

**SVEUČILIŠTE U SPLITU
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I
BRODOGRADNJE**

**POSLIJEDIPLOMSKI DOKTORSKI STUDIJ
ELEKTROTEHNIKE I INFORMACIJSKE TEHNOLOGIJE**

KVALIFIKACIJSKI ISPIT

**SUSTAVI DALJINSKOG ISTRAŽIVANJA U
DETEKCIJI I ANALIZI POŽARA**

Ana Šarić Gudelj

Split, svibanj 2023.

Sadržaj

1. UVOD	3
2. SUSTAVI DALJINSKOG ISTRAŽIVANJA	4
2.1 SUSTAVI MOTRILAČKIH KAMERA	4
2.2 SUSTAVI BESPILOTNIH LETJELICA	5
2.3 SATELITSKI SUSTAVI	5
3. METODE OBRADE PODATAKA U DALJINSKOM ISTRAŽIVANJU	7
3.1. KLASIČNE METODE OBRADE U DALJINSKOM ISTRAŽIVANJU	7
3.2. METODE STROJNOG UČENJA	7
3.2.1. ALGORITMI NADZIRANOG STROJNOG UČENJA	7
SVM (eng. Support Vector Machines)	8
KNN (eng. K- Nearest Neighbors).....	8
STABLO ODLUČIVANJA	9
ALGORITAM SLUČAJNE ŠUME	9
3.2.2. ALGORITMI NENADZIRANOG STROJNOG UČENJA	10
GRUPIRANJE (eng. CLUSTERING)	10
ANALIZA GLAVNIH KOMPONENATA	10
3.3. NEURALNE MREŽE	10
3.3.1. MREŽE S PRIJENOSOM UNAPRIJED (eng. FEED FORWARD NETWORK)	10
3.3.2. KONVOLUCIJSKE MREŽE	11
4. DOSADAŠNJA ISTRAŽIVANJA	12
4.1. DETEKCIJA POŽARA	12
4.2 PROCJENA OPOŽAREN OG PODRUČJA	17
5. ZAKLJUČAK	21
6. LITERATURA	22
PRILOG TABLICA SLIKA	26
SAŽETAK	27

1. UVOD

Živimo u vremenu kada se naglasak stavlja na očuvanje ekosustava. Na svjetskoj razini provode se različiti programi i kampanje sa svrhom očuvanja prirode. Jedan od većih problema je deforestacija. Osim sječom, šume nestaju i u razornim požarima čije posljedice znaju biti katastrofalne. Narušava se prirodna ravnoteža, nestaju životinjska staništa, građevine, poljoprivredna zemljišta, a nažalost nekada stradaju i ljudi. Osim toga problem se javlja i prilikom izgaranja određenih goriva koja u atmosferu otpuštaju opasne plinove. Svjesni tog „gorućeg“ problema znanstvenici ulažu napore u razvoj sustava koji bi mogli pomoći u prevenciji i gašenju požara kao i u procjeni nastale štete. Kako bi to bilo ostvarivo potrebno je prvo prikupiti podatke iz različitih senzora, analizirati ih i na osnovu toga primjenama novih tehnologija izraditi korisne sustave. Postojeći sustavi za predviđanje šumskih požara kao što je kanadski sustav ocjenjivanja opasnosti od šumskih požara [1] temelje se na ručno izrađenim značajkama što podrazumijeva zahtjevnu instalaciju i održavanje skupih instrumenata zbog čega se sve više istraživanja okreće sustavima temeljenim na strojnom učenju koji koriste podatke daljinskog istraživanja najčešće dobivene iz satelitskih snimaka.

McKinsey & Co daju definiciju: - „Strojno učenje temelji se na algoritmima koji mogu učiti iz podataka bez oslanjanja na programiranje zasnovano na pravilima“ [2]. Princip strojnog učenja je korištenje generičkih algoritama na velikim skupovima podataka koji rezultiraju predviđanjem određene vrijednosti ili stvaranjem korelacijske logike između zadanih podataka. Određeni skup podataka ubacuje se u generički algoritam, koji zatim, bez pisanja specifičnog koda za zadani problem, vidi logiku među unesenim podacima.

Strojno učenje temelji se na dvije osnovne vrste generičkih algoritama – nadziranom i nenadziranom učenju. Kod nadziranog učenja na osnovu ulaza pokušava se naći preslikana vrijednost funkcije na izlazu. Ako je riječ o diskretnoj odnosno ne brojčanoj vrijednosti koristi se klasifikacija, a ako se radi o kontinuiranoj ili brojčanoj vrijednosti regresija. Kod nenadziranog učenja imamo podatke bez ciljne vrijednosti, a težište je na tome da se pokuša pronaći pravilnost u podacima. Svoju primjenu pronalazi u gotovo svim zadacima gdje treba analizirati podatke iz velikih skupova, a to je u raznim područjima od medicine, analize govora, poljoprivrede, robotike, matematike i šire. Koristi se i u analizi podataka dobivenih udaljenim pristupom kao što su satelitske slike.

Satelitske slike se mogu koristiti u istraživanju šumskih požara kako bi se identificirali i locirali požari u ranoj fazi. Primjenom algoritama strojnog, odnosno dubinskog učenja u kombinaciji sa satelitskim slikama može se automatski detektirati dim i plamen. Algoritmi se treniraju na velikom skupu satelitskih slika kako bi se prepoznale značajke koje su povezane s požarom. To mogu biti boja, oblik, veličina plamena, dima ili veličina opožarenog područja. Kada se požar detektira satelitske se slike mogu koristiti za praćenje širenja požara što može biti korisno u akcijama planiranja gašenja. Osim navedenog satelitske slike u kombinaciji sa strojnim učenjem mogu se koristiti i za analizu i procjenu vegetacije, praćenje klimatskih promjena i procjene rizika od nastanka požara što može koristiti u ranoj detekciji, gašenju i procjeni štete uzrokovane požarom.

2. SUSTAVI DALJINSKOG ISTRAŽIVANJA

Pojam daljinsko istraživanje (*eng. Remote Sensing*) odnosi se na prikupljanje podataka o Zemljinoj površini koristeći tehnologije koje ne zahtijevaju fizički kontakt. Potreba za promatranjem Zemlje na lokalnoj i globalnoj razini sve je veća. Dobiveni podaci mogu se koristiti za praćenje urbanog rasta, procjenu temperature kao i za identifikaciju objekata na površini. Nakon obrade dobivaju se vrijedne informacije koje mogu biti od pomoći prilikom donošenja određenih odluka u različitim područjima. Daljinska istraživanja koriste energiju koju objekt emitira za prikupljanje informacija na maloj, srednjoj ili velikoj udaljenosti [3]. Sustave temeljene na daljinskom istraživanju dijelimo na pasivne i aktivne, ovisno o vrsti energije koju koriste za prikupljanje podataka [4]. U aktivne, između ostalog, spadaju radari [5] i optički mjerni instrumenti (*eng. Light Detection and Ranging – LIDAR*) [6]. Ti sustavi emitiraju elektromagnetske valove i laserske zrake te mjere vrijeme potrebno da se oni odbiju od zemljine površine i vrate natrag. Pasivni sustavi koriste prirodne izvore zračenja, poput sunčeve svjetlosti, jer nemaju vlastiti izvor energije. Oni mjere vrijeme potrebno da se energija, primjerice sunčeva svjetlost, odbije od zemljine površine i vrati do njih [7].

Treća skupina na koju ćemo staviti fokus su sustavi koji prikupljaju fotografije. Prema načinu prikupljanja podataka tu skupinu možemo podijeliti na još tri podskupine [8] :


- Sustavi kojima je baza na zemljinoj površini, odnosno kamere postavljene na različitim strateški važnim lokacijama.
- Kamere na letjelicama, najčešće bespilotnim koje snimaju teren i šalju podatke preko mreže u baznu stanicu.
- Satelitski sustavi

2.1 SUSTAVI MOTRILAČKIH KAMERA

Sustavi kojima je baza na zemljinoj površini često se koriste za dobivanje detaljnijih informacija koje se potom uspoređuju s informacijama prikupljenim iz letjelica ili satelitskih senzora. Ukoliko se na snimkama dobivenim sa satelita ili letjelica uoči neki objekt koji se ne može dobro razaznati pregledavaju se zemaljske kamere. Kamere postavljene na zemlji mogu dati bolju informaciju o čemu se točno radi. Zemaljski sustavi za rano otkrivanje šumskih požara najčešće se temelje na optičkim/termalnim kamerama koje su uglavnom postavljene na osmatračnicama. Većinu vremena zemaljski sustavi kombiniraju vizualne senzore s drugim vrstama senzora (vlage, dima i temperature) kako bi se poboljšala učinkovitost otkrivanja požara [8]. Kamere na zemlji mogu pokriti samo ograničena područja i moraju se pažljivo postaviti kako bi se osigurala odgovarajuća vidljivost. Koju površinu tla kamera hvata ovisi o poziciji, nadmorskoj visini i žarišnoj duljini objektiva. Potrebno je instalirati jako velik broj senzora kako bi cijelo šumsko područje bilo pokriveno, a to ekonomski nije isplativo. Zbog toga su mnogi istraživači koji se bave detekcijom šumskih požara usvojili metode kombiniranja informacija dobivenih iz zračnih i zemaljskih kamera [9].

2.2 SUSTAVI BESPILOTNIH LETJELICA

Kamere i njihova upotreba za snimanje iz zraka najjednostavnije su i najstarije od svih senzora koji se koriste za daljinsko istraživanje Zemljine površine. Pokriveno područje ovisi o nadmorskoj visini letjelice na kojoj se kamera nalazi kao i o vidnom polju (eng. Field of view-FOV) letjelice. FOV označava područje koje je vidljivo kroz leću kamere, a izražava se u stupnjevima. Na velikim visinama kamera će snimiti veće područje tla nego na nižim nadmorskim visinama, ali s manje detalja. Za slike na kojima su vidljiva samo velika obilježja kažemo da imaju grubu ili nisku rezoluciju. One na kojima je moguće detektirati sitne značajke svrstavamo u fotografije s finom ili visokom rezolucijom. Prostorna rezolucija odnosi se na veličinu najmanje značajke koju je moguće detektirati. Ako senzor ima prostornu rezoluciju 10m to znači da na slici u punoj rezoluciji svaki piksel prikazuje 10m x 10m površine na zemlji. Fotografije prikupljene iz zraka mogu imati prostornu rezoluciju manju od nekoliko centimetara. [8]



Slika 2.1 Trenutačno vidno polje bespilotne letjelice – FOV [8]

2.3 SATELITSKI SUSTAVI

Sateliti se smatraju najkorištenijom tehnologijom daljinskog istraživanja za mnoge primjene u šumarstvu. Nekoliko je studija usvojilo satelitske snimke za otkrivanje šumskih požara i požarnog dima u šumskim regijama, što bi moglo pomoći u smanjenju rizika od njihovog ponovnog nastanka [10][11]. Vremenska rezolucija satelita ograničenje je koje otežava učinkovitost praćenja šuma, jer nisu dostupne kontinuirane informacije o stanju šuma. Štoviše, oblačni i loši vremenski uvjeti sprječavaju satelite da prikupe jasne podatke o šumama [12].

Po kriteriju prostorne rezolucije satelitski sustavi se dijele u tri skupine. Sustavi srednje rezolucije od 10 do 1000m, visoke od 10 do 100m i vrlo visoke rezolucije manje od 10m [13]. Landsat i Sentinel sustavi su visoke rezolucije koji su stekli popularnost posljednjih nekoliko godina zbog toga što pružaju otvoren pristup podacima, čime je znatno olakšano dobivanje informacija potrebnih u istraživanjima.

Landsat satelit lansiran je 1972. godine i od tada prikuplja slike Zemlje. U samim počecima javljala su se ograničenja u vidu računalnih resursa, mreže i sustava za pohranu slika. Razvijen je kao rezultat suradnje američke geološke službe – USGS i američke svemirske agencije – NASA. Landsat satelitska misija sastoji se od 8 satelita od Landsat- 1 do Landsat- 8, a od 2015. godine pruža otvoren pristup. Prostorna rezolucija ide do 100 metara za termalne kanale, 30 metara za spektralne kanale pa do 15m za pankromatske snimke što ga svrstava u satelite visoke rezolucije [13]. Multispektralne snimke glavne su snimke koje se koriste u daljinskim istraživanjima. Landsat ima 7 senzora i svaki od njih snima po jednu sliku koje potom zajedno čine multispektralni snimak. Senzor u boji - RGB je jedan od i snima u vidljivom dijelu elektromagnetskog spektra na valnim dužinama od 0.4 do 0.7 mikrometara. Suprotno tome termalne snimke obično se koriste za noćna proučavanja jer snimaju na valnim duljinama 10400 – 12500 nanometara i koriste energiju koju objekt sam emitira [14]. Hiperspektralne snimke napredna su verzija multispektralnih jer osim vidljivog dijela sadrže i informacije iz ultraljubičastog i infracrvenog spektra elektromagnetskog zračenja. Jedan piksel hiperspektralne slike pruža puno više informacija o površini koja je snimljena u odnosu na običnu RGB sliku [15]. Landsat se nalazi na udaljenosti od oko 705 km od Zemlje, slika Zemlju 16 puta dnevno i odašilje oko 740 slika na Zemlju, a potrebno mu je 16 dana da se vrati na istu poziciju [16].

Europska svemirska agencija – ESA je kao odgovor na razvoj satelitskih misija za globalna istraživanja 2012. lansirala optički satelitski sustav Sentinel. Sustav se sastoji od šest satelita od kojih je svaki dizajniran za promatranje specifičnih aspekata Zemljinog okoliša i pružanje podataka za specifične primjene. Sateliti Sentinel dio su programa Copernicus, velike inicijative za promatranje i praćenje Zemlje. Podaci prikupljeni satelitima Sentinel koriste se za širok raspon aplikacija, uključujući praćenje šumskih požara, kvalitete tla, klimatskih promjena i vegetacije. Sentinel- 2 sateliti se lansiraju paralelno tako da je vrijeme ponovnog posjeta samo 5 dana kada su oba satelita Sentinel 2a i Sentinel 2b operativni, a 10 dana kada je samo Sentinel 2a u funkciji. Obuhvaća 13 spektralnih kanala od vidljive do infracrvene svjetlosti u prostornim rezolucijama koje se kreću od 60 do 10m [17]. Sateliti Sentinel-2 su izuzetno korisni za različite aplikacije i analize, kao što su monitoring šuma, praćenje kvalitete tla, praćenje kulture, praćenje klimatskih promjena, praćenje vegetacije, praćenje kvalitete voda, praćenje urbanizacije i ostalog. Dostupnost podataka putem otvorenog pristupa satelita tako visoke rezolucije podiže monitoring Zemlje na viši nivo i znatno olakšava i ubrzava daljnja istraživanja i poboljšanja postojećih sustava u različitim područjima interesa.

Osim dva navedena nekomercijalna, postoji još niz manjih komercijalnih satelita vrlo visoke rezolucije, ali oni ne pružaju otvoren pristup podacima za istraživanje pa iz tog razloga nisu navedeni.

3. METODE OBRADJE PODATAKA U DALJINSKOM ISTRAŽIVANJU

Kako bi se podaci prikupljeni iz različitih izvora daljinskog istraživanja pravilno iskoristili i dobile što korisnije informacije primjenjuje se strojno učenje i pripadajući algoritmi za obradu. Primjenom strojnog učenja iz dobivenih podataka izrađuju se klasifikacijske mape iz čega se onda dalje rade potrebne analize. Osim strojnog učenja obrada se može raditi i nekim od klasičnih metoda. [18]

3.1. KLASIČNE METODE OBRADJE U DALJINSKOM ISTRAŽIVANJU

Klasične metode obrade u daljinskom istraživanju koje se izdvajaju su terestričke metode obrade i primjena fotogrametrije.

Kod terestričkih metoda tim stručnjaka izlazi na teren, bilježi opožareno područje, procjenjuje štetu i radi detaljne izmjere kako bi se primjenom fotogrametrije dobilo približno stvarno stanje. Fotogrametrija je „tehnika mjerenja pomoću koje se iz fotografskih snimaka izvodi oblik, veličina i položaj snimljenog predmeta.“ [19] Prve globalne procjene emisija izgaranja biomase oslanjale su se na statistiku. Uzimale su se najbolje pretpostavljene vrijednosti prosječne godišnje spaljene površine u kombinaciji s prosječnim procjenama gustoće biomase i učinkovitosti izgaranja. [20]

3.2. METODE STROJNOG UČENJA

Strojno učenje neizostavan je dio u detekciji i analizi požara pa će biti opisani neki od korištenijih modela strojnog učenja. Prema osnovnoj podjeli strojno učenje dijelimo na nadzirano i nenadzirano.

3.2.1. ALGORITMI NADZIRANOG STROJNOG UČENJA


Nadzirano učenje dio je strojnog učenja koje koristi označene podatke kako bi ih na osnovu karakteristika prema kojima su označeni klasificirao. Kod nadziranog učenja trening se odvija po principu da se unosi što veći broj riješenih primjera odnosno poznatih vrijednosti funkcije $f(x)$ za određene vrijednosti varijable x , na osnovu kojih bi program bio sposoban kao rezultat dati približnu vrijednost funkcije $f(x)$ za novu varijablu x , sa kojom se prvi put susreće.

Dva najčešće korištena modela nadziranog strojnog učenja su model regresije i klasifikacije.

Regresijski model koristi se za predviđanje numeričke vrijednosti ali isto tako se koristi i za procjenu vjerojatnosti kojoj klasi pripada neki uzorak. Ako je procijenjena vjerojatnost veća ili jednaka od 50%, tada model predviđa da uzorak pripada jednoj klasi, a u suprotnom pripada drugoj klasi. Tada se za svaki uzorak prvo računa linearna kombinacija:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + e,$$

gdje je β težinski, a e slobodni koeficijent. Nakon toga se na funkciju Y primjenjuje sigmoidna funkcija koja određuje koja je vjerojatnost da dati uzorak pripada jednoj ili drugoj klasi. Metoda se trenira na testnom skupu podataka, a nakon što se provjeri točnost puštaju se podaci koje želimo obraditi [21].



Slika 3.1 Vizualni prikaz linearne regresije [21]

U slučaju klasifikacije izlaz predstavlja pripadnost predefiniranoj klasi. Uz regresiju i procjenu vjerojatnosti, klasifikacija je jedan od najčešće proučavanih modela s najvećim praktičnim značajem.

U [22] navodi se primjer kategorizacije kod udaljenog okoliša, pikseli na slici kategoriziraju se u vrste usjeva na temelju skupa podataka za obuku koji sadrži varijable ekstrahirane iz slika (ulazne varijable) i varijabli dobivenih iz prikupljenih digitalnih informacija o stanju usjeva i polja (izlazna varijabla). Model klasifikacije usjeva koji je razvijen tada se može primijeniti na ostatak slike gdje stvarni podaci nisu dostupni za klasifikaciju vrste usjeva.

SVM (eng. Support Vector Machines)

SVM [23] je model nadziranog učenja koji pomoću pridruženog algoritma analizira podatke i za klasifikaciju i regresiju. Jedan je od najsnažnijih metoda za predviđanje temeljen na okvirima statističkog učenja. Radi tako da ulazne parametre, koji mu služe za treniranje, preslikava u točke u prostoru koje potom dijeli u dvije kategorije što ga čini binarnim klasifikatorom. Ulazne parametre sortira u dvije kategorije kako bi postigao maksimalan razmak između navedenih kategorija nakon čega se novi parametri preslikavaju u taj isti prostor i predviđa se kojoj će kategoriji pripadati na osnovu toga s koje strane prostora se nalaze. Kako se određeni parametri ne mogu linearno sortirati u zadanom prostoru ulazi se mapiraju u prostor koji je višedimenzionalan. Pokazao je jako dobru primjenu u analizi parametara prikupljenih u području obrade zračnih slika.

KNN (eng. K- Nearest Neighbors)

KNN algoritam [24] kreće od pretpostavke da se parametri sličnih karakteristika nalaze u neposrednoj blizini jedan drugom. Takvu pretpostavku možemo gledati kao vrstu klasifikacije. Kako bi ustanovio koji su parametri slični računa međusobnu udaljenost koristeći Euklidovu funkciju za udaljenost u 2D prostoru:

$$d(p, z) = \sqrt{(z_2 - p_2)^2 + (z_1 - p_1)^2} ,$$

gdje su p i z točke u 2D koordinatnom sustavu između kojih mjerimo udaljenost na temelju Pitagorinog poučka. Kod ovog algoritma najvažnije je dobro odrediti početni faktor K jer o tome dalje ovisi preciznost cijelog modela.

STABLO ODLUČIVANJA

Stablo odlučivanja [25] hijerarhijski je građen model koji se sastoji od glavnog čvora (eng. root), grana i ostalih čvorova. Svaki čvor sadrži pravilo koje određuje kojim granama ići dalje dok se ne dosegne maksimalna dubina stabla. Stablo odlučivanja može se koristiti i za regresiju i za klasifikaciju. Trenirano stablo može se koristiti na novom skupu podataka tako da se svaki primjer procijeni, na osnovu znanja naučenog kroz trening, kroz stablo do konačne predikcije, vrijednosti za regresiju ili prijedloga za klasifikaciju.

ALGORITAM SLUČAJNE ŠUME

Algoritam slučajne šume [26] radi tako što gradi mnoštvo stabala odlučivanja na različitim uzorcima nakon čega uzima prosjek izlaza, koji je uglavnom broj između nula i jedan, za određivanje pripadnosti određenoj klasi, kada su u pitanju zadaci regresije, dok kod klasifikacije na izlazu dobijemo informaciju pripada li ili ne nekoj klasi.

Temelj funkcioniranja stabla odlučivanja je postavljanje smislenih pitanja na koja se odgovara s da i ne te se na osnovu dobivenih odgovora stablo dalje grana. U stablu odlučivanja postoje dva čvora, čvor odluke i čvor lista. Čvorovi odlučivanja koriste se za donošenje bilo koje odluke i granaju se dalje, dok su čvorovi lista rezultat tih odluka i ne sadrže daljnje grane. Rezultat algoritma slučajne šume je bolji što je više stabala odlučivanja.

3.2.2. ALGORITMI NENADZIRANOG STROJNOG UČENJA

Kod nenadziranog učenja glavna je značajka da automatski razvija klasifikacijske značajke. Algoritmi nenadziranog učenja traže slične značajke u podacima koje bi mogli kategorizirati i podijeliti u koherentne grupe. Te grupe nazivaju se klasteri, a metoda klasterska analiza. Za razliku od kategorizacije kod klasterske analize nije poznata izlazna varijabla. Analiza se koristi za predviđanje članstva novih objekata u klasterima na temelju analize sličnosti značajki. Najčešće se koristi grupiranje, a osim toga u algoritme nenadziranog učenja spada analiza glavnih značajki i autoenkoder.

GRUPIRANJE (eng. CLUSTERING)

Algoritam grupiranja [27] radi tako da na temelju sličnih značajki grupira slične dijelove podataka te tako pronalazi zajednički uzorak. Hijerarhijsko grupiranje najstarija je korištena metoda koja funkcionira po principu stabla, a među prvima su je koristili biolozi i sociolozi.

K-mean algoritam je najčešće korišten algoritam koji spada u particionalizirano grupiranje. Podaci su podijeljeni u K klastera gdje K označava broj podskupova, odnosno grupa nekog skupa. Podaci ili objekti koji imaju slične značajke grupiraju se u isti klaster. Algoritam radi tako da se prvo inicijalno odabere centar svakog klastera i objekti se pridružuju najbližem centru. U sljedećem koraku ponovno se izračunava centar klastera i objekt se pridružuje novom najbližem centru. Kao mjera sličnosti između centra i objekta koristi se najkraći razmak među njima odnosno euklidova udaljenost. Navedeni postupak ponavlja se sve dok se centar više ne mijenja [27].

ANALIZA GLAVNIH KOMPONENATA

Analiza glavnih komponenti [28] algoritam je koji se koristi za analizu tablice podataka i redukciju dimenzije podataka. Cilj mu je izdvojiti važne informacije iz tablice, korištenjem matematičkih transformacija, nakon čega ih formira kao skup novih varijabli koje se nazivaju glavnim komponentama. Iz njih se dobije željeni uzorak sličnosti i prikazuje točkama na karti.

3.3. NEURALNE MREŽE

Neuralne mreže [29] su matematički model čija je glavna svrha da oponašaju ljudski mozak. Cilj je naučiti mrežu kako da sama uči. Uz to se želi postići da ima sposobnost prepoznavanja objekata i zvukova kako to čini ljudski mozak ali da velike količine informacija procesira što je moguće brže kako to računala rade. Koriste se za rješavanje kompleksnih zadataka, kao što su klasifikacija i regresija, a sastoje se od neurona koji su povezani težinskim koeficijentima i vrše predviđanje vrijednosti na temelju ulaznih podataka. Postoje različite vrste neuralnih mreža, a neke od njih su neuralne mreže s prijenosom unaprijed (eng. Feed forward network), rekurentne i konvolucijske mreže.

3.3.1. MREŽE S PRIJENOSOM UNAPRIJED (eng. FEED FORWARD NETWORK)

Mreža s prijenosom unaprijed [30] smatra se najjednostavnijom arhitekturom neuralne mreže. To je vrsta neuralne mreže koja funkcionira u jednom smjeru od ulaznog do izlaznog sloja. Sastoji se od više neuronskih slojeva gdje je svaki prethodni u potpunosti povezan sa sljedećim. Koristi propagaciju unaprijed za obradu informacija. Svaka varijabla na ulazu množi se sa

težinama, a potom se dobivene vrijednosti zbrajaju. Ulazi u neuron označeni su s x_1, x_2, x_3 i x_4 , a w_1, w_2, w_3 i w_4 označavaju pripadajuće težine dok y predstavlja izlaz. Takva vrsta neurona naziva se perceptron. Vrijednost izlazne varijable ovisi o tome je li suma umnoška svih ulaznih varijabli i težina manja od granične vrijednosti t . Granična vrijednost označava pristranost prema pozitivnoj klasi.

$$y = \begin{cases} 0, & \text{ako je } \sum_i x_i * w_i \leq t \\ 1, & \text{ako je } \sum_i x_i * w_i > t \end{cases} \quad (3.3.1)$$

Ako je konačna vrijednost iznad inicijalnog praga koji se obično postavlja na nulu onda je vrijednost na izlazu 1, a u suprotnom 0. Koristeći svojstvo poznato kao delta pravilo mreža može usporediti izlaze svojih čvorova s predviđenim vrijednostima, dopuštajući da se težine prilagođavaju tijekom treniranja kako bi izlazne vrijednosti bile što točnije. Ovakav model često se koristi za klasifikaciju, a zbog jednostavne arhitekture može se koristiti u različitim aplikacijama temeljenim na strojnom učenju.

3.3.2. KONVOLUCIJSKE MREŽE

Konvolucijske mreže [29] su specijalizirana vrsta neuralnih mreža koja se sastoji od jednog ulaznog i izlaznog sloja, te jednog ili više skrivenih slojeva. Sam naziv nam govori da koriste konvoluciju, matematičku operaciju, koja je zapravo specijalizirana vrsta linearnih operacija, u barem jednom od svojih slojeva. Uobičajeno je da se višestruko izmjenjuju konvolucijski slojevi i slojevi sažimanja (eng. pooling), a najčešće završavaju s potpuno povezanim slojevima koji služe za klasifikaciju.

Jedan od osnovnih dijelova svake konvolucijske neuronske mreže jesu konvolucijski slojevi koji se sastoje od filtera u kojima su sadržane težine, a vezom jedan na više s prethodnim slojevima uče te težine kako bi mreža na izlazu dala dobre rezultate. Za razliku od njih slojevi sažimanja ne uče ništa, već eventualno mogu pamtit propagaciju pogreške i s prethodnim su slojem uvijek u relaciji jedan na jedan. Mreža se trenira mijenjanjem težina u mreži najčešće metodom širenja unatrag (eng. backpropagation). Potrebno je odrediti ulazne i izlazne parametre, definirati model i funkcije po kojima će se mreža trenirati. Mrežu je potrebno učiti na podacima koji se prikupljaju tijekom vremena kako bi ona mogla stvoriti poveznicu i na osnovu ulaznih parametara predvidjeti izlaz. Mreža uči iz težina veza između neurona u kojima je pohranjeno znanje kakav bi trebao biti izlaz u odnosu na funkciju koja je na ulazu. Te se težine mijenjaju i prilagođavaju sve dok se na izlazu ne dobije traženi rezultat.

Prednost konvolucijskih nad „običnim“ neuralnim mrežama je u tome da su uspješne kod rješavanja kompleksnih problema. Uzmimo za primjer da imamo na ulazu sliku 300x300 piksela, dobivamo 90000 neurona na ulazu. Uzmemo li u obzir da za sliku u boji taj broj trebamo pomnožiti s tri za svaku komponentu RGB jedan kanal, dobivamo 270000 neurona. Takvu mrežu postaje gotovo nemoguće istrenirati i tu konvolucijske neuralne mreže nalaze svoju primjenu. Postavljanjem većeg broja slojeva i prethodno spomenutih filteri detektiraju se bitne značajke i rubovi te na osnovu toga vrši klasifikacija [29].

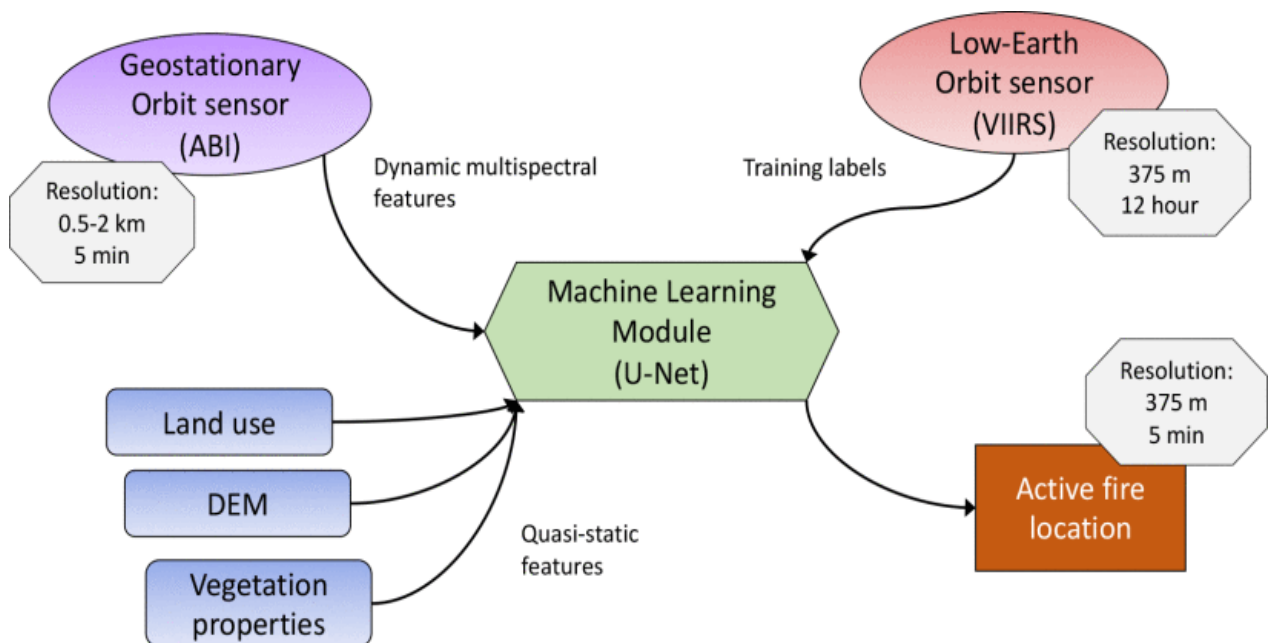
4. DOSADAŠNJA ISTRAŽIVANJA

Strojno učenje u sustavima daljinskog istraživanja najčešće se koristi u poljoprivredi za procjenu iskoristivosti usjeva [31], vatrogastvu za detekciju požara i opožarenog područja [32], u funkciji službe spašavanja za pronalazak unesrećenih [33] i pomorstvu za detektiranje brodova ili procjenu onečišćenja mora [34]. Odbor za satelite koji promatraju zemlju – CEOS (*eng. Committe on Earth Observation Satellites*) zaključio je da daljinsko istraživanje može pružiti visokokvalitetne podatke o stanju i značajkama mnogih prirodnih i izgrađenih resursa, kao što su oceani, usjevi, šume, ekosustavi i ceste [37]. Standardan primjer ekološke statistike koja se može izvesti iz podataka daljinskog istraživanja je promjena šumskog pokrova i krčenje šuma. U svom radu Liangyun i suradnici [35], su primijenili algoritme strojnog učenja na podatke dobivene iz Landsat satelitskih snimaka za procjenu obrazaca deforestacije i mapiranje pošumljavanja. Primjeri poljoprivrednih statistika koji se mogu dobiti iz podataka daljinskog istraživanja uključuju identifikaciju usjeva i prinos usjeva. Jong-Min Yeom i suradnici [36] koristili su satelitske podatke visoke vremenske rezolucije, Geostacionarne slike oceana – GOCI (*eng. Geostationary Ocean Color Imagery*) za praćenje razvoja nepererađene riže u Južnoj Koreji. Širok spektar istraživanja općenito je otkrio da metode strojnog učenja imaju tendenciju proizvesti veću točnost u usporedbi s tradicionalnim parametarskim klasifikatorima. Pristupi strojnog učenja postali su široko prihvaćeni, što dokazuje njihova upotreba u operativnom kartiranju pokrova zemljišta. Klasifikacija zemljišnog pokrova Nacionalne baze podataka o pokrovu zemlje iz 2001. za SAD izrađena je upravo pomoću stabala odlučivanja [38].

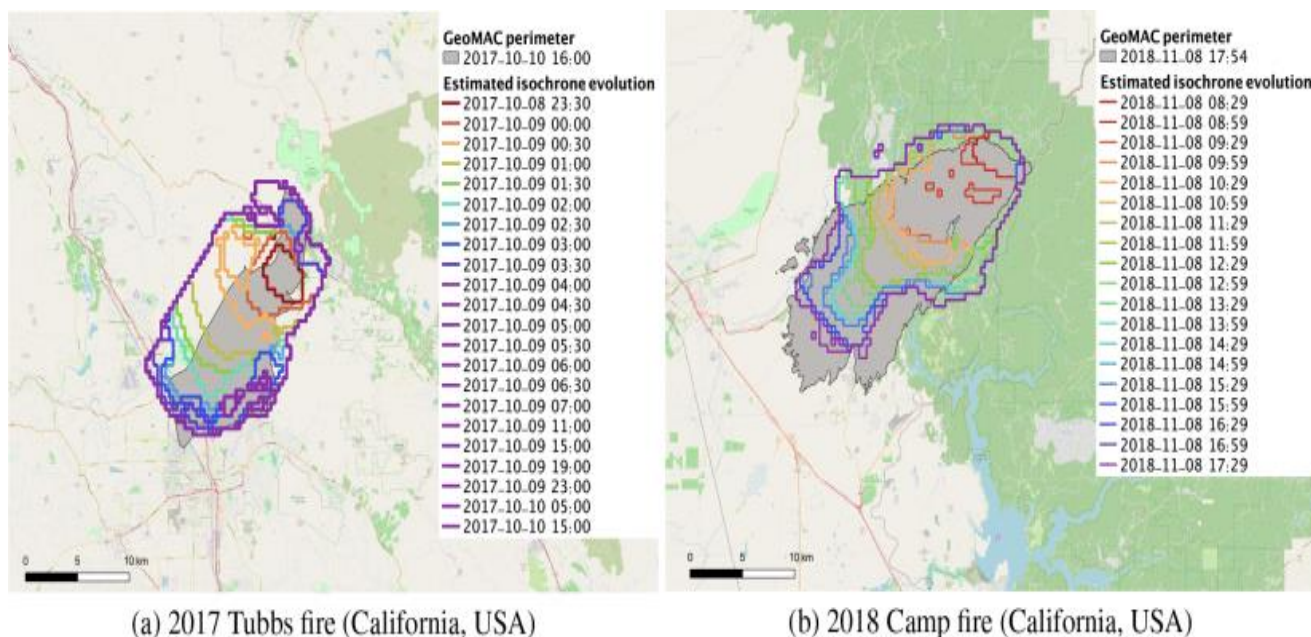
4.1. DETEKCIJA POŽARA

Trenutačan fokus istraživanja je na analizi podataka dobivenih od satelita sa svrhom postizanja sinergije između ekonomskih resursa i očuvanja okoliša. Dizajn satelita uključuje mnoge kompromise i nijedan satelit koji se trenutno nalazi u orbiti nije dizajniran posebno za brzo otkrivanje požara. Unatoč tome, postoji sve veća potreba za korištenjem satelitskih slika sa svrhom pomoći u ranom otkrivanju požara. Prostorna, radiometrijska, spektralna i vremenska rezolucija najvažnije su značajke koje se posljednjih godina značajno unaprjeđuju kako bi bilo dostupno što više detalja na satelitskim snimkama. Slike dobivene sa kamera kojima je baza na zemlji ili iz letjelica imaju dobre rezolucijske značajke ali i određene nedostatke. Nedostatak im je u sigurnosnim i financijskim ograničenjima kao i u tome što ne nude konstantu u prikupljanju podataka što otežava standardizaciju. Za razliku od njih sateliti za zemaljsko opažanje – EO (*eng. Earth Observation*) visoko su pouzdani i pružaju konzistentan tok podataka. Glavno ograničenje im je nedostatak prostorne i/ili vremenske rezolucije i tu se treba tražiti kompromis za postizanje najboljih rezultata. EO platforme rade i na geostacionarnoj orbiti – GEO (*eng. Geosynchronous Equatorial Orbits*) i na orbiti koja je blizu zemljine površine – LEO (*eng. Low Earth Orbits*). Sateliti u GEO omogućuju opažanje Zemlje s visokom vremenskom rezolucijom, dok im se ograničenja očituju u prostornoj rezoluciji. LEO sateliti lete bliže Zemlji, ali obično pružaju 2-4 snimke iste površine dnevno [41]. Obje platforme GEO i LEO koriste se za praćenje požara, ali njihova upotreba zahtijeva kompromis između prostorne i vremenske rezolucije. McCarthy i suradnici [42] predlažu sustav koji se temelji na algoritmu statističkog smanjivanja razlučivosti – SDSM (*eng. Statistical Down Scaling Model*) i U-Net konvolucijske mreže. SDSM se koristi za povećanje prostorne razlučivosti piksela na kojima je vatra za lociranje požara unutar GEO satelitskog snimka dok je U-Net konvolucijska neuronska mreža dizajnirana za obuku na LEO snimcima aktivnih požara i pomoćnim podacima o terenu, vegetaciji i upotrebi zemljišta. Sustav je dizajniran na način da su kao statičke značajke definirane informacije koje se neće često mijenjati. To su

informacije o terenu, vegetaciji i iskorištenosti zemljišta koje su preuzete iz programa LANDFIRE1, dok su dinamičke značajke klasifikacije požara dobivene iz geostacionarnih multispektralnih slika koje šalje senzor ABI (eng. *Advanced Baseline Imager*) instaliran na satelitu GOES-16 . Slike su prostorne razlučivosti između 0,5 km i 2 km, a uvoze se svako 5 minuta. Koristi se šest različitih multispektralnih pojaseva, od vidljivog crvenog (0,64 μm) do dugovalnog infracrvenog pojasa (12,3 μm). LEO slike aktivnih požara neophodne za obuku dobivaju se iz VIIRS (eng. *Visible Infrared Imaging Radiometer Suite*) senzora koji se nalazi na Suomi- NPP satelitu (eng. *Suomi National Polar-orbiting Partnership*). Suomi-NPP je satelit koji se nalazi u niskoj zemaljskoj orbiti i promatra površinu Zemlje dva puta svakih 24 sata. Sistem je testiran, na dva razorna požara Tubbs 2017. i Camp 2018., a korišten je za detekciju aktivnih piksela požara s vremenskom rezolucijom od 30 minuta i prostornom rezolucijom od 375 metara. Kombinacijom slika iz GOES i VIIRS, podataka o terenu, biljnom pokriću i iskorištenosti zemljišta, U-Net je uspio pratiti razvoj požara s 5-minutnim vremenskim intervalima i 375-m prostornom rezolucijom. Dobiveni F rezultat, koji označava mjeru točnosti testa je 0.676 za Tubbs požar iz 2017. i 0.785 za Camp 2018.



Slika 4.1. Dijagram prethodno opisanog sustava za praćenje širenja požara [42]




Slika 4.2. Napredovanje požara u intervalima od pola sata za Tubbs i Camp požar [42]

Fire event	TP rate	FP rate	FN rate	Precision	Recall	F-measure	CSI
2017 Tubbs	0.947	0.853	0.053	0.526	0.947	0.676	0.511
2018 Camp	0.771	0.194	0.229	0.799	0.771	0.785	0.646

Slika 4.3. Tablica mjernih vrijednosti požara Tubbs i Camp [42]

U-Net arhitekturu sve više istraživača koristi u kombinaciji sa podacima dobivenim iz daljinskih izvora i navode dobre rezultate. Rashkovetsky i suradnici [43] istraživali su detekciju požara u oblačnim uvjetima i uvjetima bez oblaka korištenjem četiri izvora satelitskih snimaka različitih prostornih i spektralnih rezolucija (Satinel-1, Satinel-2, Satinel-3 i MODIS). U fazi predobrade prikupljene su slike sa spomenutih satelita nakon čega su dobiveni podaci pročišćeni kako bi se smanjila mogućnost pogreške. Iz njih je generirana baza za trening, validaciju i testiranje U-Net arhitekture. Na kraju je napravljena fuzija podataka korištenjem prosjeka težina.


Single Instrument Model Performance Evaluation



Slika 4.4. Krivulja preciznosti. Što je krivulja bliže gornjem desnom kutu izvedba modela je bolja. S1—Sentinel-1/C-SAR, S2—Sentinel-2/MSI, S3—Sentinel-3/SLSTR, MODIS—Terra i Aqua/MODIS. [43]

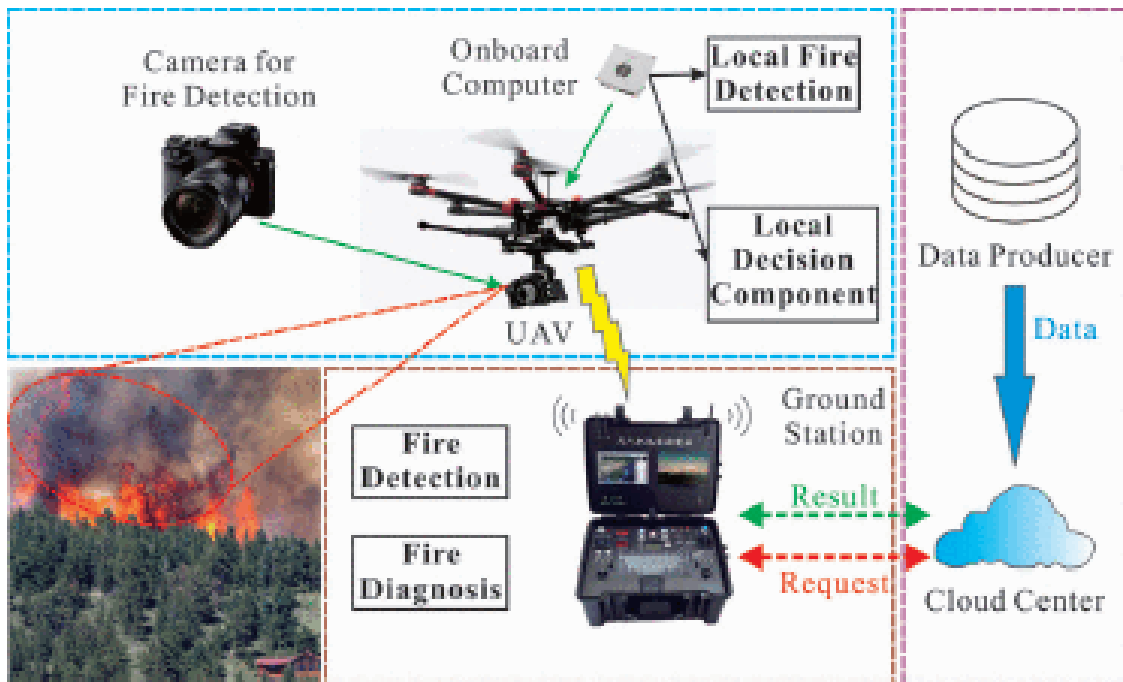
Model treniran na podacima Sentinel-2 ostvario je najbolje rezultate, a slijedili su ga Sentinel-3 i MODIS. Najbolje rezultate u vedrim uvjetima dobili su spajanjem podataka Sentinel 2 i Sentinel 3, dok spajanje Sentinel 1 i Sentinel 2 pokazuje značajnu prednost pri oblačnom vremenu.

Uz U-Net arhitekturu ističe se i Interception V3 model [39], [40]. Govil i suradnici [39] trenirali su model na skupu slika dima iz početne faze požara. Inception V3 radi sa slikama 299 x 299 piksela i ako mu se učitaju veće slike on ih komprimira čime se riskira gubitak piksela dima. Zbog toga u procesu detekcije prvo dijele sliku u segmente po 299 x 299, a zatim se svaki segment šalju sustavu na bazi strojnog učenja [39]. Sustav primjenjuje trenirani model na pojedini segment i vraća rezultat između 0 i 1, pri čemu visoke vrijednosti označavaju prisutnost dima. Kako bi smanjili broj lažno pozitivnih rezultata implementirali su algoritam koji povećava prag za detekciju dima iznad 0.5. Algoritam pronalazi maksimalnu vrijednost, za svaki pojedinačni segment. Zatim postavlja novi prag na prosjek te maksimalne vrijednosti pribrojeno sa 1.. Ako je na početku maksimalna vrijednost bila 0, prag bi bio 0,5, ali ako je bila 0,2, tada bi prag bio podignut na $(0,2 + 1) / 2 = 0,6$. Ova dinamična prilagodba praga smanjila je lažno pozitivne rezultate za 30%. Na kraju su dobili točnost na testnom setu 0,91, a F rezultat 0,89.



Slika 4.5 Primjer detekcije prisutnosti dima na slici [39]

Osim prevencije požara niz znanstvenika bavi se i istraživanjima kako unaprijediti sustave koji bi mogli pomoći vatrogasnim timovima u stvarnom vremenu prilikom gašenja požara. Većina akcija temelji se na klasičnim prostornim metodama, uključujući osmatračnice opremljene raznim sensorima. Međutim, te se metode suočavaju s nekoliko ograničenja koje mogu smanjiti učinkovitost detekcije požara. Osmatračnice imaju ograničenja kao što su ograničeni domet gledanja i visoki troškovi izgradnje. Zbog zemaljskog položaja na kojem se nalaze i same su izložene stradavanju od požara što uzrokuje dodatne troškove. Postoje sustavi za rano otkrivanje šumskih požara i upozoravanje temeljeni na bespilotnim letjelicama koji integriraju različite tehnologije daljinskog istraživanja i tehnike računalnog vida temeljene na dubokom učenju [44]. Letjelica na sebi ima kameru i računalo za brzu obradu slike u stvarnom vremenu. Podaci se šalju na zemaljsku stanicu koja potom locira požar i može poslati željenu operativnu naredbu. Informiraju se vatrogasne službe i planira akcija.




Slika 4.6. Sustav koji upozorava da je aktivan šumski požar [44]

Umjesto slanja zemaljskih posada u opasna okruženja ili korištenja različitih klasičnih tehnika koje imaju mnoga ograničenja u pogledu troškova i učinkovitosti, predlaže se korištenje bespilotnih letjelica. One su opremljene tehnologijama vizualnog daljinskog očitavanja i obećavajuće su tehnologije koje bi mogle pomoći u praćenju šumskih požara i borbi protiv njih. Kombinacija bespilotnih letjelica i arhitektura dubokog učenja mogla bi biti vrlo korisna za otkrivanje požara u njihovim ranim fazama i slanje vrijednih informacija nadležnim tijelima korištenjem učinkovitih komunikacijskih tehnologija [45],[46]. U posljednjih nekoliko godina predloženo je nekoliko algoritama za detekciju požara i dima koji se temelje na dubokom učenju i koji su postigli impresivne rezultate. Većina razvijenih algoritama detekcije temelji se na konvolucijskim neuralnim mrežama (CNN, YOLO, R-CNN, U-Net) [47] [48] što zahtijeva snažan hardver koji ih može izvršavati u stvarnom vremenu. Tehnološki napredak u smislu procesorske snage, senzorskih uređaja i softvera omogućava otkrivanje šumskih požara primjenom snažnih algoritama dubokog učenja na platformama bespilotnih letjelica. One onda mogu detektirati i lokalizirati požar te obavijestiti nadležna tijela u kratkom vremenskom periodu.

4.2 PROCJENA OPOŽAREN OG PODRUČJA

Šume su pluća zemlje i zauzimaju oko 30% ukupne površine zbog čega i je naglasak na razvoju tehnologija koje bi mogle pomoći u njihovom očuvanju. Izuzev samih ulaganja u očuvanje velik iznos financija troši se i na isplate odšteta za osigurane površine koje stradaju u požaru kao i za obnovu opožarenog područja. Procjene izrađene na temelju podataka dobivenih iz satelita procjenjuju da svake godine izgori oko 4 milijuna kilometara kvadratnih površine [49]. U tom smislu moguć je napredak u analizi i procjeni opožarenih područja. Gledano u povijesnom kontekstu može se reći da su algoritmi za otkrivanje opožarenog područja poboljšani u posljednjih deset godina, uključujući nove pristupe obrade, kao i nove senzore i nove metode integracije. Najčešće metode za globalno mapiranje opožarenog područja temeljene su na fizički utemeljenim pravilima koja razlikuju spaljene piksele od ne spaljenih, a uključeni su i

dodatni prostorni i vremenski uvjeti kako bi se nosilo s globalnom raznolikošću uvjeta požara [50]. Sličan pristup kasnije je poboljšan za generiranje proizvoda MODIS MCD64A1 [51] i FireCCI50 [52]. U dvije studije iz 2018. [53] algoritmi integriraju promjene refleksije s aktivnim opažanjima požara dobivenim iz toplinskih anomalija. Slika 4.2.



Slika 4.7 Promjene refleksije s aktivnim opažanjima požara [53]

Razvijen je indeks koji se zove normalizirani omjer sagorijevanja- NBR (eng. *The Normalized Burn Ratio*), računa se za svaki piksel i na kraju daje procjenu koliko je područje stradale vegetacije [52],[53]. Za procjenu globalnog opožarenog područja koriste se senzori koji pružaju vrlo visoku vremensku rezoluciju i grubu prostornu rezoluciju (veličina piksela $\geq 250\text{m}$).

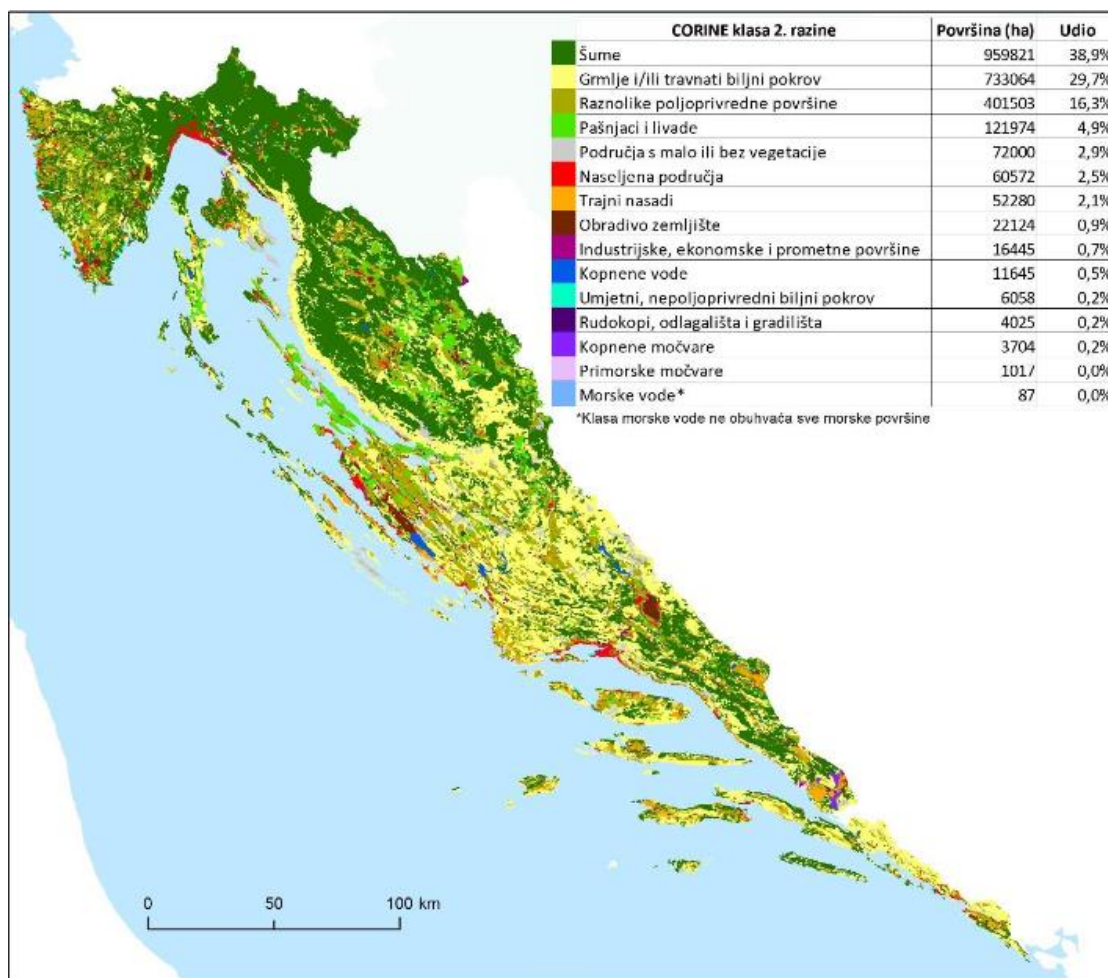
U tablici 1. naveden je popis senzora i njihove rezolucije, iz kojih je dobivena većina dostupnih podataka o opožarenim područjima [54].

SATELIT	VREMENSKA REZOLUCIJA	PROSTORNA REZOLUCIJA
ENVISAT	2 – 3 dana	300 – 1200m
JPSS (VIIRS)	1 -2 dana	375 – 750m
Landsat 1–3	18 dana	80m
Landsat 4–5	16 dana	30 - 120m
Landsat 7	16 dana	15 – 60m
Landsat 8	17 dana	15 – 100m
NOAA-7-19	1 – 2 dana	1100m
PROBA V	1 – 2 dana	300m
Sentinel 1A-B	6 dana	5 – 20m
Sentinel 2A-B	5 dana	10 – 60m

Sentinel 3A-B	1 – 2 dana	300 - 500 m
SPOT 1–7	26 dana	2.5 – 20 m
SPOT 4–5	1 – 2 dana	1000m
Terra-Aqua (MODIS)	1 - 2 dana	250 – 1000m

Tablica 4.1. Rezolucije senzora korištenih u daljinskom istraživanju

Informacije o opožarenom području osim za ekološke svrhe također su bitne i u pravnom smislu na lokalnoj i regionalnoj razini. Važno je pravilno katastarsko bilježenje učinaka požara, zbog iskorištenosti zemljišta i troškova osiguranja kod nezakonitog spaljivanja [55]. U Europi je većina zemalja donijela zakone prema kojima se namjena zemljišta na područjima zahvaćenim požarom ne može mijenjati 10 do 30 godina, ovisno o zemlji [55]. Premija osiguranja i troškovi osiguranja zahtijevaju detaljne informacije o područjima zahvaćenim požarima i razini ozbiljnosti požara, kao i opasnostima nakon požara kao što su klizišta ili blatni tokovi. Ministarstvo financija Republike Hrvatske propisalo je Pravilnik o registru šteta od prirodnih nepogoda u koje spadaju i požari [56]. Na snagu stupa ako je proglašena prirodna nepogoda. Procjena štete određuje se ovisno o vrsti zemljišta (građevinsko, poljoprivredno, šuma). Ovisi i o tome što se nalazilo na zemljištu, koja vrsta poljoprivrednih kultura, drveća, građevine. Nastavno na navedeno postavlja se pitanje na koji se način može olakšati dobivanje informacija o opožarenom području kako bi se što efikasnije odradila procjena štete. Opožarena područja potrebno je mapirati. Danas postoje četiri glavna sustava koja se bave mapiranjem opožarenih područja korištenjem satelita kao izvora podataka. To su FireCCI51, MCD64A1 Kolekcija 6 , Globalna baza podataka o emisijama požara (*eng. Global Fire Emission Database*), i FireCCILT10 [57]. Također je potrebna informacija što se prije požara nalazilo na tom području, a to se može dobiti korištenjem CORINE (*eng. Coordination of Information on the Environment Land Cover*) baze podataka.



Slika 4.8 Karta priobalne RH prema CORINE klasama 2. razine [58]

Kombinacija satelitskih slika, CORINE baze i NBR indeksa može biti dobar temelj za izradu sustava koji bi pružao početnu procjenu štete opožarenog područja. Metodologiju za procjenu opožarenog područja baziranu na ovakvoj ideji u svojem radu predložili su Lorrens i suradnici [59]. Istraživanje su radili na slikama preuzetim sa Sentinel- 2 satelita za regije Španjolske i Portugala, jer su istraživali šumske požare koji su se dogodili u sjeverozapadnoj Španjolskoj i Portugalu 2017. godine. Prema Corine Land Cover (CLC2012) iz 2012. godine, požari su uglavnom zahvatili listopadnu šumu (25 %), crnogoričnu šumu (15 %), mješovitu šumu (10 %), grmlje (30 %) i prijelaznu šumu- grm (20 %). Razina ozbiljnosti požara definirana je korištenjem diferencijalnog omjera sagorijevanja dNBR. Europski informacijski sustav o šumskim požarima – EFIS osigurava dnevno ažuriranje opsega opožarenog područja u Europi dva puta dnevno. U usporedbi sa EFISOM spomenuta metodologija poboljšava procjenu površine za čak 10%. Stoga je zaključak da je Sentinel-2 dNBR dobra alternativa EFIS-u.

5. ZAKLJUČAK

Glavne prednosti primjene metoda strojnog učenja u sustavima daljinskog istraživanja su te što na strog matematički način opisuju uzorkovanje i nedostatak modela, procjenu i predviđanja željenog izlaza kao i odnosa između varijabli. Neki modeli mogu se koristiti za testiranje hipoteza pod određenim pretpostavkama, stabla odlučivanja su primjer modela koji imaju malo pretpostavki. Nedostatak je to što je potreban velik broj istinitih podataka za treniranje modela ili verifikaciju rezultata što također implicira da je model treniran na jednoj vrsti ulaznih podataka jako teško primijeniti u drugom kontekstu bez dorade. Ipak uz primjenu potrebnih preinaka strojno učenje u kombinaciji sa podacima daljinskog istraživanja može uvelike pridonijeti napretku u održavanju i očuvanju okoliša.

Unatoč tome što su metode strojnog učenja duboko involvirane u velik spektar istraživanja daljinskog istraživanja ipak nailaze na određena ograničenja posebno kod detekcije malih nespecifičnih objekata kao što je dim. Ograničenje se javlja zbog toga što su navedeni objekti jako mali s obzirom na cijelu sliku. U tom kontekstu primjenu nalaze konvolucijske neuralne mreže. U mnogim slučajevima, požari nastaju na udaljenim mjestima što čini rano otkrivanje putem opažanja teškim, stoga se informacije dobivene putem daljinskog istraživanja smatraju ključnim rješenjem za ranu detekciju požara. Uzimajući u obzir da su požari složeni fizički procesi koji uključuju različite međusobno povezane čimbenike kao što su vrijeme, topografija, vlažnost tla i lokacija, a uz to su i dinamični potrebno je koristiti podatke iz više različitih daljinskih izvora. To implicira upotrebu fuzije podataka iz različitih izvora daljinskog istraživanja i strojnog učenja. Razvoj sustava za ranu detekciju izuzetno je važan jer može spriječiti širenje požara čime se smanjuje šteta. Osim sustava za ranu detekciju važni su i sustavi koji se bave praćenjem požara i analizom opožarenog područja. Na temelju podataka analiziranih iz prethodnih požara dobiveni rezultati korisni su u određivanju područja visokog rizika za nastanak požara kao i predviđanju brzine i smjera širenja aktualnih požara. To uvelike može pomoći u planiranju akcija gašenja. Analizom opožarenog područja u kombinaciji sa podacima o stanju terena prije požara mogu se izraditi algoritmi koji rade inicijalni izračun nastale štete. To ima tendenciju razvoja kroz buduća istraživanja sa svrhom pružanja početne procjene štete osiguravajućim kućama koje onda na osnovu toga mogu raditi detaljnije procjene.

6. LITERATURA

- [1] YANG, Suwei; LUPASCU, Massimo; MEEL, Kuldeep S. Predicting forest fire using remote sensing data and machine learning. In: *Proceedings of the AAAI Conference on Artificial Intelligence*. 2021. p. 14983-14990.
- [2] CRUTCHER, Paul D.; SINGH, Neeraj Kumar; TIEGS, Peter. Essential Computer Science.
- [3] CAMPS-VALLS, Gustavo. Machine learning in remote sensing data processing. In: *2009 IEEE international workshop on machine learning for signal processing*. IEEE, 2009. p. 1-6.
- [4] BAVISKAR, Monali, et al. REMOTE SENSING DATA PROCESSING WITH MACHINE LEARNING TECHNIQUES
- [5] JIA, Jianxin, et al. Review on active and passive remote sensing techniques for road extraction. *Remote Sensing*, 2021, 13.21: 4235
- [6] FERNANDEZ DIAZ, Juan Carlos, et al. Lidar remote sensing. In: *Handbook of satellite applications*. Springer, New York, NY, 2013. p. 757-808
- [7] GIS Geography, Passive vs Active Sensors in Remote Sensing, s Interneta, <https://gisgeography.com/passive-active-sensors-remote-sensing/>, 20.2.2023
- [8] Natural Resource Canada, Fundamentals of Remote Sensing, https://natural-resources.canada.ca/sites/www.nrcan.gc.ca/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_e.pdf 1.3.2023.
- [9] GOVIL, Kinshuk, et al. Preliminary results from a wildfire detection system using deep learning on remote camera images. *Remote Sensing*, 2020, 12.1: 166.
- [10] KHRYASHCHEV, Vladimir; LARIONOV, Roman. Wildfire segmentation on satellite images using deep learning. In: *2020 Moscow Workshop on Electronic and Networking Technologies (MWENT)*. IEEE, 2020. p. 1-5.
- [11] CARVALHEIRO, L. C., et al. Forest Fires Mapping and Monitoring of current and past forest fire activity from Meteosat Second Generation Data. *Environmental Modelling & Software*, 2010, 25.12: 1909-1914.
- [12] BARMPOUTIS, Panagiotis, et al. Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures. *Remote Sensing*, 2020, 12.19: 3177.
- [13] DEUR, Martina; GAŠPAROVIĆ, Mateo; BALENOVIĆ, Ivan. Pregled satelitskih misija i metoda klasifikacije šumskog pokrova primjenom satelitskih snimaka visoke rezolucije. *Geodetski list*, 2021, 75.2: 143-168.
- [14] <https://sr.wikipedia.org/sr-el/multispektralni%20snimak>, 10.3.2023.
- [15] KOTRIS, Dominik. *Analiza hiperspektralnih satelitskih snimki*. 2020. PhD Thesis. Josip Juraj Strossmayer University of Osijek. Faculty of Electrical Engineering, Computer Science and Information Technology Osijek. Department of Software Engineering. Chair of Visual Computing.
- [16] https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2
- [17] <https://www.usgs.gov/landsat-missions/landsat-8>, 12.3.2023.

- [18] REJAUR RAHMAN, Md; SAHA, S. K. Multi-resolution segmentation for object-based classification and accuracy assessment of land use/land cover classification using remotely sensed data. *Journal of the Indian Society of Remote Sensing*, 2008, 36: 189-201
- [19] K. Kempni, Fotografija-fotogrametrija, <https://tehnika.lzmk.hr/tehnickaenciklopedija/fotogrametrija.pdf> 12.3.2023.
- [20] SEILER, Wolfgang; CRUTZEN, Paul J. Estimates of gross and net fluxes of carbon between the biosphere and the atmosphere from biomass burning. *Climatic change*, 1980, 2.3: 207-247.
- [21] NGO, Theresa Hoang Diem; LA PUENTE, C. A. The steps to follow in a multiple regression analysis. In: *Proceedings of the SAS Global forum*. 2012. p. 22-25.
- [22] HOLLOWAY, Jacinta; MENGERSEN, Kerrie. Statistical machine learning methods and remote sensing for sustainable development goals: a review. *Remote Sensing*, 2018, 10.9: 1365.
- [23] Sunil Ray, Learn How to Use Support Vector Machines (SVM) for Data Science, [https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/#What_Is_a_Support_Vector_Machine_\(SVM\)](https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/#What_Is_a_Support_Vector_Machine_(SVM)), 15.3.2023.
- [24] <https://www.javatpoint.com/k-nearest-neighbor-algorithm-for-machine-learning>
- [25] <https://www.analyticsvidhya.com/blog/2021/08/decision-tree-algorithm/>
- [26] <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>
- [27] YADAV, Jyoti; SHARMA, Monika. A Review of K-mean Algorithm. *Int. J. Eng. Trends Technol*, 2013, 4.7: 2972-2976.
- [28] ABDI, Hervé; WILLIAMS, Lynne J. Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2010, 2.4: 433-459.
- [29] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning vol. 1: MIT press Cambridge*, 2016.
- [30] Kiprono Elijah Koech, How Neural Network Works — with Worked Example (Neural Network Series) — Part 2, <https://towardsdatascience.com/feed-forward-neural-network-with-example-neural-network-series-part-2-eeca7a081ef5> 20.3.2023.
- [31] KUMAR, Sandeep, et al. Remote sensing for agriculture and resource management. In: *Natural Resources Conservation and Advances for Sustainability*. Elsevier, 2022. p. 91-135.]
- [32] THANGAVEL, Kathiravan, et al. Autonomous Satellite Wildfire Detection Using Hyperspectral Imagery and Neural Networks: A Case Study on Australian Wildfire. *Remote Sensing*, 2023, 15.3: 720.
- [33] GOTOVAC, Sven, et al. Visual-based person detection for search-and-rescue with uas: Humans vs. machine learning algorithm. *Remote Sensing*, 2020, 12.20: 3295.
- [34] HAFEEZ, Sidrah, et al. Detection and monitoring of marine pollution using remote sensing technologies. *Monitoring of Marine Pollution*, 2018.
- [35] LIU, Liangyun, et al. Mapping afforestation and deforestation from 1974 to 2012 using Landsat time-series stacks in Yulin District, a key region of the Three-North Shelter region, China. *Environmental monitoring and assessment*, 2013, 185.12: 9949-9965.
- [36] YEOM, Jong-Min; KIM, Hyun-Ok. Comparison of NDVIs from GOCI and MODIS data towards improved assessment of crop temporal dynamics in the case of paddy rice. *Remote Sensing*, 2015, 7.9: 11326-11343.

- [37] Committee on Earth Observation Satellites. Ceos eo Handbook Special 2018 Edition. Available online: <http://eohandbook.com/sdg/index.html> 1.4.2023.
- [38] HOMER, Collin, et al. Completion of the 2001 national land cover database for the conterminous United States. *Photogrammetric engineering and remote sensing*, 2007, 73.4: 337.
- [39] Govil K, Welch ML, Ball JT, Pennypacker CR. Preliminary results from a wildfire detection system using deep learning on remote camera images. *Remote Sensing*. 2020 Jan 2;12(1):166.
- [40] Filonenko A, Kurnianggoro L, Jo KH. Comparative study of modern convolutional neural networks for smoke detection on image data. In *2017 10th international conference on human system interactions (HSI) 2017 Jul 17* (pp. 64-68). IEEE.
- [41] Lentile LB, Holden ZA, Smith AM, Falkowski MJ, Hudak AT, Morgan P, Lewis SA, Gessler PE, Benson NC. Remote sensing techniques to assess active fire characteristics and post-fire effects. *International Journal of Wildland Fire*. 2006 Sep 5;15(3):319-45.
- [42] McCarthy NF, Tohidi A, Valero MM, Dennie M, Aziz Y, Hu N. A machine learning solution for operational remote sensing of active wildfires. In *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium 2020* (pp. 6802-6805). IEEE.
- [43] RASHKOVETSKY, Dmitry, et al. Wildfire detection from multisensor satellite imagery using deep semantic segmentation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 7001-7016.
- [44] JIAO, Zhentian, et al. A deep learning based forest fire detection approach using UAV and YOLOv3. In: *2019 1st International conference on industrial artificial intelligence (IAI)*. IEEE, 2019. p. 1-5.
- [45] HRISTOV, Georgi, et al. Emerging methods for early detection of forest fires using unmanned aerial vehicles and lorawan sensor networks. In: *2018 28th EAEEIE annual conference (EAEEIE)*. IEEE, 2018. p. 1-9.
- [46] KANAND, Thorsten, et al. Wildfire detection and disaster monitoring system using UAS and sensor fusion technologies. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2020, 43: 1671-1675.
- [47] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: Convolutional networks for biomedical image segmentation. In: *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18*. Springer International Publishing, 2015. p. 234-241.
- [48] REN, Shaoqing, et al. Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 2015, 28.
- [49] CHUVIECO, Emilio, et al. Generation and analysis of a new global burned area product based on MODIS 250 m reflectance bands and thermal anomalies. *Earth System Science Data*, 2018, 10.4: 2015-2031.
- [50] CARMONA-MORENO, César, et al. Characterizing interannual variations in global fire calendar using data from Earth observing satellites. *Global Change Biology*, 2005, 11.9: 1537-1555.
- [51] GIGLIO, Louis, et al. The Collection 6 MODIS burned area mapping algorithm and product. *Remote sensing of environment*, 2018, 217: 72-85.

- [52] COCKE, Allison E.; FULÉ, Peter Z.; CROUSE, Joseph E. Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data. *International Journal of Wildland Fire*, 2005, 14.2: 189-198.
- [53] JOVANOVIĆ, Nataša; ŽUPAN, Robert. Analiza stanja vegetacije prije i nakon šumskih požara pomoću satelitskih snimaka Sentinel-2 na području Dalmacije. *Geodetski list*, 2017, 71.3: 233-248.
- [54] CHUVIECO, Emilio, et al. Historical background and current developments for mapping burned area from satellite Earth observation. *Remote Sensing of Environment*, 2019, 225: 45-64.
- [55] MOUILLOT, Florent, et al. Ten years of global burned area products from spaceborne remote sensing—A review: Analysis of user needs and recommendations for future developments. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 26: 64-79.
- [56] https://narodne-novine.nn.hr/clanci/sluzbeni/full/2019_07_65_1278.html 1.4.2023.
- [57] PINTO, Miguel M., et al. A deep learning approach for mapping and dating burned areas using temporal sequences of satellite images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 160: 260-274
- [58] HABIJANEC, Matija. Primjena daljinskih istraživanja u praćenju opožarenih područja Jadranske Hrvatske. 2019. PhD Thesis. University of Zagreb. Faculty of Science. Department of Geography.
- [59] LLORENS, Rafael, et al. A methodology to estimate forest fires burned areas and burn severity degrees using Sentinel-2 data. Application to the October 2017 fires in the Iberian Peninsula. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 95: 102243.

PRILOG TABLICA SLIKA

Slika 2.1 Trenutačno vidno polje bespilotne letjelice – FOV [8]

Slika 3.1 Vizualni prikaz linearne regresije [21]

Slika 4.1. Dijagram prethodno opisanog sustava za praćenje širenja požara [42]

Slika 4.2. Napredovanje požara u intervalima od pola sata za Tubbs i Camp požar [42]

Slika 4.3. Tablica mjernih vrijednosti požara Tubbs i Camp [42]

Slika 4.4. Krivulja preciznosti. Što je krivulja bliže gornjem desnom kutu izvedba modela je bolja. S1—Sentinel-1/C-SAR, S2—Sentinel-2/MSI, S3—Sentinel-3/SLSTR, MODIS—Terra i Aqua/MODIS. [43]

Slika 4.5 Primjer detekcije prisutnosti dima na slici [39]

Slika 4.6. Sustav koji upozorava da je aktivan šumski požar [44]

Slika 4.7 Promjene refleksije s aktivnim opažanjima požara [53]

Slika 4.8 Karta priobalne RH prema CORINE klasama 2. razine [58]

SAŽETAK

Za potrebe ovog kvalifikacijskog rada pregledano je 150 izvora literature. Na Google znalcu pretraživano je prvo sa filterom novije od 2019. godine, a potom po potrebi prošireno starijim izvorima literature. Ključne riječi koje su korištene prilikom pretrage su na engleskom jeziku . Prevedeno to su daljinsko istraživanje, dubinsko učenje, neuralne mreže, šumski požari, detekcija , bespilotne letjelice, analiza, algoritmi strojnog učenja. Od ukupno pregledanih izvora za rad je odabrano 59 referenci. U prvom dijelu rada opisani su sustavi daljinskog istraživanja, potom metode obrade podataka. Nakon toga izdvojena su dosadašnja istraživanja iz navedenog područja koja mogu biti korisna u daljnjem istraživanju. Na kraju je dat zaključak i navedena literatura.