

METODE**ZAZNAVANJE OLESENELE VEGETACIJE S KONVOLUCIJSKO NEVRONSKO MREŽO U-NET**

AVTORJI

Adam Gabrič

Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Inštitut za antropološke in prostorske študije, Novi trg 2, SI – 1000 Ljubljana in Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova cesta 2, SI – 1000 Ljubljana
adam.gabric@zrc-sazu.si, <https://orcid.org/0009-0008-4816-2881>

dr. Krištof Oštir

Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova cesta 2, SI – 1000 Ljubljana
kristof.ostir@fgg.uni-lj.si, <https://orcid.org/0000-0002-4887-7798>

dr. Žiga Kokalj

Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Inštitut za antropološke in prostorske študije, Novi trg 2, SI – 1000 Ljubljana
ziga.kokalj@zrc-sazu.si, <https://orcid.org/0000-0003-1712-0351>

DOI: <https://doi.org/10.3986/GV95205>

UDK: 712.41:528.715

COBISS: 1.01

IZVLEČEK

Zaznavanje olesenele vegetacije s konvolucijsko nevronske mrežo U-Net

S konvolucijsko nevronske mrežo U-Net smo zaznavali posamezna drevesa, skupine dreves in grmovnic, drevored, gozd, mejice, obvodno vegetacijo in drevesa v sadovnjakih, ki jih gradijo različne vrste olesenele vegetacije. Osnovni vhodni podatek je bil ortofoto, ki smo mu z namenom boljše klasifikacije dodajali dodatne sloje. Najboljši rezultat smo dobili s kombinacijo ortofota in modela višin krošenj – skupna natančnost klasifikacije je bila 93,3 %. Ta kombinacija vhodnih podatkov je zvišala natančnost klasifikacije razredov gozd in ostalo, ki predstavljata daleč največji delež učnih vzorcev, medtem ko je bil rezultat za manj zastopane razrede (zlasti drevored) tudi pri tej klasifikaciji slabši.

KLJUČNE BESEDE

nevronska mreža, olesenela vegetacija, ortofoto, model višin krošenj, klasifikacija

ABSTRACT

Woody vegetation detection with the U-Net convolutional neural network

Single trees, groups of trees and bushes, trees in rows, forest, hedges, riparian vegetation and trees in orchards, all of which are composed by different woody vegetation species, were classified using convolutional neural network U-Net. National orthophoto represented basic input data, however adding further layers was tested with a view of improving classification. Best results were obtained using orthophoto and canopy height model combination, the overall accuracy reached 93.3%. This combination increased accuracies achieved at two biggest classes (classes forest and other). The model performed much worse with other classes, that were less represented in training data, which is especially true for trees in rows.

KEY WORDS

neural network, woody vegetation, orthophoto, canopy height model, classification

Uredništvo je prispevek prejelo 16. novembra 2023.

1 Uvod

Raznoliki pokrajinski elementi v intenzivno obdelanih kmetijskih pokrajinah povečujejo heterogenost, ki jo je smiselno ohranjati zaradi različnih vzrokov. Najočitnejši je ohranjanje biotske raznovrstnosti, saj različni pokrajinski elementi rastlinskim in živalskim vrstam zagotavljajo raznolik življenjski prostor (Duelli 1997; Penko Seidl in Golobič 2020; Šumrada s sodelavci 2020). V prispevku smo zaznavali pokrajinske elemente, ki jih gradi olesenela vegetacija in imajo poleg povečevanja pestrosti pokrajine še druge pozitivne učinke. Olesenela vegetacija živalskim vrstam omogoča selitvene koridorje, saj deluje kot zatočišče pred plenilci, kmetijsko obdelavo ali neugodnim vremenom, s skladiščenjem ogljika blaži posledice podnebnih sprememb, z upočasnjevanjem vetra pa zmanjšuje odnašanje prsti (Lešnik 2018). Obenem se etični vidik ohranjanja biotske raznovrstnosti vsaj v nekaterih pokrajinah združuje z ekonomskimi in rekreativnimi vidiki ohranjanja okolja, predvsem z vidika turizma (Duelli 1997).

Olesenelo vegetacijo najdemo marsikje, na primer v gozdu, vinogradih, oljčnikih, na območjih rušja nad zgornjo gozdno mejo, na gozdnih plantažah, zemljiščih v zaraščanju, ob vodi. Pri izboru preučevanih pokrajinskih elementov smo se opirli na rezultate projekta *Opredelitev krajinske pestrosti in krajinskih značilnosti, pomembnih za ohranjanje biotske raznovrstnosti* (Golobič s sodelavci 2015). V njem so pokrajinske elemente, ki jih gradi olesenela vegetacija, zaradi različnih ekosistemskih storitev, ki jih ta zagotavlja lastni okolici, delili na drevesa in grme (ki so jih nadalje delili na posamezna drevesa in grme, drevesa in grme v vrsti, skupine dreves in grmov), gozdne zaplate, mejice (živice), obvodno vegetacijo ter visokodebelne sadovnjake. Šumrada s sodelavci (2020) poroča, da je bil našeti nabor sprejet s strani predstavnikov različnih področij (na primer kmetijstvo, ekologija, krajinska arhitektura, geografija) kot ustrezen nabor pokrajinskih elementov, ki bi jih bilo treba ohranjati, zaradi česar smo se odločili za zaznavanje sledečih razredov (v nadaljevanju razredi olesenele vegetacije): posamezna drevesa, skupine dreves in grmovnic, drevoredi, gozd, mejice, obvodna vegetacija, drevesa v sadovnjakih.

Kljub potrebi po ohranjanju posameznih pokrajinskih elementov, so natančni podatki o njih pogosto skopi (Šumrada s sodelavci 2020), kar je problematično tudi glede pokrajinskih elementov, ki jih gradi olesenela vegetacija in jih zaradi preprečevanja zaraščanja kmetje pogosto odstranjujejo, s čimer se hitro spreminjata njihova številčnost in obseg. Zaradi možnosti hitrejšega zajema podatkov na velikem območju daljinsko zaznavanje na tem področju izkazuje velik potencial (Šumrada s sodelavci 2020). Kljub temu ima tudi prepoznavanje iz daljinsko zaznanih podatkov svoje pomanjkljivosti. Lampič in Kastelic (2021) sta ugotovili, da niti terensko delo, niti prepoznavanje iz ortofotov ali iz lidarskih podatkov ni povsem ustrezno za kartiranje mejic. Še najbolj sta izpostavili lažjo prepoznavo presledkov med mejicami na lidarskih podatkih in otežen zajem iz ortofota na senčnih lokacijah. Tudi drugi avtorji so že preverjali, kakšne so možnosti segmentacije olesenele vegetacije iz večspektralnih posnetkov (na primer Guirado s sodelavci 2017; Castillejo-González 2018; Dong s sodelavci 2019; Freudenberg s sodelavci 2019; Safonova s sodelavci 2019; Sylvain, Drolet in Brown 2019; Weinstein s sodelavci 2019; Zheng s sodelavci 2019; Barros s sodelavci 2022) ali iz lidarskega modela višin krošenj (Hyyppä in Inkinen 1999; Chen, Xiang in Moriya 2020; Estornell s sodelavci 2021; Lisiewicz, Kamińska in Stereńczak 2022). Precej manj je raziskav, ki bi uporabljale več različnih podatkovnih slojev skupaj (Hoeser, Bachofer in Kuenzer 2020), s čimer smo v pričujoči raziskavi želeli zvišati skupno ter uporabnikove in izdelovalčeve natančnosti samodejne zaznave.


Večinoma se raziskave osredotočajo le na zaznavo olesenele vegetacije, pri čemer število rastlin in oblika zaraščanja ne vplivata na razred, v katerega želimo klasificirati posamezno krošnjo (na primer Guirado s sodelavci 2017; Castillejo-González 2018; Weinstein s sodelavci 2019). Že Ahlswede, Asam in Röder (2021) so ugotovili, da je razlikovanje med gozdom in mejicami zaradi njihovega podobnega spektralnega podpisa težavno. Kokalj s sodelavci (2020) so ob klasifikaciji mejic, obvodne drevnine, posameznih grmov in dreves ter sklenjenih otokov grmičevja in zaraščanja težavo naslovili z objektno klasifikacijo. Sprva so iz podatkov aerolaserskega snemanja izdelali model višin krošenj in izbrali celice, ki so vsaj 2 m nad tlemi. Klasifikacijo so izvedli z metodo naključni gozd (angleško *random forest*),

ki je segmente razporedila glede na njihovo morfologijo. V pričujoči raziskavi smo proces nadgraditi z uporabo konvolucijske nevronske mreže U-Net, ki je ena najpogostejše uporabljenih arhitektur za semantično segmentacijo (Hoeser in Kuenzer 2020), pri kateri metoda hkrati določi segment in mu pripiše razred. Njen rezultat je raster z določenim razredom vsakega piksela, vendar je šum v njenih rezultatih manj pogost kakor pri drugih metodah pikselske klasifikacije. U-Net se je na področju daljinskega zaznavanja uporabljal za najrazličnejše namene, na primer za kartiranje pokrovnosti tal (Marsetič in Kanjir 2022), palm (Freudenberg s sodelavci 2019), mej med zemljišči (Garcia-Pedrero s sodelavci 2019), stavb (Guo s sodelavci 2021), kulturnih teras (Glušič, Ciglič in Čehovin Zajc 2021; Yu s sodelavci 2022), vodnih zemljišč (Feng s sodelavci 2019; Sadiq s sodelavci 2022), vinske trte (Jones s sodelavci 2020; Barros s sodelavci 2022), bregov vodotokov (Barlow, Zhu in Glennie 2022), vrtač (Mihevc in Mihevc 2021) in gozda (Mazza s sodelavci 2019).

V pričujoči raziskavi smo preverjali prispevek posameznih podatkovnih slojev k izboljšanju skupne natančnosti zaznavanja izbranih razredov olesene vegetacije s konvolucijsko nevronske mreže U-Net. Obenem nas je zanimalo, do katere mere je mogoče s posameznimi podatkovnimi sloji in samodejno klasifikacijo ločevati med različnimi razredi olesene vegetacije. Primarno uporabljen podatek je bil državni ortofoto, ki smo mu dodali model višin krošenj, oddaljenost od grafičnih podatkov v katastru stavb, oddaljenost od vodotokov v vodnem katastru in oddaljenost od katastrskih meja v zemljiškem katastru.

2 Metode

Ker smo želeli izdelati model za klasifikacijo preučevanih razredov, ki bi bil aplikativen za območje celotne Slovenije, smo klasifikacijo preizkusili na 20 (različno velikih) preučevanih območjih (slika 1). Večino teh smo izbrali glede na seznam izjemnih krajin v Sloveniji, pet pa smo jih dodali, ker so takšna



Slika 1: Lokacije območij preučevanja.

območja v naboru izjemnih krajin manjkala. To so bila območja kraškega površja pri Senožeah, del Ljubljanskega barja, ljubljanski Tivoli kot predstavnik mestnega parka, Uniše z intenzivnimi sadovnjaki in intenzivno kmetijsko območje pri Petanjcih. Vsako preučevano območje smo glede na geografsko dolžino ali širino razdelili (približno) na polovico ter en del uporabili za učenje, drugega pa za testiranje modela. Vhodne podatke učne množice smo razrezali na kvadrate velikosti 128×128 pikselov s 50 % prekrivanjem (izrezi). Gozd je pokrival veliko večji del območij za učenje modela kakor ostali preučevani razredi olesenele vegetacije, kar je za strojno učenje, ki stremi k enakomerni razporeditvi učnih primerov med vsemi razredi, problematično. Vpliv neenakomerne razporeditve med razredi smo naslovili z izborom izrezov na podlagi sloja rabe tal iz leta 2014, ki je časovno najbližje uporabljenim podatkom daljinskega zaznavanja. Da se model ne bi naučil le kakovostne klasifikacije gozda in obenem zane-marjal prepoznavanje ostalih razredov, smo izreze, katerih posamezni deli ali ki v celoti ležijo več kot

Preglednica 1: Opis razredov in pogostost njihovega pojavljanja v množici učnih vzorcev (prirejeno po Golobič s sodelavci 2015).

razred	opis	skupaj površina (ha)	delež (%)
posamezna drevesa	Drevesa, katerih krošnje se ne dotikajo drugih drevesnih krošenj in niso zasajena v linijah ali drugem pravilnem vzorcu.	14	1,0
skupine dreves in grmovnic	Drevesa in grmi z medsebojno stičnimi krošnjami, ki niso zasajena v linijah ali drugem pravilnem vzorcu. Površina medsebojno stičnih krošenj ne presega 2500 m^2 .	62	4,3
drevoredi	Drevesa zasajena v vrsti, krošnje so približno enako velike. Lahko so stične ali nestične.	2	0,1
gozd	Drevesa in grmi z medsebojno stičnimi krošnjami, vsaj del medsebojno stičnih krošenj ima določeno dejansko rabo tal gozd. Če dejanska raba tal nobenega dela medsebojno stičnih krošenj, ki skupaj presegajo površino 2500 m^2 , ni gozd, površina pripada razredu gozd v vseh primerih, razen, če olesenela vegetacija raste linijsko ob vodotoku ali med kmetijskimi zemljišči.	494	34,1
mejice	Strnjene linije drevesne vegetacije s podrastjo, ki se pojavljajo na meji med obdelanimi kmetijskimi zemljišči.	5	0,3
obvodna vegetacija	Drevesa in grmičevje, ki se pojavlja ob stalnih vodah v obliki zaraščenega vodnega brega.	8	0,6
drevesa v sadovnjakih	Drevesa, katerih krošnje se pojavljajo v pravilnem vzorcu (kvadratna ali romboidna mreža, vzporedne linije), in kjer raba tal ni oljčnik. Oljčnikov nismo razvrstili v razred sadovnjakov zaradi njihovega specifičnega spektralnega podpisa. Ta bi modelu omogočal, da se sadovnjake uči klasificirati na podlagi spektralnega podpisa oljk in ne glede na razporeditev dreves. Krošnje dreves v sadovnjakih so lahko stične, vendar je na ortofotu pravi vzorec razporeditve dreves še razviden.	4	0,3
ostalo		860	59,4

100 m od najbližjih kmetijskih zemljišč, odstranili iz učne množice. Območje za učenje nevronske mreže je bilo razdeljeno na 13.305 izrezov, izmed katerih je bilo učenju namenjenih 90 % izrezov, validaciji pa 10 %. Površina območja za učenje je bila na koncu 14,5 km², površina območja testiranja pa 22,4 km². Slednjega nismo razrezali na izreze, temveč smo ga v celoti klasificirali naenkrat.

Preučevane razrede olesenele vegetacije smo digitalizirali z vizualno interpretacijo, pri razredih gozd in drevesa v sadovnjakih smo si pomagali tudi s slojem rabe tal. Digitalizacija razredov je potekala zaporedno – sprva smo določili območje gozda. Kasneje so si sledili razredi drevesa v sadovnjakih, mejice, obvodna vegetacija, drevoredi, posamezna drevesa in na koncu še skupine dreves in grmovnic. Olesenele vegetacije, ki smo jo že prepoznali kot predstavnika enega izmed predhodno digitaliziranih razredov, nismo označili v kasnejših korakih. Definicije razredov in omejevanje vzorcev smo prilagodili zmoglostim oziroma specifikam prepoznavanja na daljinsko zaznanih podatkih (preglednica 1). Zaradi tega v razred sadovnjakov nismo uvrščali ekstenzivnih sadovnjakov, kjer se sadna drevesa ne razlikujejo dovolj od posameznih dreves oziroma gruč dreves in grmov. V ta razred smo uvrščali le drevesa, zasajena v pravilnem vzorcu.

Obod krošenj smo digitalizirali glede na uporabljen ortofoto. Za lokacije, kjer je ortofoto nejasen, smo interpretacijo izvedli iz modela višin krošenj, izračunanega iz oblaka točk aerolaserskega skeniranja (natančnejši opis izdelave je v preglednici 2). Digitalizirani sloj razredov olesenele vegetacije (v nadaljevanju referenčni podatki) smo uporabili kot učne in testne vzorce za učenje nevronske mreže ter oceno ustreznosti modelov.

Na preučevanih območjih smo med razredi olesenele vegetacije prepoznali največ gozda, ki je v učni množici prekrival petkrat toliko površine kakor ostali preučevani razredi olesenele vegetacije skupaj. Po površini so od drugih razredov odstopale še skupine dreves in grmovnic. Najmanj je bilo drevoredov in dreves v sadovnjakih (preglednica 1). Neenakomerna razporeditev po razredih se je izkazala za težavo, zaradi katere smo odstranili izreze, prekrite le z gozdom, in tekom učenja nevronske mreže ob izračunu napake modela obtežili piksele z večjo napako klasifikacije. Ker je napaka večinoma večja pri razredih z manjšim številom učnih vzorcev, so na ta način bolj obteženi manjši razredi.

2.1 Uporabljeni podatki

Osnovni vhodni podatek je bil ortofoto v ločljivosti 0,5 m, posnet v letih 2014 in 2015, ko so zajeli tudi večino uporabljenih podatkov aerolaserskega skeniranja. Ortofoto je izdelan iz aerofotografij, združenih v mozaik. Ob izdelavi mozaika se vrednosti pikselov aerofotografij zaradi potrebe po ujemanju s sosednjimi območji prilagodi, s čimer ne ustrezajo več vrednostim, zajetim s senzorjem. Vrednosti ortofota torej spektralno ne prikazujejo dejanskega stanja, kar pa za izbrano metodo, ki temelji na prepoznavanju vzorcev in ne na iskanju dejanskih vrednosti, ni posebej pomembno.

Klasificirali smo sedem različnih nizov vhodnih podatkov. Pri prvem in drugem preizkusu smo uporabili le podatke ortofota, v prvem preizkusu kanale v rdečem, zelenem in modrem spektru, v drugem smo dodali še kanal v infrardečem spektru. Pri naslednjih preizkusih smo štirim kanalom ortofota dodali različne druge sloje. Z dodatnimi sloji, katerih izračun je opisan v preglednici 2, smo želeli izboljšati pravilnost razvrščanja obodov vseh razredov olesenele vegetacije (model višin krošenj), razvrščanje v razred dreves v sadovnjakih, ki so pogosto blizu pozidanih območij (oddaljenost od grafičnih podatkov v katastru stavb), mejic (oddaljenost od katastrskih meja v zemljiškem katastru) in obvodne vegetacije (oddaljenost od vodotokov v vodnem katastru). V štirih preizkusih smo štirikanalnemu ortofotu dodali posamezen dodatni sloj, v zadnjem preizkusu pa smo štirikanalni ortofoto združili z vsemi štirimi dodatnimi sloji (preglednica 3).

Ker je za metode strojnega učenja bolje, da imajo vsi podatki enoten razpon (Muhammad Ali in Faraj 2014), smo vse dodatne sloje normalizirali na 0–255, kakršen je tudi razpon kanalov ortofota. Podatke smo normalizirali z minimalno in maksimalno vrednostjo dodatnega sloja v učni množici. Pikseli dodatnega sloja na območju za testiranje, ki so imeli večjo vrednost od maksimalne vrednosti v učni množici, so dobili vrednost 255.

Preglednica 2: Opis nastanka dodatnih slojev.

datni sloj	način izračuna
model višin krošenj (MVK)	Odločili smo se za pristop, ki ga predlagajo Khosravipour, Skidmore in Isenburg (2016) in ki stremi k izdelavi modela višin krošenj brez nepotrebnih lukenj (<i>pits</i>) in špic (<i>spikes</i>). Pridobili smo georeferenciran in klasificiran oblak točk. Točke smo z orodjem <i>LAStools</i> sprva normalizirali, s čimer smo v oblaku točk podatke o nadmorskih višinah zamenjali z višino točke nad tlemi. Ob tem smo odstranili nikoli klasificirane točke (0), neklasificirane točke (1) in nizke točke oziroma šum (7). Za izračun višine nad tlemi je bil uporabljen radij 10 m. Oblak smo redčili, pri čemer smo obdržali le najvišjo točko za vsak kvadrat velikosti 25 × 25 cm. Izdelali smo krog osmih točk z radijem 0,1 m okoli vhodne točke. Iz tega smo izdelali MVK z ločljivostjo 0,5 m. Pri tem smo uporabili točke nizke, visoke in srednje vegetacije (razredi 3, 4 in 5). Med izdelavo MVK se izdeluje trikotniška mreža, sprva iz najvišjih točk, iz katerih se je izdelala mreža s stranicami krajšimi od 3 m. To mrežo so lahko spreminjale le še točke, ki ležijo največ 3 m pod njo, s čimer smo se znebili lukenj v drevesnih krošnjah. Ob rastriranju mreže smo pikslom, ki so bili manj kot 2 m nad tlemi, pripisali vrednost 0.
oddaljenost od grafičnih podatkov v katastru stavb (oKS)	Euklidska oddaljenost od objektov v katastru stavb z ločljivostjo 0,5 m.
oddaljenost od vodotokov v vodnem katastru (oVK)	Uporabili smo linijske podatke vodnega katastra, iz katerih smo izbrali le stalne vodotoke in odstranili prepuste, sifone in prekritja. Izračunali smo rastrski sloj evklidskih razdalj do 200 m od vodotoka v ločljivosti 0,5 m.
oddaljenost od katastrskih meja v zemljiškem katastru (oZK)	Uporabili smo podatke zemljiško katastrskega prikaza, katerih raba ni cesta, železnica ali vodotok. Da bi odstranili različno kategorizirane parcele okoli stavb, smo se odločili odstraniti manjše poligone. Po korakih 500 m ² smo preizkusili odstranjevanje poligonov z velikostjo med 500 in 5000 m ² ter se odločili odstraniti poligone s površino pod 3000 m ² . Izbrane poligone smo pretvorili v linije. Po korakih 10 m smo preizkusili odstranjevanje linij dolgih med 50 in 200 m. Glede na rezultate smo odstranili linije krajše od 150 m, da smo odstranili obode stavb. Izračunali smo evklidske oddaljenosti od tako pridobljenih linij z ločljivostjo 0,5 m.

Preglednica 3: Uporabljeni sloji v posameznem preizkusu.

ime preizkusa	uporabljeni sloji
1 RGB	rdeč, zelen in moder kanal ortofota iz let 2014 in 2015 v ločljivosti 0,5 m (RGB)
2 RGBI	rdeč, zelen, moder in bližnji infrardeč kanal ortofota iz let 2014 in 2015 v ločljivosti 0,5 m (RGBI)
3 RGBI-MVK	RGBI, model višin krošenj (MVK)
4 RGBI-oKS	RGBI, oddaljenost od grafičnih podatkov v katastru stavb (oKS)
5 RGBI-oVK	RGBI, oddaljenost od vodotokov v vodnem katastru (oVK)
6 RGBI-oZK	RGBI, oddaljenost od katastrskih meja v zemljiškem katastru (oZK)
7 RGBI-MVK-oKS-oVK-oZK	RGBI, MVK, oKS, oVK, oZK

2.2 U-Net

Klasifikacijo smo izvedli s konvolucijsko nevronske mrežo z arhitekturo U-Net, ki so jo zasnovali Ronneberger, Fischer in Brox (2015). Gre za arhitekturo s kodirnikom in dekodirnikom. Kodirnik je sestavljen iz zaporedja konvolucijskih filtrov in združevanj z maksimizacijo, pri katerih se ločljivost zmanjšuje, hkrati pa se povečuje število kanalov. V dekodirniku, v katerem se ločljivost spet povečuje, ob hkratnem zmanjševanju števila kanalov, vsak vhod združevanja z maksimizacijo mreža združi z rezultatom dekonvolucije, kar omogoča natančnejše določanje meje med posameznimi razredi. Hrbtenična arhitektura je bila *ResNet34*, ki so ga opisali He s sodelavci (2015) in je bila predhodno naučena na zbirki slik *ImageNet* (Deng s sodelavci 2009). Učenje vseh slojev hrbtenične arhitekture je bilo omogočeno.

U-Net smo učili z razširitvijo programa *ArcGIS Pro 3.1.0* na računalniku z grafično kartico *Nvidia Quadro M4000*, ki ima 8 GB pomnilnika. Število epoh je bilo 20, stopnja učenja 0,001 in velikost paketa 16. Izguba je bila izračunana z navzkrižno entropijo, pri čemer so bili bolj obteženi piksli z večjo izračunano napako.

Kakovost posamezne klasifikacije smo preverili s testno množico, za katero smo izračunali skupne natančnosti – delež pravilno klasificiranih pikslov. Uspešnost klasifikacije posameznih razredov smo opredelili z izračuni uporabnikove in izdelovalčeve natančnosti. Uporabnikova natančnost je namenjena oceni zanesljivosti dobljenega zemljevida, saj poda delež pikslov posameznega razreda na končnem zemljevidu, ki ustreza dejanskemu stanju. Izdelovalčeva natančnost je namenjena analitiku, ki je izdelal klasifikacijo. Določa jo delež pikslov posameznega razreda, ki so bili pravilno klasificirani, izmed vseh pikslov, ki bi jih model moral razvrstiti v ta razred. Obenem smo za posamezne lokacije rezultate različnih modelov tudi prikazali, pri čemer smo zaradi jasnosti prikazali zgolj rezultate modelov, ki najboljše prikazujejo razlike med klasifikacijami.


3 Rezultati

Ugotovimo lahko, da se je U-Net v vseh preizkusih dobro naučil prepoznati razrede, ki so v učni množici najpogostejši (slika 3). Izdelovalčeva in uporabnikova natančnost sta za vse teste najvišji pri razredih gozd in ostalo, ki obsegata dobrih 93 % pikslov učnih vzorcev, zato so razlike med najvišjo in najnižjo skupno natančnostjo majhne (< 1 %). Najvišjo, 93,3 %, dosega model RGBI-MVK (slika 2). Za isti preizkus sta izračunani najvišji uporabnikova (94,8 % za razred ostalo) in izdelovalčeva natančnost (97,4 % za razred gozd). Uporabnikova natančnost doseže vrednost 94,8 % še pri klasifikaciji RGBI-oVK za razred gozd (slika 3).


Z izjemo gozda so pri vseh razredih olesenele vegetacije uporabnikove natančnosti višje od izdelovalčevih (slika 3), kar pomeni, da so lažno pozitivni rezultati manjši problem od lažno negativnih. Razlog za to je predvsem napačna klasifikacija drugih razredov olesenele vegetacije v razred gozd, zaradi česar so pri tem razredu uporabnikove natančnosti nižje od izdelovalčevih. Če pogledamo le najboljše uporabnikove natančnosti za posamezne razrede, je najnižja vrednost 51,5 % za obvodno vegetacijo (RGBI-MVK-oKS-oVK-oZK), kar je še vedno veliko višje, kot je katerakoli izdelovalčeva natančnost pri petih izmed sedmih razredov olesenele vegetacije. Le razreda gozd ter skupine dreves in grmovnic sta dosegla višjo izdelovalčevo natančnost, slednje le pri klasifikaciji RGBI-MVK.

Medtem ko pri razredih olesenele vegetacije po natančnosti klasifikacije na eni strani močno odstopa gozd, na drugi strani za drevorede izdelovalčeva natančnost pri nobenem testu ne dosega vrednosti nad 5%. Trije modeli se tega razreda sploh niso naučili prepoznati, še pri treh modelih pa je bila v ta razred razvrščena le peščica pikslov, zaradi česar izdelovalčeva natančnost ne dosega vrednosti 1%. Najbolj se je odrezal model RGBI-MVK-oKS-oVK-oZK; tudi pri tem je izdelovalčeva natančnost le 3,7%. Razreda obvodna vegetacija in posamezna drevesa imata najmanj lažno negativnih primerov pri klasifikaciji z vsemi vhodnimi sloji, skupine dreves in grmovnic pri klasifikaciji RGBI-MVK, mejice pri klasifikaciji RGBI-oZK, drevesa v sadovnjaku pa pri klasifikaciji RGBI-oVK.

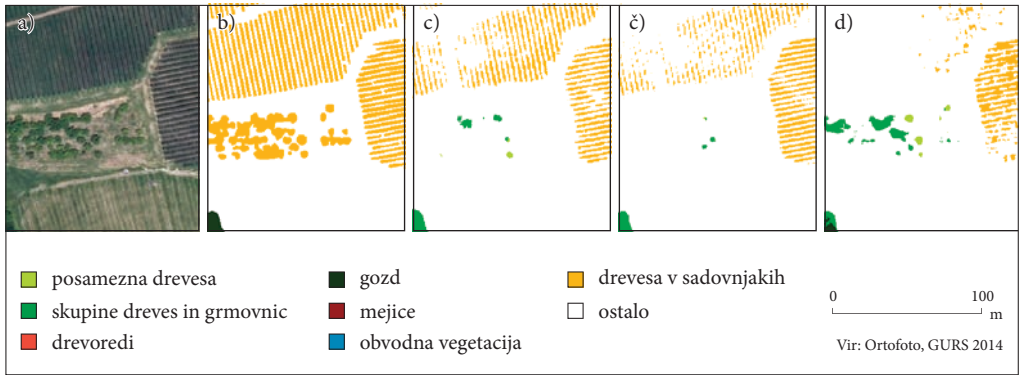
Dodajanje slojev, s katerimi smo želeli izboljšati klasifikacijo posameznega razreda, ni bilo povsem uspešno. Sloj oKS ni prinesel dodatnih informacij, potrebnih za kakovostno klasifikacijo dreves v sadovnjakih. Ti so bili z izjemo intenzivnih sadovnjakov na preučevanem območju Uniše večinoma razporejeni v druge razrede olesenele vegetacije. Pravilne napovedi na območju Uniš nakazujejo na to, da je bilo v množici za učenje verjetno preveč primerov s tega območja, kjer so drevesa v intenzivnih sadovnjakih namreč pogosto zasajena bolj v vrstah kakor v drugem pravilnem vzorcu (slika 4). Da se je uporabljena nevronska mreža sposobna naučiti postavitev v pravilnem vzorcu prepoznavati kot pomemben dejavnik, nakazuje oljčnik na preučevanem območju Koštabona (slika 5), ki ga model RGB v celoti razporeji v razred sadovnjakov (slika 5c). Kljub temu da so se modeli očitno naučili kot drevesa v sadovnjakih klasificirati vzporedne vrste olesenele vegetacije, so se modeli tudi večinoma pravilno naučili vinograde prepoznavati kot ostalo.



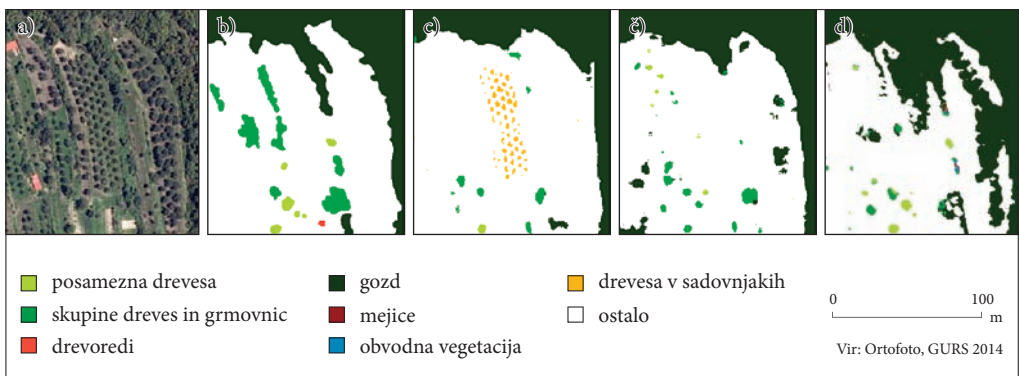
Slika 2: Razlika skupne natančnosti v primerjavi s skupno natančnostjo modela RGBI (zgoraj) in absolutne vrednosti skupne natančnosti izračunanih modelov (spodaj).




Slika 3: Uporabnikova in izdelovalčeva natančnost izračunanih modelov po razredih.



Slika 4: Drevesa v sadovnjakih na preučevanem območju Uniše: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGB, (č) RGBI in (d) RGBI-MVK-oKS-oVK-oZK.



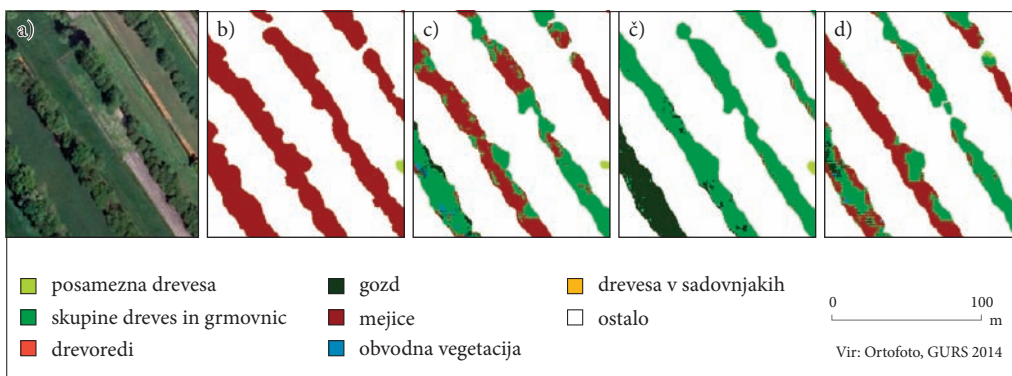
Slika 5: Oljčniki na preučevanem območju Koštabona: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGB, (č) RGBI in (d) RGBI-MVK-oKS-oVK-oZK.



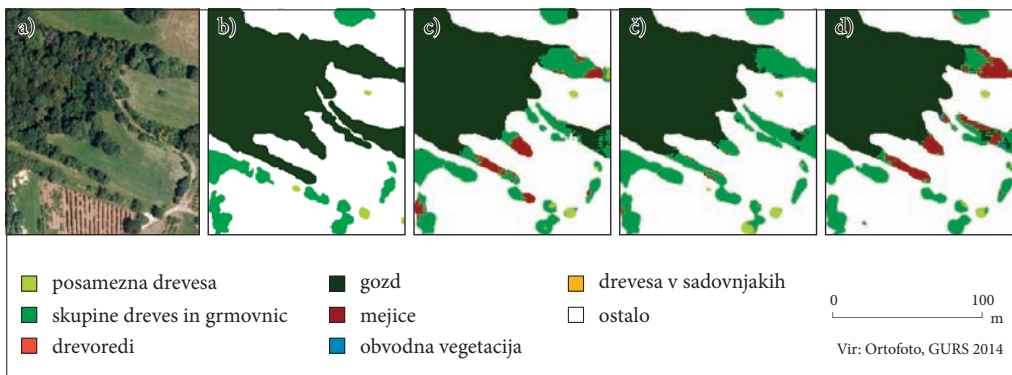
Slika 6: Napačno prepoznane sence v vinogradu na preučevanem območju Jeruzalem: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGBI, (č) RGBI-MVK in (d) RGBI-oVK.

V vinogradih pri nobenem testu ni bilo večjega števila lažno pozitivnih napovedi. Največ takšnih klasifikacij je bilo posledica senc dreves ob cesti, ki jih presenetljivo najdemo tudi na rezultatih RGBI-MVK. Pričakovali bi namreč, da bo model, ki vsebuje podatke o višinah nad tlemi, sposoben prepoznati razliko med vinsko trto in drevesom, saj ima vinska trta zaradi višine manjše od 2 m v izdelanem MVK vrednost 0 (slika 6).


Za mejice je izmed vseh kombinacij vhodnih podatkov najvišjo izdelovalčevo natančnost dosegel model RGBI-oZK. To lahko potrdimo tudi vizualno. S slike 7 je razvidno, da so bili že z modelom RGBI deli mejic prepoznani v pravičen razred (slika 7c), ob dodajanju zemljiškega katastra pa so mejice zajete manj razdrobljeno (slika 7d). Čeprav v pravičen razred še vedno niso zajete celotne mejice, so v večjem deležu razvrščene pravilno. Pri drugih modelih je večji del mejic zajet predvsem v razredu skupin dreves in grmovnic. Obenem lahko opazimo, da se je model RGBI-oZK naučil kot mejice klasificirati dele gozda, kjer je med enim in drugim gozdnim robom le nekaj 10 m (slika 8), ki smo jih med interpretacijo zajeli kot gozd, vendar imajo z mejicami mnoge skupne lastnosti. Ta problem je manj opazen pri modelu RGBI, čeprav se pojavlja tudi pri njem (slika 8c). Po drugi strani so mejice z modelom RGBI-MVK klasificirane slabše kot pri drugih klasifikacijah, saj model večje dele mejic prepozna kot skupine dreves in grmovnic (slika 7č). Podobne rezultate klasifikacije RGBI-MVK opazimo pri obvodni vegetaciji, kar se izrazito pozna pri izdelovalčevi natančnosti teh dveh razredov (slika 3).



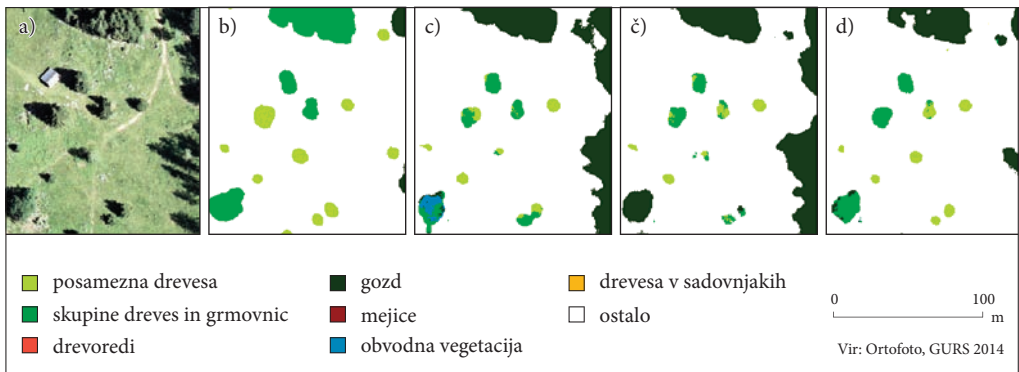
Slika 7: Mejice na preučevanem območju Ljubljansko barje: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGBI, (č) RGBI-MVK in (d) RGBI-oZK.




Slika 8: Ožji deli gozda na preučevanem območju Tomaj: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGBI, (č) RGBI-MVK in (d) RGBI-oZK.




Slika 9: Prepoznavna obvodne vegetacije na preučevanem območju dolina Krke: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGBI, (č) RGBI-oVK in (d) RGBI-MVK-oKS-oVK-oZK.



Slika 10: Posamezna drevesa na preučevanem območju Logarska dolina: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGB, (č) RGBI in (d) RGBI-MVK.



Slika 11: Natančnost prepoznavne roba gozda na preučevanem območju Otlica: (a) ortofoto, (b) referenčni podatki, rezultati klasifikacij z modeli (c) RGB, (č) RGBI in (d) RGBI-MVK.



Slika 12: Razlika natančnosti klasifikacije za združen razred olesene vegetacije v primerjavi z natančnostjo modela RGBI (zgoraj) in absolutne vrednosti natančnosti izračunanih modelov (spodaj).

Težje je opredeliti prispevek sloja oVK, s katerim smo želeli izboljšati klasifikacijo obvodne vegetacije (slika 9). Del te pravilno razvrsti že model RGBI, vendar je opazno, da je obvodna vegetacija – podobno kot mejice – preveč fragmentirana. Piksele ob vodi model prepozna kot obvodno vegetacijo, medtem ko preostanek segmenta pripiše drugim razredom olesene vegetacije. RGBI-oVK sicer razširi obvodno vegetacijo tako, da je na nekaterih delih celotna širina segmenta pripisana v razred obvodne vegetacije, vendar je po drugi strani segment še bolj razdrobljen (slika 9č). Bolje je prednosti sloja oVK izkoristil model z vsemi vključenimi vhodnimi podatki, kar je opazno predvsem na preučevanem območju v dolini Krke (slika 9e).

Fragmentacija rezultatov klasifikacij se je pokazala za težavo že pri najmanjših elementih, torej pri razredu posameznih dreves (slika 10). Pri tem razredu je najboljše razvrščanje dosegel model RGBI-MVK,

pri katerem so drevesne krošnje najbolj homogene (slika 10d), posledica česar je visoka uporabnikova natančnost tega razreda (slika 3). Model RGBI-MVK je sposoben tudi bolj natančnega zajema roba krošenj kakor ostali modeli, kar je opazno, kjer je med enim in drugim pokrajinskim elementom razdalja največ nekaj 10 pikslov. Zaradi nesposobnosti razpoznavanja presledkov med posameznimi segmenti je veliko olesenele vegetacije blizu gozdnega roba prepoznane kot gozd (slika 11). Da iz lidarskih podatkov lažje prepoznamo presledke med sosednjimi segmenti olesenele vegetacije sta na primeru mejic izpostavili Lampič in Kastelic (2021).

Klasifikacija na podlagi uporabljenih podatkov je zelo uspešna, če vse razrede olesenele vegetacije združimo v en sam razred, da dobimo le razreda olesenela vegetacija in ostalo (binarna klasifikacija) (slika 12). Tudi v tem primeru je skupna natančnost najvišja (95,5 %) pri modelu RGBI-MVK. Razlog je predvsem v visoki izdelovalčevi natančnosti, kar pomeni, da MVK zmanjša število lažno negativnih primerov. Najmanj lažno pozitivnih primerov, ki vplivajo na uporabnikovo natančnost, je pri klasifikacijah z modeloma, ki uporabljata le optične podatke (RGB in RGBI) (slika 12), čeprav so razlike med najboljšim in najslabšim modelom majhne (<1 %). Ostali dodatni sloji (oKS, oVK, oZK) na binarno klasifikacijo vplivajo negativno, kar ni nenavadno, saj so bili dodani v želji po boljšem prepoznavanju posameznih razredov. S tem smo zavestno zmanjšali delež informacij, pomembnih izključno za natančnost določitve roba segmenta olesenele vegetacije. Visoke vrednosti natančnosti klasifikacije skupnega razreda olesenele vegetacije dokazujejo, da so se vsi modeli zelo dobro naučili ločevati olesenelo vegetacijo od ostalega. Nizke vrednosti uporabnikove in izdelovalčeve natančnosti za posamezne razrede olesenele vegetacije so torej posledica težav pri ločevanju med posameznimi razredi in ne težav pri ločevanju od ostalih površin.

4 Razprava

Vsi modeli so se naučili kakovostno razlikovati med olesenelo vegetacijo in ostalim, zaradi česar skupna natančnost binarne klasifikacije v vseh primerih presega 90 %. Še najvišja je pri modelu RGBI-MVK (95,5 %), kar dokazuje, da je mogoče s kombiniranjem vhodnih podatkov dosegati boljše rezultate kakor z uporabo le enega tipa podatkov. Ostali dodatni sloji niso bili dodani, da bi zvišali natančnost določanja obodov olesenele vegetacije, temveč da bi povečali možnost ločevanja posameznih razredov olesenele vegetacije, kar se kaže v znižanju skupne natančnosti binarne klasifikacije pri modelih RGBI-oKS, RGBI-oVK in RGBI-oZK.

Ne glede na izbor vhodnih podatkov se je ločevanje preučevanih razredov olesenele vegetacije izkazalo za težavo. Vsi modeli so se najbolj naučili prepoznavati gozd, pri čemer so piksele ostalih razredov pogosto razvrstili v ta razred. V manjši meri je problem prisoten še pri razredu skupin dreves in grmovnic, ki od ostalih razredov olesenele vegetacije odstopa glede na izdelovalčevo natančnost, medtem ko gozd odstopa tudi glede na uporabnikovo. Gre za najpogostejša razreda olesenele vegetacije v učni množici, kar jasno kaže, da je bilo razmerje učnih primerov preveč neenakomerno. Vpliv velikosti posameznih razredov je najbolj opazen pri klasifikaciji RGBI-MVK, ki je dosegla najvišjo skupno natančnost, vendar je izboljšanje najizrazitejše za razrede, pri katerih je bila klasifikacija najuspešnejša že brez MVK. Nasprotno temu se je predvsem izdelovalčeva natančnost mejic in obvodne vegetacije z dodajanjem MVK znižala.

Delež razreda v učni množici ni edini dejavnik, ki vpliva na kakovost njegove klasifikacije. Razred mejic je v veliki večini testov dosegel višji izdelovalčevo in uporabnikovo natančnost kakor razred obvodne vegetacije, čeprav je bilo na preučevanih območjih obvodne vegetacije več kakor mejic. Obvodna vegetacija je od mejic višjo izdelovalčevo natančnost dosegla le pri RGBI-MVK-oKS-oVK-oZK, pri kateri je obvodna vegetacija dosegla najvišji izdelovalčevo in uporabnikovo natančnost. Razlog za višjo natančnost klasifikacije mejic kakor obvodne vegetacije ni očiten. Mogoče je, da se je model težje naučil prepoznati značilke obvodne vegetacije, saj je na nekaterih delih ob vodi označen tudi gozd, zaradi česar model težje določi mejo med enim in drugim razredom. Po drugi strani se tudi ob obdelanih kmetijskih

zemljiščih, kjer najdemo mejice, pojavljajo drugi razredi, ki so mejicam lahko zelo podobni (predvsem deli gozda in skupine dreves in grmovnic).

Razlikovanje med razredi smo želeli izboljšati z dodajanjem slojev oKS, oVK in oZK, ki so različno spreminjali rezultate modela RGBI. Sloj oKS ni izboljšal modela, vključujočega le podatke štirikanalnega ortofota. Rezultate klasifikacij z drugimi dodatnimi sloji je težje ovrednotiti, še najtežje vpliv oVK. Ta je po eni strani pri klasifikaciji obvodne vegetacije privedel do opaznega zmanjšanja števila lažno pozitivnih napovedi, po drugi strani pa je segmente obvodne vegetacije drobil na manjše dele kot ostali modeli. V razporeditvi lokacij, kjer je oVK izboljšal klasifikacijo in kjer jo je poslabšal, ni očitne logike, saj lokacij ne moremo deliti glede na kakršenkoli objektiven dejavnik, kot je na primer širina vodotoka. Ob nelogični razporeditvi pravih in napačnih zaznav tudi razlog za fragmentacijo ni jasen. Po drugi strani lahko ugotovimo, zakaj oVK ni še izraziteje povečal natančnosti klasifikacije obvodne vegetacije. Piksli ob vodi so bili že z modelom RGBI prepoznani kot obvodna vegetacija, kar dokazuje, da se je nevronska mreža že brez oVK sposobna naučiti pomena bližine vode za ta razred. Razlog, zakaj je bližino vode kot pomemben dejavnik nevronska mreža prepoznavala le za pas širok vsega nekaj pikslov in ne za celoten segment olesenele vegetacije, ni jasen, a prepoznavanje pomena okolice za pravilno klasifikacijo kaže na primerčnost uporabe konvolucijskih nevronskih mrež, ki tekom razvrščanja pikslov analizirajo tudi njihovo okolico.

Positiven učinek na klasifikacijo mejic je imel oZK, saj so z uporabo tega sloja mejice dosegle najvišjo izdelovalčevo natančnost. Pričakovali bi sicer, da se bo povečala tudi uporabnikova natančnost razreda mejic, ki pa je bila pri modelu RGBI-oZK nižja kakor pri modelu RGBI. Model RGBI-oZK je v razred mejic prišteval še predstavnike kakšnih drugih razredov olesenele vegetacije, ki so po lastnosti podobni mejicam. S tem se je povečalo število lažno pozitivnih rezultatov za ta razred, prisotnih predvsem na relativno podolgovatih delih gozda, nahajajočih se ob obdelanih zemljiščih (slika 8).

Zaradi izjemno nizke izdelovalčeve natančnosti so od ostalih preučevanih razredov izstopali drevoredi, ki se jih U-Net v treh izmed sedmih testov niti ni naučil klasificirati v lasten razred. V preostalih štirih primerih, ko so posamezni piksli bili pravilno klasificirani kot drevoredi, je izdelovalčeva natančnost klasifikacije najvišja pri modelu RGBI-MVK-oKS-oVK-oZK (3,7%). Redki pravilno klasificirani piksli drevoredov dokazujejo, da iz uporabljenih podatkov tega razreda verjetno na noben način ne bi mogli kakovostno prepoznati. Morda bi bilo smiselno preizkusiti, kakšna je klasifikacija v primeru dodajanja temu namenjenega podatkovnega sloja. Drevoredi se v veliki večini primerov nahajajo ob cestah ali poteh, zaradi česar bi lahko preverili, kakšni so rezultati klasifikacije ob dodajanju podatkov o oddaljenosti od njih. Rezultati klasifikacij ob dodajanju slojev oVK in oZK, ki sta sicer olajšala klasifikaciji obvodne vegetacije in mejic, izdelovalčeve in uporabnikove natančnosti teh dveh razredov nista zvišala za več 10%, zaradi česar verjetno tudi podatki oddaljenosti od cest in poti ne bi izraziteje izboljšali klasifikacije drevoredov. Ti namreč niso edini, ki se pojavljajo v bližini cest, tam najdemo tudi druge preučevane razrede (posamezna drevesa, skupine dreves in grmovnic, gozd), kar bi tudi ob dodajanju informacije o oddaljenosti od cest oteževalo razlikovanje med razredi olesenele vegetacije.

Izboljšati uporabnikovo in izdelovalčevo natančnost razredov olesenele vegetacije ni enostavno, saj so si preučevani razredi med seboj glede na spektralni podpis zelo podobni. Za izboljšanje se kažeta dva možna pristopa. Manjšo nadgradnjo preizkušene metode predstavlja drugačno obteževanje izračuna izgube, ki jo ob učenju uporablja konvolucijska nevronska mreža. V danem primeru smo pri izračunu izgube uporabili obteževanje pikslov z večjo napako, kar je ena izmed možnosti spopadanja s težavo neenakomerno velikih razredov. V nadaljnjih preizkusih bi bilo smiselno preizkusiti obteževanje posameznih manj zastopanih razredov, da modeli ne bi dobro klasificirali le gozda. Zagotovo bi takšno obteževanje povzročilo več napak pri večjih razredih, predvsem bi upadla natančnost klasifikacije gozda, vendar bi takšen pristop U-Net lahko privedel do učenja značilk, s katerimi je moč razlikovati med posameznimi razredi olesenele vegetacije.

Drugačen način zmanjševanja pomena večjih razredov je odstranjevanje ali dodajanje učnih primerov, da bi manjši razredi olesenele vegetacije predstavljali večji delež vzorcev, na katerih se model uči prepoznavanja značilnosti posameznega razreda. Že v pričujočem prispevku smo odstranili veliko

večino izrezov, popolnoma prekritih z gozdom, v nadaljnjih preizkusih metode pa bi bilo smiselno odstraniti še več izrezov, ki niso popolnoma, temveč le večinsko prekriti z njim. Obenem bi bilo smiselno odstraniti tudi kakšne izreze večinoma prekrte z razredom skupine dreves in grmovnic.

Dodajanje učnih primerov manjših razredov je v preučevanem primeru zahtevnejše. Do določene mere je mogoče podvajanje izrezov, na katerih se pojavljajo manj zastopani razredi, a preveliko število dvojnikov istega izreza povečuje možnost pretiranega prileganja modelov. To pomeni, da bi se modeli naučili dobrega prepoznavanja razredov olesenele vegetacije na območjih, ki jih tekom učenja pogosto vidijo, hkrati pa bi bili manj sposobni generalizacije. Posledično je tako naučen model manj uporaben za klasifikacijo območij, ki jih nevronska mreža med učenjem ni videla. Obenem na mnogih izrezih najdemo več kot en razred olesenele vegetacije, kar v praksi dodatno otežuje izenačevanje razredov na ta način. Možnost, da se na izrezu z manjšim razredom pojavljajo tudi piksli, pripadajoči gozdu, močno zmanjšuje nabor izrezov, ki bi jih bilo smiselno podvajati.

Ker se preučevani razredi medsebojno razlikujejo predvsem glede na obliko in okolico, v kateri jih najdemo, bi bilo metodološko sporno tudi ustvarjanje novih vzorcev, ki bi jih sestavili s prestavljanjem manjših razredov na območje, kjer tega razreda ni. Za pridobitev novih smiselnih učnih vzorcev na ta način bi morali oblikovati pravila glede lokacij, na katerih je mogoče izdelati nov učni vzorec posameznega razreda, s čimer bi delali v nasprotju z idejami umetne inteligence, pri kateri naj bi se model teh pravil naučil sam.

5 Sklep

Iz ortofota je z arhitekturo U-Net mogoče zanesljivo klasificirati oleseno vegetacijo kot celoto, težje pa je ločevati med preučevanimi razredi olesenele vegetacije. Ker se ti med seboj ne razlikujejo dovolj, se konvolucijska nevronska mreža nauči dobro klasificirati razrede z večjim številom učnih vzorcev, medtem ko je klasifikacija manjših razredov slabša, saj piksle manjših razredov izračunani modeli pripišejo večjim razredom. V vseh testiranih primerih je bila zato daleč najboljša klasifikacija gozda, ki ji je sledila klasifikacija skupin dreves in grmovnic. Pri vseh naučenih modelih je izdelovalčeva natančnost najnižja za razred drevoredi.

Najvišjo skupno natančnost klasifikacije (93,3 %) je dosegel model RGBI-MVK, s katerim smo želeli izboljšati razvrščanje obodov preučevanih razredov. Koristnost MVK je najbolj opazna, kjer je med segmenti olesenele vegetacije razdalja do nekaj 10 pikslov. Izmed slojev, ki smo jih dodali ortofotu z željo po izboljšanju klasifikacije posameznega razreda (oKS, oVK, oZK), se je najbolje izkazal sloj oZK, ki je izboljšal klasifikacijo mejic. Že model RGBI se je naučil prepoznavati obvodno vegetacijo ob ozkem pasu tik ob vodnih zemljiščih, zato je oVK v manjši meri prispeval le k zvišanju uporabnikove natančnosti klasifikacije obvodne vegetacije. Sloj oddaljenosti od grafičnih podatkov v katastru stavb ni izboljšal klasifikacije.

Natančnost klasifikacije bi bilo mogoče še najbolj zvišati s kakovostnejšim ločevanjem med posameznimi razredi olesenele vegetacije, za kar se ponujata dva pristopa. Prvi pristop je podoben uporabljenemu, le da tekom učenja dodatno obtežimo napako za manjše razrede. Na ta način bi se moral model bolje naučiti razlikovanja med razredi. Po drugi strani lahko klasifikacijo izvedemo v dveh korakih, sprva segmentiramo oleseno vegetacijo kot celoto in jo kasneje razporedimo v posamezne preučevalne razrede.

Zahvala: Članek je nastal v okviru ciljnega raziskovalnega projekta Prenova Regionalne razdelitve krajskih tipov in izjemnih krajin v Sloveniji ter njihova digitalizacija (V5-2135), ki ga sofinancirajo Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije, Ministrstvo za naravne vire in prostor, Ministrstvo za kulturo in Ministrstvo za kmetijstvo, gozdarstvo in prehrano, ter s podporo raziskovalnega programa Opazovanje Zemlje in geoinformatika (P2-0406), ki ga financira Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije.

6 Viri in literatura

- Ahlswede, S., Asam, S., Röder, A. 2021: Hedgerow object detection in very high-resolution satellite images using convolutional neural networks. *Journal of Applied Remote Sensing* 15-1. DOI: <https://doi.org/10.1117/1.JRS.15.018501>
- Barlow, M. C., Zhu, X., Glennie, C. L. 2022: Stream boundary detection of a hyper-arid, polar region using a U-Net architecture, Taylor Valley, Antarctica. *Remote Sensing* 14-1. DOI: <https://doi.org/10.3390/rs1401023410.3390/rs14010234>
- Barros, T., Conde, P., Gonçalves, G., Premevida, C., Monteiro, M., Ferreira, C. S. S., Nunes, U. J. 2022: Multispectral vineyard segmentation: A deep learning approach. *Computers and Electronics in Agriculture* 195. DOI: <https://doi.org/10.1016/j.compag.2022.106782>
- Castillejo-González, I. 2018: Mapping of olive trees using pansharpened quickbird images: An evaluation of pixel- and object-based analyses. *Agronomy* 8-12. DOI: <https://doi.org/10.3390/agronomy8120288>
- Chen, W., Xiang, H., Moriya, K. 2020. Individual tree position extraction and structural parameter retrieval based on airborne LiDAR Data: Performance evaluation and comparison of four algorithms. *Remote Sensing* 12-3. DOI: <https://doi.org/10.3390/rs12030571>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. 2009: ImageNet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami. DOI: <https://doi.org/10.1109/CVPR.2009.5206848>
- Dong, T., Shen, Y., Zhang, J., Ye, Y., Fan, J. 2019: Progressive cascaded convolutional neural networks for single tree detection with Google Earth Imagery. *Remote Sensing* 11-15. DOI: <https://doi.org/10.3390/rs11151786>
- Duelli, P. 1997: Biodiversity evaluation in agricultural landscapes: An approach at two different scales. *Agriculture, Ecosystems and Environment* 62, 2-3. DOI: [https://doi.org/10.1016/S0167-8809\(96\)01143-7](https://doi.org/10.1016/S0167-8809(96)01143-7)
- Estornell, J., Hadas, E., Martí, J., López-Cortés, I. 2021: Tree extraction and estimation of walnut structure parameters using airborne LiDAR data. *International Journal of Applied Earth Observation and Geoinformation* 96. DOI: <https://doi.org/10.1016/j.jag.2020.102273>
- Feng, W., Sui, H., Huang, W., Xu, C., An, K. 2019: Water body extraction from very high-resolution remote sensing imagery using deep U-Net and a superpixel-based conditional random field model. *IEEE Geoscience and Remote Sensing Letters* 16-4. DOI: <https://doi.org/10.1109/LGRS.2018.2879492>
- Freudenberg, M., Nölke, N., Agostini, A., Urban, K., Wörgötter, F., Kleinn, C. 2019: Large scale palm tree detection in high resolution satellite images using U-Net. *Remote Sensing* 11-3. DOI: <https://doi.org/10.3390/rs11030312>
- Garcia-Pedrero, A., Lillo-Saavedra, M., Rodriguez-Esparragon, D., Gonzalo-Martin, C. 2019: Deep learning for automatic outlining agricultural parcels: Exploiting the land parcel identification system. *IEEE Access* 7. DOI: <https://doi.org/10.1109/ACCESS.2019.2950371>
- Glušič, A., Ciglič, R., Čehovin Zajc, L. 2021: Zaznavanje terasiranih pokrajin kot semantična segmentacija digitalnega modela višin. Zbornik tridesete mednarodne Elektrotehniške in računalniške konference ERK 2021. Ljubljana.
- Golobič, M., Penko Seidl, N., Lestan, K. A., Žerdin, M., Pačnik, L., Libnik, N., Vrbajnščak, M., Vrščaj, B., Kralj, T., Turk, B., Bergant, J., Šinkovec, M. 2015: Opredelitev krajinske pestrosti in krajinskih značilnosti, pomembnih za ohranjanje biotske raznovrstnosti. Ciljni raziskovalni program (CRP) »Zagotovimo si hrano za jutri 2011–2020«: končno poročilo. Oddelek za krajinsko arhitekturo Biotehniške fakultete Univerze v Ljubljani. Ljubljana.
- Guirado, E., Tabik, S., Alcaraz-Segura, D., Cabello, J., Herrera, F. 2017: Deep-learning versus OBIA for scattered shrub detection with Google Earth Imagery, *Ziziphus lotus* as case study. *Remote Sensing* 9-12. DOI: <https://doi.org/10.3390/rs9121220>

- Guo, H., Shi, Q., Marinoni, A., Du, B., Zhang, L. 2021: Deep building footprint update network: A semi-supervised method for updating existing building footprint from bi-temporal remote sensing images. *Remote Sensing of Environment* 264. DOI: <https://doi.org/10.1016/j.rse.2021.112589>
- He, K., Zhang, X., Ren, S., Sun, J. 2015: Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas. DOI: <https://doi.org/10.1109/CVPR.2016.90>
- Hoeser, T., Bachofer, F., Kuenzer, C. 2020: Object detection and image segmentation with deep learning on Earth observation data: A review–Part II: Applications. *Remote Sensing* 12-18. DOI: <https://doi.org/10.3390/rs12183053>
- Hoeser, T., Kuenzer, C. 2020: Object detection and image segmentation with deep learning on earth observation data: A review–Part I: Evolution and recent trends. *Remote Sensing* 12-10. DOI: <https://doi.org/10.3390/rs12101667>
- Hyypä, J., Inkinen, M. 1999: Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland* 16-2.
- Jones, E. G., Wong, S., Milton, A., Sclauzero, J., Whittenbury, H., McDonnell, M. D. 2020: The impact of pan-sharpening and spectral resolution on vineyard segmentation through machine learning. *Remote Sensing* 12-6. DOI: <https://doi.org/10.3390/rs12060934>
- Khosravipour, A., Skidmore, A. K., Isenburg, M. 2016: Generating spike-free digital surface models using LiDAR raw point clouds: A new approach for forestry applications. *International Journal of Applied Earth Observation and Geoinformation* 52. DOI: <https://doi.org/10.1016/j.jag.2016.06.005>
- Kokalj, Ž., Stančič, L., Kobler, A., Noumonvi, K. D. 2020: Testiranje možnosti in izvedba kartiranja krajinskih struktur, pomembnih za biotsko raznovrstnost in blaženje podnebnih sprememb z daljinskimi zaznavanjem: končno poročilo. Elaborat, Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Gozdarski inštitut Slovenije. Ljubljana.
- Lampič, B., Kastelic, A. 2021: Prepoznavanje in evidentiranje mejic: Preverjanje različnih metod na pilotnem območju Ljubljanskega barja. *Dela* 56. DOI: <https://doi.org/10.4312/dela.56.5-51>
- Lešnik, A. 2018: Življenje v mejicah. Miklavž na Dravskem polju.
- Lisiewicz, M., Kamińska, A., Stereńczak, K. 2022: Recognition of specified errors of Individual Tree Detection methods based on Canopy Height Model. *Remote Sensing Applications: Society and Environment* 25. DOI: <https://doi.org/10.1016/j.rsase.2021.100690>
- Marsetič, A., Kanjir, U. 2022: Klasifikacija pokrovnosti z uporabo globokega učenja na časovnih vrstah podatkov PlanetScope. *Preteklost in prihodnost, GIS v Sloveniji* 16. Ljubljana. DOI: https://doi.org/10.3986/9789610506683_25
- Mazza, A., Sica, F., Rizzoli, P., Scarpa, G. 2019: TanDEM-X forest mapping using convolutional neural networks. *Remote Sensing* 11-24. DOI: <https://doi.org/10.3390/rs11242980>
- Mihevc, A., Mihevc, R. 2021: Morphological characteristics and distribution of dolines in Slovenia: A study of a lidar-based doline map of Slovenia. *Acta Carsologica* 50-1. DOI: <https://doi.org/10.3986/ac.v50i1.9462>
- Muhammad Ali, P., Faraj, R. 2014: Data Normalization and Standardization: A Technical Report. *Machine Learning Technical Reports* 2014-1. DOI: <https://doi.org/10.13140/RG.2.2.28948.04489>
- Penko Seidl, N., Golobič, M. 2020: Quantitative assessment of agricultural landscape heterogeneity. *Ecological Indicators* 112. DOI: <https://doi.org/10.1016/j.ecolind.2020.106115>
- Ronneberger, O., Fischer, P., Brox, T. 2015: U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham. DOI: https://doi.org/10.1007/978-3-319-24574-4_28
- Sadiq, R., Akhtar, Z., Imran, M., Ofli, F. 2022: Integrating remote sensing and social sensing for flood mapping. *Remote Sensing Applications: Society and Environment* 25. DOI: <https://doi.org/10.1016/j.rsase.2022.100697>

- Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglinets, Y., Herrera, F. 2019: Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning. *Remote Sensing* 11-6. DOI: <https://doi.org/10.3390/rs11060643>
- Sylvain, J.-D., Drolet, G., Brown, N. 2019: Mapping dead forest cover using a deep convolutional neural network and digital aerial photography. *ISPRS Journal of Photogrammetry and Remote Sensing* 156. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.07.010>
- Šumrada, T., Rac, I., Juvančič, L., Erjavec, E. 2020: Ohranjanje krajinskih značilnosti in njihovo vključevanje v ukrepe slovenske kmetijske politike. *Geografski vestnik* 92-1. DOI: <https://doi.org/10.3986/GV92103>
- Weinstein, B. G., Marconi, S., Bohlman, S., Zare, A., White, E. 2019: Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing* 11-11. DOI: <https://doi.org/10.3390/rs11111309>
- Yu, M., Rui, X., Xie, W., Xu, X., Wei, W. 2022: Research on automatic identification method of terraces on the Loess Plateau based on deep transfer learning. *Remote Sensing* 14-10. DOI: <https://doi.org/10.3390/rs14102446>
- Zheng, J., Li, W., Xia, M., Dong, R., Fu, H., Yuan, S. 2019: Large-scale oil palm tree detection from high-resolution remote sensing images using faster-RCNN. 2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama. DOI: <https://doi.org/10.1109/IGARSS.2019.8898360>

7 Summary: Woody vegetation detection with the U-Net convolutional neural network

(translated by authors)

Various structures of woody vegetation are of great ecological importance, especially in agricultural landscapes. They increase the heterogeneity of the landscape and therefore provide many ecosystem services that would be lacking without them. It is therefore worrying that, in the course of intensifying agricultural production, woody vegetation is often removed in order to increase arable land. In this paper, a method for mapping individual trees, groups of trees and shrubs, tree rows, woodlands, hedges, riparian vegetation and trees in orchards (woody vegetation classes) was tested. These landscape features are considered important for the conservation of biodiversity in the landscape, but various stakeholders have identified a lack of high quality data on their extent. Since these same stakeholders believe that remote sensing data offers an opportunity for feasible mapping of landscape features, we propose an automated approach using a convolutional neural network U-Net.

We tested the approach on 20 different areas in Slovenia, where the analysed landscape features were manually digitised using orthophoto and canopy height model (CHM) data derived from airborne laser scanning. Each area was divided into two halves, one half containing training data and the other half containing test data. The training data was cropped to create 128×128 pixel patches with a 50% overlap. As the forest made up an overwhelming proportion of the training data, only patches less than 100 m away from agricultural land were selected for training. Thus, the training area covered 14.5 km², while the test area, which was not cropped into patches, covered 22.4 km². Nevertheless, the forest covered more training area (494 ha) than all other analysed classes combined, with the second largest class being groups of trees and shrubs (62 ha).

National orthophotos with a resolution of 0.5 m from 2014 and 2015 were used as primary data. Additional layers were added to see if they provided useful information to improve the classification of the four-band orthophoto classification (RGBI). CHM was added to improve the accuracy of the created segment area (RGBI-CHM classification). Distance to graphic objects in the building cadastre was added to improve the classification of trees in orchards (RGBI-dBC classification), as these are often located close to built-up areas. The distance to cadastral boundaries in the land cadastre was added to improve the classification of hedges (RGBI-dLC classification). The distance to lines in the water cadastre was added to improve the classification of riparian vegetation (RGBI-dWC

classification). In addition, only three-band orthophoto (RGB classification) and all the above layers (RGBI-CHM-dBC-dLC-dWC classification) were tested.

The U-Net model was trained with 13,305 patches, 90% of which were used for training and the rest for validation. The backbone architecture used was the ResNet34 convolutional network pre-trained with ImageNet, with training of backbone architecture layers allowed. The model was trained using the ArcGIS Pro 3.1.0 deep learning extension on a computer with an Nvidia Quadro M4000 graphics card with 8 GB of memory. The number of epochs was 20, the learning rate was 0.001 and the batch size was 16. Cross entropy was used for loss calculation, with more challenging to classify pixels weighted more during training to mitigate the effects of an unbalanced dataset. Classification quality was assessed using Overall Accuracy (OA) and per class User's (UA) and Producer's (PA) Accuracies in the test area.

The model has no difficulty in classifying woody vegetation as a whole; however, distinguishing between different classes of woody vegetation appears to be more difficult. The highest UA and PA values in all tests were achieved by the forest and other classes. As these two classes covered most of the studied areas, the OA reached between 92.3% and 93.3% (the last value was achieved by RGBI-CHM). The highest UA was achieved by the other (RGBI-CHM classification) and forest (RGBI-dWC classification) classes, while the highest PA was achieved by forest (RGBI-CHM). The UAs are higher than the PAs for all woody vegetation classes except forest, which shows that false negatives are much less of a problem than false positives. Thus, the most difficult task seems to be classifying the woody vegetation pixels into the correct woody vegetation class. In all test results, the forest extends over the pixels of other woody vegetation classes. While the forest stands out from the other woody vegetation classes due to its high UAs and PAs, the exact opposite can be observed for the trees in rows. Three different tests were unable to classify any pixels in this class, while the highest PA in the other tests was 3.7% (RGBI-CHM-dBC-dLC-dWC). The same classification provided the highest PA for riparian vegetation, while groups of trees and shrubs achieved the highest PA with RGBI-CHM, hedges with RGBI-dLC and trees in orchards with RGBI-dWC.

The hedges, which achieved the highest PA with RGBI-dLC, show that the addition of data to distinguish between classes of woody vegetation can be helpful. The addition of cadastral data helped the model to understand that hedges are linear features near agricultural land and parcel boundaries. On the other hand, this resulted in parts of similar woody vegetation classes being classified as hedges. However, even these misclassifications seem logical when considering which parts of features of other classes were recognised as hedges. Other additional data besides the RGBI-CHM did not bring the desired improvements. While CHM allowed for a better classification of woody vegetation overall, the model achieved this by improving the classification of forest and groups of trees and shrubs that were adequately classified without the CHM as well. RGBI-CHM led to a significant reduction in the PA of hedges and riparian vegetation. Surprisingly, RGBI-dWC did not lead to an improvement in the PA of riparian vegetation. The reason for this could be the ability of RGBI classification to correctly recognise riparian vegetation as woody vegetation near water bodies. However, it could not recognise the features of riparian vegetation as a whole, which resulted in the pixels of woody vegetation near water being classified as riparian vegetation, while the rest of the features were classified into other woody vegetation classes. RGBI-dWC was also unable to recognise the feature as a whole; however, this was further improved with RGBI-CHM-dBC-dLC-dWC.

All woody vegetation classes were also combined to test whether the binary classification (woody vegetation and other classes) provided accurate woody segments. The OA was highest in this case with RGBI-CHM, reaching 95.5%. However, the OA was also above 94% for all other data combinations. RGBI-CHM improved the results of RGBI, especially at the edges of the woody vegetation classes. CHM made it easier for the model to recognise whether there is space between two woody vegetation features. The binary classification of woody vegetation achieved at least 95% UA and PA in all cases, proving that distinguishing between woody vegetation classes is the most important remaining task. One way to improve woody vegetation classification in the future is to use a weighted loss function during model

learning, which forces the model to classify smaller classes better. Another approach would be a two-stage classification, where a binary segmentation of woody vegetation segments is performed first and each segment is later classified into one of the woody vegetation classes.