



## DETEKCIJA POLJA SOLARNIH ELEKTRANA SA SATELITSKIH SNIMAKA DETECTION OF SOLAR POWER PLANT FIELDS FROM SATELLITE IMAGES

Filip Jakovljević, Fakultet tehničkih nauka, Novi Sad

### Oblast – ELEKTROTEHNIKA I RAČUNARSTVO

**Kratak sadržaj** – Ovaj istraživački rad predstavlja automatizovan sistem napravljen korišćenjem dubokog učenja, tačnije konvolucione neuronske mreže (CNN) sa U-Net arhitekturom, za detekciju i precizno lociranje solarnih elektrana na satelitskim snimcima. Sistem postiže impresivno preklapanje od 89% prema metrići preseka i unije (IoU), olakšavajući praćenje obnovljivih izvora energije i doprinoseći održivosti.

**Ključne reči:** Semantic segmentation, U-mreža, kompjuterska vizija, solarni paneli, neuronske mreže

**Abstract** – This research paper presents an automated system using deep learning, particularly a CNN with a U-Net architecture, to detect and precisely locate solar power plants in satellite images. Achieving an 89% IoU overlap, the system streamlines renewable energy monitoring, promoting sustainability.

**Keywords:** Semantic segmentation, U-net, computer vision, solar panels, neural networks

### 1. UVOD

Satelitski snimci predstavljaju važan izvor informacija o zemljištu, klimatskim uslovima i promenama koje se dešavaju na površini naše planete. Međutim, velika količina podataka koja se snima satelitima izaziva potrebu za razvojem sistema koji su sposobni za njihovu automatsku analizu. Ovaj rad se bavi segmentacijom objekata sa satelitskih snimaka. Detekcija i segmentacija objekata ima veliki potencijal da obezbedi korisne informacije u različitim oblastima, kao što su urbani razvoj, agrikultura, flora i fauna, pa čak i u vojne svrhe. Motivacija za rešavanje ovog problema leži u mogućnosti da se automatizuje proces analize satelitskih snimaka i da se omogući brže i efikasnije praćenje i identifikacija objekata od interesa.

U skladu sa tim, fokus ovog istraživanja bila je detekcija solarnih elektrana na satelitskim snimcima. Solarni elektrane predstavljaju ključni izvor obnovljive energije i igraju vitalnu ulogu u suprotstavljanju klimatskim promenama i ograničavanju uticaja na okruženje. Ipak, identifikacija i praćenje lokacija na kojima su izgrađene solarne elektrane može biti izazovna s obzirom na veliki broj mogućih lokacija i kompleksnost terena. Razvoj automatizovanog sistema za detekciju solarnih elektrana na satelitskim slikama ima potencijal da značajno olakša i

ubrza proces identifikacije i monitoringa ovih važnih izvora obnovljive energije. Time bi se doprinelo efikasnijem korišćenju energetskih resursa i ostvarivanju održive budućnosti.

### 2. IMPLEMENTACIJA SISTEMA

Sistem koji je implementiran za automatsku detekciju polja solarnih elektrana sastoji se od tri glavne komponente. Prva komponenta je ulaz u neuronsku mrežu, koji predstavlja satelitski snimak sa visokim nivoom detalja na rezoluciji 16 nad kojom se vrši detekcija. Druga komponenta je duboka neuronska mreža, čiji je zadatak da generiše izlaznu masku koja označava regije na snimku na kojima se nalaze solarni paneli. Treća komponenta je regularizacija izlazne maske, koja pomaže da se obezbedi preciznost i očuva oština kontura u konačnom izlazu mreže. Na slici 1 mogu se videti izlazi iz komponenti modela.

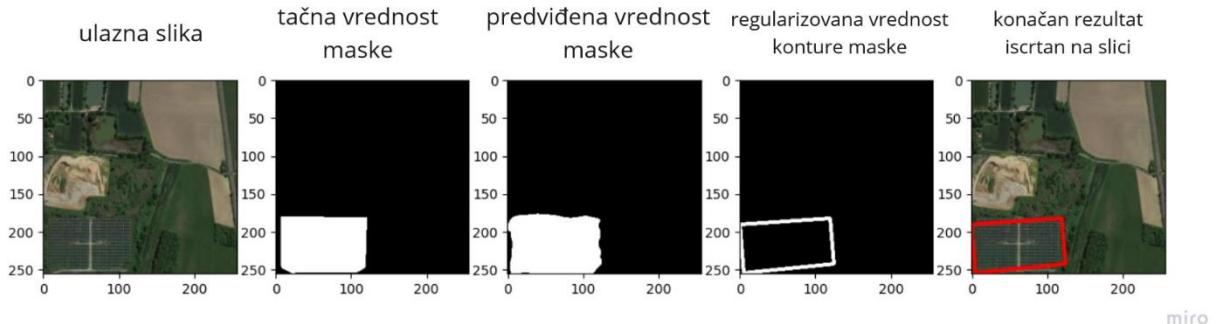
#### 2.1. Duboka neuronska mreža

Kao neuronska mreža koja rešava ovaj problem, implementirana je U-Net arhitektura [1]. U-Net arhitektura je postigla izuzetne rezultate u segmentaciji i analizi slika za druge potrebe i efikasno rešava neka ograničenja potpuno konvolucionih mreža (FCN), što je dovelo do izbora U-Net kao modela u ovom slučaju. Kako se često kombinuje sa ResNet mrežom kao osnovom, i kako je sama ResNet mreža jedan od standarda u svetu računarske vizije, odlučeno je da i ovde ona ostane osnova. Isprobano je više varijacija ResNet arhitektura različitih dubina kako bi se dobio uvid koliko dubina i veći broj parametara utiču na preciznost i kolika je kompleksnost samog problema.

Srž U-Net mreže je njen karakteristična struktura enkodera i dekodera. Mreža počinje s konstruktivnim putem (enkoderom), koji hijerarhijski izvlači osobine iz ulazne slike koristeći zaredane konvolucione slojeve sa uzorkovanjem. Ovaj put enkodera efikasno smanjuje prostorne dimenzije i povećava dubinu reprezentacije osobina. Dekoder uzima te hijerarhijske osobine koje je enkoder izvukao, skalira i rekonstruiše ih u segmentacionu masku visoke rezolucije. Time se dobija detaljna i precizna lokalizacija objekata i regiona od interesa sa ulazne slike. Ono što izdvaja U-Net arhitekturu je njen upotreba preskačućih veza. Ove veze prevazilaze razliku između puta enkodera i dekodera spajanjem mapa osobina iz enkodera sa odgovarajućim slojevima u dekoderu i daju arhitekturi karakterističan oblik po kom je i dobila ime.

### NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Aleksandar Kovačević, red. prof.



Slika 1. Izlazi iz komponenti modela

Sami enkoder i dekoder delovi mogu da se menjaju, odnosno da se na mestu njih koriste razni pretrenirani modeli kao osnova za U-mrežu. Često se uparaje sa ResNet arhitekturama raznih dubina i VGG arhitekturom kao osnovom.

## 2.2. Regularizacija poligona

Konvolucione neuronske mreže (CNN) su moćan alat za obradu slika, ali imaju tendenciju da na konačnom izlazu izgube oštrinu ivica kontura i čoškove objekata. Ovaj fenomen se dešava zbog načina na koji CNN obrađuju sliku koristeći konvolucionе slojeve, slojeve za uzorkovanje i slične tehnike. Ovi slojevi često izdvajaju bitne karakteristike slike, ali mogu "zamagliti" detalje poput oštih ivica i čoškova.

Da bi se nadoknадila ova tendencija i poboljšala preciznost izlaza CNN-a, koristi se tehnika poznata kao "regularizacija poligona" pomoću Ramer-Douglas-Peucker algoritma [2] [3].

Algoritam Ramer-Douglas-Peucker je tehnika za aproksimaciju krivulja ili kontura redukovanjem broja tačaka. Počinje s nizom tačaka i postepeno uklanja nepotrebne tačke tako da zadržava samo one koje su bitne za očuvanje oblika krivulje. Ovo čini tako što izračunava udaljenost između svih tačaka u nizu i zatim zadržava samo one tačke koje su udaljene iznad određenog praga ili epsilon vrednosti od aproksimirane krivulje.

## 3. SKUP PODATAKA

Skup podataka sadrži slike regija solarnih panela na predelu Italije koje su izvučene iz OSM (OpenStreetMap) baze podataka. Samo labeliranje solarnih panela u OSM bazi podataka nije striktno regulisano, pa se mogu naći varijacije u skupu, gde je neko označavao solarne ćelije jednu po jednu, dok je neko drugi samo označio parcelu na kojoj se nalazi polje solarnih panela.

Sam skup slika nije obuhvatio one koje ne prikazuju solarne panele, jer je početna svrha projekta bila otkriti ukupnu površinu solarnih panela na poznatim koordinatama parcela, pa se očekivalo da će slike uglavnom sadržati solarne panele. Takođe, s obzirom da je skidanje i pravljenje skupa bilo automatsko, postoji mogućnost da se u tom skupu nalaze loše labelirani podaci, zastareli satelitski snimci ili da su objekti zaklonjeni oblacima.

Slike u skupu su dimenzija 256x256x3 gde vrednosti boja upadaju u raspon između 0 i 255, a prikupljeno je ukupno

5360 slika što pokriva površinu od oko 2000 km<sup>2</sup> Zemljine površine. Skup podataka podeljen je tako da 4306 slika bude za obučavanje, a 1054 za validaciju, što predstavlja podelu blizu odnosa 80% - 20% za obučavanje i validaciju.

## 3.1. Metodologija kreiranja skupa podataka

Da bi se dobili podaci napisan je upit u Overpass QL (Overpass Query Language) jeziku, koji predstavlja način da se izvuku podaci iz OSM baze podataka. Prilikom slanja upita može se specifikovati format u kom želimo da se vrati podaci. U ovom radu kao format izabran je JSON zato što se lako učitava u GeoDataFrame. Podaci koje vraća upit su geografske koordinate tačaka, relacija i puteva. Možemo smatrati da su zatvoreni putevi poligoni, a cilj učitavanja podataka u GeoDataFrame jeste da isfiltriramo rezultate koji nisu poligoni.

Sledeći korak je pretvaranje geografskih koordinata u koordinate pločica i piksela za određeni nivo detalja. Izabran je nivo detalja 16, jer se na njemu vide polja solarnih elektrana sa njihovom okolinom. Za ove transformacije koristi se biblioteka vec\_geohash, koja je implementirana za ovu svrhu [4].

Na osnovu dobijenih koordinata pločica vrši se grupisanje poligona i skidaju se satelitski snimci. Za skidanje satelitskih snimaka iskorišćene su GoogleMaps i ArcGis provajderi web mapa. Istovremeno u ovom koraku kreiraju se i maske za svaki poligon koji upada u tu pločicu. Maske se dobijaju tako što se od piksel koordinata oduzme broj piksela početka pločice.

## 4. EKSPERIMENTI I REZULTATI

Kao eksperiment menjani su parametri dubine osnove za U-Net arhitekture i broj slika u batch-evima (veličine podskupa skupa slika). Za mrežu osnove isprobane su tri ResNet arhitekture različite dubine (ResNet18, ResNet34 i ResNet50), ispitivalo se da li povećanjem dubine dolazi do značajnijeg poboljšanja u predviđanju. Sve mreže su već uzete pretrenirane kako bi se ubrzao proces treninga. Broj slika koje su mogle da stanu u batch je bio ograničen dostupnom memorijom no isto su isprobane tri vrednosti (8, 16 i 32).

Najbolji model je postigao dobre rezultate prema metriči preseka nad unijom (IoU). IoU od 89% koji je postignut kod skoro svih modela pokazuje visok nivo tačnosti u semantičkoj segmentaciji objekata, što ukazuje na

efikasnost modela u automatskom identifikovanju i lokalizaciji solarnih instalacija na satelitskim snimcima.

Rezultati za različite osnove pokazuju da problem nije bio previše kompleksan, odnosno da se polja solarnih elektrana dosta razlikuju od svoje okoline, pošto i najjednostavnija mreža (mreža sa najmanje parametara) ima rezultate u približnom rangu kao i najkompleksnija mreža (mreža sa najviše parametara). Ovo se može opravdati činjenicom da solarni paneli često obrazuju karakterističan i pravilan obrazac koji nije lako naći u prirodi.

Rezultati za veličinu batch-a ukazuju da on nije doprineo značajnijoj promeni IoU mere. Prepostavka da se smanjenjem veličine batch-a model više prilagođava individualnim primerima i da će se to preneti na poboljšano predviđanje ovde se nije pokazala kao tačna.

Međutim, povećanjem dubine osnove modela i smanjenjem veličine batch-eva povećava se dužina treniranja.

## 5. ZAKLJUČAK

U ovom radu je korišćena duboka neuronska mreža, konkretno ResNet konvolucionna neuronska mreža, u kombinaciji sa U-Net arhitekturom za semantičku segmentaciju slika, kako bi se automatski identifikovala i lokalizovala polja solarnih elektrana na satelitskim snimcima.

Motivacija za rešavanje ovog problema leži u potencijalu za automatizaciju analize satelitskih snimaka i otkrivanju polja solarnih panela, koje igraju ključnu ulogu u suzbijanju klimatskih promena i promovisanju obnovljivih izvora energije.

Model je postigao zadovoljavajuće rezultate kada je reč o IoU metrići, sa 89% tačnosti u semantičkoj segmentaciji objekata, što ukazuje na efikasnost modela u automatskom otkrivanju i preciznom lociranju solarnih instalacija na satelitskim snimcima.

Treba uzeti u obzir da je i trening i test skup satelitskih snimaka iz regiona Italije te da bi varijacije u terenu iz kompletno drugog regiona sveta uticale na predviđanje ovog modela. Kako bi se ovo rešilo trening skup može se proširiti da obuhvati različite regije planete.

Dodavanjem satelitskih snimaka većeg nivoa detalja kao ulaznih podataka modelu, omogućila bi se šira primena za detekciju rezidencijalnih fotočelija.

Verujemo da bi poboljšanju modela doprinela i promenom načina na koji se vrši regularizacija poligona sa izlaznih maski. Trenutno ovo polje istraživanja je otvoreno i konstantno izlaze novi metodi koji uključuju razne modele neuronskih mreža i postižu bolje rezultate nego konvencionalni algoritmi.

## 6. LITERATURA

- [1] O. Ronneberger, P. Fischer i T. Brox, U-Net: Convolutional Networks for Biomedical Image Segmentation, Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015.
- [2] U. Ramer, An iterative procedure for the polygonal approximation of plane curves, Computer Graphics and Image Processing, 1972.
- [3] D. Douglas i P. Peucker, Algorithms for the Reduction of the Number of Points Required to Represent a Digitized Line or its Caricature, Cartographica: The International Journal for Geographic Information and Geovisualization, 1973.
- [4] F. Jakovljević, „vec\_geohash,“ [https://github.com/FJakovljevic/vec\\_geohash](https://github.com/FJakovljevic/vec_geohash), 2023.

## Kratka biografija:



**Filip Jakovljević** rođen je 1996. u Novom Sadu, Republika Srbija. Završava gimnaziju „Jovan Jovanović Zmaj“ i upisuje Fakultet tehničkih nauka, odsek Računarstvo i automatika. Osnovne studije završava u roku 2019. godine.  
kontakt: fillix96@gmail.com