 4.1. Digitalna kartografija

Karte se koriste već tisućljećima, kako bi čovjek imao bolju predodžbu svijeta. Kada govorimo o pojmu karte, ona nije idealna slika svijeta u manjoj veličini, već ju treba shvaćati kao apstraktnu predodžbu nečega što nam je lakše razumljivo. Ta predodžba je stvorena od nekog, tko je pritom birao što i na koji način će prikazati traženo. Ona može biti konkretna, to jest najbliži prikaz stvarnosti ili kognitivna, to jest potencirana predodžba gledanjem same karte (MacEachren 2001). Oblikujući predodžbe mi stvaramo znanje, više nego što otkrivamo postojeće (Lukić 2003).

## 4.2. Digitalna karta

Radi boljeg razumijevanja pojma digitalne karte, potrebno je definirati analognu kartu. Ona je grafička predodžba geografskog prostora.

Osnovne dvije funkcije karte su: korištenje iste kao medij pohranjivanja informacija potrebnih čovječanstvu te korištenje karte kao slike svijeta ta razumijevanje prostornih obrazaca, odnosa i složenosti okoliša (Robinson 1995).

Digitalna karta je karta u vektorskom i/ili rasterskom formatu pohranjena na nositelje pogodne za računalnu obradu. Sadrži softver i sve atribute za prikaz na ekranu monitora ili njeno korištenje (Frančula 2004). Digitalna karta se može definirati kao svaka kartografska vizualizacija u digitalnom formatu koju je moguće prikazati na zaslonu računala ili otisnuti (Lukić 2003).

## 4.3. Vrste razlučivosti

**Prostorna razlučivost** je najviša prostorna frekvencija, koju možemo razlikovati na snimci (Oluić 2001). Drugim riječima, to je veličina svake pojedine točke (eng. pixel) od koje se sastoji snimka, to jest najmanja distanca zabilježena na tlu. Na tlu ta veličina točke predstavlja određenu veličinu u stvarnosti (Bušljeta-Vdović 2006).
**Spektralna razlučivost** opisuje koje sve dijelove spektra pokriva senzor te koliko kanala registrira. Povoljnije je da senzor ima spektralno uske kanale, ali i velik broj kanala, kako bi bili zahvaćeni svi potrebni dijelovi spektra.
**Radiometrijska razlučivost** pokazuje preciznost razlikovanja razina signala koje senzor prima, što ovisi o tehničkim značajkama senzora i analogno-digitalnog konvertera.
**Vremenska razlučivost** predstavlja vrijeme između dva uzastopna snimanja istog područja unutar kojeg je isto područje snimano (Oluić 2001).

## 4.4. Kartiranje i analiza snimaka u poljoprivredi

Zračni snimci pomoću bespilotnih letjelica pružaju nove mogućnosti u preciznoj poljoprivredi te pri donošenju odluka. Određivanje svojstava biljaka analizom snimaka omogućava dobivanje informacija oko zdravstvenog stanja njih samih (Gnädinger i Schmidhalter 2017).

Daljinska istraživanja su široko korištena u raznim područjima poljoprivrede, omogućujući kartiranje raznovrsnih parametara, poput stanja biljaka, svojstava tla, količine vode te rasprostranjenosti korova (Torres-Sánchez i sur. 2013).

Za uspješnost određenog promatranja, snimanje treba biti odrađeno u visokoj prostornoj razlučivosti uzimajući u obzir odgovarajuću vremensku razlučivost radi pravovremenih uočavanja promjena te ga je potrebno potkrijepiti terenskim uzorkovanjem na prethodno određenim lokacijama (Elaraba i sur. 2015).

Prikupljene informacije se mogu koristiti za određivanje stanja usjeva ili nasada te njihovog razvoja. Samim time je moguće: otkrivanje stanja usjeva (zdravstveno stanje i problemi u razvoju) te pravovremeno poduzimanje mjera zaštite; ciljana intervencija zaštite i rješavanje određenih problema, čime se uzima u obzir i zaštita okoliša (manja upotreba kemikalija ujedno znači i manji negativan utjecaj na okoliš); simultano praćenje i upravljanje velikim i raznovrsnim područjima uz niže troškove i manje fizičke radne snage; analizirati promjene usjeva i njihove značajke, ispravno upravljati i optimizirati proizvodnju.

Neki od primjena i mogućnosti korištenja su: dobivanje informacija za donošenje relevantnih odluka u proizvodnji, utvrđivanje stupnja prisutnosti bolesti i štetnika radi provođenja i organizacije biljne zaštite, utvrđivanje strukture korištenja proizvodnih površina i stanja vegetacije, utvrđivanje nanesenih šteta od prirodnih nepogoda, prognoziranje prinosa u

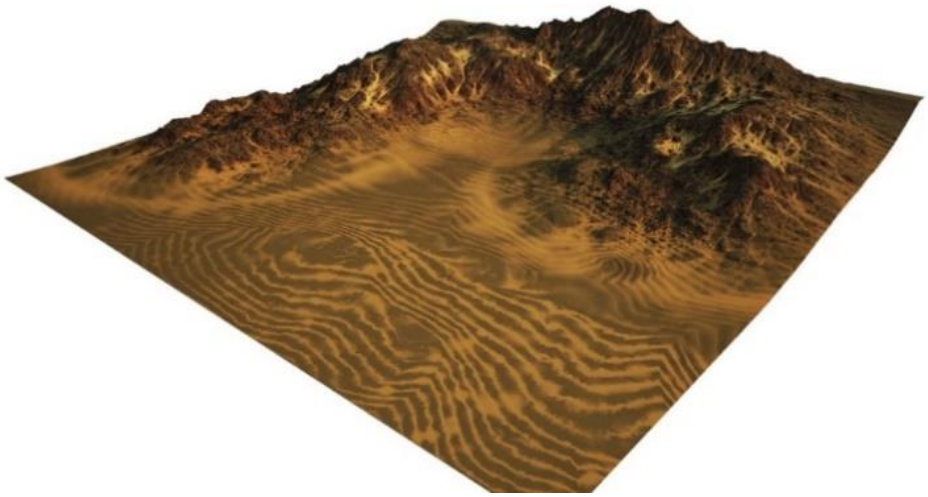
određenim fazama vegetacije, studije tla i odvodnje, utvrđivanje stupnja saliniteta tla, utvrđivanje stupnja intenziteta korištenja zemljišnih kapaciteta, dugoročne studije vezane za primjenu sustava korištenja zemljišta za industrijske i urbane potrebe, proučavanje organizacije zemljišnog prostora (Jurišić i Plašćak 2009).

Prebrojavanje jedinki se smatra korisnom funkcijom u području precizne poljoprivrede. Prebrojavanje biljaka stvara mogućnost boljeg procjenjivanja prinosa. Današnja tehnologija omogućava automatsko prebrojavanje jedinki s pogreškom odstupanja između vizualnog prebrojavanja te automatskog u iznosu od 5 %. Najčešće smetnje u automatskom prebrojavanju su prisustvo korova, loša razlučivost ili mutnost snimka koje mogu utjecati na konačni rezultat (Gnädinger i Schmidhalter 2017).

## 4.5. Digitalni model terena (DTM)

Digitalni model terena (eng. digital terrain model) trodimenzionalni je matematički prikaz površine spremljen u odgovarajućem digitalnom obliku. Izvrsna su podloga za razne projekte i situacije jer omogućuju brzo i točno određivanje koordinata i visina u svakoj točki.

DTM se izrađuje snimanjem pojedinačnih točaka na površini i njihovom obradom kako bi se dobila željena predodžba promatrane plohe. Najčešće metode za prikaz su stringovi, pravilni rasteri i mreže trokuta. Bez obzira na metodu prikaza, rezultat će uvijek odražavati točnost mjerenih podataka (Pribičević i Medak 2003).



Slika 4.1. Digitalni model terena
Izvor: https://static.turbosquid.com/Preview/001165/092/0I/3D-model-terrain_0.jpg

# 5. Geoinformacijski sustavi (GIS)

Sustav se može smatrati kao skup povezanih objekata i aktivnosti koji svojim međuodnosima služe zajedničkoj namjeni. U GIS-u je zajednička namjena donošenje odluka pri upravljanju nekim prostornim aktivnostima. Informacijski sustav s druge strane je skup postupaka provedenih nad skupom podataka kojima se dobiva informacija pogodna za donošenje odluka. Svrha GIS-a je unaprijediti donošenje odluka koje su na bilo koji način u vezi s prostorom (Tutić i sur. 2002).

GIS je informacijski sustav s geokodiranim podacima to jest određenim koordinatama u nekom koordinatnom sustavu. Najčešće je to sustav geografskih koordinata, u određenoj kartografskoj projekciji.

GIS se primjenjuje u rješavanju različitih problema. Pretraživanjem baze podataka može se odgovoriti na pitanje što se nalazi na danom položaju (Frančula 2004).

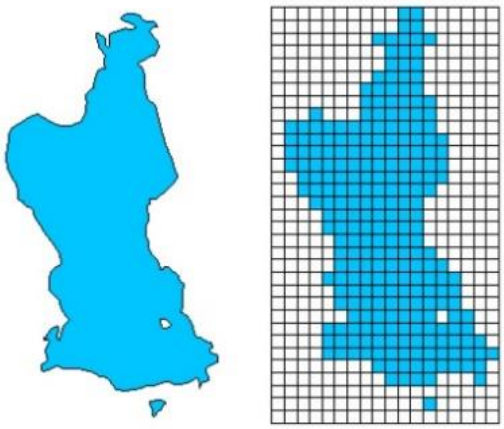
Pribičević i Medak (2003) opisuju geoinformacijske sustave kao računalne sustave za prikupljanje, obradu, analizu i prikaz prostornih podataka kojima su četiri osnovna činitelja hardver, softver, podaci i ljudi.

## 5.1. Vektorski i rasterski podaci

Vektorski set podataka sadrži koordinate točaka, crta i mnogokuta te njihovo prikazivanje vektorskim oblikom u x,y koordinatnom sustavu. Vektorski model pamti parove x,y odabranih koordinata točaka, to jest objekti su definirani ravnom crtom dviju krajnjih točaka. Ako se radi o zakrivljenoj crti, njezini krajevi predstavljaju čvorove, a crta aproksimacija niza točaka zadanih koordinata. Objekti u obliku mnogokuta omeđeni su crtama, odnosno nizom točaka poznatih koordinata (Pahernik 2006).

Rasterski format koristi piksele (eng. picture elements) kao osnovne elemente. Nije fleksibilan i precizan kao vektorski format, jer se svaka točka može predočiti jednim elementom odnosno svaka linija poljem elemenata. Podaci se mogu locirati isključivo prema najbližem elementu rastera. Primjeri izvora podataka u rasterskom formatu su zračne snimke. Svaki element u ovom obliku sadrži i jedinstvenu vrijednost koja je karakteristična za njegov element. Razlučivost podataka može se poboljšati smanjivanjem dimenzija elemenata, ali se time i povećava veličina datoteke, koja u rasterskom formatu nije ekonomična. Postupci prikupljanja, spremanja i obrade rasterskih podataka su za računalo jednostavniji. U tu svrhu koriste se posebne tehnike preklapanja (eng. overlay), zoniranja (eng. buffering) i mrežne analize (Pribičević i Medak 2003).

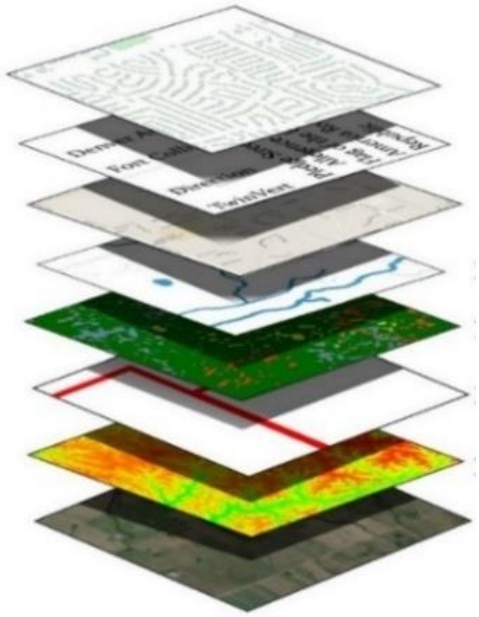
U rasterskom formatu se ne prikazuju točke, crte i površine, odnosno ne postoji logička veza između elementa, već samo svojstva pojedinog piksela (Pahernik 2006).



Slika 5.1. Vektorski model (lijevo) i Rasterski model (desno)
Izvor: http://farm3.static.flickr.com/2295/2199939046_f3bf66d23f_o.gif

## 5.2. Slojevi

U geoinformacijskim sustavima, podaci su podijeljeni u slojeve (eng. layers). Takva podjela omogućuje odvojeni prikaz podataka uz zadržavanje mogućnosti usporedbe i analize podataka iz određenih različitih slojeva. Da bi se slojevi mogli preklopiti, trebaju biti povezani i odnositi se na isto područje (Pribičević i Medak 2003).



Slika 5.2. Koncept slojeva u GIS-u
Izvor: http://www.twinvert.com/sites/default/files/LyerGIS.jpg

## 5.3. Prednosti GIS-a

Upotreba GIS-a promijenila je način korištenja karata. Ona je zamijenila analogne karte i odgovarajuća dokumentaciju. Postupci obrade prostornih i neprostornih podataka su neusporedivo brži, podaci su lako dostupni za ažuriranje te prijenos na druge uređaje. Također, velika prednost je i prijenos podataka većem broju korisnika u kratkom roku. U GIS-u je moguće simulirati različite scenarije te na temelju tih podataka donositi kvalitetne odluke (Pribičević i Medak 2003).

## 5.4. Razlika geoinformacijskih i kartografskih sustava

Analitičke operacije karakteriziraju geoinformacijske sustave. Sposobnost analize prostornih podataka ključna je stavka sustava. To je karakteristika po kojoj se GIS razlikuje od sustava kojima je primarni cilj izrada karata (Frančula 2004).

GIS je alat za integraciju, obradu, analizu i vizualizaciju većeg broja prostornih podataka. Prednosti GIS-a u usporedbi s klasičnom kartografijom su u pohrani većeg broja podataka, mogućnosti prostornih analiza i prikazivanja analiza i informacija u obliku prilagođenome korisniku.

Geoinformacijskim sustavima se ostvaruje organiziranje prostornih podataka u tematske slojeve, što korisniku pruža selekciju podataka potrebnih za obavljanje određenog projekta ili zadaće. On omogućuje prostornim analizama prikaz dinamičkih podataka izraženih kroz promjene u vremenu i prostoru.

Iako su GIS i drugi računalni programi u nekim slučajevima slični, potrebno je naglasiti da se razni programski alati za primjenu u kartografiji ne svrstavaju u GIS. Razlog toga jest što programi i sustavi za automatsko kartiranje u automatiziranoj kartografiji su namijenjeni za izradu karata u digitalnom obliku te ne mogu izvesti prostorne analize (Pavić 2012).

# 6. Bespilotne letjelice

Prema Tehničkom leksikonu (2007), bespilotna letjelica je letjelica bez ljudske posade, koja se upravlja sa Zemlje te se primjenjuje za ponajprije prikupljanje različitih informacija i opremljena je vrlo složenom opremom.

Neki od čestih kratica i naziva koji se koriste za bespilotne sustave su: UAV – unmanned aerial vehicle, UAS – unmanned aerial system, RPAS - Remotely Piloted Aircraft System, a u današnjici se često žargonski nazivaju i dronovima (eng. drone) (Colomina i Molina 2014).

## 6.1. Povijesni razvoj bespilotnih letjelica

Koncept bespilotnog leta donio je Nikola Tesla 1915. godine u svojoj disertaciji gdje opisuje naoružani bespilotni zrakoplov dizajniran za obranu Sjedinjenih Američkih Država (Dempsey 2010). Neposredno tome, dvije godine kasnije, američka vojska je proizvela prve bespilotne letjelice kontrolirane radiosignalom. Tada je započelo neprestano usavršavanje bespilotnih letjelica, isto kao i šira primjena u svim većim vojnim operacijama.

Počeci primjene bespilotnih letjelica u civilne svrhe započinju Przybilla i Wester-Ebbinghaus 1979. godine. Nakon toga, već 1980. godine Wester-Ebbinghaus predstavlja prvi model helikoptera u fotogrametrijske svrhe. Pored konstrukcija u obliku cepelina i balona, za fotogrametrijske potrebe najbolje su se pokazale konstrukcije oblika aviona i helikoptera, koje su nastavile svoj razvoj i do danas doprinijele sve većoj autonomiji i točnosti izvođenja leta (Govorčin i sur. 2012).

Tempo razvoja bespilotnih letjelica odredile su mogućnosti tehnologije, a pod time se podrazumijevaju: žiroskopski sustavi i njihovo povećanje točnosti; sustavi podataka za zrak i njihovo povećanje točnosti; radijski zapovjedni sustavi s povećanjem dosega i zaštitom; radijski i radarski sustavi za praćenje; razvoj slikovne obrade u nekoliko valnih duljina i fuziji; izvršenje prekida radijske veze; radijski, laserski i akustični barometri; GPS sustavi; računala velike brzine i komunikacije fokusirane na mrežni rad; “osjeti i izbjegni” tehnologija (Austin 2010).

## 6.2. Primjene bespilotnih letjelica

Iako korištenje bespilotnih letjelica ima velik udio u vojnom sektoru, u posljednje se desetljeće njihova primjena proširila u znanstvena istraživanja, komercijalne svrhe te zadatke javne sigurnosti, s ciljem prikupljanja podataka i snimaka ugroženih područja, izrade karata, istraživanja, spašavanja, različitog tipa nadgledanja, itd. (Govorčin i sur. 2012).

Vojna upotreba se može podijeliti na pomorsku, kopnenu i zračnu, dok je civilna upotreba raširena u područjima poput poljoprivrede, elektroprivrede, ribarstva, informacijskih usluga, prometa, očuvanja granica, otkrivanju i uništavanju mina, itd. (Pavlik i sur. 2014).

## 6.3. Primjena bespilotnih letjelica u poljoprivredi

Praćenjem poljoprivrednih površina, bespilotnim letjelicama se vrlo lako može odrediti oblik parcele, morfologija terena, gustoća sadnje i sjetve, kao i dijelovi na kojima se zadržava voda (Sito i sur. 2015 prema Lawley i sur. 2015).

Doprinos bespilotnih letjelica se odnosi na sjetvu i sadnju, gnojidbu i zaštitu usjeva i nasada. U praksi, sustav zaštite bilja često nailazi na razne probleme. Primjenom bespilotnih letjelica, površina se može nadzirati te se tako pravovremeno mogu uočiti potencijalna žarišta pojave bolesti i štetnika. Tako je moguće izbjeći nepotrebno nanošenje sredstava na cijeloj površini, već ga je moguće aplicirati lokalizirano, što je s ekološkog stajališta poželjan aspekt. Također, time je moguće ostvariti značajne ekonomske uštede, to jest veću konkurentnost proizvoda na domaćem i inozemnom tržištu (Sito 2016).

Osim prikupljanja podataka u vidljivom dijelu spektra, podaci se skupljaju i u širem dijelu elektromagnetnom spektra, poput bliskog infracrvenog (engl. near-infrared, NIR), koji je vrlo pogodan za praćenje vegetacije. Ova metoda praćenje je jednostavnija, fleksibilnija, vremenski i ekonomski isplativija te je prihvatljivija za očuvanje okoliša, u odnosu na metode praćenja iz traktora. Obradom prostornih podataka u obliku fotografija prikupljenih bespilotnim letjelicama, moguće izraditi digitalni ortofoto (DOF) te digitalni model terena (DTM) koji je koristan za detektiranje udubina u topografiji, koje su potencijal za nakupljanje većih količina vode.

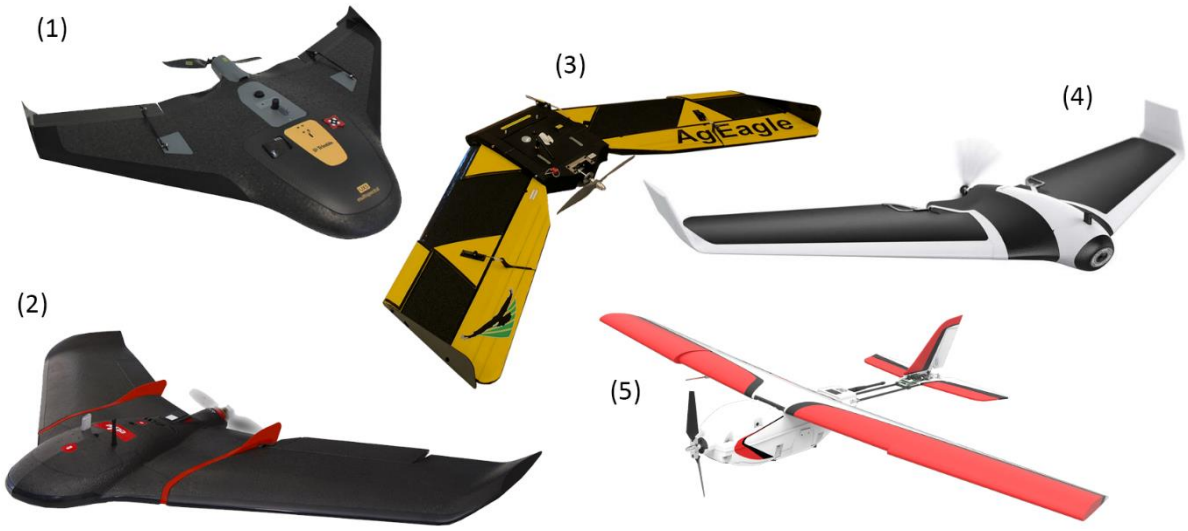
Također, karte vegetacijskih indeksa je moguće uvesti u navigacijski sustav u traktoru te na temelju nje lokalizirano tretirati samo određene dijelove, što znatno utječe na uštedu u potrošnji pesticida i mineralnog gnojiva (Sito i sur. 2016).

## 6.4. Podjela bespilotnih letjelica prema konstrukciji

### 6.4.1. Letjelice s nepokretnim krilima

Konstrukcije bespilotnih letjelica s nepokretnim krilima ili tzv. čvrstokrilne (eng. fixed wing) vrlo su otporne na vanjske utjecaje, a potrebna im je manja količina energije za let te imaju veću nosivost. Negativne strane ovakve konstrukcije su smanjena točnost provedbe predviđenog plana leta zbog veće brzine leta te potreba za uređenim uzletno-sletnim stazama u blizini objekta (Kolarek 2010).

Na tržištu se trenutno nalazi poveći izbor bespilotnih letjelica za potrebe poljoprivrede (za inspekciju, analizu, kartiranje, itd.). Neki od njih su prikazani na slici 6.1.:



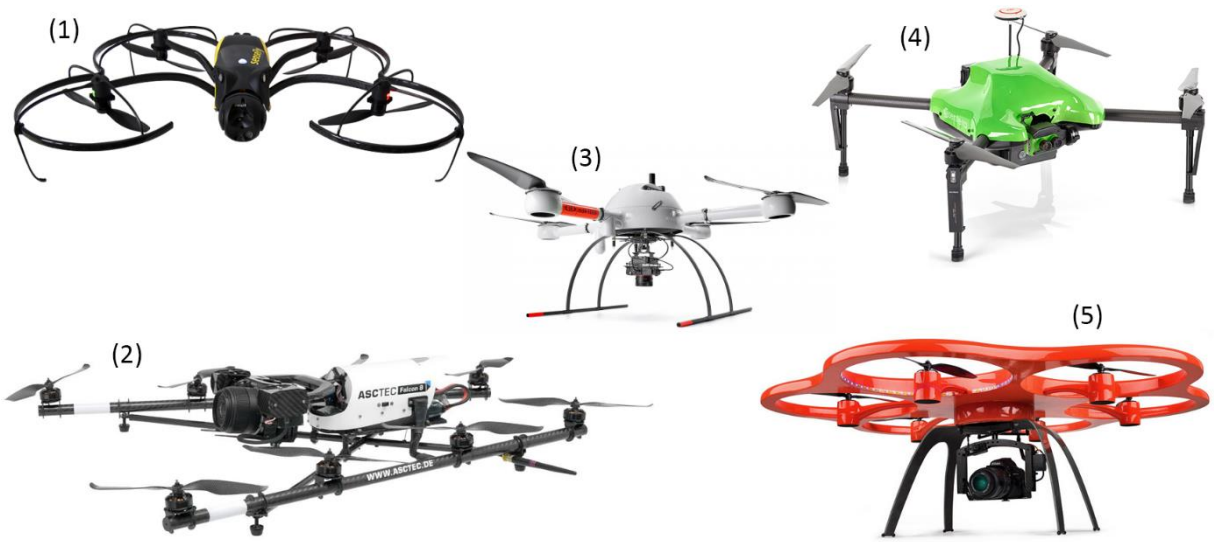

Slika 6.1. (1) UX5 Multispectral (Trimble); (2) eBee SQ (SenseFly); (3) Ag Eagle RX48 (AgEagle); (4) Disco-Pro AG (Parrot); (5) Lancaster 5 (PrecisionHawk)

Izvor: Web izvori: 9.-13. (prilagodio autor)

### 6.4.2. Letjelice s pokretnim krilima

Konstrukcije letjelica s pokretnim krilima ili tzv. rotorima (eng. multi-rotor) nude puno više mogućnosti upotrebe i trenutno su u prednosti nad čvrstokrilnim konstrukcijama. Njihova prednost je mogućnost statičnog održavanja leta te leta vrlo malim brzinama, što rezultira vrlo visokom točnošću u provedbi predviđenog plana leta. Negativne strane leže u manjoj otpornosti na vanjske utjecaje tijekom leta, ali upotrebom inercijskih sustava kod navigacije, uspješno održavaju stabilnost letjelice. One imaju manju autonomiju leta i manju nosivost (Kolarek 2010).

Neke od multi-rotor bespilotnih letjelica s mogućnostima za korištenje u poljoprivredi su prikazane na slici 6.2.:




Slika 6.2. (1) Albris (SenseFly); (2) Falcon 8 (Ascending technologies); (3) mdMapper1000DG (Trimble); (4) Omni AG (Sentera); (5) Aibot x6 (Aibotix)

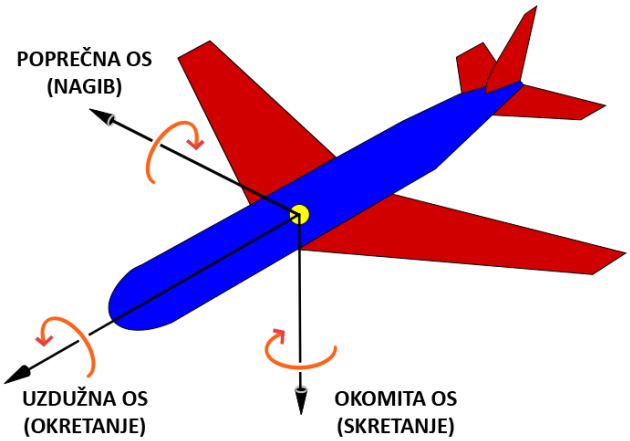
Izvor: Web izvori: 14.-18. (prilagodio autor)

## 6.5. Pozicioniranje, navigacija i kontrola leta

Danas je GNSS (eng. Global Navigation Satellite System) vodeći sustav za geolociranje te je najkorišteniji sustav za određivanje položaja bespilotne letjelice. GNSS prijemnici, zbog svoje konkurentne cijene i malih dimenzija, postali su standard za navigaciju bespilotnih letjelica. Unatoč tome, ponekad može biti teško odrediti točnu poziciju bespilotne letjelice u situaciji kada GNSS trpi smetnje. Zbog navedenog, u današnje vrijeme su dostupne integracije senzora, odnosno dodatan senzor koji daje poziciju i kada GNSS nije dostupan. Najpopularnija integracija je integracija GNSS-a i INS-a (eng. Inertial Navigation System), sustava koji su kompatibilni, a mane jednoga prednosti su drugoga (Pavlik i sur. 2014 prema Molina i sur. 2008).

INS je sustav koji pruža visoku preciznost, ali u malom vremenskom intervalu, dok je preciznost GNSS-a manja, ali je konstantna na globalnoj razini. INS-u je potrebna početna pozicija, kako bi na osnovi akceleracije računao poziciju letjelice u svakom trenu. Za tu potrebu je idealan GNSS. U slučaju da se točnost INS-a pokaže niža od GNSS-a, ponovno se uzima GNSS pozicija kao početna i počinje se računati INS-om. Na taj se način dobiva trenutna pozicija veće preciznosti nego kod samog GNSS-a. U slučaju da je GNSS dulje nedostupan, koristi se INS koji može autonomno dati podatke o poziciji te se letjelica i dalje može navoditi (Pavlik i sur. 2014 prema Jamal 2012).

INS također daje trenutne podatke o visini letjelice te smjeru kretanja. Promjena smjera kretanja letjelice se detektira u tri osi: okomitoj, uzdužnoj i poprečnoj. Pri tome se mjeri uzdužni nagib (eng. pitch), tj. usmjerenost nosa letjelice prema gore ili dolje, zatim skretanje s pravca lijevo ili desno (eng. yaw) te okretanje letjelice oko uzdužne osi (eng. roll) u smjeru kazaljki na satu ili u obrnutom smjeru.




Slika 6.3. Promjene smjera letjelice

Izvor: https://upload.wikimedia.org/wikipedia/commons/thumb/c/c1/Yaw_Axis_Corrected.svg/709px-Yaw_Axis_Corrected.svg.png (prilagodio autor)

INS i GNSS zadovoljavaju većinu potreba navigacije bespilotnih sustava, međutim, pri niskim letovima, gdje je moguća interakcija s reljefom ili objektima, oni nisu dovoljni. Ne postoje dovoljno točni podaci o svim građevina, instalacijama ili visini drveća, jer se radi o promjenjivim čimbenicima. U tom slučaju se bespilotnoj letjelici nadodaje još jedan senzor, koji predstavlja drugu integraciju senzora, integraciju GNSS-a, INS-a i obične kamere (Pavlik i sur. 2014 prema Roberts i sur. 2005).

Sustavi koji koriste običnu kameru za navigaciju nazivamo GVSS (eng. vision based sensor suite). To su sustavi koji se sastoje od običnih kamera koji izvode procese praćenja i detekcije. Te kamere se integriraju s ostala dva senzora kako bi letjelica mogla autonomno izbjegavati prepreke na svom putu. Taj sustav simulira pilota u letjelici, koji se oslanja na svoj vid radi izvršavanja ispravka na svojoj ruti ovisno o vanjskim utjecajima.

Prvi način za ostvarivanje samostalnog leta u slučaju gubljenja radijske veze je ručno upravljanje letjelicom uz registraciju svih potrebnih podataka o trenutnom stanju letjelice koji su dostupni navigatoru i operateru koji upravlja letjelicom. Operator na osnovi informacija i uputa navigatora usmjerava letjelicu na projektirani smjer i registrira snimak na unaprijed definiranoj poziciji.

Drugi način je autonomni let koji se odvija na osnovi unaprijed isplaniranog leta. Ispravljanje pogrešaka tijekom leta se odvija na temelju svih podataka o trenutnom stanju letjelice te planirane putanje. U trenu kada letjelica dostigne željenu poziciju, registrira se zračni snimak. Oba načina upravljanja letjelicom imaju svoje prednosti i mane.

**Prednosti autonomnog leta** su veća stabilnost letjelice, točnija pozicija registracije snimaka, omogućavanje operatoru trenutne kontrole kvalitete pregledom kutova nagiba, pozicije i pokrivanja terena snimkom te ušteda na vremenu snimanja.

**Nedostaci autonomnog leta** su nemogućnost uočavanja i izbjegavanja raznih prepreka prilikom leta (ptice, vodovi dalekovoda, visoki objekti i antene, visoka vegetacija i dr.), ograničenje udaljenosti upravljačke stanice od letjelice (zbog prijenosa velike količine podataka), zakonodavna ograničenja pojedinih država koja onemogućuju dobivanje dozvola za izvođenje takvih letova (Kolarek 2010).

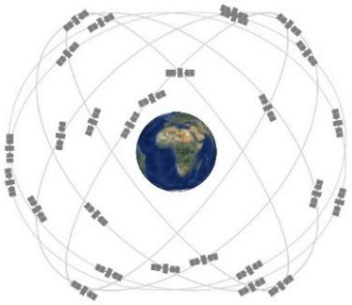
### 6.5.1. Globalni navigacijski satelitski sustavi (GNSS)

Globalni navigacijski satelitski sustavi (GNSS) je termin za satelitske navigacijske sustave (Sat Nav) koji pružaju autonomno geoprostorno pozicioniranje s globalnom pokrivenošću. GNSS omogućuje malim elektroničkim prijamnicima determinaciju njihove lokacije koristeći vremenske signale koje duž linije vida emitira radio sa satelita.

GNSS ima vrlo značajnu ulogu u uspostavi geoprostorne informacijske infrastrukture širom svijeta. U današnje doba, on je vodeći mjerni sustav za pozicioniranje i navigaciju na mnogim područjima primjene (Novaković i sur. 2009).

### 6.5.2. Globalni pozicijski sustav (GPS)

GPS je kratica za Globalni pozicijski sustav (eng. Global Positioning System), koja predstavlja mrežu satelita koja kontinuirano odašilje kodirane informacije te s kojima je omogućeno precizno određivanje položaja na Zemlji. GPS je temeljen na skupini satelita (24 aktivna) Ministarstva obrane SAD-a koji konstantno kruže oko Zemlje. Sateliti odašilju radio signale omogućujući GPS-prijamnicima određivanje položaja na Zemlji (Lapaine i sur. 2004).



Slika 6.4. Svemirski segment globalnog pozicijskog sustava
Izvor: https://www.gps.gov/multimedia/images/constellation.jpg

**Na osnovi primljenih radiovalova – signala koji su odaslani iz satelita, može se odrediti:**
**Udaljenost satelita od točke opažanja**: na osnovi konstantnosti brzine širenja elektromagnetskih valova. Udaljenost se dobiva množenjem brzine širenja elektromagnetskih valova vremenskom razlikom vremena odašiljanja i primanja signala.
**Koordinate položaja satelita**: moguće ih je izračunati u bilo kojem trenutku na osnovi primljenih parametara gibanja satelita koje je satelitski odašiljač odaslao radiosignalima.
**Koordinate točke na Zemlji**: određuju se pomoću prostornog lučnog presjeka, iz izmjerenih udaljenosti satelita od točke opažanja na Zemlji i poznatih koordinata satelita.
GPS mjerenjima izračunavaju se koordinate točke T na površini Zemlje u svjetskom geocentričnom koordinatnom sustavu, poznatim pod kraticom WGS84. Koordinate mogu biti pravokutne X, Y, Z (ishodište takvog koordinatnog sustava nalazi se u geocentru Zemlje) ili $\phi$ (geodetska širina), $\lambda$ (geodetska duljina računata od 0-tog meridijana) i h (elipsoidna visina) (Lasić 2007).

**Segmenti GPS-a**

**Prostorni (svemirski) segment;** u orbiti se koristi 24 aktivna satelita na visini od 20 200 km. Kruže oko Zemlje po približno kružnim orbitama polumjera 26 570 km, obiđu oko Zemlje za 11 h i 58 min. Orbite satelita leže u šest ravnina, koje s ravninom ekvatora zatvaraju kut nagiba i = 55°. Na satelitima se nalazi: radioodašiljač, radioprijamnik, memorija, antene, mikroprocesor za upravljanje satelitskim funkcijama i oscilatori, tj. atomski satovi.
**Nadzorni (kontrolni) segment**: služi za upravljanje cijelim sustavom putem pet zemaljskih stanica. Zemaljske stanice prate položaj i kretanje satelita te interaktivno komuniciraju s njime, periodično odašiljajući nove korekcijske podatke o položaju i putanji u računalo samih satelita.
**Korisnički segment:** ovaj segment čine svi civilni i vojni korisnici koji primaju GPS podatke odaslane iz GPS satelita i pomoću njih određuju svoj položaj, smjer kretanja i vrijeme.

**Sastavni dijelovi GPS prijamnika** su antena, radiofrekventni dio, mikroprocesor, kontrolna jedinica i izvor energije (Lasić 2007).

**Izvori grešaka GPS prijemnika**

**Ionosfersko i troposfersko kašnjenje**: Satelitski signal je usporen kad prolazi kroz atmosferu. GPS sustav koristi princip koji računa prosječno, ali ne točno vrijeme kašnjenja.
**Višestruki put signala**: Reflektiranje GPS-signala od raznih objekata prije primitka u prijemnik stvara dulji put, povećava vrijeme putovanja te tako uzrokuje pogrešku.
**Pogreške sata prijamnika**: Zbog nepraktičnosti atomskog sata u GPS-prijemniku, ugrađeni sat može sadržati male pogreške u vremenu.
**Orbitalne pogreške**: Ove pogreške su poznate kao i pogreške efemerida, to jest netočnosti o izvještaju položaja satelita.

**Broj vidljivih satelita**: Što je više satelita dostupno prijemniku, to je veća točnost. Konfiguracija terena, elektronička interferencija ili npr. gusto lišće mogu blokirati prijem signala te tako uzrokovati pogreške u položaju ili onemogućiti određivanje istog.
Što je bolja vidljivost satelita, to je bolji prijam.
**Geometrija satelita/zasjenjivanje**: nepovoljna geometrija satelita utječe na točnost te nastaje kad su sateliti smješteni na pravcu ili su tijesno grupirani. Idealna geometrija satelita postoji kad su sateliti smješteni pod velikim kutem relativno jedan u odnosu na drugi.
Točnost pozicije može se poboljšati kombiniranjem GPS-prijamnika s diferencijalnim GPS (DGPS) prijamnikom, s kojim se mogu reducirati neke od navedenih pogrešaka (Lapaine i sur. 2004).

### 6.5.3. Diferencijalni GPS (DGPS)

Diferencijalni GPS radi na principu poznavanja točnog položaja referentnih stanica te određivanju pogrešaka u satelitskim signalima. Određivanje pogrešaka se odvija po principu mjerenja udaljenosti do svakog satelita koristeći dolazne signale i uspoređujući te mjerene udaljenosti s udaljenostima izračunanim iz poznatih položaja. Diferencijalnom korekcijom se naziva razlika između mjerene i izračunate udaljenosti za svaki vidljivi satelit. Ona se za svaki praćeni satelit oblikuje u odgovarajuću korektivnu poruku i šalje DGPS-prijamnicima. Te se korekcije primjenjuju u procesu računanja GPS-prijamnika, uklanjajući uobičaje pogreške i povećavajući točnost. Postignuta točnost ovisi o GPS-prijamniku i sličnosti njegove okoline onoj referentne stanice, a izričito o njegovoj blizini od iste.

Prijamnik referentne stanice određuje komponente pogreške te u stvarnom vremenu šalje korekcije GPS-prijamniku. Iste se mogu prenositi preko radio uređaja, preko satelita, ili na neki drugi način (Lapaine i sur. 2004).

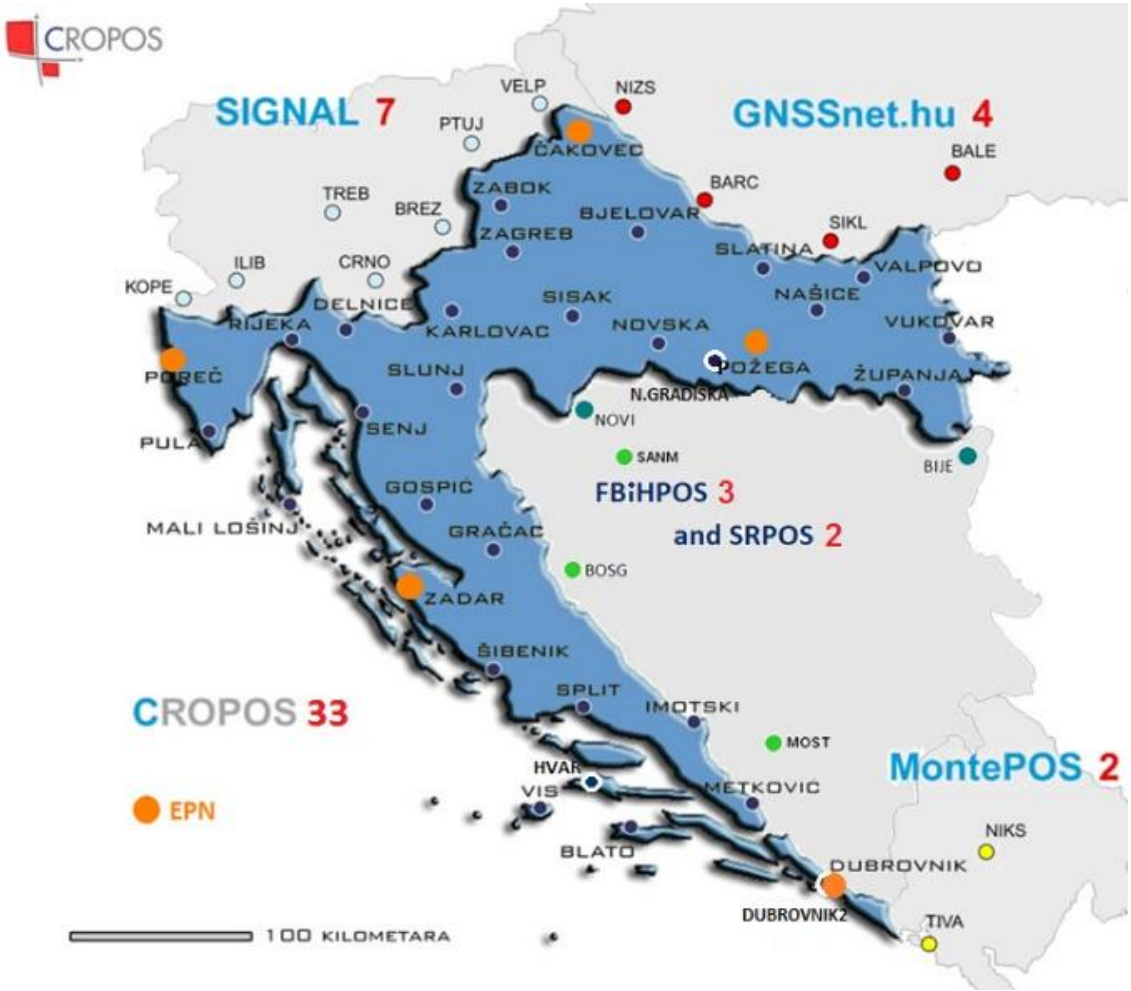
Određeni modeli bespilotnih letjelica imaju mogućnost primanja korekcije od lokalne GNSS baze ili CROPOS-a putem radio modema koji prosljeđuje korekcije prijemniku ugrađenom u bespilotni sustav.

### 6.5.4. CROPOS

CROPOS sustav je državna mreža referentnih GNSS stanica koji je postavio nove standarde određivanja položaja i navigacije u Republici Hrvatskoj te omogućava primjenu modernih metoda mjerenja i moderne tehnologije u svakodnevnom radu. CROPOS sustava osigurava određivanje koordinata točaka na cijelom području države s istom točnošću. Uspostavom sustava Republika Hrvatska je održala korak s ostalim razvijenim zemljama u kojima takvi sustavi postoje nekoliko godina, čime je omogućeno učinkovitije, jednostavnije i ekonomičnije obavljanje terenskih radova.

Primjenom klasičnih metoda mjerenja i prijema korekcijskih podataka samo s jedne stanice, ograničenje rada je u krugu do 10-ak km od bazne stanice (ili manje). Različiti vanjski utjecaji, poput utjecaja atmosfere i ionosfere, širenje signala mjerenja, orbita satelita, konfiguracija terena dovode do ograničenja udaljenosti te problema u radu. Taj nedostatak moguće je riješiti umrežavanjem više referentnih stanica čija udaljenost može biti do 80 km.

CROPOS sustav sastoji se od 33 referentne GNSS stanice na međusobnoj udaljenosti od 70 km, koje ravnomjerno prekrivaju područje države te prikupljaju podatke mjerenja i kontinuirano ih šalju u kontrolni centar. Podaci mjerenja se provjeravaju, obrađuju u kontrolnom centru zajedno uz izjednačenje mjerenja i računanje korekcijskih parametara. Korekcijski parametri dostupni su korisnicima na terenu putem mobilnog interneta i standardiziranog NTRIP (eng. Networked Transport of RTCM via Internet Protocol) protokola (Marjanović 2010).




Slika 6.5. Položaj referentnih stanica CROPOS sustava

Izvor: http://www.cropos.hr/o-sustavu/cropos-drzavna-mreza-referentnih-stanica-republike-hrvatske

## 6.6. Snimanje bespilotnom letjelicom

S obzirom na to da su kamere kod bespilotnih letjelica često smještene izvan tijela same letjelice, često su nezaštićene od vanjskih utjecaja te iz istog razloga moraju biti dovoljno izdržljive i otporne. Konstrukcijski zahtjevi kamere moraju ostati nepromijenjeni u različitim uvjetima (temperatura, atmosferski tlak, vlaga, vibracije i dr.).

Kod autonomnog leta bespilotne letjelice, uz navigaciju i registraciju pozicije snimka, inercijski sustav je glavna potpora za stabilizaciju letjelice. Na osnovi podataka inercijskog sustava, kontrolni sustav letjelice tijekom leta ispravlja sve nagibe dovodeći letjelicu u položaj najbližem horizontalnom. Prilikom neočekivane pojave vjetra tijekom leta, na osnovi GPS-a i inercijskog sustava, letjelica je sposobna sama sebe korigirati te nastaviti s planiranim letom. Sustav stabilizacije kamere ujedno služi i za učvršćivanje kamere, smanjenje mogućih vibracija te konstantan položaj.

Određene vrste letjelica s inercijskim sustavom imaju mogućnost dodatne stabilizacije kamerom po principu žiroskopa. Takav sustav smanjuje utjecaje vanjskih sila te dovodi položaj kamere do strogo željenog položaja. Osim horizontalnog položaja kamera, određeni modeli mogu zadržati bilo koji nagib od vertikalnog do potpuno horizontalnog položaja (0°–90°) (Kolarek 2010).

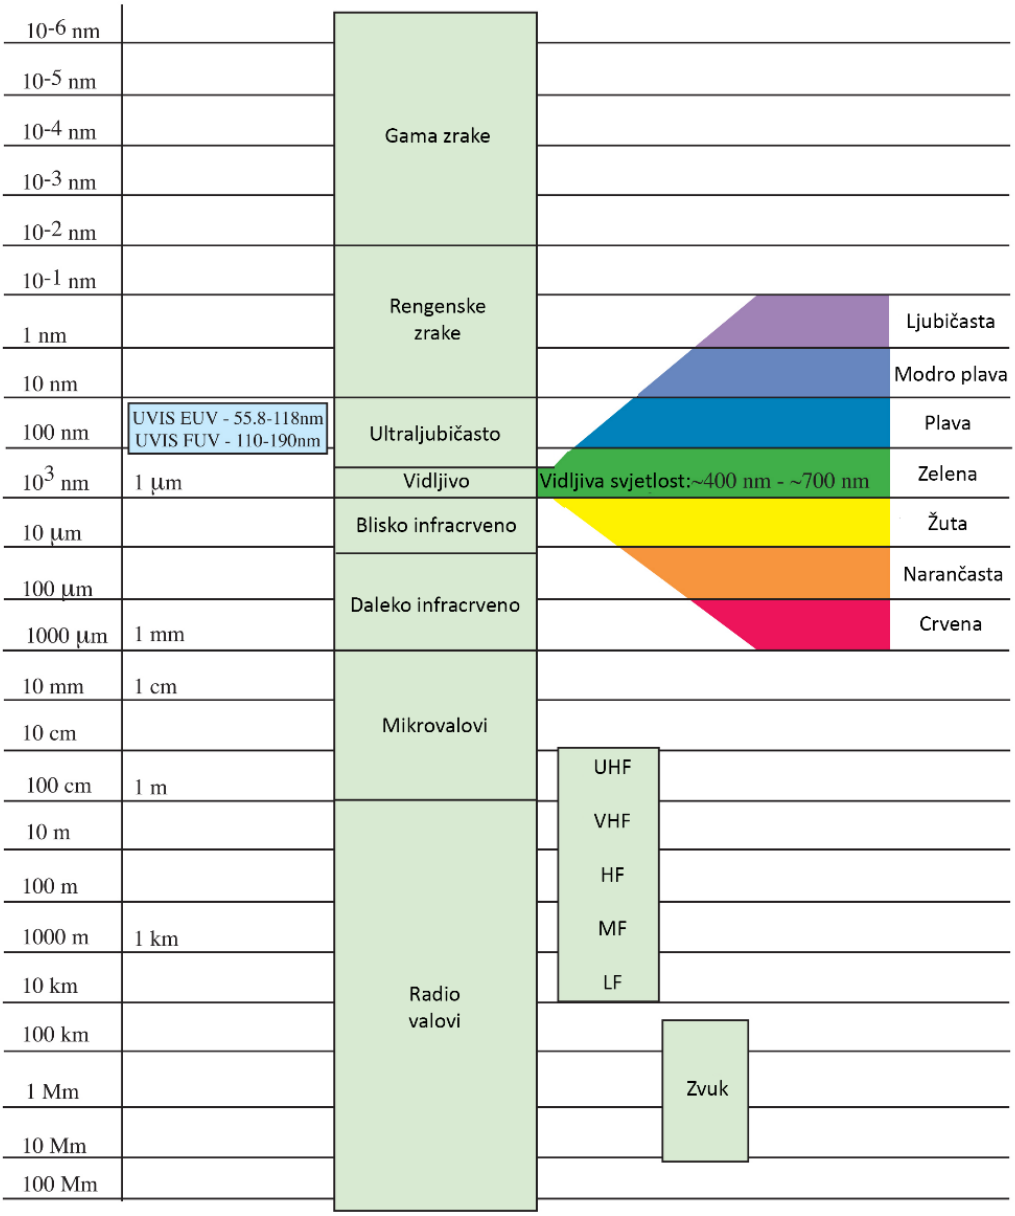
### 6.6.1. Elektromagnetsko zračenje

Elektromagnetsko je zračenje vrsta energije koja se prenosi kroz prostor najvećom mogućom brzinom. Za razliku od drugih valnih pojava, kao što je npr. zvuk, elektromagnetsko zračenje ne zahtijeva tvarni medij za svoje prenošenje i prolazi kroz vakuum (Maljković 1992).

Elektromagnetska energija može se opisati i kao harmonično kretanje u obliku valova koji se pojavljuju u jednakim intervalima vremena. Oni su klasificirani prema valnim duljinama (npr. 0,2 μm) ili spektralnim kanalima (npr. vidljivi kanal 0,4 – 0,7 μm). Ona se također objašnjava i kao tok ili strujanje fotona (virtualne čestice ili kvanti energije), a mogu se opisati valnim duljinama i frekvencijama (Oluić 2001).

## 6.6.2. Elektromagnetski spektar

Raspon elektromagnetskog spektra kreće se od gama zraka koje su kraćih valnih duljina prema dužim radiovalovima. Dijeli se ovisno o energiji, valnoj duljini i frekvenciji, a sve su tri veličine matematički vezane. U daljinskim istraživanjima se koriste vidljivo, infracrveno i mikrovalno (radar) područje elektromagnetskog spektra (Vela 2017).




Slika 6.6. Spektar elektromagnetskog zračenja

Izvor: http://lasp.colorado.edu/home/cassini/files/2016/03/Electromagnetic-SpectrumRev1.jpg (prilagodio autor)

### 6.6.3. Svjetlost

Svjetlošću se naziva elektromagnetsko zračenje valnih duljina 400-700 nm, koje ljudskom oku pobuđuje osjet vida. Svjetlost je transverzalni, linearno polarizirani ravni val koji se u homogenom izotropnom prostoru širi stalnom brzinom. Jakost električnog polja i magnetskog polja svjetlosnog vala jesu sinusne funkcije vremena i prostora.

Optika je područje fizike u kojem se proučavaju i praktično primjenjuju svjetlosne pojave (Paić 1992).

### 6.6.4. Fotometrija

Fotometrija je nauka o metodama mjerenja različitih svjetlosnih veličina. Vid, vidljivost, svjetlina su psihološki pojmovi, dok je svjetlost kao specijalno elektromagnetsko zračenje fizikalni pojam. Zato je fotometrija psihofizičkog karaktera. Sva se mjerenja osnivanju na vidnosti, pa je i cijeli sustav veličina fotometrije specifični vizualni sustav.

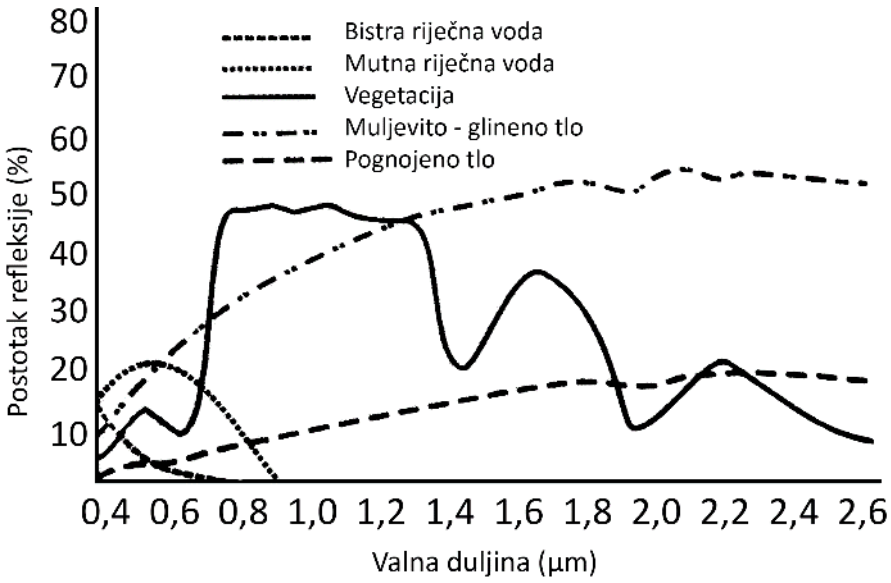
Budući da izvori svjetla zrače i elektromagnetska zračenja bez vidnog učinka (nevidljivi spektar ljudskom oku), potrebno je pri objektivnim metodama uzeti u obzir osim vidnog spektralnog područja (optičkog zračenja) još i susjedna spektralna područja ultraljubičastog i infracrvenog zračenja. Na taj se način uključuje u fotometriju elektromagnetsko zračenje do krajnje granice ultraljubičastog (10 nm) i do krajnje granice infracrvenog zračenja (10 μm) (Kempni 1992).

### 6.6.5. Interakcija Sunčeve energije sa Zemljom

Interakcijom izračene Sunčeve energije s fizičkim objektima u atmosferi i na površini Zemlje proizvodi se elektromagnetska energija. Ona može biti: reflektirana, emitirana, apsorbirana, transmitirana i raspršena.

**Karakteristike refleksije od Zemljinih objekata**

Tlo, voda i vegetacija su tri osnovna medija Zemljine površine koja su od interesa za istraživanje daljinskim metodama. Oni nemaju podjednake karakteristike refleksije i apsorpcije u različitim intervalima elektromagnetskog spektra. Drugim riječima, kada se objekti snime u različitim valnim duljinama spektra, oni će izgledati drugačije u svom tonalnom prikazu na snimci. Razlike se mogu utvrditi na snimkama te se na osnovi toga mogu izdvojiti različiti objekti kao posebne kategorije. Multispektralnom analizom moguće je precizno izdvojiti karakteristične krivulje. One su ovisne o broju interakcija između upadajućeg zračenja te mikro i makrostrukture snimanih objekata (Oluić 2001).




Slika 6.7. Prikaz spektralne refleksije za vegetaciju, tlo i vodu

Izvor: Oluić M. (2001). Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena

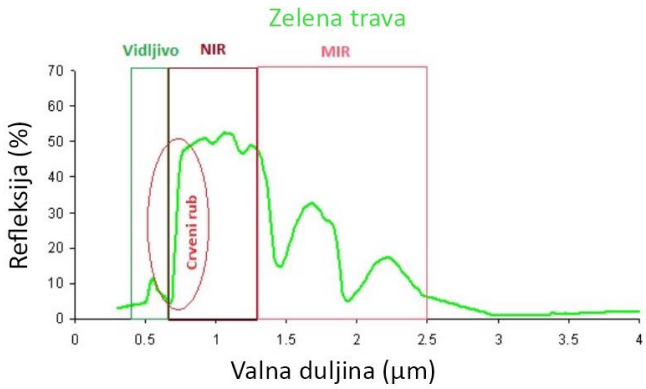
Detektiranje različitih objekata te prepoznavanje boja ljudskim okom je moguće upravo zbog reflektiranog zračenja. Kombinacija različitih valnih duljina koje se reflektiraju od objekta određuju različite boje. Refleksija se smatra udjelom unutar ukupne količine energije koja je pogodila objekt i poprima vrijednost između 0 (nema refleksije) i 1 (potpuna refleksija). Iscrtavanjem vrijednosti refleksije za raspon valnih duljina dobivamo spektralnu krivulju to jest spektralni potpis objekta (Harbaš 2014).

**Karakteristike vegetacije**

Biljke vidimo u zelenoj boji, jer je reflektirana svjetlost u području od 0,5 do 0,6 µm. Jedinstvene karakteristike za vegetaciju kreiraju apsorpcija u vidljivom spektru i refleksija u bliskom infracrvenom spektru. Stupnjem apsorpcije i refleksije definiraju se karakteristike vrsta i tipova vegetacije, gustoća biomase i promjenjive vrijednosti, poput zdravstvenog stanja vegetacije (Oluić 2001).

O karakteristikama refleksije zračenja od vegetacije primarno ovise svojstva, orijentacija i struktura lišća. Sekundarnim se karakteristikama u različitim dijelovima spektra smatraju pigment u lišću, debljina, struktura stanica te iznos slobodne vode u tkivu lišća (Oluić 2001 prema Kannegieter 1987).

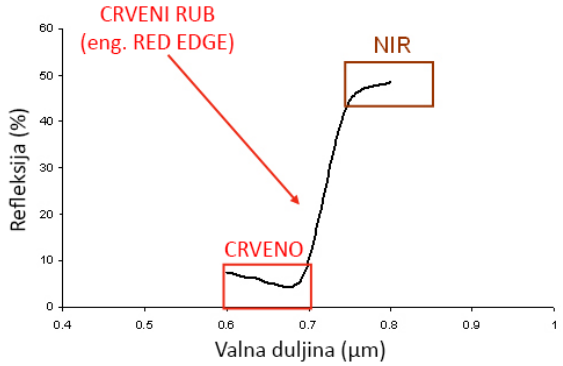
Prema Harbaš (2014) spektar refleksije vegetacije se dijeli na tri dijela i to na vidljivi (od 0, 4 µm do 0, 7 µm), blisko infracrveni (eng. near infrared - NIR) (od 0, 701 µm do 1, 3 µm) i srednji infracrveni dio spektra (eng. middle infrared - MIR) (od 1, 301 µm do 2, 5 µm) kao što je prikazano na slici 6.8.




Slika 6.8. Spektralna krivulja zelene trave

Izvor: Harbaš I. (2014). Računalne metode za detekciju vegetacije (prilagodio autor)

Na slici 6.9. je vidljiv i tzv. „crveni rub“ koji predstavlja nagli skok u spektru između velikog upijanja valnih duljina vidljive crvene i jake refleksije u NIR području (Harbaš 2014).

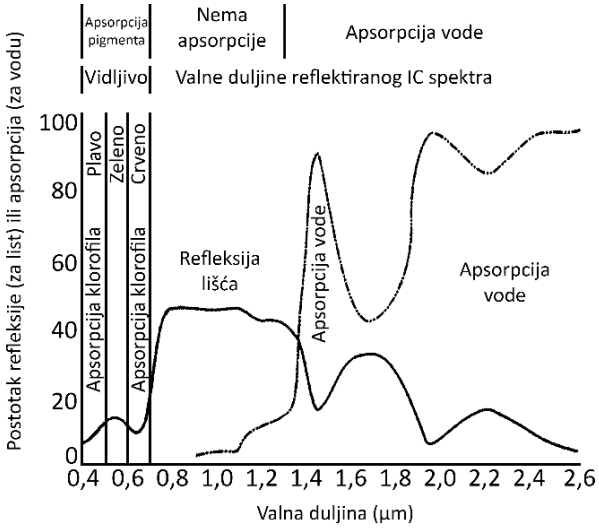



Slika 6.9. Prikaz crvenog ruba (eng. red edge)

Izvor: http://www.eumetrain.org/data/3/36/print.htm (prilagodio autor)

Refleksija plave i crvene svjetlosti manja je od njezine apsorpcije, pretežno zbog klorofila za fotosintezu. U području zelenog spektra, refleksija od vegetacije je viša. Što se tiče infracrvenog područja, apsorpcija je najveća u blisko infracrvenom području te je proporcionalna razvoju lišća ili strukturi stanica. Srednji dio infracrvenog područja refleksija je većinski određena slobodnom vodom u lišću, po principu što je više slobodne vode, lišće ima manju refleksiju. U zreloj fazi pojedinih vrsta (osušenoj) odnosi su promijenjeni, jer lišće u toj fazi najčešće nije zelene boje. S obzirom na to da u toj fazi nema fotosinteze, refleksija će biti povećana u crvenom dijelu spektra. Tada će refleksija biti povećana u srednjem infracrvenom spektru, dok će refleksija u blisko infracrvenom biti smanjena (Oluić prema Shrestha 1991).

Refleksija lišća je tipična krivulja spektralne refleksije za zeleni list. U dodatku je i krivulja za apsorpcije vode. Na slici 6.10. je moguće vidjeti navedeno.



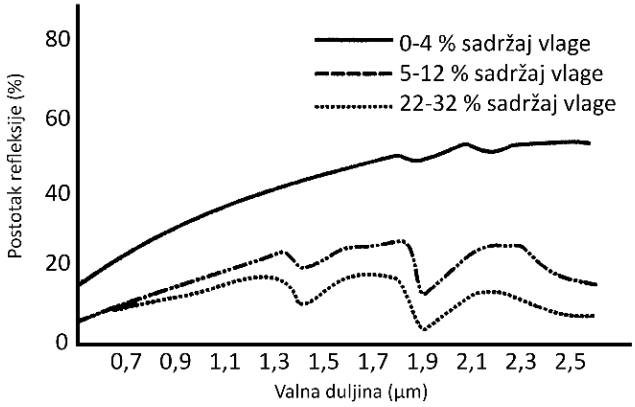

Slika 6.10. Refleksija spektra od zelenog lišća i apsorpcija spektra od vode u intervalu 0,4 – 2,6 μm

Izvor: Oluić M. (2001). Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena

Krivulja refleksije lista ukazuje na četiri područja smanjene refleksije, koja odgovara valnim duljinama 0,4, 0,7, 1,45 i 1,95 μm. 0,4 i 0,7 μm nalaze se u vidljivom dijelu spektra i uvjetovani su apsorpcijom od strane klorofila. Ova dva apsorpcijska kanala približno odgovaraju plavoj i crvenoj svjetlosti. S obzirom na to da su te dvije oduzete od spektra, preostalu vidljivu svjetlost vidimo kao zelenu te od tuda potječe zelena boja zdravog lišća. Apsorpcija vodene pare je izražena u bliskom infracrvenom području. U spektralnim kanalima gdje je naglašena apsorpcija vodene pare, dolazi do smanjenja refleksije svjetla od lišća. Drugim riječima, gdje je apsorpcija vode visoka, refleksija lišća je manja.

**Karakteristike tla**

Organske tvari u pravilu čine tla tamnija, jer manje reflektiraju upadajuće zračenje. Željezni oksidi uvjetuju crvenu boju tala, jer je kod njih veća refleksija u crvenom dijelu spektra.
Voda dobro apsorbira zračenja u bliskom infracrvenom području, pa sukladno tome vlažna tla manje reflektiraju zrake, a više ih apsorbiraju. Različiti načini kultivacije tla također utječu na refleksiju. Nedavno kultivirana tla imaju tamnije tonove kao rezultat vlage u površinskim i pripovršinskim slojevima, pa se isti na snimkama prikazuju tamnijima. Nekultivirana tla, imaju širi spektar tonova nego nedavno kultivirana tla. Sadržaj vlage u tlu direktno utječe na smanjenje refleksije tla, a posebice u vidljivom i blisko infracrvenom dijelu spektra. Suha tla često pokazuju isti spektralni oblik kao i ona sa sadržajem vode, ali vlažna pjeskovita tla pokazuju značajnu promjenu u spektralnoj krivulji. Veću refleksiju pokazuju pješčana tla s manjim sadržajem vlage, što upućuje na zaključak da sadržaj vode to jest vlage u tlu utječe na refleksiju.




Slika 6.11. Krivulja refleksije pješčanog tla

Izvor: Oluić M. (2001). Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena

Veličina čestica utječe na refleksiju tako da čestice većeg promjera imaju manju refleksiju od onih s manjim promjerom. Međutim, taj zaključak se pokazuje ispravan isključivo u laboratorijskim uvjetima, dok je tlo u rahlom stanju s uništenom strukturom. Utjecaj strukture tla na refleksiju je važniji od utjecaja teksture. Tla bez izražene strukture reflektiraju 15-20% više svjetla nego tla s dobro izraženom strukturom.

**Karakteristike vode**

Sunčeve zrake koje dospiju na površinu vode su reflektirane od iste. Ta refleksija izaziva efekt zrcalne površine, ali s obzirom da površina nije posve ravna, već je i valovita, može se javiti efekt difuzne refleksije. Većinski dio zračenja u vidljivom dijelu spektra je prijenosan kroz vodenu površinu, pa će zračenje biti ili apsorbirano ili raspršeno od čestica u vodi.

Duboku i bistru vodu u prirodi, ljudi doživljavaju u plavoj boji, a u slučaju da voda nije bistra, ona poprima zelenkastu boju ili drugačiju, ovisno o sadržaju i količini sedimenata koje nosi. Posve bistra voda ima najveću refleksiju plave svjetlosti, koja se postupno smanjuje prema zelenoj i crvenoj. Komponenta povratno raspršenog Sunčevog zračenja određuje boju vode. Plava boja dolazi od selektivnog raspršivanja kratkih valnih duljina spektra od vodenih molekula i malih čestica. Promjena plave u zelenu rezultat je selektivne apsorpcije od otopljenog materijala radi većih čestica (neselektivno raspršivanje). Iz istih razloga mutna voda pokazat će žućkastu do smeđastu boju.

Voda apsorbira većinu zračenja u blisko infracrvenom području spektra. Unatoč tome, kod mutne vode, dolazi do refleksije zračenja i u blisko infracrvenom području spektra, što se može koristiti kao parametar za odvajanje mutne od bistre vode (Oluić 2001).

### 6.6.6. Uređaji za registriranje elektromagnetske energije

Zajednička karakteristika svih tijela na Zemljinoj površini je emitiranje energije dijela elektromagnetskog spektra određene frekvencije i valne duljine. Sunčevo zračenje je uglavnom uzrok te emitirane energije. Energija ovisi o svojstvu objekta: sastava, boje, sposobnosti apsorpcije Sunčeve energije i sposobnosti emitiranja vlastite energije.

Registriranje promjena u vrsti i količini primljene elektromagnetske energije i njena vizualizacija je srž daljinskih istraživanja. Tako se dobivaju različite informacije o kvaliteti i kvantiteti objekata na Zemljinoj površini kao i njihovim među-odnosima. Pasivni uređaji registriraju reflektirano ili emitirano zračenje objekta. Aktivni uređaji koriste vlastiti izvor energije, koji odašilju prema Zemljinoj površini, otkud i dolazi reflektirani dio koji se prima i registrira. Primjer takvih uređaja su radarski uređaji.

Funkcioniranje senzora se temelji na registriranju, mjerenju i pohranjivanju elektromagnetskog zračenja za daljnju obradu. Spektralno područje koje senzori pokrivaju su vidljivo, infracrveno i mikrovalno. Ono je najčešće podijeljeno na uže dijelove koji se nazivaju spektralnim kanalima (Frančula 2004).

**Ljudsko oko detektira vidljivi dio spektra od 0,4 μm do 0,7 μm, koji u konačnici zauzima mali dio cjelokupnog spektra:**
- ljubičasta: 0,4 – 0,446 μm
- plava: 0,446 – 0,500 μm
- zelena: 0,500 – 0,578 μm
- žuta: 0,578 – 0,592 μm
- narančasta: 0,592 – 0,620 μm
- crvena: 0,620 – 0,7 μm.

**Nakon vidljivog dijela spektra slijedi infracrveni (engl. Infra Red – IR) dio spektra, koji obuhvaća valne duljine od 0,7 μm do 100 μm:**
- reflektirani IR (0,7 – 3,0 μm)
- termalni IR (3,0 – 100 μm).

**Prema broju i širini spektralnog kanala senzori mogu biti:**
**Pankromatski** (mjere refleksije u jednom širokom dijelu elektromagnetskog spektra unutar širokog raspona valnih duljina)
**Multispektralni** (mjere energiju u višekanalnom detektoru i uskom rasponu valnih duljina)
**Hiperspektralni** (sadrže više od sto spektralnih kanala)
**Ultraspektralni** (još su u razvoju) (Vela 2016)

**Fotografska kamera**

Fotografska kamera je dugi niz godina bila najvažniji instrument u daljinskim istraživanjima te se ujedno smatra i kao najstariji senzor za takva istraživanja. Jedna od tehnika izdvajanja reflektiranog zračenja je pseudo-kolor tehnika te je često korištena za ovakav tip senzora (Oluić 2001).




Slika 6.12. Model kamere Sony Nex-7
Izvor: http://www.imaging-resource.com/PRODS/NEX7/ZURFRONT-S.JPG

**Termalna kamera**

Termalne kamere opažaju zračenje u infracrvenom području elektromagnetskog spektra (u granicama od približno 0,9-14 μm). Infracrveno zračenje emitiraju sva tijela ovisno o njihovoj temperaturi, a prema zakonu zračenja crnog tijela, termografija omogućava promatranje okoline bez vidljivog osvjetljenja. Gledani termalnom kamerom, topli predmeti se ističu u odnosu na hladniju pozadinu (Šišić 2013).

Snimanje termalnim kamerama smatra se beskontaktnom metodom mjerenja temperature i njezine raspodjele na površini tijela. Metoda je temeljena na mjerenju intenziteta infracrvenog zračenja s površine promatranog tijela. Elektroničkim putem stvara se termalna slika promatranog objekta u realnom vremenu u termalnoj kameri, a tu se jedan dio spektra elektromagnetskih valova oku nevidljiv mijenja u oku vidljivo područje. Dobivenu sliku moguće je analizirati kao emitiranu toplinsku energiju objekta, snagu zračenja prispjelu na detektor kamere (Petrović 2016).



Slika 6.13. Termalna kamera za bespilotne letjelice model Vue Pro R (Flir)
Izvor: http://www.flir.com/uploadedImages/sUAS/Products/Vue-Pro/flirVuePro-profile.png

**Multispektralna kamera**

Multispektralne kamere su sustavi za dobivanje simultanih snimaka u različitim spektralnim kanalima vidljivog i bliskog infracrvenog spektra. Mogu biti sastavljene od jednostruke ili višestruke kamere, prilagođene za sinkronizirano snimanje (Oluić 2001).



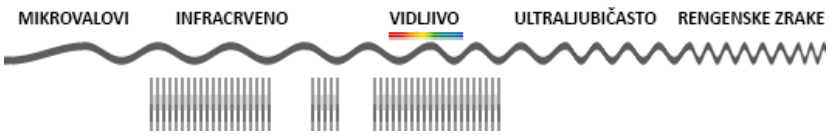

Slika 6.14. Multispektralna kamera za bespilotne letjelice model Red Edge (Mica Sense)
Izvor: https://www.micasense.com/rededge/

**Hiperspektralna kamera**

Daljinsko istraživanje sa hiperspektralnom kamerom podrazumijeva snimanje u puno spektralnih kanala diljem elektromagnetskog spektra, sadržavajući visoku spektralnu razlučivost. Za razliku od njih, multispektralne kamere nemaju tako visoku razlučivost, jer njihovi spektralni kanali obuhvaćaju šire područje. Iz navedenog razloga, hiperspektralne kamere pružaju puno više informacija od multispektralnih.




Slika 6.15. Prikaz kanala u multispektralnom snimanju (prilagodio autor)
http://gisgeography.com/multispectral-vs-hyperspectral-imagery-explained/




Slika 6.16. Prikaz kanala u hiperspektralnom snimanju (prilagodio autor)
http://gisgeography.com/multispectral-vs-hyperspectral-imagery-explained/

Za razliku od kamera koje registriraju energiju u vidljivom dijelu spektra te su postigle vrhunske prostorne razlučivosti u samo nekoliko stotinjaka grama, hiperspektralne kamere i dalje nisu na toj razini. Težina i dimenzije hiperspektralnih kamera su i dalje izazov u njihovom razvoju (Colomina i Molina 2014).




Slika 6.17. Hiperspektralna kamera model za bespilotne letjelice model OCI-UAV-1000
http://www.bayspec.com/spectroscopy/oci-uav-hyperspectral-camera/

**Mikrovalni senzori (radari)**

Radarska snimanja pripadaju aktivnim uređajima za prikupljanje podataka, jer posjeduju vlastiti izvor energije koju odašilju, a reflektirani dio ponovno primaju. Emitirani elektromagnetski val određenog trajanja i frekvencije dolazi do objekta, koji je djelomično reflektiran i dolazi do sustava, gdje se prima, pojačava i obrađuje. Dio odaslane energije je raspršen po površini, a raspršivanje i reflektiranje ovisi o značajkama površine i sastavu objekta, sadržaju vlage u objektu, itd. (Oluić 2001).



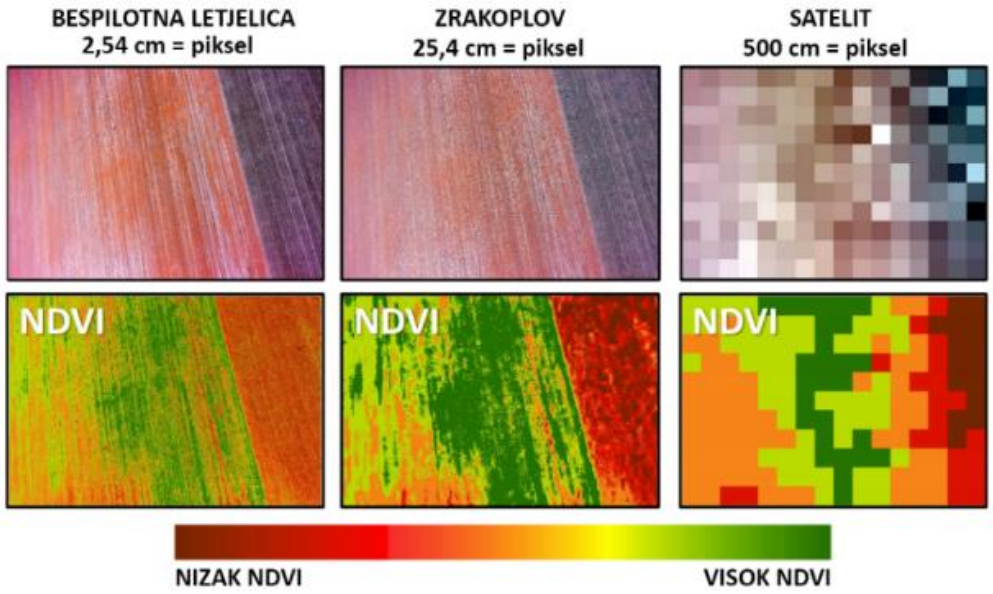
Slika 6.18. Primjer radarske kamere NanoSAR B
Izvor: http://www.soltron.co.kr/data/file/item36_1/3698894957_XBQ3GCF0_45_NanoSAR_B_Data_Sheet.pdf

# 7. Vegetacijski indeksi

Kombinacijom snimki iz više različitih spektralnih područja moguće je dobiti vegetacijski indeks, zahvaljujući karakterističnom spektralnom potpisu biljaka. Velika apsorpcija od strane klorofila se odvija u crvenom i plavom dijelu spektra, a odbija se zeleno svjetlo. Vegetacijski indeksi su bezdimenzionalna radiometrijska veličina, koja se dobiva kombinacijom informacije iz različitih kanala gdje se uglavnom koristi crveni i blisko infracrveni dio elektromagnetskog spektra (Vela 2016 prema Maeda i sur. 2016).

Prema Veli (2016), faktori utjecaja stvaranja indeksa se definiraju kao mjera elektromagnetskog zračenja vegetacije, količina zelenog prekrivača, količina klorofila u biljci, količina biomase, upijanje fotosintetičke aktivnosti radijacije (engl. Absorbed Photosynthetic Active Radiation – APAR) i radijacija indeksa lista.

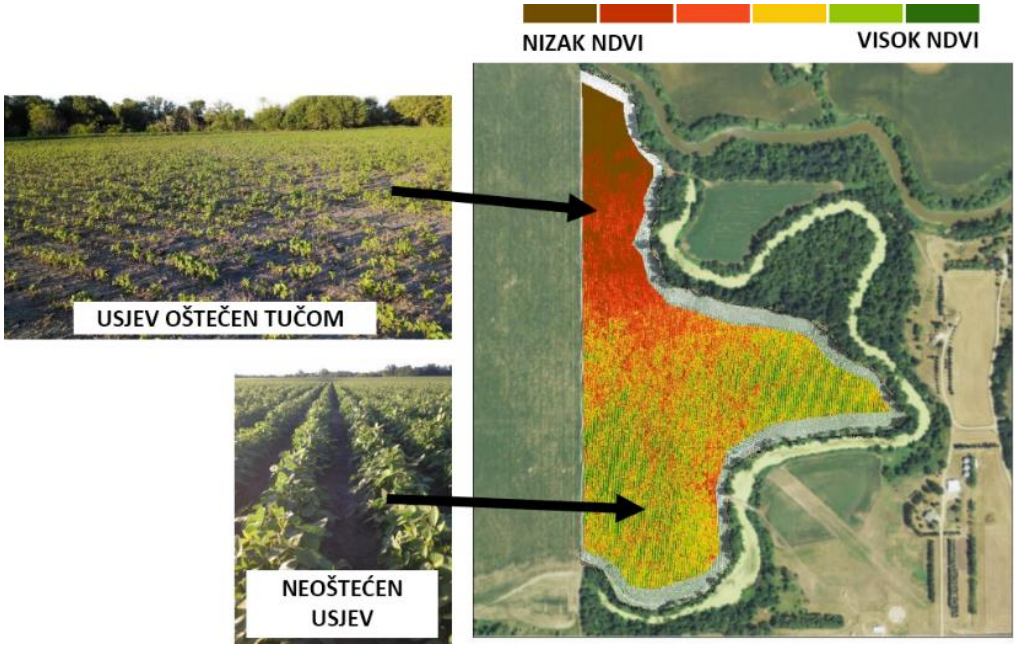
Tijekom prikupljanja podataka, na sam izračun vegetacijskog indeksa utječe nekoliko faktora vezanih uz samu vegetaciju i atmosferske uvjete. Neki od njih su unutarnja struktura lišća pri čemu se prvenstveno misli na količinu klorofila u listu, količina vode u lišću, mikro konstrukcija promatranog područja te tipovi tla. Ovi faktori direktno ukazuju na kvalitetu i raznolikost promatranog područja te eventualnu pojavu oboljenja. Što se tiče osnovnih atmosferskih faktora koji utječu na vegetacijske indekse to su kut upada Sunčevih zraka, kut prikupljanja podataka senzorom te količina vodene pare u zraku. Kako bi se uklonio utjecaj atmosferskih faktora potrebno je posjedovati senzore za njihovo trenutno određivanje čime se ostvaruje preduvjet za kalibraciju prikupljenih snimaka za iste (Sito i sur. 2015 prema Redowan i Kanan 2012).




Slika 7.1. Usporedba primjene vegetacijskog indeksa (NDVI) na snimke snimljene bespilotnom letjelicom, zrakoplovom i satelitom (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)

Vegetacijski indeksi pogodni su za praćenje vremenskih promjena vegetacije, vegetacijskog pokrova, rano otkivanje bolesti nasada, procjene uroda kao i za preciznu poljoprivredu. Nakon snimanja i obrade podataka, kartu vegetacijskog indeksa je moguće uvesti u navigacijski sustav u traktoru te na temelju nje lokalizirano tretirati dijelove nasada s manjim vegetacijskim indeksom u svrhu poboljšanja kvalitete navedenih dijelova nasada, što pridonosi uštedi u potrošnji repromaterijala te poboljšanju uroda (Sito i sur. 2015).




Slika 7.2. Primjena vegetacijskog indeksa u procjeni štete nanesene tučom (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)

## 7.1. Vegetacijski indeks normalizirane razlike (NDVI)

Klorofil najviše upija crvenu svjetlost, a reflektira zelenu. Refleksija u blisko infracrvenom području je jako izražena kod vegetacije te je upravo zato vrlo pogodna za istraživanja. Blisko infracrveno područje je prijelazno područje spektra te je baza za računanje različitih značajki vegetacije to jest indeksa vegetacije koji su alat u postupku detekcije i klasifikacije. Jedan od najpoznatijih indeksa je vegetacijski indeks normalizirane razlike (eng. normalized difference vegetation index) (Harbaš 2014).

Radi određivanja gustoće zelenila na promatranoj površini, potrebno je uzeti u obzir različite valne duljine vidljivog i blisko infracrvenog Sunčeva zračenja reflektiranog s biljaka. U trenutku interakcije Sunčevog zračenja s biljkom pigmenti u listovima (klorofili) apsorbiraju vidljivu svjetlost (od 0,4 do 0,7 μm) za potrebe fotosinteze. Reflektiranje blisko infracrvene svjetlosti je posljedica interakcije sa strukturom stanice lista (od 0,7 do 1,1 μm). Što je veći broj listova, veći je utjecaj na valne duljine svjetla (Rumora i sur. 2016 prema Irish i sur. 2006).

Temeljem blisko infracrvenih i crvenih valnih duljina određuje se relativna količina vegetacije. Ako postoji više reflektirane energije u blisko infracrvenom spektru od one u vidljivom dijelu spektra, tada je vegetacija u tom pikselu gušća (Rumora i sur. 2016).

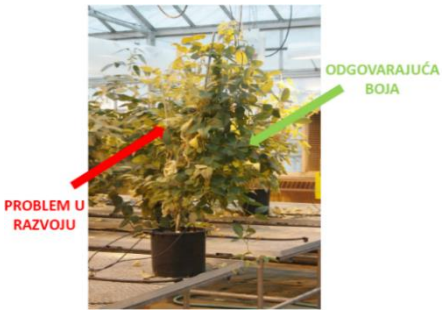
Takvo mjerenje refleksije u blisko infracrvenom i crvenom vidljivom dijelu spektra precizan je mehanizam za određivanje zdravlja same vegetacije. Pomoću indeksa mogu se pratiti sezonske i višegodišnje vegetacijske promjene (Vela 2017 prema Jensen i Lulla 1987).

Na NDVI utječe i velik broj drugih čimbenika, poput atmosferskih prilika, skala snimke, vlage vegetacije i tla, ukupnog pokrova vegetacije, razlike u tipu tla, itd. NDVI ima manju osjetljivost na promjene u samoj količini vegetacije. Povećanjem zelene vegetacije promjene u NDVI-u se sve više smanjuju. Iz tog razloga, prilikom visokih vrijednosti NDVI-a mala promjena u NDVI-u može predstavljati veliku promjenu u vegetaciji. Takav tip osjetljivosti problematičan je u analizi velikog područja s velikom količinom fotosintetski aktivne vegetacije (Rumora i sur. 2016 prema Pilaš i sur. 2014).

Izraz po kojem se računa NDVI iz refleksije svjetlosti u vidljivom i blisko infracrvenom spektru glasi (Vela 2017 prema Carlson i Ripley 1997):

NDVI = (NIR-RED) / (NIR+RED)

gdje je NIR – dio spektra l≈0,8 μm, a RED – dio spektra l≈0,6 μm



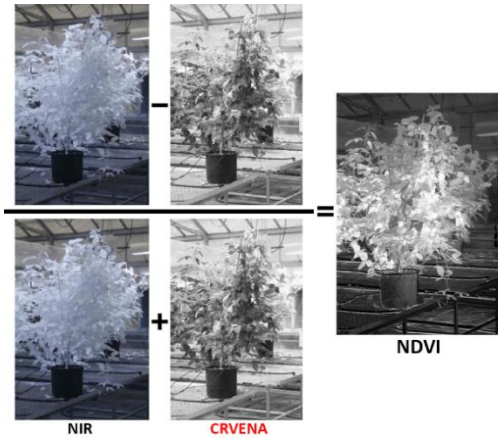

Slika 7.3. Referentna snimka soje (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)



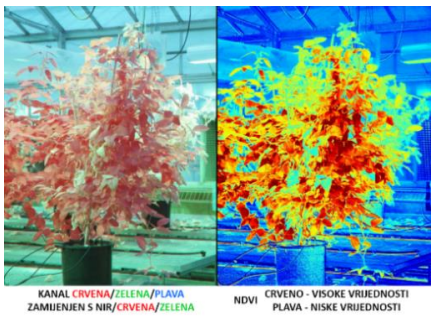

Slika 7.4. Prikaz različitih kanala snimke (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)




Slika 7.5. Ilustriran prikaz izračuna vegetacijskog indeksa normalizirane razlike (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)




Slika 7.6. Prikaz zamijenjenih kanala snimke(pseudo boje) i prikaz NDVI-a s pridodanim bojama kao vrijednostima indeksa (prilagodio autor)

Izvor: Drones in modern agriculture, Roboflight Systems (2014)

## 7.2. Zeleni vegetacijski indeks normalizirane razlike (GNDVI)

Zeleni vegetacijski indeks normalizirane razlike (eng. Green Normalized Difference Vegetation Index – GNDVI) umjesto crvenoga kanala, kao kod NDVI-a, upotrebljava zeleni kanal. Zeleni kanal se nalazi u velikoj korelaciji s vegetacijskim parametrima. Zeleni dio spektra je osjetljiviji na klorofil od crvenog dijela spektra. Iz navedenog razloga, nastao je GNDVI jer pokazuje veću korelaciju s indeksom površine lista (eng. Leaf Area Index – LAI) od NDVI-a (Vela 2017 prema Wang i sur. 2007):

GNDVI = (NIR – GREEN) x (NIR + GREEN)

## 7.3. Vodeni indeks normalizirane razlike (NDWI)

Vodeni indeks normalizirane razlike (eng. Normalized Difference Water Index – NDWI) razvijen je od strane Stuart K. McFeeters-a kako bi maksimizirao refleksiju vode koristeći zeleni dio spektra i smanjujući refleksiju NIR-a na vodenim površinama. Ovaj vegetacijski indeks također koristi prednosti visoke refleksije u NIR dijelu elektromagnetskog spektra za vegetaciju i tlo.

NDWI = (GREEN – NIR) / (GREEN + NIR)

U navedenoj formuli GREEN je zeleni kanal (l≈0,5 μm), a NIR blisko infracrveni kanal. Za vodene površine vrijednosti indeksa su pozitivne, a za vegetaciju i tlo su uglavnom nula ili negativne što daje dobar kontrast pri detekciji vodenih površina. Voda i vegetacija imaju istu refleksiju u vidljivom dijelu spektra, a u infracrvenom dijelu spektra potpuno različitu (Vela 2017 prema McFeeters 1996).

## 7.4. Vegetacijski indeks prilagođen tlu (SAVI)

U područjima s izraženijim površinama tla to jest površinama s manje biljnog pokrova, refleksija svjetlosti u crvenom i infracrvenom dijelu spektra može znatno utjecati na vrijednosti vegetacijskog indeksa. Iz tog razloga je razvijen vegetacijski indeks prilagođen tlu (eng. Soil Adjusted Vegetation Index – SAVI) koji je zapravo modificirani NDVI. SAVI se primjenjuje kada je potrebno otkloniti utjecaj tla na snimci sa smanjenim vegetacijskim pokrovom:

SAVI = ( (1 + L ) x (NIR – RED) ) / (NIR + RED + L)

gdje je L faktor prilagođavanja pozadini lišća koji se upotrebljava za postupni prestanak diferencijalnog crvenog i blisko infracrvenog učinka kroz listove biljaka (Vela 2017 prema Huete 1988).

## 7.5. Poboljšani vegetacijski indeks (EVI)

Poboljšani vegetacijski indeks (eng. Enhanced Vegetation Index – EVI) razvijen je od strane znanstvenog tima MODIS (eng. Moderate Resolution Imaging Spectroradiometer), kako bi se iskoristile sve prednosti senzora. Sličan je NDVI-ju, međutim EVI upotrebljava i plavi kanal kako bi se poboljšala osjetljivost vegetacijske refleksije. EVI je modificirani NDVI s povećanom osjetljivošću na područjima visoke biomase s minimalnim utjecajem tla. Iz razloga što koristi plavi dio spektra, ograničen je na dizajn pojedinih senzora i limitiran na vremenski period (Vela 2017 prema Jiang i dr. 2008):

EVI = G x ((NIR - RED) / (NIR + C1 x RED - C2 x BLUE + L))

gdje su: NIR, RED, BLUE – atmosferski korigirana refleksija; C1 i C2 – koeficijenti koji se odnose na korekciju aerosoli; G – faktor poboljšanja; L – faktor tla. Ovaj indeks je osjetljiviji pri visokim koncentracijama biomase, te poboljšava mogućnosti praćenja vegetacije kroz reduciranje utjecaja pozadine listova (Vela 2017 prema Jensen 1996).

## 7.6. Ostali vegetacijski indeksi

Izbor korištenog vegetacijskog indeksa potrebno je prilagoditi potrebama praćenja biljnih svojstava. Određeni vegetacijski indeksi mogu pružiti više traženih informacija o pojedinom vegetacijskom parametru u odnosu na druge, no unatoč tome, niti jedan vegetacijski indeks koji se danas koristi ne daje savršene rezultate za sve vegetacijske parametre (Sito i sur. 2015).

Popis ostalih najkorištenijih vegetacijskih indeksa:
**DVI,** eng. Difference Vegetation Index
NIR - RED
**GDVI,** eng. Green Difference Vegetation Index
NIR – GREEN
**NG,** eng. Normalized Green
GREEN / (NIR + RED + GREEN)
**NR,** eng. Normalized Red
RED / (NIR + RED + GREEN)
**NNIR,** eng. Normalized Near Infrared
NIR / (NIR + RED + GREEN)
**RVI,** eng. Ratio Vegetation Index
NIR / RED
**GRVI,** eng. Green Ratio Vegetation Index
NIR / GREEN
**GARI,** eng. Green Atmospherically Resilient Index
NIR – [GREEN – (BLUE – RED)] / NIR [GREEN – (BLUE – RED)]

**GEMI,** eng. Global Environmental Monitoring Index

$ń*(1 – 0.25*ń) – [(RED – 0.125) / (1 – RED)];$

$ń = [2*(NIR^2 - RED^2) + 1.5*NIR + 0.5*RED] / (NIR + RED + 0.5)$

**VIgreen (VIg),** eng. Vegetation Index Green

(GREEN – RED) / (GREEN + RED)

**VARIgreen (VARIg),** eng. Vegetation Index Green

(GREEN – RED) / (GREEN + RED - BLUE)

**MSAVI2,** eng. Modified Soil Adjusted Vegetation Spectral Index

$[2*NIR + 1 - √(2*NIR+1)^2 - 8*(NIR – RED)] / 2$

**OSAVI,** eng. Optimized Soil Adjusted Vegetation Index

$[(NIR – RED) / (NIR + RED +L)] * (1 + L); L=0,16$

**GSAVI,** eng. Green Soil Adjusted Vegetation Index

$[(NIR – GREEN) / (NIR + GREEN +L)] * (1 + L); L = 0.5$

**TSAVI,** eng. Transformed Soil Adjusted Vegetation Index

$[a (NIR – a*RED – b)] / [a*NIR + RED – (a*b) + X(1+a^2)]; X = 0,8,\ a= 1,2, b = 0,04$

# 8. Opis mogućnosti i značajki bespilotne letjelice Sensefly eBee

U sljedećem odlomku  kroz primjer jednog modela bit će prikazane karakteristike same letjelice i leta. Odabran je model Sensefly eBee zbog raširenosti na europskom tržištu. Ova letjelica nalazi popularnu primjenu u poljoprivredi zbog raznovrsnih i lako dostupnih kamera kompatibilnih s njom samom.

SenseFly eBee je bespilotna letjelica švicarske tvrtke SenseFly. Većinski je izrađena od fleksibilne pjene te je zbog istog razloga ultra lagana. Ona je u potpunosti autonomna. Ova pouzdana i jednostavna za upravljanje letjelica je spremna za rad u nekoliko minuta od dolaska na lokaciju.



Slika 8.1. Bespilotna letjelica eBee Sensefly
https://geomatika-smolcak.hr/wp-content/uploads/2016/12/eBee_1.jpg

## 8.1. Tehničke značajke

Masa bespilotne letjelice je  690 grama, a raspon krila joj je 96 cm. Pogonjena je litij-polimer baterijom. Brzina letenja kreće se od 40-90 km/h, a autonomija leta doseže 50 minuta. Letjelica ima krila koja se odvajaju od trupa te se s ostalim priborom za rukovanje lagano transportiraju u predviđenom kovčegu.

Rad motora je pouzdan i tih, s obzirom na tehnologiju motora bez četkica (eng. brushless engine technology). Slijetanje je preporučeno na čistini, a ukoliko se radi o ograničenom prostoru, letjelica posjeduje senzore za autonomno pravocrtno slijetanje.

Vrlo važna karakteristika eBee bespilotne letjelice je izmjenjiva kamera to jest opcija nadogradnje različitim vrstama senzora za potrebe korištenja u poljoprivredi.

**Letjelicu sačinjavaju sljedeće komponente:**

- 690 g teška bespilotna letjelica
- integriran autopilot (autonomna navigacija, polijetanje i slijetanje)
- e-Motion softver za planiranje, kontrolu i praćenje leta
- jedan od senzora za snimanje: senseFly S.O.D.A. / Sony WX RGB / Parrot Sequoia / thermoMAP SenseFly / Canon S110 NIR / Canon S110 RE
- automatska kontrola kamere putem autopilota
- USB radiomodem za razmjenu podataka
- daljinski upravljač (u slučaju preuzimanja kontrole)
- dvije baterije
- punjač baterije
- dva propelera
- kovčeg za transport svih komponenti
- letački priručnik




Slika 8.2. Bespilotna letjelica eBee zajedno sa svim komponentama unutar prenosivog kovčega

https://geomatika-smolcak.hr/wp-content/uploads/2016/12/eBee_2.jpg

## 8.2. Planiranje, kontrola i praćenje leta

Za let, to jest za planiranje, simuliranje, praćenje i kontrolu leta, koristi se eMotion softverski program u kombinaciji s bežičnom vezom putem USB radiomodema. Moguće je postaviti željene točke na karti ili ručno unijeti određene koordinate čime određujemo plan leta, a samim time i područje snimanja.

Rukovanje letjelicom je jednostavno, zahvaljujući autonomnosti čitavog sustava. Letjelica je opremljena autopilotom koji kontinuirano analizira podatke integriranog GPS-a i inercijske mjerne jedinice (eng. Inertial Measurement Unit) te pritom uzima u obzir sve ostale aspekte leta. Let je moguće dovršiti i u slučaju gubitka radioveze između prijenosnog računala i letjelice, s obzirom na to da je let isplaniran prije samog polijetanja.

Povratna informacija o tijeku leta, to jest trenutna pozicija letjelice, se dobiva preko ekrana prijenosnog računala. U slučaju željene promjene plana leta za vrijeme istog, navedeno je moguće napraviti jednostavnom kontrolom preko programa. Moguće je zadati povratak na određenu točku, narediti slijetanje ili odraditi dodatne snimke tijekom leta, pored planiranih snimki koje su unaprijed određene. Sve točke su definirane položajem, svojim opsegom, relativnom visinom s obzirom na lokaciju slijetanja te smjerom kruženja.

Učestale promjene visine, vrlo niske temperature i jak vjetar mogu utjecati na autonomiju samog leta. Rješenje za jak vjetar je sustav za prepoznavanje jačine istog te u slučaju prejakog vjetra, letjelica kreće u prizemljenje. Isti princip se koristi i u slučaju kada letjelica nema dovoljno baterije za ostatak leta. U slučaju da se GPS signal izgubi, navigacija više nije izvediva te se letjelica sama prizemljuje.

Kroz nekoliko koraka bit će prikazan način rada u programu eMotion te mogućnosti koje nudi.

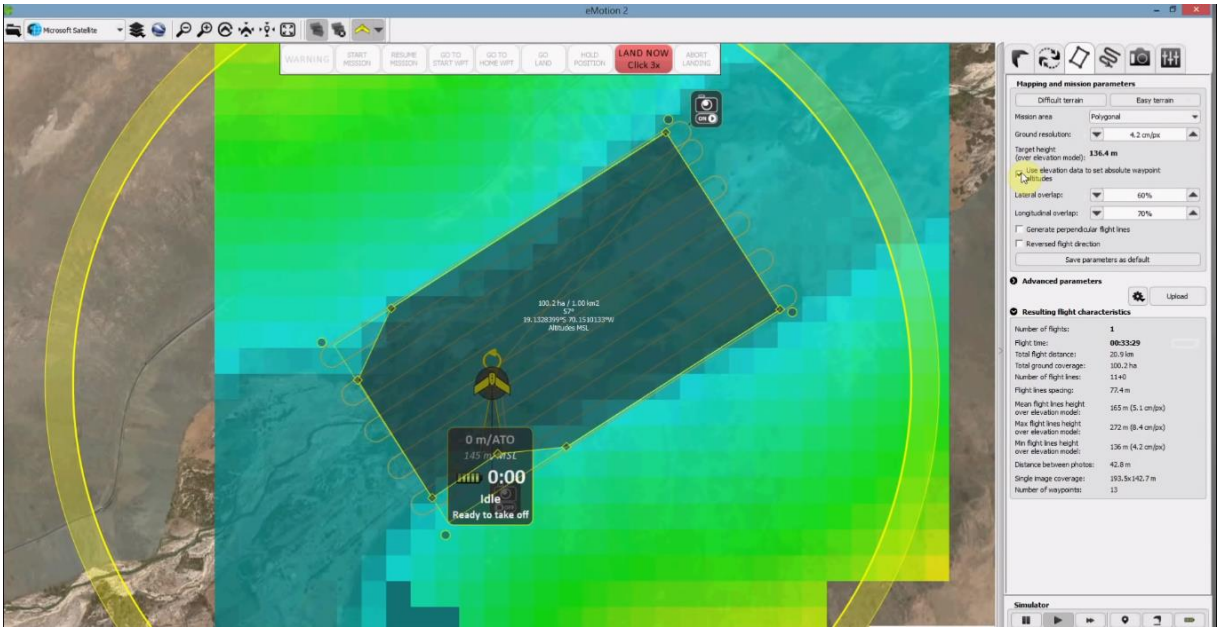
Prvi korak za programiranje leta je odabir područja snimanja, pozicioniranjem graničnih točaka. Poligonskim tipom područja, izbjegava se snimanje nepotrebnog područja.




Slika 8.3. Pozicioniranje i prilagođavanje područja kartiranja

Izvor: https://www.sensefly.com/software/emotion-2.html

Nakon područja snimanja, slijedi odabir razlučivosti u kojoj će bespilotna letjelica odraditi snimanje, to jest koliko će centimetara u stvarnosti predstavljati u konačnici jedan piksel. S obzirom na to da u stvarnosti postoje visinske razlike terena, moguće je učitati visinske podatke kako bi se visina leta prilagodila stvarnoj situaciji.




Slika 8.4. Odabir razlučivosti snimanja i prilagođavanje visine leta visinskim podacima

Izvor: https://www.sensefly.com/software/emotion-2.html

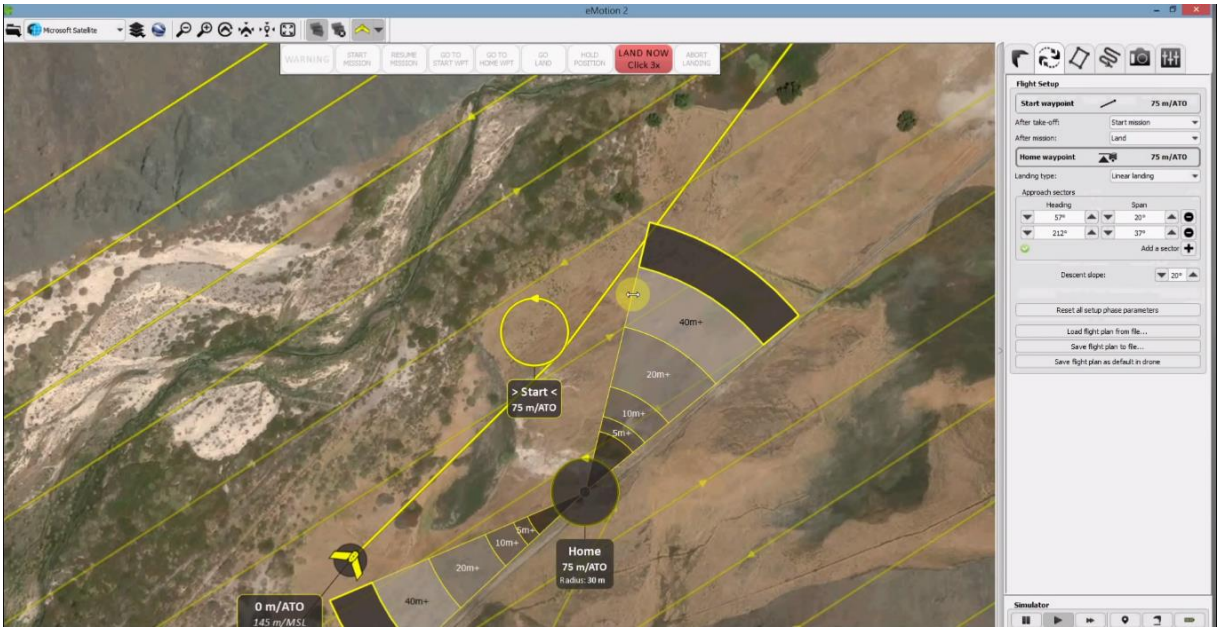
U sljedećem koraku potrebno je učitati plan leta, koji program samostalno određuje prema najefikasnijim putanjama i najmanjem broju okretaja.




Slika 8.5. Prenošenje plana leta

Izvor: https://www.sensefly.com/software/emotion-2.html

Nakon što imamo plan leta, potrebno jest odrediti detalje polijetanja i slijetanja. Smjer polijetanja nam je na izboru, a pod slijetanje možemo odrediti moguće sektore slijetanja.




Slika 8.6. Odabir smjera polijetanja i mogućnosti slijetanja

Izvor: https://www.sensefly.com/software/emotion-2.html

Prije konačnog leta, potrebno je napraviti simulaciju istog po unesenim parametrima.




Slika 8.7. Simulacija leta

Izvor: https://www.sensefly.com/software/emotion-2.html

Postoji još jedna mogućnost provjere simulacije leta, a to je u 3-D modelu, koristeći platformu Google Eartha. Na ovaj način možemo vidjeti u kojem trenu bespilotna letjelica mijenja svoju visinu radi određene razlučivosti te podudara li se to s planiranim.




Slika 8.8. Provjera plana leta u 3-D modelu (Google Earth)

Izvor: https://www.sensefly.com/software/emotion-2.html

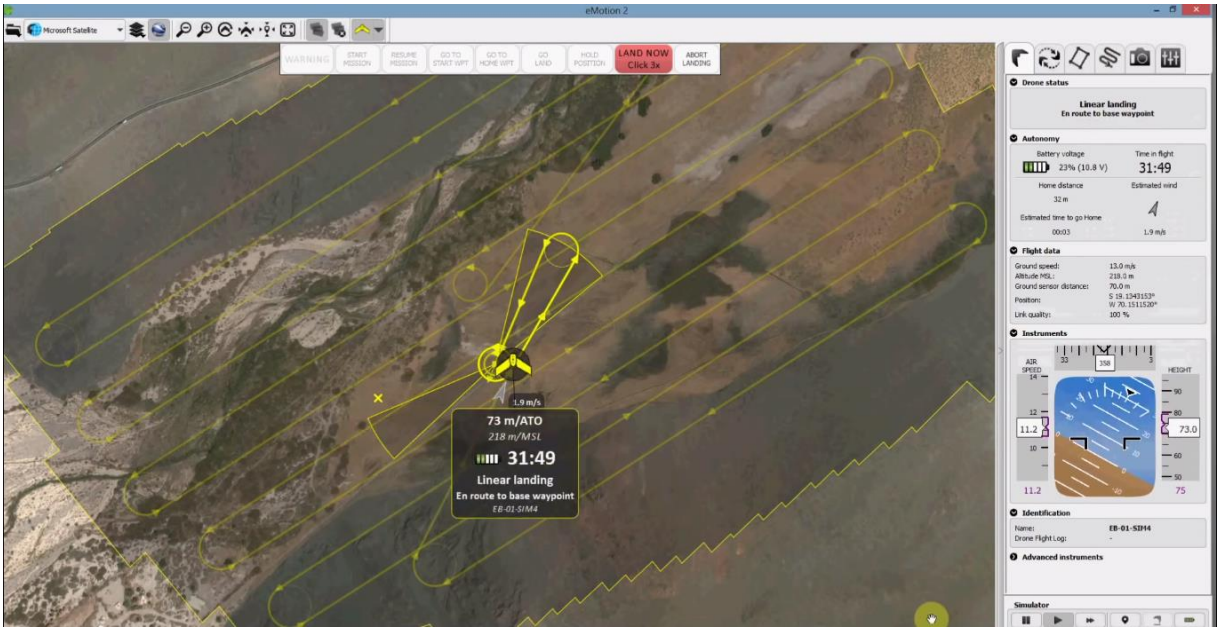
Na slici 8.9. je prikazan let u tijeku. Na sučelju su vidljivi parametri letjelice i leta, poput preostalog kapaciteta baterije, trajanje leta, smjer vjetra, brzinu kretanja, predviđeno vrijeme za kraj leta, trenutnu geografsku širinu i dužinu, itd. U ovom trenu je moguće mijenjati parametre leta, to jest izmijeniti ga za vrijeme njegovog trajanja.




Slika 8.9. Prilagodba plana leta tijekom istog i provjera parametara na sučelju

Izvor: https://www.sensefly.com/software/emotion-2.html

U konačnici, odvija se slijetanje letjelice. Ono je automatsko, a uz detekciju jačine i smjera vjetra, odabire se sektor slijetanja.




Slika 8.10. Automatsko slijetanje uz detekciju jačine vjetra i odabir sektora slijetanja

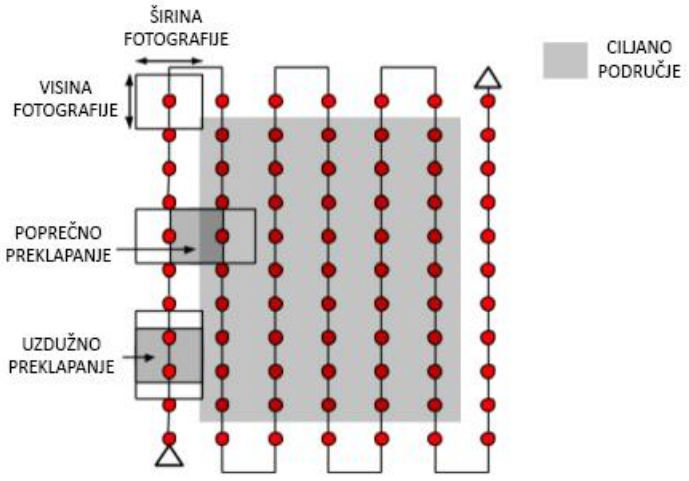
Izvor: https://www.sensefly.com/software/emotion-2.html

## 8.3. Mogućnosti snimanja

Snimanje se može obaviti na nekoliko načina:
1) Sustavno snimanje duž linije leta, na principu preklapanja. Pri kartiranju je ovaj način vrlo pogodan.
2) Snimanje se može obaviti samo na unaprijed označenim točkama, u trenu kada se letjelica nalazi iznad željene lokacije. Prikladno je za snimanje određenih i manjih područja.
3) Snimanje nije određeno unaprijed, već se odvija pravovremeno, u trenu preleta iznad određene točke, na naredbu operatora, preko eMotion sučelja.

U trenu kad se letjelica nalazi iznad tražene pozicije i fotografira, letjelica se dodatno stabilizira prekidom rada motora kako bi se postigla maksimalna kvaliteta fotografije bez neželjenih vibracija.

Standard preklapanja koji je preporučen je minimalno 75% uzdužnog preklapanja te minimalno 60 % poprečnog preklapanja.
Za potrebe poljoprivrede, to jest mogućnosti neravnog terena, preporučuje se minimalno 85% uzdužnog preklapanja te minimalno 70 % poprečnog preklapanja. Također se preporučuje da se fotografije snimaju na većim visinama radi poboljšavanja konačnih rezultata.




Slika 8.11. Definiranje ciljanog područja i preklapanja
Izvor: Uputstva za korištenje - Pix4Dmapper 4.0 (2017) (prilagodio autor)

**Serijski senzori kompatibilni s letjelicom**

**Sony WX (RGB)**

Standardna RGB (eng. red/green/blue) kamera razlučivosti 18.2 megapiksela. Koristi se za vizualnu inspekciju, kartiranje 3D modela, brojanje jedinki.




Slika 8.12. Kamera: model WX RGB

Izvor: https://www.sensefly.com/uploads/contentElements/xw.png

**Canon S110 (NIR)**

Prilagođena Canon S110 kamera koja funkcionira u NIR (eng. near-infrared) području. Modificirana je tako da je u potpunosti prilagođena autopilotu letjelice. Predviđena je za daljinsko istraživanje svojstva tla, vlage tla, detekcija problema u razvoju, detekciju biljnog stresa, upravljanje vodnim režimom, analizu erozije, brojanje jedinki.

**Canon S110 (RE)**

Prilagođena Canon S110 kamera koja radi u RE (eng. red-edge) području. Namijenjena je za detekciju biljnog stresa, upravljanje vodnim režimom, brojanje jedinki, itd.

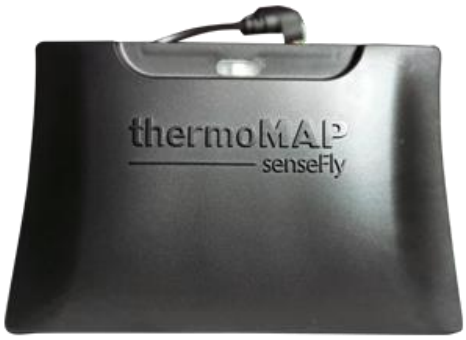



Slika 8.13. Kamera: model S110 NIR

Izvor: https://www.sensefly.com/uploads/contentElements/s110nir_03.png

**ThermoMAP SenseFly (IR)**

Termalna kamera koja radi u infracrvenom području. Namijenjena je za fiziološku analizu, određivanje rasporeda navodnjavanja, analizu funkcionalnosti sustava za navodnjavanje, evaluaciju zrelosti, predviđanje prinosa, ocjenjivanje funkcionalnosti solarnih panela, itd.




Slika 8.14. Kamera: model thermoMAP

Izvor: https://www.sensefly.com/uploads/contentElements/thermomap3.png

**Parrot Sequoia**

Multispektralna višesenzorska kamera proizvođača Parrot. Snima s četiri senzora u NIR i RE području sa 1.2 megapiksela i također s jednim od 16 megapiksela u RGB području. S gornje strane ima senzor za sunčevu svjetlost, kako bi se adekvatno kalibrirala snimka. Sadrži unutarnju memoriju od 64 gigabajta te se može konfigurirati preko bežične veze. Namijenjena je za sve navedene primjene prijašnjih NIR i RE senzora, osim za brojanje jedinki.



Slika 8.15. Kamera: model Parrot Sequoia

Izvor: https://www.sensefly.com/uploads/contentElements/sequoia-web.png

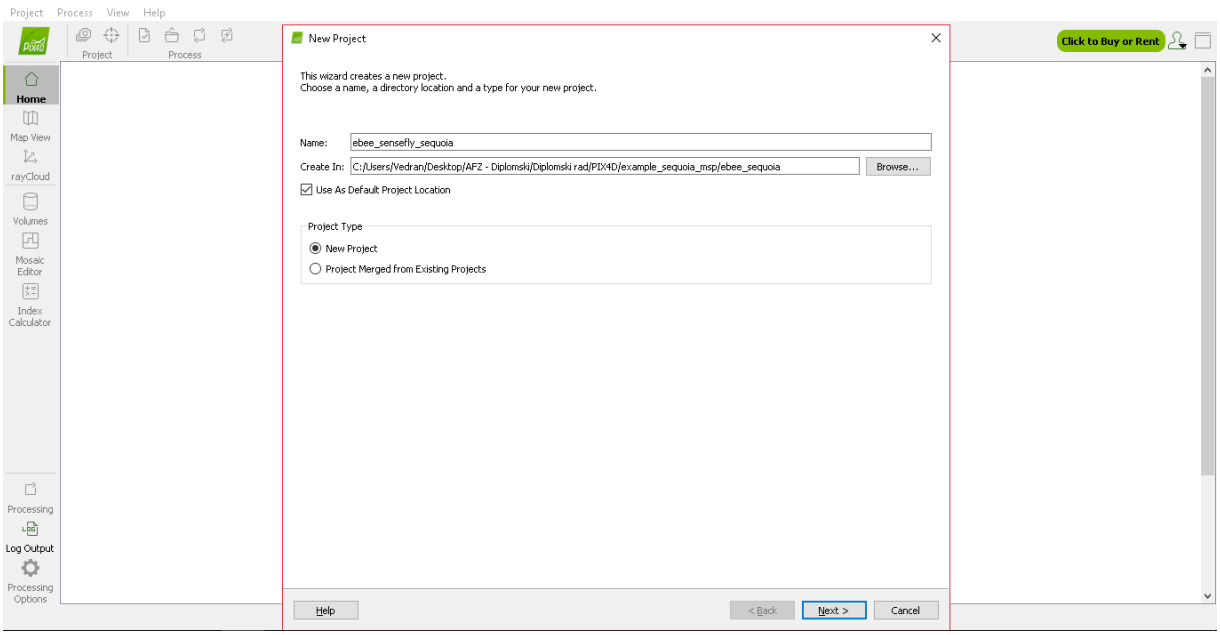
## 8.4. Obrada podataka

Za fotografije snimane sa SenseFly bespilotnim letjelicama, predviđeni su Pix4Dmapper i Pix4Dag programi. Također, određeni formati datoteka kompatibilni su s mnogim programima, kao što su: ESRI ArcGIS, GlobalMapper, Quantum GIS, Erdas Imagine, Geomedia Quick Terrain, I-Site Studio, itd.

Za demonstraciju mogućnosti, korišten je Pix4Dmapper Pro 4.0.21 sa skupom podataka prikupljenih sa Sequoia Parrot senzorom (Green, Red, Red edge, NIR) te s bespilotnom letjelicom Sensefly eBee. Korištene su snimke pružene od strane PIX4D-a na službenim stranicama, snimljenih u Švicarskoj (Lausanne). Učitane su 712 snimke, razlučivosti 1280x960 piksela. Let je odrađen na visini od 106 m te je prosječna veličina 1 piksela 10.66 cm u stvarnosti.

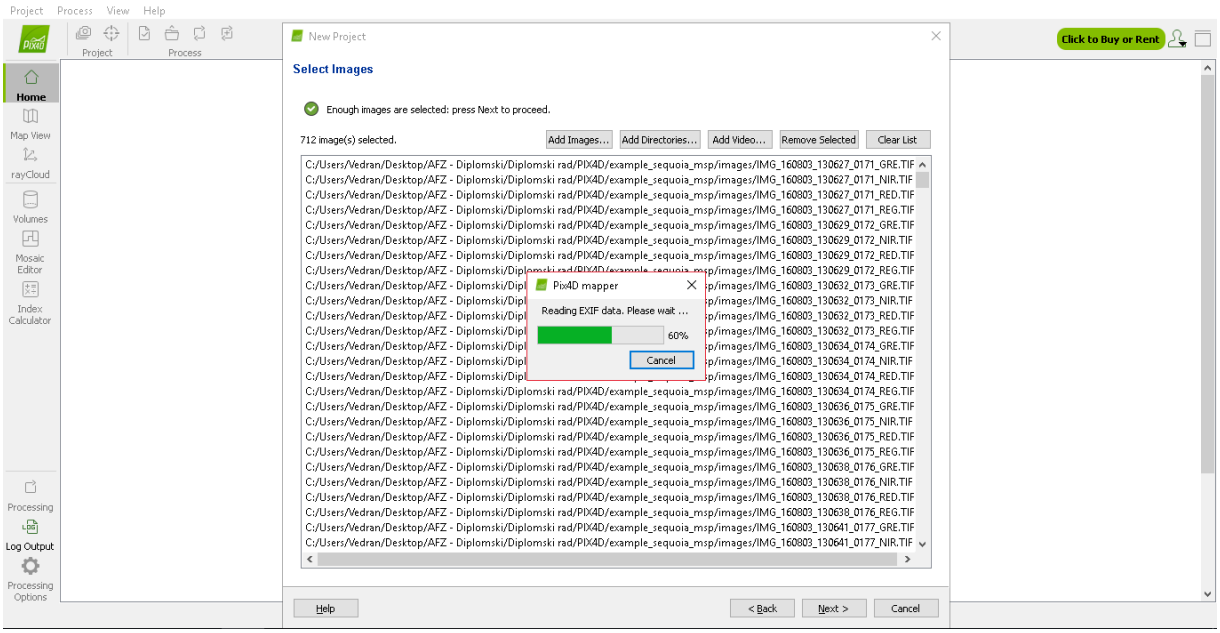
Bit će prikazati koraci obrade, radi dobivanja karte refleksije (eng. reflection map), karte vegetacijskog indeksa (eng. vegetation index map) te karte za apliciranje promjenjivom količinom (eng. variable rate application map).

Početni korak kod obrade podataka je otvaranje novog projekta. Nakon odabira imena projekta i lokacije spremanja podataka, potrebno je odabrati željene snimke za obradu. S obzirom na to da multispektralna kamera Sequoia snima u različitim područjima, svaka je snimka zasebno spremljena.




Slika 8.16. Otvaranje novog projekta

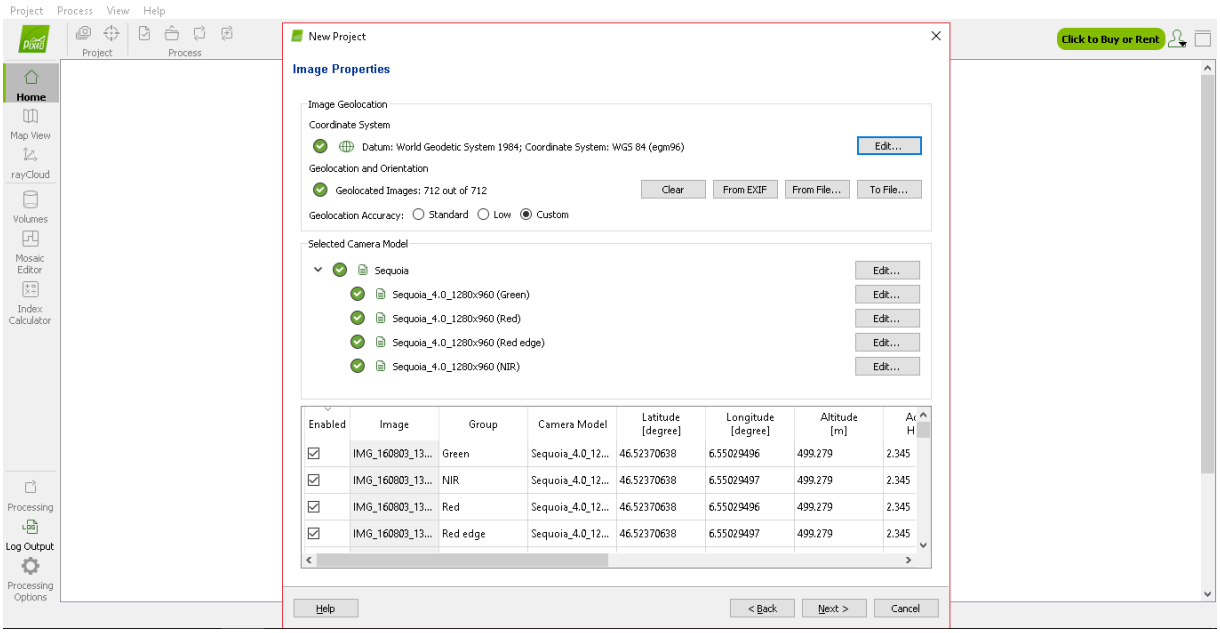
Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017




Slika 8.17. Učitavanje podataka

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

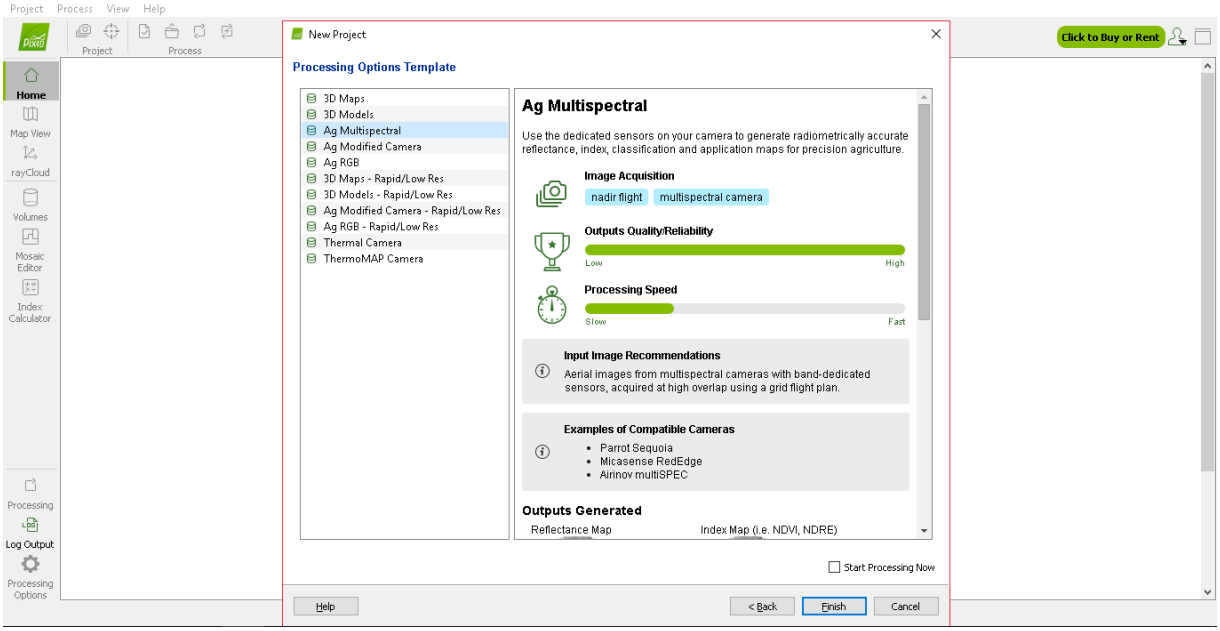
Po učitavanju, program automatski prepoznaje model kamere s kojim je snimanje obavljeno te područje spektra u kojem je obavljeno. Nakon potvrde učitanog, potrebno je odabrati željeni koordinatni sustav te mjernu jedinicu.




Slika 8.18. Svojstva učitanih podataka

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

Program nije samo platforma za potrebe poljoprivrede. Zato je potrebno odabrati neki od ponuđenih predložaka za potrebnu svrhu. Odabran je Ag Multispectral, a neki od ostalih ponuđenih su: 3D Maps, 3D Models, Ag Modified Camera, Ag RGB, Thermal Camera, itd.




Slika 8.19. Odabir predloška rada

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

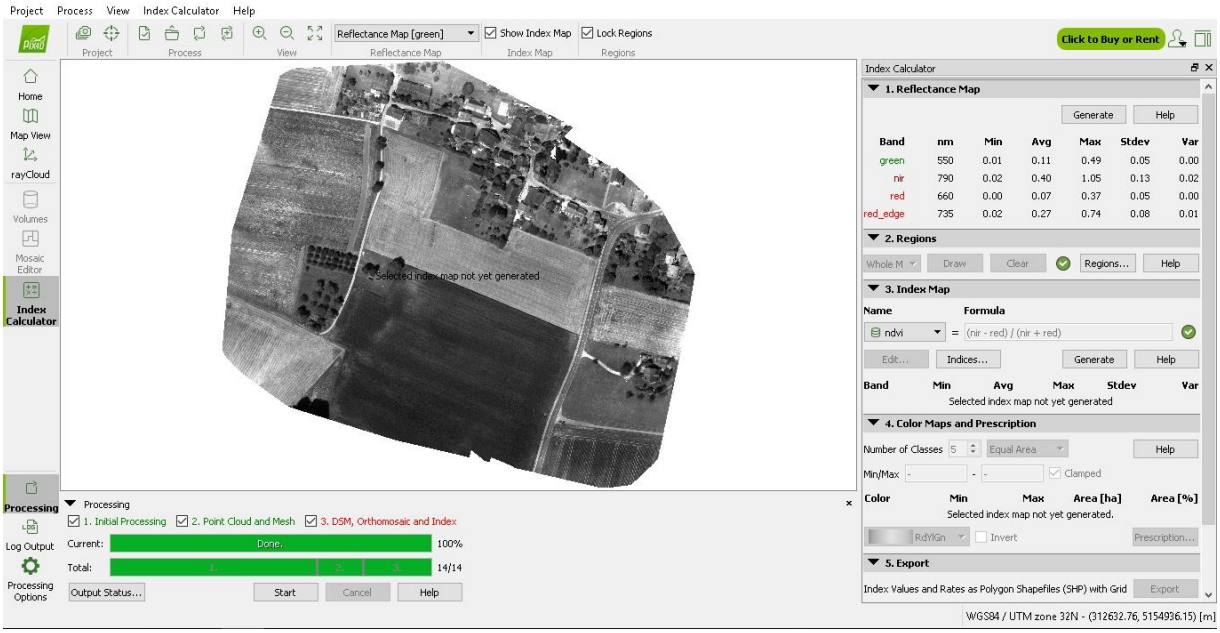
Po odabiru, otvara se satelitska snimka, zajedno s točkama na kojima su snimke obavljene. U ovom trenu, potrebno je obraditi snimke, to jest procesirati ih u kartu. Na brzinu automatskog procesiranja utječe količina snimki, dostupna radna memorija računala, snaga procesora, itd.




Slika 8.20. Prikaz georeferenciranih točaka na satelitskoj snimci

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

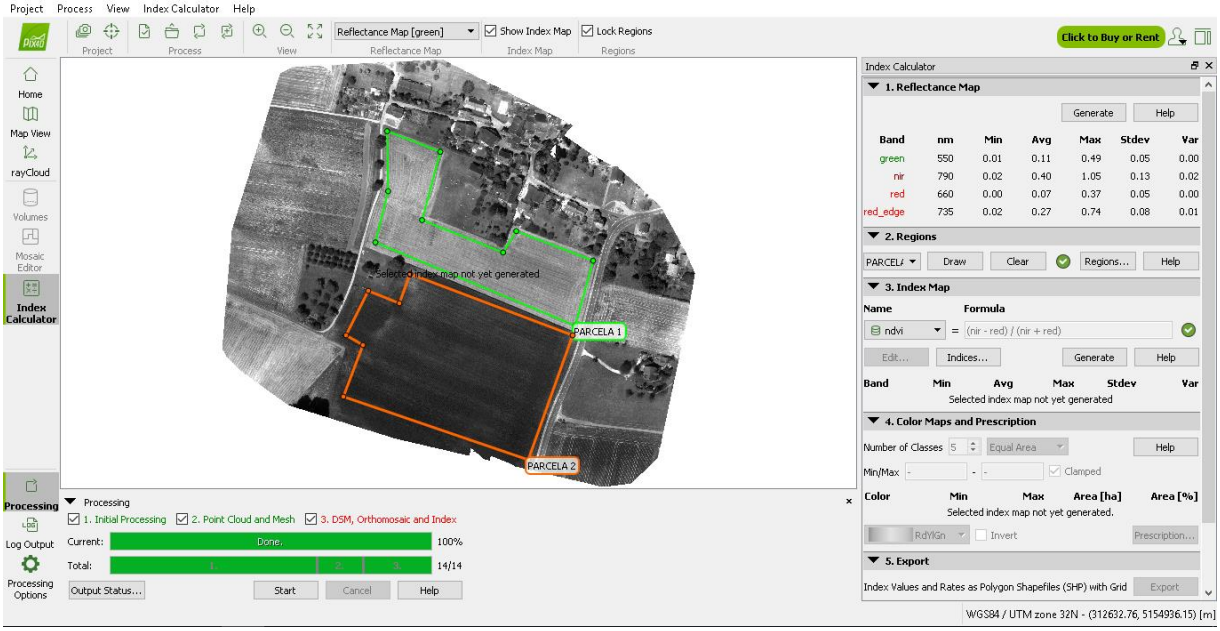
Nakon procesiranja, u glavnom izborniku, pod „View“, potrebno je otvoriti „Index calculator“. Po otvaranju funkcije, stvara se karta refleksije. Ona je dostupna u svim područjima u kojim je snimka obavljena, to jest u ovom slučaju GREEN, RED, RED EDGE I NIR.




Slika 8.21. Prikaz karte refleksije

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

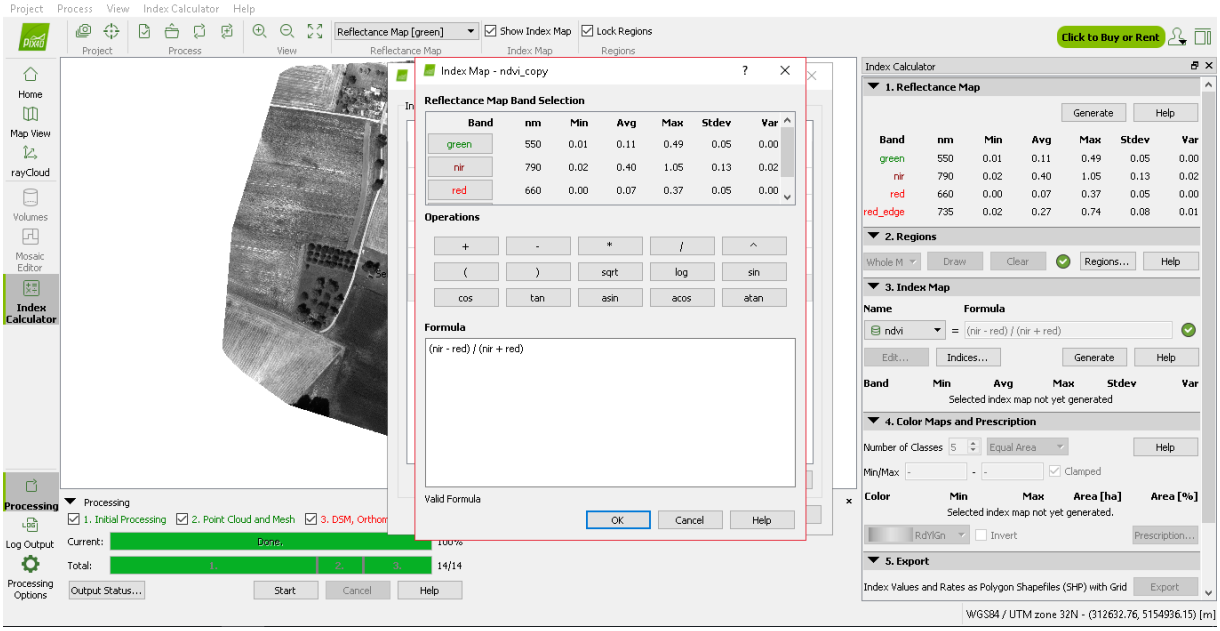
U ovom koraku potrebno je ocrtati područje promatranja, to jest parcele. Ocrtavanje se radi zbog izbjegavanja generiranja karte indeksa preko cijelog područja s neželjenim objektima.




Slika 8.22. Ocrtavanje promatranih parcela

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

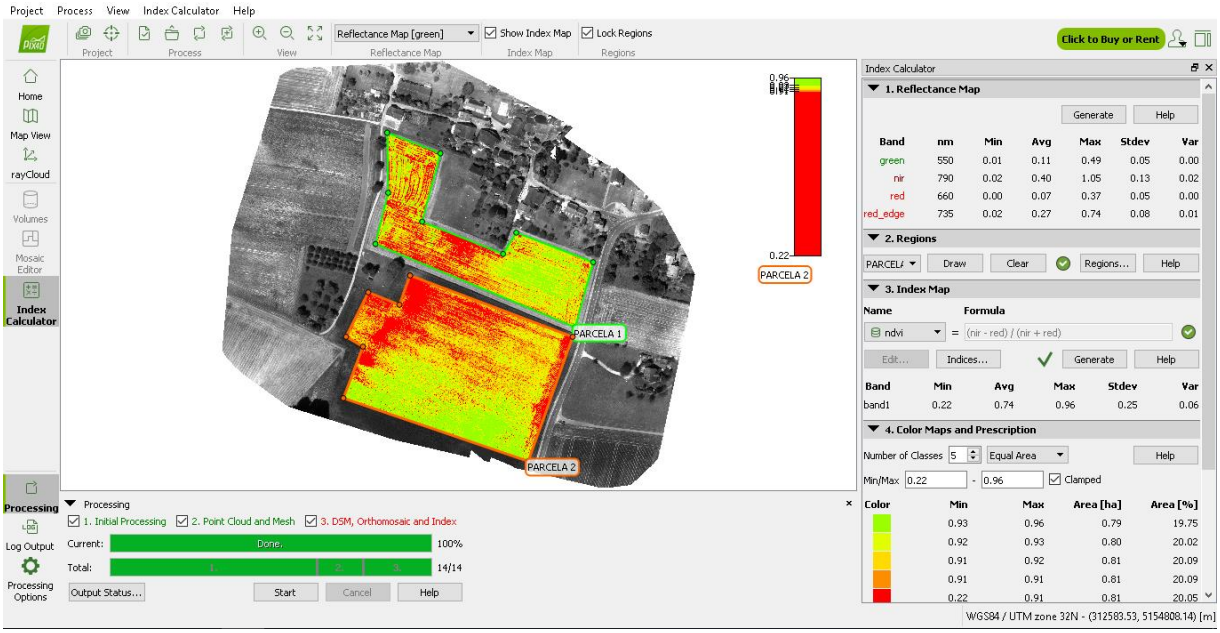
Nakon ocrtavanja potrebno je odabrati vegetacijski indeks za stvaranje navedene karte. Osim ponuđenih, moguće je samostalno unijeti matematičku formulu te ju pohraniti za budućnost.




Slika 8.23. Odabir vegetacijskog indeksa

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

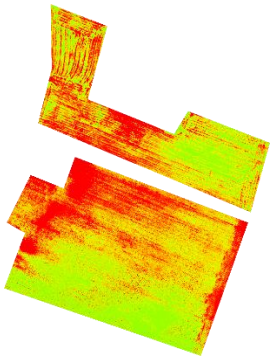
Na slici 8.24. prikazana je karta indeksa, generirana formulom za vegetacijski indeks normalizirane razlike (NDVI).




Slika 8.24. Prikaz karte indeksa

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

Kartu je moguće izvesti u .tiff i .jpg formatima za daljnje korištenje. Potrebno je napomenuti da karta sama po sebi bez poznavanja terena ne predstavlja mnogo. Radi mogućnosti korištenja, potrebna je detaljna inspekcija terena radi budućeg prepoznavanja uzoraka. Karta koja je napravljena je prikazana na slici 8.25.



Slika 8.25. Izvedena karta indeksa

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

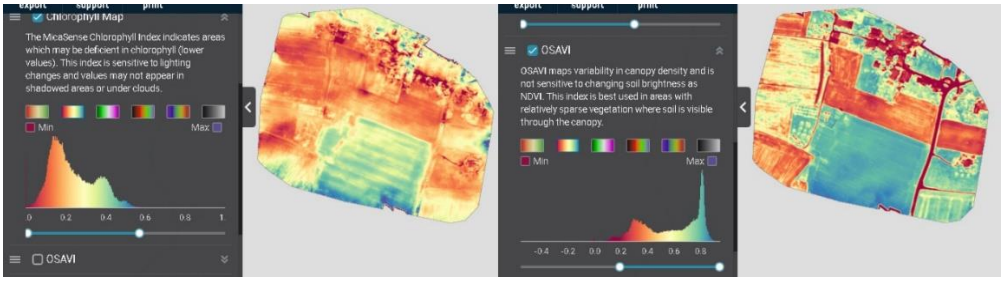
Dobivene podatke je moguće dalje obrađivati preko cloud servisa PIX4D-a. Jedna od mogućnosti je kontroliranje prikaza područja radi isticanja ili pronalaženja određenog svojstva.




Slika 8.26. Prikaz manipulacije obrađenim podacima na PIX4D cloud servisu

Izvor: https://cloud.pix4d.com/

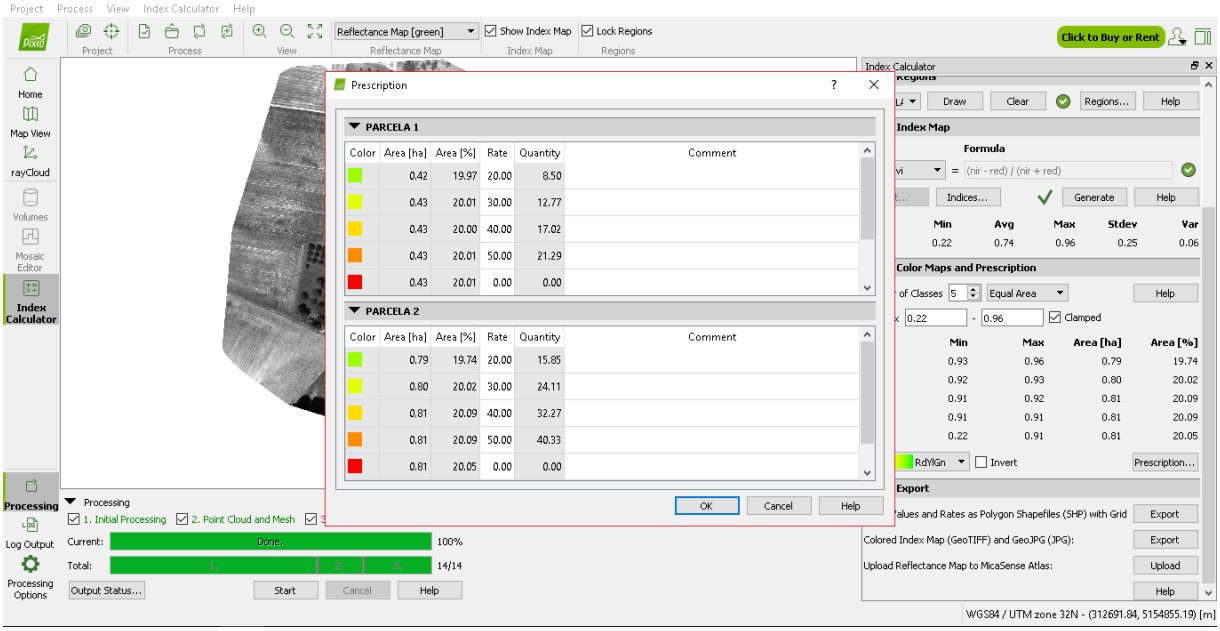
Izravno iz sučelja PIX4D-a, moguće je obrađene podatke izvesti u MicaSense online platformu. Preko nje su moguće slične opcije kao i u PIX4D-u, s već unaprijed pripremljenim vegetacijskim indeksima.




Slika 8.27. Prikaz manipulacije obrađenim podacima na MicaSense platformi (Karta klorofila i OSAVI indeks)

https://atlas.micasense.com

Ako se odrađeni podaci žele na neki način koristiti u sučelju traktora za određenu radnu operaciju to jest želi se napraviti karta za apliciranje promjenjivom količinom (eng. variable rate application map), za navedeno je predviđen korak „Color Maps and Prescription“. Ovdje možemo odrediti koliko područja razlikujemo te povezati količinu aplikacije određenog sredstva za isto. Npr. možemo odabrati da se na području gdje je vegetacijski indeks nula, niti jedna akcija ne izvrši, to jest da se na području slabog vegetacijskog indeksa, primjeni veća količina sredstva, itd.




Slika 8.28. Izrada karte za apliciranje promjenjivom količinom

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

Podatke za sučelje traktora je moguće izvesti u formatu .shp koji se nalaze u vektorskom obliku, vidljivo na slici 8.29.



Slika 8.29. Vektorski oblik podataka za apliciranje promjenjivom količinom

Izvor: PIX4Dmapper Pro, Version 4.0.21, Pix4D SA, Lausanne, CH, 2012-2017

# 9. Nadležne institucije, propisi i zakonodavstvo

Zračni promet u Republici Hrvatskoj reguliran je hrvatskim propisima, ali i zakonodavstvom Europske Unije koje je po pravnoj snazi iznad nacionalnih propisa. Osim navedenog, pojedini aspekti zračnog prometa uređeni su međunarodnim konvencijama koje obvezuju Republiku Hrvatsku i/ili Europsku Uniju.

Institucije koje su nadležne za odobrenje letova, rezervacije zračnog prostora i snimanja iz zraka te naknadnog korištenja materijala bez kojih navedeno nije moguće u pravilu su Hrvatska agencija za civilno zrakoplovstvo, Hrvatska kontrola zračne plovidbe i Državna geodetska uprava.

U ovom poglavlju opisane su navedene institucije i organizacije te propisi po kojima se letovi i snimanja moraju odvijati.

## 9.1. Hrvatska agencija za civilno zrakoplovstvo (CCAA)

Hrvatska agencija za civilno zrakoplovstvo (eng. Croatian Civil Aviation Agency – CCAA) osnovana je Zakonom o izmjenama i dopunama Zakona o zračnom prometu, kojeg je Hrvatski sabor donio na sjednici 20. travnja 2007. (NN 46/07). Osnivač Agencije je Republika Hrvatska, a osnivačka prava u skladu s odredbama ovoga Zakona obavlja Vlada Republike Hrvatske. Agencija je samostalna i neprofitna pravna osoba koja obavlja poslove od interesa za Republiku Hrvatsku u okviru djelokruga utvrđenog Zakonom o zračnom prometu i Statutom Agencije, a za svoj rad odgovara Vladi Republike Hrvatske.

Agencija je 9. ožujka 2009. počela s operativnim radom. Djelatnost Agencije obuhvaća poslove vezane za sigurnost zračnog prometa, a osobito certificiranje, nadzor i inspekciju u cilju osiguravanja kontinuiranog udovoljavanja zahtjevima za obavljanje zračnog prijevoza i drugih djelatnosti u zračnom prometu, vođenje propisanih registara i evidencija te obavljanje drugih poslova utvrđenih Zakonom o zračnom prometu.

### 9.1.1. Pravilnik o sustavima bespilotnih zrakoplova

Ovim Pravilnikom propisuju se opći, tehnički i operativni uvjeti za sigurnu uporabu bespilotnih zrakoplova, sustava bespilotnih zrakoplova i zrakoplovnih modela te uvjeti kojima moraju udovoljavati osobe koje sudjeluju u upravljanju tim zrakoplovima i sustavima.

**Pojmovi koji se koriste u Pravilniku:**
**Agencija:** Hrvatska agencija za civilno zrakoplovstvo;
**Bespilotni zrakoplov**: Zrakoplov namijenjen izvođenju letova bez pilota u zrakoplovu, koji je ili daljinski upravljan ili programiran i autonoman;
**Globalni navigacijski satelitski sustavi** (GNSS): Globalni navigacijski sustav pomoću kojeg prijemnik određuje svoju geografsku poziciju koristeći vremenske i pozicijske podatke zaprimljene sa satelita;
**Let unutar vidnog polja**: Izvođenje leta sustavom bespilotnog zrakoplova, pri čemu je rukovatelj sustava bespilotnog zrakoplova (rukovatelj) neprekidno u vizualnom kontaktu s bespilotnim zrakoplovom bez korištenja optičkih ili elektroničkih pomagala. Kontaktne leće ili korektivne naočale ne smatraju se optičkim pomagalom;
**Letačke operacije**: upotreba sustava bespilotnog zrakoplova, bez obzira da li se prima naknada ili ne, kada se bespilotni zrakoplov koristi za potrebe radova iz zraka (kao na primjer snimanja iz zraka, oglašavanja iz zraka, nadzora iz zraka, protupožarnu zaštitu, pokretanja lavina, znanstveno istraživačke letove, letove za potrebe televizije, filma i vijesti, letovi za potrebe posebnih događaja uključujući zrakoplovne priredbe, natjecateljske letove i slično);
**Operativna masa bespilotnog zrakoplova**: ukupna masa pri polijetanju;
**Operator sustava bespilotnog zrakoplova**: Fizička ili pravna osoba koja izvodi letačke operacije sustavom bespilotnog zrakoplova;
**Područje letenja**: Zračni prostor unutar kojeg se izvodi let bespilotnog zrakoplova;
**Pomoćni gospodarski objekti**: Staje, deponiji, hangari, skladišta i slično;
**Pridruženi promatrač**: Osoba koja asistira rukovatelju u izvođenju letova kada rukovatelj upravlja bespilotnim zrakoplovom koristeći sustav za prikaz pogleda iz zrakoplova (FPV);
**Rukovatelj sustava bespilotnog zrakoplova**: Osoba koja upravlja sustavom bespilotnog zrakoplova. Rukovatelj se smatra zapovjednikom zrakoplova;
**Skupina ljudi**: Okupljanje ljudi na određenom prostoru (npr. sa svrhom prisustvovanja ili sudjelovanja u organiziranom događaju – koncert, vjenčanje, priredba, proslava, demonstracije,… ili korištenje zajedničkih sadržaja – plaže, zabavni park, ….);
**Sustav bespilotnog zrakoplovna (UAS)**: Sustav namijenjen izvođenju letova zrakoplovom bez pilota koji je daljinski upravljan ili programiran i autonoman. Sastoji se od bespilotnog zrakoplova i drugih komponenti za upravljanje ili programiranje neophodnih za kontrolu bespilotnog zrakoplova, od strane jedne ili više osoba;
**Sustav za prikaz pogleda iz zrakoplova (FPV)**: Sustav koji pomoću kamere ugrađene u zrakoplovu i prikaznog uređaja na zemlji omogućuje rukovatelju prikaz pogleda iz zrakoplova;
**Zrakoplovni model**: bespilotni zrakoplov isključivo namijenjen za potrebe rekreacije i sporta.

**Područje primjene**

Odredbe ovoga Pravilnika primjenjuju se na sustave bespilotnih zrakoplova, operativne mase bespilotnog zrakoplova do i uključujući 150 kilograma koji se koriste u Republici Hrvatskoj. Odredbe se ne primjenjuju se na sustave bespilotnih zrakoplova kada se koriste za državne aktivnosti (vojne, policijske, sigurnosno-obavještajne, carinske, potrage i spašavanja, gašenja požara, obalne straže i slične aktivnosti ili službe). Odredbe ovoga Pravilnika ne primjenjuju se na sustave bespilotnih zrakoplova kada se koriste u zatvorenom prostoru.

Važno je i napomenuti da se odredbe ne primjenjuju se na bespilotne zrakoplove pod uvjetom da ne mogu postići kinetičku energiju veću od 79 J prilikom pada.

Izračun kinetičke energije:
$E\ [J] = (m_{max}[Kg] \times (v_{max}[m/s])^2) / 2,$
gdje je E kinetička energija prilikom pada, $m_{max}$ masa bespilotnog zrakoplova sa svom opremom te $v_{max}$ maksimalna brzina bespilotne letjelice.

**Klasifikacija bespilotnih zrakoplova kojima se izvode letačke operacije**

**Bespilotni zrakoplovi kojima se izvode letačke operacije s obzirom na operativnu masu, dijele se na:**
**Klasa 5**: do 5 kilograma,
**Klasa 25**: od 5 kilograma do 25 kilograma,
**Klasa 150**: od 25 kilograma do i uključujući 150 kilograma.

**Klasifikacija područja letenja**

**U odnosu na izgrađenost, naseljenost i prisutnost ljudi, područja letenja dijele se na klase:**
**Klasa I**: Područje u kojem nema izdignutih građevina ili objekata i u kojem nema ljudi, osim rukovatelja i osoblja koje je nužno za letenje.
**Klasa II**: Područje u kojem postoje pomoćni gospodarski objekti ili građevine koje nisu namijenjene za boravak ljudi i u kojem nema ljudi, osim rukovatelja i osoblja koje je nužno za letenje. Dozvoljen je samo povremeni prolazak, bez zadržavanja, ljudi kroz područje (biciklisti, šetači i sl.).
**Klasa III**: Područje u kojem postoje građevine ili objekti primarno namijenjeni za stanovanje, poslovanje ili rekreaciju (stambene zgrade, stambene kuće, škole, uredi, sportski tereni, parkovi i slično).
**Klasa IV**: Područje uskih urbanih zona (središta gradova, naselja i mjesta).

| Klasa sustava bespilotnog zrakoplova | Klasa područja izvođenja letenja | | | |
|---|---|---|---|---|
| | I<br>Neizgrađeno područje | II<br>Izgrađeno nenaseljeno područje | III<br>Naseljeno područje | IV<br>Gusto naseljeno područje |
| 5<br>OM < 5 kg | A | A | B | C |
| 25<br>5 ≤ OM < 25 kg | A | B | C | D |
| 150<br>25 ≤ OM ≤ 150 kg | B | C | D | D |

Slika 9.1. Kategorije leta: odnos klase sustava bespilotnog zrakoplova i klasa područja izvođenja letova (svaka kategorija predstavlja određenu opasnost te se sukladno njima određuju obveze operatora u Pravilniku)

Izvor: Pravilnik o sustavima bespilotnih zrakoplova - NN 69/09, NN 84/11, NN 54/13, NN 127/13 i NN 92/14

**Označavanje bespilotne letjelice**

Bespilotna letjelica koja se koristi za izvođenje letačkih operacija operativne mase veće od 5 kg mora biti označena identifikacijskom negorivom pločicom. Za bespilotne letjelice operativne mase ispod 5 kg koje se koriste u letačkim operacijama prihvatljivo je da se bespilotni zrakoplov označi identifikacijskom naljepnicom umjesto negorivom pločicom. Označavanje bespilotnog zrakoplova (ime, adresu i informacije za kontakt operatora ili vlasnika, kako je primjenjivo) mora obaviti operator.

**Izvođenje letačkih operacija**

Rukovatelj mora osigurati da se let bespilotnog zrakoplova izvodi tako da ne predstavlja opasnost po život, zdravlje ili imovinu ljudi zbog udara ili gubitka kontrole nad sustavom bespilotnog zrakoplova i da ne ugrožava ili ne ometa javni red i mir.

**Rukovatelj mora:**

- osigurati da se let bespilotnog zrakoplova odvija danju,
- prije leta provjeriti i uvjeriti se u ispravnost sustava bespilotnog zrakoplova,
- prikupiti sve potrebne informacije za planirani let i uvjeriti se da meteorološki i ostali uvjeti u području leta osiguravaju sigurno izvođenje leta,
- osigurati da je sva oprema ili teret na bespilotnom zrakoplovu odgovarajuće pričvršćen tako da ne dođe do njegovog ispadanja,
- osigurati da bespilotni zrakoplov tijekom uzlijetanja ili slijetanja sigurno nadvisuje sve prepreke,
- tijekom leta osigurati sigurnu udaljenost bespilotnog zrakoplova od ljudi, životinja, objekata, vozila, plovila, drugih zrakoplova, cesta, željezničkih pruga, vodenih putova ili dalekovoda, ne manju od 30 metara.

- osigurati da je minimalna udaljenost bespilotnog zrakoplova od skupine ljudi 150 metara,
- osigurati da se let bespilotnog zrakoplova odvija unutar vidnog polja rukovatelja i na udaljenosti ne većoj od 500 m od rukovatelja,
- osigurati da se let bespilotnog zrakoplova odvija izvan kontroliranog zračnog prostora,
- osigurati da se let bespilotnog zrakoplova odvija na udaljenosti najmanje 3 km od aerodroma i prilazne ili odlazne ravnine aerodroma, osim u slučaju kada su posebno predviđene procedure za letenje bespilotnih zrakoplova definirane naputkom za korištenje aerodroma, i
- osigurati da se tijekom leta iz ili s bespilotnog zrakoplova ne izbacuju predmeti.

Let korištenjem sustava za prikaz pogleda iz zrakoplova (FPV) smije se izvoditi isključivo zrakoplovnim modelom.

Letačke operacije sustava bespilotnih zrakoplova smiju se izvoditi na manjim ili na većim udaljenostima (izvan vidnog polja rukovatelja) ako operator prethodno ishodi odobrenje Agencije.

Letačke operacije sustava bespilotnih zrakoplova smiju se izvoditi u kontroliranom zračnom prostoru ako operator prethodno ishodi odobrenje o posebnom korištenju zračnog prostora od nadležne kontrole zračnog prometa.

**Obveze operatora**

Operator mora imenovati odgovornu osobu koja ima ukupnu odgovornost nad aktivnostima operatora i mora uspostaviti sustav izvješćivanja o događajima povezanima sa sigurnošću u zračnom prometu skladu s primjenjivim propisom te navedena izvješća čuvati najmanje dvije godine od datuma leta.

**Sustav vođenja i čuvanja zapisa o letu koji sadržava najmanje sljedeće podatke:**
Datum leta, vrijeme početka i završetka izvođenja letačkih operacija i trajanje leta, ime i prezime rukovatelja koji je obavio let, lokacija izvođenja letačke operacije, klasifikaciju područja letenja, operativna masa bespilotnog zrakoplova te napomene o događajima za koje operator procijeni da su od značaja za izvođenje letačkih operacija.

**Operativni priručnik**

Operator je dužan izraditi operativni priručnik te u skladu s njegovim odredbama izvoditi aktivnosti. Potrebno je osigurati da je isti kontinuirano usklađen s primjenjivim propisima i odredbama letačkog priručnika ili uputa za upotrebu.

Operator mora osoblju osigurati pristup operativnom priručniku koje mora biti upoznato s dijelovima operativnog priručnika koji se odnose na njihove zadaće.

**Operativni priručnik mora sadržavati minimalno sljedeće dijelove i upute:**
- Sadržaj,
- Status izmjena i listu važećih stranica,
- Dužnosti i odgovornosti osoblja uključenog u aktivnosti operatora,
- Standardni operativni postupci,
- Održavanje sustava bespilotnog zrakoplova,
- Postupci u nuždi,
- Ograničenja za izvođenje letačkih operacija,
- Izvješćivanje,
- Upravljanje rizicima,
- Osposobljenost rukovatelja, i
- Vrste i rokovi čuvanja zapisa.

**Analiza kvarova i njihovog utjecaja**

Operator mora izvršiti analizu kvarova bitnih funkcija/sustava bespilotnog zrakoplova koja pokazuje da kvar pojedine komponente ili funkcije ne dovodi do prestanka rada bitne funkcije/sustava bespilotnog zrakoplova.
Ispitivanjem se mora provjeriti ponašanje sustava bespilotnog zrakoplova u slučaju pojedinog kvara te se uvjeriti da su bitne funkcije/sustavi udvojeni i da u slučaju kvara rezervni sustav automatski ili po naredbi rukovatelja preuzima funkciju ili, da postoji način djelovanja u nuždi kojim se može nadomjestiti rad sustava u kvaru (npr. ručnim upravljanjem).
Operator mora za svaku promjenu na bespilotnom zrakoplovu koja ima utjecaja na rad bitnih funkcija/sustava bespilotnog zrakoplova izvršiti analizu kvarova i njihovog utjecaja kako bi uzeo u obzir utjecaj predmetne promjene.
Važeća analiza kvarova sustava bespilotnog zrakoplova mora se čuvati najmanje 6 mjeseci nakon prestanka izvođenja letačkih operacija s tim sustavom bespilotnog zrakoplova.

**Izjava operatora**

Operator koji namjerava izvoditi letačke operacije izjavljuje da je sposoban i da ima sredstva za preuzimanje odgovornosti povezanih s izvođenjem letačkih operacija sustavom bespilotnih zrakoplova, da sustavi bespilotnih zrakoplova kojima namjerava izvoditi letačke operacije ispunjavaju primjenjive tehničke zahtjeve, te da će letačke operacije izvoditi u skladu s odredbama Pravilnika.

**Operator mora:**
- održavati sukladnost s primjenjivim zahtjevima i informacijama sadržanima u izjavi,
- u slučaju promjena, mora odmah obavijestiti Agenciju izmijenjenom Izjavom, i
- obavijestiti Agenciju kada trajno prestane s izvođenjem letačkih operacija.

**Odobrenje Agencije**

Kada je ovim Pravilnikom propisano ishođenje odobrenja za izvođenje letačkih operacija sustavom bespilotnog zrakoplova, operator mora dostaviti Agenciji:

- ime i adresu podnositelja zahtjeva,
- opis namjeravanih letačkih operacija,
- broj i tipove sustava bespilotnih zrakoplova koje će koristiti u izvođenju letačkih operacija u okviru traženog odobrenja,
- dokaze o ispunjavanju operativnih i tehničkih zahtjeva za izvođenje letačkih operacija,
- fotografije sustava bespilotnih zrakoplova koji će se koristiti,
- dokumentaciju procjene rizika namjeravanih letačkih operacija,
- operativni priručnik, i
- Izjavu propisanu Pravilnikom za ishođenje odobrenja za izvođenje letačkih operacija kategorije D.

Zahtjev za ishođenje odobrenja za izvođenje letačkih operacija, sustavima bespilotnih zrakoplova, podnosi se na način koji odredi Agencija. U svrhu izdavanja odobrenja Agencija može provesti nadzor operatora i zatražiti izvođenje demonstracijskih letova. Odobrenje se izdaje na rok od dvije godine.

**Obvezna dokumentacija pri izvođenju letačkih operacija**

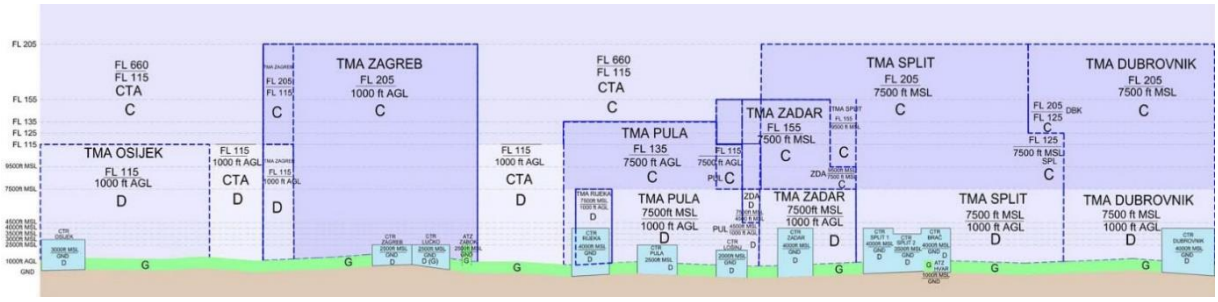
1) Letački priručnik ili uputa za upotrebu (A, B, C, D kategorija)
2) Odobrenje (A, B, C, D kategorija)
3) Polica osiguranja (A, B, C, D kategorija)
4) Izjava rukovatelja (A,B kategorija) ili Certifikat o zdravstvenoj sposobnosti Klase I ili II, ili liječničko uvjerenje o zdravstvenoj sposobnosti za upravljanje vozilima koje se izdaje vozačima kojima upravljanje vozilom nije osnovno zanimanje, a koje nije starije od 5 godina (C, D kategorija)
5) Izjava rukovatelja (A,B kategorija) ili Pilotska dozvola ili potvrda o položenom teorijskom ispitu koji provodi Hrvatska agencija za civilno zrakoplovstvo (CCAA) (C, D kategorija)
6) Izjava rukovatelja o osposobljenosti za upravljanje UAS (A, B, C, D kategorija)
7) Operativni priručnik (C, D kategorija)
8) Ostala odobrenja (Odobrenje organizatora događaja, odobrenje vlasnika zatvorenog prostora, odobrenje vlasnika posjeda, odobrenje MUP-a, odobrenje MORH-a, odobrenje Državne geodetske uprave, itd.) (A, B, C, D kategorija)

## 9.2. Hrvatska kontrola zračne plovidbe (HKZP)

Hrvatska kontrola zračne plovidbe je trgovačko društvo u vlasništvu Republike Hrvatske, koje posluje sukladno propisima EU i RH, te standardima i praksom ICAO-a (Organizacija za međunarodno civilno zrakoplovstvo) i EUROCONTROL-a (Europska organizacija za sigurnost zračne plovidbe).
Osnovna zadaća Hrvatske kontrole zračne plovidbe je pružanje usluga u zračnoj plovidbi, poštujući osnovni princip - visoki stupanj sigurnosti zračnog prometa, sukladno pravnom okviru Jedinstvenog europskog neba.

Ako se let bespilotnom letjelicom odvija u kontroliranom zračnom prostoru potrebno ga je prijaviti Hrvatskoj kontroli zračne plovidbe. Također, ako se let ne odvija iznad 300 m, nije u blizini aerodroma to jest ne utječe na rad aerodroma ili na neki drugi način ne utječe na kontrolirani zračni prostor, rezervacija zračnog prostora nije potrebna.

Područje „G“ (zeleno) prikazano na slici 9.2. je nekontroliran zračni prostor.




Slika 9.2. Klasifikacija zračnog prostora RH

Izvor: http://www.crocontrol.hr/UserDocsImages/AIS%20produkti/VFR%20karta%202016/VFR_01JUN2016-SEKTORI-pregledna.pdf

### 9.2.1. AMC Hrvatska

Jedinica za upravljanje zračnim prostorom (eng. Airspace Management Cell – AMC) združena je civilno-vojna fokusna točka nadležna za dnevno upravljanje zračnim prostorom pod nadležnošću RH, ustrojena u pružatelju usluga u zračnoj plovidbi – Hrvatskoj kontroli zračne plovidbe (HKZP). Jedinica za upravljanje zračnim prostorom prema postojećoj regulativi zadužena je za upravljanje zračnim prostorom na dnevnoj bazi i djeluje kao združena civilno-vojna fokusna točka za upravljanje zračnim prostorom u Republici Hrvatskoj.

### 9.2.2. AMC portal

Web AMC portal zamišljen je kao alat za objavu informacija o rezervacijama struktura u zračnom prostoru krajnjim korisnicima ali i kao alat koji omogućuje registriranim korisnicima rezervacije struktura u zračnom prostoru i popratnu komunikaciju s njima tijekom procesa rezervacije.




Slika 9.3. Prikaz karte trenutačnog stanja rezervacije zračnog prostora preko AMC portala

Izvor: https://amc.crocontrol.hr/hr-hr/karta-stanja

## 9.3. Državna geodetska uprava (DGU)

Državna geodetska uprava (DGU) je državna upravna organizacija koja obavlja poslove iz područja geodezije, kartografije, katastra i fotogrametrije te vodi brigu o uspostavi nacionalne infrastrukture prostornih podataka, informatizaciji katastra i geodetsko-prostornog sustava, državnoj službenoj kartografiji, geodetskoj dokumentaciji, statističkim podacima o katastru nekretnina, prostornim jedinicama i vodovima te geodetsko-katastarskim poslovima za državnu granicu.

Na temelju članka 100. Zakona o obrani (NN br. 73/13, 75/15 i 27/16), to jest Uredbi o snimanju iz zraka, Državna geodetska uprava je odgovorna organizacija za snimljene materijale iz zraka.

### 9.3.1. Uredba o snimanju iz zraka

Ovom Uredbom propisuju se uvjeti koje pravne i/ili fizičke osobe moraju ispuniti kako bi mogle snimati iz zraka državno područje Republike Hrvatske, umnožavati i/ili objavljivati snimljene materijale, postupci i uvjeti pod kojima je dopušteno iznositi snimke iz zraka iz Republike Hrvatske te postupak i način pregledavanja snimaka prije njihovog korištenja.

Po Uredbi o snimanju iz zraka, za potrebe poljoprivrede, ako su isključivo za potrebe vlasnika ili korisnika parcele, snimanje nije potrebno prijaviti. Samim time, ono se mora odvijati isključivo u zračnom prostoru vlasnika ili korisnika. Ako se vlasnik snimki želi koristiti njima javno, to jest želi ih objaviti na neki način, potrebno je zatražiti Odobrenje za snimanje prije samog leta. Ako je Odobrenje pozitivne naravi, nakon snimanja potrebno je predati snimke Državnoj Geodetskoj upravi na tzv. pregled zračnih snimaka radi izdavanja Odobrenja za uporabu zračnih snimaka.

**Snimanje iz zraka**

Snimanje iz zraka je posebna operacija radova iz zraka, kod koje se uređaj za snimanje nalazi na ili u zrakoplovu (bespilotnoj letjelici).

Snimati iz zraka državno područje Republike Hrvatske za potrebe izmjere zemljišta, istraživanja, prostornog uređenja te za druge gospodarstvene i znanstvene potrebe, mogu pravne i fizičke osobe koje su registrirane za snimanje iz zraka pri nadležnim registarskim tijelima država u kojima imaju poslovni nastan.

Naručitelj snimanja dužan je uz zahtjev za izdavanje odobrenja za snimanje iz zraka priložiti dokument izdan od nadležnog tijela Republike Hrvatske za poslove sigurnosti i zaštite civilnog zračnog prometa kojim se dokazuje da je operator zrakoplova registriran za izvođenje operacija za snimanje iz zraka.

Pod snimanjem iz zraka, u smislu ove Uredbe, ne smatra se snimanje koje sukladno posebnim propisima provode ministarstva nadležna za obranu i unutarnje poslove prilikom obavljanja redovitih poslova.

**Ciljano snimanje**

Pod ciljanim snimanjem pojedinih lokacija i građevina iz zraka podrazumijeva se snimanje vojnih i civilnih lokacija i građevina posebno važnih za obranu, ostalih izdvojenih lokacija i građevina, područja nacionalnih parkova i parkova prirode.

Ciljano snimanje iz zraka pojedinih vojnih i civilnih lokacija i građevina posebno važnih za obranu je snimanje za potrebe vlasnika, odnosno korisnika vojne i civilne lokacije i građevine posebno važne za obranu.

Ciljano snimanje iz zraka pojedinih industrijskih, gospodarskih, poljoprivrednih lokacija i građevina za potrebe vlasnika, odnosno korisnika lokacije i građevine može se obaviti sustavima bespilotnih zrakoplova u skladu s propisima o sustavima bespilotnih zrakoplova bez Odobrenja za snimanje iz zraka izdanog od strane Državne geodetske uprave kada se obavlja

unutar granica navedene lokacije i građevine u svrhu praćenja stanja izgrađenosti, oštećenosti odnosno zaštite.

**Odobrenje za snimanje iz zraka**

Pravne i fizičke osobe smiju snimati iz zraka nakon pribavljenog odobrenja za snimanje iz zraka. Isto izdaje Državna geodetska uprava naručitelju snimanja za svako pojedinačno snimanje. Odobrenje sadrži podatke o snimatelju, naručitelju snimanja, području i vremenu snimanja te svrsi snimanja te se može izdati najviše za razdoblje od 3 mjeseca.

**Zahtjev za izdavanje odobrenja za snimanje iz zraka**

Zahtjev neposredno podnosi naručitelj snimanja u pisanom obliku, slanjem poštom ili dostavom u obliku elektroničke isprave Državnoj geodetskoj upravi.

Za snimanje strogog rezervata, posebnog rezervata, nacionalnog parka i parka prirode, pored navedenih podataka, dostavlja se suglasnost javne ustanove koja upravlja zaštićenim područjem i drugi podaci u skladu s posebnim propisima.

Za iznošenje neprocesiranih zračnih snimaka prije pregleda od strane Povjerenstva za pregled zračnih snimaka, naručitelj snimanja treba priložiti izjavu s obrazloženjem nemogućnosti procesiranja zračnih snimaka u Republici Hrvatskoj.

**Pregled snimljenog materijala**

Pravne i fizičke osobe kojima je izdano odobrenje za snimanje iz zraka dužne su zračne snimke dostaviti na pregled Državnoj geodetskoj upravi odmah po obavljenom snimanju, a najkasnije u roku od osam dana od završetka snimanja.

U slučaju da snimanje nije odrađeno, pravne i fizičke osobe kojima je izdano odobrenje za snimanje iz zraka, dužne su o tome obavijestiti Državnu geodetsku upravu najkasnije u roku od osam dana od isteka odobrenja za snimanje iz zraka.

Iznositi iz Republike Hrvatske ili razmjenjivati putem interneta mogu se samo zračni snimci koji su pregledani i koje odobri Državna geodetska uprava.

Iznimno je dozvoljeno privremeno iznošenje nepregledanog snimljenog materijala u inozemstvo uz odobrenje Državne geodetske uprave radi obrade zračnih snimaka i to samo u slučajevima kada obradu nije moguće izvršiti u Republici Hrvatskoj.

Zračni snimci ne mogu se iznositi putem posrednika i komercijalnih prijevoznih tvrtki, već osoba koja iznosi navedeni materijal mora biti zaposlenik tijela ili pravne osobe naručitelja snimanja. Nakon obrade naručitelj snimanja dužan je dostaviti zračne snimke na pregled u Državnu geodetsku upravu u roku od osam dana.
Državna geodetska uprava će odmah po izdavanju odobrenja za iznošenje zračnih snimaka dostaviti nadležnoj ustrojstvenoj jedinici Ministarstva unutarnjih poslova primjerak odobrenja kojim se odobrava iznošenje zračnih snimaka iz Republike Hrvatske, uz navođenje vremena i graničnog prijelaza na kojem će biti iznijete.

**Odobrenje za uporabu zračnih snimaka**

Državna geodetska uprava i ministarstvo nadležno za poslove obrane formiraju Povjerenstvo za pregled zračnih snimki.

Povjerenstvo će u roku od 15 dana od dana dostave originalnih i kompletnih zračnih snimaka odrediti koji se snimci smiju koristiti u skladu s podnesenim zahtjevom. Temeljem zaključka Povjerenstva, Državna geodetska uprava izdat će odobrenje za uporabu zračnih snimaka.

Za upotrebu zračnih snimaka u druge svrhe od svrhe navedene u odobrenju za uporabu, vlasnik snimljenog materijala mora od Državne geodetske uprave zatražiti novo odobrenje za uporabu uz navođenje svrhe za koju će se zračni snimci koristiti. Zračne snimke nije potrebno dostavljati na ponovni pregled ako se radi o neklasificiranom materijalu.

Naručitelj snimanja vlasnik je snimljenog materijala i odgovoran je za zaštitu i uporabu snimljenog materijala sukladno izdanom odobrenju za uporabu.

**Rokovi za izdavanje odobrenja**

Državna geodetska uprava dužna je izdati Odobrenje za snimanje iz zraka u roku od 15 dana od dana predaje urednog zahtjeva, odnosno pribavljenih potrebnih suglasnosti.

Državna geodetska uprava dužna je izdati Odobrenje za uporabu zračnih snimaka u roku od 15 dana od dana obavljenog pregleda od strane Povjerenstva za pregled zračnih snimaka.

# 10. Zaključak

Jedna od osnovnih pretpostavki precizne poljoprivrede je dostupnost velikog broja informacija radi donošenja odluka. Korištenje bespilotnih letjelica i zračnih snimki direktno pridonosi tom konceptu.

Jedna od glavnih prednosti korištenja bespilotnih letjelica u pogledu atmosferskih prilika naspram satelitskog snimanja jest odvijanje samog snimanja ispod oblaka. Također, snimanje bespilotnom letjelicom omogućuje bolju prostornu razlučivost od snimanja zrakoplovom ili satelitom. S druge strane, korištenje bespilotnih letjelica uvelike ovisi o vanjskim utjecajima. Na primjer, padaline onemogućuju njihovo korištenje a jači vjetar otežava ili onemogućuje korištenje u određenim situacijama.

Korištenje bespilotnih letjelica se pokazuje vrlo korisnim pri promatranju udaljenih i nepristupačnih te velikih površina. Upravljanje i kontrola bespilotnih letjelica je jednostavna, a termin snimanja određuje korisnik sam neposredno prije samog leta. Samim time, postoji mogućnost za boljom vremenskom razlučivosti snimaka. Snimljene podatke korisnik posjeduje na svom računalu odmah po slijetanju, to jest prijenosu vanjske memorije u isto. Prijenos podataka u programe za obradu istih, automatsko kartiranje, geoinformacijske sustave i sl. je jednostavan.

Unutar područja poljoprivredne proizvodnje, mogućnosti korištenja su široke primjene. Pored vizualne inspekcije, kartiranjem i obradom podataka, moguće je dobiti niz informacija poput oblika parcele, 3-D prikaz terena, stanje vegetacije i tla, broj jedinki, dijelove terena gdje se potencijalno zadržava voda, itd. Uočavanjem odstupanja na karti, možemo terenskom provjerom verificirati naše pretpostavke da postoji određeni problem u stvarnosti. Na taj način, utvrđen uzorak na karti možemo koristiti kao sredstvo za prepoznavanje prisutnosti bolesti, štetnika i problema u razvoju, efikasnosti sustava za navodnjavanje, sl. Snimanja imaju čestu svrhu za procjenu prinosa ili utvrđivanje štete od prirodnih nepogoda.

Uz razvijene vrste senzora na tržištu, mogućnosti snimanja su široke. Pored snimanja u vidljivom dijelu spektra, snimanje se može odvijati i u nevidljivom dijelu a u praksi se blisko infracrveni pokazuje kao jedan od najkorisnijih za praćenje vegetacije. Trenutno su na tržištu najpopularnije multispektralne kamere, koje prestaju biti isključivo modificirane serijske fotografske kamere, već su izričito konstruirane za potrebe multispektralnog snimanja. Za razliku od multispektralnih kamera, hiperspektralne u ovom trenu i dalje nisu dostigle prihvatljivu cijenu, masu i praktičnost za veću raširenost u korištenju za potrebe poljoprivredne proizvodnje.

Jedan od vrijednih alata u daljinskom istraživanju su vegetacijski indeksi, koji su u današnjem dobu razvijeni za različite potrebe. Mnogi programi za obradu podataka sadrže mogućnost

izrade vlastitog vegetacijskog indeksa, stvaranjem nove matematičke formule ili korigiranjem postojeće. Rezultat korištenja su najčešće interaktivne karte vegetacijskog indeksa kojima je moguće mijenjati širinu prikaza elektromagnetskog spektra, kontraste boja radi boljeg isticanja problematičnog područja i sl. Za korištenje takve tehnologije, potrebno je znanje o interakciji Sunčeve energije sa Zemljom, koje je velikim dijelom orijentirano prema refleksiji zračenja.

Poznavanje višegodišnjih parametara te djelovanje na temelju njih samih rezultira argumentiranoj i optimalnoj uporabi sredstava za rad, kao i smanjenjem potrebe za ljudskim radom. Na ovaj način se izbjegava nepotrebno nanošenje sredstava po cijeloj površini, već se ona apliciraju lokalizirano i racionalno. Takav pristup je poželjan sa stajališta zaštite okoliša, kao i s financijskog od strane korisnika jer je njime moguće ostvariti ekonomske uštede. Određene bespilotne letjelice s njihovom programskom podrškom omogućuju prijenos obrađenih podataka u traktorsko sučelje, radi apliciranja promjenjivom količinom u svrhu njege i zaštite.

Bespilotne letjelice s nepokretnim krilima se pokazuju učinkovitije za kartiranje većih površina. S obzirom na manju masu, veće brzine i mogućnost duljeg leta, površina koju mogu pokriti u jednom letu je veća. S druge strane, veća brzina kretanja se može promatrati i kao nedostatak zbog direktnog utjecaja na smanjenje točnosti provedbe predviđenog leta, ali takav nedostatak moguće je ispraviti većim poprečnim preklopima pri snimanju. Letjelice s pokretnim krilima se u praksi pokazuju bolje za brze inspekcije ili manje površine. Također, kod njih je preuzimanje kontrole usred autonomnog leta te izvođenje istog jednostavnije zbog mogućnosti lebdjenja letjelice, koje također pojednostavljuje samo uzlijetanje i slijetanje.

Za razliku od određenih komercijalnih namjena korištenja bespilotnih letjelica i zračnih snimki, korištenje za potrebe poljoprivrede je djelomično prilagođeno samom korisniku. Poljoprivredne površine ulaze u kategorije neizgrađenog to jest nenaseljenog područja u većini slučajeva, što olakšava korištenje u skladu s aktualnim zakonima. S druge strane, poneke stavke poput definiranog vidnog polja ne idu u korist samom korisniku. Vidno polje je definirano s maksimalnih 500 metara od rukovatelja, što znači da bez prethodno zatraženog odobrenja od Agencije za civilno zrakoplovstvo, let izvan tog radijusa nije moguć, radi snimanja većih površina. Korištenje bespilotnih letjelica podrazumijeva posjedovanje određene dokumentacije i pridržavanje zakonske regulative, ali s druge strane korištenje istih nosi svoju odgovornost i rizik. Uvođenje transparentne platforme, poput AMC portala omogućilo je bolji pregled korištenja zračnog prostora samim korisnicima istog.

Uredba o snimanju iz zraka u pogledu ciljanog snimanja za potrebe poljoprivrede ide u korist korisnicima usluge u pogledu optimiziranja i unaprjeđenja proizvodnje, jer takvo snimanje nije potrebno prijaviti, ako ga odrađuje vlasnik ili korisnik parcele i odvija se isključivo u zračnom prostoru istog. S druge strane, ona ne ide u prilog znanstvenim radovima, jer ako se snimka

želi objaviti, prije samog snimanja, mora proći određenu proceduru odobrenja i pregleda snimljenog materijala, što zbog same dinamičnosti poljoprivredne proizvodnje nije idealno. Također, trenutno ne postoji službena procedura prenamjene snimaka odrađenih isključivo za korisnika ili vlasnika parcele za potrebe poljoprivrede, u snimke koje mogu biti objavljene u javnosti.

Napredak u razvoju bespilotnih letjelica za civilne potrebe u zadnjem desetljeću znatno je utjecao na raširenost korištenja tehnologije u području poljoprivredne proizvodnje. Danas je takva tehnologija lako dostupna te je relativno jednostavna za korištenje.

# 11. Literatura


1. Austin R. (2010). Unmanned aircraft systems uavs design, development and deployment, A John Wiley & Sons, Ltd., Publication, Chichester (West Sussex, United Kingdom).
2. Braum F. (1992). Fotogrametrija. Tehnička enciklopedija, Sv. 5, Zagreb, Leksikografski zavod Miroslav Krleža, 583-597
3. Bušljeta-Vdović S. (2006). Zračne snimke kao podloga za daljinska istraživanja u prostornom planiranju. Znanstveni časopis za arhitekturu i urbanizam, Vol.14 No.2(32), 247-255
4. Campbell J.B. (2007). Introduction to remote sensing, (4th ed), Taylor & Francis, London and New York
5. Colomina I., Molina P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review, ISPRS Journal of Photogrammetry and Remote Sensing 92/14, 79–97
6. Dempsey, M. E. (2010). Eyes of the Army – U.S. Army Roadmap for Unmanned Aircraft Systems 2010–2035, United States Army (http://www.rucker.army.mil/usaace/uas/US%20Army%20UAS%20RoadMap%202010%202035.pdf)
7. Donassy V. (1983). Fotografija, fotografski i nefotografski postupci snimanja u fotogrametriji i daljinskom istraživanju, Geodetski fakultet , Sveučilište u Zagrebu
8. Donassy V., Oluić M., Tomašegović Z. (1983). Daljinska istraživanja u geoznanostima. Jugoslavenska akademija znanosti i umjetnosti, Zagreb.
9. Elaraba M., Ticlavilca A. M., Torres-Rua A. F., Maslovac I., McKee M. (2015). Estimating chlorophyll with thermal and broadband multispectral high resolution imagery from an unmanned aerial system using relevance vector machines for precision agriculture. International Journal of Applied Earth Observation and Geoinformation 43, 32–42
10. Frančula N. (2004). Digitalna kartografija, Geodetski fakultet, Sveučilište u zagreb,
11. Gnädinger F., Schmidhalter U. (2017). Digital Counts of Maize Plants by Unmanned Aerial Vehicles (UAVs), MDPI, Remote Sensing, 9/6 (http://www.mdpi.com/2072-4292/9/6/544/htm)
12. Govorčin M., Kovačić F., Žižić I. (2012). Bespilotne letjelice SenseFly Swinglet CAM Ekscentar, br. 15, 62-68
13. Harbaš I. (2014). Računalne metode za detekciju vegetacije, Zavod za elektronilke sustave i obradbu informacija, Fakultet elektrotehnike i računarstva
14. Jakobović Z. (2007).Tehnički leksikon, Leksikografski zavod Miroslav Krleža, Zagreb
15. Jurišić M., Plašćak I. (2009). Geoinformacijski sustavi – GIS u poljoprivredi i zaštiti okoliša, Poljoprivredni fakultet, Osijek
16. Jurišić, M., Šumanovac, L., Zimmer, D., Barač, Ž. (2015). Tehnički i tehnološki aspekti pri zaštiti bilja u sustavu precizne poljoprivrede, Glasilo biljne zaštite, 329-332

17. Kempni K. (1992). Fotometrija, Tehnička enciklopedija, Sv. 5, Zagreb, Leksikografski zavod Miroslav Krleža,; 608-623
18. Kolarek M. (2010). Bespilotne letjelice za potrebe fotogrametrije. Znanost i struka: Ekscentar, br. 12, 70-73
19. Lapaine M., Frančula N. (2001). Kartografija i daljinska istraživanja, Bilten Znanstvenog vijeća za daljinska istraživanja i fotointerpretaciju, 145-154
20. Lapaine M., Lapaine M., Tutić D. (2004). GPS za početnike. Hrvatsko kartografsko društvo, Zagreb
21. Lasić Z. (2007). Geodetski instrumenti. Geodetski fakultet, Sveučilište u Zagrebu
22. Lovrić P. (1988). Opća kartografija, Sveučilište u Zagrebu
23. Lukić A. (2003). Digitalna karta - ususret geografiji budućnosti?, Edupoint časopis, Časopis o primjeni informacijskih tehnologija u obrazovanju (http://edupoint.carnet.hr/casopis/19/clanci/2.html#para_2)
24. MacEachren, A. M. (2004). How Maps Work, Representation, Visualization and Design. The Guildford Press, New York & London
25. Maljković D. (1992). Spektrometrija, Tehnička enciklopedija, Sv. 12, Zagreb, Leksikografski zavod Miroslav Krleža, 150-178
26. Marjanović M. (2010). CROPOS - hrvatski pozicijski sustav, Ekscentar, br. 12, str. 28-34
27. Novaković G., Đapo A., Mahović H. (2009). Razvoj i primjena pseudolita za pozicioniranje i navigaciju, Geodetski list 3, 215–241
28. Oluić M. (2001). Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena Hrvatska akademija znanosti i umjetnosti i GEOSAT d.o.o. Zagreb
29. Pahernik M., (2006). Uvod u geografsko informacijske sustave. MORH, Glavni stožer, Oružanih snaga RH, Zapovjedništvo za združenu izobrazbu i obuku "Petar Zrinski",
30. Paić M. (1992.). Optika, Tehnička enciklopedija, Sv. 9, Zagreb, Leksikografski zavod Miroslav Krleža, 654-695
31. Pavić I. (2012). Geografsko-informacijski sustav i model razvoja pomorskoga katastra. Naše more 59, 5-6
32. Pavlik D., Popčević I., Rumora A. (2014). Bespilotne letjelice podržane INS i GNSS senzorima Ekscentar, br. 17, 65-70
33. Petrović K. (2016). Infracrvena termografija - pravi izbor za redovito održavanje. Mjerna i regulacijska tehnika, Kem. Ind. 65 (1-2), 110−113
34. Pravilnik o sustavima bespilotnih zrakoplova - NN 69/09, NN 84/11, NN 54/13, NN 127/13 i NN 92/14
35. Pribičević B., Medak D. (2003). Geodezija u građevinarstvu. Sveučilište u Rijeci, V.B.Z. d.o.o.
36. Robinson, A.H., Morrison J.L., Muehrcke, P.C., Kimerling, A.J., Guptill, S.C. (1995). Elements of Cartography, John Wiley & Sons, New York

37. Rumora L., Medved I., Pilaš I., Medak D. (2016). Usporedba vrijednosti vegetacijskog indeksa dobivenog na temelju digitalnog broja i refleksije na vrhu atmosfere, Geodetski list 1/16, 59–74
38. Sito S., Kovačić F., Krznarić K. ,Šket B., Šimunović V., Grubor M., Koren M. (2015). Primjena bespilotnih sustava u zaštiti trajnih nasada, - Glasnik zaštite bilja 4/15, 39-50
39. Sito S., Kovačić F., Krznarić K., Bilandžija N., Džaja V., Šket B., Grubor M. (2016). Primjena bespilotnih sustava u hortikulturnoj proizvodnji. Proceedings: 51st croatian and 11th international symposium on agriculture. Opatija, Croatia, 507-511
40. Šišić R., Hodžić A., Kevilj A., Hrustić O. (2013). Termografija i energetska učinkovitost stambenih objekata. Elektronički časopis građevinskog fakulteta Osijek, broj 7, stranice 24-31 (http://e-gfos.gfos.hr/app/storage/protected/42-09-06-2017-12-33-27-sisic-hodzic-kevilj-hrustic.pdf)
41. Torres-Sánchez J., López-Granados F., De Castro A.I., Peña-Barrag án J.M. (2013). Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. PLoS ONE 8(3) (https://doi.org/10.1371/journal.pone.0058210)
42. Tutić D., Vučetić N., Lapaine M. (2002). Uvod u GIS, Sveučilište u Zagrebu
43. Uredba o snimanju iz zraka – NN 73/13, NN 75/15 i NN 27/16
44. Vela E., Medved I., Miljković V. (2017). Geostatistička analiza vegetacijskih indeksa na šumskom ekosustavu Česma. Geodetski list, 1/17, 25–40

## Izvori s WEB stranica:

1. http://www.ccaa.hr/ - pristupljeno 22.9.2017.
2. https://www.dgu.hr/ - pristupljeno 23.9.2017.
3. http://www.crocontrol.hr/ - pristupljeno 23.9.2017.
4. https://amc.crocontrol.hr/- pristupljeno 28.9.2017.
5. https://www.sensefly.com/ - pristupljeno 29.9.2017.
6. https://geomatika-smolcak.hr/ - pristupljeno 29.9.2017.
7. http://www.gospodarski.hr/Publication/2016/9/iskustva-s-bespilotnim-letjelicama-u-poljoprivrednoj-proizvodnji/8467#.WcpNgGi0PIU - pristupljeno 27.9.2017.
8. https://support.pix4d.com - pristupljeno 3.10.2017.
9. https://www.sensefly.com/drones/ebee-sq.html - pristupljeno 11.10.2017.
10. http://uas.trimble.com/ux5-multispectral - pristupljeno 11.10.2017.
11. http://www.precisionhawk.com/lancaster - pristupljeno 11.10.2017.
12. https://www.parrot.com/us/business-solutions/parrot-disco-pro-ag#the-all-in-one-drone-solution-for-precision-agriculture - pristupljeno 11.10.2017.
13. http://ageagle.com/rx48-2/ - pristupljeno 11.10.2017.
14. https://www.sensefly.com/drones/albris.html - pristupljeno 11.10.2017.
15. http://www.asctec.de/en/uav-uas-drones-rpas-roav/asctec-falcon-8/ - pristupljeno 11.10.2017.
16. http://uas.trimble.com/microdrones-uavs - pristupljeno 11.10.2017.

17. https://www.aibotix.com/products/aibot-x6 - pristupljeno 11.10.2017.
18. https://sentera.com/omni/ - pristupljeno 11.10.2017.
19. http://www.eumetrain.org/data/3/36/print.htm- pristupljeno 12.10.2017.
20. https://umanitoba.ca/faculties/afs/agronomists_conf/media/8_-_2-30_-_Price_Dec_11_2014_RoboFlight.pdf - pristupljeno 12.10.2017.
21. https://atlas.micasense.com - pristupljeno 16.10.2017.
22. http://www.flir.com/suas/vuepro/ - pristupljeno 16.10.2017.
23. http://www.bayspec.com/spectroscopy/oci-uav-hyperspectral-camera/ - pristupljeno 18.10.2017.
24. http://gisgeography.com/multispectral-vs-hyperspectral-imagery-explained/ - pristupljeno 18.10.2017.
25. http://www.soltron.co.kr/data/file/item36_1/3698894957_XBQ3GCF0_45_NanoSAR_B_Data_Sheet.pdf/ - pristupljeno 19.10.2017.
26. http://www.cropos.hr/ - pristupljeno 20.10.2017.
27. https://www.gps.gov/ - pristupljeno 24.10.2017.
28. http://static1.1.sqspcdn.com/static/f/891472/12276139/1305728074980/Vegetation+spectral+indic - pristupljeno 30.10.2017.
29. http://www.imaging-resource.com/PRODS/NEX7/NEX7A.HTM- pristupljeno 15.12.2017.

# Životopis

Vedran Krevh rođen je 1993. godine u Zagrebu, gdje je završio XVI. jezičnu gimnaziju. Preddiplomski studij završio je 2015. godine sa završnim radom na temu „Mogućnosti efikasnijeg korištenja poljoprivrednih strojeva i opreme primjenom GPS-a“. Iste godine upisao je diplomski studij usmjerenja Melioracije na Agronomskom fakultetu Sveučilišta u Zagrebu. Počevši od 2014. godine, vodio je Hrvatsko udruženje studenata agronomije i srodnih znanosti sljedeće dvije godine. Iste godine realizirao je prvi projekt tutorstva na Agronomskom fakultetu, koji je predvodio u istom periodu, u suradnji s brojnim kolegama. Predstavljajući Agronomski fakultet, sudjelovao je na mnogim međunarodnim i nacionalnim okupljanjima studenata biotehničkih znanosti, od kojih je nekolicinu i organizirao. Stručni interesi vezani su mu za održivo gospodarenje zemljišnim i vodnim resursima, daljinska istraživanja te primjenu suvremenih tehnologija.