

DUBOKO UČENJE ZA DELINEACIJU POLJOPRIVREDNIH PARCELA

DEEP LEARNING FOR FARM BOUNDARIES DELINEATION

Đorđe Batić, *Fakultet tehničkih nauka, Novi Sad*

Oblast – ELEKTROTEHNIKA I RAČUNARSTVO

Kratak sadržaj – Najčešće korišćen izvor za dobavljanje podataka o poljoprivrednim granicama je katastar. Međutim, proces ekstrakcije katastarskih podataka je i dalje značajno manuelan proces, što neizbežno dovodi do povećane verovatnoće za grešku u merenju, kao i povećanih troškova. Jedan od mogućih načina prevazilaženja spomenutih problema je automatizacija procesa delineacije granica parcela korišćenjem satelitskih slika i metoda dubokog učenja. U ovom radu predstavljena je konvolutivna neuronska mreža za detekciju (tj. delineaciju) poljoprivrednih granica, gde se kao ulaz modela koriste multi-spektralne satelitske slike. Istrenirani model uspešno prepoznaće granice poljoprivrednih parcela i ostvaruje rezultate bolje od autora originalnog skupa podataka. Iako su ostvareni zadovoljavajući rezultati, predloženi su koraci za poboljšanje predloženog rešenja koji bi mogli dovesti do ostvarivanja robusnijih rezultata.

Ključne reči: CNN, Delineacija, Daljinsko istraživanje, Satelitski snimci

Abstract – The most common source of field boundary data is cadaster. Unfortunately, the process of extracting cadastral information has remained highly manual, which inevitably leads to proneness to errors and high costs. One of the possible ways to improve generating and updating cadastral information is automating the delineation of boundaries through satellite imagery and deep learning-based methods. This paper presents a CNN-based architecture for delineating agricultural boundaries, where multispectral satellite images are used as an input of the model. The trained model performs accurate boundary detection and achieves better results than the authors of the original dataset. Even though satisfactory results were achieved, we proposed steps to improve the proposed solution, which could increase robustness.

Keywords: CNN, Delineation, Remote Sensing, Satellite Imagery

1. UVOD

Cambridge English Dictionary definiše granicu kao realnu ili imaginarnu liniju koja označava ivicu nečega. Ova definicija može biti proširena u agrikulturalnom domenu tvrdnjom da je granica lokacije gde se događa promena u tipu poljoprivredne kulture ili gde su dve slične poljoprivredne kulture odvojene prirodnom disruptjom u terenu [1].

Informacije o opsegu granica su zabeležene i definisane u katastru. Katastar (katastarska mapa) je obiman katalog zemljišnih parcela koje predstavljaju kontinualan prostor

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bila dr Jelena Slivka, vanr. prof.

koji je identifikovan jedinstvenim skupom homogenih imovinskih prava i geometrijskim opisom zemljišnih parcela. Literatura prepoznaje dva tipa poljoprivrednih granica: „fiksne“ i „generalne“. Fiksne granice sadrže precizno određene dimenzije, dok generalne granice predstavljaju aproksimaciju koja je podložna prostornim i vremenskim promenama. Održanje integriteta fiksnih i generalnih granica je krucijalan zadatak za pouzdanost katastarskih informacija. Međutim, kreiranje i ažuriranje katastarskih podataka je često spor, skup i proces podložan greškama, što je posledica oslanjanja na direktnе ili *ground-based* tehnike merenja [2]. Ova činjenica često dovodi do nedovoljno kvalitetnog geometrijskog kvaliteta katastarskih mapa i nedoslednosti između registrovanih podataka i stvarnog stanja na terenu. Motivisani spomenutim izazovima, interesovanje za automatske pristupe detekciji poljoprivrednih granica (tj. delineaciji) doživelo je značajan rast u naučnoj zajednici [3, 4, 5]. Pouzdana automatska detekcija poljoprivrednih granica korišćenjem satelitskih slika omogućava poverenje u tačnost katastarskih informacija i značajno smanjuje cenu definisanja i ažuriranja granica. Ovaj rad se fokusira isključivo na prirodne granice koje mogu biti detektovane sa satelitskih slika, a to uključuje najčešće: zgrade, ograde, žive ograde, zidovi, putevi, staze, određeni usevi, reke i kanali, slika 1.



Slika 1. Primer slike iz skupa podataka (levo) i primer slike iz skupa referentnih (engl. ground-truth) podataka

U poslednje vreme, konvolucione neuronske mreže (engl. *convolutional neural networks*, CNNs), algoritmi koji su zasnovani na dubokom učenju, beleže značajan uspeh u oblasti rešavanju problema mašinske vizije (engl. *computer vision*) vezanih za klasifikaciju slika [6]. Njihov uspeh je omogućen sposobnošću da pod uslovom skupa podataka sa dovoljnim nivoom varijabilnosti, efikasno nauče atribute (engl. *features*) različitih semantičkih nivoa. Skorija istraživanja pokazuju da povećanje dubine (broja slojeva) mreže obogaćuje hijerarhijsku semantiku naučenih atributa [7]. Međutim, u praksi, dodavanje novih slojeva na odgovarajuću duboku mrežu često dovodi do degradacije tačnosti prilikom treniranja. Kao odgovor na ovaj problem, autori u [7] predlažu tehniku rezidualnog učenja. Autori napominju da ova degradacija nije uslovljena problemima vezanim za nestajanje ili eksploraciju gradijenata, koji su rešeni uvođenjem normaliza-

cionalih slojeva, kao ni pretreniranjem mreže (engl. *overfitting*).

Motivisan rešenjem predloženim u [7], ovaj rad predstavlja arhitekturu koja primenjuje koncept rezidualnog učenja u domenu detekcije poljoprivrednih granica. Predloženo rešenje ostvaruje zadovoljavajuće rezultate i pokazuje sposobnost generalizacije nad oblastima koje sadrže poljoprivredne parcele različitog oblika, veličine i tipa.

U narednom poglavlju detaljno su predstavljena postojeća rešenja u oblasti delineacije poljoprivrednih parcela, kao i poređenje sa našim rešenjem. Arhitektura modela i korišćene tehnike opisane su u poglavlju 3, a poglavlje 4 sadrži analizu dobijenih rezultata i mogućih poboljšanja. Poglavlje 5 predstavlja zaključak rada.

2. PRETHODNA REŠENJA

U poslednje vreme, interesovanje za primenu metoda dubokog učenja u domenu delineacije poljoprivrednih parcela primećuje značajan rast [3, 4, 5]. Autori u [5] predlažu algoritam dubokog učenja za detekciju granica u okviru poljoprivrednih polja Navare regije u severnoj Španiji.

Satelitske slike su sakupljene korišćenjem SIGPAC sistema¹. Predložena je U-Net [8] arhitektura bazirana na isećima slika (engl. *patch-based architecture*), gde su enkoder i dekoder kreirani modifikacijom pretrenirane VGG-16 [9] mreže. Ulazi slika su preklopjeni isečci originalne RGB slike koja klasificuje svaki piksel slike kao granicu ili ne-granicu. Kako bi obezbedili robustnost, autori predlažu korak post-procesiranja koji izvršava razne nasumične transformacije ulaznog isečka slike i vraća finalnu klasu segmentirane slike mekim glasanjem (engl. *soft voting*).

Persello i drugi [4] predlažu algoritam za delineaciju malih njiva (engl. *smallholder farms*) na području Nigerije i Malija uz pomoć satelitskih slika, korišćenjem konvolucionih mreža i kombinatornog grupisanja (engl. *combinatorial grouping*). Male njive su poljoprivredne parcele malih dimenzija koje su često karakterisane učešćem porodice u obrađivanju zemljišta. Problem detekcije granica parcele u ovom kontekstu je naročito kompleksan jer uključuje parcele malih dimenzija, neregularnog oblika i pomešanih useva, što čini da granice često budu nejasno definisane. Kako bi detektovali kompleksne prostorne atribute sa satelitskih slika, autori koriste enkoder-dekoder baziranu arhitekturu i vrše predikciju granica na multi-spektralnim WorldView-2/3 slikama prikupljenim na području Nigerije i Malija.

Konačno, Masoud i drugi [3] predlažu VGG-16 arhitekturu zasnovanu na dilatacionim konvolucijama (engl. *dilated convolutions*) predloženim u [10]. Dilatacione konvolucije omogućavaju eksponencijalnu ekspanziju receptivnog polja (veličine filtera) bez gubljenja rezolucije i omogućavaju detektovanje udaljenih zavisnosti između piksela bez povećanja broja parametara. Mreža izvršava delineaciju granice na Sentinel-2 slikama 10m rezolucije slikanim nad Flevoland provincije.

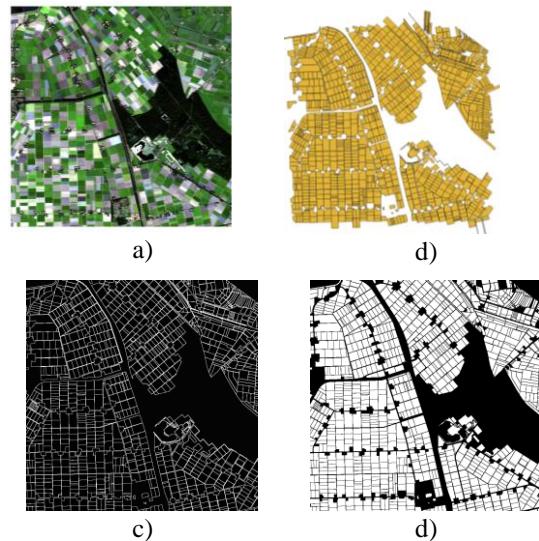
Rešenje predloženo u ovom radu oslanja se na tehnike učenja sa rezidualnim konekcijama [7]. Ulaz mreže predstavljaju multi-spektralni satelitski snimci, dok izlaz predstavlja binarna mapa koja labelira svaki piksel jednom od dve moguće klase: granica i ne-granica.

3. METOD

U narednim poglavljima izloženi su skup podataka, arhitektura i trening modela.

3.1. Skup podataka

Za treniranje i evaluaciju predloženog rešenja, korišćeni su podaci kreirani od strane autora iz [3]. Sakupljeni Sentinel-2 satelitski snimci i referentni (engl. *ground-truth*) podaci koji sadrže mapu granica parcela su sakupljeni iznad Flevoland oblasti u Holandiji. Originalne Sentinel-2. Slike sadrže 10 spektralnih kanala, četiri kanala na 10 m rezolucije (2, 3, 4, i 8 koji predstavljaju plavi, crveni, zeleni i blizu-infracrveni kanal), šest kanala na 20 m rezolucije (5, 6, 7, i 8A koji predstavljaju vegetacione kanale; i 11 i 12 SWIR kanale). Poslednja tri kanala na 60 m rezolucije (10, 11, i 12 koji predstavljaju kanale za detekciju aerosola, vodene pare i cirusa) su izostavljeni jer ne pružaju informacije relevantne za detekciju granica parcela. Ukupno, definisano je 10 poljoprivrednih oblasti (engl. *tiles*) sa parcelama, od kojih se jedna polovina koristi za treniranje, a druga za testiranje modela. Svaka oblast zauzima dimenzije od 800 x 800 piksela i površinu od 8 x 8 km². Primer jedne oblasti istraživanja i referentnih podataka dat je u donjem redu slike 2.



Slika 2. Oblast istraživanja TR1: a) RGB Sentinel-2 slika oblasti b) Referentni skup podataka za oblast c) ground-truth podaci ivica parcela d) ground-truth podaci parcela

3.2. Arhitektura

Predloženo rešenje se oslanja na arhitekture zasnovane na rezidualnom učenju [7] i ima za cilj da ekstrahuje hijerarhijske prostorne atribute multi-spektralnih ulaznih slika i transformiše ih u binarnu izlaznu sliku koja mapira granice poljoprivrednih parcela. Ulazi u mrežu predstavljaju isečke dimenzija 56 x 56 piksela, gde je za svaku od pet oblasti istraživanja (dimenzija 800 x 800 piksela) iz trening skupa generisano 1000 isečaka. Ukupno, skup podataka za obučavanje sadrži 5,000

¹ sigpac.mapama.gob.es

primeraka. Ulazne slike su potom prosleđene neuralnoj mreži koja se sastoji od dva dela: enkodera i dekodera poljoprivrednih granica. Vrste operacija koje predložena enkoder arhitektura sadrži su sledeće:

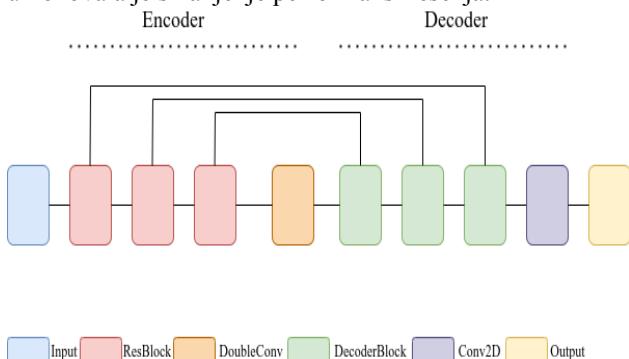
- 1) **Conv2D** konvolucioni sloj sa filterom veličine 3 (engl. *kernel-size* = 3) i ispunjavanjem veličine 1 (engl. *padding* = 1)
- 2) **Residual** ulazni podaci su obrađeni tako da generišu rezidual primenom 2-D konvolucije sa filterom veličine 1 i normalizacijom grupe (engl. *batch normalization*)
- 3) **DoubleConv** nad ulaznim podacima su dva puta ponovljene „Conv2D“ operacije praćene normalizacijom gupe i ReLU aktivacionom funkcijom.
- 4) **ResBlock** inspirisani idejom koja je predstavljena u [7], nad ulaznim podacima se primenjuje „Residual“ i „DoubleConv“ operacije čiji se izlazi sabiraju i prosleđuju ReLU aktivacionoj funkciji. Ovaj rezultat predstavlja jedan od izlaza bloka, dok je drugi izlaz rezultat „Residual“ operacije

Arhitektura enkoder dela mreže se sastoji od tri povezana „ResBlock“ bloka. Kao završni korak, nad izlazom je primenjena „DoubleConv“ operacija. Pored toga, enkoder prosleđuje i tri rezidualne reprezentacije sadržane u izlazima rezidualnih blokova (slika 3).

Naredne komponente predložene arhitekture predstavljaju dekoder koji obavlja sledeće operacije:

- 1) **DecoderBlock** obavlja „DoubleConv“ operaciju nad ulaznom reprezentacijom koja je konkatenirana sa izlazima odgovarajućeg rezidualnog bloka.
- 2) **Conv2D** generiše izlaz dekodera primenom 2-D konvolucije sa dva izlazna kanala koji predstavljaju dve moguće klase: granica i ne-granica, nad kojima je potom izvršena logaritamska *SoftMax* aktivaciona funkcija (engl. *Log-Sofmax*).

Vizuelni prikaz predložene arhitekture je prikazan na slici 3. Primene operacija smanjenja rezolucije u "ResBlock" blokovima nije dovela do povećanja tačnosti, štaviše, uzrokovala je smanjenje performansi rešenja.



Slika 3. Vizuelni primer predložene arhitekture rešenja

Mogući razlog ove pojave jeste da ulazni podaci ne sadrže dovoljno bogatu prostornu kompleksnost (zbog male veličine ulaznih isečaka) da bi ova tehnika bila uspešna. U finalnom koraku susedni, ravnomerno raspoređeni i nepreklopjeni isečci koji predstavljaju izlaze mreže su spojeni u jednu sliku koja odgovara oblasti istraživanja dimenzija 800 x 800 piksela.

3.3. Trening

Prilikom treniranja mreža, sve vrednosti piksela su normalizovane na vrednosti u opsegu [0, 1] kako bismo ubrzali vreme treniranje modela. Iskorišćen je Adam optimizator sa preporučenim parametrima $\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$, i $\epsilon = 10^{-8}$.

Vrednost broja uzoraka (engl. *batch size*) od 32 se pokazala kao najpogodnija. Veće vrednosti stepena učenja (engl. *learning rate*) su dovele do preprilagođavanja tako da je model treniran u 20 epoha sa vrednošću stepena učenja od $3e^{-4}$.

Korišćena je *Softmax* aktivaciona funkcija nad kojom je primenjena logaritamska funkcija (*Log-Sofmax*).

3.3. Procena tačnosti

Kako bismo izmerili pouzdanost rešenja za detekciju granica, korišćena je F-skor mera, dok su rezultati upoređeni sa rezultatima ostvarenim od strane autora rada [3].

Za svaku izlaznu mapu, kako bismo stekli detaljniji uvid u performanse modela, pored F-skora izračunate su i vrednosti preciznosti (engl. *precision*) i odziva (engl. *recall*).

Preciznost je definisana kao broj stvarno pozitivnih piksela koji su detektovani od strane mreže, podeljeni sa brojem svih pozitivnih detektovanih piksela:

$$p = \frac{T_{pos}}{T_{pos} + F_{pos}}$$

Odziv je mera koja je definisana brojem stvarno pozitivnih detektovanih piksela, podeljeni sa ukupnim brojem pozitivnih piksela:

$$r = \frac{T_{pos}}{T_{pos} + F_{neg}}$$

Dok je F-skor je definisan sledećom jednačinom:

$$F = 2 \cdot \frac{p \cdot r}{p + r}$$

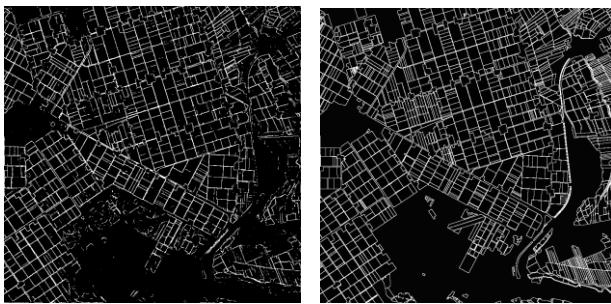
4. REZULTATI I DISKUSIJA

Evaluacijom modela utvrđeno je da dostiže veću srednju vrednost F-skor mere u odnosu na rezultate prijavljene u [3]. Vizuelni primer generisanih granica poljoprivredne parcele je prikazan na slici 4. Ostvareni rezultati su prikazani u tabeli 1.

Predloženo rešenje je sposobno da odredi poljoprivredne granice sa visokom tačnošću i pokazuje sposobnost generalizovanja kroz prepoznavanje poljoprivrednih granica nad više oblasti koje sadrže parcele različitih oblika, veličine i orientacije.

Tabela 1. Ostvareni rezultati modela nad pet oblasti (TS1-5) iz skupa za testiranje

Model	F-skor za TS1	F-skor za TS2	F-skor za TS3	F-skor za TS4	F-skor za TS5	Prosečan F-skor
Masoud i drugi [3]	0.65	0.6	0.63	0.67	0.62	0.63
Naš model	0.68	0.6	0.64	0.68	0.63	0.65



Slika 4. Primer izlaza iz mreže (levo) i slike iz skupa referentnih (engl. ground-truth) podataka

Iako rešenje predstavljeno u ovom radu ostvaruje *state-of-the-art* rezultate prilikom delineacije parcela, postoji nekolicina potencijalno značajnih poboljšanja koji mogu dovesti do povećanja tačnosti i robusnijih rezultata. Jedan od mogućih unapređenja je detekcija nad slikama iz više različitih, vremenski bliskih perioda.

Predikcija nad slikama iz više različitih datuma nam omogućuje da kreiramo konsenzus određivanjem prosečne vrednosti predikcija što ima potencijal da unapredi robusnost sistema. Sa druge strane, kvalitet ulaznih podataka se može unaprediti generisanjem kompozitnih slika na nivou meseca, čime obezbeđujemo uklanjanje oblaka i veću konzistentnost podataka.

5. ZAKLJUČAK

U ovom radu predstavljen je model koji omogućava određivanje granica (tj. delineaciju) poljoprivrednih parcela. U svrhu evaluacije pristupa korišćeni su podaci kreirani od strane autora rada [3]. Arhitektura modela bazirana je na metodama dubokog rezidualnog učenja [7]. Evaluacijom je utvrđeno da model pokazuje sposobnost uspešnog određivanja poljoprivrednih granica i generalizacije nad više oblasti koje sadrže poljoprivredne parcele različitih karakteristika. Konačno, predloženi su koraci koji mogu da omoguće dodatnu robusnost i unaprede performanse predložene arhitekture.

6. LITERATURA

- [1] Rydberg A. And Borgefors G., 2001, Integrated method for boundary delineation of agricultural fields in multispectral satellite images, IEEE Trans. Geosci. Remote Sens., vol. 39, no. 11 (pp. 2514–2520)
- [2] Enemark, S., Bell, K.C., Lemmen, C. and McLaren, R., 2014, Fit-For-Purpose Land Administration, International Federation of Surveyors (FIG): Copenhagen, Denmark

- [3] Masoud, K.M., Persello, C. and Tolpekin, V.A. Delineation of Agricultural Field Boundaries from Sentinel-2 Images Using a Novel Super-Resolution Contour Detector Based on Fully Convolutional Networks. *Remote Sens.* 2020
- [4] Persello C., Tolpekin V.A., Bergado J.R. and de By R.A., 2019, Delineation of agricultural fields in smallholder farms from satellite images using fully convolutional networks and combinatorial grouping, *Remote Sensing of Environment*, Volume 231
- [5] García-Pedrero A., Lillo-Saavedra M., Rodríguez-Esparragón D. and Gonzalo-Martín C., 2019, Deep Learning for Automatic Outlining Agricultural Parcels: Exploiting the Land Parcel Identification System, *IEEE Access*, vol. 7 (pp. 158223-158236)
- [6] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, et al. Imagenet large scale visual recognition challenge. *ArXiv:1409.0575*, 2014
- [7] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V. and He, Kaiming & Zhang, Xiangyu & Ren, Shaoqing & Sun, Jian., 2016, Deep Residual Learning for Image Recognition. 770-778. *10.1109/CVPR.2016.90*.
- [8] Ronneberger O., Fischer P., Brox T., 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*
- [9] Simonyan, K. & Zisserman, A., 2014, Very Deep Convolutional Networks for Large-Scale Image Recognition
- [10] Fisher Y. and Vladlen K., 2016, Multi-Scale Context Aggregation by Dilated Convolutions, *International Conference on Learning Representations (ICLR)*

Kratka biografija:



Đorđe Batić rođen je 1997. godine u Loznicama. Osnovne akademske studije završio je 2020. godine na Fakultetu tehničkih nauka, na kom brani i master rad 2021. godine iz oblasti Elektrotehnike i računarstva – Računarstvo i automatika.
kontakt: djordjebatic@gmail.com