

Usporedba rezultata nadziranih klasifikacija hiperspektralnih i satelitskih snimki

Puljić, Ana

Master's thesis / Diplomski rad


2024

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:256:459783>

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

Download date / Datum preuzimanja: **2024-09-09**



Repository / Repozitorij:

repozitorij.geof.unizg.hr/en



**SVEUČILIŠTE U ZAGREBU
GEODETSKI FAKULTET**

Ana Puljić

**USPOREDBA REZULTATA NADZIRANIH
KLASIFIKACIJA HIPERSPEKTRALNIH I
SATELITSKIH SNIMKI**

Diplomski rad

Zagreb, 2024.

Ana Puljić ♦ DIPLOMSKI RAD ♦ 2024.



**SVEUČILIŠTE U ZAGREBU
GEODETSKI FAKULTET**

Ana Puljić

**USPOREDBA REZULTATA NADZIRANIH
KLASIFIKACIJA HIPERSPEKTRALNIH I
SATELITSKIH SNIMKI**

Diplomski rad

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU GEODETSKI FAKULTET



Na temelju članka 19. Etičkog kodeksa Sveučilišta u Zagrebu i Odluke br. 1_349_11 Fakultetskog vijeća Geodetskog fakulteta Sveučilišta u Zagrebu, od 26.10.2017. godine (klasa: 643-03/16-07/03), uređena je obaveza davanja

„Izjave o izvornosti“ diplomskog rada koji se vrednuju na diplomskom studiju geodezije i geoinformatike, a u svrhu potvrđivanja da je rad izvorni rezultat rada studenata te da taj rad ne sadržava druge izvore osim onih koji su u njima navedeni.

IZJAVLJUJEM

Ja, **Ana Puljić**, (JMBAG: 0007182034), rođena dana 17.09.1996. u Sisku, izjavljujem da je moj diplomski rad izvorni rezultat mojeg rada te da se u izradi tog rada nisam koristila drugim izvorima osim onih koji su u njemu navedeni.

U Zagrebu, dana 14.6.2024.

Ana Puljić

I. AUTOR	
Ime i prezime:	Ana Puljić
Datum i mjesto rođenja:	17. rujna 1996., Sisak, Republika Hrvatska
II. DIPLOMSKI RAD	
Naslov:	Usporedba rezultata nadziranih klasifikacija hiperspektralnih i satelitskih snimki
Broj stranica:	56
Broj tablica:	2
Broj slika:	20
Broj bibliografskih podataka:	14 + 24 URL
Ustanova i mjesto gdje je rad izrađen:	Geodetski fakultet Sveučilišta u Zagrebu
Mentor:	izv. prof. dr. sc. Andrija Krtalić
Voditelj:	izv. prof. dr. sc. Andrija Krtalić
III. OCJENA I OBRANA	
Datum zadavanja teme:	22.1.2024.
Datum obrane rada:	14.6.2024.
Sastav povjerenstva pred kojim je branjen diplomski rad:	izv. prof. dr. sc. Andrija Krtalić
	doc. dr. sc. Ana Kuveždić Divjak
	doc. dr. sc. Luka Rumora

Zahvala

Posebnu zahvalnost iskazujem svojim roditeljima Petru i Aniti na bezuvjetnoj podršci, ljubavi i vjeri koju su mi pružili tijekom cijelog mog školovanja. Hvala braći Matiji, Luki, Marku i sestri Luciji.

Neizmjerno hvala zaručniku Mateju na ljubavi, razumijevanju i podršci koja je bila temelj mog uspjeha i inspiracija za svaki korak.

Zahvaljujem se mentoru izv. prof. dr. sc. Andriji Krtaliću na strpljenju, savjetima i iskazanom povjerenju tijekom izrade ovog diplomskog rada.

Usporedba rezultata nadziranih klasifikacija hiperspektralnih i satelitskih snimki

Sažetak: U ovom diplomskom radu opisano je istraživanje primjene hiperspektralnih i multispektralnih satelitskih snimki za klasifikaciju urbanog područja, analizira njihove prednosti i ograničenja te su uspoređeni rezultati nadziranih klasifikacija područja dijela grada Zagreba, s ciljem identifikacije različitih tipova pokrova. Proučavala se točnost i pouzdanost klasifikacije te se ističe važnost odabira optimalnih metoda i vrsta snimki za mapiranje urbanih područja. Također, definirani su pojmovi daljinskih istraživanja, elektromagnetnog spektra, spektralnih kanala, senzora te rezolucija snimki. Praktični dio rada obuhvaća slijedeće aktivnosti: izoštravanje multispektralnih kanala, analizu spektralnih potpisa i kanala te nadziranu klasifikaciju područja primjenom metode *Spectral Angle Mapping*, *Maximum Likelihood Classification* na hiperspektralnoj i multispektralnoj snimci, te *Maximum Likelihood Classification* na snimkama sa prethodno izračunatim *Normaliziranim Vegetacijskim Indeksom* (NDVI).

Ključne riječi: nadzirana klasifikacija, hiperspektralna snimka, multispektralna satelitska snimka, NDVI indeks

Comparison of supervised classification results of hyperspectral and satellite images

Abstract: This master thesis explores the application of hyperspectral and multispectral satellite imagery for the classification of urban areas, analyzing their strengths and limitations, and comparing the results of supervised classifications of areas in part of the city of Zagreb to identify different land cover types. It examines the accuracy and reliability of classification and emphasizes the importance of selecting optimal methods and types of imagery for precise mapping of urban areas. Additionally, the thesis defines concepts of remote sensing, electromagnetic spectrum, spectral bands, sensors, and image resolution. The practical part of the work involves sharpening multispectral channels, analyzing spectral signatures and bands, and supervised classification of areas using the *Spectral Angle Mapping*, *Maximum Likelihood Classification* on hyperspectral and multispectral imagery, and *Maximum Likelihood Classification* on images with previously calculated *Normalized Difference Vegetation Index* (NDVI).

Keywords: Supervised classification, hyperspectral imagery, multispectral satellite imagery,

NDVI index

SADRŽAJ

1. UVOD	1
1.1. Ciljevi i zadaci	2
1.2. Hipoteza	3
1.3. Stručni doprinos	4
2. TEORIJSKE OSNOVE RADA	5
2.1. Daljinska istraživanja	5
2.2. Elektromagnetski spektar	5
2.3. Spektralni rasponi	7
2.4. Senzori u daljinskom istraživanju	9
2.5. Rezolucija snimki	9
3. METODOLOŠKI PRISTUP	12
3.1. Multispektralni sustav	12
3.2. Hiperspektralni sustav	12
3.3. Klasifikacija snimki	14
3.4. Spektralni potpisi	15
3.5. ENVI sotver	17
3.6. Izvori podataka	17
3.6.1. WorldView-2 Satellite Sensor (0.50m)	17
3.6.2. HySpex	19
4. ANALIZA I OBRADA PODATAKA	22
4.1. Područje istraživanja	22
4.2. Izoštavanje multispektralnih kanala	22
4.3. Analiza spektralnih potpisa	23
4.4. Nadzirana klasifikacija	26
4.4.1. Nadzirana klasifikacija metodom <i>Spectral Angle Mapping</i>	26
4.4.2. SAM klasifikacija multispektralne snimke	27
4.4.3. SAM klasifikacija hiperspektralne snimke	28
4.5. Nadzirana klasifikacija metodom <i>Maximum Likelihood</i>	31
4.5.1. <i>Maximum Likelihood</i> klasifikacija multispektralne snimke	31
4.5.2. <i>Maximum Likelihood</i> klasifikacija hiperspektralne snimke	32
4.5.3. Usporedba rezultata i analiza	33
4.6. Normalizirani indeks vegetacije	34
4.7. Upotreba NDVI-a u klasifikaciji	36
4.7.1. Usporedba rezultata i analiza	38
5. DISKUSIJA	40
6. ZAKLJUČAK	42
7. LITERATURA	43

INTERNETSKI IZVORI.....	44
POPIS SLIKA.....	46
POPIS TABLICA.....	47

1. UVOD

Daljinsko istraživanje je znanost i tehnologija snimanja, obrade i analize snimki, zajedno s drugim fizikalnim podacima Zemlje i planeta, posredstvom senzora iz svemira, iz zraka i s tla. Specifičnost daljinskog istraživanja je u pohranjivanju snimki (informacija o istoj sceni - terenu) u različitim valnim duljinama. Podaci prikupljeni daljinskim istraživanjem predstavljaju količinu energije elektromagnetskog zračenja (EMR) koju reflektira ili emitira neki objekt. Tehnike daljinskog istraživanja koriste se za prikupljanje informacija o objektu bez potrebe ili mogućnosti za fizičkom interakcijom. To nam omogućuje opažanja koja inače ne bi bila moguća.

Geoprostorne podatke potrebno je obraditi i analizirati kako bi se iz njih izvukle značajne i djelotvorne informacije. Slika može vrijediti više od tisuću riječi, ali potrebno je nekoliko koraka da ta slika govori jezikom koji razumijemo.

Daljinsko istraživanje koristi senzore instalirane na različite platforme (u svemiru/u zraku) za mjerenje energetskih odziva. Senzori se dijele na aktivne i pasivne, u odnosu na potrebu izvora energije. Aktivni senzori osvjetljavaju metu vlastitim izvorom energije i mjere vrijeme, fazu, intenzitet i druge karakteristike reflektirane energije. Pasivni senzori mjere prirodnu energiju, obično sunčevu svjetlost, koja se reflektira ili emitira od objekta. (URL 1). Dvije različite vrste snimki dobivene korištenjem pasivnih senzora, koje se razlikuju po broju spektralnih kanala i spektralnoj rezoluciji su hiperspektralne i multispektralne snimke. Spektralna rezolucija je sposobnost senzora da razluči određeni dio spektra i pohrani ga kao digitalnu sliku. Hiperspektralne snimke imaju puno finiju spektralnu rezoluciju što rezultira puno većim brojem spektralnih kanala snimke.

Multispektralni senzori daljinskih istraživanja prikupljaju podatke iz vidljivog i blisko-infracrvenog područja elektromagnetskog spektra. Ova grubo spektralna kategorizacija reflektirane i emitirane energije s površine Zemlje primarni je ograničavajući faktor multispektralnih senzora. Tijekom posljednjih 2 desetljeća, razvoj zrakoplovnih i satelitskih hiperspektralnih senzora prevladao je ograničenja multispektralnih senzora.

Hiperspektralni senzori prikupljaju mnoštvo uskih spektralnih pojaseva iz vidljivog, blisko-infracrvenog, srednje-infracrvenog i kratkog-valnog infracrvenog dijela

elektromagnetskog spektra. Ti senzori obično prikupljaju 200 ili više spektralnih pojaseva, omogućujući pohranu gotovo kontinuiranog spektralnog potpisa refleksije. Osim toga, uski spektralni pojasevi karakteristični za hiperspektralne podatke omogućuju detaljniju analizu zemljinih površinskih značajki koje bi inače bile izgubljene unutar relativno grubih pojaseva prikupljenih multispektralnim podacima.

Podaci dobiveni daljinskim istraživanjem često se koriste za klasifikaciju i kartiranje vegetacije na velikim područjima, zamjenjujući tradicionalne metode klasifikacije koje zahtijevaju skupe i vremenski zahtjevne terenske aktivnosti.

Klasifikacija slike je proces dodjele klasa značajkama na slici. Što je više spektralnih kanala, to više mogu biti nijansirane klase u klasifikaciji slike. Cilj klasifikacije slike je proizvesti korištenje zemljišta/zemljišni pokrov. Softver za daljinsko istraživanje, poput softvera za obradu i analizu slike ENVI, koristi se za klasifikaciju zemljišnog pokrova. Različite vrste zemljišnog pokrova mogu se lakše razlikovati na provedenim klasifikacijama objekata na sceni, koje su izrađene korištenjem algoritama za klasifikaciju slika. Klasifikacija slike se temelji na spektralnim informacijama pojedinačnih piksela. Nenadzirana klasifikacija ili klastering, se provodi u svrhu ispitivanja mogućnosti klasifikatora, s danim setom slika, u razlučivanju pojedinih klasa koje operator može kognitivno razlučiti kao različite. Nadalje, korisnik može odrediti područja poznatog zemljišnog pokrova kako bi "trenirao" program za grupiranje sličnih piksela, što se naziva nadziranom klasifikacijom. (URL 2).

1.1. Ciljevi i zadaci

Cilj diplomskog rada je usporediti rezultate nadziranih klasifikacija područja grada Zagreba, korištenjem hiperspektralnih i multispektralnih satelitskih snimki. Dva odabrana izvora podataka uključivala su multispektralne WorldView-2 satelitske snimke i hiperspektralne snimke senzora HySpex. Nadzirana klasifikacija obavljena je koristeći statističke klasifikatore, *Maximum Likelihood* i *Spectral Angle Mapping*. Osim toga, provedeno je ispitivanje NDVI indeksa za svaku snimku, te je izvršena klasifikacija NDVI vrijednosti radi identifikacije i analize različitih tipova pokrova na području grada Zagreba. Provedene su sljedeće aktivnosti:

1. Istražene su mogućnosti hiperspektralne (HySpex) i satelitske snimke (WorldView-2) analizirajući njihove karakteristike i mogućnosti primjene

2. Provođenje nadzirane klasifikacije hiperspektralne i multispektralne snimke metodom *Spectral Angle Mapping* za analizu i identifikaciju tipova pokrova zemljišta.
3. Provođenje nadzirane klasifikacije hiperspektralne i multispektralne snimke metodom *Maximum Likelihood* radi preciznog određivanja pokrova zemljišta.
4. Usporedba rezultata nadziranih klasifikacija i analiza kvalitete i preciznosti rezultata dobivenih iz hiperspektralne snimke (HySpex) i satelitske snimke (WorldView-2), pružajući dublji uvid u njihovu primjenjivost.
5. Računanje NDVI indeksa za svaku snimku pomoću raster kalkulatora
6. Klasifikacija NDVI vrijednosti metodom *Maximum Likelihood* i analiza kvalitete i preciznosti rezultata
7. Usporedba rezultata klasifikacije metodom *Maximum Likelihood* na snimkama sa izračunatim NDVI
8. Procjena potencijala za buduća istraživanja: Kroz procjenu potencijala za buduća istraživanja, razmotrit će se mogućnosti daljnjeg razvoja i primjene u području daljinskih opažanja temeljenih na rezultatima usporedbe.

1.2. Hipoteza

Iz postavljenih ciljeva i na temelju poznavanja problematike, može se postaviti sljedeća hipoteza:

- *Na temelju postavljenih ciljeva istraživanja, pretpostavlja se da će usporedba i analiza rezultata nadziranih klasifikacija hiperspektralnih i multispektralnih snimki omogućiti dublje razumijevanje njihove primjenjivosti i preciznosti. Prema tome, očekuje se da će hiperspektralne snimke pružiti detaljnije informacije o spektralnim karakteristikama scene, što bi trebalo rezultirati preciznijom klasifikacijom u usporedbi s multispektralnim snimkama. Međutim, multispektralne snimke mogu pružiti širu pokrivenost područja i dostupne su s većeg broja satelita, što može biti korisno u određenim situacijama. Ova hipoteza bit će provjerena kroz analizu rezultata klasifikacija kako bi se potvrdila ili opovrgla te omogućilo donošenje zaključaka o primjenjivosti hiperspektralnih i multispektralnih snimki u daljinskim istraživanjima.*

Ispitivanjem ove hipoteze u istraživačkom procesu omogućit će se dobivanje zaključnih tvrdnji.

1.3. Stručni doprinos

Ovaj rad istražuje primjenu hiperspektralnih i multispektralnih snimki za klasifikaciju urbanih površina. Kroz analizu rezultata istraživanja, rad će pružiti dublje razumijevanje primjenjivosti i preciznosti obje vrste snimki, ističući njihove prednosti i ograničenja. Očekuje se da će ovo istraživanje koristiti stručnjacima iz područja geoinformatike, urbanog planiranja i prostornog modeliranja, pružajući im smjernice za bolje razumijevanje i primjenu hiperspektralnih i multispektralnih podataka u analizi urbanih područja. Kroz praktične primjere i testiranje različitih metoda klasifikacije, rad će doprinijeti boljem razumijevanju vrsta navedenih snimki i njihovih prednosti jedne nad drugom.

2. TEORIJSKE OSNOVE RADA

2.1. Daljinska istraživanja

Daljinsko istraživanje (eng. *Remote Sensing*, njem. *Fernerkundung*, fra. *Teledétectioni*) je znanost i tehnologija snimanja, obrade i analize snimki, zajedno s drugim fizikalnim podacima Zemlje i planeta, posredstvom senzora iz svemira, iz zraka i s tla (ISPRS) (URL 3). Zrakoplovi, sateliti i svemirske sonde, a u današnje vrijeme sve više i dronovi, uobičajene su platforme za opažanja u daljinskom istraživanju. Termin daljinsko istraživanje je obično ograničen na metode koje se koriste elektromagnetskom energijom kao sredstvom za otkrivanje i mjerenje značajki objekata. Takva definicija daljinskog istraživanja isključuje električna, magnetska i gravitacijska mjerenja kojima se mjeri snaga polja, a ne elektromagnetsko zračenje (Gierloff-Emden, 1989., 4). U užem smislu, daljinsko istraživanje je prikupljanje informacija o Zemljinoj površini s uređajima smještenim na različitim platformama i interpretacija tako dobivenih informacija.

Svako tijelo na Zemljinoj površini emitira energiju dijela elektromagnetskog spektra određene frekvencije i valne duljine. Emitirana energija objekata posljedica je uglavnom Sunčevog zračenja. Ona zavisi od svojstava objekata: njihovog sastava, boje i sposobnosti apsorpcije Sunčeve energije te sposobnosti emitiranja absorbirane energije. Jedan dio emitirane energije gubi se u prolasku kroz slojeve atmosfere, a manji dio primaju specijalna osjetila tzv. senzori ugrađeni u letjelicama. Registriranje promjena u vrsti i količini primljene elektromagnetske energije i njena vizualizacija suština je daljinskog istraživanja, jer se na taj način dobivaju različite informacije o kvaliteti i kvantiteti objekata na Zemljinoj površini i odnosima među njima (Frančula, 1994.).

2.2. Elektromagnetski spektar


Elektromagnetska energija putuje u valovima i obuhvaća široki spektar od vrlo dugih radio valova do vrlo kratkih gama zraka. Ljudsko oko može detektirati samo mali dio ovog spektra koji se naziva vidljiva svjetlost. NASA-ini znanstveni instrumenti koriste cijeli raspon elektromagnetskog spektra za proučavanje Zemlje, Sunčevog sustava i svemira izvan njega (URL 4).

Većina elektromagnetskog zračenja koje utječe na Zemlju dolazi od Sunca. Ovo zračenje možemo razumjeti gledajući njegov raspon valnih duljina i frekvencija, od

radiovalova dugih valnih duljina i niskih frekvencija, do gama valova kratkih valnih duljina i visokih frekvencija. Zajedno, sve te različite vrste energije, od kojih je većina nevidljiva ljudskom oku, nazivaju se elektromagnetski spektar ili skraćeno spektar (Slika 1). Svaki dio elektromagnetskog spektra ima karakteristične razine energije, valne duljine i frekvencije (URL 5).

Elektromagnetski spektar definira sve vrste spektra, uključujući i one koje ljudsko oko ne može vidjeti. Zapravo, većina spektra u svemiru nevidljiva je ljudskom oku. Dio spektra koji možemo vidjeti, sastavljen od pojedinačnih duginih boja, predstavlja samo vrlo mali dio elektromagnetskog spektra (URL 6).

Vrsta zračenja koje emitira neki objekt ovisi o njegovoj temperaturi, odnosno ranije apsorbiranoj energiji. Stvari koje su hladnije emitiraju zračenje na nižim frekvencijama i stoga na dužim valnim duljinama. Suprotno tome, stvari koje su toplije emitiraju zračenje na višim frekvencijama i kraćim valnim duljinama (URL 7).



Slika 1. Elektromagnetski spektar (modificirano prema URL 1)

Postoji sedam skupina elektromagnetskih spektara (slika 1.). Na desnoj strani prikazanog elektromagnetskog spektra su radiovalovi, najnižefrekventni oblik zračenja s najvećim valnim duljinama. Mnogi prirodni objekti emitiraju radio valove, od planeta do zvijezda, ali i drugi fenomeni, poput munja. S desna prema lijevo slijede mikrovalovi, zatim infracrveno, vidljivo svjetlo (oblik zračenja koje možemo vidjeti), ultraljubičasto, X-zrake i gama zrake. Svi ovi oblici zračenja putuju istom brzinom u svemirskom vakuumu, brzinom svjetlosti, odnosno oko 300 milijuna metara u sekundi (300 000 km/s). Svaka vrsta elektromagnetskog spektra zračenja nastaje tako što čestice ubrzavaju električnim poljem i proizvode oscilirajuće valove električnog i magnetskog polja. Udaljenost između vrhova tih valova je valna duljina zračenja, a broj valova je frekvencija (URL 1).

2.3. Spektralni rasponi

Spektralni rasponi su skupine valnih duljina. Na primjer, ultraljubičasto, vidljivo, blisko infracrveno, termalno infracrveno i mikrovalno su spektralni rasponi. Satelitski senzori koji se koriste u daljinskom istraživanju mogu biti podešeni za detekciju spektra u valnim duljinama koje su nevidljive golom oku. Svaki spektralni raspon odgovara određenom rasponu valnih duljina koje prenose specifične informacije o značajkama od interesa. Kombiniranje slika u vidljivom rasponu s različitim satelitskim rasponima pomaže pri vizualiziranju slike.


Reflektivnost spektra mjerena preko više spektralnih raspona može se vizualizirati na grafu pomoću spektralne krivulje. Ova krivulja omogućuje detaljnije razumijevanje kako različite značajke ili objekti reagiraju na različite dijelove elektromagnetskog spektra (URL 8).

Rasponi kanala zračnih ili satelitskih snimki mogu se kombinirati na više načina, ovisno o značajki koja treba biti istaknuta na slici. Budući da ljudsko oko može vidjeti samo unutar vidljivog raspona spektra, većina slika sastoji se od kombinacija crvenih, zelenih i plavih kanala, kako bi se oponašao vidljivi spektar. Ova kombinacija spektralnih raspona poznata je kao "prava" ili "prirodna" boja. Kada određena površinska značajka treba biti istaknuta na slici, koriste se spektralni rasponi iznad i ispod vidljivog raspona. Sirovi podaci podvrgavaju se obradi kako bi se smanjio šum na slici. Rezultat je takozvana "neprava" ili "lažna" boja slike koja može istaknuti zdravu vegetaciju, oblake, vlažnost tla, točke s visokom temperaturom i druge značajke. Korištenjem posebno razvijenih matematičkih algoritama, istaknute značajke također se mogu mjeriti kako bi se pružili kvantitativni podaci.

Crveni, zeleni i plavi spektralni kanali široko pokrivaju vizualno područje elektromagnetskog spektra. Plave valne duljine protežu se od oko 400 do 450 nm, zelene valne duljine protežu se od oko 500 do 600 nm, a crvene valne duljine protežu se od oko 600 do 700 nm. RGB kanali koriste se za: klasifikaciju pokrova zemlje i otkrivanje promjena, monitoring urbanog i infrastrukturnog razvoja, praćenje vegetacije i usjeva.

RGB kanali se koriste za stvaranje slika u pravim bojama i lažnim bojama (Slika 2). U slikama u pravim bojama, boje na slici usko odgovaraju prirodnim bojama objekata kao što ih vidi ljudsko oko. Kod slika u lažnim bojama, boje dodijeljene različitim pojasevima nisu reprezentativne za objekte, kako bi ih percipiralo ljudsko oko. Budući da se drugi multispektralni pojasevi nalaze izvan vidljivog spektra, odabir raspona ističe određene značajke koje nisu razlikovane u slikama u pravim bojama. Prikazi lažnih boja mogu biti

različiti, ovisno o tome koji se skup pojaseva odabere. Najčešća vizualizacija kombinira crvene, zelene i NIR pojaseve. Prikazuje crveni pojas u zelenoj boji, zeleni pojas u plavoj boji i NIR pojas u crvenoj boji (URL 9).



Slika 2. Usporedba snimki prikazanih pravim (lijevo) i lažnim (desno) bojama (modificirano prema URL 10)

Spektralni raspon blizu infracrvenog (NIR) bilježi zračenje netom izvan vidljivog crvenog dijela spektra na elektromagnetskom spektru. Proteže se u rasponu valnih duljina od 700 do 1000 nm. Ovaj spektralni raspon dobro definira i diferencira vode i vegetacijske površine. Vegetacija snažno reflektira spektar u ovom spektralnom području, a promjene u refleksiji ukazuju na zdravlje vegetacije. NIR pojas koristi se za: detekciju vode i vodene pare, monitoring zdravlja vegetacije i spektralni indeksi.

Spektralni raspon kratkog valnog infracrvenog (SWIR) zračenja proteže se u rasponu valnih duljina od 1000 do 3000 nm. Ovaj spektralni raspon pruža informacije o sastavu materijala i karakteristikama površine. Može prodrijeti kroz atmosferske efekte poput magle i vlage, te je koristan za proučavanje površine Zemlje. SWIR pojas koristi se za: monitoring infrastrukture, analizu sastava tla, identifikaciju minerala, NBR indeks.

Termalni infracrveni (TIR) ili dugovalni infracrveni spektralni pojas proteže se u rasponu valnih duljina od otprilike 3000 do 100 000 nm. Ovaj spektralni raspon bilježi termalno zračenje koje emitiraju objekti i Zemljina površina. (URL 9)

2.4. Senzori u daljinskom istraživanju

Uređaji za registriranje elektromagnetske energije dijele se prema različitim značajkama. S obzirom na izvore energije dijele se na pasivne i aktivne. Pasivni uređaji registriraju emitirano ili reflektirano zračenje objekata na Zemljinoj površini. U aktivnim uređajima koriste se vlastiti izvori energije, koja se odašilje prema Zemljinoj površini odakle se njen reflektirani dio prima i registrira. Duljina elektromagnetskih valova još je jedna značajka važna za podjelu uređaja daljinskih istraživanja. Za daljinska istraživanja Zemljine površine u obzir dolaze vidljivi dio spektra (0,4-0,7 μm) i mikrovalni (0,3-30 cm). Senzor je sustav koji prima elektromagnetsko zračenje registrira ga mjeri i pohranjuje u obliku prikladnom za dalju obradu. Nema sumnje da su senzori za daljinsko istraživanje postali ključni alat za praćenje i razumijevanje Zemljine površine i atmosfere, od praćenja vremenskih obrazaca i mapiranja prirodnih resursa do praćenja kretanja vozila. (URL 11).

Postoje različite vrste senzora koji se koriste u daljinskom istraživanju, a svaki od njih ima svoje jedinstvene karakteristike i sposobnosti. Senzori mogu biti instalirani na satelite, zrakoplove i dronove, ali mogu biti i postavljeni na tlu kako bi prikupljali trenutne ili vremenske podatke.

Aktivni senzori su oni koji imaju vlastiti izvor energije koju odašilju prema objektima koje promatraju. Primjer takvih senzora je radar, koji emitira elektromagnetsko zračenje prema cilju te mjeri reflektiranu energiju i vrijeme potrebno za povrat odaslane energije. S druge strane, pasivni senzori koriste prirodne izvore energije, poput Sunca, za prikupljanje reflektirane radijacije. Također, senzori se mogu klasificirati prema načinu prikupljanja podataka. Senzori koji stvaraju digitalne slike i senzori koji pohranjuju digitalne podatke ali ne u obliku slika, nego mjere signal na temelju intenziteta cijelog polja gledišta, uglavnom kao zapis profila (visinomjer, mjerač tlaka i temperature u atmosfere i slično) (URL 11).


Odabir senzora ovisi o primjeni i podacima koji su potrebni. Sustavi daljinskog istraživanja dizajnirani su za prikupljanje podataka iz različitih dijelova elektromagnetskog spektra, te se senzor mora odabrati kako bi odgovarao željenim valnim duljinama i rezoluciji (URL 12).

2.5. Rezolucija snimki

Rezolucija ili razlučivost označava sposobnost nekog sustava da odvojeno preslika

površinske, spektralne i radiometrijske detalje na snimci. U metodama daljinskog istraživanja najviše se koriste slijedeće četiri vrste rezolucija: prostorna, spektralna, radiometrijska i vremenska rezolucija. Ove četiri vrste rezolucija određuju količinu i kvalitetu informacija na slici (URL 13).

Prostorna rezolucija je pojam koji se koristi u daljinskom istraživanju, kartografiji, fotogrametriji i drugim tehničkim disciplinama kako bi se opisala sposobnost senzora da razlikuje objekata ili detalje u prostoru (Slika 3). U kontekstu satelitskih i zračnih snimki, prostorna rezolucija opisuje najmanju površinu Zemlje koja se preslika na jedan piksel, odnosno koju senzor može jasno i odvojeno detektirati. Drugim riječima, ona određuje koliko su detalji vidljivi na snimci (URL 13).




Slika 3. Prikaz različitih prostornih rezolucija (modificirano prema URL 12)

Spektralna razlučivost opisuje sposobnost senzora da detektira razlike u elektromagnetskom spektru. Odnosi se na broj i širinu spektralnih kanala (bandova) koje senzor može zasebno razaznati i pohraniti, kao i na širinu spektralnih raspona koje ti kanali pokrivaju. Primjerice, senzor s visokom spektralnom razlučivošću može diferencirati široki raspon valnih duljina unutar elektromagnetskog spektra, što omogućuje preciznije razlikovanje materijala i objekata na temelju njihovih spektralnih svojstava (URL 13).

Radiometrijska rezolucija odnosi se na sposobnost senzora daljinskog istraživanja da razlikuje različite razine intenziteta svjetlosti. Ona opisuje broj razina svjetlosti koje senzor može razaznati i odvojeno pohraniti. Radiometrijska rezolucija izražava se u bitovima po pikselu, a veća vrijednost bita omogućuje veći raspon razlikovanja između najtamnijih i najsvjetlijih dijelova snimke (Slika 4). Primjerice, senzor s radiometrijskom rezolucijom od 8 bita može razlikovati 256 razina intenziteta svjetlosti (2^8), dok senzor s 16-bitnom rezolucijom može razlikovati 65,536 razina (2^{16}). Veća radiometrijska rezolucija omogućava detaljnije snimanje varijacija u reflektiranoj i emitiranoj radijaciji s površine Zemlje, što je

korisno u preciznom kvantificiranju i analizi zemljišnih pokrova, zdravlja vegetacije, vodnih tijela i drugih prirodnih i antropogenih karakteristika (URL 13).



Slika 4. Prikaz različitih radiometrijskih rezolucija (modificirano prema URL 12)


Vremenska rezolucija odnosi se na učestalost kojom senzor ili satelitski sustav može ponovno snimiti ili posjetiti određeno geografsko područje. Ova mjera je ključna za razumijevanje promjena koje se događaju na Zemlji tijekom vremena, uključujući praćenje promjena u okolišu, urbanizacije, vegetacije, promjene klimatskih uvjeta i drugih dinamičkih pojava. Primjerice, satelit s visokom vremenskom rezolucijom može snimiti isto područje svakih nekoliko dana, što omogućuje istraživačima da prate brze promjene, poput poplava ili šumskih požara. Nasuprot tome, sateliti s nižom vremenskom rezolucijom mogu pokrivati isto područje svaka dva tjedna ili čak jednom mjesečno, što ih čini manje pogodnim za praćenje brzih promjena, ali i dalje korisnima za dugoročne studije promjena u okolišu (URL 13).

3. METODOLOŠKI PRISTUP

3.1. Multispektralni sustav

Za razliku od tradicionalnih kamera koje podatke prikupljaju u tri primarna kanala (crveni, zeleni i plavi) koji odgovaraju vidljivom spektru, multispektralni sustavi (MSI) koji se koriste u daljinskom istraživanju mogu prikupljati i podatke izvan vidljivog dijela spektra, uključujući ultraljubičastom, bliskom i srednje infracrvenom dijelu spektra.

MSI (Slika 5) koristi senzore koji su osjetljivi na različite dijelove elektromagnetskog spektra. Ti senzori detektiraju energiju koju reflektiraju ili emitiraju objekti unutar njihovih specifičnih spektralnih raspona. MSI izrađuje i pohranjuje više slika iste scene, svaka u drugom spektralnom rasponu. To postiže ili istovremeno, koristeći senzorski niz opremljen filtrima za različite pojaseve, ili sekvencijalno, zamjenjujući filtre ispred pojedinog senzora ili provodeći više prolaza preko ciljanog područja. Zatim sustav obrađuje sirove slike. Ovaj korak uključuje ispravljanje atmosferskih smetnji i šuma senzora. Nakon dobivanja slika, sljedeći korak uključuje analizu spektralnih podataka radi identifikacije materijala i procjene stanja. Analiza se provodi usporedbom promatranih spektralnih potpisa s poznatim potpisima specifičnih materijala. Osim toga, uključuje upotrebu statističkih i algoritama strojnog učenja za klasifikaciju područja slike na temelju njihovih spektralnih svojstava (URL 14).



Slika 5. Shematski prikaz općenite multispektralne kamere(modificirano prema URL 14)

3.2. Hiperspektralni sustav

Prikupljanje podataka hiperspektralnim sustavom (HSI) je proces u kojem se stvaraju snimke visoke spektralne razlučivosti dijeljenjem elektromagnetskog spektra na mnoge uske, susjedne spektralne raspone, obično između vidljivih i infracrvenih valnih duljina. Različiti

objekti i pojave na Zemljinoj površini reflektiraju, apsorbiraju, raspršuju i emitiraju spektar na određenim valnim duljinama, što stvara jedinstveni i karakteristični spektralni potpis koji hiperspektralni senzori mogu identificirati. HSI je znatno poboljšalo poimanje Zemljine površine i njezinih značajki, drugih planeta, svjesnost o svemiru, s većom preciznošću nego kod multispektralnih sustava.


MSI prikupljaju elektromagnetsko zračenje u malom broju kanala (oko 15-ak), širih spektralnih raspona, dok HSI prikupljaju podatke o sceni u mnogo većem broju spektralnih kanala (do nekoliko stotina), koji su jedan pored drugoga i pokrivaju uske spektralne raspone (i do 10 nm). Slike u boji se stvaraju kombinacijom po triju kanala svakog sustava. RGB prikaz prirodne slike u boji pretpostavlja kombinacije crvenog, zelenog i plavog kanala, međutim, i za MSI i za HSI se mogu stvarati slike u boji s bilo koja 3 kanala (URL 15).

Visoko razlučiva mjerenja dobivena hiperspektralnim sensorima HSI-ma omogućuju stvaranje detaljnih spektralnih podataka, koji se uspoređuju s knjižnicama ili bazama poznatih spektralnih potpisa materijala kako bi se identificirali površinski materijali. Na taj način se površinski materijali mogu identificirati usporedbom ovih izmjerenih spektara s bazama poznatih spektralnim karakteristikama materijala, poput *Spektralne knjižnice Geološkog istraživanja Sjedinjenih Država (USGS)* i *Nacionalne spektralne baze podataka Digitalne Zemlje Australije (NSD)*.

HSI pokazalo je učinkovitost u kartiranju minerala i tla, vrsta vegetacije, sastava i zdravlja, plitkih obalnih i koraljnih staništa te kvalitete vode. HSI se često fokusira na diskretni spektralni dio za određene primjene. HSI omogućuje vidljivost bliže cilju, ne u smislu prostorne već spektralne razlučivosti, što znači da vidljivost njegovog kemijskog sastava i karakteristika umjesto finije prostorne vidljivosti. Budući da HSI pruža obilje informacija u stotinama spektralnih raspona, slike postaju teške za vizualizaciju. Kako bi se analizirale sve informacije iz svih spektralnih pojaseva, potrebna je složena obrada slika. Uobičajeni formati podataka koje koristi HSI su spektralne kocke, iz koji se izračunavaju krivulje koeficijenta refleksije za svaki kanal (URL 24).

Hiperspektralna kocka je skup podataka (velikog broja spektralnih kanala) dobiven HSI-em, koja se može vizualizirati u 3D prostoru na način da su dvije dimenzije prostorne (X i Y), a treća dimenzija predstavlja spektralne informacije (valne duljine). Drugim riječima, svaki piksel u slici sadrži isti X i Y, a različitu vrijednost valne duljine koje su prikazane na osi

Z. To omogućuje detaljnu analizu materijala i objekata na sceni temeljem njihovih spektralnih svojstava. U hiperspektralnoj kocki, X i Y osi predstavljaju prostorne dimenzije scene, dok Z os predstavlja spektralnu dimenziju koja sadrži informacije u različitim valnim duljinama (koeficijent reflektivnosti). Ovakva struktura omogućava precizniju identifikaciju i klasifikaciju materijala, nego kod MSI-a, jer se temelji na puno većem broju njihovih jedinstvenih spektralnih potpisa. Hiperspektralna kocka se često koristi u različitim znanstvenim i industrijskim aplikacijama, uključujući poljoprivredu, ekologiju, rudarstvo, medicinu, i vojnu upotrebu. Na slici 6. je prikazana konstrukcija hiperspektralne kocke, gdje se uzastopnim linijama skeniranja formiraju prostorni pikseli s X i Y koordinatama ($1 \times n$) piksela, a za svaki piksel se stvaraju različiti spektralni odzivi, u odnosu na dio spektra u kojem se nalazi, i na taj način simulirajući trodimenzionalni skup podataka (URL 15).



Slika 6. Konstrukcija hiperspektralne kocke (modificirano prema URL 15)

Za svaki spektralni kanal mjereno u HSI generira se graf koeficijenata refleksije. To znači da se za svaki piksel u slici može prikazati krivulja koeficijenata refleksije. Krivulje koeficijenata refleksije omogućuju analizu scene detaljno, piksel po pikselu, i često se uparaju uz spektralnu kocku za analize područja od interesa (URL 15).

3.3. Klasifikacija snimki

Jedna od najvažnijih funkcija podataka dobivenih daljinskim istraživanjem je izrada karata korištenja zemljišta i pokrova zemljišta i može se upravljati kroz proces nazvan klasifikacija slike. U ovom radu se istražuju komponente i postupci povezani s procesom klasifikacije digitalnih snimki, te tehnike klasifikacije digitalnih snimki i objašnjava tri

uobičajene metode klasifikacije: *Spectral Angle Mapping* i *Maximum Likelihood*.

Klasifikacija slika se temelji na ideji da različite vrste značajki na površini Zemlje imaju različite spektralne odzive, a njihovo prepoznavanje se provodi kroz proces klasifikacije. U širem smislu, klasifikacija slika definira se kao proces kategorizacije piksela u slici kako bi se identificirale različite vrste zemljišnog pokrova ili druge karakteristike koje su od interesa. Postoji nekoliko pristupa klasifikaciji koji su razvijeni i široko korišteni za izradu karata pokrova zemljišta. Međutim, postoje tri glavne vrste metoda klasifikacije, a to su: nadzirane (polu-automatske) klasifikacijske metode, nenadzirane (automatske) klasifikacijske metode i objektno orijentirane (engl. object-based) klasifikacijske metode (El Rahman 2015).

Nadzirana klasifikacija slika je metoda u kojoj se koriste unaprijed definirani uzorci kako bi kategorizirala piksele na slikama. Analitičar odabire reprezentativna područja za svaku klasu pokrova zemljišta i koristi te podatke za izgradnju klasifikacijskog modela. Ovaj model se zatim primjenjuje na cijelu sliku kako bi se identificirale različite vrste pokrova zemljišta. Prednost ove metode je visoka točnost zbog kontroliranog odabira uzoraka, ali zahtijeva stručnost i može biti vremenski zahtjevna (URL 16).

Nenadzirana klasifikacija slika je metoda koja automatski grupira piksele na slici u klase na temelju njihovih spektralnih karakteristika, bez unaprijed definiranih uzoraka, ali s brojem odabranih klasa. Softver za interpretaciju slika koristi algoritme za identifikaciju prirodnih grupa piksela sličnih vrijednosti koeficijentata reflektivnosti. Ova metoda omogućava otkrivanje obrazaca i klasa koje je teško razlučiti automatski, prema njihovim vrijednostima piksela ili koeficijentata reflektivnosti, što može biti korisno za istraživačke svrhe. Manje je precizna od nadzirane klasifikacije, brža je i ne zahtijeva stručnost u odabiru uzoraka (Jwan Al-doski, 2013).

Klasifikacija temeljena na objektima ili objektno orijentirana klasifikacija koristi i spektralne i prostorne informacije za klasifikaciju. Proces uključuje kategorizaciju piksela na temelju njihovih spektralnih karakteristika, oblika, teksture i prostornih odnosa s okolnim pikselima.

3.4. Spektralni potpisi

Na površini Zemlje, objekti reflektiraju, apsorbiraju, prenose i emitiraju elektromagnetsku energiju koja dolazi od Sunca. Razvijeni su specijalizirani digitalni senzori

kako bi mjerili različite vrste elektromagnetske energije i njihovu interakciju s objektima na Zemlji. Ova sposobnost senzora omogućuje korištenje metoda daljinskog istraživanja za analizu značajki i promjena na Zemlji i u atmosferi. Jedno od čestih mjerenja energije u daljinskom istraživanju je reflektirana energija, poput vidljive svjetlosti ili bliske infracrvene, koja dolazi s kopnenih i vodenih površina. Količina reflektirane energije obično se izražava kao omjer energije elektromagnetskog spektra koja se reflektirala od površine Zemlje (albedo) i ukupne energije koja je od nje došla. Reflektivnost je 100% kada se sva energija koja dopire do objekta reflektira, a reflektivnost je 0% kada se niti jedan dio elektromagnetskog spektra ne reflektira od površine. Većina objekata ima reflektivnost između dviju navedenih krajnosti. Kroz cijeli elektromagnetski spektar, postotci reflektivnosti za različite objekte mogu se uspoređivati i prikazivati na spektralnim krivuljama ili spektralnim potpisima. Spektralni potpisi su temeljni za analize i izdvajanje objekata u metodama daljinskog istraživanja, jer omogućavaju razlikovanje različitih tipova pokrova zemljišta. Što senzor detaljnije bilježi spektralne informacije, to je više informacija moguće preciznije definirati spektralne potpise. HSI pružaju znatno detaljnije informacije u usporedbi s MSI-a, što omogućuje preciznije detektiranje razlika među objektima. U nastavku su opisane spektralne karakteristike neke od glavnih klasa pokrova zemljišta (URL 16).

Vegetacija ima jedinstveni spektralni potpis koji omogućava da se lako razlikuje od drugih tipova pokrova zemljišta. Kod zdrave, zelene vegetacije koeficijent reflektivnosti je nizak u plavom i crvenom dijelu spektra, zbog apsorpcije klorofila. Najveći koeficijent reflektivnosti je u zelenom dijelu; zbog toga vegetaciju vidimo zeleno. Koeficijent reflektivnosti u bliskom infracrvenom (NIR) dijelu spektra je mnogo veći nego u vidljivom dijelu, zbog stanične strukture listova. Kod zdravih biljaka, više NIR se reflektira, a manje apsorbira, što uzrokuje da zdrava vegetacija ima visoku refleksiju u NIR (Gendaram, 2021).

Spektralna svojstva tla variraju ovisno o sadržaju vlage, mineralnom sadržaju i teksturi. Postoji obrnuti odnos između spektralne refleksije i sadržaja vlage: niska refleksija ukazuje na visoke razine vlage. Što je tlo glađe, refleksija je veća, a padovi u refleksiji rezultat su prisutnosti vode (Campbell i Wynne, 2011).

Voda je drugačija od tla i vegetacije jer se većina elektromagnetskog zračenja ili apsorbira ili prenosi. U vidljivom dijelu spektra mala količina se apsorbira ili reflektira, dok se većina prenosi. Postoji vrlo jaka apsorpcija u NIR. Dubina, materijal i hrapavost površine utječu na refleksiju vode. Spektralni potpis vode može se koristiti za određivanje kvalitete vode

i slično (URL 17).

Spektralni potpis izgrađenog zemljišta karakteriziran je visokom refleksijom u vidljivom i infracrvenom dijelu spektra zbog prisutnosti materijala poput betona i asfalta. Ti materijali obično imaju visoku reflektivnost u svim valnim duljinama osim u NIR području gdje mogu imati nižu reflektivnost zbog svojstava apsorpcije. Izgrađeno zemljište može se razlikovati od prirodnih površina analizom ovih spektralnih značajki (URL 17).

3.5. ENVI sotver

Za potrebe ovog diplomskog rada, obrada snimki i nadzirana klasifikacija izvršene su u softveru *ENVI* verzije 5.3. Softver omogućuje detaljnu analizu snimki visoke prostorne i spektralne razlučivosti, što je bilo ključno za ovo istraživanje. Zahvaljujući bogatom setu alata za klasifikaciju slika u *ENVI* softveru, moguće je identificirati i analizirati različite klase pokrova zemljišta i druge karakteristike bitne za provedeno istraživanje.

ENVI je komercijalno softversko rješenje za geoprostornu analizu i obradu slika koje se koristi za istraživanje, analizu i interpretaciju geoprostornih podataka. Razvijen od strane kompanije Exelis Visual Information Solutions, *ENVI* pruža širok spektar alata i funkcionalnosti za obradu i analizu različitih tipova slika, uključujući multispektralne, hiper-spektralne i SAR (Synthetic Aperture Radar) slike. Ovaj softver omogućava korisnicima da obavljaju različite zadatke, kao što su klasifikacija slika, detekcija promjena, izdvajanje značajki, georeferenciranje slika i još mnogo toga. *ENVI* također nudi napredne algoritme za analizu spektralnih svojstava materijala na Zemljinoj površini, što ga čini korisnim alatom za različite industrije poput poljoprivrede, šumarstva, geologije, urbanizma, obrane i drugih. Jedna od ključnih karakteristika *ENVI* softvera je njegova fleksibilnost i mogućnost integracije s drugim geoprostornim alatima i platformama, poput GIS softvera, satelitskih platformi i senzora, što omogućava korisnicima da stvore sveobuhvatna geoprostorna rješenja prilagođena njihovim potrebama i zahtjevima projekata (L3Harris Technologies, 2021).

3.6. Izvori podataka

3.6.1. WorldView-2 Satellite Sensor (0.50m)

U praktičnom dijelu ovog diplomskog rada korišteni su multispektralni podaci WorldView-110 kamere (WV110) satelitskog senzora WorldView-2, koji je lansiran 8.

listopada 2009. godine od strane tvrtke MAXAR.

WorldView 110 kamera je senzor koji nudi visokorezolucijski pankromatski kanal rezolucije 0.46 metara i osam (8) multispektralnih kanala; četiri (4) standardne boje (crvena, zelena, plava i NIR1) i četiri (4) nova kanala (obalna, žuta, crvena ivica i NIR2), koje omogućuju snimanje u punoj boji za poboljšanu spektralnu analizu, kartiranje minerala, praćenje divljih životinja, planiranje korištenja zemljišta, pomoć u katastrofama, obranu i promjene klime. Bitni parametri WorldView-110 kamere prikazani su u tablici 1.

S poboljšanom agilnošću, WorldView-2 djeluje poput kista, brzo prelazeći velike površine kako bi u jednom prolazu prikupio multispektralne snimke. Sam WorldView-2 može svakodnevno prikupiti gotovo 1 milijun km² podataka, čime se kapacitet prikupljanja naše konstelacije udvostručuje na gotovo 2 milijuna km² dnevno. Kombinacija povećane agilnosti i velike visine omogućuje WorldView-2 tipično ponovno posjećivanje bilo kojeg mjesta na Zemlji u 1,1 dan, pri čemu vrijeme ponovnog posjećivanja pada ispod jednog dana i nikada ne prelazi dva dana, pružajući najviše prolazaka istog dana od bilo kojeg komercijalnog satelita visoke rezolucije (URL 18).

Sustav za snimanje na WorldView-2 je drugi takav sustav koji je dizajnirao i proizveo ITT Space Systems Division za MAXAR. WorldView-2 radi na visini od 770 kilometara, a napredni ugrađeni sustav za snimanje može uhvatiti multispektralne snimke s pan-izoštrenjem (s rezolucijom boljom od 0,46 metara) s gotovo 500 milja iznad Zemlje. Te slike pružaju više detalja i veliku geoprostornu točnost, dodatno proširujući primjene satelitskih snimaka u komercijalnim i vladinim tržištima. Dodana spektralna raznolikost omogućava precizno otkrivanje promjena i kartiranje (URL 19).

Osim brojnih drugih tehničkih poboljšanja, WorldView-2 može prihvatiti izravno zadavanje zadataka, što će omogućiti odabranim korisnicima širom svijeta da izravno učitavaju profile snimanja na svemirsku letjelicu i izvršavaju dostavu podataka izravno do svojih zemaljskih stanica (URL 20).

Tablica 1. Parametri WorldView-110 kamere (modificirano prema URL 20)

Način snimanja slike	Pankromatski (pan)	Multispektralni (MS) 8 kanala (4 standardne + 4 dodatne boje)
Spektralni raspon	450- 800 nm	400-450 nm (modro plava) 450-510 nm (plava) 510-580 nm (zeleno) 585-625 nm (žuta) 630-690 nm (crvena) 705-745 nm (rubno crvena) 770-895 nm (NIR1) 860-1040 nm (NIR2)
Prostorna rezolucija	0,46 m GSD	1, 8 GSD
Širina otkosa	16,4 km	
Detektori	PAN: Si CCD polje (8 μm veličine piksela) s nizom od > 35 000 detektora MS: Si CCD 4 polja (32 μm veličine piksela) s nizom od > 9300 detektora	
Kvantizacija podataka	11 bita	
Geolokacijska točnost	3 m (koristeći GPS prijemnik, žiroskop i uređaj za praćenje zvijezda) bez GCP(zemaljskih kontrolnih točaka)	
Optika	TMA teleskop s promjerom otvora 1, 1 , žarišnom duljinom = 13,3 m, f/12	
TDI (integracija vremenske odgode)	6 odabranih razina od 8 do 64 u Pan i MS	
FOV (vidno polje)	< 1, 280	
Veličina instrumenta	3 m visina	

3.6.2. HySpex

HySpex, razvijen od strane tvrtke *Norsk Elektro Optikk AS* (NEO), predstavlja tehnologiju najviše razine u području hiperspektralnog snimanja. NEO, osnovan 1985. godine kao privatna istraživačka tvrtka u području elektro-optike, a aktivnosti hiperspektralnog snimanja u NEO-u započele su 1995. godine s projektom HISS (Hyperspectral Imager for Small Satellites) za ESA-u. Tijekom godina, HySpex se etablirao kao jedan od vodećih svjetskih brendova za hiperspektralno snimanje iz zraka i sa zemlje. HySpex senzori su poznati po svojoj stabilnosti, fleksibilnosti i vrhunskoj kvaliteti podataka.

Sve HySpex kamere su linijski (*pushbroom*) hiperspektralni uređaji za snimanje. Prilikom prikupljanja podataka, kamera istovremeno hvata sve spektralne informacije iz uske linije prostorne scene. Kako se kamera pomiče preko scene, ili scena ispred kamere, prostorna scena se snima i dodaje hiperspektralnoj kocki. Tako izlazni podatkovni proizvod sadrži i prostornu scenu zajedno s kontinuiranim spektralnim informacijama za svaki piksel u

prostornoj sceni.

HySpex kamere mogu se isporučiti kao rješenja spremna za trenutnu akviziciju, omogućujući korisniku prikupljanje podataka znanstvene kvalitete odmah nakon isporuke. Sve klasične HySpex kamere (npr. HySpex VNIR-1024, VNIR-1800 i SWIR-384) mogu se lako opremiti prilagođenim lećama za blisko snimanje, omogućujući krajnjem korisniku korištenje iste kamere za aplikacije gdje je potrebna visoka prostorna rezolucija, kao i za aplikacije s dugom radnom udaljenošću (snimanja iz zraka i terenska mjerenja).

Kako bi osigurali da HySpex kamere svojim korisnicima pružaju podatke znanstvene kvalitete, sve kamere prolaze rigorozna testiranja i karakterizaciju tijekom proizvodnje. Visoka rezolucija i velika brzina, u kombinaciji s malom težinom i niskom potrošnjom energije, čine HySpex kamere tvrtke NEO vrlo pogodnima za prikupljanje podataka iz zraka. Tipična instalacija za zračne snimke sastoji se od HySpex kamera povezanih s jedinicom za prikupljanje podataka iz zraka, navigacijskim sustavom (IMU/GPS) i platformom za montažu. Mogu se isporučiti i aktivno stabilizirane i pasivno prigušene platforme za montažu, kao i standardne ploče za montažu bez prigušenja vibracija. IMU/GPS rješenja od vodećih proizvođača mogu se isporučiti i integrirati s kamerama. Alternativno, HySpex sustavi mogu se povezati s postojećim navigacijskim hardverom kupca.

Hiperspektralna kamera HySpex VNIR-1024 razvijena je za terenske, laboratorijske, zračne i industrijske primjene koja kombinira izuzetne brzine akvizicije s visokom kvalitetom podataka. Kamera može pohranjivati veliki broj slika u sekundi što je čini idealnom kamerom za industrijske primjene, letove na niskoj visini ili druge primjene. Kao i sve HySpex kamere, HySpex VNIR-1024 temeljito je testirana i kalibrirana prema referentnim standardima tijekom proizvodnje. Širok raspon leća za bliske snimke omogućuje upotrebu kamere na radnim udaljenostima koje se kreću od nekoliko cm, sa spektralnom razlučivošću od 24 μm , do beskonačnosti, na primjer za daljinsko zračno snimanje. Tablica 2. detaljnije prikazuje specifikacije navedene kamere (Norsk Elektro Optikk AS Prost Stabels, 2019).

Tablica 2. Parametri HySpex VNIR-1024 kamere (modificirano prema Norsk Elektro Optikk AS, 2019)

Spektralni raspon	400- 1000 nm
Prostorni pikseli	1024
Spektralni kanali	108
Razlučivost bitova	14 bita
Maksimalna brzina (u punoj rezoluciji)	690 fps
Potrošnja energije	6 W
Dimenzije	30,5 – 9,9 -15 cm
Težina	4,2 kg

4. ANALIZA I OBRADA PODATAKA

U sklopu praktičnog dijela istraživanja koristeći ENVI softver za obradu snimki, provedena je analiza spektralnih potpisa različitih objekata zabilježenih s HSI i MSI. Koristeći snimke dobivene hiperspektralnim (HySpex) sensorima i satelitskim sustavom Worldview-2, analizirani su i određeni rasponi kanala koji najbolje odražavaju karakteristike pojedinih klasa objekata na terenu. Na temelju analize, odabrani su specifični kanali koji su se koristili za klasifikaciju slika.

Proces uključuje provedbu klasifikacija na snimkama koje prikazuju isti dio Grada Zagreba, koristeći odabrane kanale za hiperspektralne i multispektralne satelitske snimke. Kroz ovu usporedbu, omogućena je ne samo identifikacija i klasifikacija terenskih objekata, već i detaljna analiza i interpretacija rezultata dobivenih iz dvije različite spektralne sustava. Cilj je razumjeti kako različite spektralne rezolucije utječu na preciznost i efikasnost klasifikacije u urbanom području. Ovaj pristup omogućava temeljito razumijevanje spektralnih karakteristika objekata i pruža dublji uvid u potencijale i ograničenja daljinskog istraživanja u urbanom planiranju i upravljanju prirodnim resursima. U okviru ovoga rada provedene su nadzirane klasifikacije metodama *Spectral Angle Mapping* i *Maximum Likelihood*. Nadalje, provedena je klasifikacija NDVI-ja, indeksa koji se koristi u procjeni i analizi vegetacije.

4.1. Područje istraživanja

Područje od interesa koje se obrađuje na snimkama je zagrebačko gradsko naselje Prečko. Naselje obuhvaća jugozapad Trešnjevke i njene gradske četvrti Trešnjevka-jug. Područjem prevladavaju stambeni i poslovni objekti s velikim protokom prometa i razvijenom infrastrukturom. Na snimkama koje su predmet obrade dominira Zagrebačka avenija, jedna od većih prometnica u Zagrebu. Pored urbaniziranih zona i prometnica, manji dio područja na snimci obuhvaćaju i zelene površine, uključujući drveće i travnate površine unutar parkova.


4.2. Izoštavanje multispektralnih kanala

Nakon rezanja snimke na područje od interesa potrebno je prije provođenja klasifikacije multispektralne snimke, provesti izoštavanje multispektralnih kanala s intenzitetom pankromatskog kanala. Površinska razlučivost pankromatskih kanala je približno 0.46 m, a multispektralnih kanala približno 1.84 m. Postupak se proveo u softveru PanFusion. Učitaju se pankromatski i multispektralni kanali, za metodu interpolacije je odabrana metoda najbliži

susjed, linearni odnos pankromatskog i multispektralnog kanala je 1:4, a za metodu izoštravanja kanala je odabrana BDSB (*Band Dependent Spatial Detail*). BDSB algoritam predstavlja precizan model linearnog ubrizgavanja u kojemu se izračuna optimalna detaljna slika izvučena iz pankromatskog kanala za svaki multispektralni kanal procjenom generaliziranog intenziteta ovisnog o opsegu iz multispektralnih kanala. Kao rezultat dobije se izoštrana snimka. Na slikama 7. i 8. prikazani su manji dijelovi multispektralne snimke (RGB, koji tvori prirodne boje) koji prikazuju detaljniji prikaz promjena u kvaliteti i oštini slike prije i poslije primjene postupka izoštravanja. (Krtalić, 2023.)



Slika 7. Dio multispektralne satelitske snimke (RGB, koji tvori prirodne boje) prije izoštravanja



Slika 8. Dio multispektralne satelitske snimke (RGB, koji tvori prirodne boje) nakon izoštravanja

4.3. Analiza spektralnih potpisa


Analiza spektralnih potpisa multispektralne snimke satelitskog sustava WorldView-2 uključuje proučavanje refleksije spektra u različitim spektralnim kanalima snimke. Korištenjem različitih kanala, poput crvenog, zelenog, plavog i bliskog infracrvenog, mogu se

identificirati i definirati karakteristični spektralni potpisi različitih objekata na sceni. Ova analiza omogućuje identifikaciju i klasifikaciju različitih tipova pokrova zemljišta, vegetacije i drugih objekata od interesa.


Pored multispektralnih snimki, analiza uključuje i hiperspektralne snimke koje pružaju detaljnije spektralne informacije zahvaljujući većem broju užih spektralnih kanala. Hiperspektralne snimke omogućuju precizniju identifikaciju i klasifikaciju materijala jer obuhvaćaju kontinuirani spektar refleksije elektromagnetskog spektra.

U analizi krivulja refleksije multispektralne i hiperspektralne snimke, odabrane su četiri glavne klase pokrova zemljišta: golo tlo, vegetacija (koja uključuje drveće i travu), prometnice te krovovi izrađeni od različitih materijala poput betona, cigle i lima. Odabir navedenih klasa omogućuje detaljnu analizu spektralnih potpisa različitih materijala i pokrova zemljišta prisutnih na snimci te njihovu daljnju klasifikaciju i interpretaciju. Korištenjem i usporedbom rezultata iz oba tipa snimki, moguće je postići precizniju klasifikaciju i bolju interpretaciju različitih elemenata unutar promatranog područja.

Na slici 9 prikazan je graf sa spektralnim krivuljama refleksije za prethodno definirane klase na snimci. Na slikama 9 i 10 prikazani su grafovi refleksije koji prikazuju odnos između valne duljine elektromagnetskog zračenja i reflektivnosti površine. Na horizontalnoj X osi, multispektralni graf prikazuje broj kanala, dok se na hiperspektralnom grafu koriste nanometri. Vertikalna Y os grafa predstavlja vrijednosti refleksije, pružajući uvid u razinu elektromagnetskog spektra koja se reflektira s površine u odnosu na valnu duljinu.



Slika 9. Graf spektralnih potpisa objekata na multispektralnim kanalima



Slika 10. Graf spektralnih potpisa objekata na hiperspektralnim kanalima

Kao što se vidi na slici 9 i 10, krivulje refleksije za različite površine jasno pokazuju specifične obrasce refleksije. U narednim odjeljcima detaljnije su opisane krivulje refleksije za multispektralnu i hiperspektralnu snimku.

Krivulja refleksije za golo tlo (smeđa boja) pokazuje nisku refleksiju u plavom i crvenom dijelu spektra, dok je refleksija u infracrvenom (NIR) području viša. To je zbog svojstava minerala i teksture tla koji apsorbiraju plavi i crveni dio spektra, dok se u NIR području reflektira veći dio elektromagnetskog spektra.

Krivulja refleksije za vegetaciju (žuta i zelena boja) pokazuje nisku refleksiju u plavom dijelu spektra zbog apsorpcije klorofila. U zelenom dijelu spektra, refleksija je veća zbog zelene boje klorofila. Visoka refleksija u NIR području rezultat je refleksije od strukture staničnih zidova. Razlike u krivuljama refleksije između drveća i trave mogu se vidjeti u intenzitetu refleksije i u različitim valnim duljinama gdje se postiže maksimum refleksije.

Krivulja refleksije za prometnice (crna boja) obično pokazuje visoku refleksiju u plavom dijelu spektra zbog refleksije od asfalta ili betona. Refleksija se postupno smanjuje u zelenom i crvenom dijelu spektra, dok u NIR području može biti prisutna niska refleksija.

Krivulje refleksije za različite vrste krovova mogu varirati ovisno o materijalu. Betonski krovovi mogu imati visoku refleksiju u plavom i crvenom dijelu spektra, dok cigla može

pokazati karakteristične valove refleksije u crvenom i bliskom infracrvenom području. Limeni krovovi mogu pokazati nižu refleksiju u plavom dijelu spektra, ali višu u bliskom infracrvenom području zbog metalne površine.

Grafovi refleksije dobiveni kao rezultat u analizi multispektralnih i hiperspektralnih snimki pružaju dublji uvid u ponašanje elektromagnetskog spektra u različitim valnim duljinama. U multispektralnim snimkama, krivulje refleksije obično pokazuju karakteristične obrasce za određene materijale ili površine, omogućavajući identifikaciju i razlikovanje tih materijala. S druge strane, hiperspektralne snimke omogućuju još detaljniju analizu, budući da bilježe svjetlost reflektiranu od objekata u vrlo uskim valnim duljinama kroz širok spektar elektromagnetskog spektra. To omogućuje precizniju identifikaciju materijala i otkrivanje subtilnih razlika među njima. Također, hiperspektralne snimke pružaju bogatije informacije o spektralnim potpisima materijala, što može biti korisno u različitim područjima znanosti poput geologije, poljoprivrede, urbanog planiranja i okolišne analize. Uz to, kvaliteta podataka i osjetljivost hiperspektralnih snimki omogućuju detaljnije istraživanje i bolje razumijevanje površina i materijala u analiziranim područjima.

4.4. Nadzirana klasifikacija

Provedba nadzirane klasifikacije s multispektralnim i hiperspektralnim kanalima koristi se za identifikaciju i razvrstavanje svih piksela u klase na temelju utvrđenih spektralnih svojstava objekata. Dvije korištene metode za ovu svrhu su *Spectral Angle Mapping* (SAM) i *Maximum Likelihood*. U nadziranoj klasifikaciji slika, identitet i lokacija nekih tipova pokrova zemljišta trebaju biti unaprijed poznati kroz kombinaciju terenskog rada, analize zračnih fotografija, karata i osobnog iskustva. Analitičar pokušava locirati mjesta na snimkama koja predstavljaju homogeni skup (koji se koristi kao primjer) poznatih tipova pokrova zemljišta. Ova područja nazivaju se trening lokacijama jer se spektralne karakteristike tih poznatih područja koriste za treniranje klasifikacijskog algoritma za eventualno mapiranje pokrova zemljišta ostatka slike. Nadzirane klasifikacije provedene su u ENVI softveru za obradu i analizu snimki.

4.4.1. Nadzirana klasifikacija metodom *Spectral Angle Mapping*

Metoda SAM je nadzirani klasifikacijski algoritam koji identificira različite klase snimke na temelju izračuna spektralnog kuta. Spektralni kut se izračunava između testnog vektora koji predstavlja spektralne vrijednosti svih kanala na X i Y pozicijama svakog

pojedinih piksela i referentnog vektora koji predstavlja spektralne vrijednosti svih kanala pojedine klase koju odabire korisnik.

Snimke se analiziraju pomoću SAM algoritma kako bi se izdvojile tematske informacije poput pokrova zemljišta, vodenih tijela i oblaka.

SAM algoritam temelji se na idealnoj pretpostavci da jedan piksel snimke predstavlja određeni materijal na tlu i može se jedinstveno dodijeliti samo jednoj klasi. Piksel je dodijeljen klasi čiji spektar ima najmanji kut u odnosu na referentni piksel. Rezultat je takozvani raster sloj za svaki krajnji član koji sadrži spektralni kut. Proces proizvede 2 izlazna rastera od kojih je jedan raster spektralnog kuta koji sadrži vrijednosti spektralnog kuta svake ćelije snimke i raster klase u kojemu su ćelije dodijeljene klasama krajnjih članova bazirano na vrijednosti kuta koja je postavljena na parametru vrijednosti praga. Raster se u najjednostavnijem obliku može opisati kao matrica piksela (ćelija) organiziranih u redove i stupce gdje svaki piksel reprezentira informaciju, poput boje. SAM algoritam se temelji na mjerenju spektralne sličnosti između dva spektra. Spektralna sličnost može se dobiti razmatranjem svakog spektra kao vektora u višedimenzionalnom prostoru. SAM određuje spektralnu sličnost između dva spektra izračunavanjem kuta između njih, tretirajući ih kao vektore u prostoru čija je dimenzionalnost jednaka broju kanala.

Analiza je provedena na hiperspektralnoj (HySpex) i multispektralnoj satelitskoj snimci. RGB kompozitna slika omogućuje bolju vizualizaciju površinskih razlika te je kao takva i korištena. Prednost SAM-a je korištenje samo razlikovnog kuta, a ne i njihove duljine (jačine refleksije), te je metoda neosjetljiva na nepoznate faktore osvjetljenja. Pikseli su grupirani u najrelevantniju klasu, a piksel se ne klasificira ako ne pripada niti jednoj klasi.

U ovom radu je prikazano kako SAM algoritam može učinkovito koristiti zračne i satelitske snimke za klasifikaciju različitih tematskih informacija kao što je pokrov zemljišta (URL 22).

4.4.2. SAM klasifikacija multispektralne snimke

Za multispektralne snimke satelitskog sustava WorldView-2, klasifikacija je izvedena s klasama: trava, drveće, golo tlo, krovovi različitih materijala (crijep, lim, betona) i cesta. Za početak, odabrani su referentni uzorci za svaku klasu. Na početku su odabrani uzorci za cestu, no inicijalna klasifikacija nije bila zadovoljavajuća jer mnogi dijelovi ceste nisu bili ispravno

klasificirani. Zbog toga je uzet veći broj uzoraka za cestu kako bi se poboljšala preciznost klasifikacije. Nakon uzimanja dodatnih uzoraka, klasifikacija je ponovljena. Ovaj put klasifikacija ceste je bila bolja, ali su neki krovovi od lima bili pogrešno klasificirani kao cesta.

Na slici 11 i 12 prikazane su završne klasifikacije multispektralne snimke SAM metodom. Slika 11 prikazuje prvu iteraciju koju je potrebno poboljšati radi velikog broja pogrešno klasificiranih krovova u klasi cesta. Vidljivo je da su klasifikacije poboljšane dodatnim uzorcima, ali je još uvijek prisutna konfuzija između klasa limenih i betonskih krovova i ceste (slika 11). Ovi rezultati ukazuju na potrebu za finijim podešavanjem uzoraka ili dodatnom obradom podataka.



Slika 11. Prva iteracija klasifikacije multispektralne snimke SAM metodom sa legendom



Slika 12. Završna iteracija klasifikacije multispektralne snimke SAM metodom sa legendom

4.4.3. SAM klasifikacija hiperspektralne snimke

Za hiperspektralne snimke, klasifikacija je također provedena SAM metodom, ali uz dodatak klase pločnik kako bi se postigla preciznija klasifikacija. Referentni uzorci su odabrani za klase: trava, drveće, golo tlo, krovovi različitih materijala (crijep, lim, beton), cesta i pločnik.

Korišteni su kanali od 7 do 31, što odgovara valnim duljinama od 529 do 989 nm. Ovi kanali su odabrani kako bi se izbjegli šumovi i poboljšala preciznost klasifikacije. Prilikom usporedbe spektralnih potpisa, uočeno je preklapanje između krivulja refleksije pločnika i betonskog krova u kanalima 1 do 7 što odgovara spektralnom rasponu ispod 529 nm. Zbog visokog stupnja sličnosti u ovom dijelu spektra, upotreba ovih kanala u analizi dovela je do lošije klasifikacije. Stoga, odlučeno je izostaviti ove kanale iz analize kako bi se smanjila mogućnost greške i poboljšala preciznost klasifikacije. Ova odluka je podržana detaljnom vizualnom i statističkom analizom spektralnih krivulja, gdje su kanali koji pokazuju najmanje razlike u spektralnim odzivima između pločnika i betonskog krova identificirani kao potencijalni izvori konfuzije.

Inicijalna klasifikacija nije bila zadovoljavajuća jer je pločnik često bio klasificiran kao krov od betona. To se dogodilo jer refleksija rubnika ceste u korištenim kanalima može biti slična refleksiji krova od betona. Stoga je dodana klasa pločnik kako bi klasifikator preciznije razlikovao rubnike ceste od betonskih krovova.

Na slici 13 i 14 prikazane su završne klasifikacije hiperspektralnih snimki SAM metodom. Slika 13 prikazuje rezultate klasifikacije koji uključuju sve kanale, bez dodatne klase pločnik. Uključivanje klase pločnik značajno je poboljšalo preciznost klasifikacije rubnika ceste, ali su neki dijelovi krova i dalje klasificirani kao cesta (slika 14). Ovi rezultati sugeriraju potrebu za dodatnim podešavanjem uzoraka ili upotrebom naprednijih tehnika obrade podataka. Pored toga, buduća istraživanja mogla bi uključivati analizu dodatnih spektralnih područja kako bi se poboljšala diferencijacija između sličnih klasa.



Slika 13 Prva iteracija klasifikacije hiperspektralne snimke SAM metodom s uključenim svim kanalima i bez klase pločnik sa legendom



Slika 14. Završna klasifikacije hiperspektralne snimke SAM metodom s uključenim kanalima 7- 31 i dodatnom klasom pločnik sa legendom

4.4.3.1. Usporedba rezultata i analiza

Analizom klasifikacija dobivenih multispektralnim i hiperspektralnim snimkama pomoću SAM metode, uočene su značajne razlike u preciznosti i točnosti klasifikacije za različite klase pokrova zemljišta. Ova usporedba omogućava bolje razumijevanje prednosti i nedostataka svake metode te daje smjernice za njihovu optimalnu primjenu.

Klasifikacija multispektralnih snimki sustava WorldView-2 pokazala se zadovoljavajućom za većinu klasa, ali s određenim ograničenjima. Inicijalna klasifikacija nije uspjela precizno odvojiti cestu od drugih klasa, što je zahtijevalo dodatno podešavanje uzoraka. Iako je dodatno uzimanje uzoraka poboljšalo klasifikaciju ceste, još uvijek je bilo problema s pogrešnom klasifikacijom limenih krovova kao cesta. Multispektralne snimke pružaju ograničenu spektralnu rezoluciju, što može dovesti do konfuzije između sličnih materijala zbog manjeg broja dostupnih spektralnih kanala.

Klasifikacija hiperspektralnih snimki pokazala je veću preciznost zahvaljujući višoj spektralnoj rezoluciji koja omogućuje detaljniju analizu i razlikovanje materijala. Dodavanje klase pločnik poboljšalo je klasifikaciju rubnika ceste, koji su u početnoj analizi bili često klasificirani kao krov od betona. Korištenjem kanala od 7 do 31 poboljšana je točnost klasifikacije, no ipak su se pojavile neke pogreške gdje su dijelovi krova bili klasificirani kao cesta.

Hiperspektralne snimke, zahvaljujući svojoj mogućnosti omogućavanja kontinuiranog spektra refleksije, omogućuju detaljniju i precizniju klasifikaciju različitih materijala i površina

u usporedbi s multispektralnim snimkama. Multispektralne snimke su korisne za šire analize gdje visoka spektralna rezolucija nije ključna, dok hiperspektralne snimke pružaju bolje rezultate za finiju diferencijaciju i klasifikaciju sličnih klasa. Iako su hiperspektralne snimke superiorne u smislu spektralne informacije, njihova obrada zahtijeva naprednije tehnike i dulje vrijeme obrade. S druge strane, multispektralne snimke su brže za obradu i često dovoljne za generalizirane analize. Korištenje dodatnih klasa i podešavanje referentnih uzoraka može poboljšati klasifikaciju obje vrste snimki, no izbor između hiperspektralnih i multispektralnih snimki treba temeljiti na specifičnim potrebama analize i dostupnim resursima.

4.5. Nadzirana klasifikacija metodom *Maximum Likelihood*

Maximum likelihood metoda klasifikacije je jedna od najčešće korištenih metoda za nadziranu klasifikaciju satelitskih i zračnih snimki, temeljena na statističkom pristupu koji procjenjuje vjerojatnost da piksel pripada određenoj klasi na temelju spektralnih vrijednosti.

Provedba nadzirane klasifikacije multispektralnih i hiperspektralnih snimki koristeći *Maximum Likelihood* metodu uključuje slijedeće korake: prikupljanje i priprema podataka, izbor trening uzoraka, klasifikacija, te analiza i evaluacija rezultata. Za svaku vrstu snimke odabrani su reprezentativni trening uzorci za različite klase, poput trave, drveća, golog tla, krovovi različitih materijala (crijep, lim, betona) i cesta. Ti uzorci su korišteni za treniranje *Maximum Likelihood* klasifikatora. Za svaku klasu trening uzoraka izračunati su statistički parametri, srednje vrijednosti i matrice kovarijance, koji definiraju multivarijatnu normalnu distribuciju spektralnih vrijednosti. Za svaki piksel slike, metoda izračunava vjerojatnost pripadnosti svakoj klasi koristeći multivarijatnu normalnu distribuciju. Piksel se dodjeljuje klasi s najvišom vjerojatnošću, što znači da će biti klasificiran kao dio klase čija statistička distribucija najbolje odgovara spektralnim vrijednostima tog piksela.

Prednosti *Maximum Likelihood* klasifikacije uključuju visoku preciznost jer uzima u obzir varijabilnost unutar klasa te fleksibilnost u kreiranju složenih i preklapajućih klasa. Međutim, metoda zahtijeva velike količine trening podataka za točne procjene statističkih parametara i osjetljiva je na netočne procjene matrica kovarijance, što može rezultirati lošijom klasifikacijom.

4.5.1. *Maximum Likelihood* klasifikacija multispektralne snimke

Na multispektralnoj snimci, uočene su određene pogreške u klasifikaciji. Trava je u


nekoliko slučajeva pogrešno klasificirana kao golo tlo. Ova pogreška može biti rezultat sličnih spektralnih karakteristika između suhih travnatih površina i golih tla u multispektralnim podacima. Neki dijelovi ceste su klasificirani kao krov izrađen od crijepa, što može biti posljedica sličnosti u reflektivnosti između asfalta i crijepova u određenim spektralnim pojasevima. Betonski krovovi su rijetko prepoznati, vjerojatno zbog miješanja spektralnih karakteristika betona s drugim materijalima ili nedostatka dovoljno specifičnih spektralnih pojasa. Slika 15 prikazuje rezultat *Maximum Likelihood* klasifikacije za multispektralnu snimku.



Slika 15. Rezultat klasifikacije multispektralne snimke MLC metodom sa legendom

4.5.2. *Maximum Likelihood* klasifikacija hiperspektralne snimke

Na hiperspektralnoj snimci, rezultati su znatno bolji, ali su također prisutne određene pogreške. Kao i kod multispektralne snimke, neki dijelovi ceste su pogrešno klasificirani kao krov izrađen od crijepa. Ipak, ova pogreška je manje izražena zahvaljujući dodatnim spektralnim informacijama. Betonski krovovi su bolje prepoznati zbog detaljnijih spektralnih podataka koji omogućuju razlikovanje betona od drugih materijala. Značajan dio travnatih površina klasificiran je kao drveće, što može biti rezultat sličnosti u spektrima klorofila i drugih biljnih pigmenta. Limeni krovovi su vrlo dobro klasificirani, što ukazuje na sposobnost hiperspektralnih podataka da precizno razlikuju materijale s različitim reflektivnim svojstvima. Na slici 16 je prikazan rezultat *Maximum Likelihood* klasifikacije za hiperspektralnu snimku.



Slika 16. Rezultat klasifikacije hiperspektralne snimke MLC metodom sa legendom

4.5.3. Usporedba rezultata i analiza

Maximum Likelihood klasifikacija pokazuje bolje rezultate na hiperspektralnim snimkama u usporedbi s multispektralnim. Hiperspektralne snimke, sa svojim većim brojem i užim spektralnim kanalima, omogućuju precizniju analizu i razlikovanje materijala. Detaljnije spektralne informacije iz hiperspektralnih snimki omogućile su bolju klasifikaciju betonskih krovova i limenih krovova, te su smanjile pogreške u klasifikaciji cesta kao krovova od crijepa. Međutim, određene pogreške su i dalje prisutne, primjerice, klasifikacija trave kao drveća, što ukazuje na potrebu za dodatnim unapređenjem algoritama i korištenjem dodatnih spektralnih informacija.

S druge strane, multispektralne snimke pokazale su veću sklonost pogreškama zbog manje spektralne rezolucije. Pogreške u klasifikaciji trave kao golog tla i dijelova ceste kao krovova od crijepa ukazuju na ograničenja ove metode. Ove pogreške naglašavaju potrebu za pažljivim odabirom spektralnih pojaseva kako bi se smanjila mogućnost miješanja različitih materijala. Osim toga, korištenje naprednih algoritama za obradu podataka može pomoći u poboljšanju točnosti klasifikacije i smanjenju ovih pogrešaka.

Zaključno, iako je *Maximum Likelihood* metoda relativno učinkovita za obje vrste snimki, hiperspektralne snimke pružaju značajne prednosti u preciznosti klasifikacije. Poboljšanja se mogu postići korištenjem dodatnih spektralnih informacija, unapređenjem algoritama za klasifikaciju, te kombiniranjem sa drugim metodama poput SAM metode za još precizniju analizu i klasifikaciju površina.

4.6. Normalizirani indeks vegetacije

Vegetacijski indeksi su podaci koji se računaju iz različitih kanala snimki na temelju apsorpcije i refleksije sunčeve energije u biljnom svijetu. Te zapise danas kreiraju specijalizirane kamere s optičkim uređajima koje nose sateliti, avioni, dronovi i druge letjelice, a koji su podložni daljnoj obradi. Mnogi senzori mjere crvene i infracrvene svjetlosne valove reflektirane od kopnenih površina. Koristeći matematičke algoritme, kombinacijom kanala digitalnih snimki izračunavaju se različiti vegetacijski indeksi. Vegetacijski indeks je pokazatelj trenutnog stanja vegetacije na osnovi kojeg se, uvođenjem dodatnih parametara (npr. Fenološki kalendar), može procijeniti zdravlje vegetacije za svaki piksel na satelitskoj ili zračnoj digitalnoj snimci.

NDVI je omjer razlike između blisko infracrvenog (NIR) i crvenog dijela spektra s njihovim zbrojem (URL 21).

Iako postoji veliki broj vegetacijskih indeksa, jedan od najčešće korištenih je upravo NDVI. NDVI vrijednosti kreću se u rasponu od -1,0 do +1,0. Neplodna područja poput: kamenja, pijeska ili snijega obično pokazuju vrlo niske vrijednosti NDVI (0,1 ili manje). Rijetka vegetacija poput grmlja i travnjaka ili usjeva koji stare mogu rezultirati umjerenim vrijednostima NDVI približno 0,2 do 0,5. Visoke vrijednosti NDVI približno 0,6 do 0,9 odgovaraju gustom vegetaciji poput one u umjerenim i tropskim šumama ili usjevima na vrhuncu rasta.

Pretvaranjem sirovih satelitskih podataka u NDVI vrijednosti, istraživači mogu stvoriti slike i druge proizvode koji daju grubu mjeru vrste, količine i stanja vegetacije na kopnenim površinama diljem svijeta. NDVI je posebno koristan za praćenje vegetacije na kontinentalnoj i globalnoj razini jer može kompenzirati promjene uvjeta osvjetljenja, nagiba površine i kuta gledanja (URL 22).

U posljednjem segmentu praktičnog dijela istraživanja, izračunat je NDVI indeks za multispektralne i hiperspektralne snimke, koristeći odgovarajuće spektralne kanale. Za izračun NDVI korišten je ENVI Classic softverski alat za obradu i analizu slika, te funkcija raster kalkulatora za provođenje potrebnih matematičkih operacija s kanalima snimki MSI-a i HSI-a.

Učitavanjem multispektralne i hiperspektralne snimke u ENVI softver, identificirani su

odgovarajući spektralni kanali za NIR i crveni dio spektra za obje vrste snimki. Za multispektralne snimke, korišteni su kanal 5 za crveni dio spektra čija je valna duljina 630-690 nm i kanal 8 za NIR dio spektra s valnom duljinom 770-1040 nm. Za hiperspektralnu snimku, korišteni su kanal 14 za crveni dio spektra čija je valna duljina oko 673 nm i kanal 31 za NIR dio spektra s valnom duljinom oko 998 nm.

U raster kalkulatoru, odabравši kanale prema prethodno definiranim spektralnim bandovima za svaku vrstu snimke izračunata je NDVI vrijednost za svaki piksel slike. Rezultirajući NDVI raster sloj vizualiziran je pomoću Grayscale palete boja, gdje je vegetacija prikazana svijetlim tonovima, izgrađeni, odnosno urbani dio kao što su zgrade i ceste prikazan je tamnijim tonovima boje. Na slikama 17 i 18 prikazani su rezultati izračuna NDVI-a, provedenih s kanalima multispektralnih i hiperspektralnih snimki.



Slika 17. Rezultat izračuna NDVI indeksa na multispektralnoj snimci sa legendom



Slika 18. Rezultat izračuna NDVI indeksa na hiperspektralnoj snimci sa legendom

4.7. Upotreba NDVI-a u klasifikaciji

U posljednjoj analizi klasifikacije snimki korištene su izvorne hiperspektralne i multispektralne snimke u kombinaciji sNDVI-ai vrijednostima. Nakon izračuna NDVI vrijednosti, pristupilo se kreiranju skupova kanala i slika za klasifikaciju. Proces spajanja kanala snimke uključuje kombiniranje izvornih kanala snimke s odgovarajućim NDVI-ima kako bi se kreirao skup podataka koji sadrži drugačije prikazane značajke nekog objekta, u ovom slučaju, vegetacije. Konkretno, za hiperspektralne snimke odabrani su kanali od 7 do 31, čime je obuhvaćen ključni spektar za analizu vegetacije i drugih površina.

Kombiniranjem NDVI vrijednosti s izvornim snimkama stvoren je novi skup podataka koji integrira spektralne informacije iz oba izvora, omogućavajući precizniju klasifikaciju zemljišnog pokrova. Ovaj skup koristi se kao ulaz u postupak klasifikacije metodom *Maximum Likelihood*. Takva integracija podataka omogućava korištenje svih dostupnih spektralnih i NDVI informacija kako bi se povećala točnost klasifikacije i bolje razlikovale različite klase zemljišta.


Ova metoda omogućava detaljnu analizu i klasifikaciju zemljišnog pokrova, čineći razliku između različitih tipova vegetacije, golih tla, krovova i drugih površina preciznijom i pouzdanijom. Kombinacija hiperspektralnih i multispektralnih podataka s NDVI vrijednostima pruža sveobuhvatnu osnovu za daljnju analizu i interpretaciju rezultata klasifikacije.

Rezultati klasifikacije skupa koji sadržava multispektralne kanale i NDVI, nešto su lošiji u odnosu na klasifikaciju skupa kanala hiperspektralne snimke i NDVI-a (Slika 19). Iako je vegetacija većinom točno klasificirana, problem se javlja kod golih površina koje se često pogrešno identificiraju u područjima sa siromašnom vegetacijom. Ovo može biti rezultat niže spektralne rezolucije multispektralnih snimki, što otežava preciznu identifikaciju klasa sa sličnim spektralnim karakteristikama. Zbog niže spektralne rezolucije, multispektralni kanali ne pružaju dovoljno detalja za točno razlikovanje sličnih površina, što dovodi do većeg broja pogrešno klasificiranih piksela. Limeni krovovi su također vrlo dobro klasificirani u skupu s multispektralnim kanalima. Međutim, betonski krovovi su loše klasificirani te se često miješaju s tlom i crijepnim krovom, što ukazuje na slične spektralne karakteristike između ovih klasa na multispektralnim podacima.



Slika 19. Rezultat klasifikacije skupa multispektralnih kanala i NDVI-a metodom *Maximum Likelihood* s legendom

S druge strane, rezultati klasifikacije skupa s hiperspektralnim kanalima i NDVI-em, pokazali su izuzetno dobre rezultate u klasifikaciji vegetacije i golih površina. Zahvaljujući visokoj spektralnoj rezoluciji, vegetacija je jasno diferencirana, što omogućava preciznu identifikaciju trave i drveća. Ovo je posebno korisno u urbanim sredinama gdje su zelene površine često fragmentirane. Uvrstanjem NDVI-a u klasifikaciju, dodatno je pomoglo u razlikovanju vegetacijskih klasa od ne-vegetacijskih površina. Golo tlo, koje se često pojavljuje u poljoprivrednim i neizgrađenim urbanim područjima, također je točno klasificirano zahvaljujući jedinstvenim spektralnim karakteristikama koje se jasno razlikuju od vegetacije. Unatoč ukupnoj preciznosti, rezultati klasifikacije skupa hiperspektralnih kanala i NDVI-a pokazala je izazove u razdvajanju krovova i pločnika. Primijećeno je značajno preklapanje između spektralnih karakteristika pločnika, cesta i krovova od crijepa. Ovaj problem rezultirao je miješanjem tih klasa, što je otežalo točnu klasifikaciju. Limeni krovovi su, s druge strane, točno klasificirani zahvaljujući njihovim specifičnim spektralnim potpisima koji su se jasno razlikovali od ostalih klasa. Međutim, crijepni krovovi često su pogrešno klasificirani kao ceste ili pločnici, što ukazuje na potrebu za dodatnim parametrima ili poboljšanim metodama kako bi se poboljšao rezultat klasifikacije ovih klasa. Slika 20 prikazuje rezultat klasifikacije skupa hiperspektralnih kanala i NDVI-a metodom *Maximum Likelihood*.



Slika 20. Rezultat klasifikacije skupa hiperspektralnih kanala i NDVI-a metodom *Maximum Likelihood* s legendom

4.7.1. Usporedba rezultata i analiza

Rezultati klasifikacije skupa multispektralnih kanala i NDVI-a pokazali su određene nedostatke u odnosu na skup hiperspektralnih kanala i NDVI-a. Vegetacija je uglavnom bila točno klasificirana, ali gole površine su često bile pogrešno identificirane u područjima sa siromašnom vegetacijom. Ovaj problem vjerojatno proizlazi iz niže spektralne rezolucije multispektralne snimke. Limeni krovovi su bili dobro klasificirani, dok su betonski krovovi često bili pogrešno klasificirani kao tlo ili crijepni krovovi. Ovi rezultati sugeriraju da niža spektralna rezolucija multispektralnih snimaka otežava preciznu identifikaciju klasa sa sličnim spektralnim karakteristikama, što rezultira većim brojem pogrešno klasificiranih piksela.

Upotrebom kanala hiperspektralne snimke, s druge strane, polučili su se izuzetno dobri rezultati. Vegetacija je bila precizno diferencirana, što je omogućilo točnu identifikaciju različitih tipova vegetacije, poput trave i drveća. Gole površine su također bile točno klasificirane zahvaljujući jasnim spektralnim karakteristikama koje se razlikuju od vegetacije. Iako su limeni krovovi bili točno klasificirani, značajno preklapanje spektralnih karakteristika između crijepnih krovova, pločnika i cesta otežalo je njihovu klasifikaciju. Ovi rezultati ističu prednosti visoke spektralne rezolucije hiperspektralne snimke u razlikovanju vegetacije i golih površina, ali također ukazuju na izazove u klasifikaciji urbanih površina sa sličnim spektralnim potpisima.

Integracija NDVI vrijednosti s kanalima izvornih snimki poboljšala je ukupnu točnost klasifikacije. NDVI je bio ključan u razlikovanju vegetacijskih klasa od ne-vegetacijskih površina, poboljšavajući preciznost klasifikacije. Analiza je pokazala da kombinacija

hiperspektralnih i multispektralnih podataka s NDVI vrijednostima omogućava detaljniju i precizniju klasifikaciju zemljišnog pokrova. Hiperspektralne snimke pružaju veću točnost zahvaljujući visokoj spektralnoj rezoluciji.

Daljnja integracija dodatnih parametara i razvoj naprednijih metoda, uz korištenje dodatnih spektralnih indeksa, može poboljšati klasifikaciju urbanih površina. Također, optimizacija metoda klasifikacije, poput *Maximum Likelihood* klasifikacije, može pomoći u smanjenju preklapanja klasa sa sličnim spektralnim karakteristikama. Integracija podataka, uz optimizaciju metoda analize, predstavlja ključ za precizniju i pouzdaniju klasifikaciju zemljišnog pokrova, posebno u složenim urbanim sredinama.

5. DISKUSIJA

Kroz analizu rezultata klasifikacije urbanog područja dijela grada Zagreba korištenjem metoda *Spectral Angle Mapping* i *Maximum Likelihood* s kanalima multispektralnih i hiperspektralnih snimki, dobiveni su vrijedni uvidi u učinkovitost različitih pristupa u razlikovanju tipova površina. Analiza rezultata nudi uvid u prednosti i ograničenja svake metode, kao i potencijalne implikacije za primjenu u stvarnim scenarijima.

Na multispektralnim snimkama, klasifikacija je pružila korisne rezultate, posebno u razlikovanju između golog tla, limenih krovova i cesta. Međutim, uočena su preklapanja u klasifikaciji između sličnih površina poput crijepnih krovova i cesta, što ukazuje na ograničenja u diferencijaciji klasa s manjim brojem spektralnih kanala. S druge strane, hiperspektralne snimke pružile su detaljnije rezultate, omogućujući precizniju klasifikaciju različitih tipova površina. Više spektralnih kanala omogućilo je bolje razlikovanje između sličnih klasa poput crijepnih krovova i cesta te drveća i trave. Ova preciznost otvara vrata za širok spektar primjena, od urbanog planiranja do upravljanja okolišem.

Kada se usporede rezultati multispektralnih i hiperspektralnih snimki, jasno je da hiperspektralna tehnologija nudi znatne prednosti u preciznosti klasifikacije. Međutim, treba uzeti u obzir i troškove prikupljanja i obrade hiperspektralnih podataka, što može biti ograničavajući faktor u nekim zadacima. Osim toga, analiza rezultata ukazuje na potrebu za daljnjim istraživanjem u razvoju naprednijih metoda klasifikacije koje bi mogle kombinirati prednosti multispektralnih i hiperspektralnih snimki, pružajući precizne rezultate uz optimalno iskorištenje resursa.

Ovaj diplomski rad bavio se usporedbom i analizom klasifikacije multispektralnih i hiperspektralnih snimki urbanog područja dijela grada Zagreba primjenom metoda SAM i *Maximum Likelihood*, kao i upotrebom NDVI-a u kombinaciji s metodom *Maximum Likelihood*. Cilj je bio utvrditi prednosti i nedostatke svake vrste snimki i metoda klasifikacije u prepoznavanju različitih površinskih pokrova unutar urbanog okruženja.

Analiza multispektralnih snimki sustava WorldView-2 pokazala je da su snimke korisne za generalizirane analize urbanih područja. Klasifikacija pomoću SAM metode otkrila je određena ograničenja u preciznosti, posebno u razlikovanju sličnih klasa kao što su cestovne površine i limeni krovovi. Dodavanje referentnih uzoraka poboljšalo je klasifikaciju, ali još uvijek su prisutne pogreške zbog ograničene spektralne rezolucije multispektralnih podataka.

Maximum Likelihood klasifikacija na multispektralnim snimkama pokazala je lošije rezultate od inih s kanalima hiperspektralne snimke. Problemi su se najčešće javljali kod razlikovanja suhих travnatih površina i golog tla te između asfalta i crijevnih krovova. Unatoč tome, multispektralne snimke su se pokazale korisnima za brzu obradu i analizu kada visoka spektralna rezolucija nije ključna.

Klasifikacija hiperspektralnih snimki metodom SAM pokazala je veću preciznost od one s kanalima multispektralne snimke, zahvaljujući većem broju i užim spektralnim kanalima koji omogućuju detaljniju analizu i razlikovanje materijala. Dodavanje klase pločnik značajno je poboljšalo razlikovanje rubnika ceste od krovova od betona, no još uvijek su prisutne pogreške kod razlikovanja sličnih površina. Unatoč navedenim izazovima, hiperspektralne snimke omogućile su precizniju diferencijaciju između materijala i površina u urbanom području.

Maximum Likelihood klasifikacija s kanalima hiperspektralne snimke pokazala je superiornost u odnosu na multispektralne snimke. Detaljnije spektralne informacije omogućile su bolju klasifikaciju betonskih i limenih krovova te smanjile pogreške u klasifikaciji cesta kao krovova od crijeva. Ipak, preklapanje spektralnih karakteristika između vegetacijskih klasa, kao što su trava i drveće, još uvijek predstavlja izazov.

Upotreba NDVI-a u klasifikacijiomogućava detaljniju i precizniju klasifikaciju zemljišnog pokrova. Hiperspektralne snimke omogućavaju točnije razvrstavanje vrijednosti piksela u klase zahvaljujući visokoj spektralnoj rezoluciji, dok NDVI dodatno pomaže u razlikovanju vegetacijskih i ne-vegetacijskih površina. Međutim, multispektralne snimke, iako korisne, imaju ograničenja zbog niže spektralne rezolucije, što može dovesti do netočnosti u klasifikaciji površina sličnih spektralnih karakteristika.

6. ZAKLJUČAK

Provedeno istraživanje omogućilo je donošenje sljedećih završnih zaključaka u odnosu na početno definirane ciljeve i hipoteze.

- *Potvrđena je nadmoć hiperspektralnih snimki u preciznosti klasifikacije urbanih površina u odnosu na multispektralne. Analiza rezultata istraživanja pružila je dublje razumijevanje primjenjivosti i preciznosti obje vrste snimki, naglašavajući prednosti i ograničenja svake metode. Optimizacija referentnih uzoraka ključna je za povećanje preciznosti klasifikacije.*

Kroz ovu analizu jasno je da hiperspektralne snimke, zahvaljujući svojoj visokoj spektralnoj rezoluciji, pružaju detaljnije i preciznije informacije za klasifikaciju urbanih površina u usporedbi s multispektralnim snimkama. Iako obrada hiperspektralnih podataka zahtijeva naprednije tehnike i više vremena, prednosti koje donose u smislu preciznosti klasifikacije opravdavaju dodatni napor. Multispektralne snimke, zbog jednostavnije i brže obrade, ostaju korisne za šire analize i situacije gdje visoka spektralna rezolucija nije ključna.

Metode klasifikacije poput SAM i *Maximum Likelihood* pokazale su se učinkovitima za obje vrste snimki, s hiperspektralnim podacima koji su omogućili finiju diferencijaciju sličnih klasa. Dodavanje NDVI-a može dodatno poboljšati rezultate klasifikacije, ali zahtijeva pažljivo podešavanje referentnih uzoraka i algoritama.

Naposljetku, izbor između multispektralnih i hiperspektralnih snimki te odgovarajućih metoda klasifikacije treba biti temeljen na specifičnim potrebama analize, resursima i željenoj razini preciznosti. Daljnja istraživanja mogla bi se fokusirati na razvoj naprednijih algoritama koji bi bolje iskoristili bogatstvo spektralnih informacija i dodatno smanjili pogreške u klasifikaciji. Kombinacija različitih metoda i dodatna analiza spektralnih područja također bi mogla pridonijeti još preciznijoj i učinkovitijoj klasifikaciji urbanih površina.

7. LITERATURA

Campbell, J. B. and Wynne, R. H. (2011). Introduction to Remote Sensing, Fifth edition. London: Taylor and Francis

Collins, W. (1978). Remote sensing of crop type and maturity, Photogrammetric Engineering and Remote Sensing, 44, pp. 43-55

El_Rahman, S. A., Aliady, W. A., and Alrashed, N. I. (2015): Supervised Classification Approaches to Analyze Hyperspectral Dataset

Frančula, N. et al. (1994): Daljinska istraživanja u kartografiji, Geod. list, 3, 265-276

Gierloff-Emden (1989): Fernerkundungskartographie mit Satellitenaufnahmen: Allgemeine Grundlagen und Anwendungen

Gendaram, O. and Damdinsuren, A. (2021): Comparison of Spectral Signatures in Hyperspectral and Multispectral Data

Huqqani, I. A. and Khurshid, K. (2014): Comparative Study of Supervised Classification of Urban Area Hyperspectral Satellite Imagery

Jwan Al-doski, Shattri B. Mansor, and Helmi Zulhaidi Mohd Shafri (2013): Image Classification in Remote Sensing

L3Harris Technologies (2021): 1-21_Hyperspectral-Analytics-in-ENVI-SellSheet_WEB

Maurer, Krtalić (2023): Napredna daljinska istraživanja (prezentacija)

Norsk Elektro Optikk AS Prost Stabels (2019): HySpex

Geodetski fakultet (2023): Priručnik izrađen u okviru projekta Multisenzorsko zračno snimanje Republike Hrvatske za potrebe procjene smanjenja rizika od katastrofa

Rashmi, S., Addamani, Venkat and Ravikiran (2014): Spectral Angle Mapper Algorithm for Remote Sensing Image Classification

Wacker, A. G. and Landgrebe, D. A. (1972). Minimum Distance Classification in Remote Sensing. LARS Technical Reports. Paper 25.

INTERNETSKI IZVORI

URL 1: NV5, What is remote sensing, <https://www.nv5geospatialsoftware.com/What-is-Remote-Sensing> (19.4.2024.)

URL2: International Society for Photogrammetry and Remote Sensing, <https://www.isprs.org/society/>

URL 2: EarthData, What is remote sensing <https://www.earthdata.nasa.gov/learn/backgrounders/remote-sensing> (19.4.2024.)

URL 3: The National Aeronautics and Space Administration, Introduction to the Electromagnetic Spectrum, https://science.nasa.gov/ems/01_intro/ (19.4.2024.)

URL 4: UCAR Center for science education, Electromagnetic Spectrum, <https://scied.ucar.edu/learning-zone/earth-system/electromagnetic-spectrum> (19.4.2024.)

URL 5: Space telescope science institute, The electromagnetic Spectrum, <https://hubblesite.org/contents/articles/the-electromagnetic-spectrum> (19.4.2024.)

URL 6: Space.com, What is the electromagnetic spectrum, <https://www.space.com/what-is-the-electromagnetic-spectrum> (19.4.2024.)

URL 7: EOS Data Analytics, Satellite Imagery And Spectral Band Combinations, <https://eos.com/make-an-analysis/> (19.4.2024.)

URL 8: UP42 Documentation hub, Spectral bands, <https://docs.up42.com/data/reference/spectral-bands> (19.4.2024.)

URL 9: ResearchGate, Comparative true and false composites before and after sensor corrections, https://www.researchgate.net/figure/Comparative-true-and-false-colour-composites-before-and-after-sensor-corrections_fig22_230563285 (19.4.2024.)

URL 10: GISGeography, What is remote Sensing? The Definitive Guide, <https://gisgeography.com/remote-sensing-earth-observation-guide/> (19.4.2024.)

URL 11: Geographic Book, Types of Sensors, <https://geographicbook.com/types-of-sensors/> (19.4.2024.)

URL 12: PAN GEOGRAPHY, Types of Resolution in Remote Sensing, <https://pangeography.com/types-of-resolution-in-remote-sensing/> (19.4.2024.)

URL 13: viso.ai, Multispectral Imaging: Looking Beyond the visible Light, <https://viso.ai/deep-learning/multispectral-imaging/> (19.4.2024.)

URL 14: eoPortal, Hyperspectral Imaging, <https://www.eoportal.org/other-space-activities/hyperspectral-imaging#spectral-cubes> (19.4.2024.)

URL 15: GEOSPATIAL TECHNOLOGY, What is a spectral signature in remote sensing?, <https://mapasyst.extension.org/what-is-a-spectral-signature-in-remote-sensing/> (19.4.2024.)

URL 16: REMOTESENSINGIN ACTION, SPECTRAL SIGNATURES,

<https://remotesensinginaction.wordpress.com/2015/01/12/spectral-signatures/> (19.4.2024.)

URL 17: eoPortal, WorldView-2, <https://www.eoportal.org/satellite-missions/worldview-2#performance-specifications> (19.4.2024.)

URL 18: SATELLITE IMAGING CORPORATION, WorldView-2 Satellite Snsor, <https://www.satimagingcorp.com/satellite-sensors/worldview-2/> (19.4.2024.)

URL 19: European Space Agency, WorldView-2 Instruments, <https://earth.esa.int/eogateway/missions/worldview-2> (19.4.2024.)

URL 20: agrokлуб (R)Evolucija poljoprivrede, Što su vegetacijski indeksi, koji su i čemu služe? <https://www.agroklub.com/poljoprivredne-vijesti/sto-su-vegetacijski-indeksi-koji-su-i-cemu-sluze/76027/> (19.4.2024.)

URL 21: USGS science for a changing world, NDVI, the Foundation for Remote Sensing Phenology, <https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology> (19.4.2024.)

URL 22: EOS DATA ANALYTICS, Multispectral Vs. Hyperspectral: Choose The Right Tech, <https://eos.com/blog/multispectral-vs-hyperspectral-imaging/> (19.4.2024.)

URL 23: middleton SPECTRAL VISION, What is hyperspectral imaging?, <https://www.middletonspectral.com/resources/what-is-hyperspectral-imaging/> (19.4.2024.)

URL 24: European Space Agency, Spectral signatures, https://www.esa.int/SPECIALS/Eduspace_EN/SEMPNQ3Z2OF_0.html (19.4.2024.)

POPIS SLIKA

Slika 1. Elektromagnetski spektar (modificirano prema URL 1)	6
Slika 2. Usporedba snimki prikazanih pravim (lijevo) i lažnim (desno) bojama (modificirano prema URL 10)	8
Slika 3. Prikaz različitih prostornih rezolucija (modificirano prema URL 12)	10
Slika 4. Prikaz različitih radiometrijskih rezolucija (modificirano prema URL 12)	11
Slika 5. Shematski prikaz općenite multispektralne kamere(modificirano prema URL 14) ...	12
Slika 6. Konstrukcija hiperspektralne kocke (modificirano prema URL 15)	14
Slika 7. Dio multispektralne satelitske snimke (RGB, koji tvori prirodne boje) prije izoštravanja	23
Slika 8. Dio multispektralne satelitske snimke (RGB, koji tvori prirodne boje) nakon izoštravanja	23
Slika 9. Graf spektralnih potpisa objekata na multispektralnim kanalima	24
Slika 10. Graf spektralnih potpisa objekata na hiperspektralnim kanalima.....	25
Slika 11. Prva iteracija klasifikacije multispektralne snimke SAM metodom sa legendom ...	28
Slika 12. Završna iteracija klasifikacije multispektralne snimke SAM metodom sa legendom	28
Slika 13 Prva iteracija klasifikacije hiperspektralne snimke SAM metodom s uključenim svim kanalima i bez klase pločnik sa legendom	29
Slika 14. Završna klasifikacije hiperspektralne snimke SAM metodom s uključenim kanalima 7- 31 i dodatnom klasom pločnik sa legendom	30
Slika 15. Rezultat klasifikacije multispektralne snimke MLC metodom sa legendom	32
Slika 16. Rezultat klasifikacije hiperspektralne snimke MLC metodom sa legendom	33
Slika 17. Rezultat izračuna NDVI indeksa na multispektralnoj snimci sa legendom	35
Slika 18. Rezultat izračuna NDVI indeksa na hiperspektralnoj snimci sa legendom.....	35
Slika 19. Rezultat klasifikacije skupa multispektralnih kanala i NDVI-a metodom Maximum Likelihood s legendom.....	37
Slika 20. Rezultat klasifikacije skupa hiperspektralnih kanala i NDVI-a metodom Maximum Likelihood s legendom.....	38

POPIS TABLICA

Tablica 1. Parametri WorldView-110 kamere (modificirano prema URL 20).....	19
Tablica 2. Parametri HySpex VNIR-1024 kamere (modificirano prema Norsk Elektro Optikk AS, 2019)	21