

VPLIV POLOŽAJNE NESKLADNOSTI PODATKOV DALJINSKEGA ZAZNAVANJA NA KLASIFIKACIJO DREVES

Adam Gabrič

Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti, Inštitut za antropološke in prostorske študije; Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo
adam.gabric@zrc-sazu.si, ORCID: <https://orcid.org/0009-0008-4816-2881>

dr. Dejan Grigillo

Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo
dejan.grigillo@fgg.uni-lj.si, ORCID: <https://orcid.org/0000-0002-0049-3859>

dr. Žiga Kokalj

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

DOI: https://doi.org/10.3986/9789610508885_10

UDK: 528.8:582.091(497.4)

IZVLEČEK

Vpliv položajne neskladnosti podatkov daljinskega zaznavanja na klasifikacijo dreves

Objekti nad tlemi so na ortofotu glede na lasten dejanski položaj zamaknjeni. Zanimalo nas je, ali in kako zamik vpliva na rezultate klasifikacije dreves ob hkratni uporabi ortofota in podatkov aerolaserskega skeniranja, pri katerih zamika ni. Konvolucijsko nevronska mrežo PSPNet smo naučili prepoznavanja krošenj iz združenih ortofota in modela višin krošenj, narejenega iz podatkov aerolaserskega skeniranja, ter vsakega posebej. Preverili smo, kakšna je natančnost določanja obodov krošenj posameznih dreves. Za 111 testnih drevesnih krošenj ta ni korelirala z zamikom krošenj na ortofotu, zato ne moremo potrditi, da zamik vhodnih podatkov vpliva na natančnost klasifikacije. Po drugi strani zaradi zamika nekateri vhodni podatki niso položajno skladni z maskami za učenje nevronske mreže, kar bi lahko predstavljalo težavo pri bolj zahtevni klasifikaciji (na primer klasifikaciji drevesnih vrst).

KLJUČNE BESEDE

ortofoto, aerolasersko skeniranje, Ciklično aerofotografiranje Slovenije, položajna neskladnost, klasifikacija

ABSTRACT

Effects of position incongruence of remote sensing data on tree classification

On the orthophoto, objects above the ground are displaced compared to their true position. This study aims to determine whether the displacement affects tree classification results when using both orthophoto and aerolaser scanning data, which are not affected by the displacement. We trained the convolutional neural network PSPNet to recognize tree crowns using orthophoto, canopy height model from aerial laser scanning data and a combination of both. The classification accuracy of the tree crowns for 111 test trees did not correlate with the orthophoto displacement. Although the displacement had no effect on the classification results, the findings suggest that the incongruence of the segmentation masks and the model input data could pose a challenge for a more complex classification task, such as tree species classification.

KEY WORDS

orthophoto, airborne laser scanning, Cyclic Aerial Survey of Slovenia, positional incongruence, classification

1 Uvod

Podatki aerolaserskega skeniranja Slovenije in državni ortofoto so najbolj podrobni podatki daljinskega zaznavanja, ki so prosto dostopni in razpoložljivi za ozemlje celotne države. Ortofoto in aerolasersko skeniranje se uporabljata za različne namene, mogoča pa je tudi njuna hkratna uporaba, ob čemer se je treba zavedati njenega različnega nastanka, ki vpliva na položajno neskladnost elementov nad tlemi. Zanimalo nas je, ali ob souporabi obeh podatkovnih virov položajna neskladnost vpliva na natančnost samodejne zaznave dreves s konvolucijsko nevronske mreže.

Državni ortofoto je izdelan iz fotografij Cikličnega aerofotografiranja Slovenije (CAS). Pri prevzorčenju fotografij iz centralne projekcije v pravokotno projekcijo, v kateri je izdelan ortofoto, se kot projekcijska ploskev uporabi digitalni model terena (DMT). Zaradi tega so vsi objekti, ki ležijo nad površjem Zemlje horizontalno premaknjeni (Kraus 2007; Triglav Čekada 2016), kar je najbolj očitno na primeru zvrnjenih stavb. Velikost zamika je odvisna od višine objekta in kota, pod katerim je objekt posnet. Končni ortofoto je mozaik večjega števila fotografij, ki se stikajo na šivnih linijah. Te so izbrane tako, da so šivi med sosednjimi fotografijami neopazni, zato za izdelavo ortofota niso nujno izbrane fotografije, na katerih so objekti zvrnjeni najmanj (Triglav Čekada 2016).

Podobnih položajnih netočnosti podatki aerolaserskega skeniranja nimajo. Laserski skener omogoča merjenje razdalj do objektov, v primeru aerolaserskega skeniranja je nameščen na letalu in meri razdalje do objektov na površju Zemlje. Ob razdalji skener zabeleži še kot skeniranja, kar se združi s podatki o poziciji in usmerjenosti letala ter orientaciji senzorja. Rezultat obdelave zabeleženih podatkov je oblak točk z znanimi koordinatami X, Y, Z, intenziteto vrnjenega odboja, lahko tudi redom in številom odbojev posameznega laserskega pulza, kotom pulza, razredom klasifikacije in podobno (Oštir 2006; Petrie in Toth 2018).

2 Metode dela

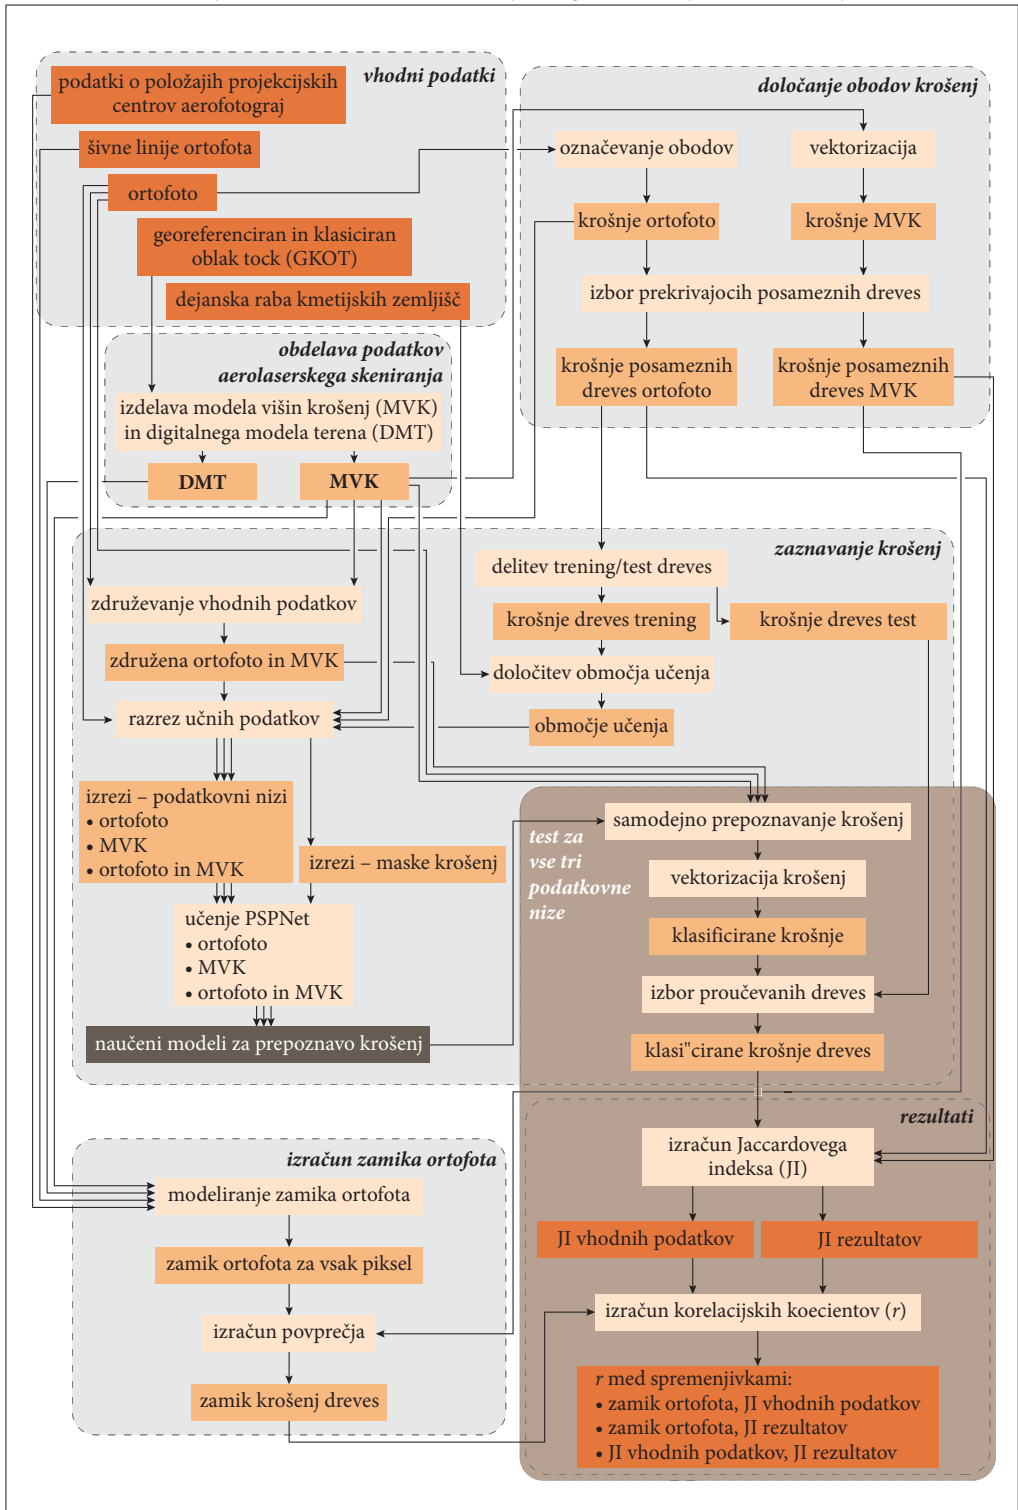
Potek dela je pregledno prikazan na sliki 1. V prvem koraku smo iz georeferenciranega in klasificiranega oblaka točk (GKOT) izdelali model višin krošenj (MVK) (poglavje 2.1). Obode krošenj (gozd, skupine dreves, mejice, posamezna drevesa ...) iz MVK smo pridobili z vektorizacijo binarne maske krošenj na MVK, medtem ko smo obode krošenj na ortofotu označevali ročno. Pri ročnem označevanju obodov krošenj iz ortofota smo posebej označevali drevesa, katerih krošnje se ne stikajo s krošnjami sosednjih dreves (posamezna drevesa). Delež krošnje, ki je napačno klasificiran zaradi zamika ortofota, bi moral biti največji za najmanjše krošnje. Vpliv neskladnosti podatkov smo zato preverjali le za posamezna drevesa, prepoznana tako na ortofotu kot tudi na MVK (poglavje 2.2).

Izbrane krošnje posameznih dreves smo uporabili za delitev na podatke za učenje konvolucijske nevronske mreže Pyramid Scene Parsing Network – PSPNet (Zhao s sodelavci 2017) in testne podatke. Da smo povečali količino podatkov za učenje konvolucijske nevronske mreže, smo za učne vzorce za trening uporabili tako drevesa kot njihovo okolico (območje učenja) (poglavje 2.3). S tem smo v učne vzorce dodali krošnje, ki se pojavljajo na robu gozda, kot del mejic, skupin dreves in podobno. Na podlagi podatkov o dejanski rabi zemljišč (Dejanska raba kmetijskih zemljišč ... 2014) smo odstranili površine, ki bi lahko slabšale prepoznavo posameznih dreves (poglavje 2.3).

Območje učenja smo razdelili na izreze, ki so sestavljeni iz binarnih mask krošenj ter podatkovnih nizov. Maske krošenj so bile generirane z rastriranjem ročno označenih krošenj na ortofotu. Podatkovni nizi so bili trije: ortofoto, MVK, združena ortofoto in MVK. Na vsakem podatkovnem nizu smo konvolucijsko nevronske mreže PSPNet učili prepoznave krošenj, s čimer smo dobili tri naučene modele (model, naučen na ortofotu, model, naučen na MVK, model, naučen na združenih ortofotu in MVK) (poglavje 2.3).

Slika 1: Potek dela. ► (str. 121)

Vpliv položajne neskladnosti podatkov daljinskega zaznavanja na klasifikacijo dreves



Za izračun zamika ortofota smo pridobili šivne linije ortofota (Šivne linije 2014a; Šivne linije 2014b; Šivne linije 2014c; Šivne linije 2014č; Šivne linije 2014d; Šivne linije 2014e; Šivne linije 2014f; Šivne linije 2015a; Šivne linije 2015b) in podatke o položajih projekcijskih centrov aerofotografij ortofota (Aerofotografije CAS 2014; Aerofotografije CAS 2015), iz GKOT pa smo izračunali MVK in DMT (poglavje 2.4). Modeliran zamik je bil določen za vsak piksel MVK. Izračunali smo povprečen zamik posameznih dreves, vektoriziranih iz MVK (poglavje 2.4). Povprečne zamike posameznih dreves smo uporabili za ugotavljanje vpliva zamika na kakovost zaznavanja obodov krošenj.

Test smo pričeli s prepoznavanjem vseh krošenj na proučevanih območjih z naučenimi modeli. Prepoznane krošnje smo vektorizirali in izbrali krošnje, ki se dotikajo krošenj posameznih dreves za test. Za vsako drevo smo izračunali Jaccardov indeks (JI) klasificirane krošnje in krošnje posameznega drevesa, prepoznanega na ortofotu (JI rezultatov) (poglavje 2.3). Izračunali smo tudi razmerje med presekom in unijo krošenj posameznih dreves, digitaliziranih iz ortofota, in krošenj posameznih dreves, vektoriziranih iz MVK (JI vhodnih podatkov) (poglavje 2.2). Za vsak naučen model smo z izračunom Pearsonovega koeficienta (r) (Illowsky s sodelavci 2013) preverili, kakšna je korelacija med zamikom in JI rezultatov ter med JI vhodnih podatkov in JI rezultatov. Za boljše razumevanje zamika smo izračunali tudi r med zamikom ortofota in JI vhodnih podatkov.

2.1 Podatki

Vpliv zamika med državnim ortofotom in podatki aerolaserskega skeniranja Slovenije na klasifikacijo dreves smo preverjali na 18 proučevanih območjih. Zaradi čim boljšega ujemanja podatkov smo stremeli k čim manjši časovni razliki med njimi. Aerolasersko skeniranje so izvedli večinoma v letih 2014 in 2015 (Triglav Čekada in Bric 2015), zato smo uporabili štiri kanale državnega ortofota (RGB iz DOF050, bIIR iz DOF050IR) iz istih let (prostorska ločljivost 0,5 m). Uporabili smo podatke, zajete z največ enoletnim razmikom, izjema so bili podatki za proučevano območje Koštabona (preglednica 1). Zaradi kratkega obdobja med zajemom enih in drugih podatkov, predpostavljamo, da so imele krošnje v času zajema podatkov še vedno podoben obseg.

Iz GKOT smo za proučevana območja izdelali MVK in DMT. Za izdelavo MVK smo uporabili pristop, ki ga predlagajo Khosravipour, Skidmore in Isenburg (2016). Pri tem smo izdelali MVK brez nepotrebnih lukenj (angleško *pits*) in špic (angleško *spikes*) v krošnjah. Za izdelavo smo uporabili orodje LAsTools (različica 230330). GKOT smo sprva normalizirali, da smo v oblaku točk podatke o nadmorskih višinah zamenjali s podatki o višini nad tlemi. Pri tem smo odstranili nikoli klasificirane točke, neklasificirane točke in nizke točke oziroma šum (razredi 0, 1, 7). Za izračun višine nad tlemi smo uporabili radij 10 m. V naslednjem koraku smo oblak točk redčili, obdržali smo najvišjo točko za vsak kvadrat velikosti 25×25 cm. Vsako točko smo osemkrat podvojili v krogu z radijem 0,1 m, s čimer smo simulirali širino laserskega pulza in izdelali nabor točk, primernih za izdelavo MVK. Iz pridobljenih točk, klasificiranih kot nizka, srednja in visoka vegetacija (razredi 3, 4, 5), smo interpolirali MVK s prostorsko ločljivostjo 0,5 m. Pred rastriranjem MVK se iterativno izdeluje mreža nepravilnih trikotnikov, sprva iz najvišjih točk, nato po višinskih pasovih. Dolžino najdaljše stranice trikotnikov in višinske pasove smo omejili na 3 m. Končno trikotniško mrežo smo rastrirali, ob čemer smo pikslom, ki so bili manj kot 2 m nad tlemi, pripisali vrednost 0.

2.2 Izbor proučevanih dreves

Krošnje na ortofotu smo prepoznali z vizualno fotointerpretacijo, pri čemer smo posebej označevali posamezna drevesa. Ob morebitni nejasnosti (na primer zaradi senc) smo uporabili še MVK. Krošnje iz aerolaserskih podatkov smo pridobili z izdelavo maske in vektorizacijo MVK. Ročno označene obode krošenj posameznih dreves smo rastrirali in ponovno vektorizirali, da so se tako obodi krošenj, modelirani iz MVK, kot tudi obodi krošenj, zarisani na ortofoto, prekrivali z robovi pikselov uporabljenih MVK in ortofota.

Preglednica 1: Datumi zajema uporabljenih podatkov.

proučevano območje	aerolasersko skeniranje	aerofotografiranje
Bukovnica	31. marec, 1. april 2014	21. maj 2014
dolina Krke	12., 14. in 15. marec 2014	22. maj 2014
Jeruzalem	31. marec, 1. april 2014	20. maj 2014
Koštabona	8. marec, 8. april 2011	8. avgust 2014
Lendavske gorice	1. april 2014	20. maj 2014
Lipica	14. februar 2014	20. julij 2014
Ljubljansko barje	8. marec 2015	6. maj 2014
Logarska dolina	29. in 30. avgust, 12. oktober 2014	12. junij, 2., 5., 6. in 7. julij 2015
Otlica	30. in 31. oktober 2014	29. avgust 2014
Petanjci	31. marec, 1. april 2014	21. maj 2014
Posavsko hribovje	20. marec 2014	20. maj 2014
Resnik-Skomarje	11., 13. in 19. oktober 2014, 28. januar 2015	22. maj 2014
Senožeče	14. in 24. februar 2014	19. julij 2014
Tivoli	8. marec 2015	6. maj 2014
Tomaj	14. februar 2014	19. julij 2014
Trenta	17. avgust, 8. september 2014	5. julij 2015
Uniše	28. januar 2015	20. maj 2014
Velika planina	29. avgust, 19. oktober 2014	2. julij 2015

Vpliv zamika ortofota na natančnost določanja obodov krošenj smo preverjali na posameznih drevesih, katerih krošnje so bile od ostalih krošenj oddaljene vsaj 10 m. To je veljalo tako za ročno označene krošnje, digitalizirane iz ortofota, kot tudi za krošnje, vektorizirane iz MVK. S tem smo zagotovili, da sosednje krošnje ne vplivajo na morebitno napačno določen obod krošnje v rezultatih. Krošnje MVK smo pregledali in odstranili tiste, pri katerih je bil obod zaradi vpliva stavb, daljnovodov ali drugih objektov nad tlemi napačno določen.

Vsem zahtevam je ustrezalo 239 krošenj posameznih dreves. Izmed teh smo jih 120 uporabili za učne modele za zaznavo krošenj, ostale smo uporabili za analizo vpliva zamika na natančnost določanja obodov krošenj. Izmed dreves za analizo vpliva zamika smo naknadno odstranili 8 dreves, saj je bilo ob pogledu na klasificirane krošnje jasno, da sta na določanje oboda krošnje negativno vplivala temno zelena trava in nizko grmičevje v okolici drevesa. V testni množici za analizo vpliva zamika je bilo torej 111 dreves.

2.3 Zaznavanje krošenj

Ker je bilo dreves za učenje PSPNet le 120 (skupna površina krošenj 6413 m²), smo učno množico povečali s krošnjami dreves v mejicah, skupinah dreves, obvodni vegetaciji ... S tem smo površino krošenj v učni množici povečali za približno 100-krat. Območje učenja smo pridobili v radiju 200 m okoli učnih dreves, pri čemer smo izločili območja gozda, območja suhih odprtih zemljišč s posebnim rastlinskim pokrovom in območja odprtih zemljišč brez ali z nepomembnim rastlinskim pokrovom, kjer se krošnje večinoma pojavljajo v obliki nizkega grmičevja. Le-to ima podoben spektralni podpis kot drevje, a različno višino, kar bi lahko negativno vplivalo na sposobnost prepoznave dreves. Gozd smo iz učne množice izločili, da se model ne bi naučil prepoznavati le večjih površin sklenjenih krošenj. Na območjih učenja ni bilo dreves, ki smo jih uporabili za testiranje rezultatov.

Nize podatkov območij učenja smo razrezali na kvadratne izreze s stranicami dolgimi 64 pikselov (32 m) in s 50 % prekrivanjem. Maske krošenj so bile binarne. Za prepoznavanje krošenj smo uporabili konvolucijsko nevronska mrežo PSPNet s hrbtencično arhitekturo ResNet34 (He s sodelavci 2016). Ta je bila predhodno naučena na slikovni bazi ImageNet (Deng s sodelavci 2009). Ob našem delu smo omogočili učenje vseh slojev hrbtencične arhitekture. Uporabili smo implementacijo PSPNet v programu ArcGIS Pro (različica 3.1.0). Delo je potekalo na računalniku z grafično kartico Nvidia RTX A4500 z 20 GB pomnilnika. Število epoh je bilo 50, stopnja učenja 0,001 in velikost paketa 64.

2.4 Zamik ortofota

Za izračun zamika visokih objektov na ortofotu smo uporabili MVK, ob čemer se zavedamo vnosa napak iz izdelkov aerolaserskega skeniranja. Menimo, da so uporabljeni podatki aerolaserskega skeniranja za izvedeni izračun dovolj točni, čeprav je ocena kakovosti zajema lidarskih podatkov močno otežena (Habib 2018a). Za podatke aerolaserskega skeniranja Slovenije so ocenili, da sta višinska in horizontalna točnost kontrolnih točk boljši od predpisanih 15 cm za višinsko in 30 cm za položajno točnost (Triglav Čekada in Bric 2015).

Za izračun zamika ortofota smo uporabili koordinate projekcijskih centrov aerofotografij, iz katerih je izdelan ortofoto, in šivne linije ortofota, ki smo jih pridobili od Geodetske uprave Republike Slovenije. Potrebovali smo še DMT, ki smo ga v prostorski ločljivosti 0,5 m interpolirali iz GKOT. Pri tem smo uporabili točke, klasificirane kot tla (razred 2).

Z enačbo 1 smo za vsak piksel izračunali višino projekcijskega centra nad tlemi (H_i), H_p je nadmorska višina projekcijskega centra v trenutku zajema posnetka, DMT_i pa vrednost piksla i na digitalnem modelu terena (slika 2).

$$\text{Enačba 1: } H_i = H_p - DMT_i$$

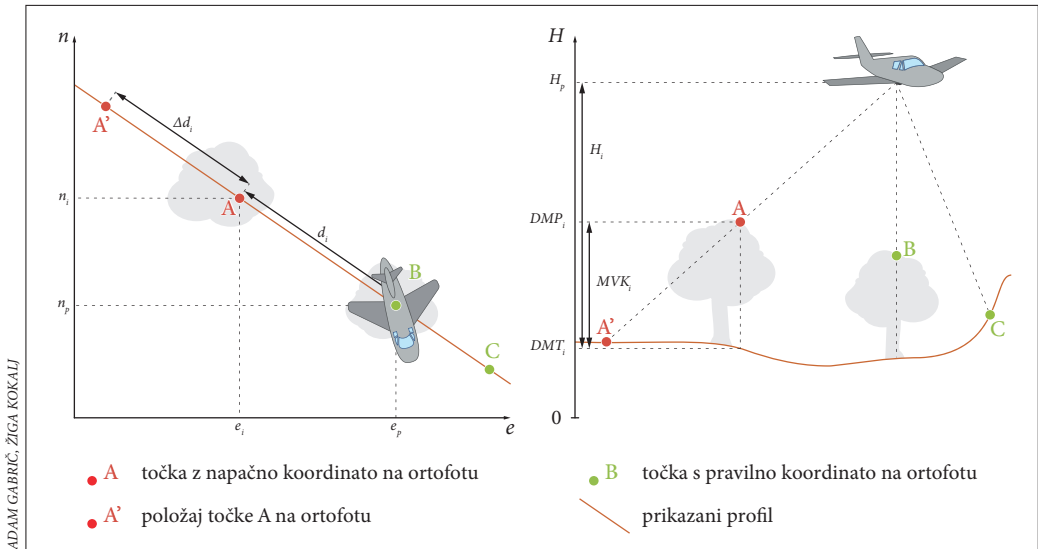
$$\text{Enačba 2: } d_i = \sqrt{(e_p - e_i)^2 + (n_p - n_i)^2}$$

Z enačbo 2 smo izračunali evklidsko razdaljo med središčem piksla i in položajem projekcijskega centra v horizontalnem koordinatnem sistemu (d_i). V enačbi 2 so e_p koordinata x projekcijskega centra v trenutku zajema posnetka, e_i koordinata x središča posameznega piksla, n_p koordinata y projekcijskega centra v trenutku zajema posnetka in n_i koordinata y središča posameznega piksla. Vse koordinate so bile v koordinatnem sistemu D96/TM. Rezultate enačb 1 in 2 smo uporabili za izračune zamika ortofota v metrih (Δd_i) (enačba 3).

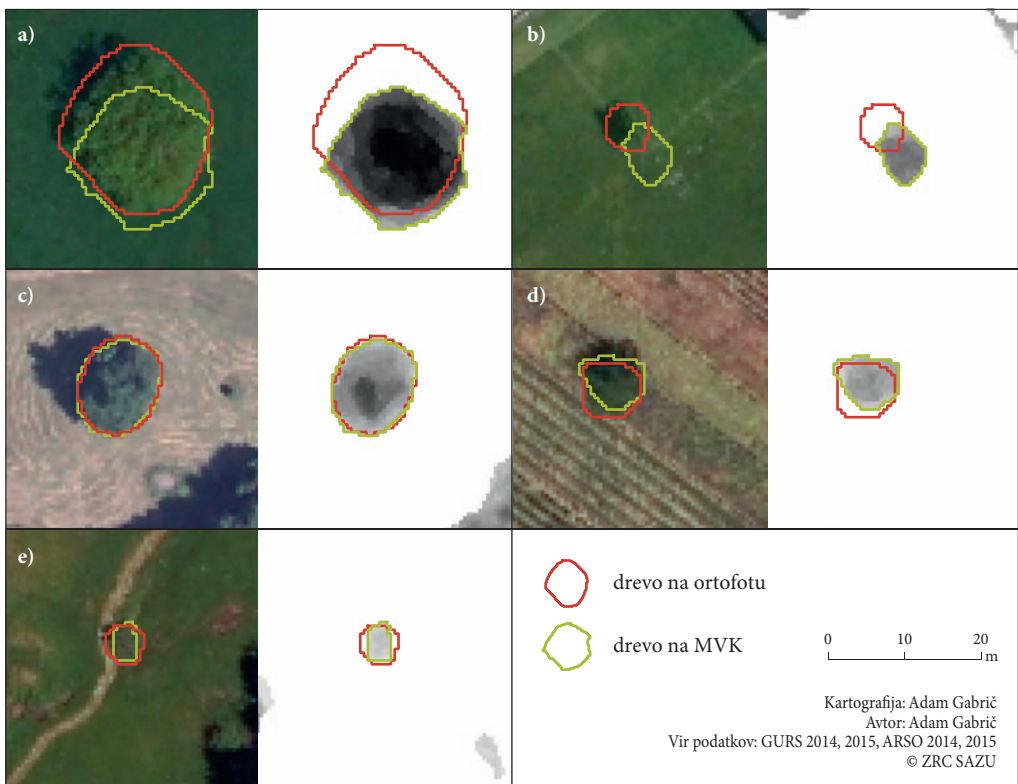
$$\text{Enačba 3: } \Delta d_i = \frac{MVK_i \cdot d_i}{H_i - MVK_i}$$

3 Analiza vhodnih podatkov


Med analiziranimi drevesi je najbolj zamaknjeno drevo višine 19,4 m na Ljubljanskem barju, zamik ortofota znaša 5,2 m, IoU vhodnih podatkov pa 0,58 (slika 3a). Mnogo manjši IoU vhodnih podatkov (0,15) ima drevo v naselju Skomarje z manjšim obsegom krošnje, višino 11,1 m in zamikom ortofota 3,4 m (slika 3b). Najvišji JI vhodnih podatkov je 0,91, dosega ga drevo višine 14,4 m v Trenti (slika 3c). V poprečju JI vhodnih podatkov znaša 0,60, mediana je 0,62. JI vhodnih podatkov 0,5 presega 87 dreves (36 %), 0,75 pa le 17 (7 %). Glede na JI vhodnih podatkov sta povprečni drevesi na slikah 3d in 3e (JI vhodnih podatkov 0,62 in 0,60), vendar pa je razlog za takšen JI različen. Medtem ko je drevo na sliki 3d na ortofotu zamaknjeno proti jugu, je razlog za različen obod krošenj drevesa na sliki 3e opazno večja krošnja na ortofotu.



Slika 2: Izvor zamika ortofota ter izračun zamika ortofota (levo: tlorisni prikaz, desno profilni prikaz).



Slika 3: Proučevana drevesa na ortofotu in MVK.



Slika 4: Odnos med JI vhodnih podatkov in zamikom ortofota.

Korelacije med JI vhodnih podatkov in zamikom ortofota ($r = -0,00$, p -vrednost = 0,99) ni. Kljub temu je opazno, da pri večjih zamikih drevesa ne dosegajo najvišjih JI vhodnih podatkov (slika 4). Medtem ko je pri nižjih zamikih JI vhodnih podatkov razpršen, pri zamiku nad 3 m ne presega 0,8. Z večanjem zamika ortofota torej največji teoretični JI vhodnih podatkov pada, vendar je iz razpršenosti grafa očitno, da zamik ni edini dejavnik, ki vpliva na skladnost obeh uporabljenih podatkovnih slojev.

4 Rezultati klasifikacij

Korelacije med zamikom ortofota in JI rezultatov ni, še največjo je dosegel model, naučen na ortofotu, kar ni smiselno, saj smo vse modele učili in njihovo natančnost preverjali z maskami, ki smo jih ročno določili iz ortofota. Pri modelu, naučenem na ortofotu, torej ni bilo zamika niti med posameznimi sloji v podatkovnem nizu, niti med maskami in podatkovnim nizom.

Podobno korelacijo med zamikom ortofota in JI rezultatov kakor model, naučen na ortofotu, je dosegel še model, naučen na združenih ortofotu in MVK. Model, naučen le na MVK, ni izkazoval nobene povezave med zamikom in JI rezultatov (preglednica 2), čeprav je pri njem celoten podatkovni niz zamažen glede na maske krošenj.

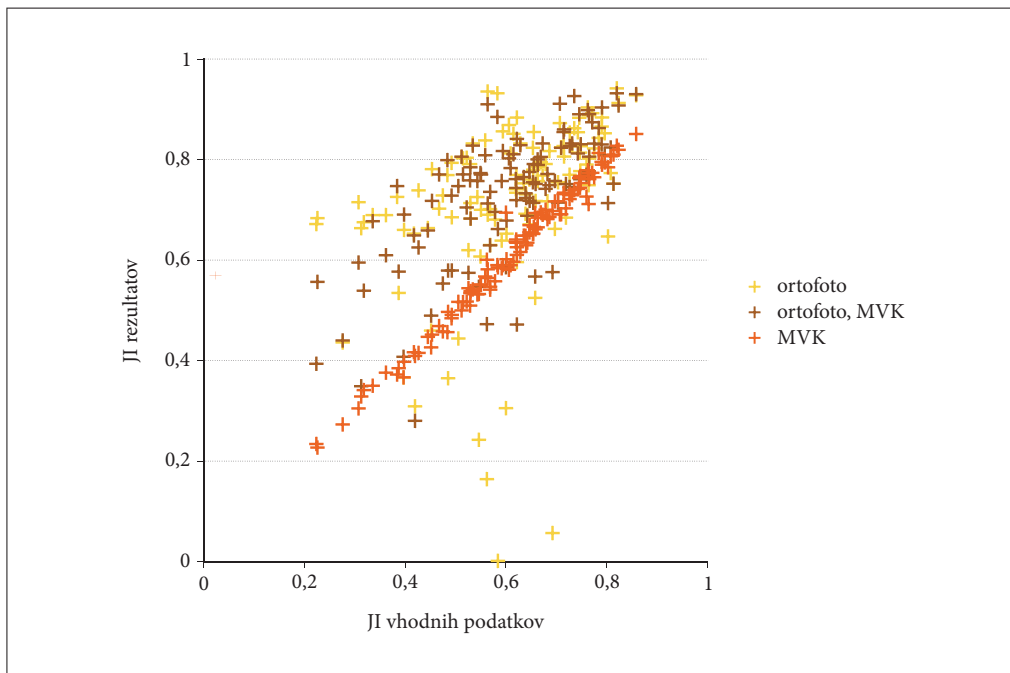
Natančnost določanja obodov krošenj posameznih dreves smo preverili s srednjo vrednostjo JI rezultatov posameznih modelov (preglednica 2). Najboljši rezultat je dosegel model naučen na združenih ortofotu in MVK, vendar je bila razlika v primerjavi z modelom, naučenim le na ortofotu, zanemarljiva. Nižje srednje vrednosti JI rezultatov za model, naučen z MVK, ne moremo imeti za dokaz, da se iz MVK model ne more naučiti prepoznavati krošenj enako kakovostno kakor iz ortofota, saj smo vse rezultate preverjali s posameznimi drevesi, prepoznanimi na ortofotu. Iz nižje srednje vrednosti JI rezultatov tega modela in majhne razlike med srednjima vrednostma ostalih dveh lahko ugotovimo, da MVK

ob uporabi mask, izdelanih iz krošenj, prepoznanih na ortofotu, ni mogel izrazito prispevati k izboljšanju določanja oboda krošenj posameznih dreves na ortofotu.

Model, naučen na MVK, je dosegal izjemno visoko korelacijo JI vhodnih podatkov in JI rezultatov, povezavo med tema spremenljivkama lahko potrdimo tudi za model, naučen na združenih ortofotu in MVK (preglednica 2). Celotne korelacije teh dveh spremenljivk sicer ne moremo pripisati zgolj povezavi zamika in natančnosti določanja obodov krošenj, saj se rahla povezanost kaže tudi za model, naučen na ortofotu. Takšno povezanost teh dveh spremenljivk lahko pripišemo odvisnosti JI od velikosti krošnje, višja korelacija pa zagotovo kaže na odvisnost JI rezultatov od JI vhodnih podatkov.

Preglednica 2: Natančnost določanja oboda krošenj posameznih dreves ter stopnja korelacije med zamikom ortofota in natančnostjo določanja obodov krošenj treh naučenih modelov.

podatkovni niz	srednja vrednost JI rezultatov	r med zamikom ortofota in JI rezultatov (p-vrednost)	r med JI vhodnih podatkov in JI rezultatov (p-vrednost)
ortofoto	0,72	0,20 (0,03)	0,39 (0,00)
MVK	0,61	-0,01 (0,94)	0,99 (0,00)
združena ortofoto in MVK	0,73	0,17 (0,07)	0,69 (0,00)



Slika 5: Odnos med JI vhodnih podatkov in JI rezultatov vseh treh modelov.

5 Diskusija

Čeprav jasne korelacije med natančnostjo določanja obodov krošenj posameznih dreves in zamikom ortofota ni, rezultati kažejo na pomen učnih vzorcev, zajetih glede na podatke, uporabljene v procesu klasifikacije. Korelacija med JI vhodnih podatkov in JI rezultatov za klasifikacijo z MVK dokazuje, da je bil model sposoben kot krošnje prepoznati le tisti del segmenta, zarisanega na ortofoto, ki se je prekrival z drevesom na MVK. Model se je naučil prepoznati krošnje glede na uporabljene podatke, čeprav se je tekom učenja učil krošnje prepoznavati v njenem obsegu iz ortofota. Neskladnost mask krošenj in podatkovnih nizov se ni izkazala za pretirano težavo, saj je model, naučen na MVK, sposoben prepoznavati krošnje. Po drugi strani bi neskladnost lahko bila težava ob zaznavanju medsebojno podobnih razredov (na primer klasifikacija posameznih drevesnih vrst ali gozdnih sestojev).

Majhna razlika med natančnostjo določanja obodov krošenj modelov, naučenih na ortofotu in na združenih ortofotu in MVK, nakazuje na majhno sposobnost učenja relevantnih značilnk na MVK. Po drugi strani je možno, da se je PSPNet ob uporabi združenih ortofota in MVK učil prepoznave krošenj na podlagi podatkov, ki so bolj usklajeni z uporabljenimi maskami. Tako se postavlja vprašanje, ali so metode klasifikacije, naučene na različnih podatkovnih virih, sposobne popolnoma izrabiti prednosti raznolikih informacij ali pa so sposobne uporabiti le podatke, s katerimi so maske za učenje modela najbolj usklajene. Če bi želeli za neko raziskavo do popolnosti izrabiti tako podatke ortofota kot tudi podatke aerolaserskega skeniranja bi morali imeti oba podatkovna vira popolnoma usklajena med seboj, pri čemer je treba poudariti ne le položajno, ampak tudi časovno usklajenost podatkov. Čeprav nas je v raziskavi bolj zanimala prva, predvidevamo, da je bila ena izmed težav modelov, naučenih na MVK, tudi druga. Za nekatera proučevana območja so bili podatki sicer zajeti v istem letu, a za določanje oboda krošenj je pomembna še usklajenost fenološke faze. Medtem ko so bile vse aerofotografije posnete v topli polovici leta, natančnejše med majem in avgustom, je aerolasersko skeniranje večinoma potekalo pozimi in zgodaj spomladi. Nekatera analizirana drevesa so bila tako na MVK neolistana, medtem ko so bila med aerofotografiranjem vsa olistana. Posledično je obseg krošnje na MVK lahko opazno manjši.

Za povečanje položajne usklajenosti vhodnih podatkov bi morali namesto klasičnega ortofota uporabiti popolnega. Pri njegovi izdelavi ob ortorektifikaciji namesto DMT uporabijo digitalni model površja (DMP). Čeprav je popolni ortofoto položajno bolj natančen, se ga ne izdeluje pogosto (Triglav Čekada 2016), saj v »senci«^zvrnjenih objektov nekatere površine niso zajete na nobeni izmed posnetih fotografij in bi na popolnem ortofotu ostale prazne oziroma bi prišlo do pojava dvojnega kartiranja (Kraus 2007; Habib 2018b; Kosmatin Fras, Šušteršič in Šašić Kežul 2021). Rešitev je v povečanju števila fotografij in povečanju vzdolžnega in prečnega preklopa (prekrivanja fotografij) (Triglav Čekada 2016), kar postopek izdelave močno podaljša in podraži, zaradi česar tudi v tujini šele v zadnjih letih klasični ortofoto zamenjujejo s popolnim (Kosmatin Fras, Šušteršič in Šašić Kežul 2021).

6 Sklep

Ugotovili smo, da zamik ortofota ne vpliva na natančnost določanja obodov krošenj, vpliva pa na kakovost učnih vzorcev, s katerimi smo model učili prepoznave krošenj. Le 36 % krošenj posameznih dreves je imelo JI vhodnih podatkov večji od 0,5. Z uporabo vseh ostalih dreves za učenje modela v učno množico dodajamo več negotovosti kakor koristnih informacij. V danem primeru so označene krošnje modelom, naučenim na položajno neusklajenih učnih vzorcih, še vedno omogočale prepoznavo dreves. Podobna položajna neskladnost bi bila bolj problematična v primeru prepoznavanja kategorij lesnate vegetacije, ki se ne razlikujejo tako izrazito od okolice.

Položajno usklajeni podatki so za strojno učenje najbolj koristni. V proučevanem primeru bi bilo tako smiselno izdelati popolni ortofoto iz fotografij, ki bi bile zajete sočasno z aerolaserskim skeniranjem, saj na usklajenost podatkov vpliva tudi fenološka faza. Podatki, uporabljeni v izvedeni analizi,

niso bili zajeti hkrati, ortofoto pa ni bil popolni ortofoto, zaradi česar lahko napake modelov izhajajo iz neuskladenosti mask za učenje modelov in MVK. Rezultati nakazujejo tudi na to, da se je model, naučen na združenih ortofotu in MVK, učil prepoznave predvsem glede na ortofoto, ki je bolj usklajen z maskami krošenj, informacije MVK pa zanemari, čeprav omogočajo kompleksnejše razumevanje analiziranih elementov.

ZAHVALA: Prispevek je nastal s finančno podporo Javne agencije za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije v okviru raziskovalnega programa št. P2-0406 Opazovanje Zemlje in geoinformatika ter projekta št. V5-2135 Prenova regionalne razdelitve krajskih tipov in izjemnih krajev v Sloveniji ter njihova digitalizacija, ki ga sofinancirajo Ministrstvo za kmetijstvo, gozdarstvo in prehrano, Ministrstvo za okolje, podnebje in energijo ter Ministrstvo za kulturo.

7 Viri in literatura

- Aerofotografije CAS. Geodetska uprava Republike Slovenije. Ljubljana, 2014.
- Aerofotografije CAS. Geodetska uprava Republike Slovenije. Ljubljana, 2015.
- Dejanska raba kmetijskih zemljišč, Register kmetijskih gospodarstev 2015. Ministrstvo za kmetijstvo, gozdarstvo in prehrano. Ljubljana, 2015. Medmrežje: <https://rkg.gov.si/vstop/> (16. 1. 2024).
- Deng, J., Dong, W., Socher, R., Li, L.-J., Kai, L., Li F.-F. 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>
- Habib, A. 2018a: Accuracy, quality assurance, and quality control of light detection and ranging mapping. *Topographic Laser Ranging and Scanning: Principles and Processing*. Boca Raton, London, New York.
- Habib, A. 2018b: Integration of LiDAR and photogrammetric data: Triangulation and orthorectification. *Topographic Laser Ranging and Scanning: Principles and Processing*. Boca Raton, London, New York.
- 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). Las Vegas. DOI: <https://doi.org/10.1109/10.1109/CVPR.2016.90>
- Illowsky, B., Dean, S., Birmajer, D., Blount, B., Boyd, S., Einsohn, M., Helmreich, J., Kenyon, L., Lee, S., Taub, J. 2013: *Introductory statistics*. Houston.
- 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>
- Kosmatin Fras, M., Šušteršič, K., Šašič Kežul, A. 2021: Popolni ortofoto v urbanih okoljih. *Geodetski vestnik* 65-1. DOI: <https://doi.org/10.15292/geodetski-vestnik.2021.01.27-45>
- Kraus, K. 2007: *Photogrammetry: geometry from images and laser scans*. Berlin, New York.
- Oštir, K. 2006: *Daljinsko zaznavanje*. Ljubljana.
- Petrie, G., Toth, C. K. 2018: *Airborne and spaceborne laser profilers and scanners*. *Topographic Laser Ranging and Scanning: Principles and Processing*. Boca Raton, London, New York.
- Šivne linije ortofota. OAF Bovec. Geodetska uprava Republike Slovenije. Ljubljana, 2015a.
- Šivne linije ortofota. OAF Celje. Geodetska uprava Republike Slovenije. Ljubljana, 2014a.
- Šivne linije ortofota. OAF Koper. Geodetska uprava Republike Slovenije. Ljubljana, 2014b.
- Šivne linije ortofota. OAF Kranj. Geodetska uprava Republike Slovenije. Ljubljana, 2015b.
- Šivne linije ortofota. OAF Krško. Geodetska uprava Republike Slovenije. Ljubljana, 2014c.
- Šivne linije ortofota. OAF Ljubljana. Geodetska uprava Republike Slovenije. Ljubljana, 2014č.
- Šivne linije ortofota. OAF Maribor. Geodetska uprava Republike Slovenije. Ljubljana, 2014d.

- Šivne linije ortofota. OAF Murska Sobota. Geodetska uprava Republike Slovenije. Ljubljana, 2014e.
- Šivne linije ortofota. OAF Nova Gorica. Geodetska uprava Republike Slovenije. Ljubljana, 2014f.
- Triglav Čekada, M. 2016: Navidezna zvrnjenost objektov na državnem ortofotu ali kaj moramo vedeti, ko uporabljamo državni ortofoto? *Geografski vestnik* 88-1. DOI: <https://doi.org/10.3986/GV88107>
- Triglav Čekada, M., Bric, V. 2015: Končan je projekt laserskega skeniranja Slovenije. *Geodetski vestnik* 59-3.
- Zhao, H., Shi, J., Qi, X., Wang, X., Jia, J. 2017: Pyramid scene parsing network. arXiv 1612.01105. DOI: <https://doi.org/10.48550/arXiv.1612.01105>