

KLASIFIKACIJA POKROVNOSTI Z UPORABO GLOBOKEGA UČENJA NA ČASOVNIH VRSTAH PODATKOV PLANETSCOPE

dr. Aleš Marsetič, dr. Urša Kanjir

ZRC SAZU, Inštitut za antropološke in prostorske študije

ales.marsetic@zrc-sazu.si, ORCID: <https://orcid.org/0000-0002-3307-508X>

ursa.kanjir@zrc-sazu.si, ORCID: <https://orcid.org/0000-0003-1332-5624>

DOI: https://doi.org/10.3986/9789610506683_25

UDK: 528.8:711.14(497.4)

IZVLEČEK

Klasifikacija pokrovnosti z uporabo globokega učenja na časovnih vrstah podatkov PlanetScope

Semantična segmentacija je postala v daljinskem zaznavanju ena ključnih metod za klasifikacijo pokrovnosti. V zadnjem obdobju se za klasifikacijo uporabljajo predvsem tehnike globokega učenja, ki temeljijo na velikemu naboru kakovostnih učnih vzorcev. Prispevek opisuje uporabo konvolucijske nevronske mreže arhitekture U-Net za učenje klasifikacijskega modela s časovno vrsto visokoločljivih satelitskih posnetkov PlanetScope. Iz vhodnih podatkov smo izdelali več modelov, najboljšega pa smo uporabili za klasifikacijo posnetkov na testnem območju. Doseženi rezultati kažejo na zanesljivost uporabljenega postopka za doseganje kakovostnih rezultatov tudi brez uporabe prenosa znanja.

KLJUČNE BESEDE

daljinsko zaznavanje, časovne vrste, globoko učenje, U-Net, satelitski posnetki, PlanetScope, semantična segmentacija

ABSTRACT

Land cover classification using deep learning on PlanetScope time series data

Semantic segmentation has become one of the key methods in remote sensing for land cover classification. Recently, deep learning techniques based on large sets of high quality training samples have been increasingly used for classification. This paper describes the application of a convolutional neural network of the U-Net architecture to learn a classification model using a time series of high-resolution PlanetScope satellite images. Several models were created from the input data, and the best one was used to classify the images from the test area. The results obtained show the reliability of the method used, which can be used to obtain good results even without the use of transfer learning.

KEY WORDS

remote sensing, time series, deep learning, U-Net, satellite images, PlanetScope, semantic segmentation

1 Uvod

Zaznavanje pokrovnosti oziroma njenih sprememb skozi čas je še vedno zelo pogosto predmet študij v daljinskem zaznavanju, saj pomaga razumeti krajinsko dinamiko. Z razvojem računalniške tehnologije in dostopom velikega nabora satelitskih posnetkov so se tehnike obdelave podatkov za določanje pokrovnosti korenito spremenile. V zadnjih letih se najbolj uveljavljajo različni pristopi strojnega učenja s poudarkom na globokem učenju. Globoko učenje temelji, v primerjavi s tradicionalnimi metodami klasifikacij, izrazito na vhodnih podatkih (Li s sodelavci 2021). Iz njih lahko s tem pristopom izluščimo več značilnosti kot s tradicionalnimi metodami, s čimer dobimo boljše rezultate klasifikacije (Szegedy s sodelavci 2016). Eden od pristopov globokega učenja v računalništvu so konvolucijske nevronske mreže (angleško *convolutional neural networks*). Čeprav se konvolucijske mreže uporabljajo že dolgo časa (LeCun s sodelavci 1989), je bil njihov uspeh zaradi zahtevnosti procesiranja in pomanjkanja učnih vzorcev (angleško *training sets*) omejen. Šele z obstojem prvih nizov večjih učnih vzorcev je uporaba nevronskih mrež doživela širšo praktično uporabo (Krizhevsky, Sutskever in Hinton 2012).

Najpogosteje se konvolucijske nevronske mreže uporabljajo za semantično segmentacijo podatkov. Semantična segmentacija je analiza posnetkov na ravni slikovnega elementa oziroma piksla in jo zato imenujemo tudi pikselska klasifikacija. S semantično segmentacijo vsem pikslom določenega posnetka oziroma slike določimo razred (oznako). S tem procesom pridobimo segmentiran posnetek, ki ga lahko kasneje še dodatno klasificiramo v podrazrede. V preteklosti je bilo opravljenih že precej raziskav na področju semantične segmentacije za potrebe klasifikacije pokrovnosti (Henry s sodelavci 2019; Tong s sodelavci 2020; Li s sodelavci 2022). Semantična segmentacija zahteva veliko število učnih vzorcev visoke kakovosti, kar zna v določenih primerih, kjer smo s terenskimi podatki omejeni, biti tudi njena omejitev.

Poznamo več vrst konvolucijskih nevronskih mrež, ki se ukvarjajo s semantično segmentacijo. Med njimi so najbolj pogoste nevronske mreže arhitekture kodirnik-dekodirnik ter nevronske mreže, ki uporabljajo razširjeno konvolucijo (angleško *dilated convolution*). Slednje so računsko bolj zahtevne. Nevronske mreže kodirnik-dekodirnik pa dosegajo rezultate, primerljive s slednjimi, z uporabo kodirnika (klasifikacijske mreže) in dekodirnika, ki po končanem kodiranju ponovno vzpostavi prvotno ločljivost in slikovnim elementom napove končni razred. V to skupino spadajo arhitekture kot so FCN (Long, Shelhamer in Darrell 2015), SegNet (Badrinarayanan, Kendall in Cipolla 2017) in U-Net (Ronneberger, Fischer in Brox 2015). U-Net smo uporabili tudi v naši raziskavi.

Kodirni del nevronske mreže, ki ga imenujemo tudi ogrodje (angleško *backbone*), je običajno globoka konvolucijska nevronska mreža, ki je sestavljena iz več stopenj konvolucijskih operacij, ki jih ločujejo operacije združevanja. To omogoča kodirniku, da zajame pomembne maske značilk (angleško *feature map*) v različnih merilih. Običajno se za ogrodje uporablja že obstoječe klasifikacijske mreže, kot so ResNet-50 (He s sodelavci 2016), VGG16 (Simonyan in Zisserman 2015), MobileNet (Howard s sodelavci 2017), ki so bile naučene na obsežnih podatkovnih bazah. Dekoderji so zadolženi za izdelavo rezultatov, ki so enake velikosti kot vhodni podatki. Dekonvolucije (angleško *deconvolutions*) (Noh, Hong in Han 2015) se v semantični segmentaciji uporabljajo za ostrenje podatkov v prvotno (izvorno) ločljivost.

Konvolucijske nevronske mreže se uporabljajo tudi v drugih aplikacijah daljinskega zaznavanja. V Sloveniji so raziskovalci uporabili globoko učenje na primer za segmentacijo in klasifikacijo cestišča (Smole 2019), izdelavo visokoločljivega sintetičnega ortofota iz posnetkov Sentinel-2 (Mangafić in Žagar 2020) in za zaznavanje stavb (Šanca s sodelavci 2021).

V tem prispevku smo za pridobitev razredov pokrovnosti s semantično segmentacijo satelitskih posnetkov uporabili nevronske mreže arhitekture U-Net. Nevronsko mrežo smo učili na časovni vrsti posnetkov PlanetScope na območju doline reke Rižane ter njeno uporabnost kasneje preizkusili na testnem območju v okolici mesta Velenje. Pri učenju smo uporabili učne vzorce rabe tal, pridobljene iz evidence dejanske rabe kmetijskih in gozdnih zemljišč (MKGP 2022). Raziskava ugotavlja primernost vhodnih podatkov in metode učenja za semantično segmentacijo satelitskih posnetkov visoke ločljivosti.

2 Študijska območja in podatki

V študiji smo uporabili prosto dostopne optične satelitske posnetke PlanetScope, ki zagotavljajo visoko prostorsko in časovno ločljivost. Podjetje Planet Labs zaradi številčnosti njihovih satelitov v nizki zemljini orbiti omogoča skoraj dnevno opazovanje Zemlje. Posnetki, ki jih ponujajo njihovi sateliti *Dove*, zajemajo štiri spektralne kanale (R, G, B in NIR), njihova prostorska ločljivost je 3 m.

Učno območje v raziskavi je bila dolina reke Rižane z obalo in mestom Koper (velikost območja okoli 16 km × 6 km), razvit model pa smo kasneje uporabili in testirali na območju Šaleške doline in mesta Velenje (območje veliko 15 km × 10 km). Za območje Kopra smo od aprila leta 2017 do avgusta 2021 pridobili po en brezoblačen posnetek na mesec (skupaj 53 visokoločljivih posnetkov). Na območju Velenja, kjer smo razvit model globokega učenja testirali, smo uporabili tri različne sezonske posnetke iz leta 2020 – januarskega, aprilskega in julijskega. Leto 2020 namreč sovпада z izdelavo uporabljenih referenčnih oziroma učnih podatkov, kar je pomembno pri ovrednotenju končnih rezultatov.

Terenski oziroma referenčni podatki, ki smo jih uporabljali za učenje in testiranje rezultatov raziskave, so pridobljeni iz podatkovnega sloja dejanske rabe tal. To so podatki evidence dejanske rabe kmetijskih in gozdnih zemljišč, ki jo upravlja in vodi Ministrstvo za kmetijstvo, gozdarstvo in prehrano (MKGP) Republike Slovenije (MKGP 2022). Terenske podatke smo glede na njihovo najbližjo podobnost združili v pet splošnih in številčno najpogostejših razredov pokrovnosti oziroma rabe tal: njiva, travnik, gozd, urbano in voda. Razred njive predstavljajo vse kmetijske površine, razred travnik pa predstavlja vse zelene površine, ki ne spadajo pod gozd ali kmetijske površine. Netipično rabo tal (na primer močvirje, rastlinjaki) in poligone rabe tal manjše od 500 m² smo odstranili iz nabora učnih vzorcev. Kasneje smo dodali tudi razred neklasificirano, kamor je model pri klasifikaciji uvrstil vse tiste slikovne elemente, ki ne ustrezajo nobenemu od naštetih petih razredov.

Območje učenja smo določili glede na razmerje pokritosti z izbranimi razredi pokrovnosti. Pazili smo, da je območje imelo približno enak odstotek iz vsakega posameznega razreda. Razen razreda njiva, ki je imel na izbranem učnem posnetku le 5,5 % delež, so bili ostali razredi relativno enakomerno zastopani (preglednica 1). Vse satelitske posnetke v časovni vrsti smo obrezali na izbrano območje, tako, da so na koncu imeli vsi velikost 5564 × 2148 slikovnih elementov.

Prilagojen vektorski sloj rabe tal (učne vzorce) smo pred uvrstitvijo v model rastrirali na ločljivost slikovnega elementa 3 m × 3 m in ga obrezali na območje posnetkov. Tako pripravljen sloj je predstavljal masko s petimi razredi pokrovnosti in enim neopredeljenim razredom.

3 Metode dela

Za postopek semantične segmentacije smo izdelali program v programskem jeziku Python, ki za globoko učenje uporablja knjižnici *Keras* in *TensorFlow*. Pred vstopom v učenje vhodne podatke najprej razdelimo na majhne slike velikosti 256 × 256 slikovnih elementov, kar omogoča gladko učenje

Preglednica 1: Odstotek posameznega razreda na učnem območju.

razred	delež [%]
njiva	5,5
travnik	22,6
gozd	28,4
urbano	21,2
voda	22,3

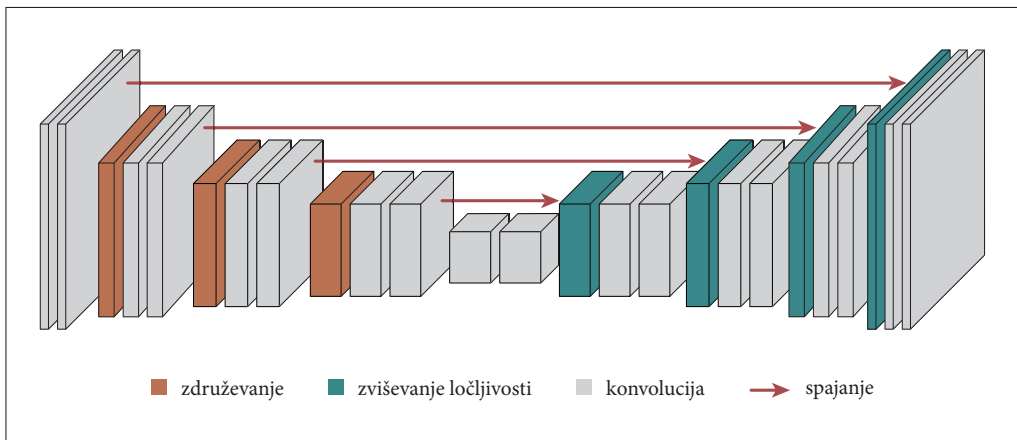
modela na podatkih. Vsi posnetki uporabljajo isto masko referenčnih podatkov, kar lahko povzroča napake pri učenju, posebno na objektih, ki se skozi sezono ali med posameznimi leti precej spreminijo (na primer kmetijske površine). Slike, ki imajo prisotnih več kot 10 % neoznačenih slikovnih elementov oziroma manj kot 90 % veljavnih referenčnih podatkov, odstranimo iz učnega vzorca. Po opisani predpripravi podatkov nam je v podatkovnem nizu ostalo 6032 uporabnih slik. Te smo naključno razdelili v razmerju 4:1, pri čemer smo 80 % slik uporabili za učenje, 20 % pa za testiranje pravilnosti pridobljenih rezultatov.

Kot že omenjeno, smo v študiji uporabili nevronske mreže arhitekture U-Net, ki za osnovo uporablja standardno arhitekturo kodirnik-dekodirnik. Te arhitekture so sestavljene iz osnovnih konvolucijskih nivojev in nivojev združevanja (angleško *pooling layer*), s katerimi zmanjšamo število učnih parametrov. Posebnost mreže U-net je spajanje (angleško *concatenation*) mask značilk iz drugega dela mreže (dekodirnik) s tistimi, ki so bile naučene v prvem delu (kodirnik). Združevanje konvolucijskih nivojev iste ločljivosti se zgodi po nivoju zviševanja ločljivosti. Arhitektura uporabljene mreže U-net je prikazana na sliki 1.

Za aktivacijsko funkcijo, ki uteženo vsoto nevronov preslika v izhodne neurone, smo izbrali pogosto uporabljeno nelinearno funkcijo ReLU (angleško *Rectified Linear Unit*) (Yu s sodelavci 2020). Za določanje uspešnosti učenja smo definirali funkcijo izgube (angleško *loss function*), ki je bila sestavljena iz kombinacije kockaste (angleško *dice*) in žariščne (angleško *focal*) izgube. Kombinacija deluje bolje v primerih, ko odstotek razredov v učnem območju ni uravnotežen (Jadon 2020). Funkcija izgube primerja napoved z učnimi podatki, s čimer lahko ocenimo uspešnost učenja. V procesu učenja pa iščemo takšne parametre nevronske mreže, ki zagotavljajo najmanjšo povprečno vrednost funkcije izgube za vse učne primere. Da to dosežemo, uporabljamo iterativne optimizacijske algoritme. V našem primeru smo uporabili metodo Adam (angleško *Adaptive Moment Estimation*), ki je trenutno eden najpogostejše uporabljenih optimizacijskih algoritmov v globokem učenju (Soydancer 2020).

Izdelana nevronska mreža ne uporablja predhodno naučenih modelov oziroma ne deluje na podlagi prenosa znanja (angleško *transfer learning*), ampak so začetni parametri modela izbrani naključno. Učenje nevronske mreže poteka v naslednjih korakih (glej sliko 2):

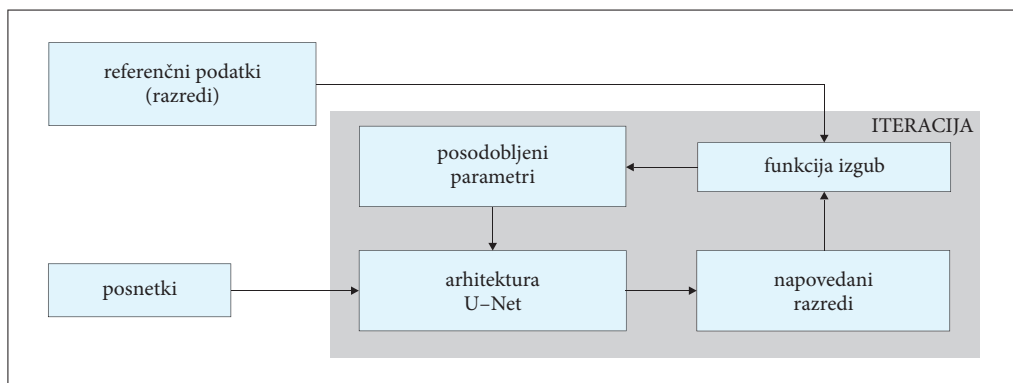
- v mrežo se vstavi vhodne slike in referenčne podatke (učne vzorce) iz česar se izračuna napoved,
- s primerjanjem napovedi in referenčnih podatkov se preko funkcije izgub izračunajo odstopanja,
- z dobljenimi rezultati se izračunajo gradienti aktivacijskih funkcij,
- z uporabo gradientov se posodobijo parametri nevronske mreže.



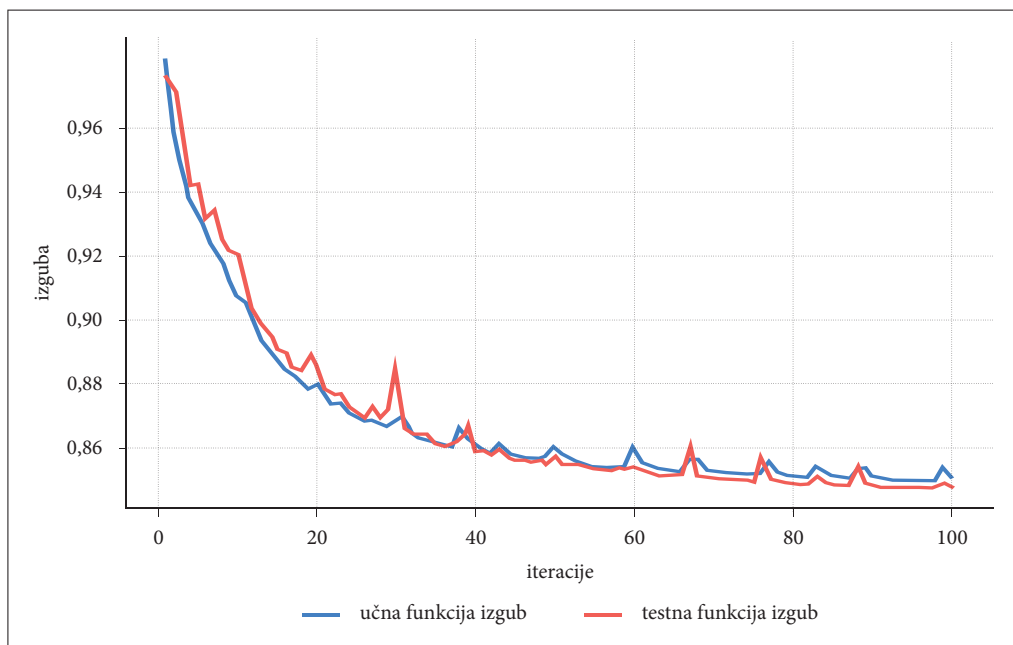
Slika 1: Arhitektura nevronske mreže U-net. Sivi kvadri predstavljajo nivoje konvolucije, oranžni zniževanje, turkizni pa zviševanje ločljivosti. Rdeče puščice kažejo smeri nivojev združevanja oziroma spajanja.

Postopek se ponavlja dokler model ne doseže določenega največjega števila iteracij ali dokler rezultat (funkcija izgub na testnem nizu) ne konvergira. V našem primeru smo izvedli 100 iteracij; njihovo število smo določili empirično. Funkciji za učni in testni niz se obnašata podobno in dosežeta relativno stabilno vrednost že okrog 60. iteracije (slika 3).

Za potrebe testiranja uspešnosti učenja na različnih podatkovnih nizih smo naučili 3 modele, vsakega z različno dolžino trajanja časovne serije. Prvi model je kot vhodne podatke upošteval celotno časovno serijo mesečnih posnetkov od aprila 2017 do avgusta 2021 (53 posnetkov), drugi le posnetke za leti 2018 in 2019, tretji pa samo tiste iz leta 2019.



Slika 2: Shema poteka učenja nevronske mreže. Postopek prehoda celotne podatkovne zbirke čez nevronske mreže se iterativno ponavlja.



Slika 3: Primer funkcij izgube za učni in testni niz, ki smo ju dobili pri učenju nevronske mreže v trajanju 100 iteracij.

4 Rezultati

Ovrednotenje uspešnosti modelov smo naredili z izračunom evalvacijskih metrik in ovrednotenjem matrik zamenjav (angleško *confusion matrix*). Razvit model smo najprej ovrednotili tako na učnem območju (območje Kopro) kot tudi na testnem območju (območje Velenja). Na območju za učenje smo za kontrolo izbrali posnetek PlanetScope iz julija 2020, na testnem območju pa smo izbrali tri posnetke, iz januarja, aprila in julija leta 2020. Uspešnost klasifikacije smo preverili na podlagi podatkov rabe tal MKGP.

Uspešnost napovedi lahko pri klasifikaciji, kjer zaznavamo več razredov, predstavimo z matriko zamenjav. Ta nam prikaže število pravilno pozitivnih (angleško *true positive*, *TP*), pravilno negativnih (angleško *true negative*, *TN*), napačno pozitivnih (angleško *false positive*, *FP*) in napačno negativnih (angleško *false negative*, *FN*) napovedi. Vrednosti v matriki zamenjav smo uporabili za izračun sledečih evalvacijskih metrik. Klasifikacijska točnost predstavlja delež pravilno napovedanih primerov:

$$\text{točnost} = \frac{TP + TN}{TP + TN + FP + FN}$$

Preciznost predstavlja razmerje med pravilno pozitivnimi napovedmi in vsemi pozitivnimi napovedmi:

$$\text{preciznost} = \frac{TP}{TP + FP}$$

Priklic predstavlja pozitivne primere, ki so bili pravilno napovedani kot pravilni:

$$\text{priklic} = \frac{TP}{TP + FN}$$

Mera *F1* pa predstavlja harmonično povprečje priklica in preciznosti:

$$F1 = \frac{2 \cdot \text{preciznost} \cdot \text{priklic}}{\text{preciznost} + \text{priklic}}$$

Rezultati evalvacije so predstavljeni v preglednicah 2, 3 in 4. Preglednica 2 prikazuje evalvacijske metrike za posnetek PlanetScope iz julija 2020, ki je bil posnet na učnem območju. Posnetek smo klasificirali z modelom, ki smo ga učili na celotni časovni vrsti. Pričakovano so vrednosti zelo visoke, posebno pri klasifikaciji razredov gozda in vode.

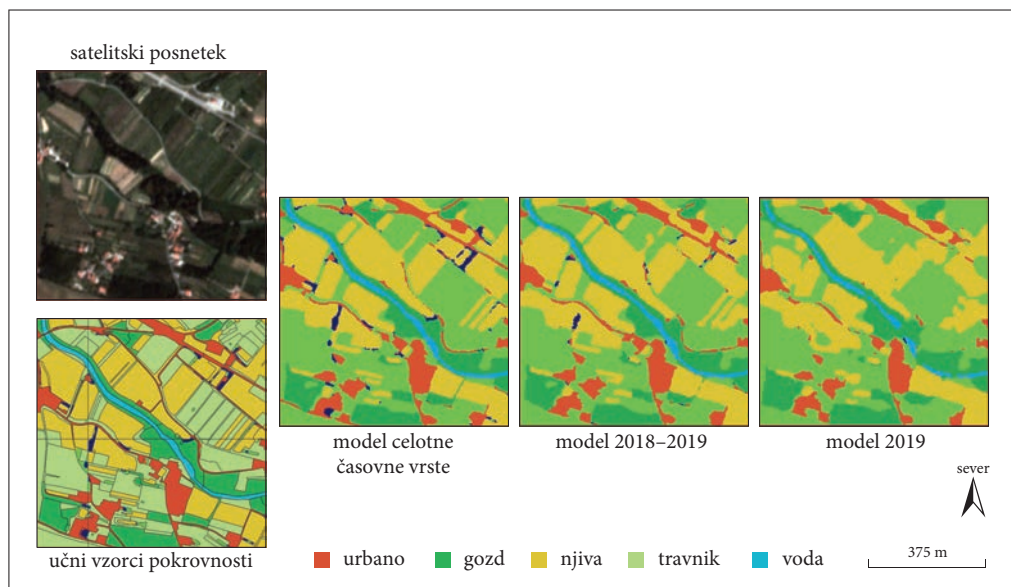
Slika 4 prikazuje klasifikacijo posnetka okolice mesta Koper z modeli, ki smo jih učili na različnih časovnih vrstah. Izboljšava modela z uporabo več učnih primerov se najbolj vidi pri sami klasifikaciji in natančnosti obrisov. Pri klasifikaciji z modelom 2019 se več objektov združi v enega, veliko objektov pa sploh ni zaznanih. Modela s celotno časovno vrsto in model 2018–2019 sta si zelo podobna, pri prvem pa so obrisi vendarle bolj podobni maski učnih vzorcev.

Preglednica 2: Evalvacija posnetka PlanetScope iz julija 2020 na učnem območju (mesto Koper z okolico).

razred	točnost	preciznost	priklic	F1
njiva	0,9012	0,9532	0,9429	0,9480
travnik	0,8802	0,9251	0,9477	0,9363
gozd	0,9294	0,9494	0,9778	0,9634
urbano	0,8966	0,9647	0,9270	0,9455
voda	0,9735	0,9982	0,9752	0,9866

Uspešnost modela, ki je za učenje uporabljal celotno časovno vrsto, smo preizkusili na treh posnetkih PlanetScope v letu 2020 (januar, april in julij) na območju Velenja (preglednica 3). Najboljše rezultate smo dobili julija, ko je na posnetku najmanj senc in je večina vegetacije na višku ozelenelosti. Najbolj homogeni razredi (gozd, travniki) so imeli tudi najboljšo kombinirano natančnost *F1*. Najslabše rezultate dobimo januarja, ko so na posnetku dolge sence in slabše svetlobne razmere. Večino večjih senc je model klasificiral v vodo, kar je vidno na nizki vrednosti preciznosti. V vseh primerih pa smo dobili zelo slabe rezultate za razred njiva. Razlog za tako slabe vrednosti metrik je v manjšem številu učnih vzorcev za ta razred in v veliki variabilnosti razreda skozi leto. Malenkost boljši rezultati so januarja, ko so njive načeloma brez pridelkov oziroma gole. Kljub uporabi ene same maske učnih vzorcev za vse posnetke so rezultati klasifikacij relativno dobri.

Različni rezultati klasifikacije pokrovnosti za testirane posnetke (Velenje in okolica) so vidni na sliki 5. Naučen model smo testirali na posnetkih, zajetih v treh različnih časovnih obdobjih. Glede na sezono zajema posnetka, so rezultati klasifikacije različni in večinoma odražajo stanje vegetacije.



Slika 4: Primeri klasifikacije pokrovnosti z različnimi modeli.

Preglednica 3: Evalvacija posnetkov PlanetScope iz testnega območja (mesto Velenje z okolico) za vse tri izbrane posnetke, zajete v različnih mesecih v letu 2020.

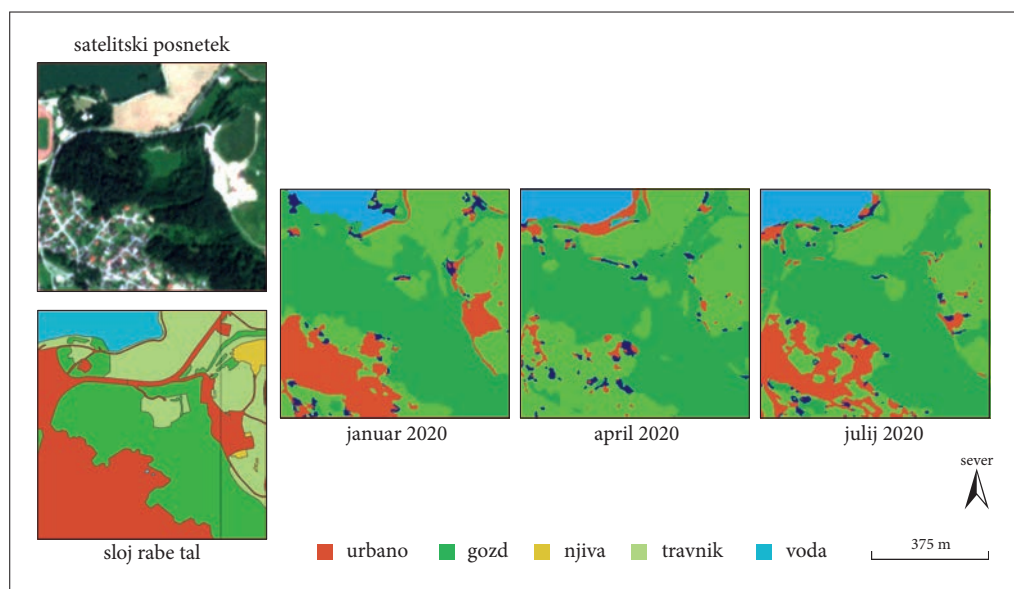
razred	januar 2020			april 2020			julij 2020		
	preciznost	priklic	F1	preciznost	priklic	F1	preciznost	priklic	F1
njiva	0,2996	0,0221	0,0411	0,2205	0,0176	0,0327	0,1977	0,0117	0,0221
travnik	0,6581	0,5468	0,5973	0,6960	0,6788	0,6873	0,7331	0,7056	0,7191
gozd	0,7744	0,8839	0,8255	0,8264	0,9496	0,8837	0,8421	0,9641	0,8990
urbano	0,6373	0,4516	0,5286	0,7316	0,4881	0,5855	0,7682	0,5648	0,6510
voda	0,2206	0,6811	0,3332	0,9094	0,6929	0,7865	0,8734	0,7226	0,7909

Klasifikacije bolje orišejo obrise nekaterih objektov kot sloj rabe tal MKGP, katerega smo uporabili pri analizi točnosti. Posebno pri juljski klasifikaciji je urbano območje bolje segmentirano, saj so na območju prisotni tudi travniki in gozd. Poleg tega se ponekod na sliki vidi tudi slaba točnost določenih objektov, posebno obdelovalnih površin oziroma njiv.

Na koncu smo izračunali še skupno točnost za vse razrede. Izračunamo jo kot razmerje med pravnimi primeri in vsemi primeri oziroma napovedmi:

$$\text{skupna točnost} = \frac{\text{pravilni primeri}}{\text{število vseh primerov}}$$

Rezultati analiz posnetkov v okolici mest Koper in Velenje so prikazani v preglednici 4. Rezultati na učnem območju, ko uporabimo manjše število vhodnih podatkov, so pričakovano slabši. Presenetni pa le manjši upad točnosti (za približno 4 %), če za učenje uporabimo časovno vrsto v trajanju le enega



Slika 5: Detajl območja mesta Velenje in izračunani rezultati klasifikacije pokrovnosti na treh testnih posnetkih PlanetScope.

Preglednica 4: Skupna točnost analiz na posnetkih PlanetScope. Vse tri modele smo ocenili samo na posnetku Kopra, za območje Velenja pa smo izbrali model celotne časovne vrste.

posnetek	skupna točnost [%]
Koper julij 2020 – model celotne časovne vrste	95,77
Koper julij 2020 – model 2018 - 2019	93,69
Koper julij 2020 – model 2019	91,64
Velenje julij 2020	80,55
Velenje april 2020	78,27
Velenje januar 2020	70,44

leta. Za posnetke Velenja smo dobili okoli 80 % točnost, razen za januarski posnetek, kjer je bila točnost klasifikacije okoli 70 %. Ta rezultat je posledica slabe klasifikacije njiv in vode ter nekoliko slabše klasifikacije gozda in travnikov, ki sta prevladujoča tipa pokrovnosti na tem območju.

5 Sklep

V prispevku smo opisali uporabo postopka semantične segmentacije satelitskih posnetkov visoke ločljivosti. Za učenje smo uporabili časovno vrsto posnetkov PlanetScope in podatke o rabi tal MKGP, ki smo jih vstavili v nevronska mrežo arhitekture U-Net. Kljub temu, da nevronska mreža ni uporabila prenosa znanja oziroma predučenih uteži, so rezultati hitro konvergirali. Testirali smo tri različne modele, ki so služili za klasifikacijo testnih posnetkov iz treh različnih časovnih obdobij. Na testnih posnetkih smo dosegli točnost okoli 80 %, razen za zimski posnetek, kjer je bila točnost okoli 70 %. Slabši rezultati klasifikacije so predvsem posledica neuskkljenih razredov med učnimi oziroma referenčnimi podatki (raba tal MKGP) in dejansko situacijo pokrovnosti na satelitskih posnetkih v času zajema. Sloj rabe tal je pogosto posplošen (na primer urbane površine). Obenem je tudi na satelitskih posnetkih težko določiti nekatere razrede. Na primer njive so zaradi ozelenosti poljščin v določenem časovnem obdobju identične razredu travnik, zato so posledično napake pri klasificiranju tega razreda glede na fenološki razvoj pričakovane. Prav tako so za uspešnost zaznave pomembni deleži učnih vzorcev. Tisti razredi, ki so večinsko zastopani, so ponavadi vedno boljše klasificirani, saj so tudi njihovi učni vzorci pogostejši.

Dobljeni rezultati klasifikacije potrjujejo, da je postopek lahko uspešen in pogojno primeren za klasifikacijo pokrovnosti v osnovne razrede. Uspešnost bi lahko povečali z uporabo daljše časovne vrste ter z uporabo natančnejšega sloja učnih vzorcev, posebno za razred obdelovalnih kmetijskih površin.

Za izboljšanje uspešnosti klasifikacije je na voljo še več možnosti. Poleg izboljšanja učnih vzorcev, razširitev območij učenja in izdelave mask za vsak posnetek posebej, bi lahko učenje prilagodili letnemu času. Prilagojen model bi nato uporabili za klasifikacijo posnetkov iz obdobja, na katerem smo model učili. Klasifikacijo bi lahko izboljšali tudi z uporabo naprednejših arhitektur nevronske mreže ali njihovih kombinacij, ki bi bile prilagojene prav za določeno nalogo (na primer Li s sodelavci 2022).

ZAHVALA: Raziskava je bila opravljena v okviru projekta J2-9251, J6-9395 in programa P6-0079, ki jih financira Javna agencija za raziskovalno dejavnost Republike Slovenije.

6 Viri in literatura

- Badrinarayanan, V., Kendall, A., Cipolla, R. 2017: SegNet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39. DOI: <https://doi.org/10.1109/TPAMI.2016.2644615>
- He, K., Zhang, X., Ren, S., Sun, J. 2016: Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway. DOI: <https://doi.org/10.1109/CVPR.2016.90>
- Henry, C. J., Storie, C. D., Palaniappan, M., Alhassan, V., Swamy, M., Aleshinloye, D., Curtis, A., Kim, D., 2019: Automated LULC map production using deep neural networks. *International Journal of Remote Sensing* 40. DOI: <https://doi.org/10.1080/01431161.2018.1563840>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H., 2017: MobileNets: Efficient convolutional neural networks for mobile vision applications. arXiv:1704.04861 [cs]. DOI: <https://doi.org/10.48550/arXiv.1704.04861>

- Jadon, S. 2020: A survey of loss functions for semantic segmentation. 2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB). Piscataway. DOI: <https://doi.org/10.1109/CIBCB48159.2020.9277638>
- Krizhevsky, A., Sutskever, I., Hinton, G. E., 2012: ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*. Red Hook.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., Jackel, L. D. 1989: Backpropagation applied to handwritten zip code recognition. *Neural Computation 1*. DOI: <https://doi.org/10.1162/neco.1989.1.4.541>
- Li, H., Li, Y., Zhang, G., Liu, R., Huang, H., Zhu, Q., Tao, C. 2021: Remote sensing images semantic segmentation with general remote sensing vision model via a self-supervised contrastive learning method. arXiv:2106.10605v1 [cs.CV]. DOI: <https://doi.org/10.48550/arXiv.2106.10605>
- Li, X., Li, T., Chen, Z., Zhang, K., Xia, R. 2022. Attentively learning edge distributions for semantic segmentation of remote sensing imagery. *Remote Sensing 14*-1. <https://doi.org/10.3390/rs14010102>
- Long, J., Shelhamer, E., Darrell, T., 2015. Fully convolutional networks for semantic segmentation. arXiv:1411.4038 [cs]. DOI: <https://doi.org/10.48550/arXiv.1411.4038>
- Mangafič, A., Žagar, T. 2020: Izdelava visokoločljivega sintetičnega ortofota na osnovi posnetkov Sentinel-2 z uporabo super-ločljivostnih generativnih nasprotniških mrež. *Modeliranje pokrajine, GIS v Sloveniji 15*. Ljubljana. DOI: https://doi.org/10.3986/9789610504696_07
- MKGP – Portal, 2022. Medmrežje: <https://rkg.gov.si/vstop/> (25. 2. 2022).
- Noh, H., Hong, S., Han, B. 2015: Learning deconvolution network for semantic segmentation. arXiv:1505.04366 [cs]. DOI: <https://doi.org/10.48550/arXiv.1505.04366>
- Ronneberger, O., Fischer, P., Brox, T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv:1505.04597 [cs]. DOI: <https://doi.org/10.48550/arXiv.1505.04597>
- Šanca, S., Oštir, K., Mangafič, A. 2021: Zaznavanje stavb z uporabo nevronske mreže, učenih s prenosom znanja. *Geodetski vestnik 65*. <https://doi.org/10.15292/geodetski-vestnik.2021.04.559-593>
- Simonyan, K., Zisserman, A. 2015: Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556 [cs]. DOI: <https://doi.org/10.48550/arXiv.1505.04597>
- Smole, T. 2019: Globoko učenje za segmentacijo in klasifikacijo cestišča. Magistrsko delo, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko. Ljubljana.
- Soydaner, D. 2020: A comparison of optimization algorithms for deep learning. *International Journal of Pattern Recognition and Artificial Intelligence 34*. DOI: <https://doi.org/10.1142/S0218001420520138>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016: Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Piscataway. DOI: <https://doi.org/10.1109/CVPR.2016.308>
- Tong, X.-Y., Xia, G.-S., Lu, Q., Shen, H., Li, S., You, S., Zhang, L. 2020: Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment 237*. <https://doi.org/10.1016/j.rse.2019.111322>
- Yu, Y., Adu, K., Tashi, N., Anokye, P., Wang, X., Ayidzoe, M.A., 2020. RMAF: Relu-Memristor-Like Activation Function for deep learning. *IEEE Access 8*. DOI: <https://doi.org/10.1109/ACCESS.2020.2987829>