

Univerza
v Ljubljani

Fakulteta
*za gradbeništvo
in geodezijo*



DIPLOMSKA NALOGA

UNIVERZITETNI ŠTUDIJSKI PROGRAM PRVE STOPNJE GEODEZIJA IN GEOINFORMATIKA

Ljubljana, 2019

Univerza
v Ljubljani

*Fakulteta za
gradbeništvo in
geodezijo*



Kandidat/-ka:

Mentor/-ica:

Predsednik komisije:

Somentor/-ica:

Član komisije:

STRAN ZA POPRAVKE, ERRATA

Stran z napako	Vrstica z napako	Namesto	Naj bo
-----------------------	-------------------------	----------------	---------------

»Ta stran je namenoma prazna.«

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:	004.042:528.837(497.4)(043.2)
Avtor:	Primož Skledar
Mentor:	prof. dr. Krištof Oštir
Somentor:	doc. dr. Dejan Grigillo
Naslov:	Analiza uporabnosti odprtokodnega programa Sentinel Application Platform za obdelavo satelitskih posnetkov
Tip dokumenta:	diplomska naloga – univerzitetni študij
Obseg in oprema:	42 str., 14 pregl., 35 sl., 2 en., 2 graf., 6 pril.
Ključne besede:	SNAP, obdelava satelitskih posnetkov, klasifikacija, piksel

Izvleček

V diplomski nalogi je obravnavana analiza uporabnosti odprtokodnega programa Sentinel Application Platform za obdelavo satelitskih posnetkov. Opredeljena je teoretična osnova metod obdelave satelitskih posnetkov, s poudarkom na nadzorovani klasifikaciji. Opisana so glavna orodja, ki so pogosto uporabljena v raznih obdelavah v programu. V postopku klasifikacije se uporabljajo določena orodja, ki so podrobneje opredeljena v diplomski nalogi. Vsa ta orodja so bila uporabljena na testnem primeru, na katerem so bile izvedene vse vrste metod klasifikacije, ki jih omogoča program SNAP. Izračunane so tudi natančnosti metod klasifikacije in analiza uspešnosti metod klasificiranega primera. Prav tako je bila opravljena primerjava odprtokodnega programa SNAP s podobnimi drugimi programi, ki omogočajo obdelavo satelitskih posnetkov.

»Ta stran je namenoma prazna.«

BIBLIOGRAFIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC:	004.042:528.837(497.4)(043.2)
Author:	Primož Skledar
Supervisor:	Prof. Krištof Oštir, Ph. D.
Co-advisor:	Assist. Prof. Dejan Grigillo, Ph. D.
Title:	An usefulness evaluation of the open source program Sentinel Application Platform for analyzing satellite imagery
Document type:	Graduation Thesis – University studies
Scope and tools:	42 p., 14 tab., 35 fig., 2 eq., 2 graph., 6 ann.
Keywords:	SNAP, analysing satellite imagery, classification, pixel

Abstract

The topic of this thesis is an analysis of the usefulness of the open-source Sentinel Application Platform program for satellite imagery processing. The theoretical basis of satellite imagery processing methods is defined. The emphasis is placed on the supervised classification. All the main tools in the program, which are widely used in various processes, are described. Tools that were used in the classification process are analysed and described in detail. These tools were used on a test example where all types of classification methods are performed by the program. The accuracy of the classification methods is determined and the analysis of the method's performance of the classified example is also made. SNAP was compared to other programs that allow satellite imagery processing.

»Ta stran je namenoma prazna.«

ZAHVALA

Iskreno se zahvaljujem za podporo in strokovno pomoč mentorju prof. dr. Krištofu Oštirju in somentorju doc. dr. Dejanu Grigillu.

Moja zahvala gre tudi družini in prijateljem za podporo v letih mojega študija kakor tudi za podporo in spodbudo pri pisanju diplomske naloge.

»Ta stran je namenoma prazna.«

KAZALO VSEBINE

STRAN ZA POPRAVKE, ERRATA	I
BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK	III
BIBLIOGRAFIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT	V
ZAHVALA	VII

1 UVOD	1
1.1 NAMEN IN CILJI	2
2 KLASIFIKACIJA PODOB	3
2.1 NENADZOROVANA KLASIFIKACIJA	4
2.2 NADZOROVANA KLASIFIKACIJA	5
2.2.1 Metoda največje verjetnosti	5
2.2.2 Metoda najmanjše razdalje	6
2.2.3 Metoda spektralnih kotov	6
2.2.4 Metoda naključni gozdovi	7
2.2.5 Metoda k – najbližjega sosedu (KNN)	7
2.3 VREDNOTENJE REZULTATOV KLASIFIKACIJE	8
3 PROGRAM SNAP	9
3.1 MISIJE SENTINEL	9
3.2 SPLOŠNO O PROGRAMU SNAP	9
3.3 FORMAT PODATKOV	10
3.4 STRUKTURA MAPE	10
3.4.1 Metapodatki	11
3.4.2 Vektorski podatki	11
3.4.3 Kanali	11
3.4.4 Maske	12
3.5 GLAVNA ORODJA ZA NAVIGACIJO IN DELO V PROGRAMU TER NJIHOVE KOMPONENTE	12
3.5.1 Orodja delovnega okna	12
3.5.2 Osnovna orodna vrstica	13
3.6 ORODJA V POSTOPKU KLASIFIKACIJE	20
3.6.1 Uvoz in obrezovanje posnetka	20
3.6.2 Izdelava učnih vzorcev	22
3.6.3 Izvedba klasifikacije	23
3.6.4 Ocena kakovosti	26
3.6.5 Izvoz datotek in rezultatov	26
3.7 DINAMIKA RAZVOJA PROGRAMA SNAP	27
3.8 FORUM STEP	27

»Ta stran je namenoma prazna.«

4	PRIMER KLASIFICIJE SATELITSKEGA POSNETKA SENTINEL-2	28
4.1	PODATKI IN OBMOČJE	28
4.2	METODOLOGIJA	29
4.3	REZULTATI IN ANALIZA	29
5	PRIMERJAVA SNAP Z DRUGIMI PROGRAMI.....	35
5.1	DEFINIRANJE MERIL IN IZBIRA PROGRAMOV	35
5.2	ANALIZA PRIMERJAVE PROGRAMOV	35
6	ZAKLJUČEK.....	39
	VIRI.....	40
	PRILOGE	42

»Ta stran je namenoma prazna.«

KAZALO SLIK

Slika 2-1: Numerična (levo) in klasificirana (desno) podoba (Campbell in Wynne, 2011: 335).....	3
Slika 2-2: Metoda največje verjetnosti (Oštir, 2006: 181)	6
Slika 2-3: Metoda najmanjše razdalje (Oštir, 2006: 181)	6
Slika 2-4: Spektralni kot.....	7
Slika 2-5: Metoda k - najbližjega sosedu (Campbell in Wynne, 2011: 363).....	7
Slika 3-1: Razširjena mapa v programu SNAP	10
Slika 3-2: Podmapa Metadata	11
Slika 3-3: Podmapa Vector Data	11
Slika 3-4: Podmapa Bands	12
Slika 3-5: Podmapa Masks	12
Slika 3-6: Orodja v delovnem oknu	12
Slika 3-7: Orodje Colour Manipulation	13
Slika 3-8: Osnovna orodna vrstica	14
Slika 3-9: Orodje File, orodja Import (levo), orodja Export (desno)	14
Slika 3-10: Orodje Scatter Plot.....	15
Slika 3-11: Primer histograma - spektralni kanal NIR z masko	16
Slika 3-12: Orodje Statistics - kanal NIR.....	16
Slika 3-13: Orodje Statistics - kanal NIR z maskami.....	17
Slika 3-14: Orodje Raster in orodja Geometric Operations	17
Slika 3-15: Orodje Raster, orodja Classification.....	18
Slika 3-16: Orodje Optical	18
Slika 3-17: Orodje Spectrum View	18
Slika 3-18: Orodje Window	19
Slika 3-19: Orodje Open RGB Image Window.....	19
Slika 3-20: Orodje Help	20
Slika 3-21: Resampling: orodje – I/O Parameters.....	21
Slika 3-22: Resampling: orodje - Resampling parameters.....	21
Slika 3-23: Orodje Subset	22
Slika 3-24: Orodja za risanje vektorjev.....	22
Slika 3-25: Primer izrisanih vzorcev	23
Slika 3-26: Orodje klasifikacije – primer metode naključni gozdovi.....	24
Slika 3-27: Orodje klasifikacije SAM.....	25
Slika 3-28: Določanje barv pri klasifikaciji SAM.....	25
Slika 3-29: Okno Pin Manager in vnesen testni primer za prikaz.....	26
Slika 4-1: Posnetek območja Dravskega polja	28

»Ta stran je namenoma prazna.«

KAZALO GRAFOV

Graf 1: Primerjava natančnosti klasifikacije Kappa.....	33
Graf 2: Primerjava skupne natančnosti	33

»Ta stran je namenoma prazna.«

KAZALO PREGLEDNIC

Preglednica 1: Objavljene in odpravljene napake po letih	27
Preglednica 2: Spektralni kanali Sentinel-2A	28
Preglednica 3: Primer matrike napak	30
Preglednica 4: Natančnosti metode naključni gozdovi	31
Preglednica 5: Natančnosti metode največje verjetnosti	31
Preglednica 6: Natančnosti metode najmanjše razdalje	31
Preglednica 7: Natančnosti metode KDTree K - najbližji sosed.....	31
Preglednica 8: Natančnosti metode K - najbližji sosed.....	32
Preglednica 9: Natančnosti metode spektralnih kotov	32
Preglednica 10: Dostopnost programov	35
Preglednica 11: Vrste klasifikacij v programih.....	36
Preglednica 12: Generiranje posnetka RGB in legende	37
Preglednica 13: Funkcije za oceno natančnosti.....	37
Preglednica 14: Pomoč, ki jo nudijo programi.....	38

»Ta stran je namenoma prazna.«

OKRAJŠAVE IN SIMBOLI

SNAP	<i>Sentinel Application Platform</i> (Platforma Sentinelovih aplikacij)
ESA	<i>European Space Agency</i> (Evropska vesoljska agencija)
STEP	<i>Science Toolbox Exploitation Platform</i> (Platforma za raziskavo znanstvenih orodij)
GIS	<i>Geographical informational system</i> (Geografski informacijski sistem)
ESRI	<i>Environmental System Research Institute</i> (Inštitut za okoljske sisteme)
EC	<i>European Comission</i> (Evropska komisija)
MSI	<i>Multispectral imager</i> (Multispektralni snemalnik)
RGB	<i>Red, Green, Brue</i> (rdeča, zelena, modra)
GPF	<i>Graph Processing Framework</i> (grafični modelirnik)
RF	<i>Random Forest</i> (Naključni gozd)
MLC	<i>Maximum Likelihood Classifier</i> (Klasifikacija največje verjetnosti)
MDC	<i>Minimum Distance Classifier</i> (Klasifikacija minimalne razdalje)
KNN	<i>K-nearest neighbour</i> (K-najbližji sosed)
SAM	<i>Spectral Angle Mapper</i> (Metoda spektralnih kotov)
FOSS	<i>Free Open Source System</i> (Brezplačen odprtokodni sistem)
NIR	<i>Near-infrared</i> (bližnje infrardeče)

»Ta stran je namenoma prazna.«

1 UVOD

Satelitski posnetki delno ali v celoti prikazujejo Zemljo, druge planete in nebesna telesa. Uporabljajo se za mnoge namene: v kmetijstvu, gozdarstvu, geologiji, izobraževanju, vojski, meteorologiji itd. Njihova obdelava in interpretacija poteka s specializirano programsko opremo za daljinsko zaznavanje.

Posebej za namen obdelave satelitskih posnetkov je bil razvit program Sentinel Application Platform (SNAP), ki ga je financirala Evropska vesoljska agencija (ESA). SNAP je zbirka aplikacijskih programskih vmesnikov, ki so bili razviti za lažjo uporabo, pregledovanje in obdelavo različnih daljinsko zaznanih podatkov. Sentinel Toolbox so različne skupine orodij, ki so združene v programu SNAP. Namen teh orodij je dopolniti program s funkcijami, namenjenimi ravnanju s podatki, ki jih pridobimo iz satelitov za opazovanje Zemlje (Science toolbox exploitation platform, 2019).

SNAP se uporablja za celostno obdelavo satelitskih posnetkov, torej tudi za klasifikacijo, kar je cilj te naloge. Klasifikacija je postopek razvrščanja pikselov v razrede. Ker ima posnetek satelita Sentinel-2 13 spektralnih kanalov, rezultati klasifikacije temeljijo na 13 spektralnih vrednosti v pikslu, ki se medsebojno povezujejo. Rezultat klasifikacije je rastrska slika, ki se uporablja za analize na veliko področjih izven daljinskega zaznavanja in za izdelavo različnih statistik.

Diplomska naloga je sestavljena iz štirih delov. V prvem delu so opisane teoretične osnove obdelave satelitskih posnetkov. Poudarek je na klasifikaciji podob, tako nenadzorovani kot nadzorovani. Nadzorovana klasifikacija je opredeljena podrobneje, saj je v nalogi večji poudarek na nadzorovani klasifikaciji. Vsaka metoda nadzorovane klasifikacije, ki je vključena v SNAP, je teoretično opisana.

Drugi, glavni del naloge, opisuje SNAP. Podan je standardni format podatkov imenovan BEAM-DIMAP in zgradba podatkovne mape, ker ima edinstveno strukturo v primerjavi z drugimi zapisi. Podatkovna mapa vsebuje podatke o metapodatkih, vektorskih podatkih, posnetkih in maskah. Uporablja se za pridobivanje informacij, ki jih potrebujemo pri obdelavi satelitskih posnetkov. Predstavljena so glavna orodja v delovnem oknu in osnovni orodni vrstici programa. Ker je v tej nalogi poudarek na klasifikaciji, je opisan tudi celoten postopek in uporaba orodij in njihovih funkcij. Na kratko je opredeljen tudi razvoj programa SNAP, kakor tudi forum Science Toolbox Exploitation Platform (STEP), ki je namenjen javnim in odprtim razpravam.

Tretji del naloge opisuje praktično delo s primerom v programu SNAP. Uporabljen je satelitski posnetek Dravskega polja posnet avgusta 2018 s satelitom Sentinel-2. Testni primer je bil izveden na vseh razpoložljivih nadzorovanih klasifikacijah, ki jih program omogoča. Za zaključek testnega primera je bila opravljena tudi ocena natančnosti opravljenih klasifikacij z matriko napak, delno s programom Excel, ker program SNAP celotne ocene natančnosti ne omogoča.

Zadnji, četrti del naloge, je primerjava programa SNAP s programi ArcMap, QGIS in SAGA GIS. Definirala so se merila, po katerih je bila narejena primerjava med programi, v tabelah pa so podane funkcionalnosti programov, vključenih v analizo.

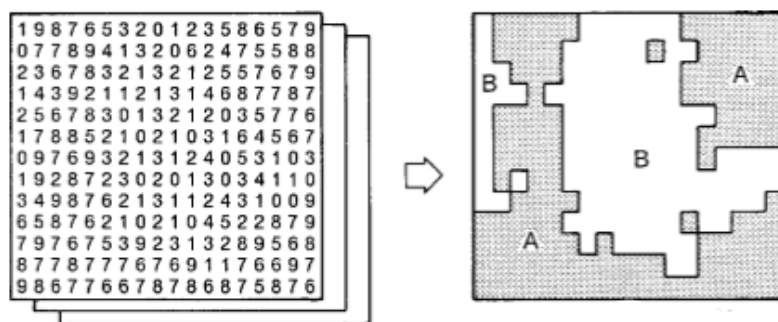
1.1 Namen in cilji

Namen diplomske naloge je pregled orodij, ki jih omogoča program SNAP in analizirati njegovo uporabnost, ga primerjati z drugimi podobnimi programi ter ugotoviti, ali bi ga lahko vključili v učno shemo študija geodezije. Na primeru sem skušal ugotoviti, kako je program dejansko uporaben za konkretni postopek nadzorovane klasifikacije.

SNAP omogoča uporabo več orodij, kot jih je omenjenih v diplomski nalogi. Ravno zato je bil eden od ciljev določiti glavna in najpogosteje uporabljena orodja v programu v postopku klasifikacije. Zastavljen cilj je dosežen z uspešno izvedenim primerom klasifikacije po vseh metodah, ki jih program omogoča, teoretično definicijo metod, primerjavo programa SNAP z drugimi podobnimi programi, analiza njegove uspešnosti, prednosti in pomanjkljivosti.

2 KLASIFIKACIJA PODOB

Klasifikacija podob je postopek razvrščanja pikslov¹ v razrede. Vsak piksel ima več vrednosti, odvisno od števila spektralnih kanalov, ki sestavljajo podobo. Piksele lahko na podlagi vrednosti ročno ali samodejno razvrstimo v razrede (Slika 2-1). Rezultat klasifikacije je običajno tematska karta. Razredi so homogeni, kar pomeni, da imajo piksli v enem razredu podobno spektralno vrednost (Campbell in Wynne, 2011).



Slika 2-1: Numerična (levo) in klasificirana (desno) podoba (Campbell in Wynne, 2011: 335)

Klasificirana podoba je definirana iz opazovanja numerične ali digitalne podobe in posledičnega grupiranja pikslov s podobnimi spektralnimi vrednostmi.

Klasifikacija je eden najpomembnejših postopkov pri obdelavi podob, pridobljenih z metodami daljinskega zaznavanja. Predstavlja povezavo med daljinskim zaznavanjem in geografskimi informacijskimi sistemi (GIS). Pridobljene posnetke podob iz vesolja ali zraka, ki so v rastrski obliki, obdelamo in pridobimo sloje, ki predstavljajo razrede. Te lahko uporabimo v sistemih GIS in izvedbo analiz (Oštir, 2006).

Rezultat klasifikacije je najpogosteje karta pokrovnosti. Vizualna interpretacija je najstarejša metoda klasifikacije satelitskih posnetkov, kjer operater interpretira podatke na podlagi satelitskih posnetkov in jih ročno digitalizira. Ta način klasifikacije je subjektiven, zamuden in se dandanes skoraj ne uporablja več (Lang, 2008). Z razvojem tehnologije je prevladala digitalna klasifikacija, ki razrede določi z upoštevanjem spektralnih informacij. Takšno klasifikacijo lahko imenujemo tudi spektralno prepoznavanje vzorcev (Oštir, 2006).

Postopek klasifikacije se vedno izvaja v določenih korakih, ki so (Oštir, 2006):

- pridobivanje podob (npr. satelitskih posnetkov),
- predobdelava podob,
- priprava testnih območij,
- razvrščanje pikslov v razrede,
- prepoznavanje razredov in
- vrednotenje rezultatov kot zaključek.

¹ Piksel ali *picture element* predstavlja enoto slike. Je točkovni element, ki teoretično nima oblike, ampak je običajno prikazan s kvadratom in vsebuje podatke o karakteristiki (barvi) slike.

Pri razdelitvi pikslov v razrede poznamo dve vrsti razredov: informacijske in spektralne. Informacijski razredi so tiste kategorije, ki so v interesu uporabnika podatkov. To so na primer različne vrste gozda, različne vrste rabe tal, ki zagotavljajo informacije za planerje, menedžerje, znanstvenike idr. Spektralni razredi so skupine pikslov, ki imajo podobno vrednost v posameznih kanalih (Campbell in Wynne, 2011). Iskanje povezave med informacijskim in spektralnim razredom je glavni namen klasifikacije.

Klasifikacija podob temelji na uporabi pravil statističnega odločanja v večspektralni domeni ali po pravih logične odločitve v prostorski domeni. Obstajata dve vrsti klasifikacije (Environmental Systems Research Institute, 2016):

- nenadzorovana in
- nadzorovana.

2.1 Nenadzorovana klasifikacija

Pri nenadzorovani klasifikaciji se piksli razvrščajo v razrede glede na njihovo »naravno« zduževanje v spektralnem prostoru. Pri prvem koraku klasifikacije (gručenje) ni potrebe po poznavanju območja klasifikacije, saj se upošteva, da so vrednosti rabe tal ali podobnih predmetov v spektralnem prostoru blizu, medtem ko so različni tipi rabe tal daleč narazen v spektralnem prostoru. Ta način je nekoliko idealiziran, saj lahko pride tudi do določenega prekrivanja razredov. Najprej se določijo spektralni razredi, ki se jim pripišejo tudi informacijski razredi (Oštir, 2006).

Postopek nenadzorovane klasifikacije je razdeljen na dva dela:

- gručenje in
- identifikacija razredov.

Gručenje pomeni združevanje večrazsežnih podatkov v gruče (razrede) z različnimi matematičnimi algoritmi. Rezultat gručenja so homogeni razredi, brez poznavanja njihove dejanske pokrovnosti. S prepoznavanjem razredov opazovalec razredom določi ustrezno označbo (Oštir, 2006).

Ena najpreprostejših metod nenadzorovane klasifikacije je K-povprečje (ang. K-Means), pri kateri je osnova iskanje podobnosti. Izbere se poljubno določeno število središč gruč in se za tem izračunajo razdalje pikslov do teh centrov z metodo najmanjše razdalje. Postopek se ponovi in naredi iterativno, dokler niso spremembe v klasifikaciji dovolj majhne. Še ena od pogosto uporabljenih in učinkovitejših metod je ISODATA, ki deluje po podobnem principu kot K-povprečje. Izvaja se dinamično z združevanjem središč sorodnih razredov, velike gruče razdeli v več delov in majhne tudi izbriše (Oštir, 2006).

Prednosti, ki jih ima nenadzorovana klasifikacija (Campbell in Wynne, 2011):

- ni potrebe po podrobnem poznavanju območja obdelave,
- možnosti človekove napake je minimalna,
- razredi, ki so v določenih metodah nadzorovane klasifikacije lahko nedefinirani, se tukaj razvrstijo v ločene razrede.

Pomanjkljivost pri tej metodi je omejen nadzor nad razredi. Nenadzorovana klasifikacija prepozna spektralno homogene razrede, za katere ni nujno, da ustrezajo informacijskim razredom, ki so v interes analitiku (Campbell in Wynne, 2011).

2.2 Nadzorovana klasifikacija

Nadzorovana klasifikacija ima dva koraka:

- izdelava učnih vzorcev in
- razvrščanje v razrede.


V koraku izdelave učnih vzorcev se set poligonov, imenovanih učni vzorci, uporabi za izvedbo klasifikacije. Vsak poligon učnega vzorca je sestavljen iz pikslov in njihovih lastnosti. Ti imajo v posameznem vzorcu običajno podobne vrednosti. Drugi korak je klasifikacija, kjer se piksli razporedijo v razrede. Operater določi informacijske razrede z učnimi vzorci, program za obdelavo podob pa na podlagi učnih vzorcev določi lastnosti posameznega razreda. Te so podane s spektralnim podpisom, ki praviloma zajema povprečne, največje in najmanjše vrednosti, standardne odklone in podobne informacije v vseh kanalih (Oštir, 2006). Na podlagi teh lastnosti so se razvile različne metode klasifikacije.

Nadzorovana klasifikacija je bolj razširjena kot nenadzorovana. Uporablja se pri analizah določenih območij v več časovnih obdobjih. V tem primeru se lahko informacije, potrebne za klasifikacijo, zaradi različnih vplivov po določenem času spremenijo. Posodobitve se ne izvajajo samodejno, ampak jih je treba ročno posodablјati in generalizirati. V procesu priprave ima operater že določeno znanje o območju, ki ga klasificira. Težava neujemanja spektralnih in informacijskih razredov se tukaj ne pojavi. Operater ima nadzor in lahko hitro odkrije večje napake s pregledom podatkov. Nadzorovana klasifikacija ima tudi določene slabosti in omejitve, recimo subjektivnost operaterja (Campbell in Wynne, 2011).

V nadaljevanju bom opisal metode razvrščanja pikslov v razrede.

2.2.1 Metoda največje verjetnosti


Pri razvrščanju pikslov v razrede se upoštevajo povprečja, variance in korelacije med piksli. Metoda upošteva normalno (Gaussovo) razporejenost pikslov v spektralnem prostoru. V tem prostoru ustvari elipsoidne ploskve enake verjetnosti (slika 2-2). Na sliki so opazni trije oštevilčeni piksli, ki so problematični, vendar jih je mogoče razvrstiti pravilno. S podajanjem a-priori (predhodno znane) verjetnosti lahko dopolnimo metodo največje verjetnosti, kar pove, s kakšno verjetnostjo se bodo posamezni podobi določile rabe tal, na primer gozd (Oštir, 2006).



Slika 2-2: Metoda največje verjetnosti (Oštir, 2006: 181)

2.2.2 Metoda najmanjše razdalje


Najprej se izračuna povprečje vrednosti pikslov za vsak razred in nato najmanjša oddaljenost posameznega piksla od povprečja razreda. Pikel pripada razredu, od katerega je izračunana najmanjša razdalja od povprečja razreda. Metoda ne upošteva razpršenosti pikslov, zato je večja verjetnost napak. V primerjavi z drugimi je ena od hitrejših metod (Campbell in Wynne, 2011).



Slika 2-3: Metoda najmanjše razdalje (Oštir, 2006: 181)

2.2.3 Metoda spektralnih kotov

Pri tej klasifikaciji se uporablja n -razsežnostni kot za ujemanje pikslov glede na referenčne spektre. Razsežnost uporabljenega prostora določa število spektralnih kanalov, tako lahko algoritem določa spektralno podobnost z izračunom kota med dvema različnima spektroma, pri tem pa ju obravnava kot vektorja. V n -razsežnostnem prostoru primerja kot med končnim vektorjem in vsakim pikslom vektorja, kjer manjši koti predstavljajo večje ujemanje. Možnost je tudi, da se posamezni piksli ne razvrstijo v razrede, in sicer tisti, ki so oddaljeni za več od izbranega praga maksimalnega kota (Rashmi et al., 2014).




Slika 2-4: Spektralni kot

2.2.4 Metoda naključni gozdovi

Metodo naključni gozdovi (RF; ang. Random Forest) je predlagal Breiman (2001). Metoda naključni gozdovi (RF) uporablja za razvrščanje pikslov regresijsko drevo. Prednost pri tej metodi je iterativna in naključna izdelava vzorcev podatkov in spremenljivk. Ti pa se uporabijo za izdelavo velikih drevesnih skupin ali naključnega gozda klasifikacije in regresijskega drevesa. Klasifikacijski izpis iz metode naključni gozdovi predstavljajo razredi pikslov na podlagi statističnega odločanja mnogih drevesnih skupin (Breiman, 2001).

2.2.5 Metoda k – najbližjega sosedu (KNN)

Metoda k - najbližjega sosedu (ang. k – nearest neighbour) je metoda klasifikacije, ki klasificira piksele glede na najbližje učne vzorce. Rezultat klasifikacije KNN je pripadnost piksla k razredu, ki se določi tako, da ga »izvolijo« njegovi sosedje in je pripisan razredu, ki je najbolj običajen v skupini najbližjih sosedov. Običajno je k majhno celo število. Izbran piksel pripada razredu, ki je predstavljen z največjim vzorcem med k – sosedi. Med algoritmi strojnega učenja je ta metoda najpreprostejša in je tip počasnega učenja (Frontline Systems, 2019).



Slika 2-5: Metoda k - najbližjega sosedu (Campbell in Wynne, 2011: 363)

2.3 Vrednotenje rezultatov klasifikacije

Vsako klasifikacijo je treba ovrednotiti, kar pomeni, da se izračuna njena natančnost. To se naredi tako, da po celotnem klasificiranem območju razporedimo referenčne točke. Za te točke je potrebno poznavanje razreda, torej kateri vrsti rabe tal pripada določeni piksel. Kakovost postopka klasifikacije podaja matrika napak. Ta matrika je zapisana kot seznam, pri katerem se opravi primerjava med rezultatom klasifikacije in referenčnimi podatki, ter za vsak razred poda število pravilno in napačno klasificiranih pikslov. Splošno velja, da je natančnost pri klasifikaciji nad 90 % dobra in nad 80 % še zadovoljiva (Oštir, 2006).

3 PROGRAM SNAP

3.1 Misije Sentinel

Copernicus je program za opazovanje Zemlje. Izvaja ga Evropska komisija skupaj z Evropsko vesoljsko agencijo (ESA). ESA razvija satelite Sentinel, ki jih definira in financira Evropska komisija. Podatki, ki se pridobivajo iz satelitov Sentinel, se lahko uporabljajo na raznih področjih, recimo pri razumevanju in preučevanju klimatskih oziroma podnebnih sprememb, zagotavljanju varnosti (npr. radar pri ladijskem transportu) in urejanju prostora. Prav tako zagotavljajo natančne, časovno in preprosto dostopne informacije.

Copernicus sestavlja pet misij satelitov Sentinel:

- Sentinel-1 je radarski sistem, namenjen snemanju kopnega in oceanov,
- Sentinel-2 je osredotočen na snemanje kopnega,
- Sentinel-3 in Sentinel-6 sta namenjena snemanju oceanov in voda,
- Sentinel-4 in Sentinel-5 sta namenjena snemanju atmosfere in
- Sentinel-5P je namenjen snemanju atmosfere in je osredotočen na klimatske spremembe, ozon in UV žarke.

Misija Sentinel-2 ima v tirnici že dva identična satelita imenovana Sentinel-2A in Sentinel-2B. En satelit posname celotno zemeljsko površino v 10-ih dnevih, dva pa v 5-ih dneh in s tem se zagotavljajo stalno posodobljeni podatki. Satelitske posnetke visoke ločljivosti zagotavljata s snemalnim sistemom MSI (Multispectral Imager) (ESA Earth Online, 2019).

3.2 Splošno o programu SNAP

ESA za podporo misij razvija brezplačna odprtokodna orodja Sentinel (ang. Sentinel Toolboxes), ki so sestavni del programa Sentinel Application Platform (SNAP). STEP (Science Toolbox Exploitation Platform) je znanstvena platforma Evropske vesoljske agencije za dostop do programa SNAP in knjižnic Sentinel 1, 2 in 3 Toolbox, za pridobivanje dokumentacije o programu, za pogovore z razvijalci in vodji programa, promocijo rezultatov in dosežkov (European Space Agency, 2019).

SNAP (Sentinel Application Platform) je program, ki so ga razvila podjetja Brockmann Consult, Array System Computing in C-S. Predstavlja združenje vseh knjižnic Sentinel Toolbox in dodatnih osnovnih orodij. Vsaka knjižnica orodij ima svoj namen, na primer Sentinel-2 Toolbox vsebuje orodja za klasifikacijo optičnih satelitskih posnetkov (STEP Toolboxes, 2019).

Glavni deli Sentinel Toolboxov so:

- namizna aplikacija za vizualno interpretacijo, analizo in obdelavo podatkov,
- nabor orodij, ki se izvajajo v ukazni vrstici,
- grafični modelirnik,
- orodje za pretvorbo formata datoteke podatkov BEAM-DIMAP, GeoTIFF, HDF-5, ...

Glavne lastnosti program SNAP (STEP Toolboxes, 2019) so:

- hiter prikaz posnetka in hitra ter preprosta navigacija,
- grafični modelirnik (GPF, Graph Processing Framework),
- urejanje slojev omogoča dodajanje in spreminjanje posnetkov drugih kanalov, posnetkov iz WMS strežnikov in podatkov vektorskih datotek,
- dobra opredelitev območja zanimanja, statistike in razne analize,
- preprosto definiranje mask in prekrivanja,
- natančno določanje projekcije,
- uporaba referenčnih točk za georeferenciranje in projekcijske popravke,
- hitra pridobitev in arhiviranje posnetkov z orodjem *Product library*.

3.3 Format podatkov


Sentinel Toolbox in programi uporabljajo svoj vhodni/izhodni format podatkov, zaradi česar je preprosto uvoziti podatke v druge aplikacije. Format se imenuje DIMAP in ga je razvilo podjetje Spot Image. SNAP uporablja posebni profil DIMAP, imenovan BEAM-DIMAP, z naslednjimi karakteristikami (ESA SNAP, 2019):

- ena glava izdelka v formatu XML, ki vsebuje metapodatke o izdelku,
- povezan podatkovni imenik, ki vsebuje podatke za vsak kanal (na primer B1, B2 itn.),
- vsaka slika v imeniku je sestavljena iz glavne datoteke (ASCII) in slikovne podatkovne datoteke.

Format podatkov v tej nalogi je opisan na primeru satelitskega posnetka satelita Sentinel-2.

3.4 Struktura mape

Struktura mape je edinstvena, saj je na tak način zgrajena samo pri tem programu. V program se uvozi kot datoteko ZIP² in se lahko razširi (Slika 3-1). Sestavljena je iz metapodatkov (ang. metadata), vektorskih podatkov (ang. vector data), kanalov (ang. bands) in mask (ang. masks).




Slika 3-1: Razširjena mapa v programu SNAP

Struktura mape je uporabna in pregledna, saj omogoča vpogled v ustvarjene poligone (učni vzorci), zgodovino uporabljenih orodij in izvedenih postopkov ipd. Vsebuje vse podatke, ki jih potrebujemo za obdelavo satelitskega posnetka.

² Datoteka ZIP je stisnjena mapa, ki zavzame manj prostora na trdem disku, kot razširjeni elementi, ki zavzamejo več prostora na računalniku (trdem disku) in jih je lažje prenašati v druge računalnike, zato se mape, datoteke, videi ipd. stisnejo v eno datoteko ZIP.

3.4.1 Metapodatki

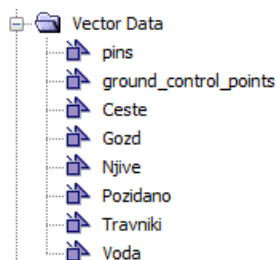
Metapodatki se nahajajo v razdelku glavne mape v podmapi *Metadata* (Slika 3-2). V njej so vsi podatki, potrebni za analizo. Teh je veliko, vendar večino podatkov, ki jih potrebujemo, najdemo v podmapi *Abstracted_Metadata*. Pomembni so predvsem podatki o prostorski ločljivosti, številu pikslov, robnih koordinatah, datumu in uri zajetega posnetka ipd.



Slika 3-2: Podmapa Metadata

3.4.2 Vektorski podatki


Vektorski podatki se nahajajo v podmapi *Vector Data*. Razširjeno mapo prikazuje slika 3-3, v primeru na sliki so že narejeni vzorci za klasifikacijo. Prednost te mape je v navigaciji po vzorcih, kar pomeni, da se pri obdelavi in risanju vzorcev v podmapi aktivira posamezen vzorec, ki se bo po aktivaciji spreminjal. *Pins* so točkovni podatki v vektorski obliki, ki so predhodno generirani in so namenjeni oceni natančnosti. *Ground_control_points* so oslonilne točke, ki se uporabljajo za georeferenciranje posnetkov. *Pins* se pri klasifikaciji uporablja za določevanje referenčnih točk pri ocenjevanju natančnosti.



Slika 3-3: Podmapa Vector Data

3.4.3 Kanali


Podmapa *Bands* je najpomembnejša, saj vsebuje posnetek, ki je razdeljen na več spektralnih kanalov. Pri rezultatu klasifikacije in drugih postopkov ima lahko drugačno zgradbo. Vsak kanal je mogoče prikazati tudi posamično. V podmapah *sun* in *view* so dodani še drugi podatki in posnetki, vendar za to nalogo niso pomembni, zato se jih v postopku obrezovanja izloči, ker zavzemajo veliko prostora na trdem disku. Za klasifikacijo posnetka s satelita Sentinel-2, so najpomembnejši kanali B2, B3, B4 in B8, (Slika 3-4), ki imajo prostorsko ločljivost 10 m.



Slika 3-4: Podmapa Bands

3.4.4 Maske

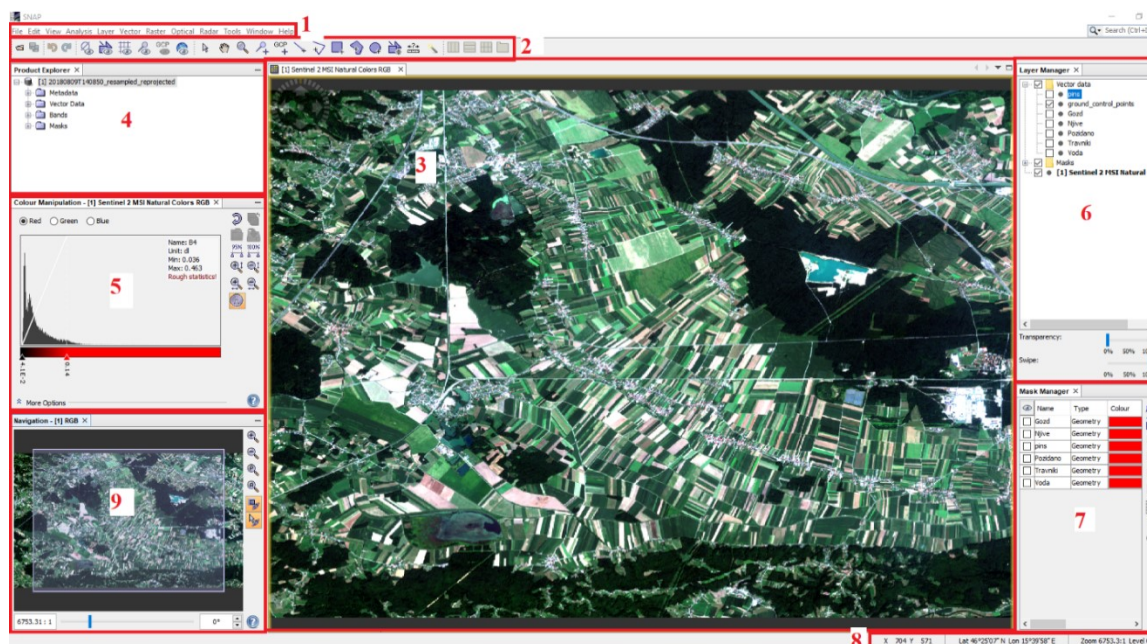
Podmapa *Masks* dobi pravo vlogo šele pri risanju mask (Slika 3-5). V postopku klasifikacije se pri opredelitvi učnih vzorcev prav tako generirajo maske.



Slika 3-5: Podmapa Masks

3.5 Glavna orodja za navigacijo in delo v programu ter njihove komponente

3.5.1 Orodja delovnega okna



Slika 3-6: Orodja v delovnem oknu

Vsa orodja lahko poljubno nastavljamo in premikamo v programu. Stalna so samo orodja v osnovni orodni vrstici (št. 1) in prikaz koordinat (št. 8). Orodja, ki so označena na sliki 3-6 s števili od 1 do 9, so:

- 1 Osnovna orodna vrstica vsebuje nabor vseh orodij, ki jih ponuja program SNAP.
- 2 Orodjarna za hitrejši potek dela v programu. V tej orodni vrstici je mogoče poljubno dodajati ali odvzemati orodja.
- 3 Okno, v katerem je odprta slika RGB. V tem oknu lahko prikazujemo različne vrste datotek (slike oziroma posnetki, sezname, metapodatki ipd.).
- 4 *Product Explorer* je raziskovalec izdelkov namenjen navigaciji po mapi in iskanju želene datoteke oziroma podatka.
- 5 *Colour Manipulation* omogoča upravljanje barvnih prikazov, orodje je uporabno predvsem po končani klasifikaciji, saj ponudi poljubno spreminjanje barv (Slika 3-7). Lahko se tudi uvozijo ali izvozijo že v naprej pripravljene barve razredov, kar je koristno pri ponavljajočih se postopkih, kjer so barve enake.

Label	Colour	Value	Frequency
no data	Yellow	-1	0.000%
Ceste	Grey	0	7.199%
Gozd	Green	1	48.937%
Njive	Brown	2	4.961%
Pozidano	Red	3	8.136%
Travniki	Light Green	4	29.670%
Voda	Blue	5	1.097%

Slika 3-7: Orodje Colour Manipulation

- 6 *Layer Manager* je upravitelj slojev. V njem se posamezni sloji (vzorci, posnetke ipd.) lahko aktivirajo ali deaktivirajo. Določa se jim transparentnost.
- 7 *Mask Manager* (slo. upravitelj mask) je orodje za upravljanje z maskami. Vsebuje podobne funkcije kot *Layer Manager*.
- 8 Del programa, kjer se izpisujejo pikselske in referenčne koordinate.
- 9 *Navigation* je navigacijsko orodje za lažjo navigacijo po posnetku. Slika ali posnetek se poljubno približa ali oddalji, poveča ali pomanjša na pikselsko velikost ali velikost celotnega posnetka.

3.5.2 Osnovna orodna vrstica

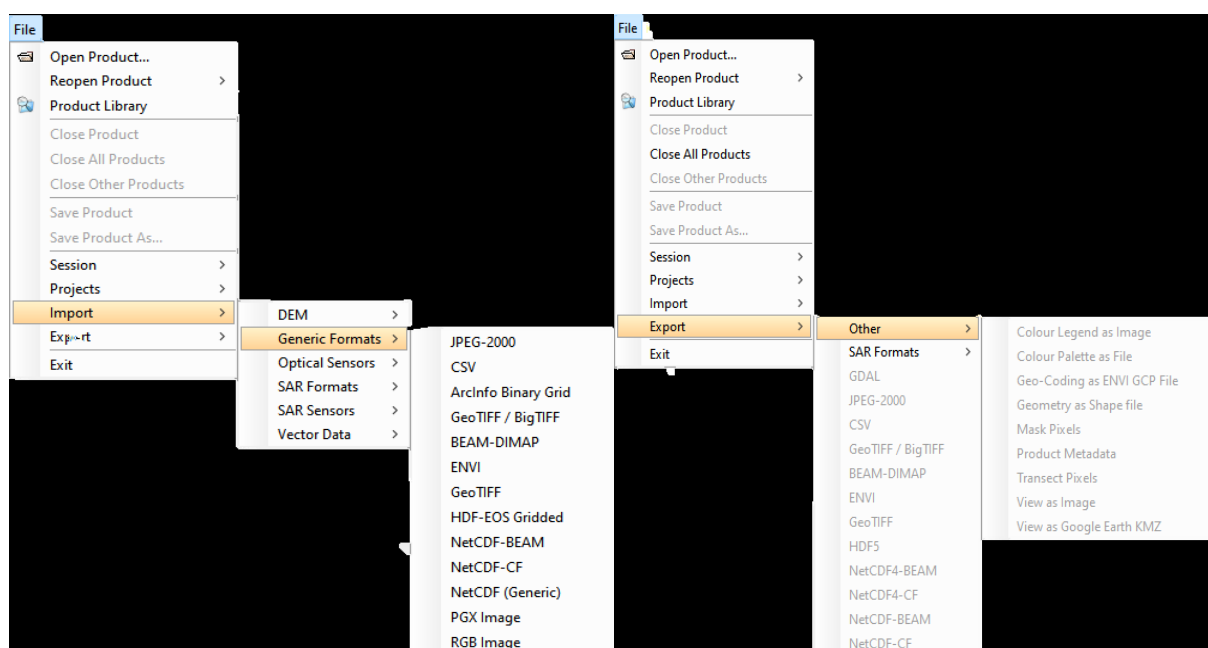
Vsa orodja najdemo v osnovni orodni vrstici (Slika 3-8). Na sliki 3-6 je označena s številko 1. V nadaljevanju bom poudaril samo orodja, ki se uporabljajo v postopku klasifikacije in pri statističnih analizah.

File Edit View Analysis Layer Vector Raster Optical Radar Tools Window Help

Slika 3-8: Osnovna orodna vrstica

3.5.2.1 File

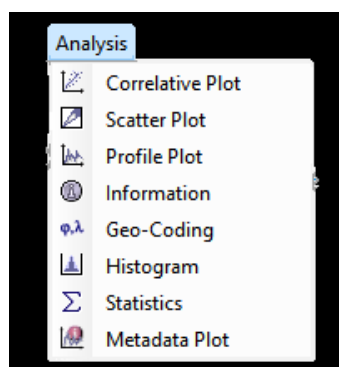
Prvo orodje v glavni orodni vrstici je *File*, datoteka. V tem orodju se lahko upravlja s projekti in datotekami. Pogosto uporabljena orodja so za odpiranje projekta, uvoz in izvoz datotek v številnih zapisih. Na sliki 3-9 je prikaz večine zapisov, ki jih je mogoče uvoziti (ang. import) in izvoziti (ang. export).




Slika 3-9: Orodje File, orodja Import (levo), orodja Export (desno)

3.5.2.2 Analysis

Naslednja izmed pomembnejših orodij je orodje za analizo, ki vsebuje številna podorodja.




Pri postopku klasifikacije je mogoče uporabljati vsa orodja za analize.

1. *Scatter plot*  → orodje za grafični prikaz raztrosa vrednosti,

Graf, ki prikazuje raztros vrednosti v dveh izbranih kanalih (pri Sentinelu-2 je najpogostejši rdeči B4 in bližnji infrardeči B8) in prikaže razsipnost vrednosti enega rastra z drugim. Na desni strani orodja se izbereta ustrezen posnetek in spektralni kanal. Označi se lahko tudi *Auto min/max*. Z orodji na spodnji desni strani se izvozi graf kot sliko. S temi orodji je mogoče določiti lastnosti grafa, kot so ime, interval ipd. (Slika 3-10).

Pomembno je vedeti, da vrednost v rumeni barvi prikazuje veliko število pikslov, ki se prekrivajo, medtem ko v črni barvi majhno število pikslov. Kjer ni obarvano, ni prekrivanja. Rdeči in bližnji infrardeči kanal se uporabljata za odkrivanje vegetacije, zato prihaja do pogostega prekrivanja (Slika 3-10).



Slika 3-10: Orodje Scatter Plot

Graf lahko prikažemo tudi na podoben način, kjer uporabimo masko (npr. Njive). Tako bi dobili prekrivanje rdečega in infra rdečega kanala v posamezni maski. Izberemo »Use ROI mask«, kar pomeni, da se izbere maska *Region of interest*.

2. *Histogram*  → orodje za izris histograma,

S histogramom prikazujemo gostoto pikslov na posnetku ali v izbrani maski. V *Product Explorer* je potrebno izbrati kanal, za katerega se izdela histogram. Izbere se maska in druge nastavitve, ki pa niso nujno potrebne. Način izvoza je enak kot pri orodju *Scatter Plot*.


Na sliki 3-11 je primer histograma, kjer je izbran bližnji infrardeč (NIR) spektralni kanal.



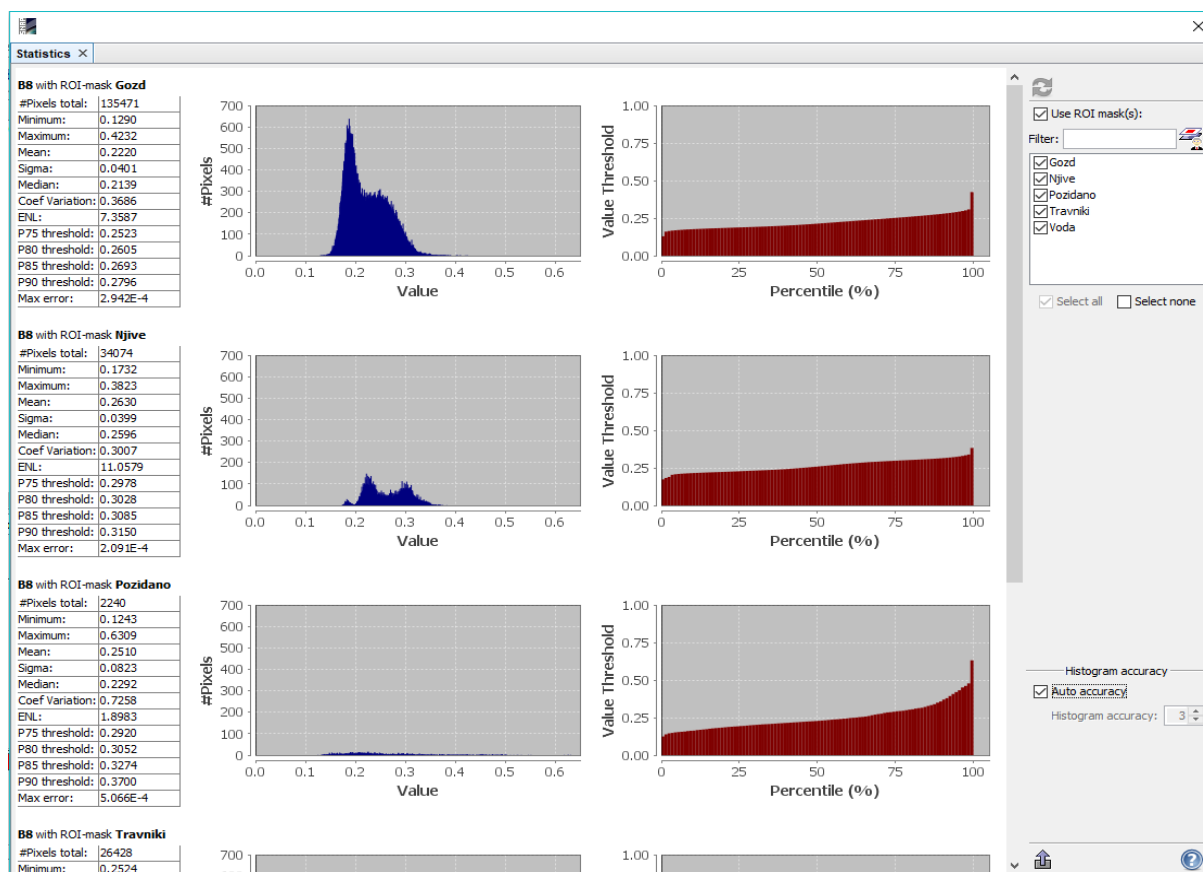
Slika 3-11: Primer histograma - spektralni kanal NIR z masko

3. *Statistics*  → orodje za izračun statistike,

Z orodjem *Statistics* je mogoče izračunati minimalno, maksimalno in povprečno vrednost pikslov. Izračunajo se tudi drugi statistični podatki, ki so koristni pri specifičnih analizah (Slika 3-12). Prav tako kot v prejšnjih dveh orodjih, je mogoče izračunati statistiko za posamezne spektralne kanale kot tudi za posamezne maske v spektralnem kanalu (Slika 3-13). Statistične podatke je mogoče izvoziti v formatu CSV.



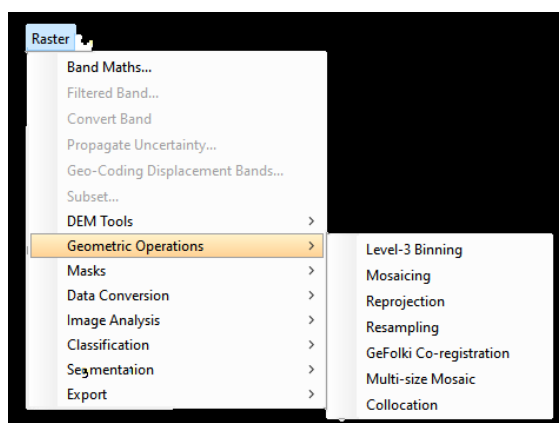
Slika 3-12: Orodje Statistics - kanal NIR



Slika 3-13: Orodje Statistics - kanal NIR z maskami

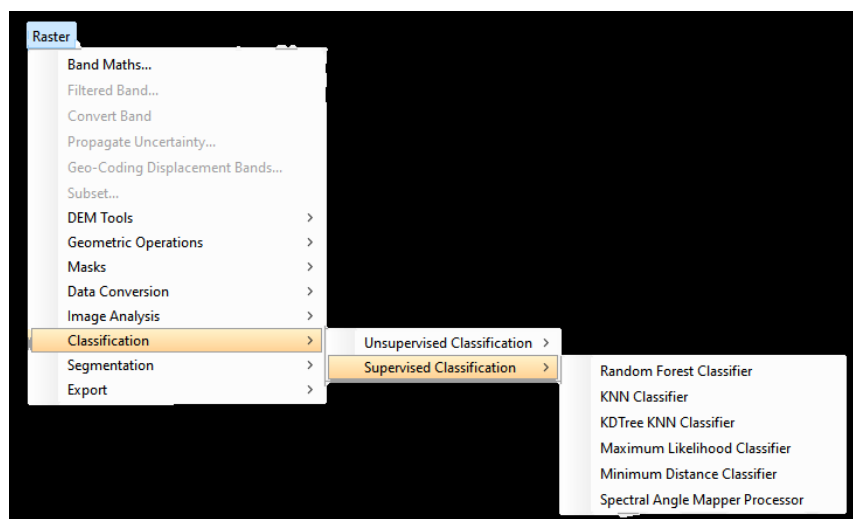
3.5.2.3 Raster

V to orodno vrstico spadajo orodja za obdelavo rastrskih podob. Zelo uporabne in pomembne so geometrijske operacije (ang. Geometric Operations), ki zajemajo orodja, potrebna za klasifikacijo, kot sta *Resampling* in *Reprojecting* (podrobneje v poglavju 3.6).



Slika 3-14: Orodje Raster in orodja Geometric Operations

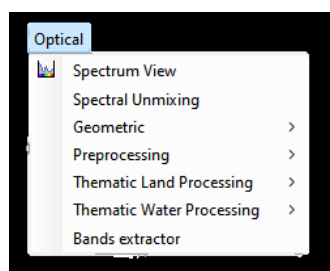
V meniju *Raster* so tudi orodja klasifikacije. Na spodnji sliki se vidijo vse vrste nadzorovane klasifikacije, ki jih SNAP omogoča.



Slika 3-15: Orodje Raster, orodja Classification


3.5.2.4 Optical

Za to nalogo je izmed nabora orodij, prikazanih na sliki 3-16, pomembno samo orodje Spektralni pogled (ang. Spectrum View).



Slika 3-16: Orodje Optical

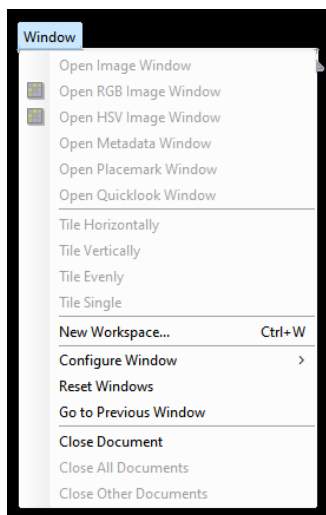
Orodje *Spectrum View* (Slika 3-17) omogoča pregled spektralnega podpisa posnetka. To pomeni, kolikšno vrednost odbojnosti svetlobe ima določena opazovana površina.



Slika 3-17: Orodje Spectrum View


3.5.2.5 Window

Za prikaz posnetka potrebujemo orodje za odpiranje slikovnega okna RGB (ang. Open RGB Image Window) (Slika 3-18). V drugem razdelku orodij *Window* so nastavitve prikaza (ang. Window Arrangement), to so orodja *Tile Horizontally*, *Tile Vertically*, *Tile Evenly* in *Tile Single*, s katerimi je lahko odprtih več posnetkov hkrati.



Slika 3-18: Orodje Window

Orodje za odpiranje posnetka (Slika 3-19) ponuja vnaprej pripravljeno razporeditev spektralnih kanalov, kjer prikaže posnetek v naravnih barvah, umetnih barvah³ ali katerih drugih, odvisno od izbire. Običajno se uporabljajo naravne ali umetne barve.

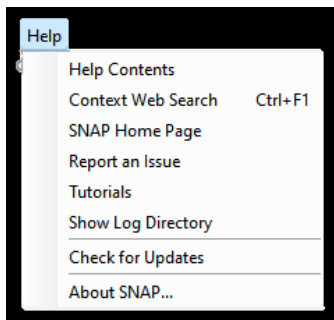


Slika 3-19: Orodje Open RGB Image Window

³ Umetna barva je lahko katera koli kombinacija kanalov, ki ni sestavljena iz rdečega, zelenega in modrega dela spektra.

3.5.2.6 Help

Orodja *Help* (pomoč; Slika 3-20) so vgrajena skoraj v vse programe. Pri tem sta pomembni orodji *Help Contents* in *Tutorials*, saj nudita največ ključnih informacij. Kratko in jedrnato so podane teoretične osnove in uporabnost posameznih orodij v programu. Do informacij je mogoče dostopati preko navodil ali video vadnic.



Slika 3-20: Orodje Help

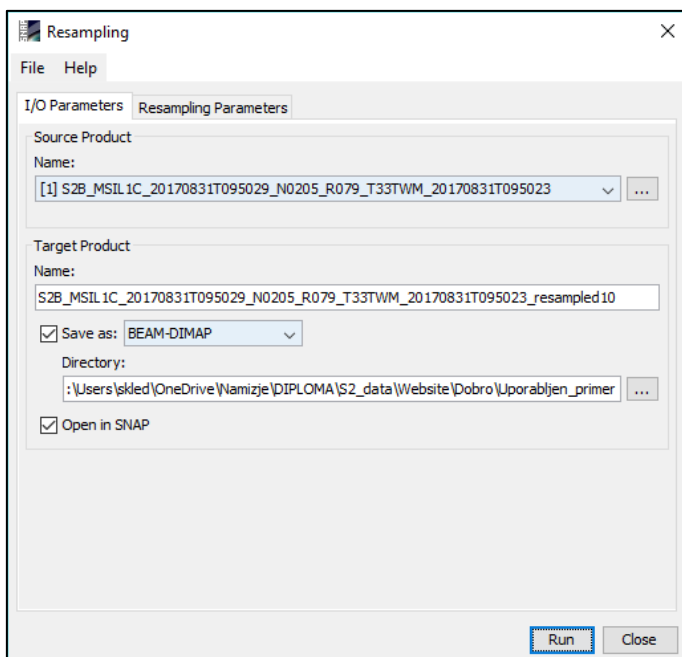
3.6 Orodja v postopku klasifikacije

3.6.1 Uvoz in obrezovanje posnetka

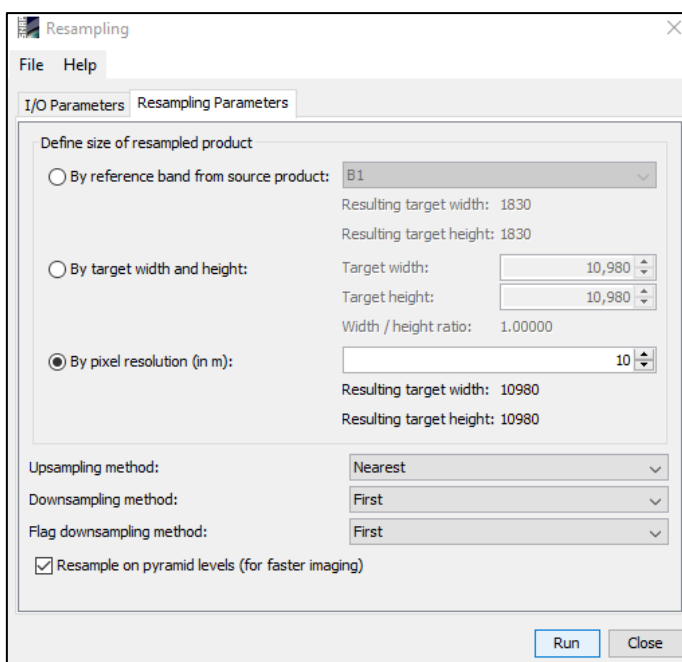
Za uvoz posnetka se uporablja ukaz *Open Product*. Datoteke morajo biti v formatu ZIP.

Ko je datoteka pripravljena za uvoz v program SNAP, se razširi in z dvojnim klikom na izbran posnetek prikaže v delovnem oknu. Odpreti jo je mogoče z orodjem *Open RGB Image Window*.

Nato se uporabi orodje *Resampling* (Raster → Geometric Operations → Resampling), zaradi različne ločljivosti kanalov. Za izvedbo klasifikacije morajo biti vsi v enaki ločljivosti. Določijo se vhodni podatki, ime nove datoteke, vrsta datoteke (izberemo standardni format za program SNAP) in izhodno datoteko (Slika 3-21). Določimo parametre, na podlagi katerih bo orodje delovalo. Pri tem se ločljivost ne sme zmanjšati, zato običajno izberemo najboljšo ločljivost, ki jo ponujajo podatki. Satelitski posnetki Sentinel-2 imajo prostorsko ločljivost 60 m, 20 m in 10 m, zato izberemo 10 m (Slika 3-22).



Slika 3-21: Resampling: orodje – I/O Parameters

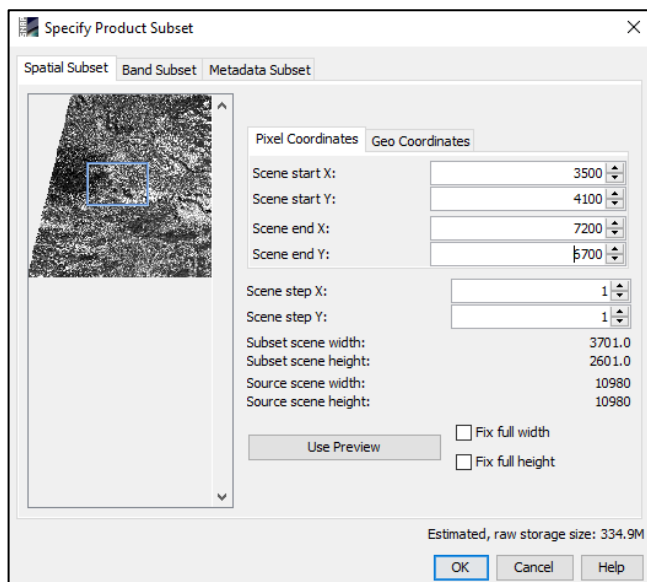


Slika 3-22: Resampling: orodje - Resampling parameters

Za obrezovanje se uporabijo orodje *Subset* (Raster → Subset) (Slika 3-23). Določi se, koliko kanalov se bo obrezalo, kjer se običajno ohranijo vsi kanali, če pa za to ni potrebe, izberemo vsaj kanale B2, B3, B4 in B8, ki so najpomembnejši in zajemajo veliko večino podatkov. V tem koraku se lahko izbrišeta mapi *sun* in *view*, kateri se nahajata v podmapi *Bands*, da ne zasedata dodatnega podatkovnega prostora in upočasnit postopek obdelave.

Najprej izberemo robne koordinate izbranega območja. V spodnjem desnem kotu programa so vidne koordinate v referenčni in pikselski obliki (posnetek mora biti odprt v delovnem oknu). Vpišemo

koordinate in sprožimo postopek. Območje lahko določimo tudi tako, da označimo območje na posnetku, ki je v pomanjšanem merilu prikazan v orodju in nanj narišemo pravilni štirikotnik. Po opravljenem postopku SNAP ustvari začasno datoteko. To je zelo uporabno pri poskusih. Obdelane, klasificirane in procesirane izdelke shranimo ročno, ker program ne omogoča samodejnega shranjevanja.




Slika 3-23: Orodje Subset

3.6.2 Izdelava učnih vzorcev

Orodja, ki so prikazana na sliki 3-24, so namenjena risanju vektorskih podatkov. Vključijo se z View → Toolbars → Tools.

za označevanje, za premikanje posnetka, približevanje/oddaljevanje, risanje vzorcev




Slika 3-24: Orodja za risanje vektorjev

Najprej ustvarimo nov vektorski podatkovni sloj (Vector → New Vector Data Container). Prikazan je v podmapi *Vector Data*.

Pri risanju vzorcev smo pozorni, da v obstoječo kategorijo vzorca ne vključimo pikslov, ki temu vzorcu ne ustrezajo. Pri opredelitvi učnih vzorcev izberemo območja, ki zavzemajo celoten razpon pikselskih vrednosti, ki jih vsebuje določen razred.

Pri risanju vzorcev običajno uporabimo poligone. Orodje *Layer Manager* omogoča upravljanje z vzorci. Ustvarjeni poligoni se dodajajo v nabor učnih vzorcev razreda, ki je trenutno izbran v orodju Layer Manager.

Na sliki 3-25 je prikazan primer izdelanih vzorcev. Priporočljivo je izbirati velike vzorce, vendar hribovito in pozidano območje, ki je prikazano na sliki, tega ne omogoča.



Slika 3-25: Primer izrisanih vzorcev

3.6.3 Izvedba klasifikacije

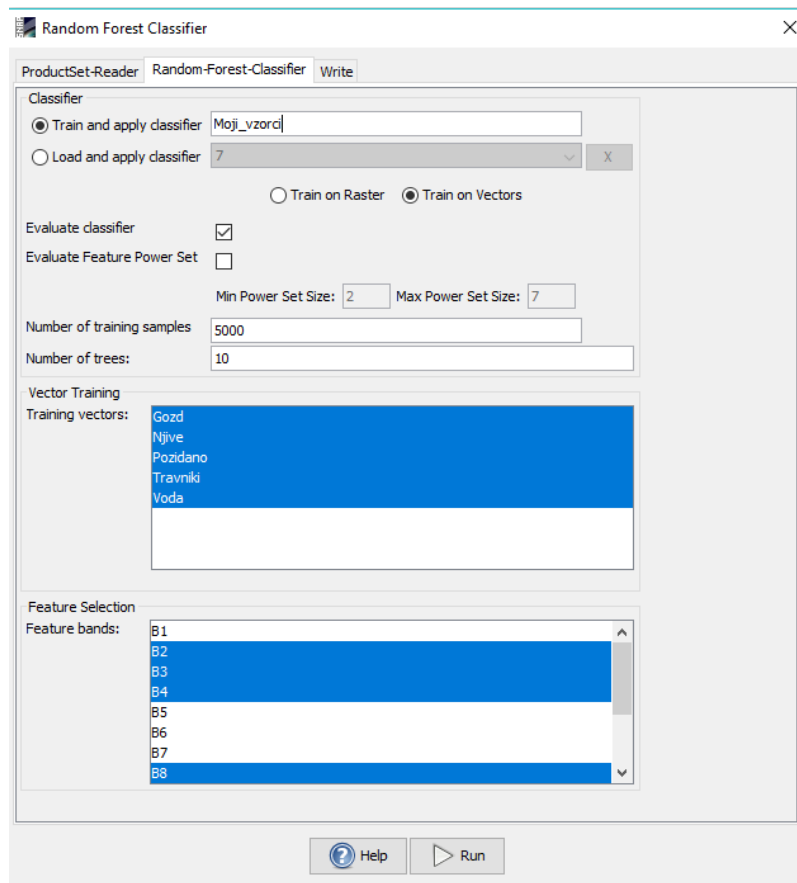
Program SNAP omogoča klasifikacije, kot so:

- Metoda naključni gozdovi,
- Metoda največje verjetnosti,
- Metoda najmanjše razdalje,
- Metoda k – najbližjega sosedu (KNN),
- KDTree KNN klasifikacija in
- Metoda spektralnih kotov.

Prvih pet naštetih klasifikacij je med sboj podobnih, v SNAPu imajo zelo podobna orodja, zato je v nadaljevanju opisan le primer klasifikacije z metodo naključni gozdovi. Metoda spektralnih kotov deluje drugače, zato se tudi orodje razlikuje.

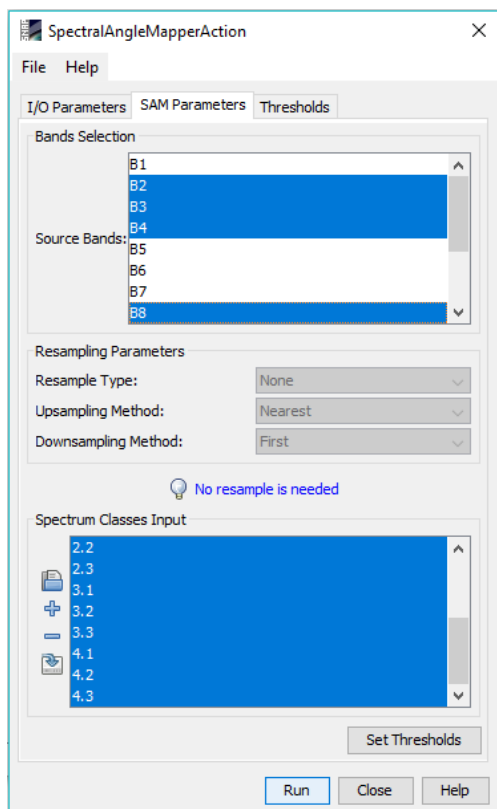
Orodje za klasifikacijo odpremo v glavni orodni vrstici *Raster*. V zavihku *ProductSet-Reader* se v orodju izbere pripravljen posnetek. V zavihku *Random-Forest-Classifer* (Slika 3-26) poimenujemo vzorec, ki ga bomo shranili v eno od pripravljenih map (na primeru *Moji_vzorci*). Izberemo vektorske podatke, ki se bodo zapisali v vzorce in shranili v predhodno poimenovano datoteko. Prav tako izberemo spektralne kanale, s katerimi se bo izvedla klasifikacija.

Na koncu v zavihku *Write* poimenujemo končni izdelek klasifikacije. Določimo tudi standardni format za program SNAP, lahko pa izberemo poljuben format datoteke.



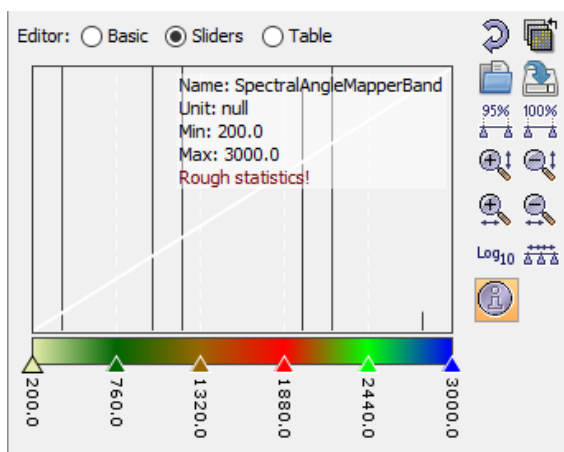
Slika 3-26: Orodje klasifikacije – primer metode naključni gozdovi

Pri orodju metode spektralnih kotov določimo vhodne podatke, ime, format rezultata in mapo, kamor se bo rezultat shranil. V zavihku *SAM Parameters* (Slika 3-27) izberemo spektralne kanale, ki jih bomo uporabili v klasifikaciji. Če spektralni kanali niso predhodno prevzorčeni na enako prostorsko ločljivost, lahko to naredimo tudi v tem orodju. Spektralne razrede določimo tako, da vnesemo točke, ki jim moramo določiti koordinate iz posnetka. Orodje nam omogoča tudi izvoz in uvoz spektralnih razredov. V zavihku *Thresholds* se lahko poljubno določa utež (hierarhija) oziroma prednost določenemu razredu.




Slika 3-27: Orodje klasifikacije SAM

Po opravljeni klasifikaciji je rezultat viden v črno-beli barvni lestvici. Nato še prilagodimo paleto barv, izberemo recimo tako, ki se je uporabljala pri drugih klasifikacijah (Slika 3-28). Barve lahko določimo tudi ročno. S pomikanjem drsalcev (ang. Slider) je mogoče določiti primerno razmerje med barvami.



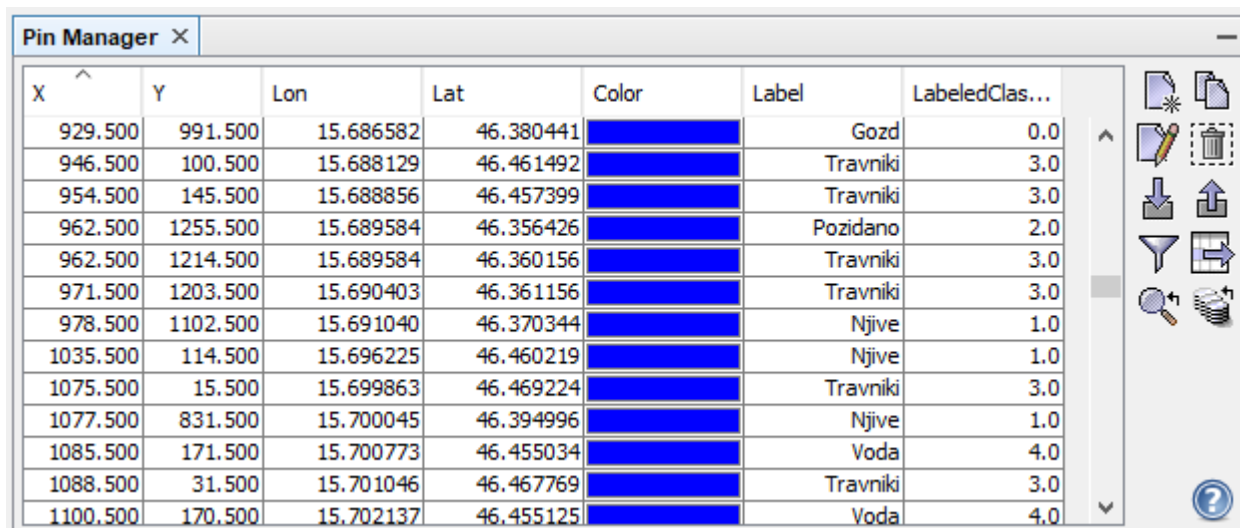
Slika 3-28: Določanje barv pri klasifikaciji SAM

3.6.4 Ocena kakovosti klasifikacije

Oceno kakovosti klasifikacije naredimo z referenčnimi točkami z orodjem *Pin placing tool* . Na referenčni posnetek postavimo poljubno število referenčnih točk, priporočljivo je vsaj 30 na razred. Nato v oknu *Pin Manager* (Slika 3-29), ki služi za upravljanje, prilagodimo lastnosti v stolpcu *Label*. Referenčnim točkam dodamo imena razredov z enakim imenom, kot so poimenovani sloji (vzorci). Te točke izvozimo v tekstovno ali XML datoteko.

V izdelek klasifikacije uvozimo narejeno tabelo referenčnih točk, nato uporabimo orodje za filtriranje, ki ustvari nov stolpec tako, da vanj vnese vrednosti za vsako referenčno točko. Vrednosti pa so določene iz *LabeledClasses*. Te vrednosti so vidne v oknu *Colour Manipulation*, v stolpcu *Value*.

Stolpca *Label* in *LabeledClasses* primerjamo in naredimo matriko napak v programu Microsoft Excel ali kateremkoli poljubnem programu in tako dobimo natančnost klasifikacije.



X	Y	Lon	Lat	Color	Label	LabeledClasses
929.500	991.500	15.686582	46.380441		Gozd	0.0
946.500	100.500	15.688129	46.461492		Travniki	3.0
954.500	145.500	15.688856	46.457399		Travniki	3.0
962.500	1255.500	15.689584	46.356426		Pozidano	2.0
962.500	1214.500	15.689584	46.360156		Travniki	3.0
971.500	1203.500	15.690403	46.361156		Travniki	3.0
978.500	1102.500	15.691040	46.370344		Njive	1.0
1035.500	114.500	15.696225	46.460219		Njive	1.0
1075.500	15.500	15.699863	46.469224		Travniki	3.0
1077.500	831.500	15.700045	46.394996		Njive	1.0
1085.500	171.500	15.700773	46.455034		Voda	4.0
1088.500	31.500	15.701046	46.467769		Travniki	3.0
1100.500	170.500	15.702137	46.455125		Voda	4.0

Slika 3-29: Okno Pin Manager in vnesen testni primer za prikaz

3.6.5 Izvoz datotek in rezultatov

Vse izvoze opravimo s funkcijo *File* → *Export*. Za izvoz posnetka v formatu TIFF je potrebno izbrati GeoTIFF. Ta je združljiv z drugimi programi in vsebuje geolokacijske podatke in vrednosti rastrov, zato je priporočljiv izvoz v tem formatu.

Rezultat klasifikacije se lahko izvozi tudi kot rastrski sloj z *Other* → *View as Image*. V oknu, ki se odpre na desni strani, označimo *Full scene* in določimo format rastrskega sloja. Izvoz na ta način ohrani barvno lestvico prikaza, vendar ne vsebuje geolokacije, zato izvoz *View as Image* uporabljamo samo v primeru, ko podatka o geolokaciji ne potrebujemo.

Po končani klasifikaciji izvozimo še vektorje (vzorci) v zapis ESRI Shape z orodjem *Geometry as Shape file*. Ta zapis omogoča uvažanje vzorcev v druge programe, kot so ArcMap, QGIS idr.

3.7 Dinamika razvoja programa SNAP

Program SNAP se pogosto posodablja, kar je mogoče zaznati po pogostih obvestilih o posodobitvah in vrsti posodobitve. Pri vsakem programu se pojavljajo pomanjkljivosti, ki jih razvijalci pri pisanju programa niso predvideli. Komunikacija z njimi poteka večinoma na forumu STEP. Zaradi dejavnosti tako razvijalcev kot uporabnikov se program znova in znova izboljšuje. V času nastajanja te naloge je trenutna verzija programa 6.0.9. Glavne posodobitve so definirane s prvo številko v imenu, to je s 6. Manjše oziroma vmesne posodobitve, kot so popravki težav v programu in podobno, definira zadnja številka v imenu, trenutno je to številka 9. Program samodejno obvešča o posodobitvah. Na razpolago so tudi zapiski popravkov (ang. Release Notes), ki so javno objavljeni. Pri vsaki posodobitvi je dodano pojasnilo sprememb in sprememba v programski kodi. Priložene so tudi diskusije iz foruma, kjer se je težava objavila. Možen je vpogled v vse podatke o posodobitvah v vsaki na novo nastali različici kot tudi preteklih različicah programa.

Na spletni strani *senbox.atlassian.net* lahko ustvarjamo poljubne grafe in analize posodobitev in sprememb v programu. Analize pokažejo odpravljene napake glede na pretekle objave, vendar ne iz tekočega meseca. Analize in grafi se lahko prikazujejo tudi po urnem, dnevnem, tedenskem, četrtnem ali letnem intervalu. Spodnja preglednica prikazuje letno število objavljenih in odpravljenih napak.

Preglednica 1: Objavljene in odpravljene napake po letih

Leto	Število objavljenih napak	Število odpravljenih napak
2014	53	10
2015	298	177
2016	287	189
2017	209	127
2018	141	34
2019 (do julija)	125	97

Vpogled v programsko kodo programa SNAP omogoča sistem GitHub. GitHub je brezplačen in odprtokoden sistem za nadzor programske kode in projektov, zasnovan je tako, da obravnava vse od majhnih do zelo velikih projektov. Deluje tudi kot varnostna kopija oziroma »backup«. V tem sistemu je uporabniku omogočeno tudi poljubno spreminjanje in prilagajanje kode (GitHub, 2019).

3.8 Forum STEP


Forum STEP je spletna stran za javne in odprte razprave. Teme, ki se v večini pojavljajo, so povezane z reševanjem težav v programu in pridobivanjem znanja o uporabi. Forum je voden, moderirajo ga štirje moderatorji. Uporabniki so odgovorni le za aktivno sodelovanje.

Forum STEP je sestavljen iz podkategorij, ki so ločene glede na zanimanje uporabnikov, kot so Sentinel 1, 2 in 3 Toolbox, SNAP, za razvijalce in drugo. Za klasifikacije optičnih satelitskih posnetkov je primerna podkategorija Sentinel-2 Toolbox oziroma »s2tbx«. Odzivnost moderatorjev, skrbnikov sistema in drugih uporabnikov je dokaj hitra, zato se lahko težave hitro odpravijo. Tudi v primeru, če kaj ne deluje, se lahko posvetujemo na forumu z moderatorji ali drugimi uporabniki. Če pride do večje težave, ki se pojavi pri več uporabnikih, jo poskušajo odpraviti v najkrajšem možnem času.

4 PRIMER KLASIFICIJE SATELITSKEGA POSNETKA SENTINEL-2

4.1 Podatki in območje

Analizo sem naredil za območje Dravskega polja v Podravski regiji. Uporabil sem posnetek Sentinel-2, ki je bil zajet 9. avgusta 2018 ob 10:00. Leži med 46.3432360° S in 46.4705888° S geografske širine ter 15.6020745° V in 15.8203935° V geografske dolžine. Območje vključuje ravninske predele, kjer so najbolj značilne kmetijske obdelovalne površine, kot so njive in travniki ter vodna območja. Veliko je tudi hribovitega območja, kjer je še posebej izrazit del Pohorja in hribovje, ki se od Ptuijske Gore razteza na vzhod in zahod. Že iz samega posnetka je razvidno, da se pojavljata dve vrsti vasi, to sta obcestna vas na ravninah in razložene vasi v hribovju.



Slika 4-1: Posnetek območja Dravskega polja

Multispektralni podatki satelita Sentinel-2A imajo 13 spektralnih kanalov (Preglednica 2). Prostorska ločljivost je 60 m, 20 m in 10 m. Za vse klasifikacije so bili uporabljeni modri, zeleni, rdeči in bližnji infrardeči spektralni kanali.

Preglednica 2: Spektralni kanali Sentinel-2A

Sentinel-2 kanali	Osrednje valovne dolžine	Ločljivost (m)
Kanal 1 – obalni aerosol	0,443	60
Kanal 2 – moder	0,490	10
Kanal 3 – zelen	0,560	10
Kanal 4 – rdeči	0,665	10
Kanal 5 – vegetacija rdeči rob	0,705	20
Kanal 6 – vegetacija rdeči rob	0,740	20
Kanal 7 – vegetacija rdeči rob	0,783	20

Kanal 8 – bližnje infrardeči	0,842	10
Kanal 8A – vegetacija rdeči rob	0,865	20
Kanal 9 – vodna para	0,945	60
Kanal 10 – SWIR – Cirrus (infrardeči)	1,375	60
Kanal 11 – SWIR – (infrardeči)	1,610	20
Kanal 12 – SWIR – (infrardeči)	2,190	20

4.2 Metodologija

Za klasificiran primer sem uporabil vse klasifikacije, ki jih omogoča program SNAP, in sicer so to:

- Metoda naključni gozdovi,
- Metoda največje verjetnosti,
- Metoda najmanjše razdalje,
- Metoda k – najbližjega soseda (KNN),
- KDTree KNN klasifikacija,
- Metoda spektralnih kotov.

Definicije metod so navedene v podpoglavju 2.2 Nadzorovana klasifikacija.

4.3 Rezultati in analiza

Pri programih, kot je npr. QGIS, so vgrajena orodja za izračun natančnosti klasifikacije. Program SNAP tega orodja nima, zato sem izračun natančnosti opravil z Microsoft Excelom. V SNAPu sem določil le referenčne točke na referenčnem posnetku. Njihov razred sem določil s poznavanjem okolice in topografskih kart, kjer je jasno razvidna raba tal. Nato sem tem točkam dodal še razred iz klasificiranega posnetka. Naredil sem primerjavo med vrednostjo piksla iz referenčnega posnetka in vrednostjo iz klasificiranega posnetka.

Tako sem ustvaril matriko napak, v kateri so vsote referenčnih točk iz referenčnega posnetka in klasificiranega posnetka, ter kakšno je njihovo ujemanje. Za boljšo predstavbo sem dodal primer matrike napak na preglednici 3. Potreboval sem seštevke referenčnih vrednosti, ki sem ga izračunal za vsak razred ločeno, po stolpcih. Klasificirane vrednosti sem dobil iz programa ter na enak način kot referenčne, naredil seštevke klasificiranih vrednosti. V primeru v preglednici vidimo, da se referenčne in klasificirane vrednosti ne ujemajo, zato se pojavijo tudi nepravilne vrednosti. Če bi imeli popolno ujemanje, bi bil rezultat idealiziran. Vse seštevke referenčnih vrednosti sem seštel in dobil vsoto vseh referenčnih točk. Enako sem naredil za klasificirane točke. Vrednosti vsot referenčnih in klasificiranih točk sta se ujemale, ta vrednost na primeru znaša 248. Pred izračunom natančnosti sem potreboval še pravilne vrednosti, ki so razvidne iz matrike napak. Število referenčnih točk, ki se ujemajo v referenčni in klasificirani vrednosti, imenujemo pravilne vrednosti, to so diagonalne vrednosti v primeru. Nato sem izračunal natančnost izdelovalca in uporabnika za vsak razred posebej.

Preglednica 3: Primer matrike napak

Razred	-1	0	1	2	3	4	Klasificirane
0 Gozd		85			1		86
1 Njive			36	1	8		45
2 Pozidano		4	4	31		7	46
3 Travniki		1			44		45
4 Voda						27	27
Referenčne		89	40	32	53	34	248

Za izračun skupne natančnosti sem uporabil podatke pravih vrednosti oziroma pravilno definiranih pikslov in skupnim številom vrednosti razredov, ki sem jih pridobil iz matrike napak.

Za analizo rezultatov se izračunajo tri statistike. Prva je *natančnost izdelovalca* (ang. producer accuracy), ki daje informacijo o pravilno izračunanih referenčnih točkah. Namenjena je ovrednotenju kakovosti dela analitika (izdelovalca). Druga je *natančnost uporabnika* (ang. user accuracy), ki poda delež pravilno klasificiranih točk glede na celotno število točk v posamezni kategoriji. Namenjena je uporabniku, ker mu pove, ali se lahko zanaša na podatke (Oštir, 2006).

Tretja natančnost je *skupna natančnost* (ang. overall accuracy), ki v celosti ovrednoti natančnost izvedene klasifikacije. Podana je v odstotkih in se izračuna tako, da se pravilno definirane piksele po diagonali matrike sešteje in deli s skupnim številom referenčnih pikslov (Langley, Cheshire, Humes, 2001).

Za kontrolo točnosti se izračuna Kappa (κ). S to statistiko se bolje oceni celotna natančnost klasifikacije, ker vsebuje informacije o ostalih vrednostih matrike napak. Izračuna se po formuli (NCSS, 2019):

$$\kappa = \frac{f_u - f_n}{N - f_n}, \quad (1)$$

kjer je:

f_u ... seštevek pravilno definiranih pikslov,

f_n ... število referenčnih in klasificiranih vrednosti deljeno z vsoto vrednosti v vzorcih,

N ... število vseh pikslov.

$$f_n = \frac{R1 \cdot K1 + R2 \cdot K2 + \dots + Rn \cdot Kn}{N}, \quad (2)$$

kjer je:

Rn ... število referenčnih pikslov v enem stolpcu,

Kn ... število klasificiranih pikslov eni vrstici.

V poglavju priloge so za vsako metodo podani rezultati klasifikacije in matrike napak kot tudi izračun uporabnikove in izdelovalčeve natančnosti. V spodnjih preglednicah so prikazane natančnosti vseh metod klasifikacije.

Preglednica 4: Natančnosti metode naključni gozdovi

Metode	Metoda naključni gozdovi (RF)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	98,9	100,0	0,9632	97,2
Njive	95,0	100,0		
Pozidano	96,9	93,9		
Travniki	100,0	100,0		
Voda	91,2	96,9		

Preglednica 5: Natančnosti metode največje verjetnosti

Metode	Metoda največje verjetnosti (MLC)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	95,5	98,8	0,8689	89,9
Njive	90,0	80,0		
Pozidano	96,9	67,4		
Travniki	83,0	97,8		
Voda	79,4	100,0		

Preglednica 6: Natančnosti metode najmanjše razdalje

Metode	Metoda minimalne razdalje (MDC)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	96,6	100,0	0,9104	93,2
Njive	100,0	78,4		
Pozidano	62,5	100,0		
Travniki	98,1	94,5		
Voda	97,1	91,7		

Preglednica 7: Natančnosti metode KDTree K - najbližji sosed

Metode	KDTree metoda K – najbližji sosed (KDTree KNN)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	100,0	100,0	0,9578	96,8
Njive	97,5	95,1		
Pozidano	100,0	86,5		
Travniki	96,2	98,1		
Voda	85,3	100,0		

Preglednica 8: Natančnosti metode K - najbližji sosed

Metode	K – najbližji sosed (KNN)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	100,0	100,0	0,9578	96,8
Njive	100,0	93,0		
Pozidano	100,0	88,9		
Travniki	94,3	98,0		
Voda	85,3	100,0		

Preglednica 9: Natančnosti metode spektralnih kotov


Metode	Metoda spektralnih kotov (SAM)			
Razredi	Nat. izdelovalca (%)	Nat. uporabnika (%)	Kappa (κ)	Skupna nat. (%)
Gozd	92,1	96,5	0,8421	87,9
Njive	90,0	69,2		
Pozidano	81,3	86,7		
Travniki	88,7	87,0		
Voda	79,4	100,0		

Vse klasifikacije so bile izvedene uspešno, vendar se pojavijo tri natančnosti, ki izstopajo, ker je njihova vrednost manjša od 70 %. Prva se pojavi pri metodi največje verjetnosti pri razredu pozidano in znaša 67 %, druga nastane pri metodi minimalne razdalje pri razredu pozidano in ima vrednost 63 % in tretja pri metodi spektralnih kotov pri razredu njive in znaša v vrednosti 69 %.

Ob primerjavi natančnosti izdelovalca in natančnosti uporabnika je razvidno, da so si vrednosti zelo podobne, ponekod celo identične. Prihaja tudi do velikih odstopanj, kjer se ena pojavi pri metodi največje verjetnosti v razredu pozidano, druga pri metodi najmanjše razdalje, prav tako v razredu pozidano. Razlika v natančnosti med njima je večja od 25 %.


Natančnost klasifikacije Kappa je v vseh primerih dobra. Na Grafu 1 sem prikazal primerjavo natančnosti klasifikacije Kappa, kjer je razvidno, da ima največjo vrednost metoda naključni gozdovi 0,9632 in najnižjo metoda spektralnih kotov 0,8421.

Graf 1: Primerjava natančnosti klasifikacije Kappa



Skupna natančnost je pri vseh metodah dobra. Najboljšo natančnost ima metoda naključni gozdovi z vrednostjo 97 %; najslabšo pa ima metoda spektralnih kotov z vrednostjo 88 %. Primerjava skupne natančnosti je na Grafu 2.

Graf 2: Primerjava skupne natančnosti



Natančnost izdelovalca, natančnost uporabnika, statistika Kappa in skupna natančnost so najboljše rezultate pokazali pri metodi naključni gozdovi, zato je razvidno, da je ta metoda najuspešnejša. Ugotovil sem, da ima metoda spektralnih kotov najslabšo natančnost izdelovalca in uporabnika, kar se pozna tudi na statistiki Kappa in skupni natančnosti.

Kljub najmanjši natančnosti metode spektralnih kotov ima vrednost skupne natančnosti razmeroma visoke. Kot je zgoraj opredeljeno, je 80 % natančnost zadostna in 90 % dobra, ker je pri tej metodi skupna natančnost 88 % se lahko zaključi, da je dobra.

Takoj za metodo naključni gozdovi sta metodi K – najbližji sosed in KDTree KNN, ki imata zelo podobne rezultate. Do tega prihaja, ker imata metodi skoraj enake algoritme, teoretično bi rezultati zato morali biti zelo podobni, če ne celo identični. Glavna razlika je v tem, da ima metoda KDTree K – najbližji sosed nekoliko poenostavljene algoritme in je veliko hitrejša.

5 PRIMERJAVA SNAP Z DRUGIMI PROGRAMI

5.1 Definiranje meril in izbira programov

Opravi sem primerjavo programa SNAP z drugimi programi, zato da dobimo boljši pogled, ko se odločamo za izbiro programa za klasifikacijo. Izbrani programi za izvedbo klasifikacije so:

- SNAP,
- ArcMap,
- QGIS,
- SAGA GIS.

ArcMap je licenčni izdelek podjetja ESRI (Environmental System Research Institute). Je glavna komponenta ESRI-jevega programa ArcGIS. ArcMap prikazuje geografske informacije kot zbirko slojev in drugih elementov v zemljevidu. Uporablja se za opravljanje širokega spektra skupnih nalog GIS (Environmental Systems Research Institute, 2016).

QGIS je uporabniku prijazen brezplačen odprtokodni geografski informacijski sistem, licenciran pod GNU General Public License. Je uradni projekt Open Source Geospatial Foundation (OSGeo). Program podpira številne rastrske, vektorske in podatkovne formate ter funkcionalnosti (QGIS, 2019).

SAGA GIS (System for Automated Geoscientific Analyses) je geografski informacijski sistem, narejen za preprosto in učinkovito uporabo prostorskih algoritmov. Ponuja celovit in rastoč sklop znanstvenih metod. Ideja za razvoj SAGA GIS se je pojavila v poznih devetdesetih letih pri delu na več raziskovalnih projektih v Nemčiji (Conrad, et al., 2015).

Merila, ki sem jih uporabil za primerjavo programov, so:

- dostopnost programa,
- vrste klasifikacij, ki jih vsebuje,
- generiranje posnetka RGB in legende,
- avtomatiziran izračun ocene natančnosti,
- pomoč, ki jo program nudi.

Za izbrana merila menim, da so pomembna pri postopku klasifikacije s programskim orodjem. Nekatera sem določil na podlagi dela s programom, druga pa glede na informacije in pomoč, ki jo je mogoče najti na spletnih straneh ali v samem programu.

5.2 Analiza primerjave programov

Preglednica 10: Dostopnost programov

Program \ Dostopnost	SNAP	ArcMap	QGIS	SAGA GIS
Odprtokoden	DA	NE	DA	DA
Brezplačen	DA	NE	DA	DA

Vsi omenjeni programi razen ArcMap-a so odprtokodni in brezplačni, FOSS (Free Open Source System).

Preglednica 11: Vrste klasifikacij v programih

Program		SNAP	ArcMap	QGIS	SAGA GIS
Klasifikacija					
SLO	ANG				
Klasifikacija naključnega gozda	Random Forest (RF) classifier	DA	DA	/	/
Klasifikacija največje verjetnosti	Maximum likelihood classifier	DA	DA	DA	DA
Klasifikacija najkrajše razdalje	Minimum distance classifier	DA	/	DA	DA
Klasifikacija K – najbližji sosed	K – nearest neighbour (KNN) classifier	DA	/	/	/
Proces za preslikovanje spektralnih kotov	Spectral angle mapper processor	DA	/	DA	DA
Klasifikacija SVM	Support Vector Machine (SVM) Classifier	/	DA	/	/
LCS klasifikacija	Land cover signature classification	/	/	DA	/
Paralelipipedna klasifikacija	Paralelipiped classification	/	/	/	DA
Klasifikacija mahalanobis razdalje	Mahalanobis distance classification	/	/	/	DA
Analiza k-povprečja gruče	K-Means (KM) Cluster Analysis	DA	/	DA	/
Analiza maksimiziranega pričakovanja gruče	Expectation Maximization (EM) Cluster Analysis	DA	/	/	/
Klasifikacija ISO gruče	ISO Cluster Classifier	/	DA	DA	/
Binarno kodirana metoda	Binary encoding method	/	/	/	DA

Pri vrstah vgrajenih klasifikacij (našteti v Preglednici 10) opazimo, da jih ima največ SNAP. Omogoča kar sedem različnih klasifikacij in v bližnji prihodnosti imajo namen omogočiti še klasifikacijo SVM. SAGA GIS jih prav tako omogoča veliko, to je šest. Oba omenjena programa se uporabljata za obdelavo satelitskih posnetkov. Program QGIS se ne uporablja samo za obdelavo satelitskih posnetkov, ampak kot GIS, kljub temu ima šest vrst klasifikacij. ArcMap jih ima najmanj, in sicer štiri.

Preglednica 12: Generiranje posnetka RGB in legende

Program	SNAP	ArcMap	QGIS	SAGA GIS
RGB, legenda				
Odpiranje posnetka RGB v poljubnih barvah	Omogočene vnaprej pripravljene kombinacije spektralnih kanalov	Ročno določanje spektralnih kanalov	Omogočene vnaprej pripravljene kombinacije spektralnih kanalov	Ročno določanje spektralnih kanalov
Legenda	Delna izdelava legende	Celotna izdelava legende	Celotna izdelava legende	Celotna izdelava legende

Generiranje posnetkov RGB pomeni prikaz spektralnih kanalov v R (rdeča), G (zeleni) in B (modra) barvi; tako nastane barvni prikaz posnetka. Pri programu SNAP je 12 že vnaprej pripravljenih kombinacij, lahko pa se prilagajajo tudi poljubno. Tudi v programu QGIS je možno izbrati že pripravljene naravne in umetne barve. Pri ostalih programih se ti določajo ročno.

Generiranje legende v programu pospeši postopek prikaza rezultatov. To operacijo omogočajo vsi programi razen SNAP, pri katerem je funkcija generiranja legende omogočena le delno. Pri izvažanju legende v programu SNAP se lahko izvozi barvna paleta z vrednostmi, kjer se lahko prilagaja samo naslov legende.

Preglednica 13: Funkcije za oceno natančnosti

Program	SNAP	ArcMap	QGIS	SAGA GIS
Točke in natančnosti				
Testne točke	Ročno	Ročno	Delno avtomatizirano	Ročno
Matrika napak	NE	DA	DA	NE
Natančnost uporabnika	NE	DA	DA	NE
Natančnost izdelovalca	NE	DA	DA	NE
Povprečna natančnost	NE	DA	DA	NE
Kappa	NE	DA	NE	NE

Referenčne točke je pri vseh programih treba vnesti ročno. Le QGIS omogoča samodejno generiranje točk, pri katerih je še vedno treba določiti razred referenčne točke. SNAP in SAGA GIS generiranja matrike napak in izračunov natančnosti ne omogočata, zato je ta postopek potrebno narediti v drugem programu (npr. Microsoft Excel). ArcMap omogoča vse izračune, medtem ko QGIS ne omogoča izračuna Kappa.

Preglednica 14: Pomoč, ki jo nudijo programi

Program \ Pomoč	SNAP	ArcMap	QGIS	SAGA GIS
Podrobna navodila	DA	DA	DA	DA
Slikovna gradiva	DA	DA	DA	DA
Video navodila	DA	DA	DA	DA
Primeri	DA	DA	DA	DA
Forum	Aktiven	Zelo aktiven	Aktiven	Aktiven

Našteti programi so zelo razširjeni, uporablja jih veliko ljudi, praviloma so razvijalci zelo aktivni pri izboljšanju programa. Programi sproti nastajajo in se nadgrajujejo, obsežna je pomoč, ki je na voljo uporabnikom.

6 ZAKLJUČEK

Namen naloge je bil analizirati uporabnost odprtokodnega programa SNAP za obdelavo satelitskih posnetkov in ga primerjati z drugimi podobnimi odprtokodnimi in komercialnimi programi.

Pri opredelitvi in analizi programskih orodij sem najprej ugotovil, da je struktura mape, ki jo uporablja SNAP, edinstvena. Lasten format program obdeluje in prikaže pregledno, preprosto in uporabno. Nato sem analiziral glavna orodja, ki so pomembna za klasifikacijo in druge postopke, ki so v programu. Glavna delovna okna so predhodno definirana, vendar jih je mogoče poljubno spreminjati. Orodja so, kot v večini podobnih programov, podana v glavni orodni vrstici. Program omogoča veliko funkcij, ki so v postopku obdelave satelitskih posnetkov za uporabnika zelo koristna in praktična. Posebej priročna in pregledna je »pomoč«, ki jo program ponuja.

V nalogi sem predstavil orodja v postopku klasifikacije optičnih satelitskih posnetkov na primeru posnetka Sentinel-2 od začetka, torej uvoza podatkov, do izvoza rezultatov. Pri tem je pomembno, da se obrezovanje posnetka z orodjem *Subset* naredi na začetku obdelave, saj so satelitski posnetki visoke prostorske in spektralne ločljivosti in zato veliki. Orodja za klasifikacijo so si med seboj zelo podobna, v večini se razlikujejo samo po določenih parametrih, ki se spreminjajo glede na metodo. Nekoliko zahtevnejša je bila ocena natančnosti, saj samodejnega orodja za izdelavo matrike napak SNAP ne pozna. Ročno se vnašajo samo referenčne točke in njihova pripadnost v razredu.

Izbral sem si primer satelitskega posnetka in ga klasificiral z vsemi metodami nadzorovane klasifikacije, ki jih program omogoča. Najuspešnejši med njimi sta bili metoda naključni gozdovi in metoda k – najbližji sosed. Obe metodi in metoda največje verjetnosti so dosegle skupno natančnost nad 95 %, torej je rezultat zelo dober. Metodi najkrajše razdalje in spektralnih kotov sta imeli skupno natančnost med 87 % in 90 %, kar je prav tako dober rezultat. Splošno gledano na rezultate, ki so bili pridobljeni pri klasificiranem primeru, so zelo uspešni in bi bili uporabni za nadaljnje analize.

Opravi sem tudi primerjavo med programi SNAP, ArcMap, QGIS in SAGA GIS, ki so pogosto uporabljeni za obdelavo satelitskih posnetkov. Program ArcMap je plačljiv, medtem ko so ostali brezplačni. Kot ugotovitev lahko podam, da je ArcMap med izbranimi programi, ne glede na to, da je plačljiv, najmanj primeren za obdelavo satelitskih posnetkov. SNAP ponuja največji nabor raznolikih metod klasifikacije, hkrati pa omogoča tudi velik nabor orodij za analizo. Še ena izmed pomembnejših funkcij, ki jih ima program in po njej tudi izstopa, so pretvorbe formatov datotek, kjer je na voljo izbira veliko različnih formatov.

Kot glavno in zaključno ugotovitev trdim, da je program SNAP kakovosten, pregleden in enostaven za uporabo ter ponuja širok nabor orodij za klasifikacijo. Prav tako se lahko primerja z zelo dragimi komercialnimi in tudi odprtokodnimi programi in jih v prihodnosti lahko nadomesti za namen obdelave satelitskih posnetkov.

VIRI

Atlassian. 2019. Release Note.

<https://senbox.atlassian.net/secure/ReleaseNote.jspa?projectId=10100&version=12200> (Pridobljeno 3. 7. 2019.)

Breiman, L. 2001. Random Forest. Nizozemska. Machine Learning 45: str. 5-32.

<https://link.springer.com/content/pdf/10.1023%2FA%3A1010933404324.pdf> (Pridobljeno 18. 6. 2019.)

Campbell, J.B., Wynne, R.H. 2011. Introduction to Remote Sensing. 5. izdaja. New York. The Guilford Press: 717 str.

http://dl.gisman.ir/Ebooks/Free/2011/Introduction_to_Remote_Sensing_www.GISman.ir.pdf
(Pridobljeno 2. 5. 2019.)

Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., and Böhner, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, Geosci. Model Dev., 8, 1991-2007, doi:10.5194/gmd-8-1991-2015.

Environmental Systems Research Institute. 2016. ArcMap 10.4, What is image classification?

<https://desktop.arcgis.com/en/arcmap/10.4/extensions/spatial-analyst/image-classification/what-is-image-classification-.htm> (Pridobljeno 2. 5. 2019.)

Environmental Systems Research Institute. 2016. ArcMap 10.4, What is ArcMap?

<http://desktop.arcgis.com/en/arcmap/10.3/main/map/what-is-arcmap-.htm> (Pridobljeno, 24. 6. 2019.)

European Space Agency (ESA). 2019.

<https://www.esa.int/ESA> (Pridobljeno 3. 7. 2019.)

European Space Agency (ESA) Sentinel Online. 2019. Sentinel-2.

<https://sentinel.esa.int/web/sentinel/missions/sentinel-2> (Pridobljeno 8. 8. 2019.)

Frontline Systems. 2019. K-nearest neighbours classification method.

<https://www.solver.com/k-nearest-neighbors-classification-method> (Pridobljeno 18. 6. 2019.)

GitHub. 2019. SNAP.

<https://github.com/senbox-org/snap-desktop/blob/6.x/ReleaseNotes.md#new-in-snap-607> (Pridobljeno 3. 7. 2019.)

Lang, S. 2008. Object-based image analysis for remote sensing applications: modeling reality – dealing with complexity. V: Blaschke, T. (ur.), Lang, S. (ur.), Hay, G. J. (ur.). Object-based image analysis. Berlin, Springer

Langley, S.K., M. Cheshire, H., S. Humes, K. 2001. A comparison of single date and multitemporal satellite image classifications in a semi-arid grassland. Journal of Arid Environments, vol 49, Issue 2, str. 401-411.

<https://www.sciencedirect.com/science/article/abs/pii/S0140196300907717> (Pridobljeno 2. 5. 2019.)

NCSS. 2019. Kappa Test for Agreement Between Two Raters. PASS Sample Size Documentation, Poglavlje 811: str. 811/1-811/12

https://ncss-wpengine.netdna-ssl.com/wp-content/themes/ncss/pdf/Procedures/PASS/Kappa_Test_for_Agreement_Between_Two_Raters.pdf (Pridobljeno 24. 6. 2019.)

Oštir, K., 2006. Daljinsko zaznavanje. Ljubljana: Založba ZRC: 252 str.

<https://iaps.zrc-sazu.si/sites/default/files/9616568728.pdf> (Pridobljeno 2. 5. 2019.)

QGIS. 2019.

<https://www.qgis.org/en/site/about/index.html> (Pridobljeno 24. 6. 2019.)

Rashmi, S., Swapna, A., Venkrat in Ravikiran S. 2014. Spectral Angle Mapper Algorithm for Remote Sensing Image Classification. India. International Journal of Innovative Science, Engineering & Technology, Vol. I Issue 4. Objavljeno junij 2014.

http://ijiset.com/v1s4/IJISSET_V1_I4_27.pdf (Pridobljeno 18. 6. 2019.)

Satellite imaging corporation. 2017. Sentinel-2A (10m) Satellite Sensor.

<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/> (Pridobljeno 10. 4. 2019.)

Saga GIS tutorials.

<https://sagatutorials.wordpress.com/> (Pridobljeno 24. 6. 2019.)

Science toolbox exploitation platform. 2019.

<http://step.esa.int/main/> (Pridobljeno 7. 6. 2019.)

STEP Toolboxes. 2019. SNAP.

<http://step.esa.int/main/toolboxes/snap/> (Pridobljeno 7. 6. 2019.)

STEP forum. 2019. s2tbx.

<https://forum.step.esa.int/c/s2tbx> (Pridobljeno 10. 4. 2019.)

PRILOGE

PRILOGA 1: REZULTAT KLASIFIKACIJE PO METODI NAKLJUČNI GOZDOVI IN MATRIKA NAPAK

PRILOGA 2: REZULTAT KLASIFIKACIJE PO METODI NAJVEČJE VERJETNOSTI IN MATRIKA NAPAK

PRILOGA 3: REZULTAT KLASIFIKACIJE PO METODI MINIMALNE RAZDALJE IN MATRIKA NAPAK


PRILOGA 4: REZULTAT KLASIFIKACIJE PO METODI K – NAJBЛИŽJEGA SOSEDA IN MATRIKA NAPAK

PRILOGA 5: REZULTAT KLASIFIKACIJE PO METODI KDTREE K – NAJBЛИŽJEGA SOSEDA IN MATRIKA NAPAK

PRILOGA 6: REZULTAT KLASIFIKACIJE PO METODI SPEKTRALNIH KOTOV IN MATRIKA NAPAK

PRILOGA 1: REZULTAT KLASIFIKACIJE PO METODI NAKLJUČNI GOZDOVI IN MATRIKA NAPAK

Klasificiran raster



Legenda:

Razredi

0	Gozd
1	Njive
2	Pozidano
3	Travniki
4	Voda

Matrika napak


	Razred	-1	0	1	2	3	4	Klasificirane
-1	Nedoločeno		1				3	4
0	Gozd		88					88
1	Njive			38				38
2	Pozidano			2	31			33
3	Travniki					53		53
4	Voda				1		31	32
	Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	88	88	98,9	100,0
Njive	40	38	38	95,0	100,0
Pozidano	32	33	31	96,9	93,9
Travniki	53	53	53	100,0	100,0
Voda	34	32	31	91,2	96,9
Skupaj	248	244	241		
Povprečje				96,4	98,2

PRILOGA 2: REZULTAT KLASIFIKACIJE PO METODI NAJVEČJE VERJETNOSTI IN MATRIKA NAPAK

Klasificiran raster



Legenda:

Razredi

0	Gozd
1	Njive
2	Pozidano
3	Travniki
4	Voda

Matrika napak

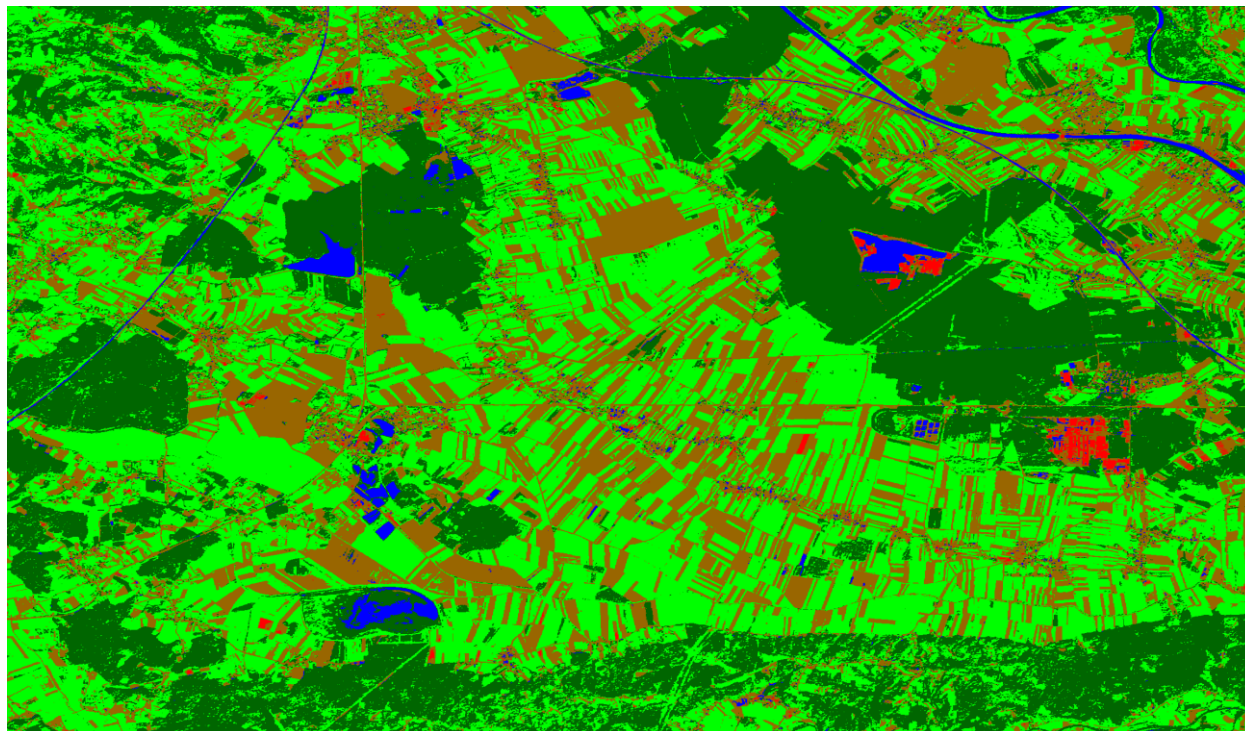
	Razred	-1	0	1	2	3	4	Klasificirane
-1	Nedoločeno							0
0	Gozd		85			1		86
1	Njive			36	1	8		45
2	Pozidano		4	4	31		7	46
3	Travniki		1			44		45
4	Voda						27	27
	Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	86	85	95,5	98,8
Njive	40	45	36	90,0	80,0
Pozidano	32	46	31	96,9	67,4
Travniki	53	45	44	83,0	97,8
Voda	34	27	27	79,4	100,0
Skupaj	248	249	223		
Povprečje				89,0	88,8

PRILOGA 3: REZULTAT KLASIFIKACIJE PO METODI MINIMALNE RAZDALJE IN MATRIKA NAPAK

Klasificiran raster



Legenda:

Razredi

0	Gozd
1	Njive
2	Pozidano
3	Travniki
4	Voda

Matrika napak


Razred	-1	0	1	2	3	4	Klasificirane
-1 Nedoločeno							0
0 Gozd		86					86
1 Njive			40	9	1	1	51
2 Pozidano				20			20
3 Travniki		3			52		55
4 Voda				3		33	36
Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	86	86	96,6	100,0
Njive	40	51	40	100,0	78,4
Pozidano	32	20	20	62,5	100,0
Travniki	53	55	52	98,1	94,5
Voda	34	36	33	97,1	91,7
Skupaj	248	248	231		
Povprečje				90,9	92,9

PRILOGA 4: REZULTAT KLASIFIKACIJE PO METODI K – NAJBЛИŽJEGA SOSEDA IN MATRIKA NAPAK

Klasificiran raster



Legenda:

Razredi

0	Gozd
1	Njive
2	Pozidano
3	Travniki
4	Voda

Matrika napak


	Razred	-1	0	1	2	3	4	Klasificirane
-1	Nedoločeno							0
0	Gozd		89					89
1	Njive			40		3		43
2	Pozidano				32		4	36
3	Travniki					50	1	51
4	Voda						29	29
	Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	89	89	100,0	100,0
Njive	40	43	40	100,0	93,0
Pozidano	32	36	32	100,0	88,9
Travniki	53	51	50	94,3	98,0
Voda	34	29	29	85,3	100,0
Skupaj	248	248	240		
Povprečje				95,9	96,0

PRILOGA 5: REZULTAT KLASIFIKACIJE PO METODI KDTREE K – NAJBЛИŽJEGA SOSEDA IN MATRIKA NAPAK

Klasificiran raster



Legenda:		
Razredi		
	0	Gozd
	1	Njive
	2	Pozidano
	3	Travniki
	4	Voda

Matrika napak


	Razred	-1	0	1	2	3	4	Klasificirane
-1	Nedoločeno							0
0	Gozd		89					89
1	Njive			39		2		41
2	Pozidano			1	32		4	37
3	Travniki					51	1	52
4	Voda						29	29
	Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	89	89	100,0	100,0
Njive	40	41	39	97,5	95,1
Pozidano	32	37	32	100,0	86,5
Travniki	53	52	51	96,2	98,1
Voda	34	29	29	85,3	100,0
Skupaj	248	248	240		
Povprečje				95,8	95,9

PRILOGA 6: REZULTAT KLASIFIKACIJE PO METODI SPEKTRALNIH KOTOV IN MATRIKA NAPAK

Klasificiran raster



Legenda:

Razredi

0	Gozd
1	Njive
2	Pozidano
3	Travniki
4	Voda

Matrika napak

	Razred	-1	0	1	2	3	4	Klasificirane
-1	Nedoločeno							0
0	Gozd		82			2	1	85
1	Njive			36	6	4	6	52
2	Pozidano			4	26			30
3	Travniki		7			47		54
4	Voda						27	27
	Referenčne		89	40	32	53	34	

Izračun natančnosti izdelovalca in uporabnika

Razred	Referenčne	Klasificirane	Pravilno	Natančnost (%)	
				Izdelovalec	Uporabnik
Gozd	89	85	82	92,1	96,5
Njive	40	52	36	90,0	69,2
Pozidano	32	30	26	81,3	86,7
Travniki	53	54	47	88,7	87,0
Voda	34	27	27	79,4	100,0
Skupaj	248	248	218		
Povprečje				86,3	87,9