

DETEKCIJA NASELJA NA SATELITSKIM SNIMCIMA

DETECTION OF SETTLEMENTS IN SATELLITE IMAGES

Tamara Todić, *Fakultet tehničkih nauka, Novi Sad*

Oblast - ELEKTROTEHNIKA I RAČUNARSTVO

Kratak sadržaj - U radu je razmatran problem klasifikacije sadržaja multitemporalnih, multimodalnih i multispektralnih slika dobijenih pomoću sistema daljinske detekcije, a u cilju pronalaženja naselja. Akcenat je na integrisanju podataka iz različitih izvora.

Ključne reči: detekcija naselja, satelitski snimci, neuronska mreža, fuzija podataka

Abstract - The paper considers the problem of classification of content of multitemporal, multimodal and multispectral remote sensing images, with the aim of settlement detection. The accent is on the integration of data from multiple different sources.

Keywords: Settlement detection, satellite images, neural network, data fusion

1. UVOD

Sistemi za opservaciju Zemlje svakodnevno generišu ogromne količine podataka, koji se mogu koristiti u razne svrhe, između ostalog, za detekciju naseljenih mesta, što je i tema ovog rada.

U 2012. godini postignut je značajan napredak što se kvaliteta satelitskih snimaka tiče - lansirani su novi sateliti sa opremom koja je omogućila da se dobiju slike veće rezolucije, tačnosti i osetljivosti. Posebno su zanimljivi snimci dobijeni noću - jer se tada uočavaju osvetljeni delovi planete, što je važno za brojna istraživanja - između ostalog, i za temu kojom se bavi ovaj rad - detekcija naselja [1].

Za detekciju naselja, informacija o tome gde su osvetljene oblasti je veoma važna. Ali, naselja koja nemaju pristup električnoj energiji ne mogu biti detektovana samo na osnovu prisustva svetlosti tokom noći. Za taj problem potrebno je iskoristiti i dnevne snimke. Zatim, korisno je imati snimke iste oblasti kroz vreme, jer se oblasti sa gustom vegetacijom menjaju u skladu sa godišnjim dobima, za razliku od urbanih oblasti.

2. PREGLED LITERATURE

U radu [2], integrišu se vremenske i prostorne informacije u cilju klasifikacije piksela satelitskih slika sa SENTINEL-2 i VHSR u jednu od 12 klasa. Koristi se model koji ima 2 grane, jednu koja obrađuje vremenski niz podataka, i drugu koja je zadužena za prostorne informacije. Vrš se fuzija obeležja dobijenih iz ove dve

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Branko Brkljač, docent.

grane, i nad tim se radi klasifikacija, a takođe se klasifikuju i izlazi svake grane zasebno, kako bi se mreža podstakla da izvuče maksimalnu količinu informacija iz svake vrste podataka. Za poređenje rezultata korišćen je *Random Forest* (RF), i performanse M^3 Fusion modela prevazilaze performanse *Random Forest* algoritma. Rezultati za pet različitih slučajnih trening-test podela podataka, dobijeni na osnovu snimaka francuskog ostrva Reunion, iz 2016. i 2017. godine, dati su u tabeli 1.

Tabela 1. Rezultati M^3 Fusion modela za klasifikaciju piksela sa satelitskih snimaka u poređenju sa RF, prema [2]

br. eksp.	RF		M^3 Fusion		Gain	
	Acc.	F-Meas	Acc.	F-Meas	Acc.	F-Meas
1	87,39	87,11	90,67	90,67	+3,28	+3,56
2	88,47	88,05	91,52	91,39	+3,05	+3,34
3	85,21	84,62	89,25	89,15	+4,04	+4,53
4	88,33	88,05	90,61	90,7	+2,28	+3,08
5	87,29	86,88	90,09	89,96	+2,8	+3,08

U radu [3] koriste se konvolucione neuronske mreže za klasifikaciju urbanog otiska - najpre su korišćene poznate arhitekture poput U-Net, SegNet i FCN, ali samo na slikama iz jednog trenutka - ne na vremenskim nizovima, a zatim je arhitektura koja je pokazala najbolji rezultat, u ovom slučaju U-Net, trenirana na vremenskim nizovima snimaka. Kada se koristi vremenski niz snimaka, performanse se popravljaju za 2.72% i 6.4% za dve klase koje postoje u odnosu na slučaj kad se koristi samo slika iz jednog trenutka.

U radu [4] koristi se konvoluciona neuronska mreža kako bi se detektovala neformalna naselja na VHR (engl. Very High Resolution) satelitskim snimcima. Pošto je potrebno klasifikovati svaki piksel, tokom treninga, u mrežu ulaze delovi slike, engl. *patch*, koji okružuju piksel od interesa i model se trenira da izvrši klasifikaciju jednog *patch*-a. Kada se dobije istreniran model, on se koristi tako što klizajući prozor veličine *patch*-a iz treninga prelazi preko slike pri čemu se pomera za po jedan piksel, i na svakom mestu se vrši klasifikacija *patch*-a. Postignuta je tačnost 91,71%.

3. OPIS BAZE PODATAKA

U ovom istraživanju korišćena je baza podataka koja je data na 2021 IEEE GRSS Data Fusion Contest: Track DSE takmičenju, gde je cilj bio da se uz pomoć multitemporalnih, multimodalnih i multispektralnih satelitskih slika detektuju naselja koja nisu snabdevena električnom energijom. Takmičenje je organizovano od strane odbora

Image Analysis and Data Fusion Technical Committee (IADF TC), u okviru udruženja IEEE Geoscience and Remote Sensing Society (GRSS), sa ciljem da se promoviše istraživanje u oblasti daljinske detekcije u svrhe automatskog pronalaženja naselja bez pristupa električnoj energiji.

Bazu podataka čini 98 slika veličine 800x800 piksela, rezolucije 10m. Ravnomerno su raspoređene u trening, validacioni i test skup (60/19/19). Test skup nije vidljiv takmičarima, a za validacioni nisu dostupne labela [5].

Svaka slika ima 98 kanala, i sve slike su skalirane tako da GSD (engl. Ground Sampling Distance) bude 10m. Svaka slika dakle ima površinu 64km². Snimci su dobijeni sa četiri satelita: SENTINEL-1 - vremenski niz od 4 snimka po 2 kanala koja odgovaraju VV i VH polarizaciji; SENTINEL-2 - vremenski niz od 4 snimka po 12 kanala iz vidljivog i SWIR (engl. Short Wave Infrared) dela spektra; Landsat 8 - vremenski niz od 3 snimka po 11 kanala iz VNIR (engl. Visible Near InfraRed), SWIR i TIR (engl. Thermal InfraRed) delova spektra, s tim da je izostavljen opseg talasnih dužina koje se koriste za detekciju cirusa (oblaka), jer ne sadrži informacije o tlu; VIIRS - vremenski niz od 9 snimaka po 1 kanal koji sadrži noćne sat. snimke.

Za svaku sliku date su po dve labela/oznake - jedna u formi indeksirane slike veličine 800x800 piksela, prostorne rezolucije 10m, na kojoj svaki region veličine 500x500m (zona od 50x50 piksela) ima jedinstvenu klasu (oznaku); i druga labela u formi slike veličine 16x16 piksela, gde svaki piksel ima svoju klasu, a prostorna rezolucija pojedinačnog piksela je 500m. Ukupno postoje 4 klase ili kategorije naselja: 1) bez električne energije, 2) naselja sa električnom energijom, 3) region bez naselja ali sa električnom energijom, i 4) region bez naselja i bez električne energije. Odgovarajuće numeričke oznake date su u tabeli 2.

Tabela 2. Vrednosti piksela i boje koje odgovaraju klasama u korišćenom skupu satelitskih snimaka [5]

Vrednost piksela	Klasa	Boja
1	Naselje bez električne energije (klasa od interesa)	ff0000
2	Bez naselja i bez električne energije	0000ff
3	Naselja sa električnom energijom	ffff00
4	Bez naselja sa električnom energijom	b266ff


Zastupljenost pojedinih klasa u skupu podataka prikazana je na slici 1, a primer kako su labelirane slike na slici 2.

Skup podataka nije izbalansiran, najveći deo (53,1%) čine uzorci iz klase bez naselja i bez električne energije, 41,1% su uzorci iz klase naselja bez električne energije, dok klasa naselja sa električnom energijom čini 4,4% skupa, a klasa bez naselja, sa električnom energijom samo 1,4% [5].

Slika 3 prikazuje broj slika iz skupa podataka koje na sebi sadrže svaku od klasa. Oznake i boje odgovaraju onima u tabeli 2.



Slika 1. Raspodela klasa u skupu podataka



Slika 2. SENTINEL-2 slika sa labelama [5]

Na svakoj slici u skupu podataka za trening javljaju se klase naselja bez električne energije i bez naselja i bez električne energije. Klasa naselja sa električnom energijom javlja se na 38% trening slika, a region bez naselja sa električnom energijom na 32% trening slika.



Slika 3. Broj slika iz skupa podataka koje na sebi sadrže određenu klasu.

Svaka slika koja sadrži region bez naselja sa električnom energijom sadrži i sve ostale klase. 19 od 60 slika iz trening skupa sadrži sve 4 klase, dok 37 slika sadrži samo

klase naselja bez električne energije i bez naselja i električne energije (klase 1 i 2).

4. MODEL

Kako su u bazi dostupni vremenski nizovi multispektralnih slika sa različitih satelita, ideja je da se model za detekciju naselja projektuje tako da koristi sve raspoložive podatke. Po ugledu na M³Fusion model [2], razvijena je neuronska mreža koja klasifikaciju dela slike (engl. *patch-a*) realizuje kroz fuziju podataka i sastoji se iz dve grane za obradu.

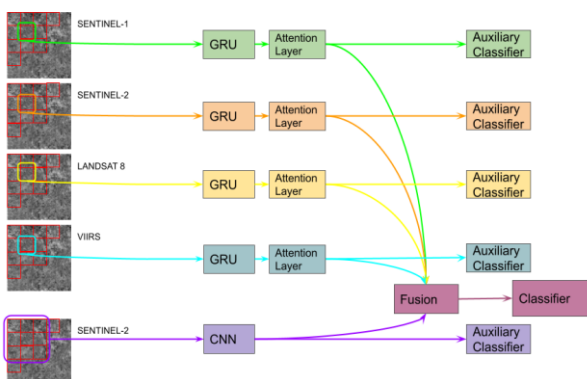
Jedna grana ima fokus na podacima kroz vreme, i sadrži rekurentnu neuronsku mrežu (RNN), tačnije GRU (engl. *Gated Recurrent Unit*). Ulaz u ovu granu je vremenski niz jednog dela slike za koji je data jedinstvena labela (jedan *patch*) veličine 50x50 piksela (500x500m). Nakon GRU nalazi se "attention" mehanizam, sa idejom da nauči koji vremenski trenutak je koliko važan za klasifikaciju.

Druga grana je sa fokusom na prostorne informacije - ulaz je deo satelitske slike veličine 150x150 piksela (1500x1500m), koji predstavlja okolinu *patch-a* od interesa. Tu sliku obrađuje konvoluciona neuronska mreža (CNN). Ideja je da se posmatranjem okoline *patcha* od interesa dobijaju korisne informacije za njegovu klasifikaciju.

Izračunata obeležja na izlazu dve opisane grane se konkateneraju i zatim prolaze kroz klasifikator - potpuno povezanu neuronsku mrežu.

Dodatno, kako bi se podstaklo da mreža i iz vremenskih i iz prostornih podataka izvuče što više diskriminativnih informacija, koriste se dva pomoćna klasifikatora - jedan koji prepoznavanje kategorija realizuje samo na osnovu obeležja dobijenih iz grane koja obrađuje podatke kroz vreme, i drugi koji se oslanja samo na obeležja iz grane koja posmatra okolinu regiona od interesa [2].

Ako se koriste snimci sa više satelita u skladu sa tim se povećava i broj grana koje sadrže GRU, i za svaku se dodaje još po jedan pomoćni klasifikator. Na slici 3 je prikazana šema modela kada se koriste sva 4 satelita.



Slika 3. Šema korišćenog eksperimentalnog modela

5. EKSPERIMENTI

U cilju poređenja GRU i konvolucione GRU, kao i korišćenja svih raspoloživih podataka spram korišćenja samo nekih satelita, izvršeno je nekoliko eksperimenata.

U svakom eksperimentu, na ulazu u granu koja sadrži CNN je SENTINEL-2 slika. Poređene su performanse sistema za prepoznavanje kada se na ulaz grane koja sadrži RNN postavi samo VIIRS, zatim kombinacija SENTINEL-2 i VIIRS, i na kraju kombinacija sva 4 raspoloživa satelita.

Funkcija cene koja je korišćena za optimizaciju parametara modela predstavlja zbir funkcija cene (međuentropije) za svaki klasifikator u modelu.

Za iterativnu optimizaciju korišćen je *Adam* algoritam, a brzina učenja je postavljena na 10^{-4} . Treninzi su izvršavani na NVIDIA TITAN Xp grafičkoj kartici, a potrebna memorija za jedan model sa konvolucionom GRU koji integriše sva 4 satelita je 3,9GB. Model koji ima GRU i integriše sva 4 satelita zahteva 262MB. Trajanje jedne epohe je približno 20 minuta. Za implementaciju modela korišćena je *PyTorch* biblioteka. S obzirom na to da za validacioni deo skupa podataka nisu date labele, iz skupa za obuku koji sadrži 60 slika izdvojeno je 20% za validaciju.

Pošto su korišćene satelitske slike u nekoj meri već bile sa predobradom - izvršene su geometrijske korekcije, uklonjeni oblaci i slično, dodatno je izvršena normalizacija tako da sva obeležja budu u istom opsegu - da svaki kanal ima srednju vrednost nula i jediničnu varijansu.

S obzirom da CNN modul "posmatra" deo slike oko regiona od interesa, kako bi mogli da se koriste i ivični regioni slika se pre ulaza u ovaj modul proširuje tako što se simetrično "ogleda" na ivicama. Sem toga, u okviru korišćene baze date su i labele koje sadrže 4 klase. Pošto je primarni cilj da se detektuju naselja, bez obzira na snabdevenost električnom energijom, labele su prevedene u 2 klase - po jedna za region sa i bez naselja. Regioni koji sadrže naselja sa pristupom električnoj energiji i oni koji sadrže naselja bez pristupa električnoj energiji su spojeni u jednu klasu, a regioni koji nemaju naselja ali imaju električnu energiju i oni koji nemaju ni naselja ni električnu energiju u drugu klasu (kategoriju).

6. REZULTATI

Vrednosti funkcije cene i tačnosti na validacionom delu podataka koje su postignute u 6 eksperimenata date su u tabeli 3. Prikazana vrednost za funkciju cene izračunata je tako što je funkcija cene koja je korišćena tokom treninga (zbir međuentropija za glavni i sve pomoćne klasifikatore) podeljena sa brojem klasifikatora. Tačnost je data samo na osnovu glavnog klasifikatora.

Tabela 3. Funkcije cene i tačnost na validacionim podacima

Sateliti (korišćena merenja)	GRU		Konvoluciona GRU	
	funk. cene / br. klas.	tačnost	funk. cene / br. klas.	tačnost
VRIIS	0.6241	0.7523	0.6096	0.7145
S-2 VIIRS	0.7039	0.7301	0.6314	0.7454
S-1, S-2 L8, VIIRS	0.7444	0.7210	0.5276	0.7650

Ukoliko se koristi konvoluciona GRU, tačnost raste kako se koristi više satelita za klasifikaciju. Najbolju tačnost na validacionom skupu podataka postigao je model sa konvolucionom GRU koji integriše sva četiri satelita čiji se snimci nalaze u bazi podataka.

U tabeli 4 prikazane su postignute tačnosti za svaki model i svaku klasu posebno. Zelenom bojom su osenčena polja kod modela koji imaju najbolje performanse za datu klasu. Najbolje su performanse za klasu bez naselja i bez električne energije, a najlošije je za klasu naseljenih mesta koja nemaju električnu energiju, sem kod modela koji koristi GRU i sva četiri satelita - kod njega su za ovu klasu performanse veće nego za klasu bez naselja, sa električnom energijom. Takođe, ovaj model je postigao značajno veću tačnost za klasu naselja bez električne energije nego modeli sa konvolucionom GRU, što ni za jednu drugu klasu nije slučaj.

Tabela 4. Tačnost svakog od modela za svaku klasu posebno

Klasa	GRU			Konvoluciona GRU		
	VIIRS	S-2 VIIRS	S-1,S-2 L8 VIIRS	VIIRS	S-2 VIIRS	S-1, S-2 L8 VIIRS
1	0.1878	0.2365	0.4637	0.1981	0.2438	0.3247
2	0.9787	0.9671	0.7752	0.9706	0.9919	0.9808
3	0.8000	0.6750	0.8125	0.7625	0.7250	0.8250
4	0.4906	0.6226	0.2830	0.4906	0.7170	0.6415

7. ZAKLJUČAK

Izvedeno je nekoliko eksperimenata u cilju poređenja GRU i konvolucione GRU, kao i korišćenja nekoliko kombinacija satelita za detekciju naselja na satelitskim snimcima. Modeli sa konvolucionom GRU pokazali su se kao bolji što se tiče tačnosti, ali zahtevaju više resursa za obuku. Različite performanse za različite klase su očekivane s obzirom na to da skup podataka nije izbalansiran.

Iako iz klase sa naseljima koja su snabdevena električnom energijom ima malo uzoraka - svega 4.4% skupa podataka, tačnost za ovu klasu je dosta visoka kod svih modela. To je takođe očekivano, pošto se razlike u odnosu na regione bez naselja vide i na dnevnim i na noćnim snimcima. Potrebno je dalje uvesti izmene u arhitekturama modela kako bi se dobili bolji rezultati, i izbalansirati skup podataka kako bi se smanjile razlike u performansama među klasama.


8. ZAHVALNICA

The authors would like to thank the IEEE GRSS Image Analysis and Data Fusion Technical Committee, Hewlett Packard Enterprise, SolarAid, and Data Science Experts for organizing the Data Fusion Contest.

9. LITERATURA

- [1] C. Kyba et al., "High-Resolution Imagery of Earth at Night: New Sources, Opportunities and Challenges", *Remote Sensing*, vol. 7, no. 1, pp. 1-23, 2014. Dostupno: 10.3390/rs70100001 [Pristupljeno 30. avgusta 2021].
- [2] P. Benedetti, D. Ienco, R. Gaetano, K. Ose, R. Pensa and S. Dupuy, " M^3 Fusion: A Deep Learning Architecture for Multiscale Multimodal Multitemporal Satellite Data Fusion", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 12, pp. 4939-4949, 2018. Dostupno: 10.1109/jstars.2018.2876357 [Pristupljeno 29. avgusta 2021].
- [3] L. El Mendili, A. Puissant, M. Chougrad and I. Sebari, "Towards a Multi-Temporal Deep Learning Approach for Mapping Urban Fabric Using Sentinel 2 Images", *Remote Sensing*, vol. 12, no. 3, p. 423, 2020. Dostupno: 10.3390/rs12030423 [Pristupljeno 29. avgusta 2021].
- [4] N. Mboga, C. Persello, J. Bergado and A. Stein, "Detection of informal settlements from VHR satellite images using convolutional neural networks", *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017. Dostupno: 10.1109/igarss.2017.8128166 [Pristupljeno 29. avgusta 2021].
- [5] 2021 IEEE GRSS Data Fusion Contest: www.grss-ieee.org/community/technical-committees/data-fusion.

Kratka biografija:



Tamara Todić rođena je u Kikindi 1997. godine. Osnovne akademske studije na Univerzitetu u Novom Sadu uspešno je završila 2020. god. na Fakultetu tehničkih nauka, studijski program Energetika, elektronika i telekomunikacije, smer Komunikacione tehnologije i obrada signala. Master rad iz oblasti elektrotehnike i računarstva - Obrada signala, odbranila je 2021. Godine.

Kontakt: tamaratodic97@gmail.com