

SVEUČILIŠTE U ZAGREBU

GEODETSKI FAKULTET

Dominik Miletić

DETEKCIJA PROMJENA U PROSTORU NA SNIMKAMA
NANOSATELITA UPOTREBOM NEURONSKIH MREŽA

ZAGREB, 2021.

Ovaj rad izrađen je na Katedri za geoinformatiku Zavoda za geomatiku Geodetskog fakulteta u Zagrebu pod vodstvom doc. dr. sc. Marija Milera i predan je na natječaj za dodjelu Rektorove nagrade u akademskoj godini 2020./2021.

Sadržaj rada

1. UVOD.....	1
1.1 Pregled dosadašnjih istraživanja	2
1.2 Cilj i hipoteze rada	4
2. NEURONSKE MREŽE	5
2.1 Arhitekture neuronskih mreža	5
2.1.1 Duboka neuronska mreža.....	5
2.1.2 Povratna neuronska mreža	6
2.1.3 Konvolucijska neuronska mreža	7
2.2 Aktivacijske funkcije.....	8
2.2.1 Sigmoidna funkcija	9
2.2.2 Hiperbolična tangens funkcija	9
2.2.3 ReLU funkcija.....	10
2.2.4 Leaky ReLU funkcija.....	11
2.3 Algoritam povratnog rasprostiranja pogreške	12
3. METODOLOGIJA RADA.....	14
3.1 Priprema podataka.....	14
3.1.1 Izvori podataka i programsko okruženje.....	14
3.1.2 Spajanje satelitskih snimki i izrezivanje na područje od interesa.....	17
3.1.3 Priprema uzoraka za učenje neuronske mreže	18
3.1.4 Augmentacija podataka.....	21
3.2 Definiranje UNet neuronske mreže.....	23
3.2.1 UNet arhitektura.....	23
3.2.2 Definicija funkcije gubitka i algoritma optimizacije	24
4. ANALIZA REZULTATA.....	25
5. RASPRAVA.....	39
6. ZAKLJUČAK.....	42

Zahvale.....	43
Popis literature	44
Sažetak	47
Summary	48
Popis slika	49
Popis tablica	50
Popis grafikona	51

1. UVOD

Tehnologije opažanja Zemlje, ali i drugih planeta neprestano su bile velik interes čovječanstva. S porastom kvalitete života diljem svijeta često se pojavljivala potreba za praćenjem promjena poput promjene vegetacije, izdvajanja novogradnje itd. na nekom području. Prvi značajni korak bio je u 11. stoljeću s razvojem fenomena *Camere obscurae*, a kasnije su od neophodnog značaja bila istraživanja u području optike i dizajniranja leća koja su dovela do razvoja teleskopa pomoću kojeg je bilo moguće opažati planete u našem Sunčevom sustavu. Promatranje površine Zemlje bio je težak posao sve dok uz brojna dostignuća u avioindustriji nisu začeta daljinska istraživanja kakva se i danas poznaju uz neprekidan daljnji razvitak.

Prema Međunarodnom društvu za fotogrametriju i daljinska istraživanja (URL 1) (engl. International society for photogrammetry and remote sensing) daljinska istraživanja predstavljaju znanost i tehnologiju prikupljanja, obrade i analiziranja snimki zajedno s ostalim fizikalnim podacima Zemlje i planeta posredstvom senzora iz svemira, zraka i tla.

Daljinska istraživanja se brzo razvijaju s razvojem tehnologija senzora. Veliki napredak postignut je u broju aktivnih senzora koji neprestano prikupljaju fizikalne, kemijske i biološke informacije o Zemljinoj atmosferi i njezinoj površini. Novije generacije satelitskih senzora sve češće se lansiraju u većim grupama zbog potrebe za većom temporalnom rezolucijom satelita iznad bilo kojeg područja. Posljedica toga je da su se dimenzije satelita koji nosi senzor morale značajno smanjiti kako bi se smanjili troškove lansiranja. Danas je moguće proizvesti dovoljno male satelite da su brojni dobili naziv nanosatelit.

Zbog kompleksnih korisničkih zahtjeva postignuti su uspjesi sa smanjivanjem spektralne razlučivosti, a samim time i povećavanjem broja kanala snimki čime se dobiva mogućnost pouzdanije interpretacije objekta na sceni. Sami sateliti imali su značajan napredak i u pogledu prostorne razlučivosti (engl. Ground Sample Distance). Današnji senzori (poput onih koji se nalaze na WorldView-2 ili GeoEye-2) su u mogućnosti prikupljati informacije s prostornom rezolucijom boljom od 0.5 metara.

Spomenutim razvojem tehnologije, sve je veća važnost posvećena praćenju nekog područja ili fenomena od interesa tijekom užeg vremenskog razvoja. Uz praćenje objekata dolazi do izdvajanja i detekcije objekata od interesa, ali i izdvajanje njihovih promjena. Detekcija promjena posredstvom senzora, osobito iz svemira zbog velikog vidnog polja, široko je primjenjiva za npr. praćenje urbanizacije, razvoj dinamike šumskih područja, kao pomoć u

kriznim situacijama, za razumijevanje ljudskih utjecaja na okoliš itd. Upravo zbog senzora visoke prostorne rezolucije postalo je pogodno pratiti promjene u područjima s velikim brojem objekata od značaja (npr. gradska područja) s visokom razinom automatske interpretacije same promjene.

1.1 Pregled dosadašnjih istraživanja

Detekcije promjena mogu se podijeliti prema pristupu (Asokan, Anitha, 2019.) u pet kategorija: algebarski, transformacijski, klasifikacijski pristup, GIS i napredni pristupi.

Primjer algebarskog pristupa detekciji promjena zasniva se na promjeni spektralnog kuta (Wen, Yang 2009.) u prostoru značajki za svaki piksel između dvije snimke. Promjene u spektralnog kutu često predstavljaju promjene fizikalnih parametara objekta. Nakon generiranog prikaza potrebno je odrediti prag (engl. threshold) kojim se odlučuje je li došlo do promjene na samom pikselu ili ne.

Definicija promjena na razini piksela dobrim je dijelom zavisna o potrebama stručnjaka. Ponekad je dovoljno odrediti samo najznačajnije promjene primjenom Helmholtzovog principa (Lisani, Morel, 2003.), dok se prag može odrediti iz prosječnih vrijednosti prostora oko piksela od interesa.

Metode koje se zasnivaju na pikselima često imaju problema prilikom korištenja satelitskih snimaka vrlo visoke rezolucije (manje od jednog metra) (Liu i dr., 2016.). Otkrivanje promjena koja se temelji na pojedinim pikselima često je opterećeno šumom. Tada je poželjno iskoristiti modele koji se zasnivaju na strukturama ili značajkama. Problem je izraženiji u gradskim sredinama gdje može doći do paralakse zbog nepoklapanja položaja senzora između dva datuma od interesa. Tomu pridonose i brojni drugi utjecaji poput kombiniranja različitih senzora, manjak kontrasta te utjecaji sjena i oblačnih pokrova. Jedno od predloženih rješenja koristi profile morfoloških atributa (Falco i dr., 2013.) za pankromatske (jednokanalne) snimke. Takav pristup dozvoljava izdvajanje geometrijskih značajki scene različitih mjerila. Promjene se otkrivaju usporedbom karti geometrijskih značajki za različite datume.

Ako se radi o snimkama vrlo visoke rezolucije često je cilj pratiti promjene na zgradama, ali kao što je prethodno spomenuto, paralaksa je česti problem. Moguće je u tom slučaju iskoristiti stereoparove (Tian i dr., 2016.) kako bi se došlo do rješenja spajanjem generiranog digitalnog plošnog modela i prostorno vremenskih informacija kako bi se dobile karte vjerojatnosti

zgrada. Promjene se otkrivaju na objektnoj razini temeljem karti vjerojatnosti, potom na razini piksela kako bi uklonili ekstremne vrijednosti.

Također jedna od složenijih i učinkovitih metoda za otkrivanje promjena je deduktivna fuzija. Ova metoda koristi se ukoliko su slojevi prethodno segmentirani metodom poput nasumičnih višeslojnih Markovih polja (Benedek i dr., 2015.) nakon čega se provodi fuzija na razini piksela.

Razvojem daljinskih istraživanja raste i popularnost strojnog učenja kao složenog rješenja za otkrivanje promjena na način da se pripreme uzorci za učenje zajedno s označenim značajkama nad kojima se dogodila promjena, često na razini piksela. Tim pristupom mogu se razviti i naučiti višestruke neuronske mreže koje su sposobne dati opće rješenje specifičnog problema. Poseban tip neuronske mreže, konvolucijske neuronske mreže, su po svojoj prirodi vrlo pogodne za analiziranje promjena na snimkama. Takve mreže mogu se kombinirati i s *attention* mehanizmima koji se zasnivaju na oduzimanju pojedinih kanala od prethodnih karti značajki (Chen i dr., 2020.) kako bi se postigli kvalitetniji rezultati.

Nove arhitekture neuronskih mreža neprestano se istražuju i razvijaju. Jedna od poznatijih mreža nazvana je *Early Fusion* čiji se ulaz sastoji od snimki koja se sastoji od spojene dvije. Takva mreža ulazi u početku u konvolucijsku mrežu koja završava na potpuno povezanim slojevima (Daudt i dr., 2018.). Uz *Early Fusion* u literaturi se spominje i Sijamska mreža u kojoj paralelno ulazi par snimki koji se nakon nekoliko konvolucijskih slojeva spajaju.

Iako je arhitektura same mreže je bitna stavka u bilo kojem problemu strojnog učenja, funkcije gubitka (engl. Loss function) su sastavni dio učenja mreže te je ovo područje još uvijek nedovoljno poznato i predstavlja aktivno istraživačko područje. Funkcija težinskog kontrastnog gubitka pokazala je dobre rezultate u sijamskoj arhitekturi konvolucijske neuronske mreže (Zahn i dr., 2017.).

Potpuno konvolucijske neuronske mreže potencijalno mogu isto dati visoko-kvalitetne rezultate. Mreža temeljena na UNet++ arhitekturi također je korištena za otkrivanje promjena gdje se kombiniraju izlazi za više razina obrade kako bi stvorili karte s visokom prostornom razlučivošću (Peng, Zhang i Guan, 2019.).

1.2 Cilj i hipoteze rada


Cilj ovog rada je primijeniti UNet konvolucijsku neuronsku mrežu za otkrivanje promjena između para satelitskih snimki prikupljenih PlanetScope misijom te analizirati razlike rezultata dobivenih s i bez poboljšanja ulaznih podataka. Hipoteze ovog rada su:

1. UNet konvolucijskom neuronskom mrežom moguće je detektirati promjene između parova satelitskih snimki prikupljenih istim senzorom u različito vrijeme
2. Povećanjem brojnosti podataka kroz augmentaciju moguće je povećati kvalitetu dobivenih rezultata

Ovaj rad sastavljen je od šest poglavlja. U uvodnom poglavlju iskazana je motivacija za izradom rada te je dan pregled prethodnih istraživanja uz strukturu samog rada. U drugom poglavlju opisane su osnove strojnog učenja i struktura neuronskih mreža. U trećem poglavlju opisano je prikupljanje podataka, njihova priprema i obrada za učenje mreže. U četvrtom poglavlju predstavljene su dobiveni rezultati za oba skupa podataka te se analizira kvaliteta dobivenih rješenja. U petom poglavlju uspoređuju se rezultati i njihova kvaliteta s prethodnim radovima. U posljednjem poglavlju dan je zaključak po poglavljima.

2. NEURONSKE MREŽE

Osnovna jedinica umjetne neuronske mreže jest neuron koji se može zamisliti kao objekt koji sadrži jedan broj. Pojedinačni neuroni se obično spajaju u slojeve koji se dalje međusobno povezuju. Takva struktura naziva se model potpuno povezanih slojeva i u njoj je svaki neuron u sloju povezan sa svim neuronima prethodnog i sljedećeg sloja. Općenito, pojedini neuron u mreži poprima vrijednost kao umnožak težina i vrijednosti neurona iz prethodnog sloja. Takva vrijednost prolazi kroz aktivacijsku funkciju te se šalje dublje u mrežu (slika 1.).



Slika 1. Struktura neurona

Školski primjer upotrebe neuronskih mreža je u raspoznavanju ručno napisanih brojeva koji se skeniraju i daju kao ulaz u mrežu koja je sposobna klasificirati broj.

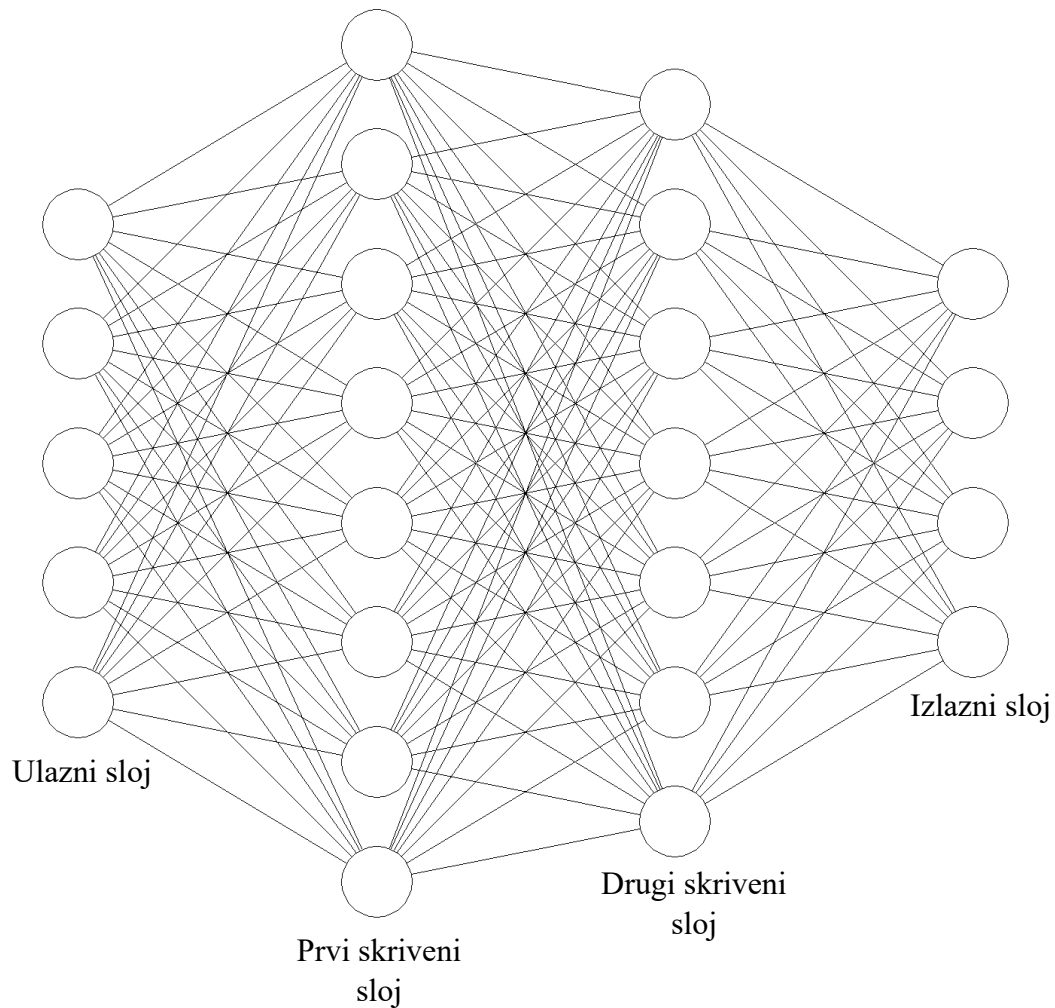
2.1 Arhitekture neuronskih mreža

U ovom podpoglavlju opisane su danas najčešće korištene arhitekture neuronskih mreža s opisom mogućih primjena.

2.1.1 Duboka neuronska mreža

Duboka neuronska mreža je mrežna struktura (slika 2.) koja se sastoji od ulaznog sloja, određenog broja skrivenih slojeva i izlaznog sloja. Unutar svakog sloja postoji određeni broj neurona. Primjer primjena dubokih neuronskih mreža su sustavi za preporuku, razvoj modela


za upravljanje raskrižjima, bioinformatika, otkrivanje droga i dr (Hordri, Yuhaniz, Shamsuddin, 2016).



Slika 2. Skica duboke neuronske mreže s dva skrivena sloja

2.1.2 Povratna neuronska mreža

Povratna neuronska mreža se usredotočuje na sekvencijalne informacije. Specifičnost ove mreže leži u tome da se podaci u mreži obrađuju u petljama kako bi se privremeno zadržala stečena znanja, odnosno, svaki izlaz mreže ponovno se vraća u istu mrežu. Moguće je definirati mrežu gdje se u svakom sloju nalazi povratna petlja (slika 3.). Neke od mogućih primjena povratnih neuronskih mreža su za predviđanje kaotičnih događajih, učenje jezika modeliranja dinamičkih sustava, adaptivno upravljanje robotima i dr. (Medsker, Jain, 2001.)




Slika 3. Sloj povratne neuronske mreže

2.1.3 Konvolucijska neuronska mreža

Specifičan tip mreže koji je vrlo prikladan za obradu slika je konvolucijska neuronska mreža. Osim klasičnih, potpuno povezanih slojeva, ovaj tip mreže sastoji se i od konvolucijskih slojeva te slojeva uzorkovanja. Konvolucijski sloj predstavljen je filterom dimenzija $n \times n$, gdje je n neparan broj. Time se dobiva nova slika značajki. Sloj uzorkovanja je sloj koji se ne uči, već je on statičan i prethodno definiran, a najčešće se primjenjuje kako bi se provelo sažimanje slike za neki faktor koji se definira drugim filterom dimenzija $m \times m$, gdje je m iz skupa prirodnih brojeva takav da je m pravi djelitelj dimenzija slike. Nad tim filterom uzimaju se ili prosječne vrijednosti ili maksimalna, što je prikazano na slici 4. Konvolucijske neuronske mreže se međusobno najviše razlikuju u izlaznom sloju koji može također biti konvolucijski, ali i potpuno povezani sloj. Ukoliko je zadnji sloj konvolucijski obično to predstavlja izlaznu sliku gdje se ističu značajke od interesa, a ako je zadnji sloj potpuno povezani sloj (kao u dubokim neuronskim mrežama) onda se najčešće radi o klasifikaciji cijele snimke.

Najčešći cilj ovakve mreže je izvući specifične značajke slika te za izlaz (rezultat) dati klasifikaciju. Tipične primjene konvolucijskih neuronskih mreža (Shamsaldin i dr., 2019.) su prepoznavanje lica, označavanje scene, klasifikacija slika, detekcija promjena i sl.



Slika 4. Primjer strukture konvolucijske neuronske mreže (URL 2)

2.2 Aktivacijske funkcije

Aktivacijske funkcije su sastavni dio neuronskih mreža. One su te koje daju odluke o tome kako će krajnji rezultat pojedinog neurona izgledati, odnosno hoće li se pojedini neuron aktivirati ili ne (Feng, Lu, 2019.). Ulaz u aktivacijsku funkciju predstavljaju težinske sume neurona zbrojene s konstantom iz prethodnog sloja. Za učenje neuronske mreže neophodno je da su funkcije derivabilne kako bi se mogao provesti algoritam propagacije unatrag.

Općenito, izlaz neurona može se opisati sljedećim izrazom (URL 3):

$$y = \varphi \left(\sum_{i=1}^m x_i * w_i + b \right) \quad (1)$$

gdje su:

- x_i – ulazni signali neurona
- w_i – težine neurona
- b – greška sloja
- φ – aktivacijska funkcija

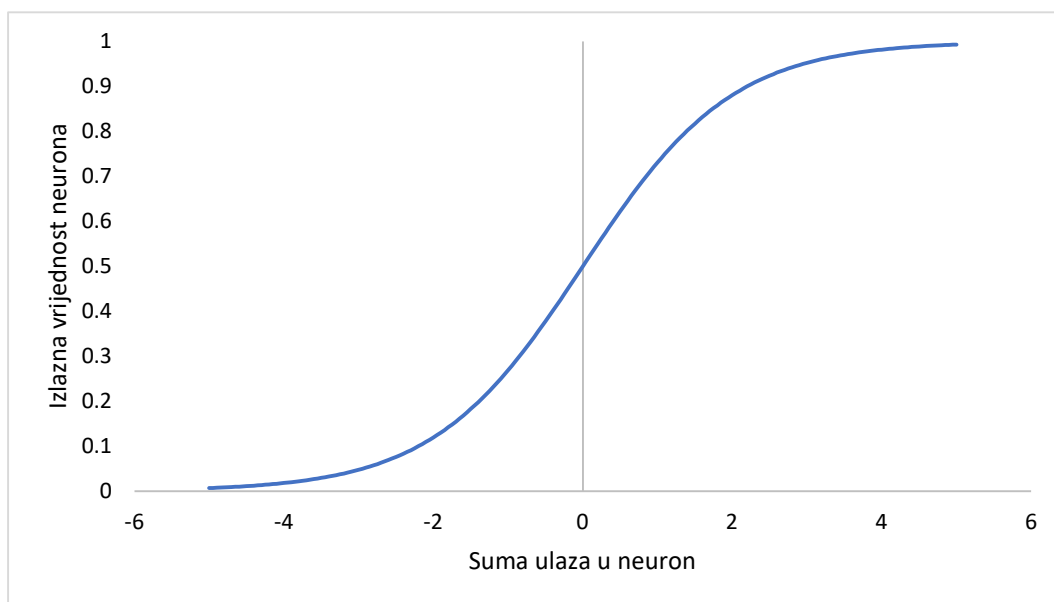
U nastavku je dan pregled najčešće korištenih aktivacijskih funkcija.

2.2.1 Sigmoidna funkcija

Sigmoidna ili logistička funkcija je nelinearna aktivacijska funkcija koja je definirana izrazom:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Bitno svojstvo ove funkcije je da njena kodomena u rasponu $\langle 0, 1 \rangle$ koja se tumači kao vjerojatnost. Također, ima svojstvo da uvijek daje pozitivan rezultat neovisno u ulazu, što je rezultat činjenice da nije centrirana u koordinatnom sustavu. S grafikona 1. također se može zaključiti da vrlo male vrijednosti rezultiraju izlazu blizu 0, dok se vrlo visoke vrijednosti preslikavaju blizu 1. Jedna od prednosti korištenja ove funkcije jest njena derivacija, koja je glatka i neprekidna funkcija. Time se znatno olakšava učenje neuronske mreže.



Grafikon 1. Sigmoid aktivacijska funkcija


2.2.2 Hiperbolična tangens funkcija

Hiperbolična tangens funkcija, iako sličnog izgleda kao i sigmoidna funkcija, ima različita svojstva. Kodomena funkcije je u rasponu $\langle -1, 1 \rangle$, što znači da je, za razliku od sigmoidne funkcije, u mogućnosti dati negativni rezultat. Funkcija je definirana izrazom:

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3)$$

S grafikona 2 također se može zaključiti da vrlo male vrijednosti rezultiraju izlazu blizu -1, dok se vrlo visoke vrijednosti preslikavaju blizu 1. Kao i u slučaju sigmoidne funkcije, derivacija

ove funkcije je također glatka i neprekidna. Prednost nad sigmoidnom funkcijom ima u tome da su gradijenti veći u blizini nule što može rezultirati bržim učenjem mreže, ali i većom osjetljivošću na promjene u ulazu.




Grafikon 2. Hiperbolička tangens aktivacijska funkcija

2.2.3 ReLU funkcija

ReLU (engl. Rectified Linear Unit) je linearna funkcija koja rezultira nulom, osim u slučaju kada je ulaz veći od 0 kada je rezultat jednak ulazu:

$$f(x) = \max(0, x) \quad (4)$$

Na grafikonu 3. dana je vizualizacija ReLU funkcije. Ova funkcija nema svojstvo da je njena derivacija glatka i neprekidna funkcija što se nadomješta vrlo jednostavnim računom derivacije. Utvrđeno je (Szandała, 2020.) da ReLU funkcija ima znatno učinkovitije učenje mreže u odnosu na ostale aktivacijske funkcije.



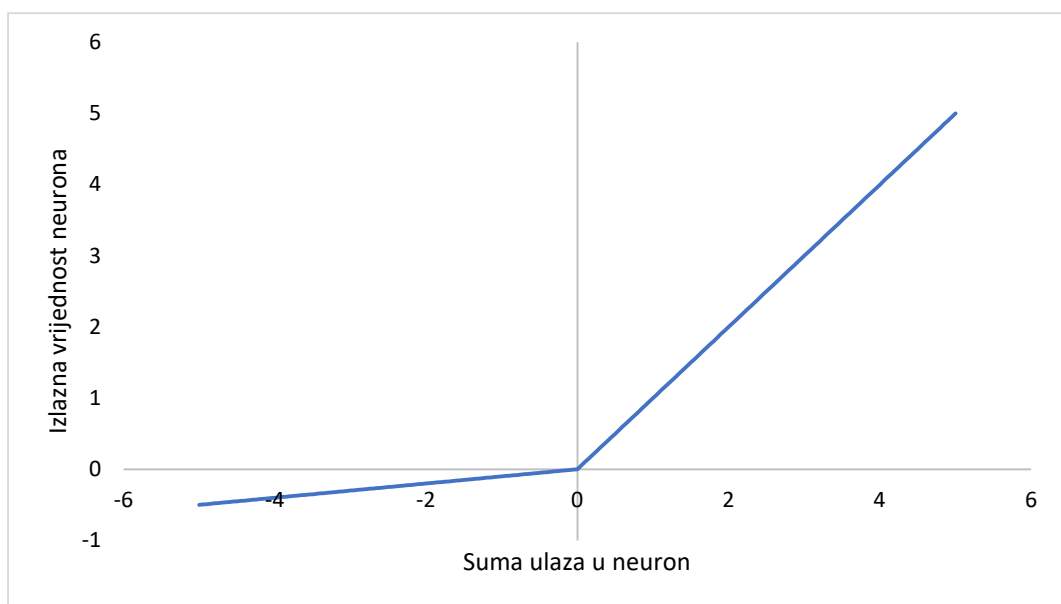
Grafikon 3. ReLU aktivacijska funkcija, prag = 0

2.2.4 Leaky ReLU funkcija

Slična funkcija je Leaky ReLU koja za vrijednosti manje od 0 množi ulaz s vrlo malom konstantom, obično oko 0.1 (Szandała, 2020.):

$$f(x) = \begin{cases} \alpha x & \text{za } x \leq 0 \\ x & \text{za } x > 0 \end{cases} \quad (5)$$

S grafikona 4. vidljivo je da se ulazne vrijednosti manje od 0 preslikavaju u vrijednosti manje od 0, dok ulazi veći od 0 se preslikavaju u samog sebe. Kao i obična ReLU funkcija, ovdje se također ne pronalazi glatka i neprekidna derivacija funkcije.




Grafikon 4. Leaky ReLU aktivacijska funkcija

2.3 Algoritam povratnog rasprostiranja pogreške

Najvažniji dio svake neuronske mreže je njeno učenje, odnosno treniranje. Svaka pravilno konstruirana mreža je u mogućnosti dati izlazno rješenje iako je u samom početku to izlazno rješenje obično grubo netočno. Zbog toga je potrebno učiti mrežu u više epoha, tj. prolazaka kroz podatkovni skup. Za učenje bilo koje neuronske mreže postoji ulazni skup podataka zajedno s pripadnim poznatim krajnjim rezultatima za koje se želi dati opće pravilo.

Cilj algoritma povratnog rasprostiranja pogreške je pronaći težine mreže takve da za svaki ulaz iz skupa za učenje mreže dobije izlaz koji je sličan *treba* vrijednosti. Iz tog razloga, nakon što se za pojedinu epohu u trenutku učenja dobije konačni rezultat, taj rezultat se uspoređuje s *treba* vrijednosti. Ukoliko se dobivene vrijednosti razlikuju od prave vrijednosti, znači da postoji pogreška sustava koja se treba modelirati. Postoji veliki broj funkcija kojima se može izraziti tako dobivena greška, a jedna od najčešće korištenih je srednja kvadratna pogreška.

Sljedeći korak podrazumijeva raspodjelu pogreške u svakom sloju (i neuronu) što se radi kroz gradijente aktivacijskih funkcija. Raspodjela pogrešaka započinje od zadnjeg sloja te se promatra kako pojedina težina utječe na pogrešku što se može vizualizirati 2D plohom u 3D prostoru. Na slici 5. dan je primjer modelirane plohe težina za jedan sloj. Na apscisnu i ordinatnu os nanesene su težine dok aplikatna os predstavlja pogrešku. Za takav model potrebno je za svaku težinu izračunati gradijent kako bi se moglo definirati kako će se iste popravljati. Cilj je minimizirati pogrešku, a gradijent služi kako bi „usmjerili“ popravku težina u pravom smjeru.



Slika 5. Pogreška kao funkcija težina (Makin, 2006.)

Navedeni postupak se vrši za svaki pojedini sloj unazadno. Time je moguće izmijeniti težine pojedinih neurona kako bi dobili bolje rješenje. Sljedećim izrazom (Kröse, Smagt, 1996) računaju se nove težine svakog pojedinog neurona:

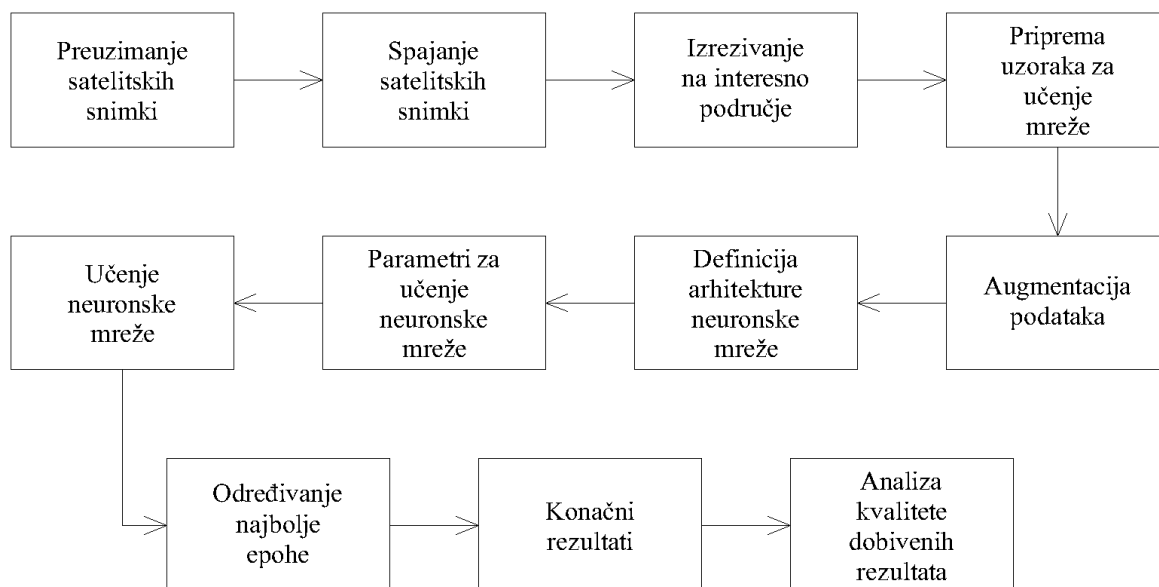
$$w_{ij} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \quad (6)$$

gdje je:

- w_{ij} – težina između i-tog neurona prethodnog sloja i j-tog neurona trenutnog sloja
- η – brzina učenja, konstanta
- $\frac{\partial E}{\partial w_{ij}}$ – parcijalna derivacija greške po težinama

3. METODOLOGIJA RADA

U sljedeća dva potpoglavlja opisan je korišteni tijekom izrade implementacije UNet neuronske mreže, stvaranja karte detektiranih promjena i analiziranja dobivenih rezultata koji je definiran na slici 6.



Slika 6. Tijek izrade karte promjena


3.1 Priprema podataka

U ovom podpoglavlju opisuju se proces pripreme podataka za učenje neuronske mreže.

3.1.1 Izvori podataka i programsko okruženje

Planet Labs je tvrtka koja se bavi opažanjem Zemlje. Njihov cilj je satelitima za daljinska istraživanja snimati cijelu Zemljinu površinu pomoću velike konstelacije satelita visoke i vrlo visoke rezolucije. Uz to, pruža i web-platforme kako bi omogućila uvid na odluke koje su visokog prioriteta.

PlanetScope konstelacija satelita sastoji se od više od 180 DOVE (URL4) satelita. Nazvani su *cubesateliti* ili skraćeno *cubesati* zbog svojih iznimno malih dimenzija koje spadaju u kategoriju nanosatelita. Na slici 6. prikazan je PlanetScope DOVE nanosatelit, dok su u tablici 1. dani parametri misije.



Slika 7. PlanetScope DOVE nanosatelit (Izvor: URL 2)

Tablica 1. Parametri PlanetScope misije (Izvor: URL 2)

Visina orbite	450 - 500 km
Tip orbite	Sa Suncem sinkrona
Inklinacija orbite	98°
Maksimalna/minimalna geografska širina	± 81.5°
Interval ponovnog preleta	Približno jedan dan
Vrijeme prelaska iznad Ekvatora	U intervalu 9:30 – 11:30 (lokalno solarno vrijeme)

Osnovne specifikacije satelita prikazane su u tablici 2. Proizvođač garantira kalibraciju satelita s apsolutnom točnošću od 5%.

Tablica 2. Specifikacije DOVE satelita (Izvor: URL 2)

Masa	5.8 kg
Dimenzije	10 cm x 10 cm x 30 cm
Životni vijek satelita	2 – 3 godine

PlanetScope kamere na svakom DOVE cubesatu sadrže 4-kanalni senzor s radiometrijskom rezolucijom od 12 bita čiji su detalji prikazani u tablici 3.

Tablica 3. Parametri kanala PlanetScope kamere (Izvor: URL 5)

Naziv kanala	Raspon valnih duljina
Plavi	455 – 515 nm
Zeleni	500 – 590 nm
Crveni	590 – 670 nm
Bliski infracrveni	780 – 860 nm

Prostorna razlučivost senzora u nadiru iznosi 3.7 – 4.0 metara s približnim dimenzijama obuhvata 24 km x 16 km. Prostorna razlučivost preuzorkuje se na 3.0 metara u procesu obrade.

Na zahtjev Geodetskog fakulteta preuzeto je ukupno 6 snimki – tri snimke 2019. i tri za 2020. godinu za interesno područje, tj. šire područje grada Zagreba. S ciljem minimiziranja različitih bioloških i atmosferskih razlika, snimke su preuzete u približno istom razdoblju. Također, neophodno je da preuzete snimke imaju minimalnu prekrivenost oblacima što bi dodatno ograničilo uporabljivost snimki. Preuzete snimke prikupljene su za datume 6. kolovoza 2019. i 22. kolovoza 2020. Radiometrijske korekcije te korekcije senzora su provedene od strane proizvođača. Preuzete snimke su u *.GeoTIFF formatu te imaju razinu obrade 3A, odnosno snimke su ortorektificirane te su preslikane u UTM 33N projekcijskom sustavu na WGS84 elipsoidu. Vrijednosti piksela preuzetih snimki predstavljaju površinsku reflektancu s radiometrijskom rezolucijom 16 bita.


Programsko okruženje ovog rada sastoji se od dva dijela: Anaconda sučelje za Python 3.7 programski jezik te QGIS 3.8.3 programski alat otvorenog koda za računalne geografske informacijske sustave.

Uz standardne module u Pythonu korišteni su dodatni neophodni moduli:

- NumPy: modul koji omogućava numerička računanja u Python okruženju (URL 6)
- GDAL: modul za obradu rasterskih i vektorskih oblika podataka (URL 7)
- TensorFlow: modul za stvaranje modela strojnog učenja (URL 8)
- Keras: modul građen na TensorFlow-u, daje programsko sučelje pogodno za strojno učenje (URL 9)

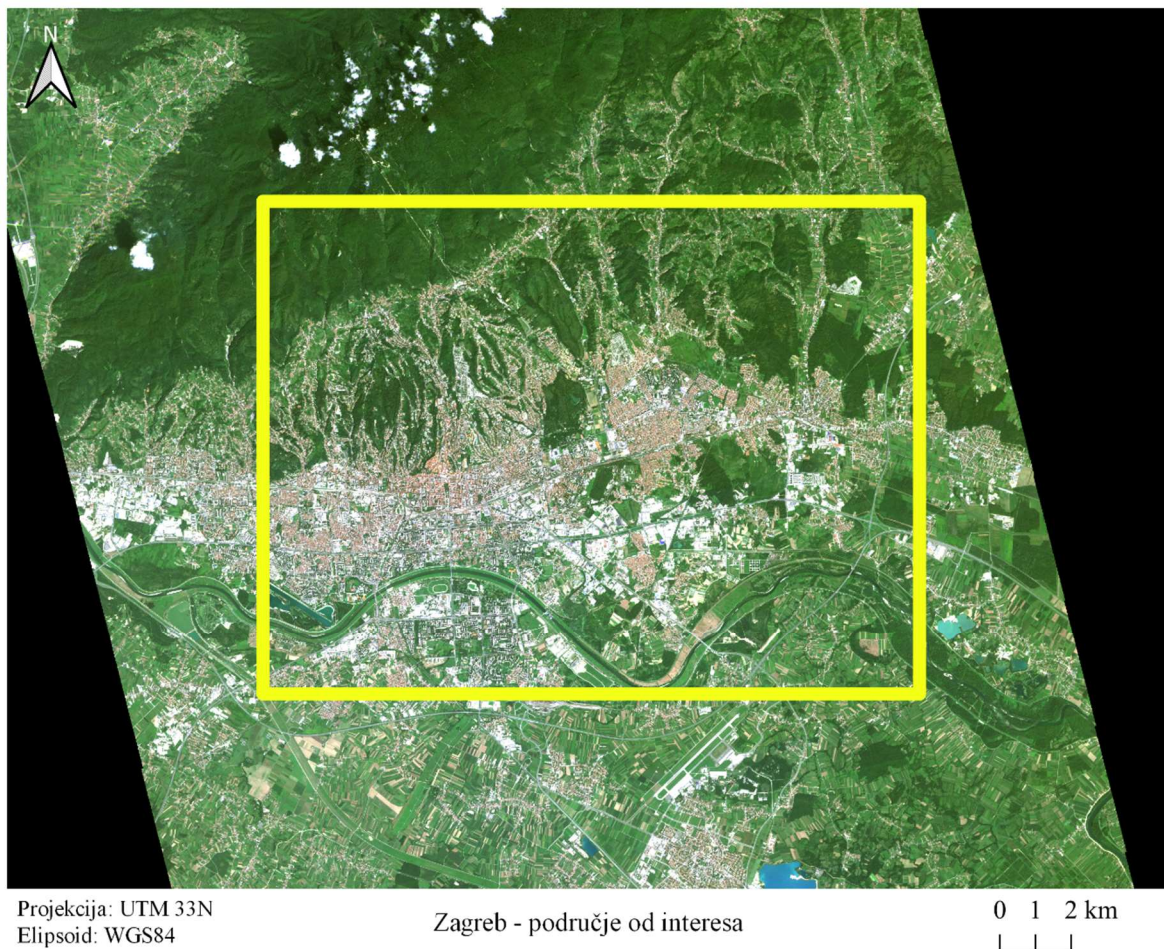
3.1.2 Spajanje satelitskih snimki i izrezivanje na područje od interesa

Sljedeći korak u pripremi podataka je spajanje satelitskih snimki iste godine zbog maksimiziranja područja preklopa između parova satelitskih snimki (slika 8.). Taj proces je odrađen ugrađenom funkcijom unutar QGIS programskog alata.



Slika 8. Preuzete PlanetScope snimke za područje Zagreba, 2020.

Usljed nepoklapanja putanji satelita u trenutku snimanja interesnog područja potrebno je izrezati oba spojena rastera na isti obuhvat kako bi bili usporedivi. To područje (slika 9.) u pogledu rezolucije mora biti djeljivo s 512 (po obje koordinatne osi) zbog uvjeta mreže te je tako izračunato da su maksimalne dimenzije 6144x4608 piksela. Područje na je sjeveru ograničeno oblacima, dok je s preostalih strana ograničeno zbog utjecaja rezolucije i preklopa spojenih snimki.




Slika 9. Spojene PlanetScope snimke s označenim područjem od interesa

3.1.3 Priprema uzoraka za učenje neuronske mreže

Zbog specifičnih dimenzija ulaznog rastera u UNet mreži spojen je par 4-kanalnih rasterskih snimki u jednu 8-kanalnu snimku što je postignuto putem Python programskog jezika korištenjem GDAL modula.



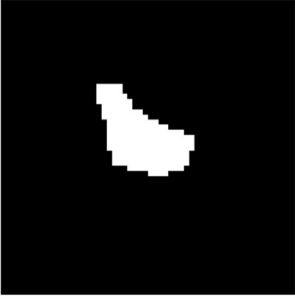
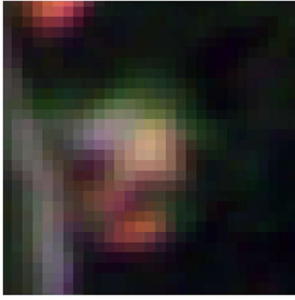
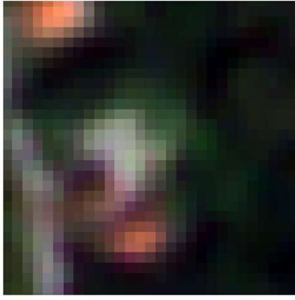
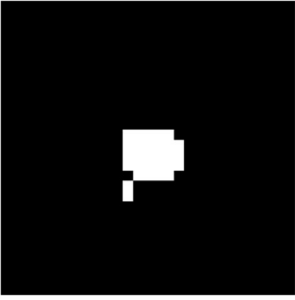


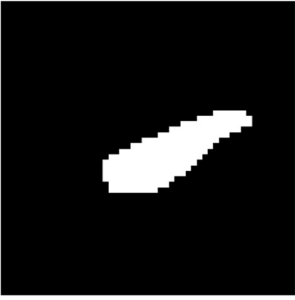


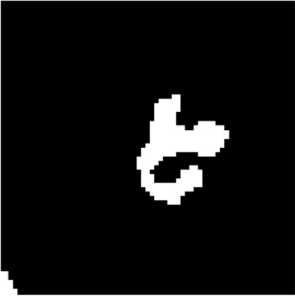

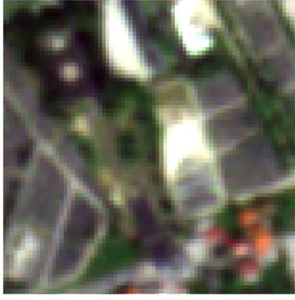

Drugi dio predobrade obuhvaćao je izrezivanje novostvorenog rastera na rasterske pločice dimenzija 512x512 piksela čime je osigurano postizanje dovoljnog sažimanja u neuronskoj mreži. Korišten je GDAL modul unutar Pythona, a dobiven je skup podataka od 108 raster pločica (slika 10.) (12 stupaca na 9 redaka).



Slika 10. Podjela na rasterske pločice područja od interesa


Nadalje, uz pripremljene ulazne rastere, na dijelu ukupnog skupa podataka ručno su definirane oznake, odnosno kreiran je jednokanalni binarni raster s označenim promjenama na rasterskim pločicama. Zbog ograničenih računalnih sredstva nasumično je odabrano 10 rasterskih pločica koji su reprezentativni po opsegu mogućih promjena koje se žele detektirati. Označavanje rasterskih pločica obavljeno je učitavanjem u QGIS te su promjene između snimki vektorizirane poligonima. Nakon označavanja svih promjena na pojedinoj rasterskoj pločici izvršena je pretvorba vektorskih oznaka u rasterske koristeći ugrađene funkcije *Rasterize* u QGIS-u. Raster oznaka iste je rezolucije i prostornog obuhvata kao i sama rasterska pločica. U tablici 4. prikazani su primjeri označavanja promjena.

Tablica 4. Primjeri označavanja promjena između para snimki

Scena 2019.	Scena 2020.	Označena promjena
		
		
		
		
		

3.1.4 Augmentacija podataka


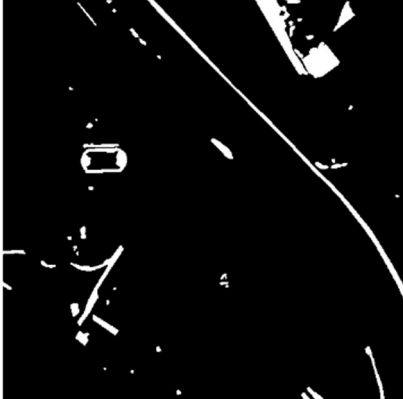






Nedostatak velikog broja uzoraka za učenje mreže, kao i pripadajućih oznaka je jedan od čestih problema konvolucijskih neuronskih mreža, kojeg stručnjaci nerijetko rješavaju oslanjajući se na augmentaciju podataka. Augmentacija podataka može se opisati kao proces kojim se na određenom skupu podataka provode geometrijske operacije (translacija, rotacija, zrcaljenje, smicanje, povećavanje i smanjivanje) kao i brojne druge tehnike (npr. izoštravanje snimke, izmjena kontrasta i sl.) s ciljem povećavanja izvornog skupa podataka (Mikołajczyk, Grochowski, 2018.). Takve metode obično su vrlo jednostavne za izvođenje i mogu značajno ojačati mrežu bez uvođenja novih uzoraka. Još jedan razlog upotrebe augmentacije podataka je izbjegavanje problema preprilagođenja. To je značajan problem ukoliko se uče mreže s malim skupom podataka što rezultira mrežom naučenom na maloj varijabilnosti, tj. mreža se potpuno prilagodi uzorcima za učenje, ali u trenutku kada se trebaju predvidjeti nove značajke rezultati su obično nezadovoljavajući, kao na grafikonu 5. (Shorten, Khoshgoftaar, 2019.).



Grafikon 5. Slučajevi učenja mreže; crno) uzorci; plavo) nedovoljno prilagođenje; zeleno) dobro prilagođenje; crveno) preprilagođenje

Augmentacija za svrhe ovog rada sastojala se od operacija rotiranja i zrcaljenja. S obzirom na to da se rasterske pločice koje se koriste za ulaz u neuronsku mrežu imaju kvadratnu dimenziju ne dolazi do gubitka podataka. Svaka rasterska pločica s pripadajućim rasterskim oznakama rotirana je u intervalima od 90° do punog kruga, čime su dobivene tri dodatne snimke/oznake, odnosno 4 puta više podataka. Uz rotaciju, svaka snimka je i zrcaljena u odnosu na apscisnu os te su dobivene još 4 snimke/oznake za pojedinu sirovu snimku. Navedeno konačno rezultira sa 7 rastera više i pripadajućih oznaka, odnosno 8 puta većim skupom podataka. Augmentacija je izvršena koristeći NumPy i GDAL module unutar Pythona.

Tablica 5. Augmentiranje rastera s označenim promjenama


Tip zrcaljenja	Izvorno	Rotacija za 90°
Izvorno		
Zrcaljenje s obzirom na apcisu		
Zrcaljenje s obzirom na ordinatu		
Zrcaljenje s obzirom na apcisu i ordinatu		

3.2 Definiranje UNet neuronske mreže

U podpoglavlju opisana je korištena UNet arhitektura neuronske mreže, funkcija gubitka i algoritam optimizacije.

3.2.1 UNet arhitektura

Korištena neuronska mreža ima UNet arhitekturu čiji se detalji mogu vidjeti na slici 11. Ulazni 8-kanalni raster u početku uveden je u dvije konvolucije s filterom 3x3 (rubni pikseli svakog pojedinog kanala se zadržavaju) svaki s 64 različita kanala značajki gdje se svaki kanal aktivira ReLU aktivacijskom funkcijom. Nakon toga prethodna konvolucija je sažeta (2x2) po principu najvećih brojeva (engl. max pooling) uz udvostručavanje kanala značajki. Navedeni proces je ponovljen dodatna tri puta do dosega 1024 sloja značajki (ukupno 4 razine sažimanja). Na zadnjem konvolucijskom sloju četvrte i pete razine provedeno je nasumično odbacivanje 50% i 25% slojeva, respektivno. Nakon toga uslijedio je postupak preuzorkovanja (2x2) u višu razinu s pola slojeva značajki prethodne konvolucije na koju je spojena izlazna konvolucija iz prethodne razine iste rezolucije čime se dobivaju 1024 sloja. Nakon spajanja uslijedila su dva konvolucijska sloja s 512 filtera te se postupak ponavljao ponovo do prve razine. Po završetku preuzorkovanja rezultat je proveden kroz četiri konvolucijska sloja sa 64, 64, 2 i 1 filterom, respektivno. Posljednji konvolucijski sloj aktiviran je sigmoidnom funkcijom (preduvjet za funkciju gubitka) koja predstavlja jednokanalnu rastersku rezolucije 512x512 piksela na kojoj su označene i segmentirane promjene između para snimki. Zadnji konvolucijski sloj ima filter 1x1.



Slika 11. UNet arhitektura

3.2.2 Definicija funkcije gubitka i algoritma optimizacije

Za funkciju gubitka korištena je težinska binarna križna entropija (engl. weighted binary crossentropy). Razlog primjene te funkcije leži u činjenici da su klase bez promjene i s promjenom u velikom kvantitativnom nerazmjeru koji, prema uzorcima za učenje za predmetno područje grada Zagreba, iznosi približno 1:21.

Binarna križna entropija je funkcija gubitka koja se koristi isključivo u binarnoj klasifikaciji te je prikladna za ovaj zadatak. Funkcija gubitka definirana je izrazom 6 (Ho, Wookey, 2020.):

$$J = -\frac{1}{M} \sum_{m=1}^M [w \times y_m \times \log(h_{\theta}(x_m)) + (1 - y_m) \times \log(1 - h_{\theta}(x_m))] \quad (6)$$

Gdje je:

- M – broj uzoraka za učenje
- w – težina
- y_m – ciljna oznaka za dani uzorak m
- x_m – ulaz za dani primjerak za učenje
- h_{θ} – model s težinama neuronske mreže

Korišteni optimizator za težine je Adam (engl. Adaptive Moment Estimation) zbog mogućih šumova u unazadnoj propagaciji s inicijalnom stopom učenja od 0.0001.

Nakon kreiranih uzoraka i oznaka za učenje te definiranja UNet neuronske mreže sve navedeno je povezano unutar Python skripte koristeći module NumPy, GDAL, TensorFlow i Keras.

Ukupan broj parametara u neuronskoj mreži dan je sljedećim izrazom (URL 7):

$$\text{Broj parametara} = (m * n * d + 1) * k \quad (7)$$


gdje je:

- m – širina konvolucijskog filtera
- n – visina konvolucijskog filtera
- d – broj filtera u prethodnom sloju
- k – broj filtera u trenutnom sloju

4. ANALIZA REZULTATA

Dostupni računalni resursi uvjetovali su učenje UNet mreže u Pythonu kroz 300 epoha, odvojeno za skup podataka uz i bez augmentacije. Izdvojeno je nasumično odabranih 20% podataka kako bi se mogla procijeniti kvaliteta naučene mreže po epohama. Ukupan broj težina UNet mreže (izraz 6.) iznosi 28 279 605.

Prilikom izdvajanja najpovoljnije epohe pozornost je usmjerena na rezultate validacije podataka. Rezultati funkcije gubitka i matrice konfuzije zapisani su programskom skriptom u Pythonu u *.csv obliku zajedno sa svim izračunatim težinama u *.h5 obliku. Funkcija gubitka po epohama prikazana je grafikonom 6.

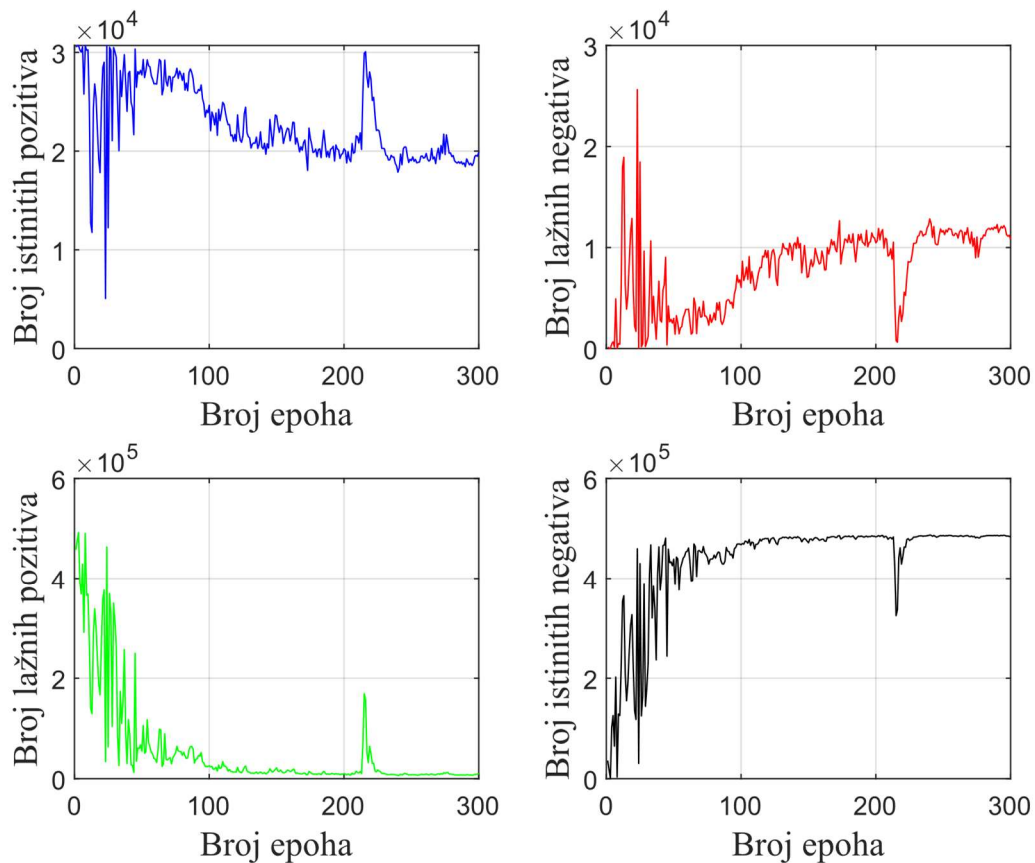


Grafikon 6. Funkcija gubitka modela na skupu za validaciju po epohama


Iz grafikona 6. se zaključuje kako je mreža naučena na augmentiranom skupu podataka daje znatno bolje rezultate u odnosu na skup bez augmentacije. Primjetno je kako augmentiranom skupu funkcija počinje konvergirati uz razmjerno male oscilacije. Funkcija nad skupom bez augmentacije ima relativno značajniji šum te unutar 300 epoha ne pokazuje tendenciju

konvergencije. Uz navedeno, funkcija gubitka na augmentiranom skupu pokazuje znatno manje vrijednosti.

Matrice konfuzije su neophodne kako bi se dobile informacije o uspješnosti učenja mreže. Oba skupa podataka (grafikoni 7 i 8) pokazuju sličan trend, tj. broj istinitih i lažnih pozitiva u prosjeku opada s epohama dok broj istinitih i lažnih negativu u kontrastu raste. Navedeno je posljedica procesa učenja, odnosno u početnim epohama mreža pretpostavlja jako velik broj piksela s promjenom u odnosu na broj piksela bez promjene, a ukoliko je pretpostavljeno puno (istinitih i lažnih) promjena mala je vjerojatnost detekcije piksela bez promjene. Također, primjećuje se kako svi elementi matrice konfuzije počinju konvergirati, no primjetna je razlika u brzini konvergencije – augmentirani skup podataka znatno stabilnije i brže konvergira (skup bez augmentacije je konvergirao oko 150-e epohe dok je skup s augmentacijom konvergirao oko 100-te epohe).



Grafikon 7. Matrica konfuzije po epohama za skup podataka bez augmentacije



Grafikon 8. Matrica konfuzije po epohama za skup podataka uz augmentaciju

Iako matrica konfuzije pokazuje informacije za odabrani skup, ti podaci nisu direktno usporedivi. To je posljedica toga da augmentirani skup podataka sadrži 8 puta više podataka, uz napomenu da su podaci za validaciju odabrani slučajnim izborom. Kako bi bilo moguće pratiti točnost modela definira se ukupna točnost modela u danoj epohi kao omjer točnih otkrivenih podataka od svih podataka:

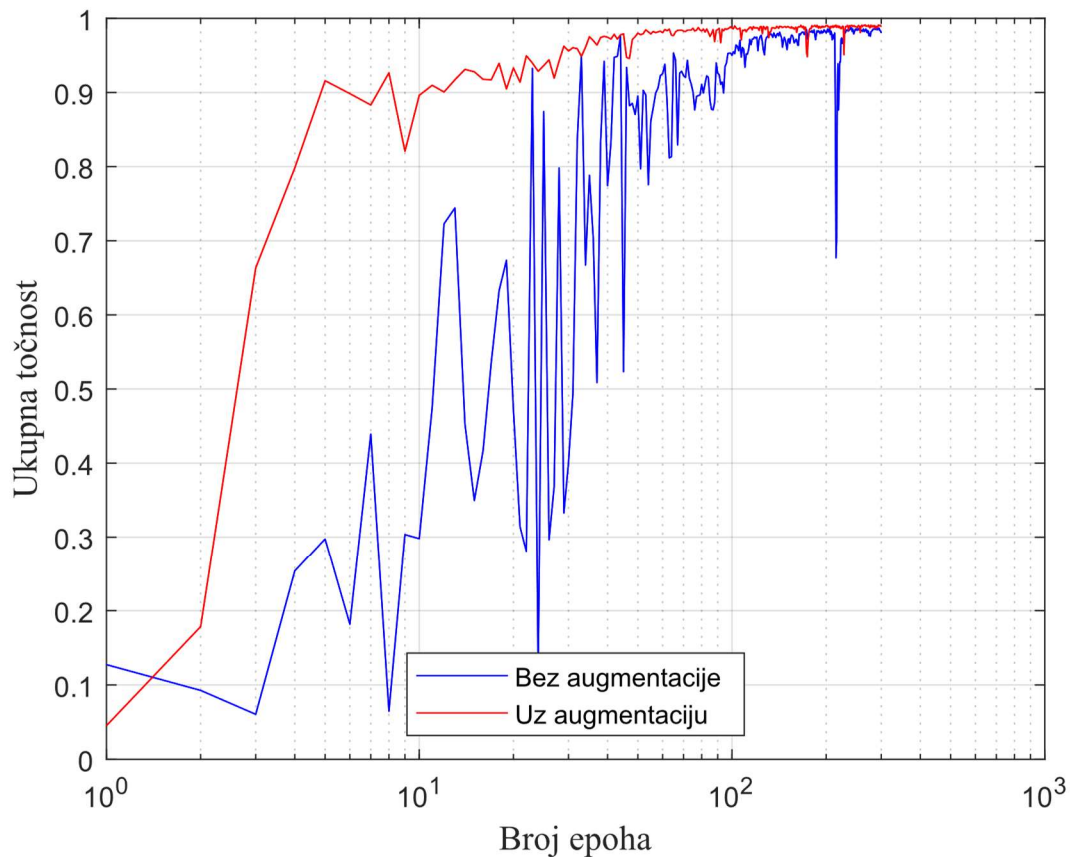
$$Ukupna\ točnost = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

Gdje je:

- TP – istinit pozitiv
- TN – istiniti negativ
- FP – lažni pozitiv
- FN – lažni negativ

Grafikon 9. prikazuje ukupnu točnost modela po epohama prikazanima na logaritamskoj skali (baza 10). Ukupna točnost po svojoj prirodi ima tendenciju najvećeg poboljšanja u ranijim

trenucima učenja. Oba skupa podataka daju očekivane rezultate. Mreža naučena na augmentiranom skupu podataka daje znatno bržu konvergenciju. Mreža naučena na neaugmentiranom skupu podataka slabije konvergira, u odnosu na augmentiranu mrežu jer je znatno opterećenija šumom. Model bez augmentacije konvergira ukupnoj točnosti od 98.3%, dok model uz augmentaciju konvergira prema 98.9%.



Grafikon 9. Ukupna točnost modela na skupu za validaciju po epohama

Prilikom tumačenja rezultata neophodno je znati kako su klase u velikom nerazmjeru (na skupu za validaciju pronađeno je približno 21 puta manje piksela s promjenama) tako da promatranje ukupne točnosti kao mjere kvalitete detekcije promjena nije zadovoljavajuće (Sun, Wong i Kamel, 2011.). Stoga je, uz gubitak, matricu konfuzije i ukupnu točnost, za tumačenje rezultata korištena i preciznost (engl. Precision), opoziv (engl. Recall) i F1-ocjena.

Preciznost je mjera koja opisuje omjer točno pozitivnih podataka i podataka koji su označeni kao pozitivni te se može dati izrazom:

$$Preciznost = \frac{TP}{TP + FP} \quad (9)$$


Opoziv je mjera kojom se promatra udio točno pozitivnih podataka i ukupnog broja pozitivnih podataka:

$$Opoziv = \frac{TP}{TP + FN} \quad (10)$$

Preciznost i opoziv su uvijek u obrnutoj ovisnosti jedan o drugome, odnosno, ako je dobra preciznost opoziv će biti lošiji. Vrijedi i obratno, dobar opoziv loše utječe na preciznost. Preciznost i opoziv promatraju se istovremeno jer samostalno ne daju potpunu informaciju o kvaliteti modela. Zbog važnosti opoziva i preciznosti oni se kombiniraju u jednu metriku. Za slučaj kada su opoziv i preciznost od jednake važnosti tada se koristi F1-ocjena koji promatra njihovu harmonijsku sredinu (izraz 5.):

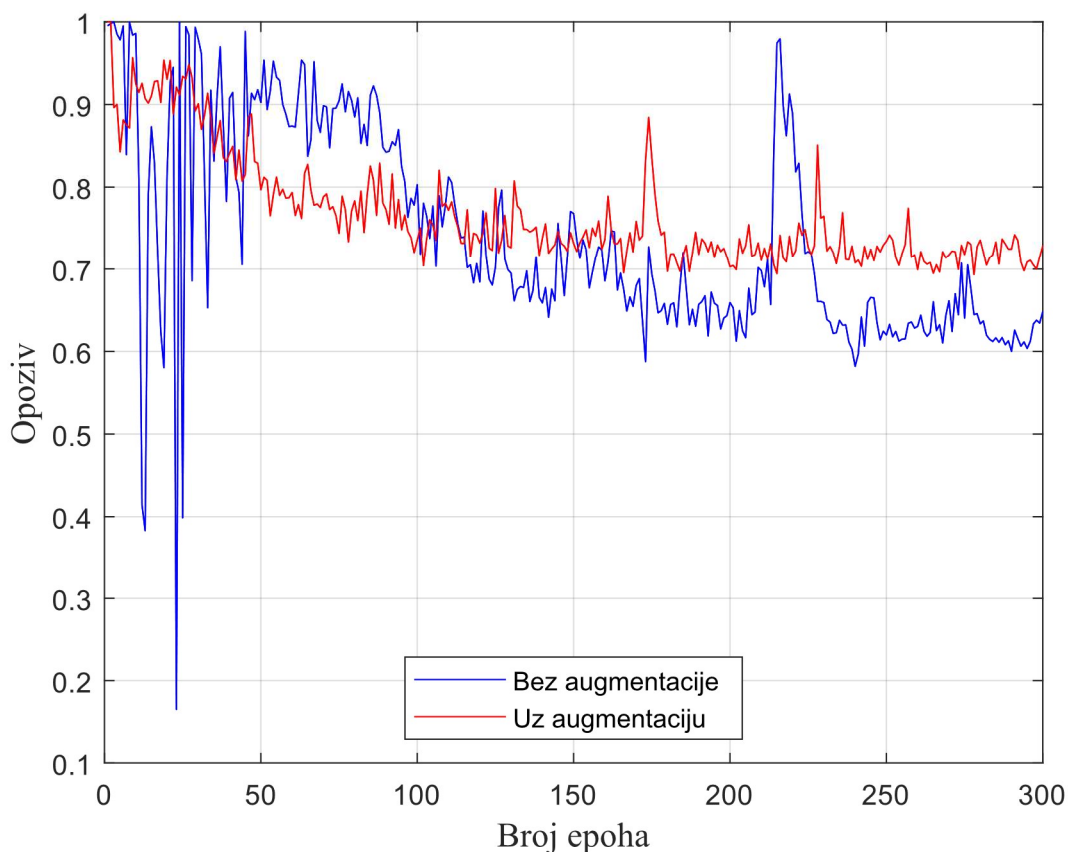
$$F1 - ocjena = \frac{2 * Preciznost * Opoziv}{Preciznost + Opoziv} \quad (11)$$

Grafikon 10 prikazuje preciznost modela po epohama. Preciznost mreže za oba skupa podataka raste s epohama te počinju konvergirati. Vidljiva je razlika u brzini konvergencije kao i vrijednosti u koju konvergiraju. Skup bez augmentacije i dalje sadrži značajan šum preciznosti, te za posljednjih 50 epoha postiže srednju vrijednost od 69.8% sa standardnim odstupanjem 2.33%. Augmentirani skup u posljednjih 50 epoha postiže srednju vrijednost 75.4% sa standardnim odstupanjem 2.27%.




Grafikon 10. Preciznost modela na skupu za validaciju po epohama

Na grafikonu 11. prikazan je opoziv modela po epohama. Primjetno je da opoziv mreže opada s epohama te počinje konvergirati s oba skupa podataka. Opadanje opoziva je posljedica prethodno objašnjene opadanja broja istinitih pozitivnih vrijednosti i rasta lažnih negativnih vrijednosti. S obzirom na blisku povezanost s preciznošću, opoziv također pokazuje razlike u razini i brzini konvergencije. Na skupu bez augmentacije u zadnjih 50 epoha postiže se srednja vrijednost od 63.1% sa standardnim odstupanjem 2.27%. Na augmentiranom skupu podataka u posljednjih 50 epoha dolazi do srednje vrijednosti od 71.8% sa standardnim odstupanjem od 1.53%.



Grafikon 11. Opoziv modela na skupu za validaciju po epohama


Grafikon 12. prikazuje F1-ocjenu mreže po epohama koja kombinira harmonijsku sredinu opoziva i preciznosti. Rezultat je sukladan prethodnom, nastavlja se trend rasta F1-ocjene po epohama učenja te ubrzo dolazi do konvergencije. Zbog direktne povezanosti F1-ocjene s preciznosti i opozivom, F1-ocjena daje stabilniji prikaz. Augmentirani skup podataka i dalje se pokazuje kao kvalitetniji sa srednjom vrijednosti od 73.6% i standardnim odstupanjem 0.53% u posljednjih 50 epoha. Model bez augmentiranih podataka u posljednjih 50 epoha poprima 66.2% srednje vrijednosti sa standardnim odstupanjem 0.54%.



Grafikon 12. F1-ocjena modela na skupu za validaciju po epohama s označenom najboljom vrijednosti

S grafikona 12. odabrane su najviše vrijednosti kako bi mogli odabrati model težina koje će rezultirati najkvalitetnijim rezultatima. Za mrežu naučenu na sirovim podacima odabran je 223. model težina s F1-ocjenom od 68.0%, a za mrežu naučenu na augmentiranim podacima 165. model težina s F1-ocjenom od 74.2%.

Po odabiru optimalnog modela za oba slučaj napravljene su procjene za svaku rastersku pločicu (ukupno 108) te su rezultati mozaicirani kako bi se dobio jedan raster promjena cjelokupnog područja, kao što je prikazano na slikama 12. i 13.




Projekcija: UTM 33N
Elipsoid: WGS84

Zagreb - spojeni izlazni rezultat bez augmentacije

0 1 2 km
└───┬───┘


Slika 12. Izlazni rezultati bez augmentacije



Slika 13. Izlazni rezultati uz augmentaciju

Vizualno je moguće zaključiti kako rezultati bez augmentacije u prosjeku daju veći broj detektiranih piksela, osobito u rubnim područjima obično prividno opadajuće vjerojatnosti. Kontrastno tome, rezultati dobiveni uz augmentaciju daju oštrije rezultate s većom vjerojatnosti, rubovi objekta su izraženiji.

Budući da izlazni rasteri sadrže vrijednosti u rasponu od 0 do 1, sljedeći korak podrazumjeva određivanje praga kojim se definira dolazi li na pojedinom pikselu do promjene. Izračunate su F1-ocjene za pragove u intervalima od 0.005 te se ponovno traži maksimum. Takvim pristupom određeni su pragovi za augmentirani skup podataka 0.48 te za skup bez augmentacije 0.835. Nakon određenih pragova sve vrijednosti piksela koje su ispod zadanog praga su klasificirane kao klasa 0, odnosno bez promjene, a sve iznad je klasificirano u klasu 1, tj. promjena čime se dobiva binarna slika. Na slikama 14. i 15. prikazani su krajnji rezultati.




Projekcija: UTM 33N
Elipsoid: WGS84

Zagreb - Detektirane promjene bez augmentacije

0 1 2 km







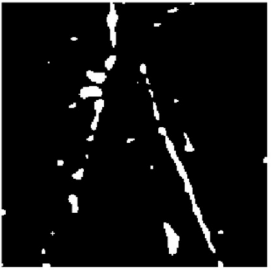













Slika 14. Spojeni izlazni rezultati bez augmentiranja



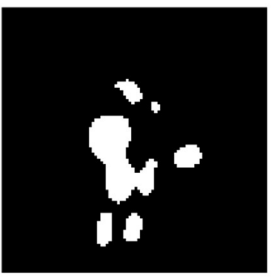





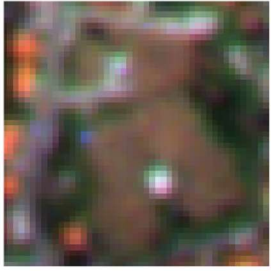
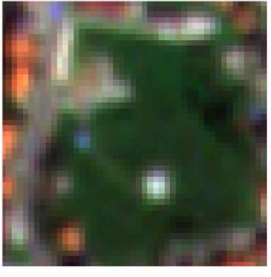



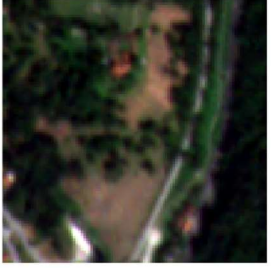








Slika 15. Spojeni rezultati uz augmentaciju

Iako dobivene F1-ocjene za model bez i uz augmentaciju iznose 68.0% i 74.2%, respektivno, potrebno je dobiti uvid u prirodu grešaka. U tablici 6. prikazane su usporedbe scene istog područja u dva različita datuma te dobiveni rezultati.


Tablica 6. Usporedba rezultata

Scena 2019.	Scena 2020.	Promjene bez augmentacije	Promjene uz augmentaciju
			
			
			
			
			


Scena 2019.	Scena 2020.	Promjene bez augmentacije	Promjene uz augmentaciju
			
			
			
			
			

5. RASPRAVA


Spojeni izlazni rezultati, iako nesavršeni, objektivno daju zadovoljavajuće rezultate detekcije promjena. Zaključuje se da je prva hipoteza ovog rada postignuta. Iz grafikona prezentiranih u prethodnom poglavlju dokazano je da je augmentacija podataka rezultirala znatno boljim rješenjem – između najboljih epoha uočava se razlika 6.2% te se zaključuje da je druga hipoteza ovog rada također postignuta. Postignuća ovog rada ukazuju na veliku isplativost povećanja skupa podataka za učenje. Zbog nesavršenosti sustava moguće je i dalje pronaći detektirane promjene niže kvalitete za mrežu naučenu na skupu za augmentaciju, ali i obratno, kao što je prikazano na primjeru nogometnog igrališta i novogradnje, respektivno (slike 16. i 17.). Uz navedeno potrebno je voditi računa o mogućim pogreškama senzora (slika 18.) koje mogu također rezultirati lažnim promjenama.



Slika 16. Primjer loše detekcije promjena mreže uz augmentaciju; a) Stvarno stanje; b) Rezultat bez augmentacije; c) Rezultat uz augmentaciju



Slika 17. Primjer loše detekcije promjena mreže bez augmentaciju; a) Stvarno stanje; b) Rezultat bez augmentacije; c) Rezultat uz augmentaciju



Slika 18. Vidljiva pogreška senzora

Jedan od nedostataka augmentacije podataka je dulje vrijeme učenja mreže – u ovom radu na računalu s mobilnim 6-jezgrenim procesorom i grafičkom karticom s 4 GB VRAM-a na sirovom skupu podataka kroz 300 epoha mreža se učila približno 40 minuta, a na skupu uz augmentaciju približno 5 sati i 15 minuta. Iz grafikona danih u prethodnom poglavlju zaključuje se kako je moguće smanjiti broj epoha učenja, osobito za augmentirani skup podataka za barem 20%. Drugo ograničenje rada je djeljivost rezolucije ulaznog skupa

podataka s 8 kako bi se postiglo potpuno sažimanje u mreži. Dodatno je vremenski zahtjevno izraditi adekvatan broj uzoraka za učenje mreže, čak i uz augmentaciju.

Najbolji postignuti rezultati mreže naučene na sirovom skupu podataka i na skupu uz augmentaciju daju rezultate od 68.0% i 74.2% F1-ocjene za klasu promjene. Dalje je potrebno usporediti rezultate s brojnim drugim istraživanjima. Benedek i dr. (2015) u svom radu pokazuju da su najviši rezultat postigli na neurbaniziranom području koristeći CXM višeslojni model gdje postižu F1-ocjenu od 74.3%, dok za bilo koji drugi skup podataka, neovisno o načinu označavanja promjena i korištenom modelu, postižu F1-ocjenu ispod 66% čime se zaključuje kako su rezultati u ovom radu marginalno bolji. Chen i dr. (2020) u svom istraživačkom radu pokazuju višu kvalitetu F1-ocjene u iznosu od 74.3% te se također uspoređuju s U-Net modelom gdje su postigli 68.9%. Vidljivo je kako rezultati ovog rada pokazuju poboljšanje u odnosu na njihovo istraživanje. Daudt i dr. (2018) u svom radu prate opoziv klase promjene te postižu vrijednosti 78.5-85.6% što je u prosjeku znatno bolji rezultat, no nedostaju rezultati preciznosti koja bi dala bolji uvid u kvalitetu istraživanja. Zhan i dr. (2017) primjenom dubokih sijamskih konvolucijskih neuronskih mreža postižu točnost od 86.7% F1-ocjene. Peng, Zhang i Guan (2019) postižu još višu kvalitetu detekcije promjena primjenom UNet++ neuronske mreže. Rezultati dobivenim ovim radom su i dalje usporedivi s prethodno navedenim istraživanjima zbog razmjerno malog skupa za učenje mreže, uz očekivanje značajnih poboljšanja s rastom uzoraka za učenje kao i odabira reprezentativnih uzoraka za interesno područje. Primjetno je da spomenuta istraživanja također kvalitetno otkrivaju promijenjene objekte, no kao i u ovom istraživanju, greške se ponajviše pojavljuju na rubovima detektiranih objekta (u smislu oduzimanja i dodavanja piksela).

Konačno, rezultati bez augmentacije dobivaju područje pod promjenom 6.84% od ukupne površine interesnog područja, dok je rezultatima uz augmentaciju dobiveno 7.60% područja pod promjenom. Zbog velikog raspona u dimenzijama objekta razmjerno je teško dobiti adekvatnu kartu promjena s F1-ocjenom iznad 90%.

6. ZAKLJUČAK

Sve je veća potražnja za detekcijom prostornih promjena, osobito u modernom i užurbanom svijetu. Potencijalno kvalitetno rješenje te problematike je moguće dobiti putem metoda daljinskih istraživanja, što je demonstrirano ovim radom. Metode daljinskih istraživanja ovisne su o visokoj frekvenciji broja snimki koji se mogu prikupiti u danom vremenskom roku zbog čega je razvijena tehnologija nanosatelita koji su malih dimenzija bez velikih kompenzacija. Paralelno s razvojem daljinskih istraživanja metode strojnog učenja našle su primjene u širokom spektru ljudskih djelatnosti te je upotreba već postojećih programskih rješenja u programskom pogledu korisnički pristupačna te se utrošeno vrijeme pripreme može drastično umanjiti, osobito programskih modula koji se mogu naći za Python.

U ovom radu predložena je složena UNet arhitektura konvolucijskih neuronskih mreža za svrhe otkrivanja promjena između para satelitskih snimki. Korištene satelitske snimke su PlanetScope snimke s 4 kanala visoke prostorne razlučivosti s prethodno izvršenim korekcijama. Preduvjet za izvršavanje zadatka detekcije promjena podrazumijeva da su snimke radiometrijski i geometrijski korigirane. Preuzete satelitske snimke spojene su u jedan par snimki koji se naknadno prilagođava području od interesa. Temeljem istih podataka vizualnom interpretacijom stvoreni su uzorci za učenje s pripadajućim oznakama. Sa svrhom povećanja broja uzoraka, ali i kvalitete naučene mreže, pristupa se augmentaciji sirovih podataka.

Iz dobivenih rezultata može se zaključiti kako je moguće naučiti neuronsku mrežu za otkrivanje promjena između parova satelitskih snimki u razmjerno kratkom vremenskom roku. Također pokazuje se da je augmentacija podataka rezultirala znatno kvalitetnijom i robusnijom mrežom u odnosu na mrežu koja se učila isključivo na sirovim podacima. Augmentacijom podataka postignuto je poboljšanje F1-ocjene od približno 8% nakon 300 epoha s maksimumom od 74% za razmjerno mali set uzoraka za učenje. Uzevši u obzir računalna ograničenja i manji skup podataka, augmentacijski pristup daje dobru alternativu ručnom pripremanju velikog broja uzoraka za učenje čime se vrijeme pripreme podataka drastično smanjuje. Očekivana su znatna poboljšanja s porastom sirovih uzoraka za učenje kao i uvođenjem kompleksnijih metoda augmentacije.

Moguća su daljnja istraživanja u pogledu analiziranja promjena u varijabilnim vremenskim intervalima za praćenje urbanizacije i ljudskog utjecaja na okoliš kao i u otkrivanju promjena temeljem snimki dobivenih s različitim sensorima na širem državnom području.

Zahvale

Zahvaljujem se mentoru doc. dr. sc. Mariju Mileru na beskrajnom pomoći, strpljenju i danoj prilici. Zahvaljujem se Ivanu Brkiću, mag. ing. geod. et geoinf., Dini Dobriniću, mag. ing. geod. et geoinf. i dr. sc. Luki Rumori na trudu i brojnim savjetima. Zahvaljujem se Mladenu Miletiću, mag. ing. traff. na pomoći pri pripremanju grafičkih elemenata. Hvala obitelji i prijateljima tijekom izrade rada.

Popis literature

Asokan, A., Anitha, J. (2019): Change detection techniques for remote sensing applications: a survey, *Earth Sci Inform* 12, 143-160.

Benedek, C., Shadaydeh, M., Kato, Z., Szirányi, T., Zerubia, J. (2015): Multilayer Markov Random Field models for change detection in optical remote sensing images, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 107, 22-37., ISSN 0924-2716

Chen, L., Zhang, D., Li, P., Lv, P. (2020): Change Detection of Remote Sensing Images Based on Attention Mechanism, *Computational Intelligence and Neuroscience*, Volume 2020, Article ID 6430627

Daudt, R. C., Le Saux, B., Boulch, A., Gousseau, Y. (2018): Urban Change Detection for Multispectral Earth Observation Using Convolutional Neural Networks, *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2115-2118.

Falco, N., Mura, M. D., Bovolo, F., Benediktsson, J. A., Bruzzone, L. (2013): Change Detection in VHR Images Based on Morphological Attribute Profiles, *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 3, 636-640.

Feng, J., Lu, S. (2019): Performance Analysis of Various Activation Functions in Artificial Neural Networks, *Journal of Physics: Conference Series* 1237.

Ho, Y., Wookey, S. (2020): The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling, *IEEE Access*, vol. 8, 4806-4813.

Hordri, N., Yuhaniz, S., Shamsuddin, S. M. (2016): Deep Learning and Its Applications: A review

Krose, B., Smagt, P. v. d. (1996): An introduction to Neural Networks, Eighth edition, Amsterdam

Lisani, J. L., Morel, J. (2003): Detection of major changes in satellite images, *Proceedings 2003 International Conference on Image Processing*, I-941.

Liu, G., Delon, J., Gousseau, Y., Tupin, F. (2016): Unsupervised change detection between multi-sensor high resolution satellite images, *2016 24th European Signal Processing Conference (EUSIPCO)*, 2435-2439.

- Makin, J.G. (2006): Backpropagation
- Medsker, L. R., Jain, L. C. (2001): RECURRENT NEURAL NETWORKS Design and Applications, CRC Press
- Mikołajczyk, A., Grochowski, M. (2018): Data augmentation for improving deep learning in image classification problem. 117-122.
- Peng, D., Zhang, Y., Guan, H. (2019): End-to-End Change Detection for High Resolution Satellite Images Using Improved UNet++, Remote Sensing 2019, 11, 1382.
- Shamsaldin, A., Fattah, P., Rashid, T., Al-Salihi, N. (2019): The Study of The Convolutional Neural Networks Applications, UKH Journal of Science and Engineering 3, 31-40.
- Shorten, C., Khoshgoftaar, T. (2019): A survey on Image Data Augmentation for Deep Learning, Journal of Big Data 6,
- Sun, Y., Wong, A. K. C., Kamel, M. S. (2011): Classification of imbalanced data: A review, International Journal of Pattern Recognition and Artificial Intelligence, 23., 687-719.
- Szandała, T. (2020): Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks
- Tian, J., Qin, R., Cerra, D., Reinartz, P. (2016): BUILDING CHANGE DETECTION IN VERY HIGH RESOLUTION SATELLITE STEREO IMAGE TIME SERIES, ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, III-7. 149-155.
- Wen, X., Yang, X. (2009): A new change detection method for two remote sensing images based on spectral matching, 2009 International Conference on Industrial Mechatronics and Automation, 89-92.
- Zhan, Y., Fu, K., Menglong, Y., Sun, X., Wang, H., Qiu, X. (2017): Change Detection Based on Deep Siamese Convolutional Network for Optical Aerial Images, IEEE Geoscience and Remote Sensing Letters, vol. 14, no. 10, 1845-1849.

URL 1: International Society for Photogrammetry and Remote Sensing, <https://www.isprs.org/> (19.6.2021.)

URL 2: Alexander Lenail, <http://alexlenail.me/>, (24.6.2021.)

URL 3: IntechOpen, <https://www.intechopen.com/books/digital-systems/neural-network-principles-and-applications>, (24.6.2021.)

URL 4: Planet, <https://www.planet.com/products/planet-imagery/> (23.6.2021.)

URL 5: European Space Agency, <https://earth.esa.int/eogateway/missions/planetscope>, (23.6.2021.)

URL 6: NumPy, <https://numpy.org/>, (24.6.2021.)

URL 7: Geospatial Data Algorithms Library (GDAL), <https://gdal.org/>, (24.6.2021.)

URL 8: TensorFlow, <https://www.tensorflow.org/>, (24.6.2021.)

URL 9: Keras, <https://keras.io/>, (24.6.2021.)

URL 10: Towards Data Science, <https://towardsdatascience.com/>, (24.6.2021.)

Sažetak

Autor: Dominik Miletić

Naziv rada: Detekcija promjena u prostoru na snimkama nanosatelita upotrebom neuronskih mreža

Jedan od istaknutih zadataka daljinskih istraživanja je detekcija promjena na nekom području unutar zadanog vremenskog perioda. Nerijetko zbog složenosti sustava nije vremenski isplativo ručno određivati promjene, a zbog nelinearnosti problema brojni stručnjaci traže nova robusna rješenja. Ovaj rad predlaže korištenje UNet model konvolucijske neuronske mreže za svrhe detektiranja promjena između parova koregistriranih satelitskih snimki. Ovaj pristup primijenjen je na satelitskim snimcima visoke prostorne rezolucije s 4 kanala prikupljenih PlanetScope misijom za područje grada Zagreba u razmaku od jedne godine. Uzorci za učenje mreže ručno su označeni vektorizacijom u QGIS programskom alatu. Nakon označavanja promjena obje snimke predmetnog područja podijeljene su u raster pločice 512x512 piksela te su naknadno spojene u jedan raster s 8 kanala koji će predstavljati ulaz u UNet mrežu. Prikupljeni skup podataka također je augmentiran tako da se pojedini ulazni raster transformirao u kombinacijama rotiranja i zrcaljenja zajedno s pripadajućim oznakama. UNet mreža učila se na augmentiranom i neaugmentiranom skupu podataka u Python programskom jeziku uz odvojeni dio ulaznih podataka za validaciju rezultata. Nakon što je mreža naučena, napravljene su procjene detekcije promjena na svim rasterima. Analizom rezultata koji su dobiveni temeljem oba skupa podataka može se zaključiti da augmentacija podataka može poboljšati kvalitetu za manji skup podataka.

Ključne riječi: detekcija promjena, PlanetScope, konvolucijske neuronske mreže, UNet, augmentacija

Summary

Author: Dominik Miletic

Title: Spatial change detection on nanosatellite imagery using neural networks

One of the most prominent tasks of remote sensing is change detection on a given area for a given time interval. Often due to the complexity of the change detection system manual interpretation is highly inefficient. Considering that change detection is a nonlinear problem many experts are looking for a new robust solution. This paper suggests use of UNet convolutional neural network for purposes of change detection between pairs of coregistered satellite images. This approach was applied to high spatial resolution images with 4 bands acquired by PlanetScope mission for city of Zagreb area in a time interval of one year. Training samples have been manually labelled (vectorised) within the QGIS software. After labelling changes both sets of images have been divided into 512x512 pixel raster tiles and they have been concatenated to create an image with 8 bands which will be used as an input to UNet network. Gathered dataset has also been augmented by combining mirroring and rotating each raster input as well as its respective label. UNet network has been trained on both augmented and non-augmented datasets in Python programming language while keeping a certain percentage of input data for validation. After the network has been trained change detection predictions are made for every image. By analysing the results given by both datasets it can be concluded that augmentation can improve F1-score for a small dataset.

Keywords: change detection, PlanetScope, convolutional neural networks, UNet, augmentation

Popis slika

Slika 1. Struktura neurona.....	5
Slika 2. Skica duboke neuronske mreže s dva skrivena sloja.....	6
Slika 3. Sloj povratne neuronske mreže.....	7
Slika 4. Primjer strukture konvolucijske neuronske mreže (URL 2).....	8
Slika 5. Pogreška kao funkcija težina (Makin, 2006.).....	12
Slika 6. Tijek izrade karte promjena.....	14
Slika 7. PlanetScope DOVE nanosatelit (Izvor: URL 2).....	15
Slika 8. Preuzete PlanetScope snimke za područje Zagreba, 2020.....	17
Slika 9. Spojene PlanetScope snimke s označenim područjem od interesa.....	18
Slika 10. Podjela na rasterske pločice područja od interesa.....	19
Slika 11. UNet arhitektura.....	23
Slika 12. Izlazni rezultati bez augmentacije.....	33
Slika 13. Izlazni rezultati uz augmentaciju.....	34
Slika 14. Spojeni izlazni rezultati bez augmentiranja.....	35
Slika 15. Spojeni rezultati uz augmentaciju.....	36
Slika 16. Primjer loše detekcije promjena mreže uz augmentaciju; a) Stvarno stanje; b) Rezultat bez augmentacije; c) Rezultat uz augmentaciju.....	39
Slika 17. Primjer loše detekcije promjena mreže bez augmentaciju; a) Stvarno stanje; b) Rezultat bez augmentacije; c) Rezultat uz augmentaciju.....	40
Slika 18. Vidljiva pogreška senzora.....	40

Popis tablica

Tablica 1. Parametri PlanetScope misije (Izvor: URL 2)	15
Tablica 2. Specifikacije DOVE satelita (Izvor: URL 2).....	15
Tablica 3. Parametri kanala PlanetScope kamere (Izvor: URL 5).....	16
Tablica 4. Primjeri označavanja promjena između para snimki	20
Tablica 5. Augmentiranje rastera s označenim promjenama	22
Tablica 6. Usporedba rezultata	37

Popis grafikona

Grafikon 1. Sigmoid aktivacijska funkcija	9
Grafikon 2. Hiperbolička tangens aktivacijska funkcija.....	10
Grafikon 3. ReLU aktivacijska funkcija	11
Grafikon 4. Leaky ReLU aktivacijska funkcija	11
Grafikon 5. Slučajevi učenja mreže; crno) uzorci; plavo) nedovoljno prilagođenje; zeleno) dobro prilagođenje; crveno) preprilagođenje.....	21
Grafikon 6. Funkcija gubitka modela na skupu za validaciju po epohama	25
Grafikon 7. Matrica konfuzije po epohama za skup podataka bez augmentacije.....	26
Grafikon 8. Matrica konfuzije po epohama za skup podataka uz augmentaciju	27
Grafikon 9. Ukupna točnost modela na skupu za validaciju po epohama	28
Grafikon 10. Preciznost modela na skupu za validaciju po epohama.....	30
Grafikon 11. Opoziv modela na skupu za validaciju po epohama	31
Grafikon 12. F1-ocjena modela na skupu za validaciju po epohama s označenom najboljom vrijednosti	32