

Klasifikacija lave na Islandu pomoću multispektralnih snimaka Sentinel-2

Talić, Sara

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering / Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:169:769585>

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

Download date / Datum preuzimanja: **2025-01-24**



Repository / Repozitorij:

[Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
Diplomski studij geološkog inženjerstva

**KLASIFIKACIJA LAVE NA ISLANDU POMOĆU MULTISPEKTRALNIH
SNIMAKA SENTINEL-2**

Diplomski rad

Sara Talić
GI 476

Zagreb, 2024



KLASA: 602-01/24-01/60
URBROJ: 251-70-14-242
U Zagrebu, 02.07.2024.

Sara Talić, studentica

RJEŠENJE O ODOBRENJU TEME

Na temelju vašeg zahtjeva primljenog pod KLASOM 602-01/24-01/60, URBROJ: 251-70-14-241 od 24.04.2024. priopćujemo vam temu diplomskog rada koja glasi:

KLASIFIKACIJA LAVE NA ISLANDU POMOĆU MULTISPEKTRALNIH SNIMAKA SENTINEL-2

Za mentora ovog diplomskog rada imenuje se u smislu Pravilnika o izradi i obrani diplomskog rada Doc.dr.sc. Ivan Medved nastavnik Rudarsko-geološko-naftnog-fakulteta Sveučilišta u Zagrebu.

Mentor:

Doc.dr.sc. Ivan Medved

(titula, ime i prezime)

Predsjednica povjerenstva za
završne i diplomske ispite:

Izv.prof.dr.sc. Ana Maričić

(titula, ime i prezime)

Prodekan za nastavu i studente:

Izv.prof.dr.sc. Borivoje

Pašić

(titula, ime i prezime)

KLASIFIKACIJA LAVE NA ISLANDU POMOĆU MULTISPEKTRALNIH SNIMAKA SENTINEL-2

Sara Talić

Rad izrađen: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za geofizička istraživanja i rudarska mjerena
Pierottijeva 6, 10 000 Zagreb

Sažetak

Cilj ovog diplomskog rada je korištenje daljinskih istraživanja u svrhu klasificiranja lave na Islandu pomoći QGIS alata i njegovih dodataka. Kao posljedica niza erupcija vulkana krajem listopada 2023. godine u narednim mjesecima Island je iskusio niz zastrašujućih i opasnih situacija u kojima su bile potrebne mjere evakuacije. Korištenjem Sentinel-2 satelita preuzeta su dva seta podataka od kojih jedan predstavlja područje prije erupcije, a drugi poslije erupcije. Upotrebom SCP plugin-a za QGIS softver napravljeni su treninzi za nadziranu klasifikaciju prije i poslije erupcije lave. Algoritmi po kojima je rađena klasifikacija su *maximum likelihood* (*maksimalna vjerojatnost*), *minimum distance* (*minimalna udaljenost*) i *spectral angle mapping* (*spektralno kutno kartiranje*), sva tri algoritma korištena su na četiri treninga i uz promatranje samog njihovog rada, uspoređena je i ovisnost kvalitete treninga o dobivenim rezultatima.

Ključne riječi: Island, lava, klasifikacija, Sentinel-2, QGIS, SCP

Diplomski rad sadrži: 47 stranice, 2 tablica, 34 slike, 27 reference

Jezik izvornika: Hrvatski

Pohrana rada: Knjižnica Rudarsko-geološko-naftnog fakulteta, Pierottijeva 6, Zagreb

Mentor: dr. sc. Ivan Medved, docent RGNF-a

Ocenjivači: dr. sc. Ivan Medved, docent RGNF-a
dr. sc. Jasna Orešković, profesorica RGNF-a
dr. sc. Tomislav Korman, izvanredni profesor RGNF-a

University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering

Master's Thesis

CLASSIFICATION OF LAVA IN ICELAND USING SENTINEL-2 MULTISPECTRAL IMAGES

Sara Talić

Thesis completed at: University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering
Department of geophysical exploration and mine surveying
Pierottijeva 6, 10 000 Zagreb

Abstract

The purpose of this thesis is to classify lava in Iceland using remote sensing and GIS tools and plugins. In the last months Iceland experienced multiple frightening and dangerous situations in which evacuation measures were necessary as a result of a series of volcanic eruptions at the end of October 2023. Two sets of Sentinel-2 satellite data were downloaded, one which represents area of interest before eruption and the other after. Using the SCP plugin for QGIS software, four training data sets were made to use for supervised classification on examples before and after lava. Algorithms used for the classification are maximum likelihood, minimum distance and spectral angle mapping, all three algorithms were trained on all four training sets. In the end, the quality analysis was performed to determine which algorithm is the most suitable

Keywords: Iceland, lava, classification, Sentinel-2, QGIS, SCP

Thesis contains: 47 pages, 2 tables, 34 figures, 27 references

Original in: Croatian

Archived in: Library of Faculty of Mining, Geology and Petroleum Engineering, Pierottijeva 6, Zagreb

Supervisor: Assistant Professor Ivan Medved, PhD

Reviewers: Assistant Professor Ivan Medved, PhD
Professor Jasna Orešković, PhD
Associate Professor Tomislav Korman, PhD

Defence date: July, 8, 2024 , Faculty of Mining, Geology and Petroleum Engineering, University of Zagreb

Veliko hvala mojoj obitelji na podršci i bodrenju tijekom cijelog studiranja i pisanja ovog rada. Mama, tata, Neno i dida hvala vam što ste vjerovali u meni čak i kada nisam sama u sebe.

SADRŽAJ

1.	UVOD	1
2.	PODRUČJE ISTRAŽIVANJA	2
2.1.	Geologija Islanda	2
2.2.	Vulkanizam na Islandu	4
2.3.	Tijek dogadaja	6
3.	TEORIJSKE OSNOVE	11
3.1.	Daljinska istraživanja.....	11
3.2.	Sentinel-2	13
3.3.	QGIS	16
3.4.	Klasifikacija rasterskih podataka	16
3.5.	Nadzirana klasifikacija	16
3.6.	Nenadzirana klasifikacija	19
3.7.	Semi-Automatic Classification Plugin (SCP)	20
4.	OBRADA PODTAKA.....	22
4.1.	Band set.....	23
4.2.	Trening.....	24
5.	REZULTATI	26
5.1.	Utjecaj kvalitete treninga	32
6.	ZAKLJUČAK.....	36
7.	LITERATURA	38

POPIS SLIKA

Slika 2-1. Područje Islanda (Freeworldmaps, 2021.)	2
Slika 2-2. Geološka karta Islanda (Geologictimepics, 2024.)	3
Slika 2-3. Prikaz tektonskih ploča na Islandu (USGS, 2024.).....	4
Slika 2-4. Sustavi vulkana na poluotoku Reykjanes (Andrew i Gudmundsson, 2006.).....	5
Slika 2-5. Vrste vulkana na Islandu (Shutterstock, 2024.)	6
Slika 2-6. Lokacija intruzije u odnosu na grad Grindavik (The Intependent, 2023.).....	7
Slika 2-7. Tokovi lave u vrijeme erupcije (Scientificamerican, 2024.).....	8
Slika 2-8. Lokacije pukotina nastalih erupcijama u siječnju (BBC, 2024.)	9
Slika 2-9. Tokovi lave koji su se približili naselju (Phys, 2024.).....	10
Slika 3-1. Vizualni prikaz rada daljinskih istraživanja (Byjus, 2024).....	11
Slika 3-2. Primjeri prikupljanja podataka daljinskim metodama (Gisgeography, 2024.) ...	12
Slika 3-3. Različite rezolucije podataka (Gisgeography, 2024)	12
Slika 3-4. Spektralna rezolucija (Gisgeography, 2024.).....	13
Slika 3-5. Razlika između multispektralnih i hiperspektralnih podataka (Edmundoptics., 2024.).....	14
Slika 3-6. Orbitalna konfiguracija Sentinel-2 satelita (ESA, 2024.)	15
Slika 3-7. Princip rada algoritma <i>maksimalne vjerojatnosti</i> (Núñez, et al, 2019.).....	17
Slika 3-8. Princip rada algoritma <i>minimalne udaljenosti</i> (Razaque, et al, 2021.).....	18
Slika 3-9. Princip rada algoritma <i>spektralnog kutnog kartiranja</i> (Hafedh Hamza, et al, 2016.)	19
Slika 3-10. Razlika između nadzirane i nenadzirane klasifikacije (Superannotate, 2023.).	19
Slika 3-11. SCP plugin sa svim njegovim mogućnostima (QGIS, 2024.)	21
Slika 4-1. Područje promatranja prije erupcije vulkana	22
Slika 4-2. Područje promatranja poslije erupcije vulkana	23
Slika 4-3. Učitani band setovi s pridodanim valnim duljinama	24
Slika 4-4. Primjer jednog treninga s određenim klasama	25
Slika 4-5. Svi definirani treninzi s njihovim ukupnim brojem klasa.....	25
Slika 5-1. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma <i>maksimalne vjerojatnosti</i>	27
Slika 5-2. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma <i>minimalne udaljenosti</i>	28

Slika 5-3. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma <i>spektralnog kutnog kartiranja</i>	29
Slika 5-4. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma <i>maksimalne vjerojatnosti</i>	30
Slika 5-5. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma <i>minimalne udaljenosti</i>	31
Slika 5-6. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma <i>spektralnog kutnog kartiranja</i>	32
Slika 5-7. Prikaz utjecaja kvalitete treninga korištenjem algoritma <i>maksimalne vjerojatnosti</i>	33
Slika 5-8. Prikaz utjecaja kvalitete treninga korištenjem algoritma <i>minimalne udaljenosti</i>	34
Slika 5-9. Prikaz utjecaja kvalitete treninga korištenjem algoritma <i>spektralnog kutnog kartiranja</i>	35

POPIS TABLICA

Tablica 3-1. Valne duljine, rezolucija i opisi kanala satelita (Gisgeography, 2024.).....	15
Tablica 3-2. Usporedba između nadzirane i nenadziranje klasifikacije (Gisgeography, 2024.)	20

1. UVOD

Daljinska istraživanja su koristan i efikasan način promatranja Zemlje i njenog okoliša. Ona nam omogućuju brzo i precizno dobivanje podataka za lokacije koje su nam nedostupne zbog nepristupačnosti terena ili zbog same udaljenosti željenog promatranog područja koje može biti udaljeno tisućama kilometrima od nas. Ovisno o potrebi istraživanja koriste se razni tipovi instrumenata za dobivanje snimaka kao što su velike satelitske misije, razne letjelice poput dronova, zrakoplova, helikoptera i slično. Primjena daljinskih istraživanja je mnogobrojna i koristi se u raznim znanstvenim područjima poput šumarstva, poljoprivrede, geologije, monitoringa oceana i obala, hidrologije itd.

Island je zbog više razloga zanimljiv raznim istraživačima. Pozicioniran je na posebnom mjestu između Atlantskog i Arktičkog oceana i za državu koja toliko izolirana i ograničena svojim teritorijem posjeduje razne prirodne pojave koje se ne nalaze često u ostaku svijeta. Ledenjaci i hladna polarna klima odlikuju Island i stoga je okoliš, ali i ljudski i životinjski svijet odraz takvih surovih uvjeta. No specifična lokacija otoka koji se nalazi na Srednjoatlantskom grebenu ujedno omogućava značajnu tektonsku aktivnost na cijelom području što dovodi do velikog broja gejzira i izuzetne vulkanske aktivnosti. Jedinstveni uvjeti na Islandu znači da su ljudi i institucije upoznati s nepogodama s kojima se mogu susretati, ali i dalje ih prirodne neprilike mogu iznenaditi svojim razmjerima kao što se dogodilo pred kraj 2023. godine.

Serijske potresa u listopadu 2023. godine najavili su povećanu vulkansku aktivnost sjeverno od grada Grindavik koji je u sljedećih nekoliko mjeseci ostao pod ugrozom od velikih tokova lave koji su prijetili uništenju grada.

U ovom radu iskoristit će se podaci prikupljeni iz svemirske misije razvijene od strane Europske svemirske agencije. Program u kojem je razvijena svemirska misija zove se Copernicus, a sam naziv svemirske misije je Sentinel-2. Iz prikupljenih multispektralnih satelitskih snimaka, korištenjem nadzirane klasifikacije u QGIS-u, dobit će se klasifikacija eruptirane lave na Islandu i proučiti će se algoritmi dostupni u pluginu (*maksimalna vjerojatnost, minimalna udaljenost, spektralno kutno kartiranje*) i njihove mogućnosti definiranja različitih klasa.

2. PODRUČJE ISTRAŽIVANJA

Island je nordijska otočna država smještena između Atlantskog i Arktičkog oceana. Nalazi se na vrlo tektonski aktivnom i geološki zanimljivom području s velikim brojem ledenjaka, gnezira i vulkana (Slika 2-1.).

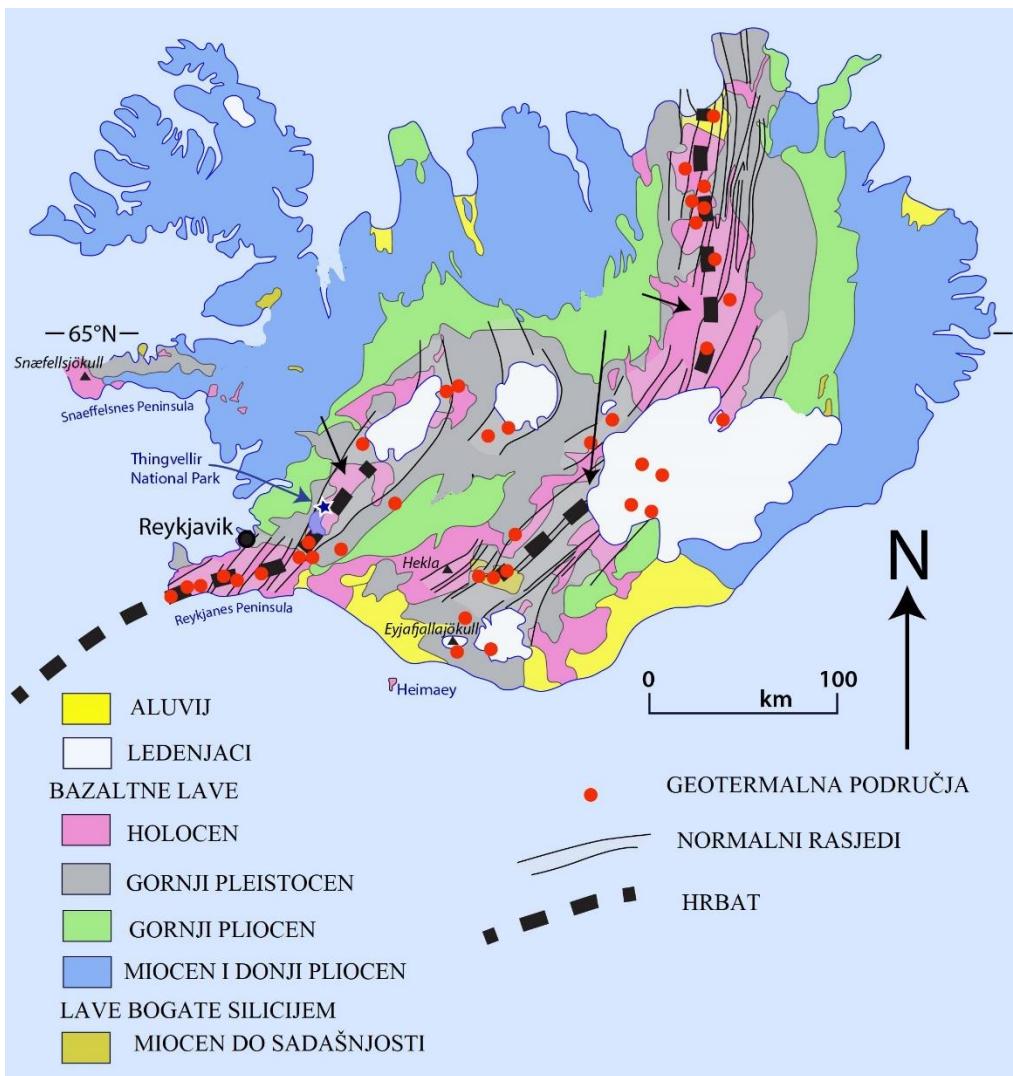


Slika 2-1. Područje Islanda (Freeworldmaps, 2021.)

2.1. Geologija Islanda

Podloga islandskih stijena je mlada u usporedbi sa starosti ostalih kontinenata. Najstariji pronađeni primjeri supstrata imaju oko 16 milijuna godina. Površinske naslage, odnosno sedimenti, uglavnom potječu s kraja posljednjeg ledenog doba (oko 15 000 godina ili mlađe). Najznačajniji utjecaj na izgled i oblikovanje Islanda imali su ledenjaci, vulkanizam, kopnene vode i okolni ocean (Icelandic Institute of Natural History, 2024).

Otpriklike 10% strukture zemlje sastoji se od riolita, dacita i drugih kiselih stijena, a najčešći tip bazaltne stijene je toplit (Slika 2-2.).



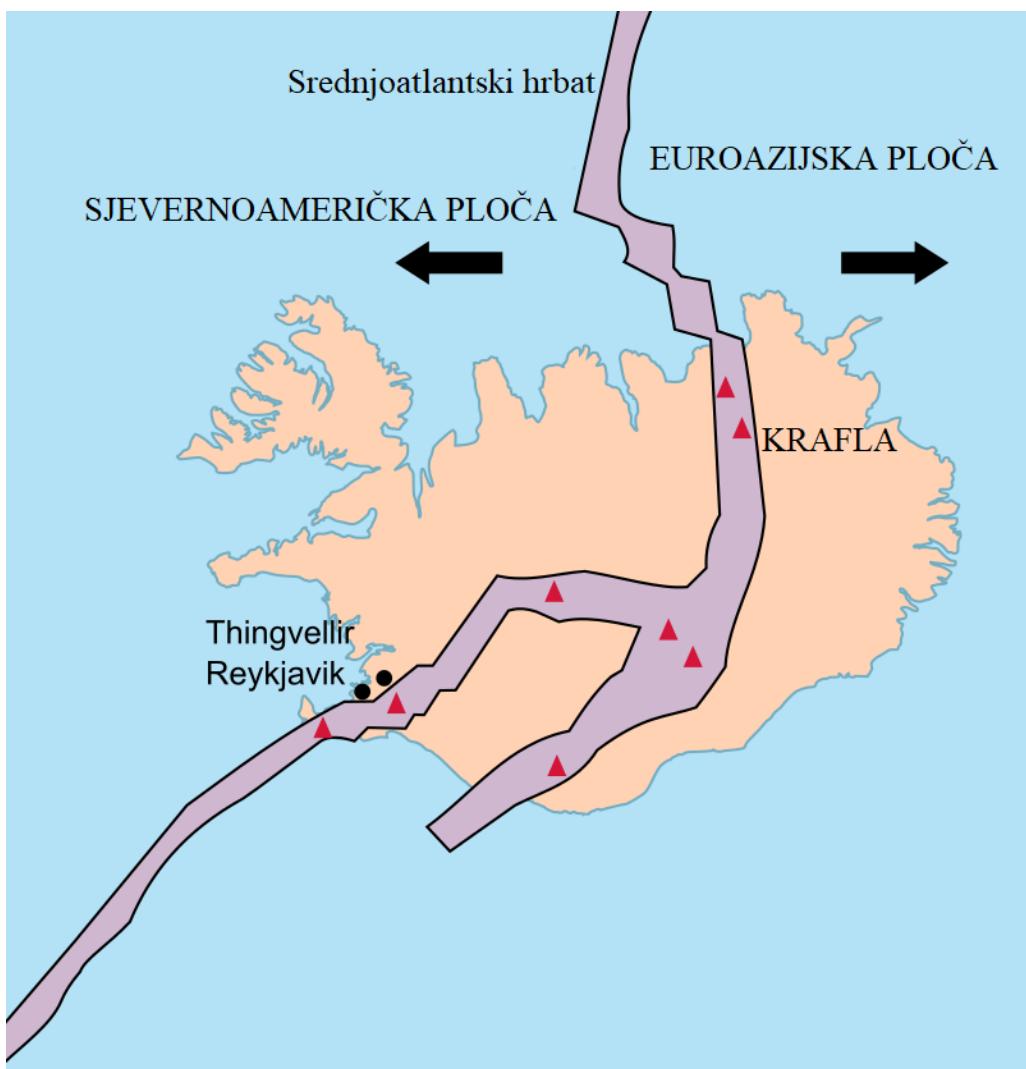
Slika 2-2. Geološka karta Islanda (Geolictimepics, 2024.)

Divergentne granice pojavljuju se duž centara širenja gdje se ploče odmiču i nova kora se stvara magmom koja se gura prema gore iz plašta. Najpoznatija divergentna granica je Srednjoatlantski greben. To je potopljeni planinski lanac koji se proteže od Arktičkog oceana do južnog vrha Afrike. Brzina širenja duž grebena je u prosjeku je oko 2,5 centimetra godišnje (cm/god), ili 25 km u milijun godina.

Island se proteže preko Srednjeatlantskog grebena i dijeli duž centra širenja između sjevernoameričke i euroazijske ploče, Sjeverna Amerika pomicanje se prema zapadu u odnosu na Euroaziju. Posljedice pomicanja ploča lako su vidljive oko vulkana Krafla, u sjeveroistočnom dijelu Islanda. Ovdje su se postojće pukotine u tlu proširile, a nove se pojavljuju svakih nekoliko mjeseci. Od 1975. do 1984. dogodile su se brojne pojave riftinga (pučanja površine) duž zone pukotine Krafla (Slika 2-3.). Neki od tih događaja rascjepa bili su popraćeni vulkanskom aktivnošću, tlo bi se postupno dizalo 1-2 m prije nego što bi se

naglo spustilo, signalizirajući nadolazeću erupciju. Između 1975. i 1984. pomaci uzrokovani rascjepima iznosili su oko 7 m (USGS, 2024).

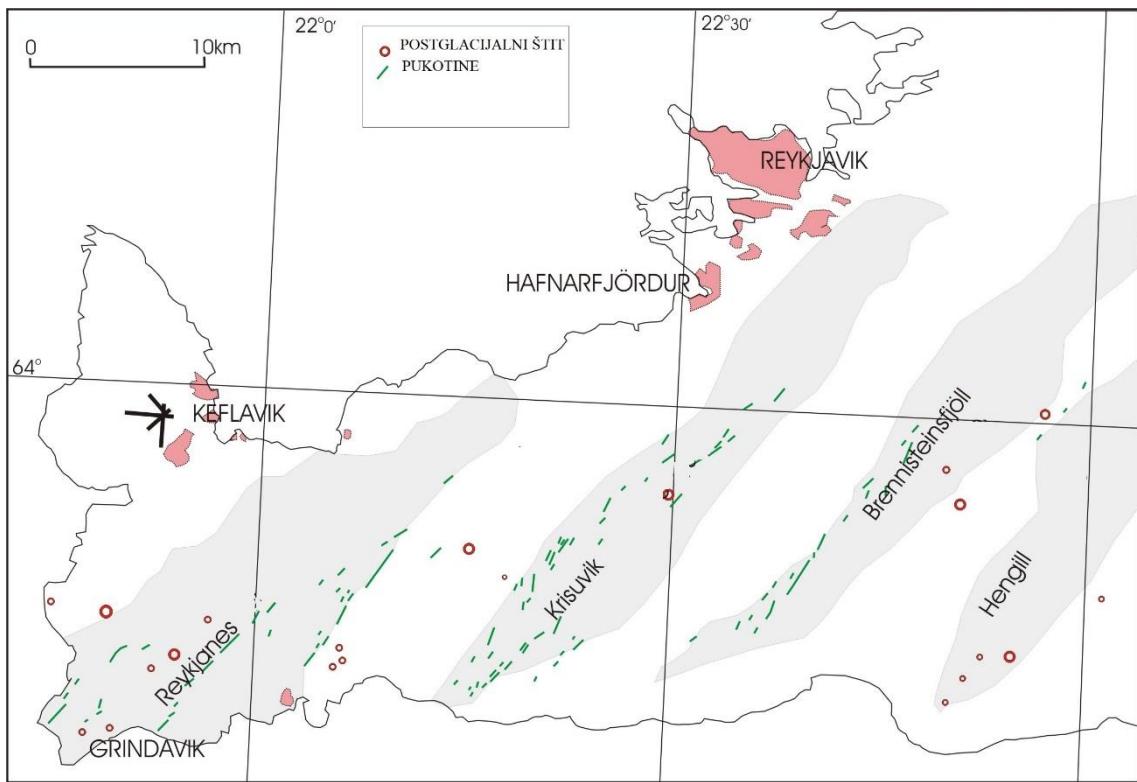
Otoci Atlantskog oceana nastali vulkanizmom Srednjoatlantskog grebena su Azori, Bermuda, Madeira, Kanarski otoci, Sveta Helena, Tristan da Cunha i drugi. Island je najveći otok iz te skupine zbog dodatnog vulkanizma uzrokovano vrućom točkom (hot spot) ispod zemlje, koja se polagano pomiče prema sjeverozapadu preko njega (Nat.is, 2024.).



Slika 2-3. Prikaz tektonskih ploča na Islandu (USGS, 2024.)

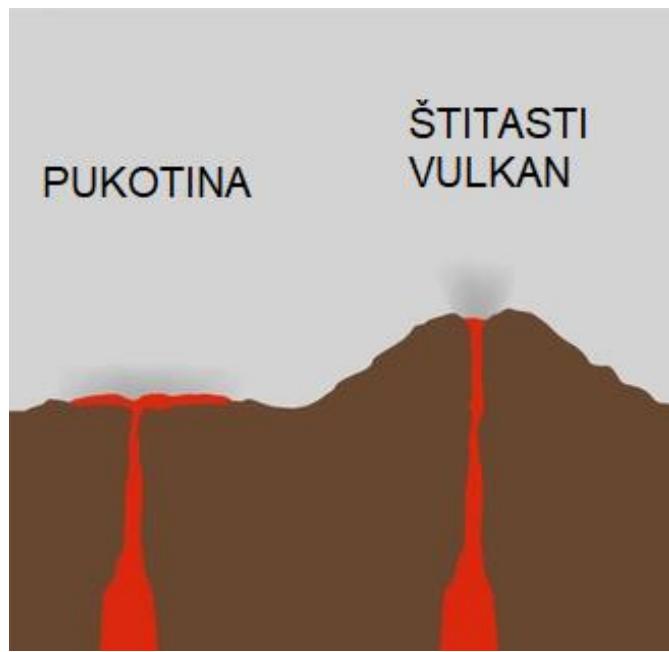
2.2. Vulkanizam na Islandu

Od posebnog značaja za ovaj rad biti će vulkanski sustav Reykjanes na jugozapadnom vrhu istoimenog poluotoka. On obuhvaća široko područje postglacijskih bazaltnih kratera, pukotina i malih štitastih vulkana (Slika 2-4.). Sam poluotok sastoji se od četiri sustava koji se protežu dijagonalno preko poluotoka Reykjanes (Smithsonian institution, 2024.).



Slika 2-4. Sustavi vulkana na poluotoku Reykjanes (Andrew i Gudmundsson, 2006.)

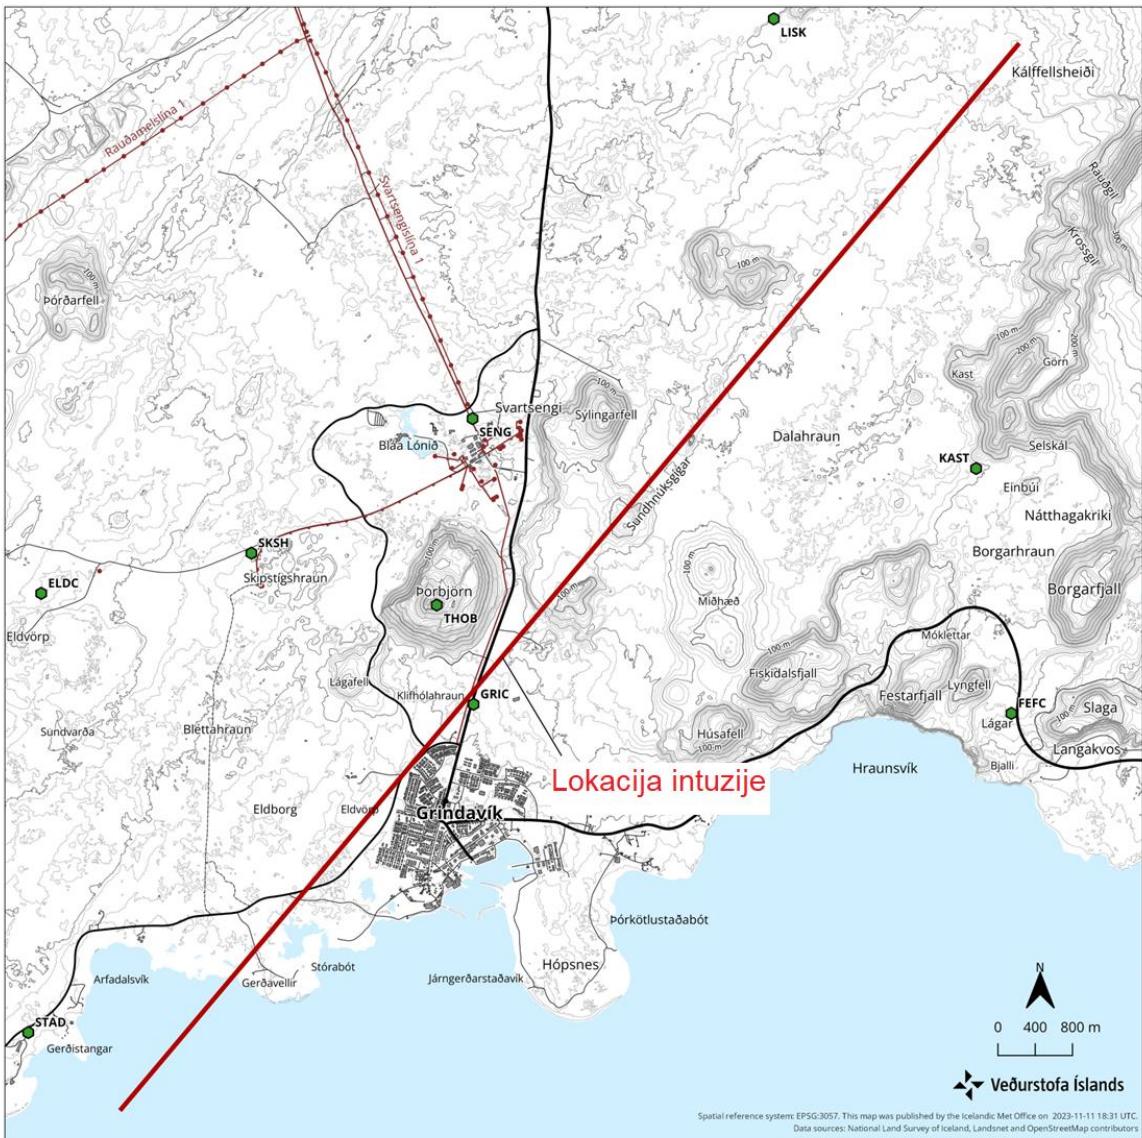
Razlike između volumena lave u jednom vulkanskom sustavu mogu jako oscilirati ovisno o vrsti vulkana (Slika 2-5.). Prosječni volumen lave štitastih vulkanskih erupcija mnogo je veći od prosjeka volumen lave pukotinskih erupcija. Na Reykjanes poluotoku prosječni volumen eruptirane lave iz 101 pukotine jest oko $0,1 \text{ km}^3$, dok je prosječni volumen 26 štitnih vulkana oko 1 km^3 . Također postoji i korelacija između sastava erupcije i vrste vulkana. Pukotine proizvode više razvijeni bazalti, obično toleit ili kvarc-toleit. (Andrew i Gudmundsson, 2006.)



Slika 2-5. Vrste vulkana na Islandu (Shutterstock, 2024.).

2.3. Tijek dogadaja

Niz prvih značajnih potresa 24.10.2023. zabilježio je islandski meteorološki zavod (IMO) na poluotoku Reykjanes. Do 26.10.2023. detektirano je više od 4000 potresa na dubinama od 2-6 km. Ukupno 14 potresa imalo je magnitudu veću od 3 stupnja po Richterovoj ljestvici, a najveći od njih imao je magnitudu 4.5 stupnja po Richterovoj ljestvici. GPS postaje nisu zamjetile značajnije deformacije tla, iako je jedna postaja očitala pomak tla prema jugoistoku od 2 centimetra. Seizmička aktivnost znatno se smanjila do 28.10.2023., ali na podacima satelitskog radara i GPS-a pokazala su se uzdizanja sa središtem oko Svartsengija, grada smještenog 1,5 km sjeverozapadno od planine Thorbjorn. Izdizanje je počelo u nekom trenutku prethodnog dana i vjerojatno je značilo magmatsku intruziju u podzemlju. Daljnja modeliranja pokazala su da se magma nakuplja na dubini od oko 4 km i ukazuje na njen kretanje. Monitoring područja kroz studeni se nastavio i zabilježeno je preko 20 000 podrhtavanja tla, izdizanja su se povećala i svi prikupljeni podaci ukazivali su na puno veće i značajnije pomake tla za razliku od zadnje četiri velike erupcije na Islandu. Radarske snimke 10.11.2023. pokazale su da je intruzija veća od 15 km i nalazi se na manje od kilometar dubine, a pojavili su se i štetni plinovi u zraku (Slika 2-6.). Iz grada Grindavík evakuirano je oko 4000 stanovnika, a zatvoreno je i odmaralište Blue Lagoon. Seizmička aktivnost se smirila i do 28.11.2023. bilo je manje od 500 podrhtavanja s magnitudama manjim od 1 stupanj po richteru, a istraživanja su pretpostavila da je magma nastavila teći u srednji dio dajka.



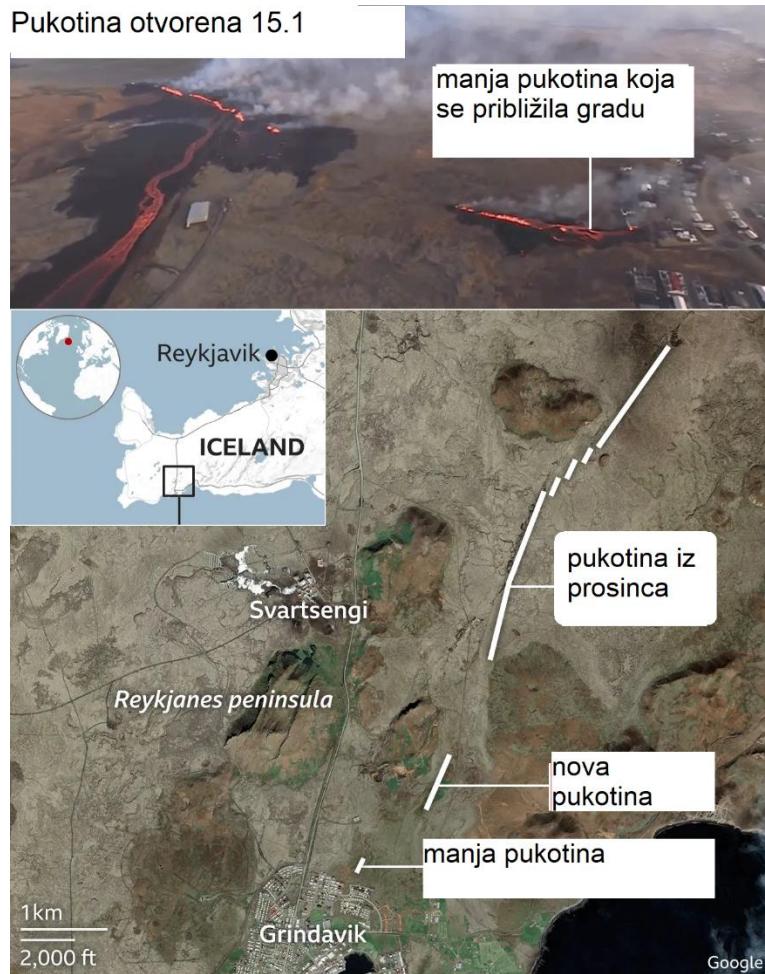
Slika 2-6. Lokacija intruzije u odnosu na grad Grindavík (The Intependent, 2023.)

IMO je izvijestio da je nova erupcija na poluotoku Reykjanes započela u 22:17 18.12.2023. iz pukotina koje su se otvorile na lokaciji u blizini starijeg niza kratera Sundhnúkagígar, oko 3 km sjeveroistočno od grada Grindavíka. Dajk je počeo prodirati ispod tog područja krajem listopada, a magma je nastavila teći i prihranjivati dajk uzrokujući pucanje tla u područjima duž njegove osi. Erupciji je neposredno prethodio niz potresa koji je započeo u 21:00 18.12.2023., a otvaranje pukotine bilo je popraćeno značajnom deformacijom tla. Ukupna duljina pukotine procijenjena je na 4 km. Velike fontane lave su se uzdizale stotinama metara visoko duž pukotine, hraneći tokove lave u više smjerova (Slika 2-7.).



Slika 2-7. Tokovi lave u vrijeme erupcije (Scientificamerican, 2024.)

Brzina ispuštanja lave tijekom prva dva sata erupcije bila je oko $1.0 \times 10^{-7} \text{ km}^3$ u sekundi, a izlazila je iz 5 glavnih otvora. Već sutradan 19.12.2023. brzina ispuštanja lave bila je oko jedne četvrtine brzine izmjerene na početku erupcije i oko jedne trećine pukotine bila je aktivna. Fontane lave bile su niže, uzdizale su se do 30 m i ostala su aktivna samo tri otvora. Znanstvenici su 26.12.2023. zaključili da je erupcija potpuno prestala. Ukupno je izbilo oko 0.012 km^3 lave, pokrivajući površinu od oko $3,4 \text{ km}^2$. Između 10. siječnja -16. siječnja 2024. i 14. veljače - 28. veljače 2024. dogodile su se još dvije erupcije kojima je prethodila seizmička aktivnost (Slika 2-8.).



Slika 2-8. Lokacije pukotina nastalih erupcijama u siječnju (BBC, 2024.)

U siječnju su evakuirani građani obližnjeg grada i nije im bio dopušten povratak do daljnog. Proračuni modela pokazali su da se tijekom veljače $0,008$ do $0,009 \text{ km}^3$ magme nakupilo ispod područja Svartsengi. Zadnja erupcija počela je 2. ožujka 2024. i trajala je kroz travanj. Većina stanovnika Grindavíka ostala je evakuirana, ali ostatak koji nije bio je dobio upozorenje da ne mogu ostati preko noći u svojim kućama (Slika 2-9.). Područje protoka lave bilo je oko $5,99 \text{ km}^2$ s približnim volumenom od $0,0257 \text{ km}^3$. Tokovi lave napredovali su preko starijih tokova nastalih prijašnjim erupcijama (US Geological Survey, 2024.)



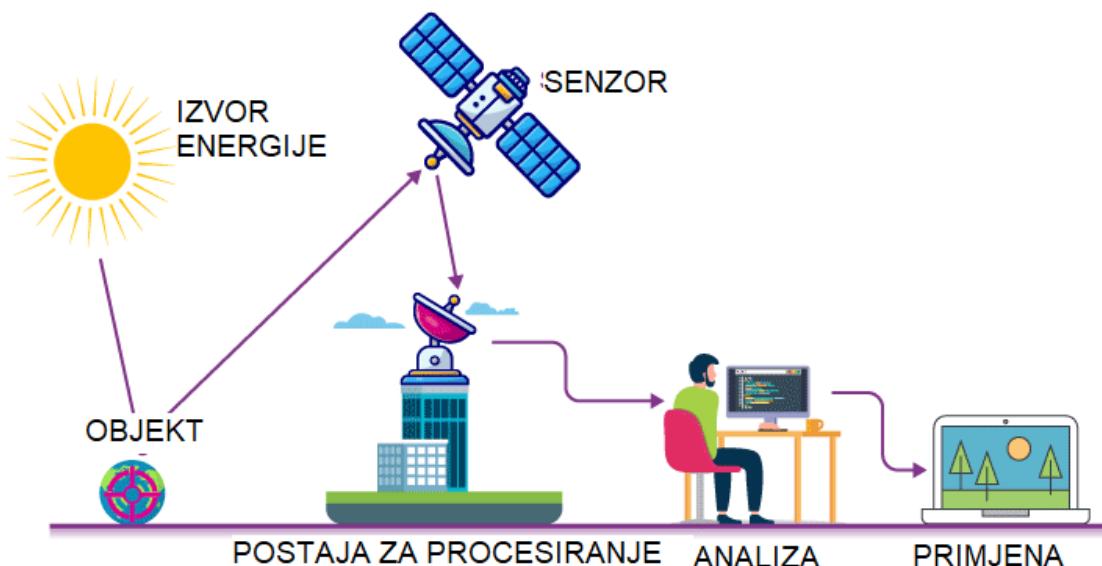
Slika 2-9. Tokovi lave koji su se približili naselju (Phys, 2024.)

3. TEORIJSKE OSNOVE

Za potrebe dobivanja i obrade podataka korištene su danas dostupne metode daljinskih istraživanja u kombinaciji s besplatnim softverom QGIS koje će biti opisane u sljedećem poglavlju.

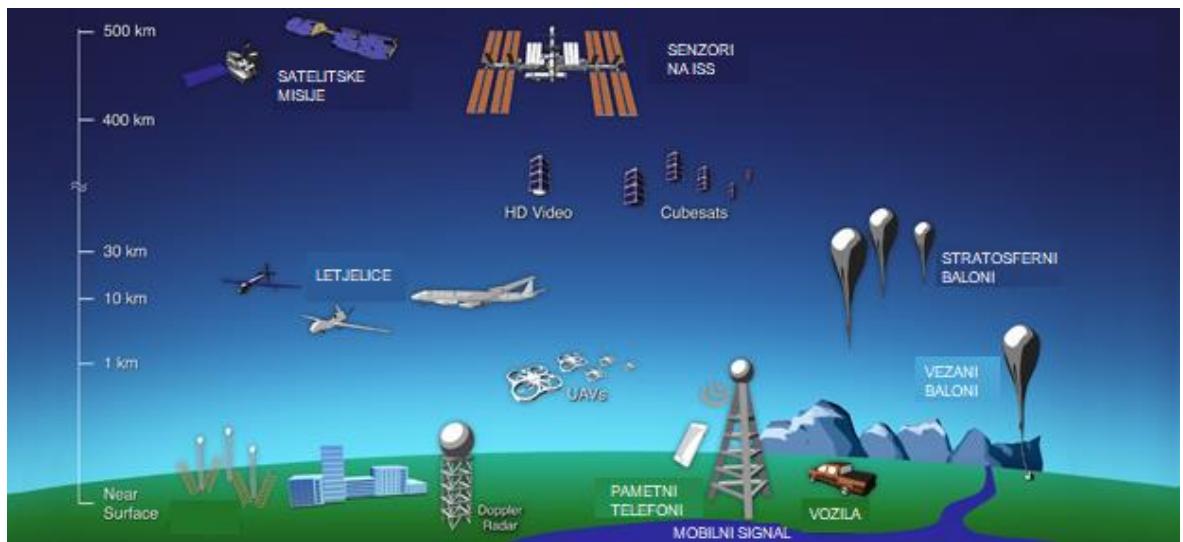
3.1. Daljinska istraživanja

Daljinsko istraživanje je proces otkrivanja i praćenja fizičkih karakteristika područja mjeranjem njegovog reflektiranog i emitiranog zračenja na daljinu (Slika 3-1.) obično iz satelita ili letjelice (USGS, 2022.).



Slika 3-1. Vizualni prikaz rada daljinskih istraživanja (Byjus, 2024)

Svaki tip senzora korišten u daljinskim istraživanjima ima svoje prednosti i nedostatke. Kod odabira metode i senzora moraju se uzeti u obzir faktori kao što su ograničenja leta, razlučivost slike i pokrivenost. Na primjer, sateliti snimaju podatke na globalnoj razini, a dronovi su prikladniji za letove u malim područjima, zrakoplovi i helikopteri pokrivaju područje između dronova i satelita, te se mora procijeniti koja će od ovih opcija odgovarati potrebama zadatka (Slika 3-2.).



Slika 3-2. Primjeri prikupljanja podataka daljinskim metodama (Gisgeography, 2024.)

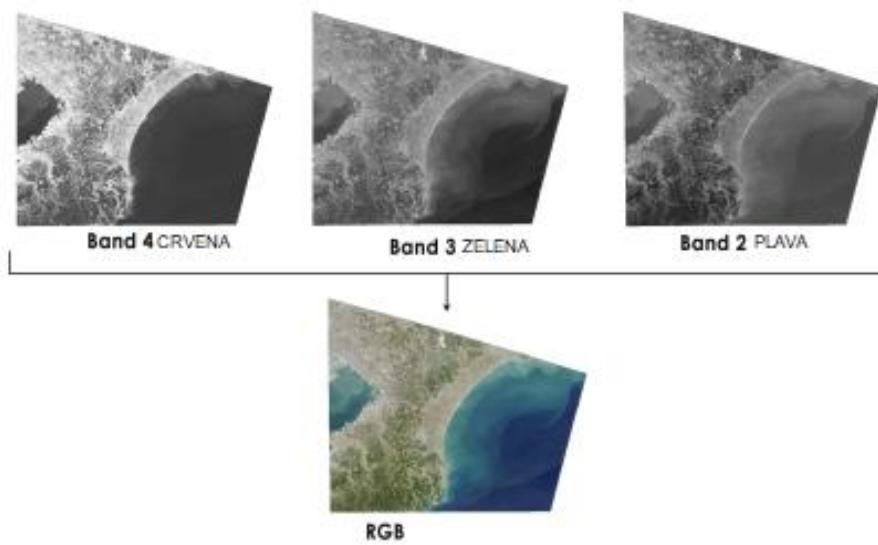
U daljinskim istraživanjima razlikujemo tri vrste rezolucija snimaka , i to su: prostorna, spektralna i vremenska rezolucija.

Prostorna rezolucija su zapravo detalji slike u pikselima. Visoka prostorna razlučivost znači više detalja u pikselu, dok niža prostorna razlučivost znači manje detalja u istoj veličini piksela. Tipično, snimci UAV-a imaju jednu od najvećih prostornih razlučivosti (Slika 3-3.).



Slika 3-3. Različite rezolucije podataka (Gisgeography, 2024)

Spektralna rezolucija je količina spektralnih detalja u pojasu (eng. *band*). Visoka spektralna rezolucija znači da su njegovi bandovi uži, a niska spektralna rezolucija ima šire bandove koji pokrivaju veći dio spektra (Slika 3-4.)

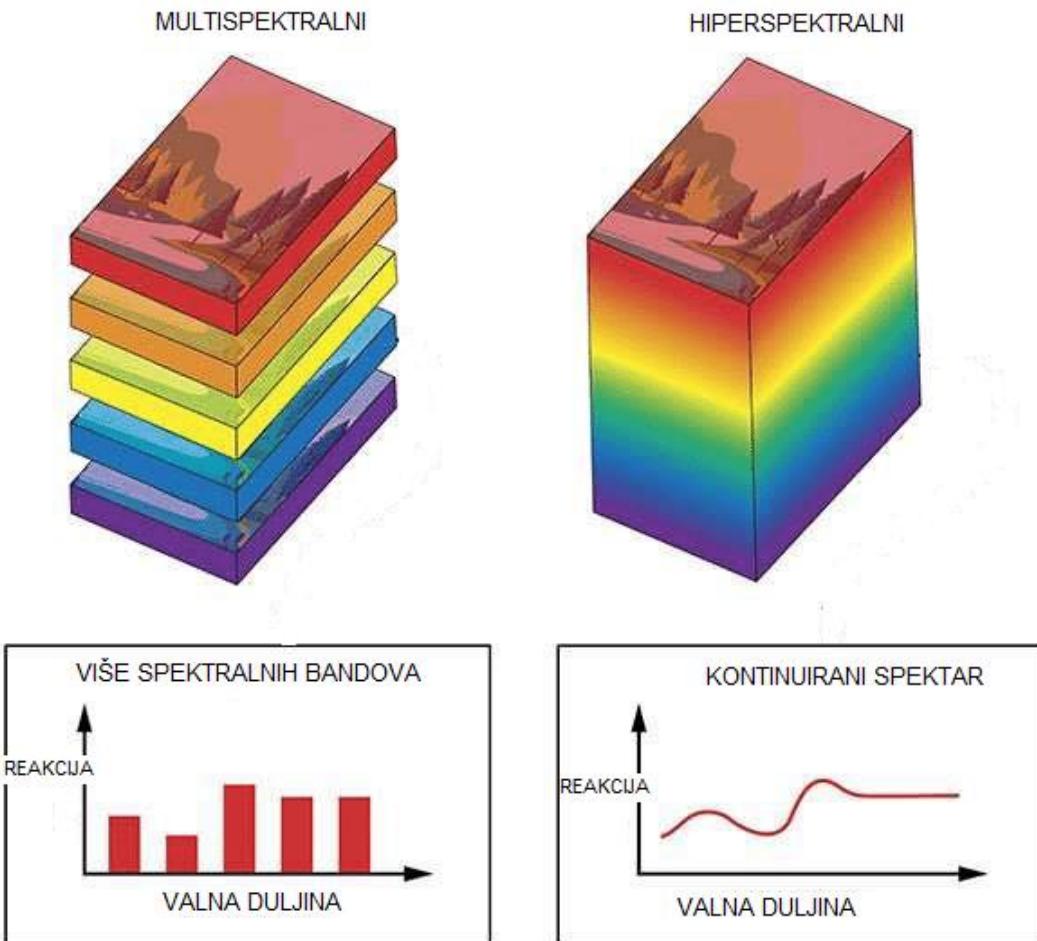


Slika 3-4. Spektralna rezolucija (Gisgeography, 2024.)

Vremenska rezolucija je vrijeme koje je potrebno satelitu da se vrati na početni položaj. UAV-ovi, zrakoplovi i helikopteri su fleksibilni te ovise o nama, a sateliti kruže oko Zemlje određenim putanjama. Budući da slijede kontinuirani orbitalni put, vremena ponovnih posjeta istog područja su dosljedna s ponekim odstupanjima (Gisgeography, 2024.).

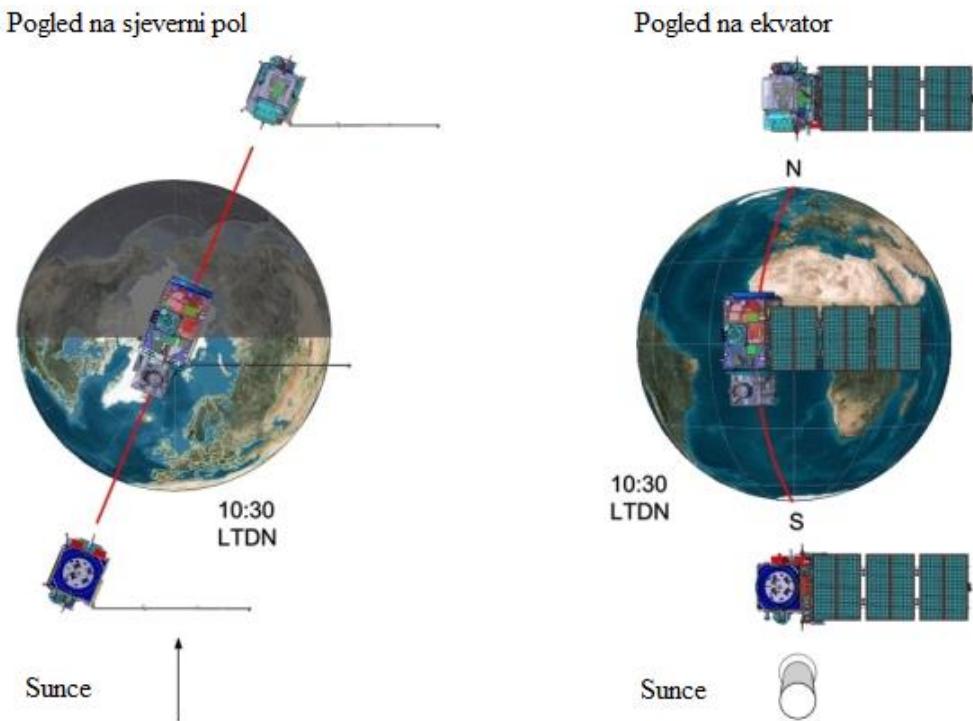
3.2. Sentinel-2

Sentineli su sateliti dizajnirana za isporuku podataka i slika koje su namijenjene europskom programu Copernicus. Sentinel-2 je misija za snimanje širokog pojasa, visoke razlučivosti i multispektralnih snimaka (Slika 3-5.).



Slika 3-5. Razlika između multispektralnih i hiperspektralnih podataka (Edmundoptics., 2024.)

Sastoje se od dva identična satelita (Sentinel-A i Sentinel-B) u istoj orbiti, udaljenih 180° za optimalnu pokrivenost i isporuku podataka (Slika 3-5.). Zajedno pokrivaju sve kopnene površine Zemlje, velike otoke, kopnene i obalne vode svakih pet dana na ekvatoru. Sastoje se od 13 kanala i može imati prostornu rezoluciju od 10, 20 ili 60 metara (ESA,2024).



Slika 3-6. Orbitalna konfiguracija Sentinel-2 satelita (ESA, 2024.)

Plavi , zeleni , crveni (B2,B3 i B4) i bliski infracrveni (B8) kanali imaju rezoluciju od 10 metara. Crveni (B5), NIR (B6, B7 i B8A) i kratkovalni infracrveni SWIR (B11 i B12) imaju rezoluciju od 20 metara. Obalni aerosol (B1) i cirrusni pojas (B10) imaju veličinu od 60 metara (Tablica 3-1.) (Gisgeography, 2024).

Tablica 3-1. Valne duljine, rezolucija i opisi kanala satelita (Gisgeography, 2024.)

Band	Rezolucija	Valna duljina	Opis
B1	60 m	443 nm	Ultra plava (obalna i aerosolna)
B2	10 m	490 nm	Plava
B3	10 m	560 nm	Zelena
B4	10 m	665 nm	Crvena
B5	20 m	705 nm	Vidljivi i bliski infracrveni (VNIR)
B6	20 m	740 nm	Vidljivi i bliski infracrveni (VNIR)
B7	20 m	783 nm	Vidljivi i bliski infracrveni (VNIR)
B8	10 m	842 nm	Vidljivi i bliski infracrveni (VNIR)
B8a	20 m	865 nm	Vidljivi i bliski infracrveni (VNIR)
B9	60 m	940 nm	Kratkovalni infracrveni (SWIR)
B10	60 m	1375 nm	Kratkovalni infracrveni (SWIR)
B11	20 m	1610 nm	Kratkovalni infracrveni (SWIR)

B12	20 m	2190 nm	Kratkovalni infracrveni (SWIR)
-----	------	---------	--------------------------------

3.3. QGIS

QGIS je besplatna aplikacija geografskog informacijskog sustava (GIS) i ona je službeni projekt Open Source Geospatial Foundationa (OSGeo). Podržava razne formate vektorskih i rasterskih podataka kao i brojne baze podataka s mnogim funkcijama za njihovu obradu. Za povećanje namjene i personalizacije korištenja QGIS aplikacije razvijeni su razni pluginovi odnosno dodaci koji se mogu instalirati u samu aplikaciju. Proširenja razvijaju neovisne organizacije i programeri koristeći opciju QGIS pythona, ovisno o njihovim potrebama i interesima (QGIS, 2024.).

3.4. Klasifikacija rasterskih podataka

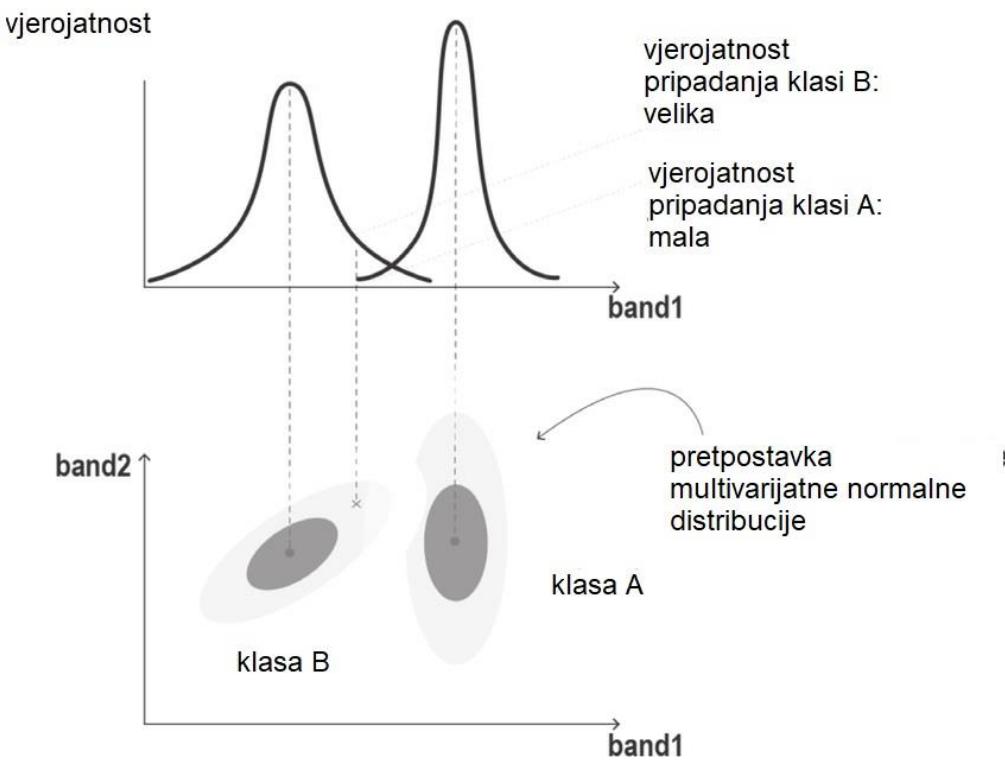
Jedan od načina upotrebe daljinskih istraživanja je klasifikacija rasterskih podataka. Ona uključuje prikupljanje i analizu podataka s različitih senzora te kategorizaciju različitih tipova zemljišnog pokrova na temelju njihovih spektralnih svojstava. Neke od klasa zemljišnog pokrova su šume, oranice, urbana područja, vodene površine, močvare i neiskoristiva zemljišta (Gisgeography, 2024.).

3.5. Nadzirana klasifikacija

Za potrebe klasifikacije zemljišnog pokrova postoje dva različita pristupa nadzirana i nenadzirana klasifikacija (eng. *supervised and unsupervised classification*).

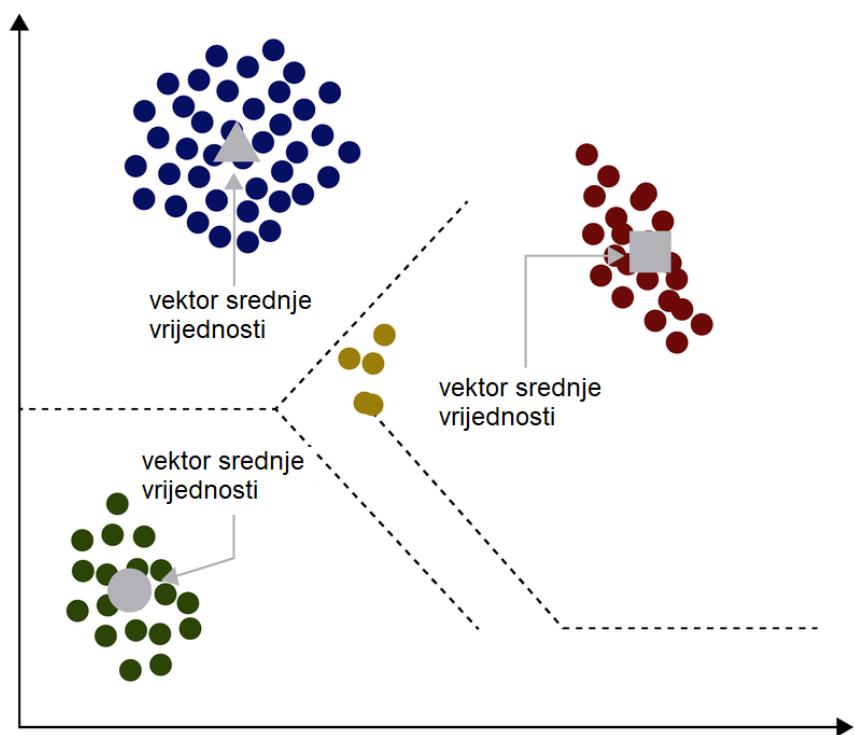
Nadzirana klasifikacija je metoda u kojoj se koristi set trening podataka za klasifikaciju piksela na slici. Set trening podataka sastoji se od primjera svake vrste zemljišnog pokrova koju se želi kartirati. Ručno se odabire uzorak za trening sa snimke i dodjeljuje im se odgovarajuća klasa pokrova zemlje. Razni algoritmi razvijeni su kako bi se pokrilo što više različitih primjera (Spatialpost, 2024.).

Klasifikacija maksimalne vjerojatnosti (eng. *maximum likelihood classification*) je algoritam u kojem se pretpostavlja da statistika za svaku klasu u svakom bandu ima normalnu raspodjelu i izračunava vjerojatnost da određeni piksel pripada određenoj klasi. Osim ako se ne odabere prag vjerojatnosti, svi pikseli su klasificirani. Svaki piksel se dodjeljuje klasi koja ima najveću vjerojatnost. Ako je najveća vjerojatnost manja od praga koji je naveden, piksel ostaje neklasificiran (Slika 3-7.).



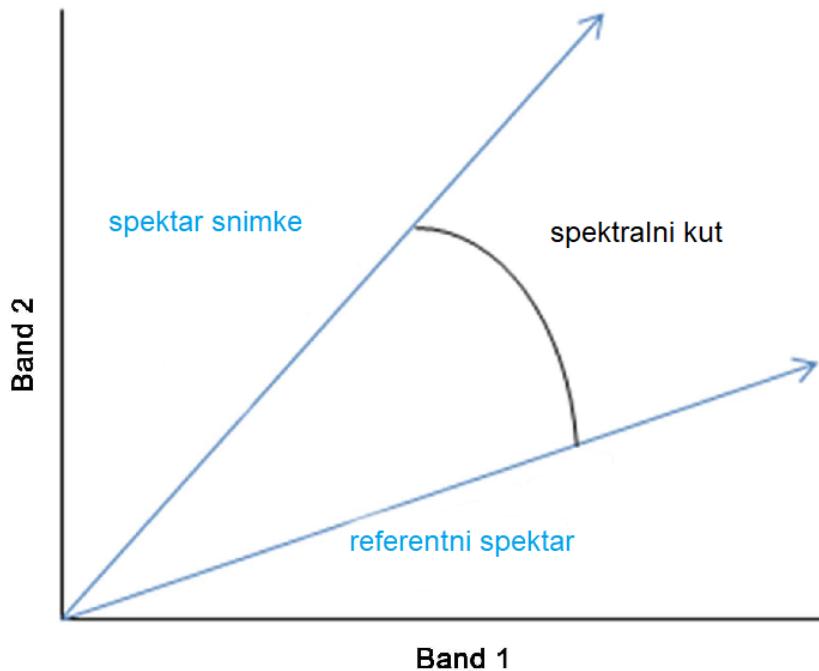
Slika 3-7. Princip rada algoritma *maksimalne vjerovatnosti* (Núñez, et al, 2019.)

Klasifikacija minimalne udaljenosti (eng. *minimum distance*) koristi vektor srednje vrijednosti svakog krajnjeg člana i izračunava euklidsku udaljenost od svakog nepoznatog piksela do vektora srednje vrijednosti za svaku klasu (Slika 3-8.). Svi pikseli klasificiraju se u najbližu klasu osim ako nije zadana standardna devijacija ili prag udaljenosti, tada neki pikseli mogu ostati nekласificирани ako ne zadovoljavaju odabране kriterije (Nv5geospatialsoftware, 2024.).



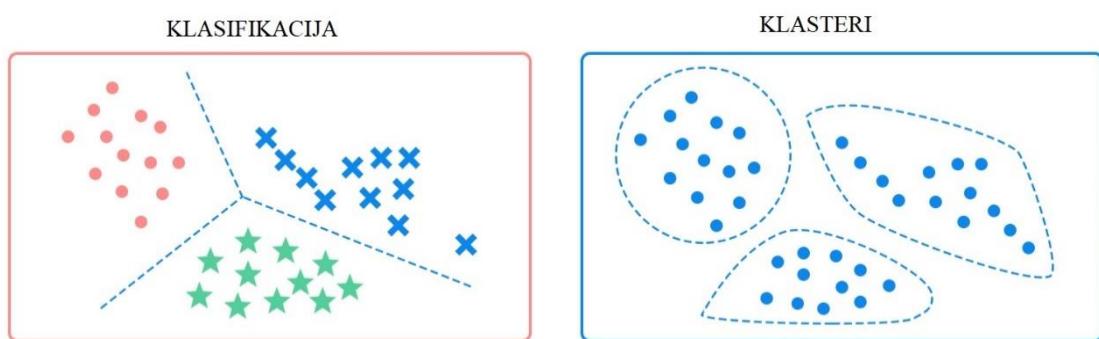
Slika 3-8. Princip rada algoritma *minimalne udaljenosti* (Razaque, et al, 2021.)

Spektralno kutno kartiranje (eng. *Spectral Angle Mapping*) klasifikacija (SAM) je metoda za izravnu usporedbu spektra snimke s poznatim spektrom (obično utvrđenim u laboratoriju ili na terenu pomoću spektrometra) ili krajnjim članom. Ova metoda tretira oba spektra (nepoznati i poznati) kao vektore i izračunava spektralni kut između njih (Slika 3-9.). Neosjetljiva je na osvjetljenje budući da SAM algoritam koristi samo smjer vektora, a ne duljinu vektora. Rezultat SAM klasifikacije pokazuje najbolje podudaranje za svaki piksel (Csr.utexas, 2024.).



Slika 3-9. Princip rada algoritma *spektralnog kutsnog kartiranja* (Hafedh Hamza, et al, 2016.)

Algoritam za klasifikaciju koristi ove trening podatke za klasificiranje preostalih piksela. Za što točnije rezultate potrebno je odabrati reprezentativne piksele za svaku klasu koji predstavljaju spektralnu varijabilnost te klase. Broj piksela potrebnih za pouzdanu klasifikaciju ovisi o složenosti područja promatranja i broju klasa, a točnost klasifikacije ovisi o kvaliteti treninga i izboru algoritma (Spatialpost, 2023.).



Slika 3-10. Razlika između nadzirane i nenadzirane klasifikacije (Superannotate, 2023.)

3.6. Nenadzirana klasifikacija

Nenadzirana klasifikacija (eng. *unsupervised classification*) koristi algoritam koji automatski grupira piksele sa sličnim spektralnim svojstvima u klastere (Slika 3-10.). Ne trebaju se napraviti trening podaci, umjesto toga algoritam analizira spektralna svojstva snimke i identificira klaster piksela sa sličnim spektralnim svojstvima. Nakon grupiranja

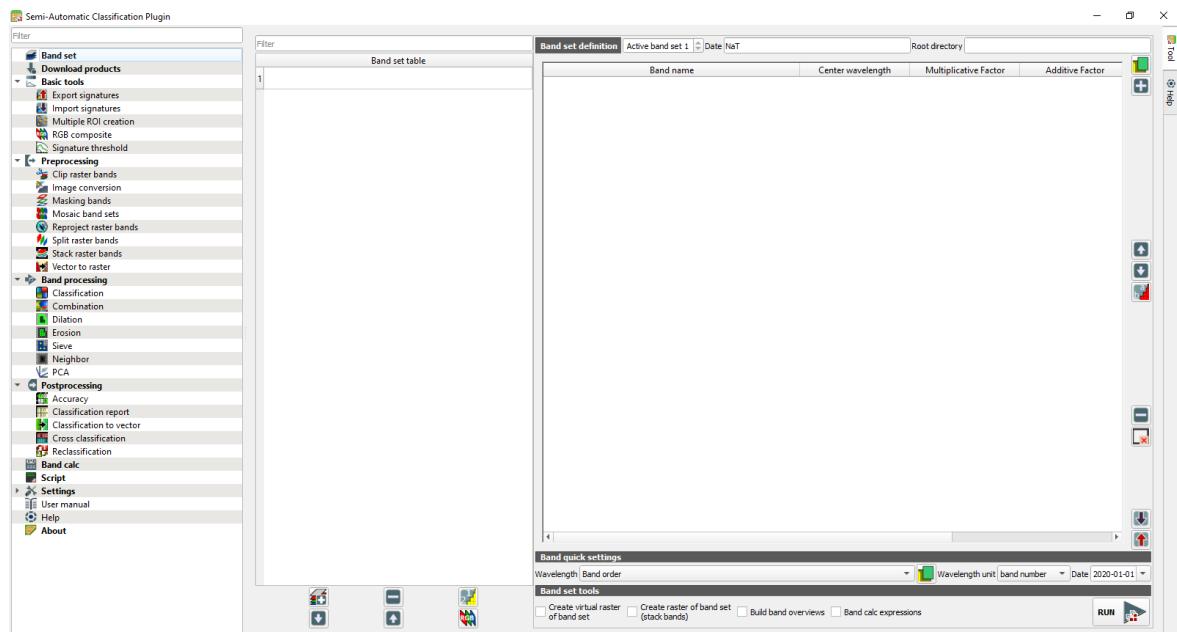
klastera odabire se broj klasa ovisno o području i potrebama istraživanja (Spatialpost, 2024.). Razlika između nadzirane i nenadzirane klasifikacije prikazana je u Tablici 3-2.

Tablica 3-2. Usporedba između nadzirane i nenadzirane klasifikacije (Gisgeography, 2024.)

Značajke	Nadzirana klasifikacija	Nenadzirana klasifikacija
Trening podaci	Korisnik sam zadaje podatke	Nisu potrebni trening podaci
Algoritam	Korisnik sam odabire algoritam	Algoritam prepoznae prirodno grupiranje
Procjena točnosti	Korisnik uspoređuje klasificirane piksele s podacima za provjeru valjanosti	Korisnik klasterima ručno dodjeljuje klase zemljишnog pokrova
Broj klasa	Korisnik određuje broj klasa	Algoritam određuje broj klasa
Prikladno za	Specifične klase zemljишnog pokrova	Istraživačke studije
Točnost	Točniji ako su trening podaci reprezentativni i ako je algoritam ispravno odabran	Manje točna od nadzirane klasifikacije
Nedostaci	Ovisnost o kvaliteti trening podataka i algoritmu	Ovisno o interpretaciji korisnika i određivanju broja klasa
Primjena	Kartiranje korištenja zemljišta i zemljишnog pokrova, monitoring okoliša, upravljanje prirodnim resursima, upravljanje geohazardima, urbano planiranje, poljoprivreda i šumarstvo	Kartiranje korištenja zemljišta i zemljишnog pokrova, monitoring okoliša, upravljanje prirodnim resursima, upravljanje geohazardima, urbano planiranje, poljoprivreda i šumarstvo

3.7. Semi-Automatic Classification Plugin (SCP)

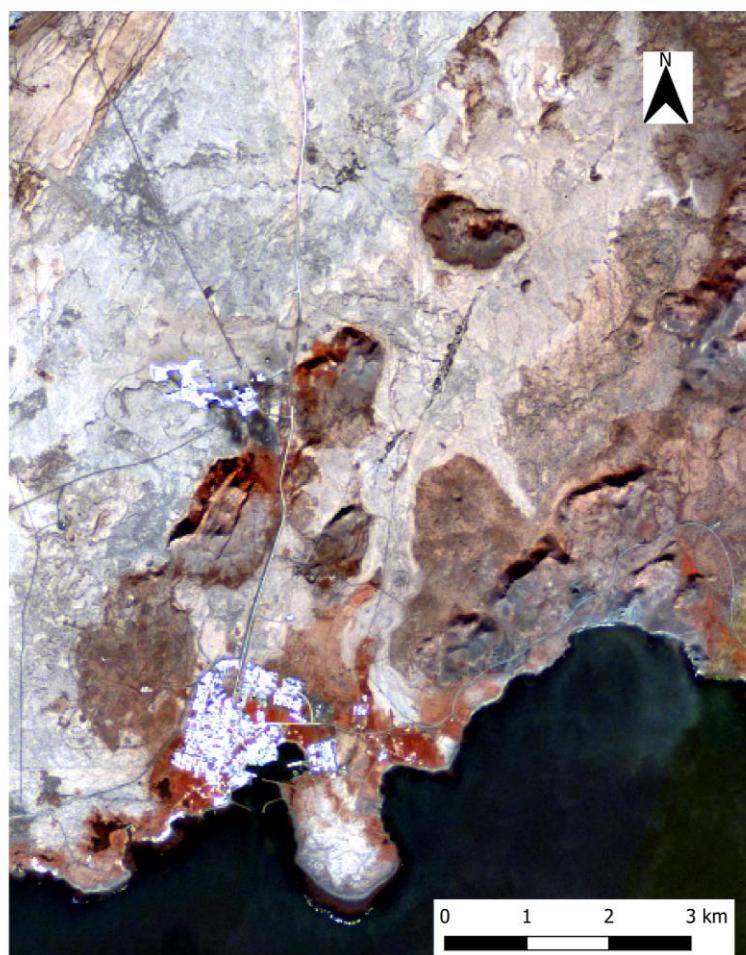
Semi-Automatic Classification Plugin (SCP), odnosno dodatak za poluautomatsku klasifikaciju nalazi se u centru ovog rada. Plugin je razvio Luca Congedo 2013. godine, inženjer s radom u daljinskim istraživanjima. Prednost ovog plugin-a je to što je besplatan i vrlo lako ugradiv u QGIS softver. Glavna funkcija mu je da omogućuje nadziranu klasifikaciju podataka preuzetih iz multispektralnih satelitskih snimaka, ali također ima mogućnosti preuzimanja i uređivanja samih podataka prije i poslije klasifikacije (Slika 3-11.). Za osnovno korištenje potrebna je instalacija Remotior Sensus, GDAL, OGR, Numpy, SciPy, and Matplotlib dodataka (Congedo, 2021.).



Slika 3-11. SCP plugin sa svim njegovim mogućnostima (QGIS, 2024.).

4. OBRADA PODTAKA

Za obradu podataka prvo smo morali dobro proučiti tijek događaja vulkanske aktivnosti. Podaci koji su se razmatrali morali su predstavljati područje promatranja na kojem nije bilo nikakvih vidljivih naznaka promjena koje su mogle nastati kao rezultat vulkanizma. Zbog početnih podrhtavanja tla sredinom listopada 2023. godine, morale su se gledati snimke prije desetog mjeseca. Uzimajući u obzir vremenski raspored, pomoću europskog Copernicus programa preuzeta su dva seta podataka za Sentinel-2. Prvi set preuzet je za dan 11.09.2023. godine i on će predstavljati naše područje prije erupcije vulkana. Taj datum odabran je jer su podaci za promatranje bili najjasniji i vremenski je dovoljno udaljen od prvih početnih potresa i naznaka vulkanske aktivnosti (Slika 4-1.).



Slika 4-1. Područje promatranja prije erupcije vulkana

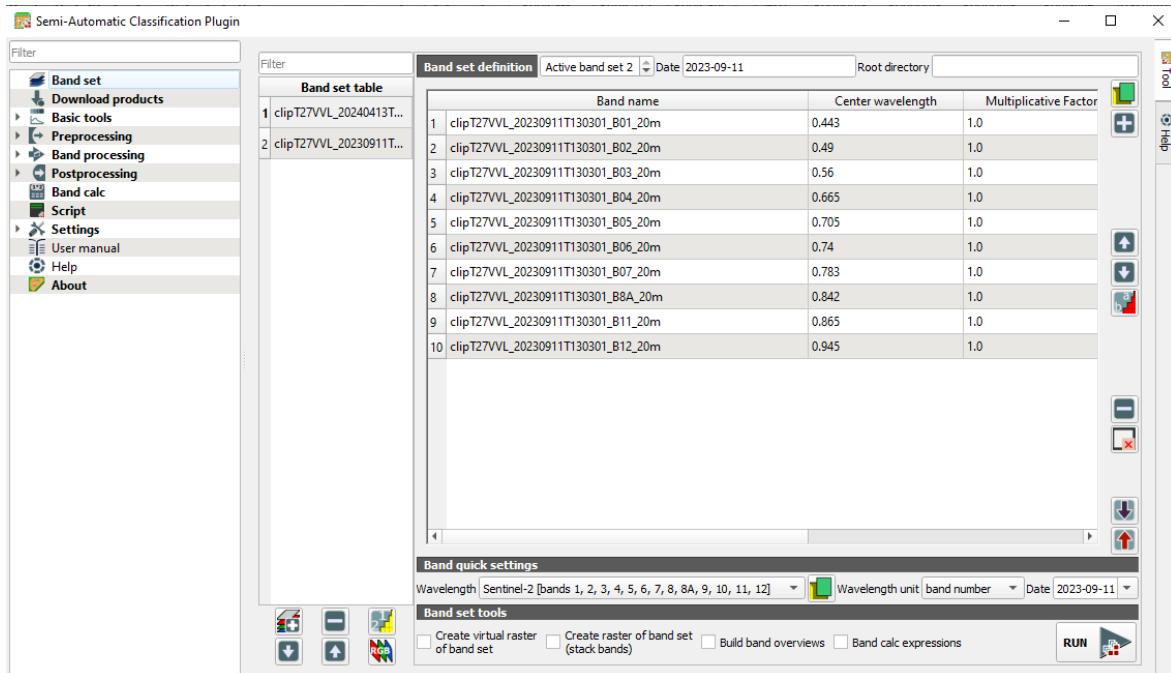
Drugi set je preuzet za 13.04.2024. i predstavljaće područje poslije. U vrijeme pisanja ovog rada vulkanska aktivnost nije u potpunosti prestala i stoga rezultati bi se mogli razlikovati ukoliko se s istim trening podacima analiziraju snimci nekog kasnijeg datuma (Slika 4-2.).



Slika 4-2. Područje promatranja poslije erupcije vulkana

4.1. Band set

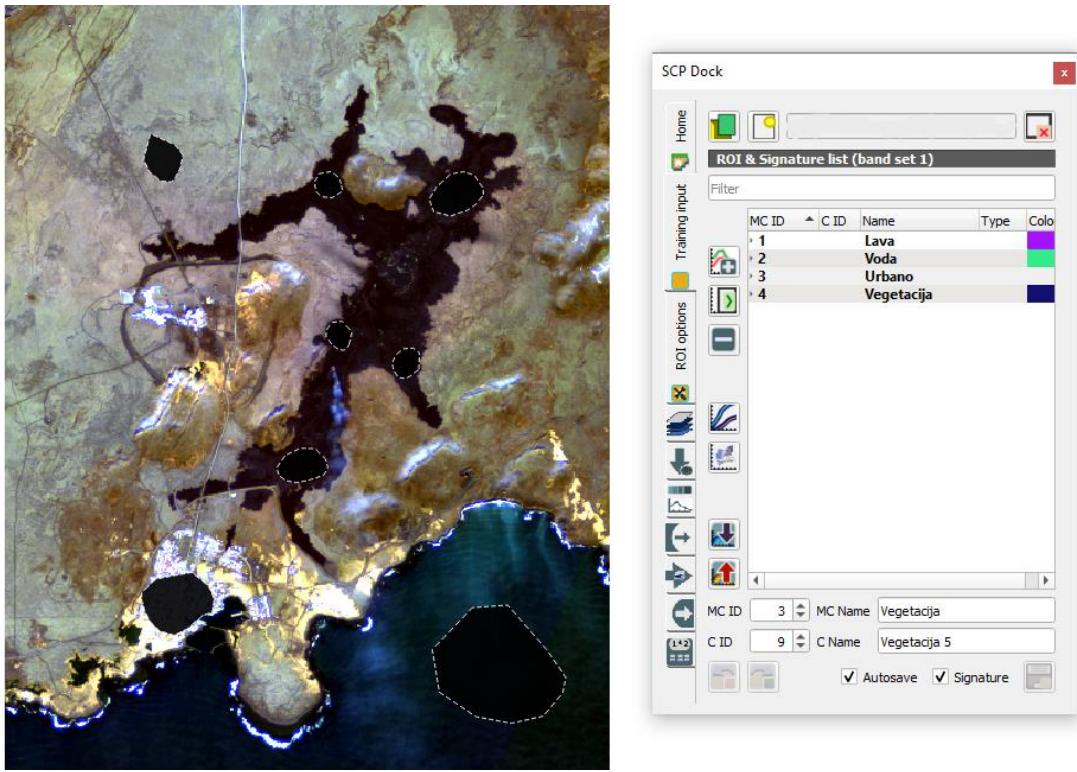
Oba seta podataka preuzeti su s 14 kanala, od kojih smo odbacili AOT (Aerosol Optical Thickness), SCL (Scene Classification Layer), TCI (True Colour Images) I WV (Water Vapour), a rezolucija im je 20 m. Zasebno su učitani podaci za situacije prije i poslije i svaki će tvoriti jedan band set. Budući da snimke zahvaćaju veliko okružje van našeg područja interesa pomoću SCP plugin-a izdvojeno je manje područje s rastera kako bi se omogućilo brže i bolje rukovanje podacima. Svaki izrezani band set je učitan u plugin i pridodane su mu osnovne postavke za rad kao što su valne duljine i datum odabira snimaka (Slika 4-3.)



Slika 4-3. Učitani band setovi s pridodanim valnim duljinama

4.2. Trening

Za nadziranu klasifikaciju potreban je trening u kojem ćemo sami definirati površine i pridodati im odgovarajuću klasifikaciju. U ovom radu napravljena su tri treninga na podacima poslije erupcije i jedan na podacima prije. Svaki trening imao je drugačije postavljene parametre kako bi se moglo uočiti razlike u samim ulaznim podacima i kako bismo odredili utjecaj detaljnosti treninga na rezultate klasifikacije (Slika 4-4.).



Slika 4-4. Primjer jednog treninga s određenim klasama

U prva tri treninga postavljene su četiri kategorije makroklase: lava, voda, urbano i vegetacija, a svaki od njih imao je postupno više definiranih segmenata kako bismo mogli napraviti usporedbu kvalitete podataka ovisno o parametrima treninga. U četvrtom treningu postavljene su tri makroklase (Slika 4-5.).

MC ID	C ID	Name	Type	Color
1	1	Lava 1	R&S	purple
1	2	Lava 2	R&S	green
1	3	Lava 3	R&S	blue
1	4	Lava 4	R&S	dark blue
1	5	Lava 5	R&S	pink

MC ID	C ID	Name	Type	Color
1	1	Lava 1	R&S	purple
1	2	Lava 2	R&S	green
1	3	Lava 3	R&S	blue
1	4	Lava 4	R&S	dark blue
1	5	Lava 5	R&S	pink
2	6	Urbano 1	R&S	yellow
2	7	Urbano 2	R&S	orange

MC ID	C ID	Name	Type	Color
1	1	Voda 1	R&S	yellow
1	2	Voda 2	R&S	orange
1	3	Voda 3	R&S	red
1	4	Voda 4	R&S	dark red
1	5	Voda 5	R&S	purple
2	6	Urbano 1	R&S	yellow
2	7	Urbano 2	R&S	orange
3	8	Voda	R&S	yellow
4	9	Vegetacija 1	R&S	green
4	10	Vegetacija 2	R&S	blue
4	11	Vegetacija 3	R&S	dark blue
4	12	Vegetacija 4	R&S	grey

MC ID	C ID	Name	Type	Color
1	1	Voda	R&S	yellow
2	2	Urbano	R&S	orange
2	3	Urbano2	R&S	red
3	4	Vegetacija 1	R&S	green
3	5	Vegetacija 2	R&S	blue
3	6	Vegetacija 3	R&S	dark blue
3	7	Vegetacija 4	R&S	grey
3	8	Vegetacija 5	R&S	purple
4	13	Voda	R&S	yellow

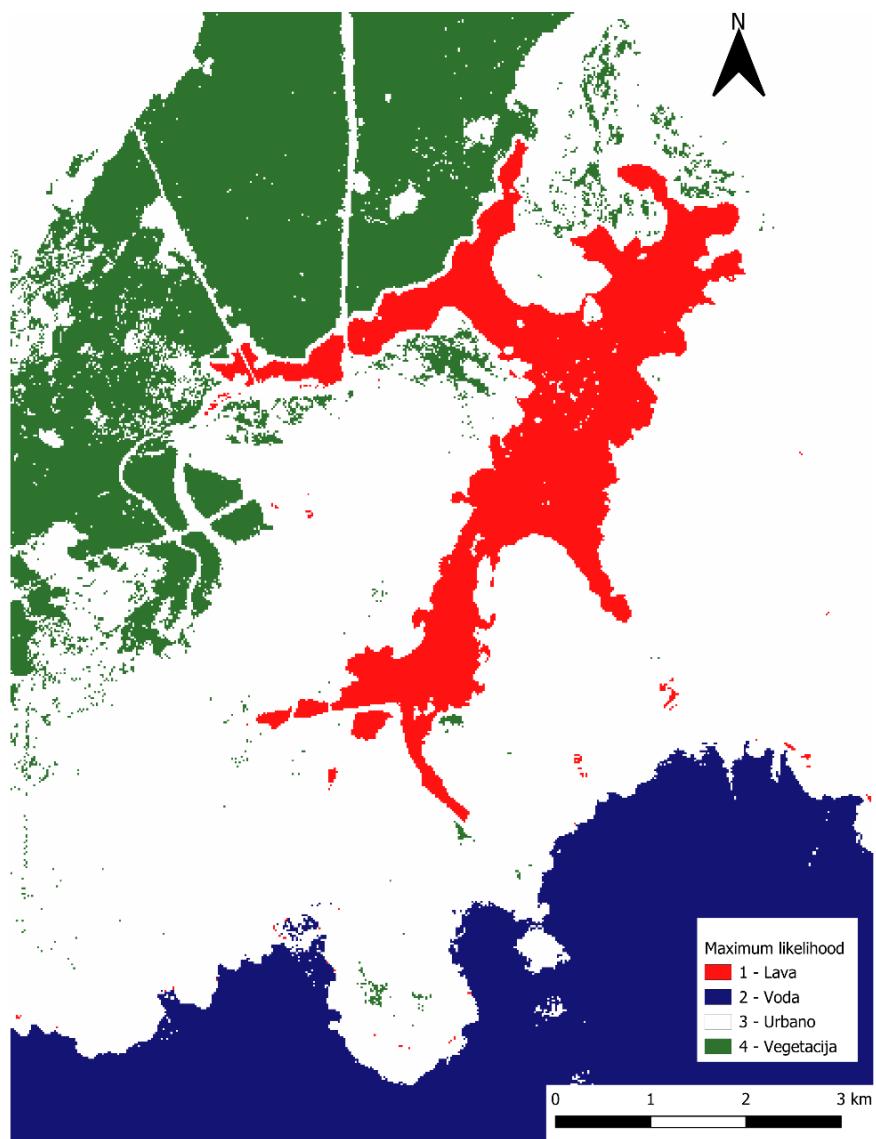
Slika 4-5. Svi definirani treninzi s njihovim ukupnim brojem klasa

Na ovim podacima korištena su tri algoritma za klasifikaciju: *maksimalna vjerojatnost*, *minimalna udaljenost*, *spektralno kutno kartiranje*.

5. REZULTATI

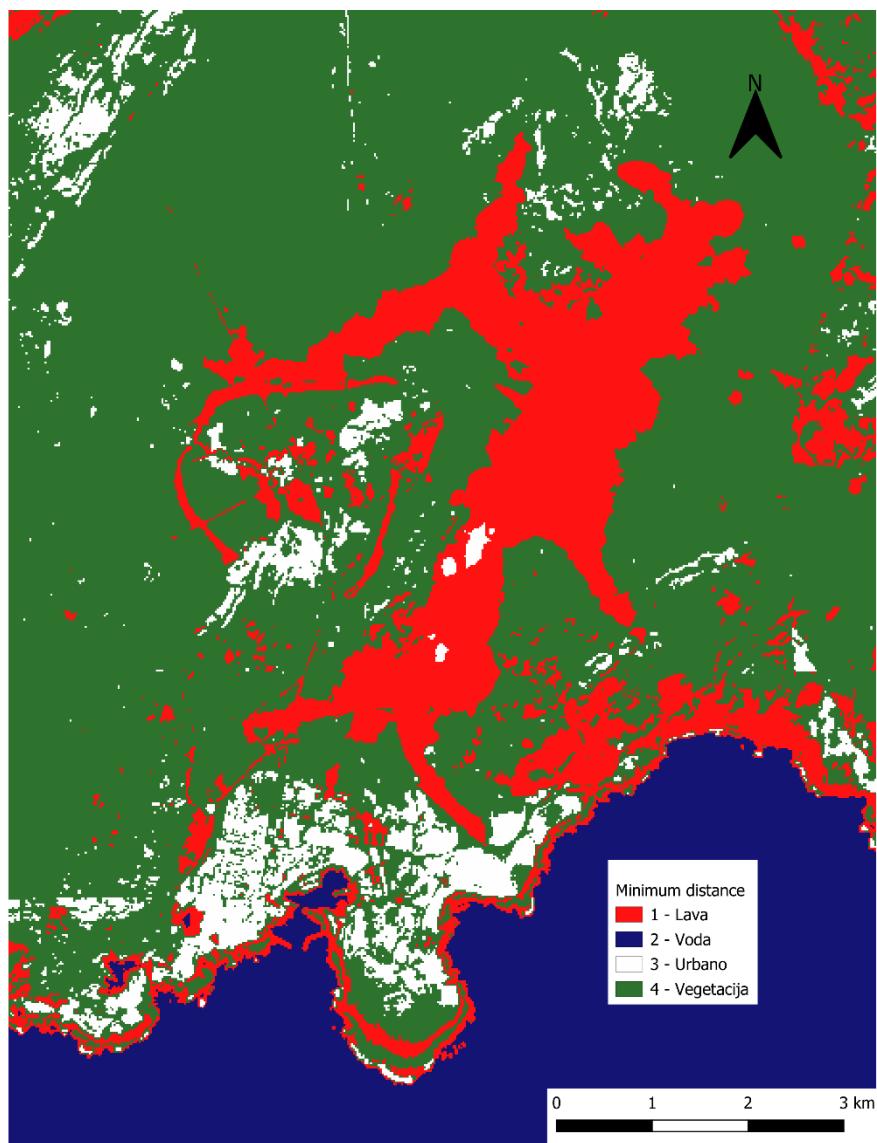
Svi treninzi prvo su obradili snimke poslije erupcije lave, a zatim je napravljen poseban trening za situaciju prije.

Prvi algoritam koji se koristio je *maksimalna vjerojatnost*. Lava koja je prikazana crvenom bojom dobro je klasificirana i odgovara stvarnoj situaciji i stvarnim dimenzijama, također algoritam nije imao problema s klasificiranjem vode i plavom bojom je dobro označio rub na kontaktu između obale i mora. Urbani dio, prikazan bijelom bojom, je prenaglašen i dio površine je krivo klasificiran. Cijeli južni i istočni dio područja označen je kao urbana površina, a sam grad Grindavík ne može se prepoznati na karti. Prometnice koje se nalaze između vegetacije i lave na sjeveru su dobro određene i lako prepoznatljive. Zelenom bojom je označena vegetacija i dio koji je algoritam klasificirao je točno predstavljen, ali veliki dio vegetacije na jugu i istoku nedostaje (Slika 5-1.).

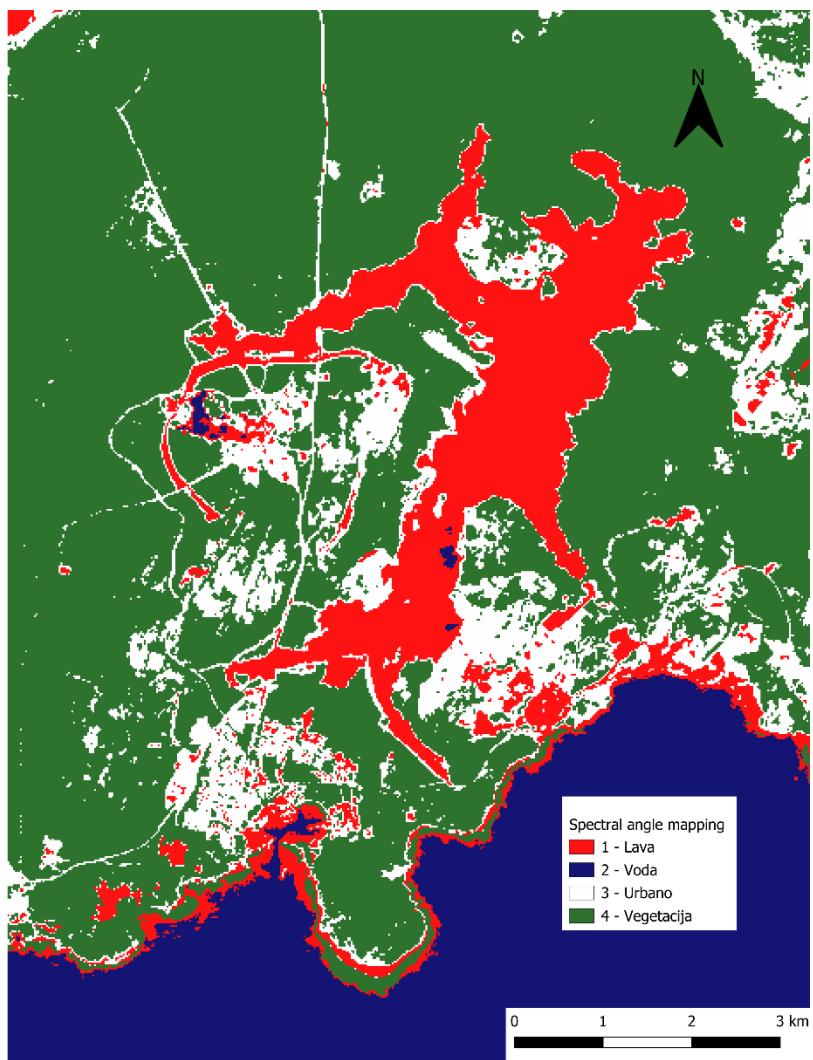


Slika 5-1. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma *maksimalne vjerojatnosti*

Minimalna udaljenost algoritam je crvenom bojom dobro klasificirao oblik lave na samom vulkanu, ali je također uz rub kopna i mora krivo označio veliko područje kao lavu, ujedno i obližnje vrhove planina je prikazao crveno, stoga jedan dio klasifikacije odgovara stvarnoj situaciji sa snimke satelita, dok se drugi vidno razlikuje. Voda je klasificirana dobro s plavom bojom, a grad Grindavik se može jasno vidjeti kao urbano područje bijele boje. U ovom primjeru prometnice nisu dobro vidljive i ne mogu se raspoznati na karti, a u samom centru erupcije nalazi se mali dio krivo klasificiranog urbanog područja. Vegetacija, naznačena zelenom, je bolje prikazana nego na algoritmu *maksimalne udaljenosti* i predstavlja stvarnu situaciju koja je vidljiva na samim sentinelovim snimkama (Slika 5-2.)



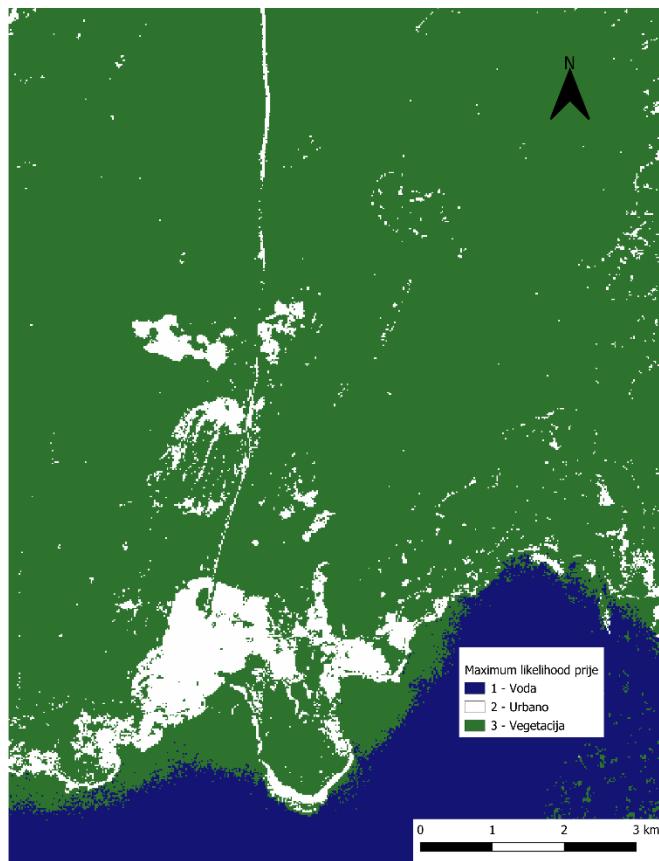
Slika 5-2. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma *minimalne udaljenosti*. Spektralno kutno kartiranje je ispravno označilo crvenom bojom lavu, sam oblik i dimenzije najbolje odgovaraju snimkama prije, iako je ponovno uz rub kopna krivo klasificiralo lavu na mjestu gdje se ne nalazi. Voda je točno klasificirana na jugu, ali mali dio plave boje nalazi se u samom centru vulkana gdje je najizraženija erupcija. U ovom algoritmu urbani dio grada je dobro naznačen, zajedno sa prometnicama koje se jasno vide. Zelena boja vegetacije prikazuje stvarnu sliku u prirodu i prekriva većinu promatranog područja (Slika 5-3.)



Slika 5-3. Rezultati prvog treninga na podacima poslije erupcije korištenjem algoritma spektralnog kutnog kartiranja

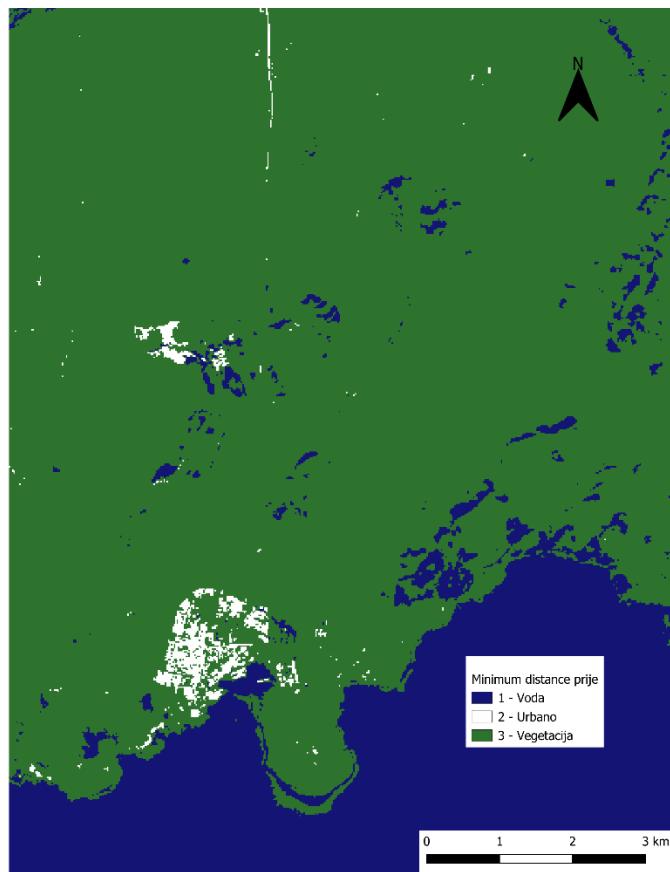
Za situaciju prije erupcije niti jedan od prva tri treninga nisu bili pogodni i rezultati klasifikacije bili su neupotrebljivi jer bi algoritmi klasificirali istu klasu za cijelo područje. Stoga je napravljen poseban trening na podacima prije erupcije s tri klase koje su bile: voda, urbano i vegetacija.

Maksimalna vjerojatnost je krivo klasificirao područje oko ruba mora i kopna, prenaglašena je vegetacija zelene boje i čini se kao da je rub kopna dalje nego što je u stvarnosti. Urbani dio grada Grindavik je dobro označen, kao i prometnice, ali su obližnji vrhovi planina netočno klasificirani u urbanu klasu. Voda je dobro određena i nalazi se samo na pripadnom južnom dijelu karte (Slika 5-4.).



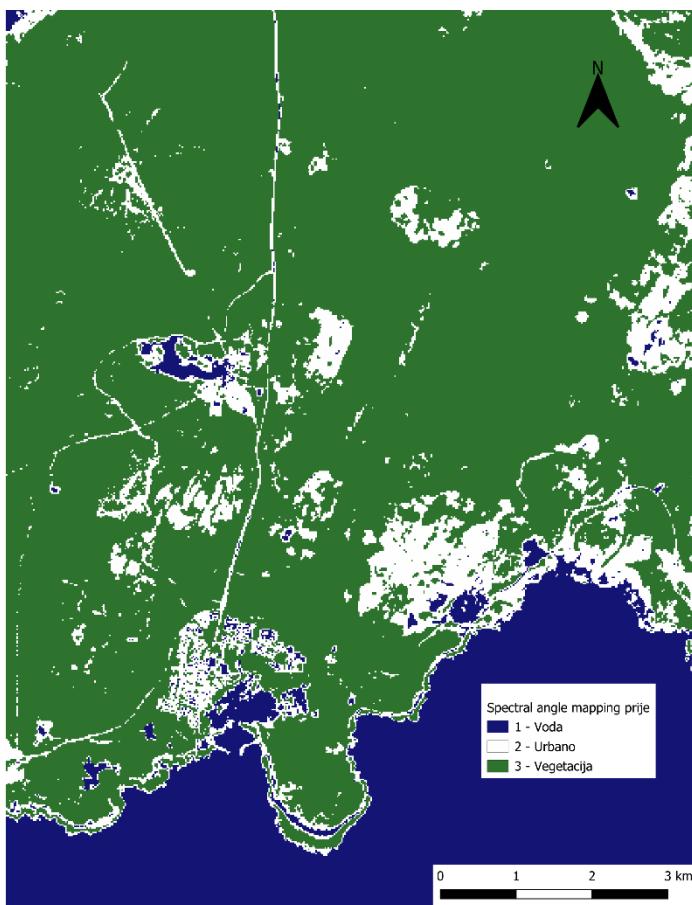
Slika 5-4. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma *maksimalne vjerojatnosti*

Minimalna udaljenost algoritam je urbano područje grada klasificirao kao i na snimkama sentinel-a i podudara se s njegovom lokacijom, ali prometnice su netočne i većina ih se ne vidi i raspoznaje na karti. Voda koja je označena plavom bojom je dobro određena na granici s kopnjom, ali u središtu karte i na istoku netočno je klasificirana. Vrhovi planina stavljeni su u klasu vode i bez upoznavanja sa stvarnom situacijom i sentinelovih snimaka, na temelju same karte moglo bi se protumačiti da se tamo nalaze jezera ili neka druga vrsta kopnene vode, što je u potpunosti u netočno (Slika 5-5.).



Slika 5-5. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma *minimalne udaljenosti*

Spektralno kutno kartiranje je algoritam koji je najbolje objedinio podatke za ovu situaciju i ima najviše podudaranja sa snimkama prije erupcije, iako posjeduje neke greške. Urbana klasa je dobro definirana u području grada i prometnica međutim na istočnom dijelu je krivo naznačena bijelom bojom. Klasa vode je dobro odredila granicu između kopna i mora, ali se u središtu karte nalazi dio plave površine koji je krivo interpretiran. Vegetacija prikazuje stvarnu sliku i zauzima najveću površinu (Slika 5-6.)



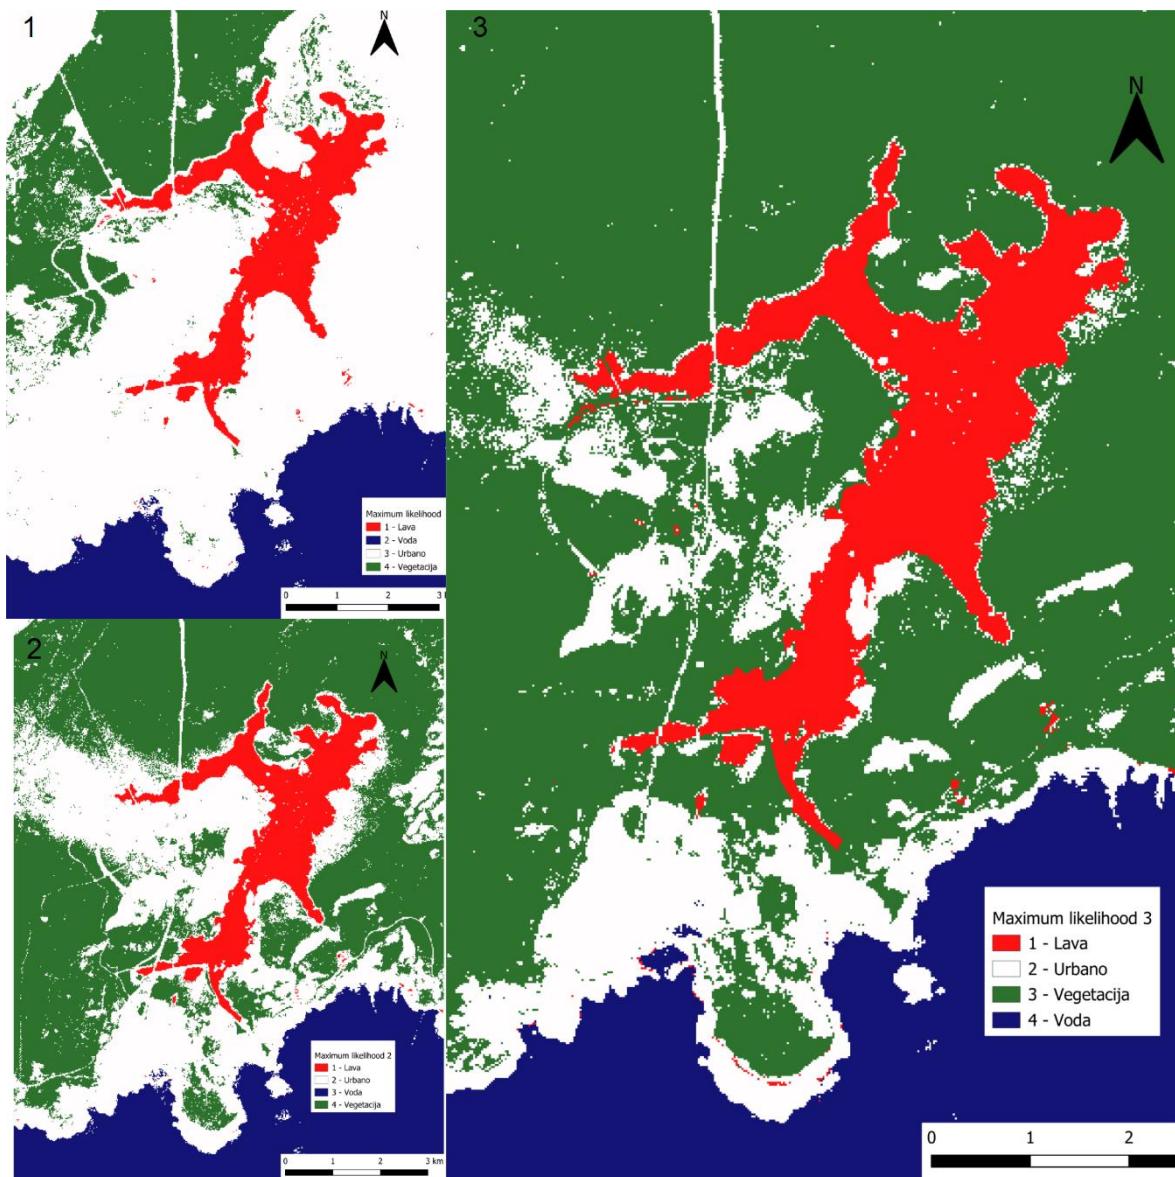
Slika 5-6. Rezultati četvrtog treninga na podacima prije erupcije korištenjem algoritma spektralnog kutnog kartiranja

5.1. Utjecaj kvalitete treninga

Osim odabranih klasa, utjecaj na rezultat klasifikacije može biti i kvaliteta i detaljnost treninga. U promatranju primjera poslije erupcije svaki slijedeći trening bio je detaljniji od prošlog i na svima su testirana sva tri algoritma.

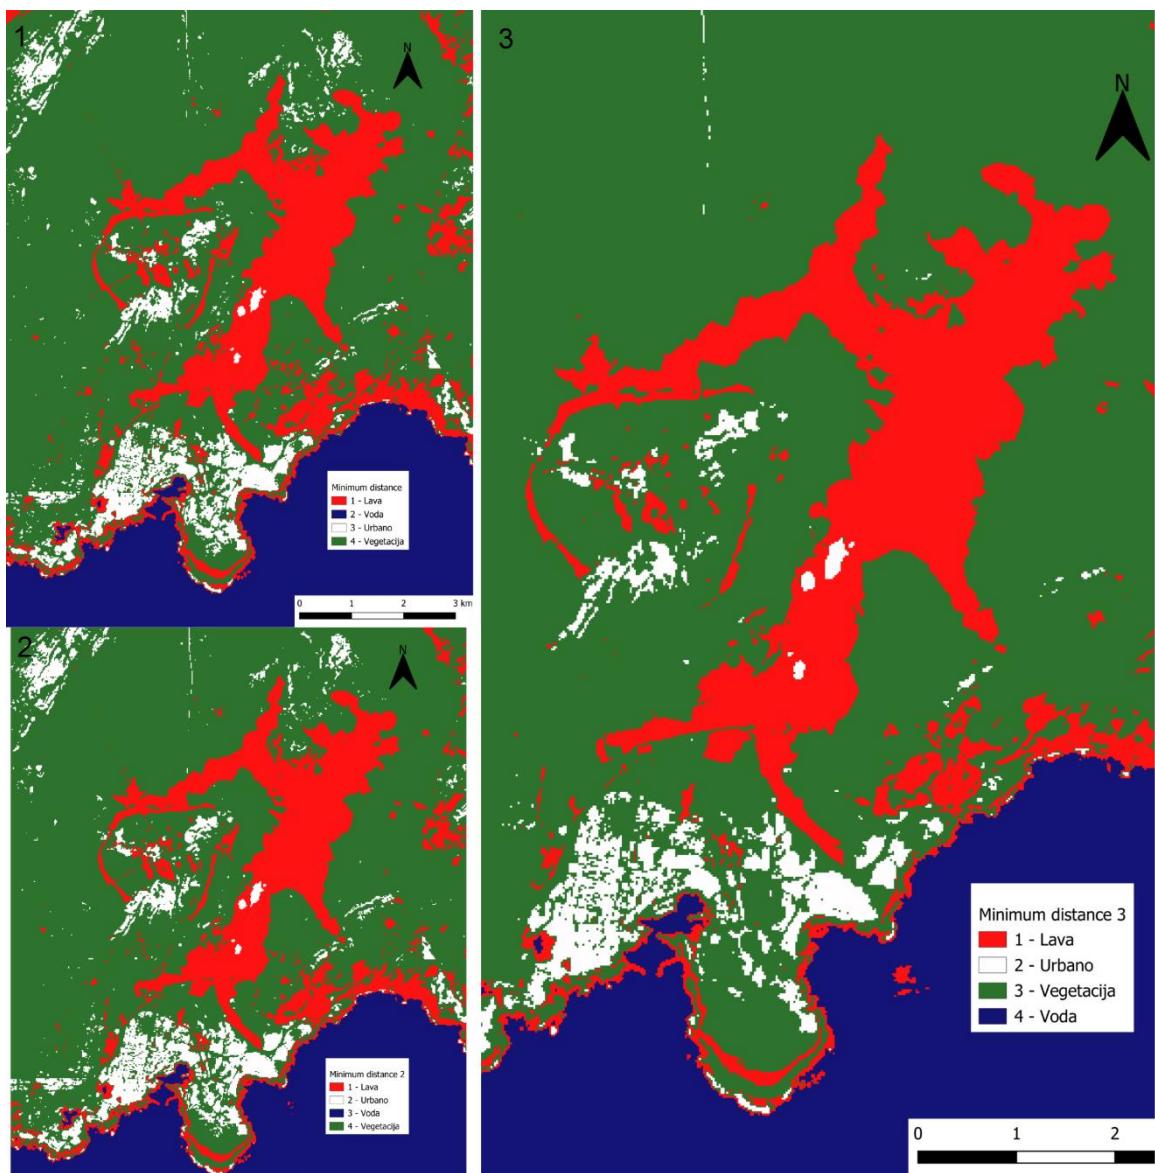
Prvi trening imao je definiranih sveukupno osam segmenata, njih najviše pet za lavu i po jedan za vodu, vegetaciju i urbano područje. Drugi trening je imao također pet segmenata definiranih za lavu, četiri za vegetaciju, dva za urbano i jedan za vodu. Treći trening je imao sveukupno 14 od čega pet za lavu, šest za vegetaciju i dva za urbano. Iz dobivenih karti klasifikacije primjećuje se da detaljniji trening značajno poboljšava rezultate algoritama.

Rezultati prvog treninga za *maksimalnu vjerojatnost*, označen brojem jedan (Slika 5-7.), su loše klasificirali urbano područje i vegetaciju. U drugom detaljnijem treningu, označen brojem dva, se urbana zona smanjila, a vegetacija povećala. U trećem treningu, označen brojem tri, se mogu vidjeti jasnije definirane granice grada, ali i dalje postoji višak oko obližnjih planinskih vrhova.



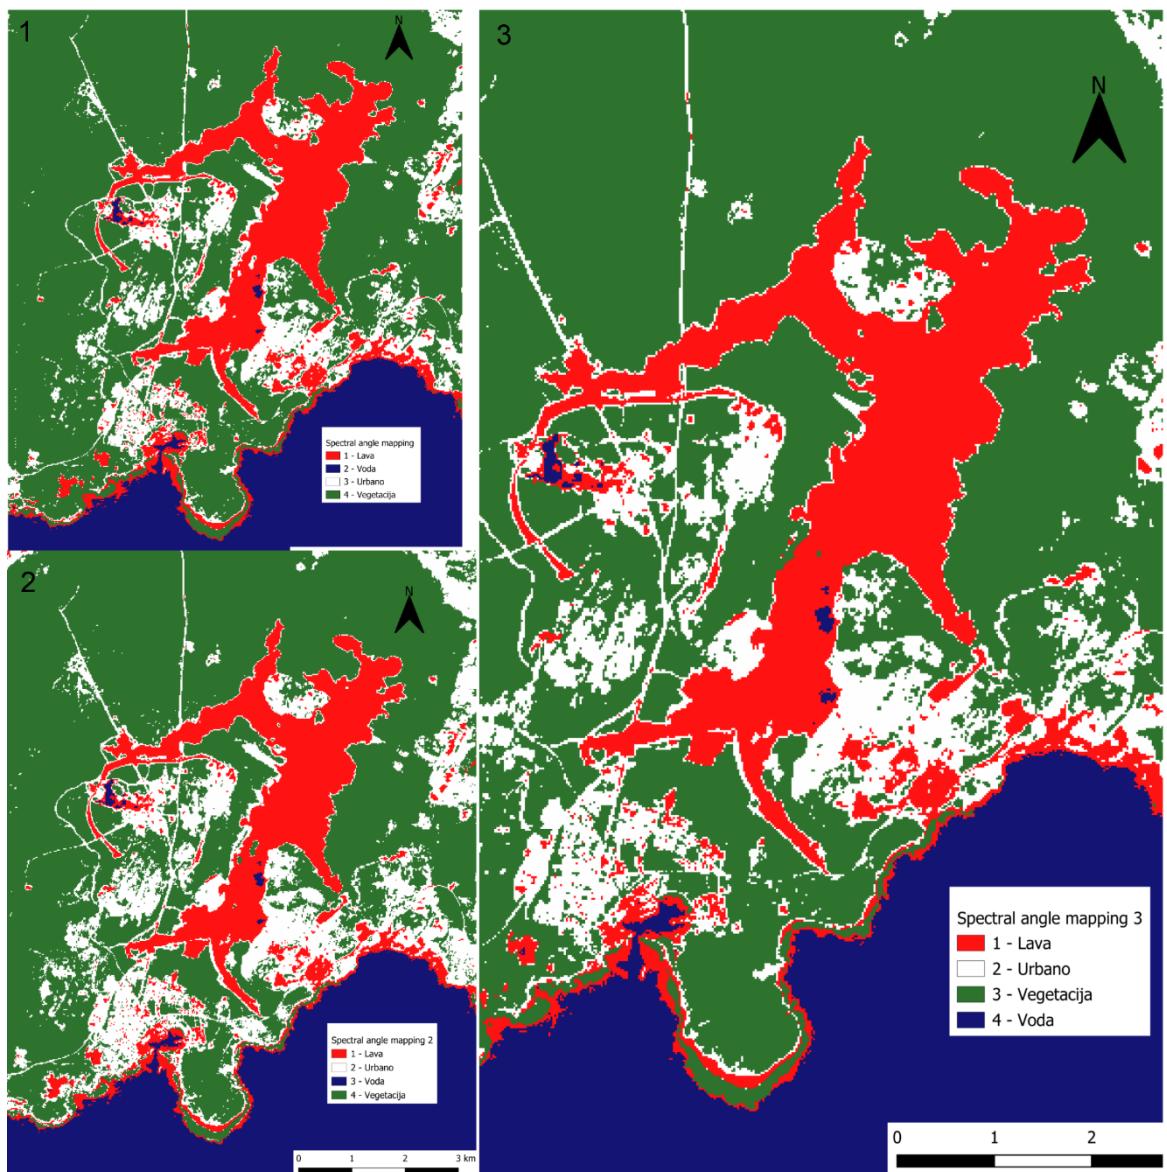
Slika 5-7. Prikaz utjecaja kvalitete treninga korištenjem algoritma *maksimalne vjerojatnosti*

Minimalna udaljenost je u prvom treningu, koji je označen brojem jedan, ispravno definirao grad, ali je nije klasificirao prometnice i krivo je označio granicu kopna i mora. S detaljnijim treninzima, koji su označeni brojevima dva i tri, algoritam je na mjestu erupcije uklonio mali višak lave, ali nije odstranio urbano područje u sredini vulkana. Uklonjeni su mali mjestimični dijelovi krivo detektirane urbane klase, ali se prometnice i kontakt mora i kopna nije popravio (Slika 5-8.).



Slika 5-8. Prikaz utjecaja kvalitete treninga korištenjem algoritma *minimalne udaljenosti*

Spektralno kutno kartiranje je imao najbolji omjer točno klasificirane lave, urbanog područja i vegetacije, ali i dalje s ponekim krivim dijelovima, kao što je prikazano brojem jedan. Detaljnijim treningom uklonili su se viškovi urbanog područja kojih ima najviše, brojevi dva i tri. Preostao je dio koji je u lavi klasificiran kao voda (Slika 5-7.).



Slika 5-9. Prikaz utjecaja kvalitete treninga korištenjem algoritma spektralnog kutnog kartiranja

6. ZAKLJUČAK

Cilj ovog rada bio je klasifikacija eruptirane lave na Islandu i proučiti koji od dostupnih algoritama je najpogodniji za prikazivanje određenih klasa. Za dobivanje satelitskih snimaka koristila se misija Sentinel-2, a podaci su preuzeti za dvije situacije. Prvi set podataka preuzet je za datum 11.09.2023. i on predstavlja situaciju prije erupcije vulkana, a drugi je preuzet za 13.04.2024. i prikazuje područje promatranja poslije erupcije vulkana.

Za dobivanje klasifikacije korišten je QGIS softver s posebnim pluginom za nadziranu klasifikaciju (SCP). Snimke su učitane i obrađene prema potrebi u pluginu, a zatim su se napravili treninzi prema kojima se radila klasifikacija. Tri treninga podataka napravljena su za situaciju poslije erupcije i svaki od njih imao je detaljnije određene klase, jedan trening odraćen je za situaciju prije erupcije. Dostupni algoritmi za klasifikaciju su bili : *maksimalna vjerojatnost, minimalna udaljenost, spektralno kutno kartiranje*.

Maksimalna vjerojatnost algoritam je dobro klasificirao prometnice, vodu i lavu, ali nije radio veliku razliku između vegetacije i urbanog područja. U ovom algoritmu se vidi velika razlika između detaljnosti treninga podataka i rezultata. Prvi najmanje detaljan trening je pogrešno klasificirao veliki dio urbanog područja, dok je s trećim urbana zona smanjena na prihvatljivo u odnosu na stvarnu situaciju.

Minimalna udaljenost algoritam je dobro odredio lavu na vulkanu, vodu, vegetaciju i dio oko samog grada Grindavik, ali prometnice i višak lave uz obalu je pogrešno klasificirao. U ovom primjeru kvaliteta treninga nije imala veliki značaj na rezultat klasifikacije, budući da niti jedna od krivo definiranih klasa nije zamjetno popravljena u skladu sa stvarnom situacijom.

Algoritam za *spektralno kutno kartiranje* je klasificirao točno lavu, vodu i vegetaciju, a u urbanoj klasi je dobro definirao prometnice i grad, ali je ostao primjetan dio urbane klase blizu vulkana koji je netočan. Detaljnost treninga podataka je u ovom algoritmu neznatno promijenila klasu i nisu se značajno popravili rezultati kako bi se više podudarali sa snimkama sentinel-a, ali je karta izgleda uređenije.

Trening na podacima prije erupcije potvrdio je koji algoritmi određuju klase bolje ili koji segmenti klasa se više ističu koristeći odgovarajući algoritam.

Ovisno o potrebama klasifikacije na promatranom području može se koristiti drugačiji algoritam. Ukoliko je tražena detaljnija klasifikacija grada bez obzira na prometnice koristan je algoritam *minimalna udaljenost*, ukoliko je potreba za poznavanjem prometnica važnija predlaže se *spektralno kutno kartiranje*. Ako je isključivo važna lokacija lave bez potrebnih

točnih informacija o urbanoj klasi koristio bi se algoritam *maksimalna vjerojatnost* s detaljnijim treningom.

7. LITERATURA

- Andrew, R., Gudmundsson, A., 2006., Holocene shield volcanoes in Iceland
- Hafedh Hamza, M., Al- Thubaiti, A., Dhibe, M., 2016. Dasymetric Mapping as a Tool to Assess the Spatial Distribution of Population in Jeddah City
- Núñez, J. M., Fernández, S., Ávila, G., Montejano, J., 2019., High-Resolution Satellite Imagery Classification for Urban Form Detection
- Razaque, A., Almi'ani, M., Haj Frej, M., Alotaibi, M., 2021., Improved Support Vector Machine Enabled Radial Basis Function and Linear Variants for Remote Sensing Image Classification
- BBC, (2024.), Iceland volcano, URL: <https://www.bbc.com/news/world-europe-67756413> , (3.5.2024.)
- Byjus, (2024.), Remote sensing, URL: <https://byjus.com/physics/remote-sensing/>, (2.5.2024.)
- Copernicus.eu, (2024), About Copernicus URL:<https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2> (3.5.2024)
- Csr.utexas, (2024), Spectral Angle Mapper Classification URL:<https://www.csr.utexas.edu/projects/rs/hrs/analysis.html> , (6.6.2024)
- Geologictimepics, (2024.), Iceland mid Atlantic rift, URL: <https://geologictimepics.com/2018/09/30/iceland-where-you-can-walk-a-mid-atlantic-rift-and-some-other-geology-photos/> (6.6.2024.)
- Gisgeography (2024), Sentinel-2, URL:<https://gisgeography.com/sentinel-2-bands-combinations/> , (3.5.2024)
- ESA, (2023.), European Space Agency, URL: <https://www.esa.int/> , (5.5.2024)
- Edmundoptics., (2024.), Hyperspectral and Multispectral Imaging. URL: <https://www.edmundoptics.com/knowledge-center/application-notes/imaging/hyperspectral-and-multispectral-imaging/>, (6.5.2024.)
- Freeworldmaps, (2021.), Iceland physical map, URL:<https://www.freeworldmaps.net/europe/iceland/map.html> (5.5.2024)
- Fromgistors, (2024), Semi-Automatic Classification Plugin for QGIS, URL:<https://fromgistors.blogspot.com/> (6.5.2024)
- Icelandic Institute of Natural History, (2024), Geology , URL: <https://www.ni.is/en/geology>, (16.5.2024)

Nat.is, (2024), Geography-and-nature, URL:<https://nat.is/category/about-iceland/geography-and-nature/geology/>, (30.5.2024)

Nv5geospatialsoftware,(2024),MaximumLikelihood
URL:<https://www.nv5geospatialsoftware.com/docs/MaximumLikelihood.html> (5.6.2024.)

QGIS, (2024), The Leading Open Source Desktop GIS,
URL:<https://www.qgis.org/en/site/about/index.html> ,(10.5.2024.)

Phys, (2024.), Iceland lava, URL: <https://phys.org/news/2024-01-iceland-daunting-period-lava-volcano.html>, (30.5.2024.)

Scientificamerican, (2024.), Volcanic Eruptions in Iceland, URL:
<https://www.scientificamerican.com/article/at-volcanic-eruptions-in-iceland-and-beyond-efforts-to-control-lava-remain-challenging/>, (10.5.2024.)

Shutterstock, (2024.) , Fissure Vents, URL: https://www.shutterstock.com/search/fissure-vents?image_type=vector (10.5.2024.)

Spatialpost, (2024), Supervised-vs-unsupervised classification
URL:<https://www.spatialpost.com/supervised-vs-unsupervised-remote-sensing/>, (7.6.2024.)

Superannotate, (2023.), What is image classification, URL:
<https://www.superannotate.com/blog/image-classification-basics>, (19.5.2024.)

The Intependent, (2023.), Iceland earthquake, URL:
<https://www.independent.co.uk/news/world/europe/grindavik-iceland-volcano-eruption-evacuations-b2446155.html> (7.6.2024.)

USGS, (2024), Remote Sensing, URL: <https://www.usgs.gov/> , (19.5.2024.)

Volcano.si.edu, (2024), Iceland Volcanoes
URL:https://volcano.si.edu/volcanolist_countries.cfm?country=Iceland (10.6.2024.)