

# Zaznavanje terasiranih pokrajin kot semantična segmentacija digitalnega modela višin

Anže Glušič\*, Rok Ciglič<sup>+</sup> in Luka Čehovin Zajc\*

\* Univerza v Ljubljani, Fakulteta za računalništvo in informatiko

<sup>+</sup> Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Geografski inštitut Antona Melika

E-pošta: anze.glusic@gmail.com, rok.ciglic@zrc-sazu.si, luka.cehovin@fri.uni-lj.si

## Abstract

We present our preliminary study on applying a semantic segmentation model to the problem of detecting terraced landscapes from LIDAR data. The study is conducted on south-west region of Slovenia, we are using digital elevation model and reference annotations that were manually identified by experts. These annotations are incomplete and the main question of our study is if they can still be used to bootstrap our predictive model. We provide details about data pre-processing and training setup. Our results show that the model can help identify terraces even using noisy training data, providing further opportunities for weakly supervised and interactive training scenarios.

## 1 Uvod

Globoki modeli konvolucijskih nevronske mreže nam omogočajo, da v slikovnih podatkih odkrivamo kompleksne vzorce. Taki modeli se lahko uspešno uporabijo v nalogah, ki bi drugače zahtevale veliko zamudnega ročnega dela in bile podvržene pristranskosti in spremenljivi pozornosti. Primer take naloge je pregledovanje podatkov daljinskega zaznavanja površja. V naši študiji smo se osredotočili na digitalni model višin, pridobljen s tehnologijo LIDAR, na katerem hočemo naučiti globoki model, ki bo določil področja terasiranih pokrajin, bolj natančno se osredotočamo na kulturne terase.

Kulturne terase so zgradili zaradi lažjega kmetovanja, zmanjšane erozije prsti in uravnavanja količine vode [1, 2]. Na seznam svetovne kulturne dediščine je uvrščenih že nekaj terasiranih pokrajin [3, 4]. Kulturne terase pa ponekod izginjajo zaradi zaraščanja ali neustrezne obdelave. Leta 2010 je bila na globalni ravni sprejeta Honghejska deklaracija<sup>1</sup>. Teraso so tudi v Sloveniji že prepoznane kot dragocen element pri ohranjanju pokrajine<sup>2</sup>, a zaenkrat Slovenija še nima povsem ustreznega kriterija za identifikacijo teras ter sistema upravljanja [5].

Teraso sestavljata ravna ali rahlo nagnjena, različno široka terasna ploskev, namenjena obdelavi, in bolj strma, različno visoka terasna brežina. Bolj je pobočje strmo,

<sup>1</sup>Deklaracija je bila sprejeta z namenom, da opozori na pomen kmetijskih (kulturnih) teras ter pripomore k zaščiti in razvoju terasiranih območij po celem svetu.

<sup>2</sup>Uredba o navzkrižni skladnosti, Uradni list RS 97/2015.




Slika 1: Primer terasirane pokrajine v Goriških Brdih (fotografija: Matjaž Lenarčič) ter njenega digitalnega modela višin, prikazanega kot senčen relief. Na modelu višin so terase dobro vidne kot črtast vzorec.

ožje so terasne ploskve [6, 5]. Pretekle raziskave so pokazale na raznolikost kulturnih teras in njihov pomen za prebivalstvo, niso pa uspeli izpeljati natančnih postopkov za njihovo objektivno samodejno prepoznavanje. Danes je to, zaradi novih podatkovnih virov in razvoja metod strojnega učenja bolj izvedljivo, kot pred nekaj leti. V članku predstavljamo trenutne rezultate razvoja globalnega modela za zaznavanje terasiranih pokrajin na osnovi digitalnega modela višin. Pričakujemo, da bo napovedni model pripomogel k izboljšani metodologiji prepoznavanja kulturnih teras. Detajlna določitev teras bi izboljšala razumevanje in vrednotenje njihovih okoljskih, socialnih in ekonomskih pomenov [7]. Evidenca teras je pomemben temelj vseh nadaljnjih raziskav in izvajanja uradnih postopkov ter ima tudi širši pomen (npr. za ohranjanje kulturne pokrajine, prehransko varnost).

## 2 Sorodna dela

Ker so digitalni modeli višin za večja območja dokaj novi, njihov zajem pa drag, so prve metode za samodejno prepoznavanje terasiranih pokrajin delovale na analizi bolj dostopnih satelitskih slik [8, 9]. Metode delujejo na slikovnih preslikavah in analizi signala [8] ter osnovnih konceptih strojnega učenja [9]. Za območja, kjer je na voljo digitalni model višin, prinese njegova uporaba prednosti, saj je mogoče dobre rezultate dobiti z relativno preprostimi ekspertnimi sistemi izpeljanimi iz analize površja [7, 10, 11]. Dodatno informacijo je mogoče dobiti s kombinacijo večih virov (višine, ortofoto, sloj rabe tal) [12].

Po našem vedenju globoko učenje v kontekstu detek-



Slika 2: Prikaz obravnavanega območja v obliki digitalnega modela reliefa, na katerem so območja, ki so v referenčnih podatkih označena kot terase, prikazana z rdečo barvo. S turkizno barvo je prikazana meja Slovenije.

cije terasiranih pokrajin še ni bilo uporabljeno, še posebej ne na digitalnem modelu višin. Kot najbolj sorodno delo bi tako opredelili nedavno uporabo globokega učenja za prepoznavanje vrtač v Sloveniji [13], ki so sicer ena izmed bolj pogosto analiziranih reliefnih oblik.

### 3 Podatki

V letih 2011, 2014 in 2015 se je z laserskim skeniranjem posnela celotna Slovenija, pripravljene so bili sloji višin reliefa in površja v obliki oblaka točk ter kot rastrski digitalni model višin v ločljivosti 1m [14], ki ga bomo uporabili kot vhodni podatek v naš model<sup>3</sup>. Kot referenco za učenje in vrednotenje smo uporabili podatke, pridobljene v okviru projekta *Terasirane pokrajine v Sloveniji kot kulturna vrednota* [5, 15, 16]. V okviru projekta se je v obdobju 2011 do 2014 z ročno analizo letalskih posnetkov (ortofoto) zabeležilo kulturne terase za območje celotne Slovenije. V okviru naše analize smo se osredotočili na jugozahodni del Slovenije, ki vsebuje največ terasiranih pokrajin. Obravnavano območje je prikazano na Sliki 2. Območje je veliko približno  $80 \times 50$  km ( $79561 \times 50960$  celic). Del pravokotnega območja, za katerega sicer imamo digitalni model reliefa zaradi načina zajema sega izven meja Slovenije. Zaradi omejitve beleženja teras na Slovensko ozemlje, smo se za naše delo omejili na območje znotraj države (68.5% celic pravokotnega območja).

Glede na referenčne podatke je delež terasiranih pokrajin relativno majhen glede na celotno obravnavano ozemlje, zgolj 5.9%. Zato govorimo o neuravnoteženih podatkih, ki so obenem še geografsko neenakomerno po-

razdeljeni. Poleg tega smo že pred začetkom eksperimentov vedeli, da je seznam teras pomanjkljiv, predvsem ne obsega teras, ki so zapuščene in zaraščene, zato jih pri pregledu letalskih posnetkov pogosto ni bilo mogoče opaziti, možna pa je tudi človeška napaka.

### 4 Metodologija

Kljub izzivom, omenjenim v prejšnjem poglavju, smo raziskavo začeli s predpostavko, da je zaradi načina učenja odpornost globokih modelov na šum v oznakah v določenih primerih velika [17]. Problem zaznavanja terasiranih pokrajin zaradi raznolikih oblik teras v raziskavi obravnavamo kot klasičen problem semantične segmentacije. Na tem področju je zelo pogosto uporabljena globoka arhitektura UNet [18], ki je prikazana na Sliki 3. Gre za polno konvolucijski samokodirnik, ki preko plasti konvolucij in združevalnih slojev z maksimizacijo opiše lastnosti večjega območja v posamezni celici ozkega grla. V drugem delu se podatki postopoma spet rekonstruirajo na izvorno velikost slike v ciljno obliko za vsak slikovni element – klasifikacija v enega izmed ciljnih razredov.

Model UNet smo prilagodili za uporabo na naših podatkih. Število parametrov modela zmanjšali na 25% s sorazmernim zmanjšanjem števila kanalov v vsaki plasti. Podatke procesiramo v obliki zaplat velikosti  $512 \times 512$ , izrezanih iz celotnega digitalnega modela višin. Vhod v model je dvo-kanalna matrika parcialnih odvodov zaplate, ki so normalizirani z deljenjem z maksimalno vrednostjo odvoda znotraj znanih teras (19 m). Taka predstavitev nam omogoči, da je porazdelitev vrednosti podobna na vseh izsekih podatkov. Izhod iz modela je dvo-kanalna matrika verjetnosti, da posamezna celica vsebuje terase ali ne. Tekom učenja se napovedana dvo-kanalna verjetnost primerja z referenco. Za to smo uporabili večrazredno Dice-ovo funkcijo napake [19], ki je primerna za učenje segmentacije na neuravnoteženih podatkih.


### 5 Eksperimentalni rezultati

Da smo model eksperimentalno ovrednotili, smo podatke razdelili na učni in testni del. Ker je porazdelitev podatkov zelo neenakomerna, smo uporabili delitev območja v obliki šahovnice (območja velikosti:  $2048 \times 2048$  celic). Liha področja šahovnice so namenjena učenju, nato pa se vertikalno in diagonalno izmenjujejo območja namenjena učenju in vrednotenju. S tem smo dosegli skoraj enakomerno zastopanost teras v obeh množicah.

Iz ustreznega dela šahovnice smo naključno vzorčili vzorce, ki so v celoti znotraj le tega. Ker večina podatkov ne pripada terasam, smo vzorčenje tekom učenja pogojili s pripadnostjo vsaj 1% vzorca terasam (glede na referenčne podatke). Učno množico smo naknadno obogatili z naključnimi kombinacijami zrcaljenja ter rotacije.

Model smo optimizirali z metodo Adam [20] v 40000 korakih v paketih po 16 vzorcev. Hitrost učenja je bila 0.001. Naučeni model smo najprej kvantitativno ovrednotili na celotni testni polovici zbirke z natančnostjo in priklicem. Rezultati so povzeti v Tabeli 1, za referenco smo vzeli naključni binarni klasifikator.


<sup>3</sup>Surove podatke hrani Agencija RS za okolje.



Slika 3: Uporabljeni model za semantično segmentacijo. Vhod v model sta parcialna odvoda, pridobljena iz digitalnega modela višin, izhod pa binarna maska prisotnosti terasiranih pokrajin.

	Natančnost	Priklic	F1
Naključno	0.06	0.50	0.10
Model	0.54	0.67	0.52

Tabela 1: Kvalitativno vrednotenje dobljenega modela na testnem delu podatkov. Prikazane so mere natančnost, priklic in F1.



Slika 4: Napake na celotnem obravnavanem območju (rdeči kanal) skupaj z deležem teras v referenčnih podatkih (zeleni kanal).

Kvantitativni rezultati sicer potrjujejo, da se je model nečesa naučil, vendar pa so slabši od pričakovanj. Zato smo podatke in napako ovrednotili tudi kvalitativno. Na Sliki 4 je prikazana napaka, povprečena po področjih  $512 \times 512$  celic skupaj z deležem teras na teh področjih. Vidimo lahko, da se veliko napak pojavlja na področjih, kjer se tudi drugače pojavljajo terase. Ob podrobnem pregledu smo ugotovili, da so referenčni podani podatki bolj šumni, kot smo pričakovali. Največ napak prihaja iz neoznačenih (terase so vidne na senčenem reliefu, vendar niso označene), napačno označenih (so označene vendar jih tam ni) in nenatančno označenih območij (označeno ni natančno območje, terase se nadaljujejo izven območja


ali pa je območje oznake preširoko). Vse to v prvi vrsti negativno vpliva na funkcijo napake, ki se optimizira med učenjem in v model vnaša šum, po drugi strani pa izkrivi tudi rezultate vrednotenja.

V Sliki 5 je zbranih nekaj primerov najbolj pogostih odstopanj med referenčnimi oznakami in napovedmi modela, ki smo jih odkrili med kvalitativnim pregledom. V prvi vrstici so primeri ne-zaznanih teras. V nekaterih primerih so terase enostavno preozke, da bi jih model zaznal (A-1). V določenih primerih so referenčne oznake, vsaj glede na digitalni model višin, napačne (B-1) ali pa vsaj vprašljive (C-1). V drugi vrstici so primeri delnih referenčnih oznak, kljub širšemu obsegu teras so označena samo določena zemljišča (A-2), oznake so napačne, vendar je poleg njih model pravilno zaznal terase (B-2). V določenih primerih (C-2) referenčne oznake samo niso natančne, napake v mejah pa prispevajo k skupni napaki. V tretji vrstici so najprej prikazani primeri očitnih teras, ki jih je model našel, pa niso bile med referenčnimi podatki (A-3 in B-3), kot zadnji so primeri dobrega ujemanja referenčnih podatkov in napovedi modela (C-3).

## 6 Zaključek

V članku smo predstavili delne rezultate naše raziskave na temo zaznavanja terasiranih pokrajin v Sloveniji. V okviru raziskave smo uporabili podatke digitalnega modela višin ter referenčne podatke, pridobljene z ročno analizo letalskih posnetkov. Problem smo zastavili kot učenje modela za semantično segmentacijo. Referenčni podatki niso bili uravnoteženi, poleg tega smo že vnaprej vedeli, da referenčne oznake najverjetneje niso popolne in vsebujejo napake. Kljub temu smo pri analizi rezultatov ugotovili, da je, kljub nadzorovanemu načinu učenja in slabšim kvantitativnim kazalnikom, model robusten na napake v referenčnih podatkih. V nadaljevanju bomo zato model poskusili izboljšati z upoštevanjem dodatnih modalnosti, npr. letalski posnetki, ter upoštevanjem konteksta kot je informacija o parcelaciji. Zaradi šumnih podatkov bomo celoten postopek učenja modela poskusili zastaviti kot delno-nadzorovano ali interaktivno učenje.

**Zahvala:** Raziskava je bila delno financirana v okviru ARRS projektov L6-4038 in Z2-1866 ter ARRS programov P6-0101 in P2-0214.



Slika 5: Izbrani primeri ujemanja z referenčnimi podatki. Zelena - ujemanje, Rdeča - samo napoved, Modra - samo referenca.

## References

- [1] M. Varotto, L. Bonardi, and P. Tarolli. *World terraced landscapes: history, environment, quality of life*, volume 9. Springer, 2018.
- [2] T. Berčič and L. Ažman Momirski. Parametric terracing as optimization of controlled slope intervention. *Water*, 12(3):634, 2020.
- [3] L. Ažman Momirski and T. Berčič. Ignored regions: Slovenian terraced landscapes. *Annales*, 26(3):399–418, 2016.
- [4] D. Kladnik, R. Ciglič, M. Geršič, B. Komac, D. Perko, and M. Zorn. Diversity of terraced landscapes in slovenia. *Annales*, 26(3):469–486, 2016.
- [5] D. Kladnik, D. Perko, R. Ciglič, and M. Geršič, editors. *Terasirane pokrajine*. Založba ZRC, 2016.
- [6] L. Ažman Momirski, D. Kladnik, B. Komac, F. Petek, P. Repolusk, and M. Zorn. *Terasirana pokrajina Goriških brd*, volume 17. Založba ZRC, 2008.
- [7] F. Ferrarese, S. Eugenio Pappalardo, A. Cosner, S. Brugnaro, K. Alum, A. Dal Pozzo, and M. De Marchi. Mapping agricultural terraces in italy. methodologies applied in the mapter project. In *World Terraced Landscapes: History, Environment, Quality of Life*, pages 179–194. Springer, 2019.
- [8] Y. Zhang, M. Shi, X. Zhao, X. Wang, Z. Luo, et al. Methods for automatic identification and extraction of terraces from high spatial resolution satellite data (china-gf-1). *International Soil and Water Conservation Research*, 5(1):17–25, 2017.
- [9] W. Sun, Y. Zhang, X. Mu, J. Li, P. Gao, G. Zhao, T. Dang, and F. Chiew. Identifying terraces in the hilly and gully regions of the loess plateau in china. *Land Degradation & Development*, 30(17):2126–2138, 2019.
- [10] A. Ninfo. An assessment of the threat to the terraced areas along the brenta canal: an approach based on lidar. *Terraced landscapes of the Alps. Atlas. Project Alpter-Interreg iib Alpine Space Programme Co-funded by the European Union*, pages 28–30, 2008.
- [11] D. Godone, D. Giordan, and M. Baldo. Rapid mapping application of vegetated terraces based on high resolution airborne lidar. *Geomatics, Natural Hazards and Risk*, 9(1):970–985, 2018.
- [12] T. Berčič. Discovering terraced areas in slovenia: reliable detection with LIDAR. *Annales*, 26(3):449–468, 2016.
- [13] A. Mihevc and R. Mihevc. Morphological characteristics and distribution of dolines in slovenia, a study of a lidar-based doline map of slovenia. *Acta Carsologica*, 50(1), May 2021.
- [14] M. Čekada Triglav and V. Bric. Končan je projekt laserskega skeniranja slovenije. *Geodetski vestnik*, 59(3):586, 2015.
- [15] D. Kladnik, D. Perko, R. Ciglič, and M. Geršič, editors. *Terraced Landscapes*. Založba ZRC, 2016.
- [16] M. Šmid Hribar, M. Geršič, P. Pipan, P. Repolusk, J. Tiran, M. Topole, et al. Cultivated terraces in slovenian landscapes. *Acta geographica Slovenica*, 57(2):83–97, 2017.
- [17] D. Rolnick, A. Veit, S. Belongie, and N. Shavit. Deep learning is robust to massive label noise. *arXiv preprint arXiv:1705.10694*, 2017.
- [18] O. Ronneberger, P. Fischer, and T. Brox. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, volume 9351 of *LNCS*. Springer, 2015. (available on arXiv:1505.04597 [cs.CV]).
- [19] C. H. Sudre, W. Li, T. Vercauteren, S. Ourselin, and M. Jorge Cardoso. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, pages 240–248. Springer, 2017.
- [20] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.