

Raspoznavanje tipa terena na temelju satelitskih snimki

Mučaj, Klaudija

Undergraduate thesis / Završni rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:200:944175>

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

*Download date / Datum preuzimanja: **2024-04-29***

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science
and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA**

Sveučilišni studij

**RASPOZNAVANJE TIPA TERENA NA TEMELJU
SATELITSKIH SNIMKI**

Završni rad

Klaudija Mučaj

Osijek, 2019. g.

SADRŽAJ

1. UVOD	1
1.1. Zadatak završnog rada.....	1
2. RASPOZNAVANJE TIPA TERENA.....	2
2.1. Načini snimanja	2
2.2. Povijesni razvoj.....	3
2.3. Baze slika	4
2.4. Primjena	6
3. POSTUPCI STROJNOG UČENJA ZA RASPOZNAVANJE TIPA TERENA.....	7
3.1. Predobrada.....	8
3.2. Značajke.....	9
3.2.1. Značajke teksture slike	9
3.2.2. Indeksi vegetacije	10
3.3. Klasifikatori.....	11
3.3.1. Metoda vektora podrške	12
3.3.2. Stablo odluke.....	13
3.3.3. Slučajne šume	14
3.3.4. Algoritam k najbližih susjeda.....	15
3.4. Vrednovanje	16
4. PROGRAMSKO RJEŠENJE	19
4.1. Korištene biblioteke	19
4.2. Postavke eksperimenta	20
4.3. Analiza rezultata.....	21
5. ZAKLJUČAK.....	29
LITERATURA	30
SAŽETAK.....	33
ABSTRACT	34
ŽIVOTOPIS.....	35
PRILOZI.....	36

1. UVOD

Pojam pokrova zemljišta je prema [1] definiran kao svaki promatrani fizički ili biološki pokrov Zemljine površine, što uključuje umjetne površine, poljoprivredna područja, šume, (polu-) prirodna područja, močvare, vodena tijela i drugo. Znanstvenici u posljednjih nekoliko desetljeća prikupljaju podatke o različitim tipovima zemljišta kako bi mogli mapirati, kontrolirati i procjenjivati šira područja (zemljišta) [1], kao i za praćenje promjena našeg okoliša. U početku je proces prikupljanja podataka bio dugotrajan i neisplativ, no razvojem tehnologije on postaje mnogo dostupniji. Nova tehnologija za prikupljanje podataka o pokrovu zemljišta podatke najčešće dostavlja kao slike. Ali proces mapiranja i dalje zahtjeva mnogo vremena. Paralelno je tekao i razvoj strojnog učenja, zbog čega su se znanstvenici krenuli baviti problemom klasifikacije tipova terena, odnosno raspoznavanja tipa terena. Htjeli su osmisliti neki algoritam koji bi mapirao Zemlju brže nego ljudi. Ovime nastaju nova pitanja, kao što su kako će se pojedini tipove terena definirati, koji je najučinkovitiji algoritam, na koji način će se izvlačiti podaci iz slika, i mnoga druga. U ovom će se radu neki postupci i koraci razvijanja učinkovitog modela strojnog učenja za raspoznavanje tipa terena opisivati, i ocjenjivat će se četiri različita klasifikatora kako bi se otkrilo koji je učinkovitiji za ovaj problem.

Najčešći načini prikupljanja podataka, razvoj problema raspoznavanja tipa terena, te primjena i važnost raspoznavanja tipa terena će biti prikazani u drugom poglavlju. Također, u drugom će se poglavlju predstaviti baza podataka korištena u ovom radu. Zatim će u trećem poglavlju biti objašnjen način na koji se podaci pripremaju za klasifikator te opisani klasifikatori koji su odabrani za uspoređivanje, kao i način njihova vrednovanja. U četvrtom se poglavlju postavlja eksperiment i analiziraju njegovi rezultati. Zaključak donosi razmatranja vezana uz uspješnost klasifikatora te smjernice za budući rad.

1.1. Zadatak završnog rada

U teorijskom dijelu rada potrebno je opisati postupke i korake strojnog učenja za klasifikaciju terena na temelju satelitskih snimki. U praktičnom dijelu rada usporediti uspješnost različitih postupaka na podatkovnom skupu satelitskih snimaka dostupnih iz literature.

2. RASPOZNAVANJE TIPOA TERENA

Daljinsko očitavanje je područje znanosti koje se bavi prikupljanjem informacija o značajkama objekata bez stupanja u ikakav fizički kontakt sa njima pomoću elektromagnetskih, toplinskih i radio valova, te analizom tih podataka [2]. Postoje razne tehnologije kojima se ti podaci skupljaju, neke od njih su Dopplerov radar, LIDAR, radiometri, fotometri, sateliti, i mnoge druge [3]. Upravo se zahvaljujući tim tehnologijama mogu skupljati i podaci o Zemlji. Točnije, podaci o Zemlji se mogu skupljati onim tehnologijama koje koriste elektromagnetske valove. Upravo zbog činjenice što se njima mogu skupljati podaci o Zemlji, uređaji za daljinsko očitavanje imaju veliku ulogu u mapiranju zemljšnog pokrova kroz proces raspoznavanja tipa terena.

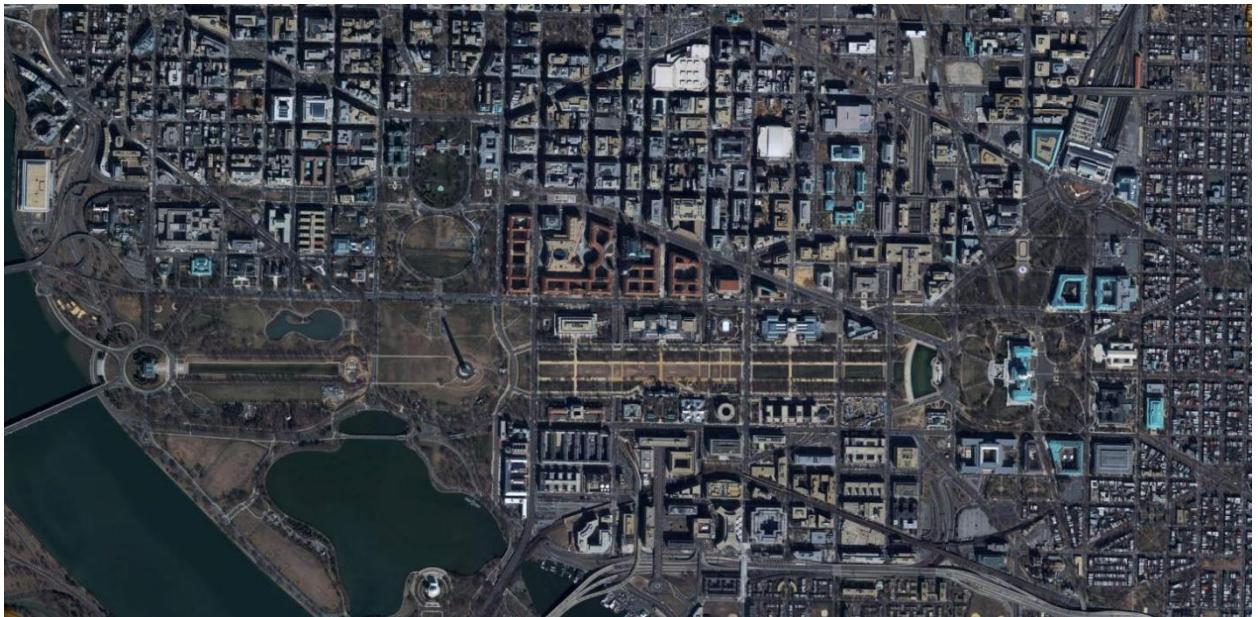
Raspoznavanje tipa terena je proces koji promatranim geografskim područjima, odnosno grupiranim pikselima dodjeljuje klasu u koju pripadaju, i to na temelju podataka prikupljenih daljinskim očitavanjem. Prepoznavanje Zemljine površine sa satelitskih snimaka, te njenog mapiranje je glavni cilj raspoznavanja tipa terena. Raspoznavanje tipa terena se temelji na klasifikaciji slika, što je proces dodjeljivanja oznaka pikselima slike.

Učinkovitost raspoznavanja tipa terena uvelike ovisi o kvaliteti prikupljenih podataka, zbog čega se znanstvenici u posljednjih nekoliko desetljeća i danas trude unaprijediti uređaje kojima se skupljaju podaci o Zemlji.

2.1. Načini snimanja

Kao što je u uvodu rečeno, postoji mnogo različitih tehnologija i načina kojima se prikupljaju podaci o Zemlji. Najčešće se ti podaci prikupljaju u obliku slika, snimljene iz zrakoplova ili, češće, satelita. Satelit je općenito bilo koji objekt koji kruži oko nekog planeta ili zvijezde. On može biti prirodan ili umjetan. Primjer prirodnih satelita su mjeseci koji kruže razne planete, poput Jupiterovih mjeseca, ali i sam Jupiter, jer on kruži oko Sunca. No, prirodni sateliti ne omogućavaju prikupljanje podataka o planetima koje kruže. U tu svrhu služe umjetni sateliti, koji se definiraju kao strojevi koji su namjerno postavljeni u Zemljinoj orbiti, ili orbiti nekog drugog planeta [4]. Točnije, sateliti koji se nalaze u Zemljinoj orbiti i koji služe za promatranje Zemlje se nazivaju sateliti za promatranje Zemlje. Upravo ta vrsta satelita omogućuje znanstvenicima prikupljanje većeg broja podataka o Zemlji i to brže od instrumenata na Zemlji, najčešće u obliku slika. Te se slike nazivaju satelitske slike. Kako bi sateliti uspjeli prikupiti informacije na razini cijele Zemlje, moraju se nalaziti na polarnoj orbiti.

Većina umjetnih satelita sadržavaju dva ista glavna dijela: antenu za odašiljanje i primanje informacija, te izvor napajanja. No, uz to, radi prikupljanja informacija o Zemlji, sateliti sadržavaju kamere i različite senzore. Na slici 2.1. prikazana je slika Washington DC-a iz 2002. godine snimljene satelitom. Iako LIDAR tehnologija omogućuje određivanje povišenosti objekata, ne omogućuje učinkovito prepoznavanje tipa terena, dok satelitske snimke to omogućavaju.



Slika 2.1. Satelitska snimka Washington, DC [5]

2.2. Povijesni razvoj

Karte pokrovnosti zemljišta su se u prošlosti dobivale terenskim istraživanjima, odnosno znanstvenici su odlazili do nekog područja i bilježili su o kojem se tipu terena radi. Takav način skupljanja podataka se dokazao kao dugotrajan i neekonomičan proces na razini regije [6]. Pojavom prvih satelita, znanstvenici su se okrenuli snimanju zemljine površine pomoću senzora u satelitu, kako bi se pomoću tih podataka moglo prepoznati o kojem se tipu terena radi. Tako je već 1972. godine, 15 godina nakon lansiranja prvog umjetnog satelita, lansiran Landsat 1 satelit, prvi u nizu NASA-ih satelita programa Landsat. Landsat je program čiji je jedan od mnogih ciljeva kontinuirano pružanje zapisa Zemljine površine [7]. Landsat 1 je jedan od prvih satelita koji je, zbog činjenice da svaki tip terena reflektira različite oku vidljive i nevidljive valne duljine, bio opremljen multi spektralnim skenerom.

Landsat 1 je bio poticaj mnogim drugim vladinim organizacijama i agencijama SAD-a, kao i komercijalnim tvrtkama, za lansiranje svojih satelita. Naravno, i druge zemlje svijeta su krenule sa razvijanjem svojih satelita. Neke od poznatijih organizacija, agencija, tvrtaka i programa su:

Nacionalna uprava za oceane i atmosferu ili NOAA (engl. *National Oceanic and Atmospheric Administration*) čije se snimke koriste za istraživanje oceana; GeoEye čije se snimke satelita Ikonos-2 koriste za mapiranje urbanih i ruralnih prirodnih resursa, te prirodnih katastrofa; snimke visoke rezolucije za provjeru procjene pokrova zemljišta pruža satelit QuickBird tvrtke Digital Globe; Copernicus, program promatranja Zemlje kojim upravlja Europska komisija zajedno sa Europskom svemirskom agencijom; Europska agencija za okoliš koordinira projekt CORINE Pokrov Zemljišta (engl. *CORINE Land Cover*), koji pruža prikaz cijelog kontinenta Europe; i mnoge druge. Iako svaka organizacija, agencija i tvrtka ima svoje satelite, sve one imaju više zajednički ciljeva, kao što je mapiranje pokrovnosti Zemlje.

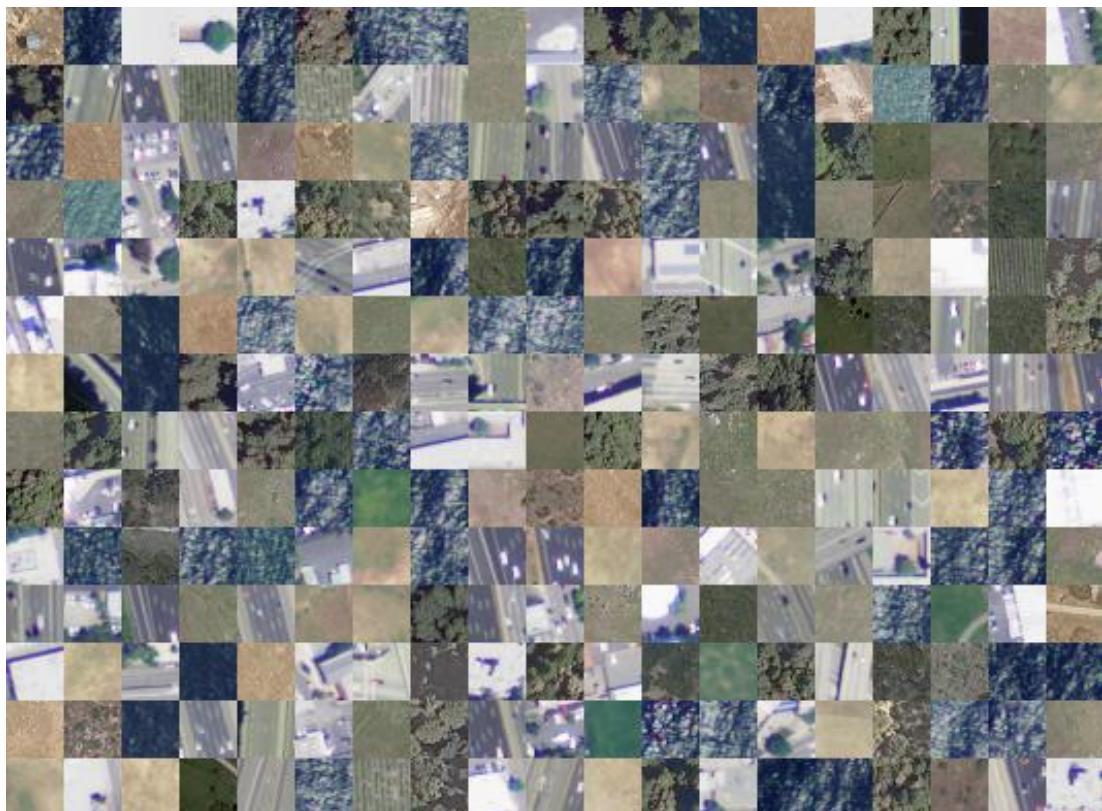
U početku su se karte pokrova zemljišta dobivale pomoću AVHRR podataka NOAA-inih satelita. Iz njihovih se podataka izdvajao NDVI koeficijent. Ubrzo je dokazano kako je za pravilno klasificiranje tipova terena pomoću NDVI koeficijenata nekog područja potrebno imati podatke, odnosno snimke tog područja kroz duže vremensko razdoblje [8]. Razlog tome je što na iznos NDVI koeficijenta utječu vremenske prilike u trenutku snimanja, odnosno je li bilo kišovito, oblačno ili sunčano. No, razvojem tehnologije dobivanje slika visoke rezolucije iz satelita je postalo dostupnije. Ti sateliti, uz uobičajene RGB (engl. *Red, Green, Blue*) senzore, u sebi najčešće sadržavaju i dodatne senzore za nevidljivi spektar svjetlosti. Ti se dodatni senzori ugrađuju zbog činjenice da svaki tip terena upija i reflektira različite valne duljine svjetlosti, pa čak i one nevidljive ljudskom oku.

Upravo napredak u tehnologiji utječe i na napredak u stvaranju sustava koji će sa visokom učinkovitosti prepoznавати tipove terena. Prvi takav sustav je bio klasifikacijski sustav zemljine površine Anderson, kojeg je razvio USGS. On omogućava raspoznavanje devet kategorija zemljine površine, ali mu preciznost varira između 38% i 62% [9]. Stoga znanstvenici kreću sa razvijanjem metoda za klasifikaciju tipa terena, koji će imati visoku preciznost. Istraživanjem raznih radova uočava se kako su najčešće korišteni modeli klasifikacije klasifikator maksimalne vjerojatnosti ili MLC (engl. *maximum likelihood classifier*) (na primjer Townshend 1992 [10]), neuronske mreže (na primjer [11]), stablo odluke (na primjer [12]), te SVM (na primjer [13]). No, u posljednjih nekoliko godina znanstvenici sve više koriste vjerojatnosnu klasifikaciju zemljišta (engl. *probabilistic land cover classifications*), za koje je dokazano da zadržavaju više informacija iz slika [14]. Duboko učenje se također sve više koristi za prepoznavanje tipa terena, kao što je prikazano u [15].

2.3. Baze slika

Jedan od većih problema u procesu raspoznavanja tipa terena je pronađak kvalitetne baze podataka. Naime, iako su razne baze satelitskih snimaka dostupne na internetu, veliki dio njih nije označen, odnosno na njima nisu označeni tipovi terena koji se nalaze na slikama. Upravo je ta oskudnost označenih podataka jedan od razloga zbog kojega je razvoj raspoznavanja tipa terena bio usporen.

Baze slika koje se koriste u ovom radu su razvijene za rad [16]. Autori tog rada su iz Nacionalnog programa poljoprivrednih slika (engl. *National Agriculture Imagery Program, NAIP*) preuzeli ukupno 1500 satelitskih slika na kojima svaki pojedini piksel predstavlja jedan metar kvadratni. Satelit kojim su te slike snimljene je sadržavao senzore za prepoznavanje četiri valnih duljina: crvenu, zelenu i plavu boju, te valne duljine u blizini infracrvene boje ili NIR (engl. *near infrared*). Na tim su se slikama, dimenzija 6000x7000 piksela, prvo ručno, pomoću specijaliziranog alata, određivali tipovi terena. Nakon toga su one „razrezane u krpice“ dimenzija 28x28 piksela, čime je dobiveno ukupno 905,000 sličica. Te sličice su zatim podijeljene u dvije baze: SAT-4 i SAT-6. Razlika između njih je ta što su u SAT-4 bazi označena 4 tipa terena, dok su u SAT-6 označena 6 tipa terena. Za ovaj rad odabrana je baza SAT-4. Na slici 2.2. su prikazani primjeri slika koji se nalaze u bazama.



Slika 2.2. Primjeri slika koje se nalaze u bazi [16]

Baza SAT-4 se sastoji od ukupno 500,000 sličica. Svaka sličica predstavlja jedan od mogućih četiri tipa terena: neplodna zemlja, drveće, travnjak i klasu koju čine svi ostali tipovi terena. Od tih 400,000 sličica 100,000 je korišteno u ovom radu. 80,000 je korišteno za treniranje različitih klasifikatora, dok je 20,000 korišteno za njihovo testiranje.

2.4. Primjena

Glavni cilj klasifikacije satelitskih snimaka je prepoznavanje Zemljine površine i njihova reprezentacija u obliku tematskih karata [17]. Ovime proizlazi pitanje zašto organizacije i znanstvenici troše toliko resursa i vremena na stvaranju takvih karata. Jedan od većih razloga je da bi znanstvenici mogli predvidjeti kako će ekosustavi Zemlje reagirati na klimatske promjene. Naime, na Zemljine cikluse klime, ugljika i vode svaki tip zemljišnog pokrova drugačije djeluje. Poznato je i da promjene zemljišnog pokrova utječu na zdravlje čovjeka, ekonomiju i okoliš [18], a duže vremensko mapiranje pokrovnosti pomaže u praćenju tih promjena, bilo da su one nastale prirodnim putem ili ljudskim aktivnostima. Praćenje promjena u zemljišnom pokrovu također pomaže i u sprječavanju budućih katastrofa, prikupljanju informacija o okolišu, te praćenju prirodnih resursa. Ali, na koji je to način moguće pratiti „količinu“ prirodnih resursa pomoću promjena zemljišnog pokrova? Na vrlo jednostavan način. Na primjer, neka satelitske snimke nekog područja Zemlje od prije četiri mjeseca prikazuju manju šumu, dok snimke od prije mjesec dana prikazuju kako pola te šume više nema. Na temelju te promjene može se zaključiti kako je ta manja šuma najvjerojatnije krčena i da se prirodni resurs drva tog područja smanjio. Praćenje promjena zemljišnog pokrova također pomaže i u očuvanje rijetkih staništa, obnavljanju šuma, te procjenu populacije raznovrsnih životinja.

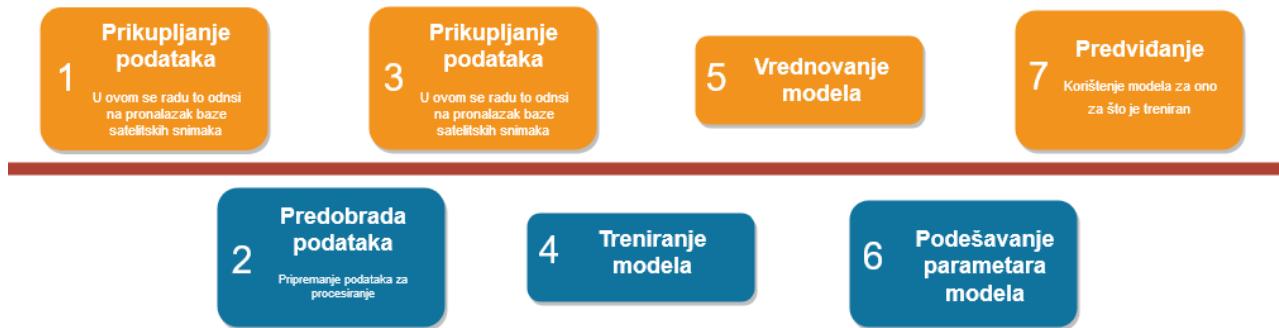
3. POSTUPCI STROJNOG UČENJA ZA RASPOZNAVANJE TIPOVIMA TERENA

Strojno učenje su kroz njegovu povijest stručnjaci definirali na više različitih načina. No, većina se tih definicija može sažeti u jednoj rečenici: „Strojno učenje je zbirka algoritama i tehnika koje se koriste za stvaranje računalnih sustava koji, kako bi mogli predvidjeti i zaključiti, uče iz podataka.“ [19]. U današnje se vrijeme čovjek u svakodnevnom životu susreće sa strojnim učenjem. Na primjer, YouTube ima algoritam koji nam na temelju videozapisa koji su pregledani predlaže nove videozapise za koje predviđa da će se korisniku svidjeti. Također, usluge elektroničke pošte imaju algoritme koji mogu prepoznavati neželjenu poštu i premještati ju u posebnu mapu. Osim što se strojno učenje upotrebljava za olakšavanje svakodnevnog života, ono se primjenjuje i u rješavanju raznih problema, kao što su optimizacija, prepoznavanje govora, medicinska dijagnostika, prepoznavanje slika, klasifikacija i mnogih drugih.

Ranije je rečeno kako je raspoznavanje tipa terena tema koju obuhvaća problem klasifikacije slika, odnosno ono je proces prepoznavanja kojem tipu terena pripada pojedini piksel na slici [20]. Tip terena se može sa slike prepoznavati na dva načina, odnosno postoje dvije vrste klasifikacije tipa terena [15]:

- Klasifikacija na razini slike – klasifikacija pojedinačnih slika iz skupa satelitskih snimaka
- Klasifikacija na razini piksela – klasifikacija svakog piksela satelitske snimke.

Iako su to dvije različite vrste klasifikacije, postupci kojima se one postižu su jednake kao i za sve algoritme strojnog učenja. Ti postupci su, prema [21], prikazani na slici 3.1..



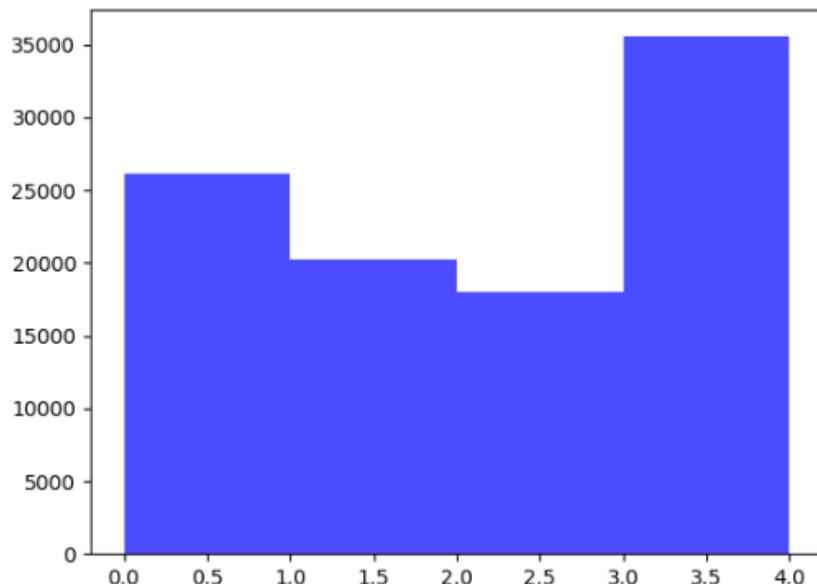
Slika 3.1. Postupci strojnog učenja

U nastavku se malo detaljnije prolazi kroz neke od navedenih koraka, iako je za izradu programskog rješenja bilo potrebno proći kroz svaki korak.

3.1. Predobrada

Strojno učenje ne bi bilo moguće bez kvalitetnih prikupljenih podataka iz kojih će model učiti. No, podaci prikupljeni iz stvarnog svijeta nisu savršeni, znaju biti nepotpuni, često im nedostaju neke vrijednosti, prirodne prilike utječu na njih i drugo. Zbog toga je predobrada sirovih podataka jedan od najvažnijih koraka strojnog učenja. Predobradom podataka se nedostatci sirovih podataka pokušavaju minimizirati, čime se dobivaju podaci koji su spremi za daljnje procesiranje. Predobrada podataka uključuje transformaciju podataka, njihovo čišćenje, normalizaciju, izdvajanje i odabir značajki, i mnogo drugo [22]. Predobradom podataka se dobiva konačni skup podataka za trening, koji se prosljeđuje modelu kako bi učio iz njega.

Na slici 3.2. je prikazan histogram raspodjele pojedinog tipa terena u korištenoj bazi podataka. Histogram je graf koji prikazuje frekvenciju pojedinih grupa podataka, odnosno njihovu raspodjelu. Koristi se za analizu podataka, točnije za analizu distribucije podataka, odstupanja pojedinih primjera, te nesimetričnost podjele podataka. Iz slike se može vidjeti kako su ostali tipovi terena najzastupljeniji u bazi, dok je slika travnjaka najmanje. Ta nesimetrična podjela podataka može utjecati na klasifikator na način da klasifikator ne nauči najbolje prepoznavati travnjake. Iako je izdvajanje značajki predstavlja dio predobrade podataka, u idućem su poglavlju opisane neke od najznačajnijih metoda izdvajanja značajki.



Slika 3.1. Histogram podjele tipova terena: interval $[0, 1]$ predstavlja neplodnu zemlju; interval $[1, 2]$ predstavlja drveće; interval $[2, 3]$ predstavlja travnjak; interval $[3, 4]$ predstavlja ostale tipove terena

3.2. Značajke

Prema [23], značajka je u strojnom učenju definirana kao mjerljiva osobina objekta koji se trenutno promatra i pokušava analizirati, dok se sam proces izdvajanja značajki naziva inženjerstvo značajki (engl. *feature engineering*). Značajke se izdvajaju kada podaci sadrže mnogo suvišnih informacija, što je teško izbjegći. Upravo se zbog toga izdvajanje i odabir značajki smatra jednim od najbitnijih dijelova predobrade. Općenito se iz slika može izdvojiti veliki broj informacija, no istraživanjem literature otkriveno je kako su informacije o teksturi slike, te iznosi indeksa vegetacije najčešće izdvojene za algoritme raspoznavanja tipa terena [16].

3.2.1. Značajke teksture slike

U obradi slike se tekstura definira kao „varijacija podataka manjih razmjera od razmjera predmeta interesa“ [24], čime se pružaju informacije o prostornom rasporedu boja ili intenziteta na slici. Tako one omogućavaju detektiranje rubova između različitih objekata na slici, kontrast, korelaciju, entropiju i drugo. Detekcija rubova je vrlo korisna kada se iz satelitske snimke nekog područja pokušava prepoznati koji se tipovi terena nalaze na toj slici. No, u ovom se radu koristi baza slika u kojoj svaka pojedina slika predstavlja jedan tip terena, zbog čega neće biti potrebno detektirati rubove.

Kako bi se iz slike mogle izdvojiti pojedine značajke teksture, prvo je potrebno pronaći matricu podudaranja razina sive boje (engl. *gray level cooccurrence matrix*). Neka N označava broj razina sive boje, a P matricu podudaranja razina sive boje. Iz matrice podudaranosti sivih razina mogu se izdvojiti takozvane Haralickove značajke teksture. Haralickove značajke teksture su set od 14 značajki teksture koje su 1973. godine predložene u [25]. Od njih 14, za potrebe ovog rada odabrano je 6 značajki: drugi kutni moment, homogenost, kontrast, različitost, energija i korelacija. Prema [26] i [27] se odabrane značajke teksture dobivaju koristeći iduće izraze:

- Drugi kutni moment ili ASM (engl. *angular second moment*)

$$ASM = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j}^2 \quad (3 - 1)$$

- Homogenost ili HOM (engl. *homogeneity*)

$$HOM = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P_{i,j}}{1 + (i-j)^2} \quad (3 - 2)$$

- Kontrast ili CON (engl. *contrast*)

$$CON = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j} * (i - j)^2 \quad (3 - 3)$$

- Različitost ili DIS (engl. *dissimilarity*)

$$DIS = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j} * |i - j| \quad (3-4)$$

- Energija ili ENG (engl. *energy*)

$$ENG = \sqrt{ASM}$$

- Korelacija ili COR (engl. *correlation*)

$$COR = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{(i - \mu_i) * (j - \mu_j) * P_{i,j}}{\sigma_i * \sigma_j}, \quad (3-5)$$

gdje su:

- μ_i, μ_j – srednja vrijednost razina sive boje, koje se dobivaju idućim izrazima:

$$\mu_i = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i * P_{i,j} \quad (3-6)$$

$$\mu_j = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} j * P_{i,j} \quad (3-7)$$

- σ_i, σ_j – standardna devijacija razina sive boje, koje se dobivaju idućim izrazima:

$$\sigma_i = \sqrt{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j}(i - \mu_i)^2} \quad (3-8)$$

$$\sigma_j = \sqrt{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j}(j - \mu_j)^2} \quad (3-9)$$

3.2.2. Indeksi vegetacije

Prema [28] indeksi vegetacije su kombinacije dvije ili više valnih duljina reflektiranih s površine izvedeni korištenjem svojstava refleksije vegetacije. Dizajnirane su za isticanje određenih svojstava vegetacije, zbog čega svaki indeks naglašava određeno svojstvo vegetacije. U ovom su radu korištena 3 različita indeksa, to su: normalizirani indeks vegetacije (procjenjuje sadržava li promatrano područje vegetaciju), poboljšani indeks vegetacije (optimizirani indeks vegetacije) i indeks atmosferske otpornosti (indeks koji minimizira učinke atmosferskog raspršenja). Za pojedinu se sliku računaju pomoću njenih vrijednosti vidljive svjetlosti (crvene, zelene i plave boje) i nevidljive svjetlosti (NIR zraka), i to na način [16]:

- Normalizirani indeks vegetacije ili NDVI (engl. *Normalized Difference Vegetation Index*)

$$NDVI = \frac{NIR - Crvena}{NIR + Crvena} \quad (3-10)$$

- Poboljšani indeks vegetacije ili EVI (engl. *enhanced vegetation index*)

$$EVI = G * \frac{NIR - Crvena}{NIR + c_{crvena} * Crvena - c_{plava} * Plava + L}, \quad (3 - 11)$$

gdje su G , c_{crvena} , c_{plava} i L predefinirane konstante redom iznosa 2.5, 6, 7.5 i 1.

- Indeks atmosferske otpornosti ili ARVI (engl. *atmospherically resistant vegetation index*)

$$ARVI = \frac{NIR - (2 * Crvena - Plava)}{NIR + (2 * Red + Plava)} \quad (3 - 12)$$

3.3. Klasifikatori

U prethodnom je poglavlju utvrđeno kako za prepoznavanje tipa terena na temelju satelitskih snimaka postoji mnogo različitih metoda i algoritama strojnog učenja koji se koriste. U ovom će se radu ocjenjivati četiri algoritma strojnog učenja za klasifikaciju, koji se češće nazivaju klasifikatori. Četiri algoritma koja će se uspoređivati su: metoda vektora podrške, stablo odluke, slučajna šuma i model k najблиžih susjeda. To su algoritmi koji se u literaturi najčešće koriste za nadziranu klasifikaciju.

Klasifikacija je u strojnem učenju, a i u statistici, problem prepoznavanja pripadnosti nekog novog objekta jednom od definiranih razreda. Ali prije nego što mogu odlučiti, algoritmi moraju naučiti razlikovati te razrede. Na primjer, za prepoznavanje mačaka i pasa algoritmu se prvo mora dostaviti više primjera mačaka i više primjera pasa. Taj se skup primjera naziva trening skup. Na njima klasifikator uči razlike između njih, odnosno uči ih prepoznavati. Radi provjere točnosti prepoznavanja pojedine klase, klasifikatoru se donose slike koje do sada nije vidi, jer će one nad kojima je trenirao lakše prepoznati, nego nove. Taj se skup naziva testni skup.

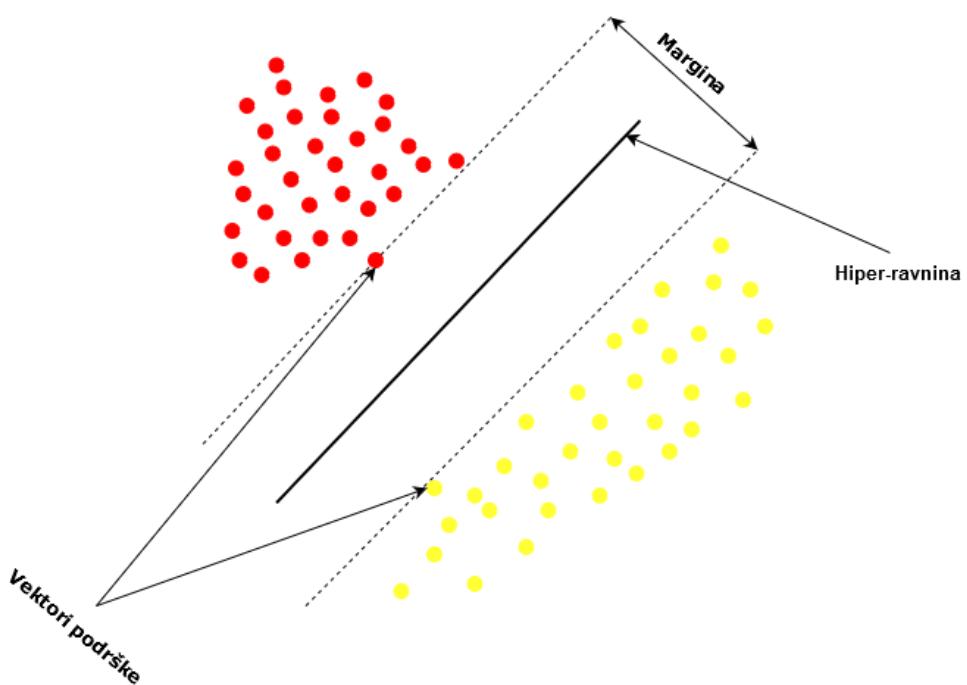
Nadzirana klasifikacija je klasifikacija koja ima trening skup kojem se unaprijed znaju očekivane vrijednosti izlaza, s obzirom na ulaz koji je dan klasifikatoru [19]. Drugim riječima, uz ulaze x (na primjer slike pojedinog objekta) poznati su i izlazi Y (klase koje klasifikator treba naučiti prepoznavati), i s obzirom na njih pronalazi se funkcija koja najbolje opisuje ovisnost $Y=f(x)$, odnosno funkcija koja najučinkovitije daje točne rezultate.

Uz nadziranu, postoji i nenadzirana klasifikacija. Nenadzirana klasifikacija ima trening skup na kojem su podaci neoznačeni. Odnosno, u nenadziranoj klasifikaciji za pojedini objekt nije unaprijed poznato kojoj klasi pripada [19].

3.3.1. Metoda vektora podrške

Metoda vektora podrške ili SVM (support vector machine) je nadzirani model učenja koji je primjenjiv u klasifikaciji i problemima regresije. Cilj SVM-a je pronaći hiper-ravninu koja će optimalno razdvajati klase. To se postiže pronalaženjem maksimalne moguće udaljenosti od podataka pojedinih klasa. Odnosno, potrebno je pronaći najveću moguću marginu. Marginu je udaljenost između hiper-ravnine i najbližih joj podataka.

Bilo bi dobro objasniti i zašto se metoda vektora podrške tako zove. Naime, podatke, s obzirom na koje se računa margina, se mogu promatrati kao vektori, čime se računanje margine svodi na računanje udaljenosti dvaju vektora. Ta dva vektora se nazivaju vektorima podrške (slika 3.3.).



Slika 3.3. Prikaz SVM-a , napravljeno prema uzoru na [29]

SVM je i binarni model, što znači da klasifikator može razlikovati dvije različite klase. No, prepoznavanje više različitih klasa se postiže reduciranjem problema klasifikacije više klasa na više problema binarnih klasifikacija. Za to postoji dva načina: jedan protiv svih (engl. *one-vs.-rest*, *OvR*) i jedan protiv jedan (engl. *one-vs.-one*, *OvO*).

Jedan protiv svih ili OvR trenira klasifikator na način da za svaku od N klasa određuje hiper-ravninu kojom ju razdvaja od ostalih klasa. Time se dobiva N različitih hiper-ravnina. Jedan protiv jedan ili OvO klasifikator uči razlikovati različite parove klasa, odnosno uči razlikovati prvu klasu od druge, prvu klasu od treće, drugu od treće, i tako dalje. Time se za N različitih klasa dobiva $N(N-1)/2$ različitih hiper-ravnina.

3.3.2. Stablo odluke

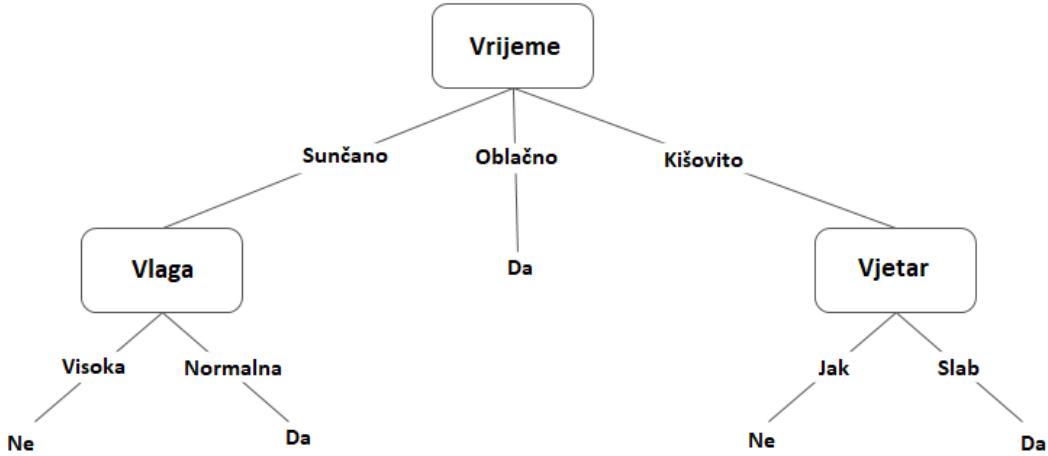
Stablo odluke je nadzirani model učenja koji je primjenjiv i u problemima regresija i u klasifikaciji, poput SVM-a. Ono na osnovi raznih uvjeta identificira načine na koje će podijeliti podatke. Razlog zbog kojega se ovaj model zove stablo odluke je jer na kraju podjele poprimi oblik stabla. Poput stabla, ima unutarnje i vanjske čvorove te grane. Unutarnji čvorovi predstavljaju ispitivanje nekog svojstva, grane odgovore na to ispitivanje, a vanjski čvorovi predstavljaju oznaku klase. Model stabla odluke je vrlo jednostavan i intuitivan čovjeku, zbog čega je jedna od najčešće korištenih metoda nadziranog učenja, što je prikazano na idućem primjeru.

Neka neki rekreativni igrač tenisa igra samo onim danima kada su određeni uvjeti zadovoljeni. Skupljanjem i analizom podataka o danima kada je igrao tenis i danima kada ga nije igrao, koji su predstavljeni u tablici 3.1., može se lako otkriti kojim danima igrač igra, a kojima ne igra. Umjesto da se svaki novi dan uspoređuje sa danima u tablici, tražeći gdje se podudara većina ili svi uvjeti, od podataka se određuje stablo odluke prikazano na slici 3.4., čime će se lakše dolaziti do odluke.

Tablica 3.1. Skupljeni podaci o danu

Dan	Vrijeme	Temperatura	Vлага	Vjetar	Igrano?
1	Kišovito	Niska	Normalna	Jak	Ne
2	Kišovito	Blaga	Visoka	Slab	Da
3	Sunčano	Visoka	Visoka	Jak	Ne
4	Oblačno	Visoka	Normalna	Slab	Da
5	Kišovito	Blaga	Visoka	Jak	Ne
6	Sunčano	Visoka	Visoka	Slab	Ne
7	Oblačno	Visoka	Visoka	Slab	Da
8	Sunčano	Blaga	Normalna	Jak	Da
9	Oblačno	Blaga	Visoka	Jak	Da
10	Kišovito	Blaga	Visoka	Jak	Ne

Intuitivno se kao prvo pitanje postavlja kakvo je vrijeme danas. Moguće je primijetiti kako u slučaju oblačnog vremena tenisač igra, bez obzira na vlagu i jačinu vjetra. No, ukoliko je kišovito, tenisač provjerava je li vjetrovito, te ukoliko nije odlučuje igrati. Za sunčane se dane tenisač pita je li normalna količina vlage, te u slučaju pozitivnog odgovora odlučuje igrati. Na kraju se može zaključiti kako za odluku temperatura niti jednom nije igrala ulogu, što olakšava buduće prikupljanje podataka o danu.



Slika 3.4. Stablo odluke za odlučivanje o igranju tenisa

3.3.3. Slučajne šume

Jedan od problema na koje stablo odluke često nailazi je loša generalizacija, odnosno dok ono odlično klasificira trening podatke, to mu ne polazi za rukom sa neviđenim podatcima. Tu slučajne šume nadmašuju stabla odluke.

Slučajne šume ili RF (engl. *random forest*) je model strojnog učenja koji se sastoji od više različitih stabala odluke, te se može koristiti i za probleme klasifikacije i za probleme regresije [30]. Iako se model slučajne šume sastoji od više stabala odluke, ono bolje generalizira. To je postignuto načinom kojim se stvara svako pojedino stablo. Naime, svako se stablo stvara metodom odvajanja (engl. *bagging*), odnosno podskupom trening podataka. Također, svako odvajanje unutarnjeg čvora se vrši na temelju m značajki, tako da je $m < M$, odnosno m mora biti manji od ukupnog broja značajki. Time se postiže jedinstvenost svakog stabla odluke unutar slučajne šume.

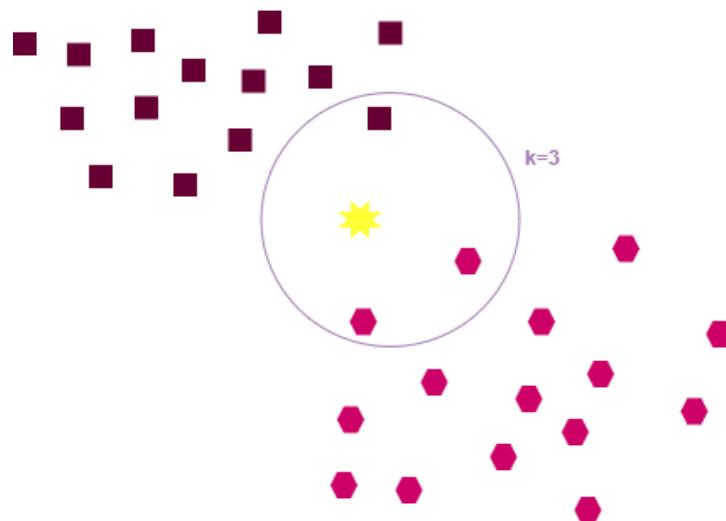
Način na kojem slučajna šuma odlučuje o kojoj se klasi radi naziva se metoda glasanja (engl. *voting*). Drugim riječima, svako stablo odluke unutar slučajne šume, neovisno o drugim stablima, predviđa o kojoj se klasi radi, odnosno glasa o klasi. Ta se glasovanja prate, te se na kraju odlučuje za onu klasu za koju je najviše stabala glasovalo.

3.3.4. Algoritam k najbližih susjeda

Model k najbližih susjeda ili kNN (engl. *k nearest neighbours*) je model strojnog učenja koji se najčešće koristi za klasifikaciju, iako je primjenjiv i na problemima regresije. To je model koji pretpostavlja da se u neposrednoj blizini nalaze slični objekti. Vrlo se često naziva lijenim algoritmom učenja, jer niti u jednom trenutku prije klasifikacije ne prolazi kroz fazu treniranja. To je prednost jer znači da model može klasificirati neviđene podatke bez treninga, što omogućava dodavanje novih i uklanjanje zastarjelih podataka iz trening skupa, i to bilo kad.

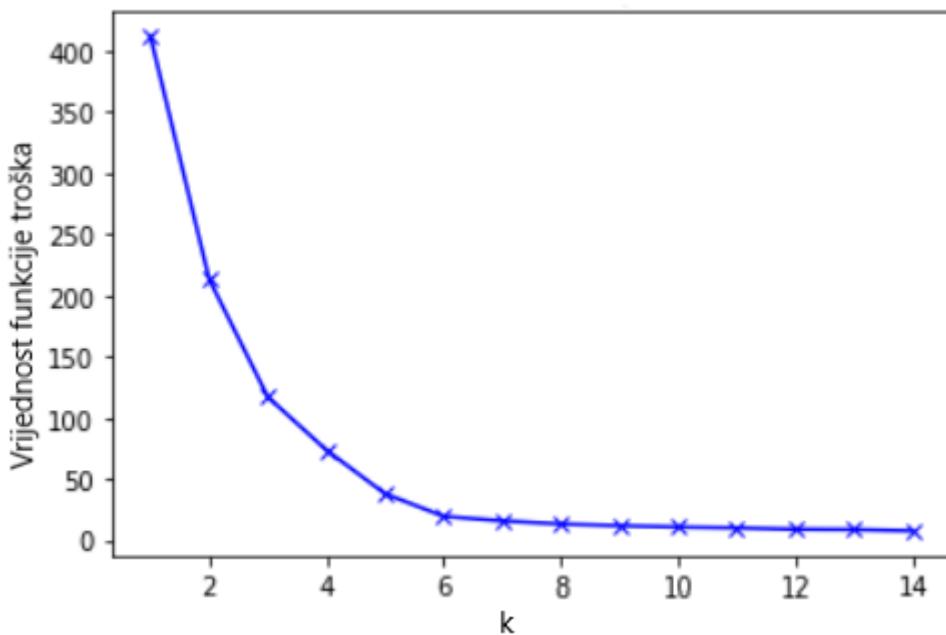
Način na kojem kNN model radi je vrlo jednostavan. Prvo se klasifikatoru predaju trening podaci i on ih sačuva. Zatim mu se preda novi podatak za kojeg treba predvidjeti kojoj klasi pripada. Klasa novog podatka se određuje na temelju k mu najbližih trening podataka, gdje je k prirodni broj. Odnosno, model računa udaljenost između novog podatka i svakog trening podatka, te pronalazi njih k koji su novom podatku najbliži, odnosno koji su mu najbliži susjedi. Novi podatak time pripada onoj klasi koja se najviše puta pojavljuje u najbližim susjedima. Udaljenost od susjeda se može odrediti na mnogo različitih načina, odnosno pomoću raznih mjera udaljenosti. Neke od njih su Euklidска udaljenost (engl. *Euclidean distance*), Manhattan udaljenost (engl. *Manhattan distance*), Minkowski udaljenost (engl. *Minkowski distance*).

Na slici 3.5. je prikazan primjer kNN modela koji raspoznaže dvije klase, ljubičaste kvadrate i ružičaste šesterokute na temelju 3 najbliža susjeda. Na slici je prikazana i žuta zvijezda, koja predstavlja objekt koji se želi klasificirati. Vidljivo je kako će se u ovom slučaju zvijezda klasificirati kao ružičasti šesterokut, jer mu je od 3 najbližih susjeda jedan ljubičasti kvadrat i čak dva ružičasta šesterokuta.



Slika 3.5. Primjer kNN modela, napravljeno prema uzoru [31]

Pri odabiru broja k potrebno je paziti da on nije višekratnik broja klasa, jer je u suprotnom moguće da jednak broj svih klasa budu najbliži susjadi novog podatka. Problem određivanja broja susjeda, odnosno vrijednosti broja k se najčešće rješava metodom lakta (engl. *elbow method*). Na testnom se skupu za različite vrijednosti broja k izračunava vrijednost funkcije troška. Funkcija troška (engl. *cost function*) je mjera koja otkriva koliko je model pogriješio, odnosno koliko su predviđene vrijednosti udaljene od stvarnih vrijednosti. Na temelju njih se crta graf ovisnosti vrijednosti funkcije troška o vrijednosti k (slika 3.6.). Na grafu se pronađazi vrijednost broja k koja je najbliža mjestu na kojem vrijednost funkcije troška drastično opadne. Ta je vrijednost optimalna vrijednost broja k. Za manje vrijednosti model ne predviđa s dovoljno velikom točnošću, zbog čega se naziva nedovoljnim modelom (engl. *underfitting model*). Za veće se vrijednosti dobiva previše prilagođen model (engl. *overfitting model*), odnosno model koji ne generalizira dobro.



Slika 3.6. Graff funkcije ovisnosti vrijednosti funkcije troška o vrijednosti k – nagli pad se vidi na mjestu gdje k poprima vrijednost 5

3.4. Vrednovanje

Kako se u posljednjih nekoliko godina znanstvenici sve više bave problemom raspoznavanjem tipa terena, tako se sve više rješenja i algoritama strojnog učenja objavljuje. Tu se javlja pitanje kojim će se kriterijem ili kriterijima ti algoritmi ocjenjivati. Najčešće su to uobičajeni kriteriji kojima se ocjenjuju klasifikatori, no sve se više radova bavi tom problematikom, kao što [32] i [33]. U ovom će se radu odabrana četiri klasifikatora ocjenjivati uobičajenim kriterijima, odnosno mjerama za ocjenjivanje klasifikatora, a to su: mjera F1, preciznost, odziv i točnost.

Za izračun tih mjera vrlo je bitna matrica zabune. Matrica zabune je tablica koja se, prema [19], koristi za opisivanje performanse klasifikacije. Redovi tablice predstavljaju stvarne klase, dok stupci predstavljaju klase koje je predvidio klasifikator. Važno je napomenuti kako se u nekim izvorima može naići i na matricu zabune kojoj stupci predstavljaju stvarne klase, a redovi predviđene klase, koja je zapravo inverzna na prvi oblik matrice, što u stvarnosti ne mijenja vrijednosti izračunatih mjeru. Razlog tome leži u činjenici što mjere ovise o broju stvarnih i lažnih pozitiva, te o broju stvarnih i lažnih negativa. Pozitiva predstavlja klasu koju se trenutno promatra, a negativa sve ostale klase.

Na slici 3.6. je na primjeru klasificiranja mačaka i pasa prikazana matrica zabune. Za pozitiv je uzeta klasa pas. Stvarni pozitiv ili TP (engl. *true positive*) je broj koji otkriva koliko je puta klasifikator točno predvidio da se radi o psu. Lažni pozitiv ili FP (engl. *false positive*) je broj koji govori koliko je puta klasifikator predvidio da se radi o psu, a u stvarnosti se radilo o mački. Stvarni negativ ili TN (engl. *true negative*) predstavlja broj koji govori koliko je puta klasifikator točno predvidio da se radi o mački, dok lažni negativ ili FN (engl. *true negative*) govori o tome koliko je puta klasifikator predvidio da se radi o mački, dok se u stvarnosti radilo o psu.

		PREDVIĐENE KLASE	
		Pas	Mačka
STVARNE KLASE	Pas	TP = 46	FN = 6
	Mačka	FP = 4	TN = 44

Slika 3.6. Matrica zabune klasificiranja 52 slika pasa i 48 slika mačaka, tako da je klasa pas klasa koju promatramo

Preciznost ili P (engl. *precision*) je mjera koja otkriva koliko često klasifikator predviđa da se radi o promatranoj klasi, a da se u stvarnosti o njoj i radi. Odnosno, to je omjer između stvarnih pozitiva i zbroja stvarnih pozitiva i lažnih pozitiva. Iz gornjeg primjera, pomoću formule (3 – 13) se može izračunati preciznost tog modela, i ona iznosi 0.92. Dakle kada model predviđa da se radi o psu, on je u 92% slučajeva u pravu.

$$P = \frac{TP}{TP+FP} \quad (3 - 13)$$

Odziv ili R (engl. *recall*) je mjera koja otkriva koliko dobro model prepoznaje promatranoj klasu, to jest ono je omjer između stvarnih pozitiva i zbroja stvarnih pozitiva i lažnih negativa. Gornjem

primjeru se pomoću formule (3 – 14) izračunava odziv, čime se dobiva iznos od 0.88, što znači da model od ukupnog broja slika pasa prepoznaće psa u njih 88%.

$$R = \frac{TP}{TP+FN} \quad (3 - 14)$$

Mjera F1 ili F1 (engl. *F1 score*) se definira kao harmonijska sredina preciznosti i odziva. Ona se računa prema formuli (3 – 15). Za gornji se primjer dobiva iznos od 0.9, odnosno 90%, iz čega se može zaključiti kako i preciznost i odziv imaju vrlo visoku vrijednost. Općenito, vrijednost mjere F1 je bliža 1 ako su vrijednosti preciznosti i odziva visoke. No, što su one niže, to je mjera F1 bliža 0.

$$F1 = 2 * \frac{P*R}{P+R} \quad (3 - 15)$$

Točnost ili A (engl. *accuracy*) je mjera koja daje informaciju o tome koliko je posto predikcija bilo točno. Točnost gornjeg primjera je 0.9, odnosno 90%, koja je izračunata pomoću formule (3 – 16).

$$A = \frac{TP+TN}{TP+FP+TN+FN} \quad (3 - 16)$$

Neka je M oznaka za matricu zabune i neka je i oznaka za redove, a j oznaka za stupce. Također, neka P_i i R_i označavaju preciznost i odziv i -te klase po redu, od njih N . Time se dobivaju idući opći izrazi za računanje preciznosti i odziva promatrane klase, te točnosti, pomoću kojih je lakše vizualizirati računanje mjera ukoliko se ne radi o binarnoj klasifikaciji, odnosno ukoliko se radi o višeklasnoj klasifikaciji (engl. *multiclass classification*).

$$P_i = \frac{M_{i,i}}{\sum_{j=0}^{N-1} M_{j,i}} \quad (3 - 17)$$

$$R_i = \frac{M_{i,i}}{\sum_{j=0}^{N-1} M_{i,j}} \quad (3 - 18)$$

$$A = \frac{\sum_{i=0}^{N-1} M_{i,i}}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} M_{i,j}} \quad (3 - 19)$$

4. PROGRAMSKO RJEŠENJE

U ovom će se poglavlju prikazati programsko rješenje ovoga rada, koji je pisan u programskom jeziku python. U programu će odabrani klasifikatori pokušati predviđati tip terena koji je prikazan na slici. Prije samog predviđanja, oni su istrenirani na trening skupu. Podatke trening skupa čine izdvojene značajke, koje su opisane u poglavlju 3.2.. Nakon njihova treninga, klasifikatori se testiraju. To se postiže učitavanjem trening skupa. Podatcima trening skupa klasifikatori pokušavaju odrediti klasu. Na temelju njihovih rezultata određuju se uspješnosti pojedinih klasifikatora za problem raspoznavanja tipa terena.

4.1. Korištene biblioteke

Razlog zbog kojeg je python programski jezik kojim je pisano programsko rješenje je taj što python nudi veliki broj biblioteka za manipulaciju i vizualizaciju podataka, procesiranje slika, te za strojno učenje. Na slici 4.1. je prikazan uvoz korištenih biblioteka.

```
import csv
from pathlib import Path
from pandas import DataFrame
import numpy as np
from sklearn import preprocessing, svm, tree
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.metrics import classification_report, accuracy_score, f1_score, precision_score, recall_score
from sklearn.neighbors import KNeighborsClassifier
import scipy.io as sio
import scipy as sp
from skimage import measure, feature
from cv2 import cvtColor, COLOR_RGB2GRAY
import matplotlib.pyplot as plt
```

Slika 4.1. Uvoz korištenih biblioteka

Biblioteka *scipy.io* sadržava razne klase, funkcije i module pogodne za pisanje i čitanje raznih formata datoteka. U programskom rješenju ovoga rada je korištena jer sadržava funkciju kojom je omogućeno učitavanje i pisanje u Matlab datoteke, te izlistavanje varijabli koje se u njoj nalaze. Kako je manipulacija Matlab datoteka u pythonu ograničena, podatke je potrebno pretvoriti u strukturu podataka kojom je moguće manipulirati u pythonu. Strukture najpogodnije za to su matrice. Ali, za oblikovanje matrice su potrebne dvije dodatne biblioteke, *pandas* i *NumPy*.

Pandas je biblioteka koja pruža visokoučinkovite i jednostavne strukture podataka i alate za analizu podataka u pythonu [34]. Funkcijom *pandas* biblioteke se dobiveni rječnik podataka pretvara u strukturu podataka *dataframe*.

NumPy je paket za znanstveno računanje u pythonu. Osim što se primjenjuje u znanstvene svrhe, *NumPy* se također koristi kao učinkovit višedimenzionalni spremnik generičkih podataka [35]. *NumPy* je od bitne važnosti u ovom radu jer se u njegovim N-dimenzionalnim poljima, odnosno matricama, spremaju podatci. Time je omogućena učinkovita manipulacija podatcima, zbog već ugrađenih metoda u *NumPy* biblioteci.

Scikit-learn je biblioteka koja sadržava učinkovite alate za manipulaciju podataka [36]. *Scikit-learn* je u stvari biblioteka za strojno učenje. U njoj su sadržani razni algoritmi modela strojnog učenja, kao što su SVM-a i kNN, te mnoge druge. *Scikit-learn* uvelike olakšava proces pisanja programskog rješenja. Bez nje je potrebno algoritme svakog korištenog modela pisati od nule. Uz razne modele strojnog učenja, *scikit-learn* također pruža razne funkcije i klase kojima se olakšava i proces poboljšavanja modela (na primjer *GridSearchCV*), te vrednovanje tih modela. Kako su ovom programskom rješenju potrebne samo određene funkcije, uključeni su samo potrebni dijelovi biblioteke.

OpenCV je biblioteka koja pruža metode za manipulaciju slika, dok biblioteka *scikit-image* pruža razne funkcije i metode pomoću kojih se efikasnije izdvajaju značajke teksture slike.

4.2. Postavke eksperimenta

Ukupan broj slika korištenih za treniranje i testiranje klasifikatora je 100,000. Trening skup se sastoji od 80,000 slika, dok se testni skup sastoji od 20,000 slika. Rezolucija svake slike je 28x28 piksela. Tretiranjem svakog piksela kao jedne značajke dobiva se 784 značajki za svaku sliku. Radi smanjivanja tog broja, iz slika se izdvaja 8 značajki, koje su opisane u poglavljju 3.2.. Svaka izdvojena značajka ima svoj raspon vrijednosti, što trening klasifikatora čini osjetljivo na razmjer pojedine značajke. Zbog toga su one normalizirane na vrijednosti između 0 i 1 pomoću *L2* norme. Tako dobivene značajke su predane klasifikatoru na trening.

Zbog činjenice da u niti jednoj python biblioteci ne postoje gotove funkcije niti metode za računanje indeksa vegetacija, potrebno je samostalno napisati funkcije za njihovo računanje. Kako se u pythonu operatorom dijeljenja matrice međusobno dijele elementi matrice, odnosno njime se vrši Hadamardovo dijeljenje matrica kojim se svaki element matrice u brojniku dijeli sa odgovarajućim elementom matrice u nazivniku, potrebno je voditi računa o matrici u nazivniku, jer postoji mogućnost da će joj neki element biti jednak nuli. Stoga se prvo računa matrica nazivnika i zatim se računa njena prosječna vrijednost, nakon čega se brojnik dijeli s njom. Time je dobivena matrica indeksa vegetacije svakog pojedinog piksela, kojoj se također tražila srednja

vrijednost kako bi se dobio indeks vegetacije cijele slike. Na slici 4.2. je prikazan primjer funkcije kojom se dobiva NDVI indeks, na sličan su način napisane i funkcije za dobivanje EVI i ARVI indeksa.

```
def calculateNDVI(image):
    R = image[:, :, 0]
    NIR = image[:, :, 3]
    NDVI = (NIR+R)
    NDVI = np.mean(NDVI)
    NDVI = (NIR-R)/NDVI
    return np.mean(NDVI)
```

Slika 4.2. Funkcija za računanje NDVI indeksa

Moguće je da korištenje klasifikatora python biblioteka sa već zadanim hiperparametrima neće pridonijeti u stvaranju učinkovitog klasifikatora za problem raspoznavanja tipa terena. Stoga se prvo moraju otkriti hiperparametri kojima se postiže najveća učinkovitost pojedinog klasifikatora. Ručno mijenjanje parametara te njihovo testiranje zahtjeva mnogo vremena, a postoji i mogućnost da se neka vrijednost nekog hiperparametra slučajno preskoči. Zbog toga se koristi klasa *GridSearchCV*. Objekt te klase omogućava testiranje različitih vrijednosti predanih joj hiperparametara klasifikatora. Osim toga, predajom joj testnih podataka objekt klase *GridSearchCV* pronalazi hiperparametre koji daju najbolje rezultate. Upravo je pomoću objekta klase *GridSearchCV* otkriveno kako su idući parametri za pojedini klasifikator najbolji:

- SVM : C = 1000; oblik funkcije odluke (engl. *decision function shape*) = OvR; jezgra (engl. *kernel*) = linearni
- Šuma odluke: kriterij = entropija; maksimalna dubina stabla = 25; maksimalni broj značajki = sve značajke; minimalni broj uzoraka za vanjski čvor = 1; minimalni broj uzoraka potrebno za razdvajanje unutarnjeg čvora = 2
- Slučajne šume: kriterij = entropija; upotreba bootstrap podataka = ne; maksimalna dubina pojedinog stabla = bez ograničenja; maksimalni broj značajki = \log_2 (*ukupan broj značajki*); broj stabala = 100
- kNN: broj susjeda = 5; računanje udaljenosti = Manhattan; udaljenost težina (engl. *weight*) = udaljenost

4.3. Analiza rezultata

U ovom će se poglavlju prikazati rezultati klasifikacije svakog klasifikatora. Na temelju rezultata F mjere, preciznosti, odziva i točnosti će klasifikatori biti vrednovani. Vrijednosti mjera su izračunate pomoću matrice zabune. Svaki se klasifikator deset puta trenirao i testirao, naravno svaki put sa različitim podatcima u trening i testnom skupu. Ovakav pristup naziva se metodom izostavljanja (engl. *holdout method*). U tablicama 4.1., 4.2, 4.3. i 4.4. su prikazane prosječne vrijednosti dobivenih mjera za svaki tip terena. Sa tablice 4.1. se može vidjeti kako SVM klasifikator iznimno loše klasificira slike drveća, i to sa odzivom od 32,1%, ali dobro klasificira ostale tipove terena, odnosno klasu „Ostalo“, sa odzivom od 90.7%. Nesimetričnost podjele podataka, nedovoljan broj izdvojenih značajki su samo neki od mogućih razloga lošeg klasificiranja drveća SVM klasifikatora.

Tablica 4.1. Prosječni rezultati mjera pojedinih klasa SVM klasifikatora

	Preciznost	Odziv	Mjera F
<i>Neplodna zemlja</i>	$0,866 \pm 0,0046$	$0,826 \pm 0,0049$	$0,847 \pm 0,0046$
<i>Drveće</i>	$0,690 \pm 0,0089$	$0,321 \pm 0,0070$	$0,435 \pm 0,0050$
<i>Travnjaci</i>	$0,801 \pm 0,0094$	$0,627 \pm 0,0078$	$0,703 \pm 0,0046$
<i>Ostalo</i>	$0,625 \pm 0,0050$	$0,907 \pm 0,0046$	$0,739 \pm 0,0030$

U tablici 4.2. su prikazani prosječni rezultati DT klasifikatora. Može se vidjeti kako je klasificiranje klase „Ostalo“ najuspješnije sa preciznošću od 96% i točnošću 96%, kao i za SVM klasifikator. Iako se sve klase sa visokim odzivom i preciznošću klasificiraju, vrijednosti mjera klasificiranja travnjaka su nešto niže, za gotovo 6%. Najmanja zastupljenost primjera klase „Travnjak“ (slika 3.1.) je jedan od mogućih razloga lošije klasifikacije.

Tablica 4.2. Prosječni rezultati mjera pojedinih klasa DT klasifikatora

	Preciznost	Odziv	Mjera F
<i>Neplodna zemlja</i>	$0,938 \pm 0,0040$	$0,939 \pm 0,0030$	$0,940 \pm 0,0000$
<i>Drveće</i>	$0,959 \pm 0,0030$	$0,958 \pm 0,0040$	$0,960 \pm 0,0000$
<i>Travnjaci</i>	$0,905 \pm 0,0067$	$0,906 \pm 0,0049$	$0,907 \pm 0,0046$
<i>Ostalo</i>	$0,960 \pm 0,0000$	$0,960 \pm 0,0000$	$0,960 \pm 0,0000$

Tablica 4.3. prikazuje prosječne rezultate RF klasifikatora. Iz tablice je moguće vidjeti kako RF klasifikator malo bolje prepoznaje ostale tipove terena od travnjaka, kao što je slučaj i kod DT klasifikatora. Može se vidjeti i kako RF klasifikator najbolje prepoznaje klasu „Drveće“ sa

prosječnim odzivom od 98.1%, dok je klasa „Ostalo“ bila najbolje prepoznata od SVM i DT klasifikatora.

Tablica 4.3. Prosječni rezultati mjera pojedinih klasa RF klasifikatora

	Preciznost	Odziv	Mjera F
<i>Neplodna zemlja</i>	0,960 ± 0,0000	0,969 ± 0,0030	0,964 ± 0,0049
<i>Drveće</i>	0,980 ± 0,0000	0,981 ± 0,0030	0,980 ± 0,0000
<i>Travnjaci</i>	0,954 ± 0,0049	0,950 ± 0,0000	0,950 ± 0,0000
<i>Ostalo</i>	0,986 ± 0,0049	0,980 ± 0,0000	0,980 ± 0,0000

Iz tablice 4.4. se može vidjeti kako kNN klasifikator najgore prepoznae travnjake, poput DT i RF klasifikatora. Kao i RF klasifikator, kNN klasifikator najbolje prepoznae klasu „Drveće“ sa prosječnim odzivom od 97%.

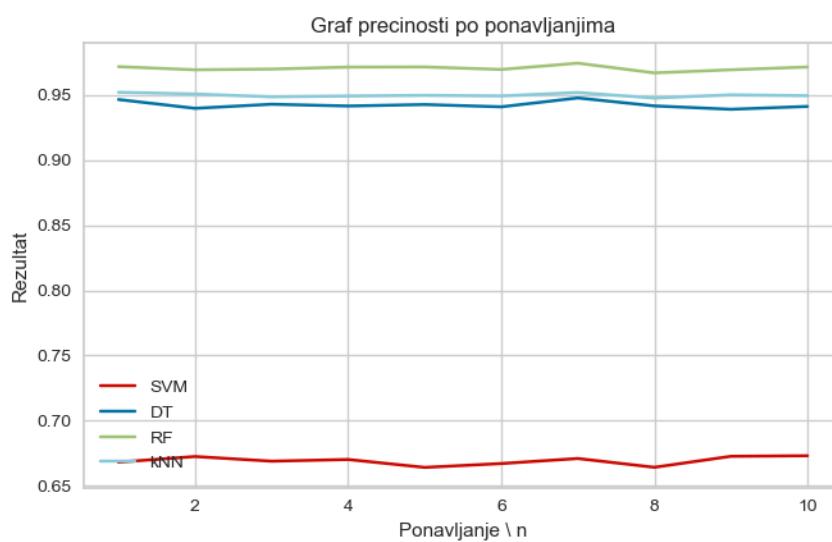
Tablica 4.4. Prosječni rezultati mjera pojedinih klasa kNN klasifikatora

	Preciznost	Odziv	Mjera F
<i>Neplodna zemlja</i>	0,937 ± 0,0046	0,958 ± 0,0040	0,949 ± 0,0030
<i>Drveće</i>	0,952 ± 0,0040	0,970 ± 0,0000	0,960 ± 0,0000
<i>Travnjaci</i>	0,933 ± 0,0078	0,917 ± 0,0046	0,925 ± 0,0050
<i>Ostalo</i>	0,970 ± 0,0000	0,956 ± 0,0049	0,960 ± 0,0000

U tablicama koje slijede prikazane su izračunate vrijednosti mjera vrednovanja svake iteracije i svakog klasifikatora. Također, prikazane su i prosječne vrijednosti klasifikacija, te njihova standardna devijacija. U tablici 4.5. prikazane su izračunate vrijednosti preciznosti pojedinog klasifikatora. Iz tablice 4.5. se može vidjeti kako SVM klasificira sa prosječnom preciznošću od 66.9%, odnosno udio točno klasificiranih primjera u skupu pozitivno klasificiranih primjera je 66.9%. Uzrok niske preciznosti SVM klasifikatora je vrlo niska preciznost klasificiranja drveća (tablica 4.1.). Ostatak klasifikatora klasificiraju sa vrlo visokom preciznošću, DT sa prosječnom vrijednošću od 94.2%, RF sa 97.1%, te kNN sa 95%. Odstupanja od prosječne vrijednosti preciznosti su za svaki klasifikator vrlo niska. Na slici 4.3. prikazan je grafički prikaz tablice 4.5..

Tablica 4.5. Izračunate vrijednosti preciznosti pojedinih klasifikatora

	SVM	DT	RF	kNN
1	0,668	0,947	0,972	0,952
2	0,672	0,940	0,969	0,951
3	0,669	0,943	0,970	0,949
4	0,670	0,942	0,971	0,949
5	0,664	0,943	0,971	0,950
6	0,667	0,941	0,970	0,949
7	0,671	0,948	0,974	0,952
8	0,664	0,942	0,967	0,948
9	0,673	0,939	0,969	0,950
10	0,673	0,941	0,971	0,949
$\mu \pm \sigma$	$0,669 \pm 0,0031$	$0,942 \pm 0,0026$	$0,971 \pm 0,0019$	$0,950 \pm 0,0013$
Min.	0,664	0,939	0,967	0,948
Max.	0,673	0,948	0,974	0,952



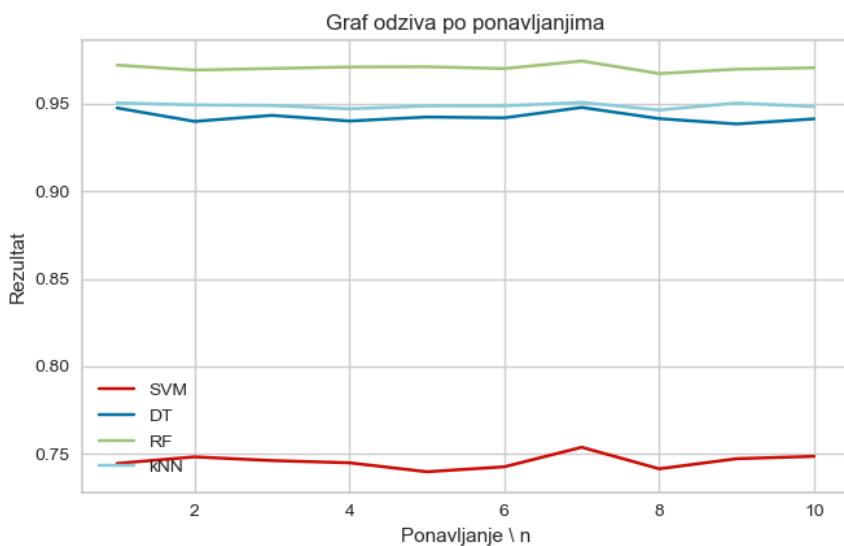
Slika 4.3. Grafički prikaz preciznosti pojedinog klasifikatora po ponavljanjima

U tablici 4.6. prikazane su dobivene vrijednosti odziva pojedinih klasifikatora. Uočljivo je kako je odziv SVM klasifikatora znatno veći od njegove preciznosti, točnije prosječna vrijednost odziva mu je 74.6%, što znači da je SVM-u udio pozitivno klasificiranih primjera u skupu pozitivnih primjera veći nego u skupu pozitivno klasificiranih primjera. Odzivi ostalih klasifikatora se ne razlikuju za velike vrijednosti od preciznosti. Prosječna vrijednost DT klasifikatora je 94.2%, RF

klasifikatora je 97%, te kNN klasifikatora je 94.9%. Odstupanja od prosječne vrijednosti odziva nisu velika, najveće odstupanje pripada SVM klasifikatoru i ono iznosi 0.38%. Grafički prikaz rezultata prikazan je na slici 4.4..

Tablica 4.6. Izračunate vrijednosti odziva pojedinih klasifikatora

	SVM	DT	RF	kNN
1	0,745	0,947	0,972	0,950
2	0,748	0,940	0,969	0,949
3	0,746	0,943	0,970	0,949
4	0,745	0,940	0,971	0,947
5	0,740	0,942	0,971	0,949
6	0,743	0,942	0,970	0,949
7	0,754	0,948	0,974	0,951
8	0,742	0,941	0,967	0,946
9	0,747	0,938	0,970	0,950
10	0,749	0,941	0,970	0,948
$\mu \pm \sigma$	$0,746 \pm 0,0038$	$0,942 \pm 0,0029$	$0,970 \pm 0,0018$	$0,949 \pm 0,0014$
Min.	0,740	0,938	0,967	0,946
Max.	0,754	0,948	0,974	0,951



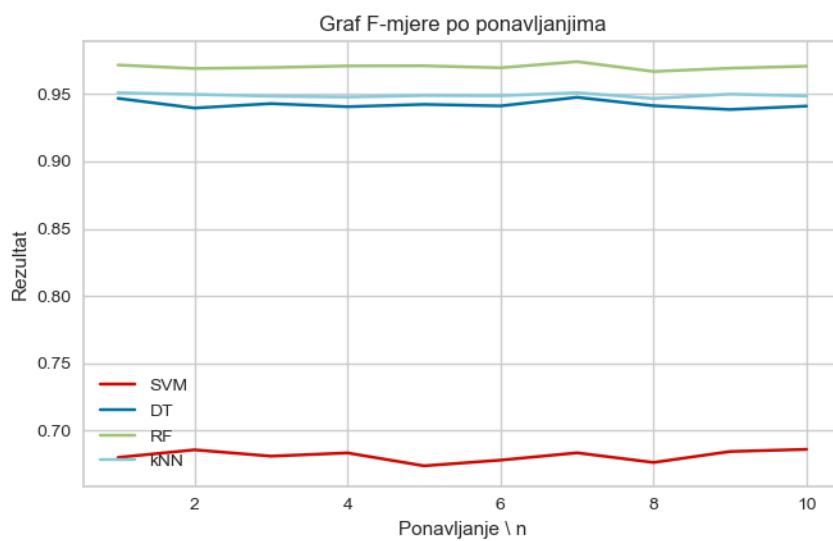
Slika 4.4. Grafički prikaz preciznosti pojedinog klasifikatora po ponavljanjima

U tablici 4.7. prikazane su dobivene vrijednosti mjere F pojedinih klasifikatora. Uzroci niske vrijednosti F mjere SVM klasifikatora (68.1%) su niske vrijednosti preciznosti i odziva. Zbog vrlo visokih i približno jednakih vrijednosti preciznosti i odziva ostalih klasifikatora, vrijednosti mjere

F su visoke i približno jednake vrijednostima preciznosti i odziva. Grafički prikaz tablice 4.7. prikazan je na slici 4.5..

Tablica 4.7. Izračunate vrijednosti mjere F pojedinih klasifikatora

	SVM	DT	RF	kNN
1	0,680	0,947	0,972	0,951
2	0,685	0,940	0,969	0,950
3	0,681	0,943	0,970	0,949
4	0,683	0,941	0,971	0,948
5	0,673	0,942	0,971	0,949
6	0,678	0,941	0,970	0,949
7	0,683	0,948	0,974	0,951
8	0,676	0,941	0,967	0,947
9	0,684	0,939	0,969	0,950
10	0,686	0,944	0,971	0,949
$\mu \pm \sigma$	$0,681 \pm 0,0039$	$0,942 \pm 0,0028$	$0,970 \pm 0,0018$	$0,949 \pm 0,0013$
Min.	0,673	0,939	0,967	0,947
Max.	0,686	0,948	0,974	0,951



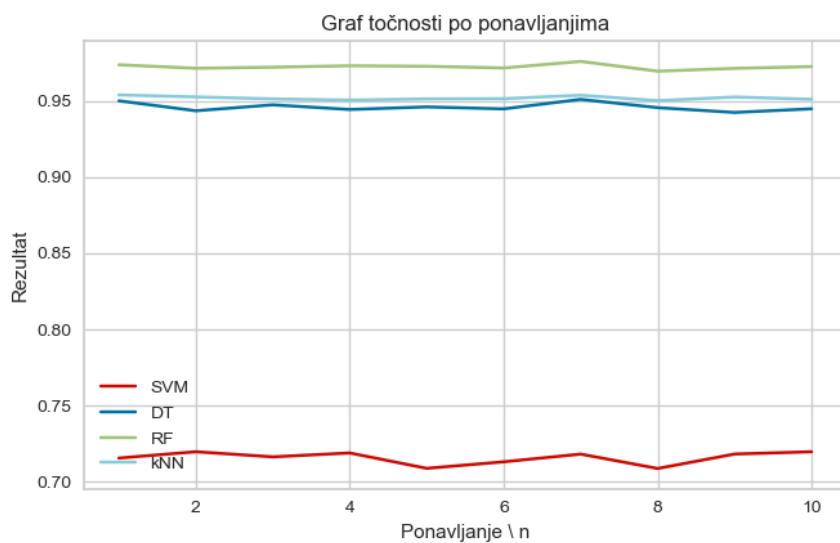
Slika 4.5. Grafički prikaz F-mjere pojedinog klasifikatora po ponavljanjima

Dobivene vrijednosti točnosti pojedinih klasifikatora prikazane su u tablici 4.8. i grafički su prikazane na slici 4.6.. Ponovo se može vidjeti kako SVM klasifikator ima najnižu vrijednost od 71.6%. Također se može vidjeti i visoka točnost RF klasifikatora od 97.2%, što je samo 2% više

od kNN klasifikatora (95.2%). Visoka točnost RF klasifikatora znači da se od 20,000 testnih slika, njih oko 19,440 točno klasificira.

Tablica 4.8. Izračunate vrijednosti točnosti pojedinih klasifikatora

	SVM	DT	RF	kNN
1	0,716	0,950	0,974	0,954
2	0,720	0,944	0,971	0,953
3	0,716	0,947	0,972	0,951
4	0,719	0,944	0,973	0,951
5	0,709	0,946	0,973	0,951
6	0,713	0,945	0,972	0,951
7	0,718	0,951	0,976	0,954
8	0,709	0,946	0,970	0,950
9	0,718	0,942	0,971	0,953
10	0,720	0,945	0,973	0,951
$\mu \pm \sigma$	$0,716 \pm 0,0040$	$0,946 \pm 0,0026$	$0,972 \pm 0,0016$	$0,952 \pm 0,0012$
Min.	0,709	0,942	0,970	0,950
Max.	0,720	0,951	0,976	0,954



Slika 4.6. Grafički prikaz točnosti pojedinog klasifikatora po ponavljanjima

Iz svih gore prikazanih rezultata može se zaključiti kako se klasifikator SVM pokazao kao neuspješan. Iako je iz tablice 4.1. vidljivo kako SVM klasificira 3 tipa terena s relativno visokim uspjehom, iznimno loša klasifikacija drveća je uzrokovala niske vrijednosti izračunatih mjera.

Uspoređivanjem tablica 4.1., 4.2., 4.3. i 4.4. može se zaključiti kako RF klasifikator najbolje prepoznaje pojedine klase. Uspoređivanjem se tablica 4.5., 4.6., 4.7. i 4.8. može zaključiti kako se kao najuspješniji klasifikator za raspoznavanje tipa terena pokazao RF, odnosno slučajna šuma, čije vrijednosti mjera nadilaze 97%.

5. ZAKLJUČAK

Znanstvenici su kroz nedavnu prošlost prepoznali važnost poznavanja pokrovnosti Zemlje, odnosno tipa terena određenog područja. Naime, promjene tipa terena utječu na ljudsko zdravlje i ekonomiju, a i na Zemljine cikluse klime. Zbog toga su znanstvenici odlučili mapirati pokrov Zemlje. Njenim ciklusnim mapiranjem mogu se vidjeti promjene koje su nastale bilo ljudskim djelovanjem ili prirodnim putem. Sam proces mapiranja je dugotrajan, no razvojem strojnog učenja znanstvenici su odlučili pokušati ubrzati taj proces na način da modeli strojnog učenja nauče prepoznavati tipove terena sa satelitskih slika. Najčešće korišteni modeli strojnog učenja u raspoznavanju tipa terena su SVM, DT, RF i neuronske mreže. Iako se u posljednjih nekoliko godina sve više znanstvenika bavi problemom raspoznavanja tipa terena, njihov značajan napredak je ponajprije spriječen zbog nedostatka pravilno označenih satelitskih snimaka. Istina je da velik broj organizacija svoje satelitske snimke postavlja na Internet, no na njima su vrlo rijetko označeni tipovi terena. Zbog toga se modeli strojnog učenja često znaju trenirati i testirati na istim slikama, što nije preporučeno, jer time nije moguće doznati koliko će dobro model moći prepoznavati tipove terena sa novih primjera. U praktičnom dijelu ovog rada uspoređivala su se četiri klasifikatora: SVM, DT, RF i kNN. Iako se kNN ne koristi često za problem raspoznavanja tipa terena, u ovom je radu pokazano kako nadmašuje SVM klasifikator. Klasifikatori su morali predviđati kojem tipu terena pripada pojedina slika. Sa slikama su prvo izdvojene značajke kojima se tipovi terena razlikuju. Zatim su se slike pri svakom ponavljanju dijelile u novi trening i testni skup, kako bi se moglo bolje uvidjeti generaliziraju li modeli dobro ili ne. Uspoređivanjem rezultata raznih mjera, može se zaključiti kako se od navedenih četiri klasifikatora slučajna šuma, odnosno RF, pokazao kao najuspješniji.

LITERATURA

- [1] A. Di Gregorio, L. J. M. Jansen, Land Cover Classification System, Food and Agriculture Organization of the United Nations, Rim, Italija, 2000., dostupno na: <http://www.fao.org/3/X0596E/X0596e00.htm> [27-lip-2019]
- [2] M. S. M. Altaei, S. M. Ahmed, Satellite Image Classification using Multi Features Based Descriptors, International Research. Journal of Advanced Engineering and Science, br. 2., sv. 3, str. 87–94, tra. 2018.
- [3] M. Sharma, Different types of Remote Sensing - Active and Passive, Geospatial World, 2018., dostupno na: <https://www.geospatialworld.net/videos/active-and-passive-remote-sensing/> [24-kol-2019]
- [4] S. May, What Is a Satellite?, NASA, 2015., dostupno na: <http://www.nasa.gov/audience/forstudents/5-8/features/nasa-knows/what-is-a-satellite-58.html> [27-lip-2019]
- [5] DigitalGlobe, Washington, D.C. from Space, Smithsonian National Air and Space Museum, dostupno na: <https://airandspace.si.edu/multimedia-gallery/web10612-2006hjpg> [27-lip-2019]
- [6] M. K. Arora, Land cover classification from Remote Sensing data, Geospatial World, 2010., dostupno na: <https://www.geospatialworld.net/article/land-cover-classification-from-remote-sensing-data/> [27-lip-2019]
- [7] L. Rocchio, About « Landsat Science, NASA, 2019, dostupno na: <https://landsat.gsfc.nasa.gov/about/> [27-lip-2019]
- [8] A. Strahler, D. Muchoney, J. Borak, M. Friedl, S. Gopal, E. Lambin, A. Moody, MODIS Land Cover and Land-Cover Change, 1999.
- [9] D. DiBiase, J. A. Dutton, Classifying Landsat Data for the National Land Cover Dataset, The Nature of Geographic Information, dostupno na: https://www.e-education.psu.edu/natureofgeoinfo/c8_p19.html [27-lip-2019]
- [10] Z. Azizi, A. Najafi, H. Sohrabi, Forest Canopy Density Estimating, Using Satellite Images, Working Groups VIII/11: Sustainable Forest and Landscape Management, sv. 37, str. 1127–1130, Beijing, Kina, srp. 2008.
- [11] S. Gopal, C. E. Woodcock, A. H. Strahler, Fuzzy Neural Network Classification of Global Land Cover from a 1° AVHRR Data Set, Remote Sensing of Environment, br. 2., sv. 67, str. 230–243, velj. 1999.

- [12] M. A. Friedl, C. Brodley, A. H. Strahler, Maximizing land cover classification accuracies produced by decision trees at continental to global scales, *IEEE Transactions on Geoscience and Remote Sensing*, br. 2., sv. 37, str. 969–977, tra. 1999.
- [13] C. Huang, L. S. Davis, J. R. G. Townshend, An assessment of support vector machines for land cover classification, *International Journal of Remote Sensing*, br. 4., sv. 23, str. 725–749, sij. 2002.
- [14] V. F. Rodriguez-Galiano, M. Chica-Olmo, F. Abarca-Hernandez, P. M. Atkinson, C. Jeganathan, Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture, *Remote Sensing of Environment*, sv. 121, str. 93–107, lip. 2012.
- [15] X. Yu, X. Wu, C. Luo, P. Ren, Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework, *GIScience & Remote Sensing*, br. 5., sv. 54, str. 741–758, ruj. 2017.
- [16] S. Basu, S. Ganguly, S. Mukhopadhyay, R. DiBiano, M. Karki, R. Nemani, Deepsat: a learning framework for satellite imagery, *Proceedings of the 23rd SIGSPATIAL international conference on advances in geographic information systems*, sv. 37, Seattle, WA, 2015
- [17] J. B. Chrystal, S. Joseph, Land Cover Classification of Satellite Images Using Artificial Neural Network and Support Vector Machine, *International Journal of Advances in Electronics and Computer Science*, br. 6., sv. 2, str. 83-85, lip. 2015.
- [18] S. Graham, Land Cover Classification, NASA, srp. 1999., dostupno na:
<https://www.earthobservatory.nasa.gov/features/LandCover> [27-lip-2019]
- [19] M. Swamynathan, Mastering Machine Learning with Python in Six Steps, Apress, Berkeley, CA, 2017.
- [20] Image Classification Techniques in Remote Sensing, GIS Geography, 2014., dostupno na:
<https://gisgeography.com/image-classification-techniques-remote-sensing/> [27-lip-2019]
- [21] K. Bakshi, The Seven Steps Of Machine Learning, TechLeer, 2017., dostupno na:
<https://www.techleer.com/articles/379-the-seven-steps-of-machine-learning/> [27-lip-2019]
- [22] S. B. Kotsiantis, D. Kanellopoulos, P. E. Pintelas, Data Preprocessing for Supervised Learning, *International Journal of Computer Science*, br. 1, sv. 1, str. 111-117, 2007.
- [23] J. M. Zhang, M. Harman, L. Ma, Y. Liu, Machine Learning Testing: Survey, Landscapes and Horizons, ArXiv190610742 Cs Stat, lip. 2019.
- [24] M. Petrou, P. García Sevilla, Image Processing: Dealing with Texture Chichester, UK: John Wiley & Sons, Ltd, Wiltshire, Ujedinjeno Kraljevstvo, sij., 2006.

- [25] R. M. Haralick, K. Shanmugam, I. Dinstein, Textural Features for Image Classification, IEEE Transactions on Systems, Man, and Cybernetics: System, br. 6., sv. SMC-3, str. 610–621, stu. 1973.
- [26] C. M. R. Caridade, A. R. S. Marçal, T. Mendonça, The use of texture for image classification of black & white air photographs, International Journal of Remote Sensing, br. 2., sv. 29, str. 593–607, sij. 2008.
- [27] G. Balamurugan, K. B. Jayaraman, Classification of Land Cover in Satellite Image using Supervised and Unsupervised Techniques, International Jorunal of Computer Applications, br. 5., sv. 135, str. 15–18, velj. 2016.
- [28] Vegetation Indices, L3 Harris Geospatial Solutions, dostupno na:
<https://www.harrisgeospatial.com/docs/VegetationIndices.html> [28-lip-2019]
- [29] I. Morgun, How-to simulate Support Vector Machine (SVM) in R, en.proft.me, Vinnytsia, Ukraina, 2014., dostupno na: <http://en.proft.me/2014/04/22/how-simulate-support-vector-machine-svm-r/> [15-kol-2019]
- [30] T. Hastie, R. Tibshirani, J. H. Friedman, The elements of statistical learning: data mining, inference, and prediction, Springer, New York, NY, 2009.
- [31] Classification parameter optimization, Perseus documentation, 2014, dostupno na:
<http://www.coxdocs.org/doku.php?id=perseus:user:activities:matrixprocessing:learning:classificationparameteroptimization> [17-kol-2019]
- [32] R. DeFries, Multiple Criteria for Evaluating Machine Learning Algorithms for Land Cover Classification from Satellite Data, Remote Sensing of Environment, br. 3., sv. 74, str. 503–515, pros. 2000.
- [33] S. S. Rwanga, J. M. Ndambuki, Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS, International Journal of Geosciences, br. 4., sv. 08, str. 611–622, trav., 2017.
- [34] Python Data Analysis Library, Pandas, dostupno na: <https://pandas.pydata.org/> [14-srp-2019]
- [35] NumPy, NumPy, dostupno na: <https://www.numpy.org/> [14-srp-2019]
- [36] scikit-learn: machine learning in Python, SciKit, dostupno na: <https://scikit-learn.org/stable/index.html#> [15-srp-2019]

SAŽETAK

U teorijskom dijelu ovog rada objašnjen je problem raspoznavanja tipa terena, te su opisani postupci i koraci strojnog učenja za raspoznavanje tipa terena. U praktičnom je dijelu prikazan program kojim su se za problem raspoznavanja tipa terena uspoređivali četiri klasifikatora. Ti klasifikatori su: SVM, DT, RF, te kNN. Korištena je baza satelitskih snimaka SAT-4. U njoj su označena četiri tipa terena: neplodna zemlja, drveće, travnjak i klasa koju čine svi ostali tipovi terena. Klasifikatori na temelju značajki slika predviđaju o kojem se tipu terena radi. Podaci od 100,000 slika se prvo dijele na trening i testni skup. Klasifikatori na trening skupu uče prepoznavati tipove terena, a na testnom skupu predviđaju o kojem se tipu terena radi. Na temelju rezultata predviđanja testnog skupa, izračunavaju se iduće mjere: F-mjera, preciznost, odziv i točnost. Klasifikatori se vrednuju s obzirom na te mjere. Usporedbom rezultata tih mjer zaključuje se kako se klasifikator RF pokazao kao najuspješniji u raspoznavanju tipa terena.

Ključne riječi: klasifikacija, raspoznavanje tipa terena, SAT-4, značajke teksture

ABSTRACT

Terrain type recognition based on satellite imagery

The problem of terrain type recognition is explained in the theoretical part of this thesis. With it, the procedures and steps of creating a machine learning models for terrain type recognition are explained. The practical part of this thesis shows a program which is used for comparing four classifiers on the terrain type recognition problem. The four classifiers are: SVM, DT, RF, and kNN.. The SAT-4 satellite imagery database is used in this thesis. The database contains pictures which are labeled as barren land, trees, grassland or other (which represents all other land cover classes). Based on image features, the classifiers predict the land type. A dataset of 100,000 pictures is first divided into a training and test set. On the training set the classifiers learn to recognize the types of terrain, while they are tested on the test set. Based on the results of the test set predictions, the following measures are calculated: F-score, precision, recall and accuracy. With these measures the classifiers are evaluated. By comparing the results of these measures, the RF classifier was shown to be the most successful in recognizing terrain type.

Keywords: classification, terrain type recognition, SAT-4, texture features

ŽIVOTOPIS

Klaudija Mučaj je rođena 11. siječnja 1998. godine u Rijeci, Hrvatska. Prve dva razreda osnovne škole pohađa u Crikvenici, nakon čega se seli u Osijek. Ondje završava osnovnu školu, nakon čega upisuje III. gimnaziju Osijek, odnosno prirodoslovno – matematičku gimnaziju. 2012. godine upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija, smjer računarstvo.

PRILOZI

1. „Raspoznavanje tipa terena na temelju satelitskih snimki“ u .docx formatu
2. „Raspoznavanje tipa terena na temelju satelitskih snimki“ u .pdf formatu
3. Izvorni kod