

Naslov članka/Article:

Avtomatsko zaznavanje vrtač z metodo slikovnega ujemanja

Automatic Doline Detection Using Image Matching

Avtor/Author:

dr. Klemen Kregar, mag. Sonja Trškan, Neža Lanišek, Janja Pančur

<https://doi.org/10.59132/geo/2020/1/33-40>

CC licenca



Priznanje avtorstva-Nekomercialno-Brez predelav



Geografija v šoli 1/2020, letnik 28

ISSN 1318-4717

Izdal in založil: Zavod Republike Slovenije za šolstvo

Kraj in leto izdaje: Ljubljana, 2020

Spletna stran revije:

<https://www.zrss.si/strokovne-revije/geografija-v-soli/>

Avtomatsko zaznavanje vrtač z metodo slikovnega ujemanja

Automatic Doline Detection Using Image Matching



Dr. Klemen Kregar,
Fakulteta za gradbeništvo in
geodezijo Univerze v Ljubljani
klemen.kregar@fgg.uni-lj.si



Mag. Sonja Trškan
Gimnazija in srednja šola
Rudolfa Maistra Kamnik
sonja.trskan@gssrm.si



Neža Lanišek
Gimnazija in srednja šola
Rudolfa Maistra Kamnik
neza.lanisek@gmail.com



Janja Pančur
Gimnazija in srednja šola
Rudolfa Maistra Kamnik
janja.pancur@gmail.com
COBISS: 1.03

Izvleček

Raziskovalna naloga *Vrtače Rampolj in okolice v kamniški občini* je na 52. državnem srečanju mladih raziskovalcev prejela zlato priznanje v kategoriji Geografija in geologija. Med raziskovalnim delom smo odgovarjali na raziskovalna vprašanja, ali bi se dalo vrtače dovolj zanesljivo prepoznati z avtomatsko obdelavo lidarskega modela površja. Za namen raziskave smo na obravnavanem območju planot vzhodno od Kamnika na terenu popisali vse vrtače. Razvili smo novo metodo za zaznavanje vrtač, ki temelji na postopku slikovnega ujemanja. Za razliko od ostalih metod za avtomatsko zaznavanje vrtač, ki temeljijo na iskanju posamezne geometrične značilnosti terena (npr. lokalnega minimuma ali zaprtih kotanj), ta metoda temelji na iskanju območij, ki imajo obliko, podobno vrtači. Analizirali smo uspešnost predlaganega postopka s primerjavo terenskih podatkov. Kakovost zaznave ocenjujemo z deležem vrtač, ki smo jih zaznali, ter deležem zadetkov, ki v resnici niso vrtače.

Ključne besede: elektronski tahimeter, merjenje dolžin, ločljivost, natančnost

Abstract

The research project *Dolines of Rampolj and its Surroundings in the municipality of Kamnik* received the Golden Award in geography at the 52nd National Meeting of Young Researchers. The scientific research question was: Can dolines be reliably detected automatically from the LiDAR elevation model? For the purpose of the research, all dolines were inventoried on the field in a well-defined plateau area east of Kamnik. A new method for the detection of dolines was established based on the Image Matching algorithm. Unlike other doline detection methods used to find a particular geometrical characteristic, e.g. local minima or enclosed sink, the proposed method is used to detect areas with a doline shape. The quality of the proposed method was evaluated based on the comparison with field observations. The quality is evaluated through the proportion of the actual dolines detected and also the proportion of false detections that are not confirmed by field observations.

Keywords: total station, distance measurements, precision, accuracy

Uvod

Študij vrtač je pomemben za raziskovanje krasa (Sauro, 2013). Geologi in krasoslovci se ukvarjajo z analizo oblike vrtač, preko katere lahko sklepajo o geogenih procesih, ki spreminjajo kraško površje.

V letih 2014 in 2015 je bilo celotno površje Slovenije skenirano iz zraka s tehnologijo lidar.

Podatki so prosto dostopni, deklarirana gostota je vsaj 5 točk/m² (Geodetski inštitut Slovenije, 2015). Iz oblakov točk je izrisan digitalni model reliefa v obliki rastrske mreže z velikostjo celic 1 m. Lahko rečemo, da so takšni podatki idealni za analizo leg in oblik vrtač.

Z geodetskega vidika so pomembne naloge, ki se tičejo obdelave modela reliefa, saj so njihovi rezultati koristni za sorodna področja, kot sta

geologija ali krasoslovje. Dve tipični nalogi, kjer vidimo doprinos geodezije, sta avtomatsko zaznavanje položajev vrtač ter geometrijska parametrizacija oblike vrtač (izračun površin, volumna, strmine, globine itd.).

Območje

V raziskovalni nalogi *Vrtače Rampolj in okolice v kamniški občini*, ki sta jo izvedli dijakinji Gimnazije in srednje šole Rudolfa Maistra Kamnik, smo obravnavali vrtače na planotah vzhodno od Kamnika. Območje je na severu omejeno s Tuhinjsko dolino, na zahodu z jarkom potoka Potočnica, ki se v vasi Potok izliva v Nevljico, na jugu se teren spusti proti gozdom Rudnika pri Radomljah in Kolovca, zato lahko rečemo, da je meja glavna cesta Kamnik–Velika Lašnja, na zahodu pa se območje konča s hribom Velika špica, od katerega se teren strmo spusti proti mestu Kamnik. Celotno območje prekrije pravokotnik 3 x 6 km – to je 18 listov lidarskih podatkov, od koordinate (470000, 119000) na jugozahodu do koordinate (476000, 122000) na severovzhodu (slika 1). Vrtače se nahajajo v skupinah na višje ležečih uravninah v smeri od zahoda proti vzhodu: Velika špica, Tolsta gora, območje severno od Nevljice in južno od ceste Kamnik–Ločica, Vrtače ter sklop Rampolje in Zapolje.

Preučevano območje predstavlja skrajni del severozahodnih posavskih gub. Je sestavljen greben; na jugu ga gradijo permokarbonske kamnine, na severnem delu pa so večinoma kraške planote na apnencih. Na vrhu se greben zaključuje v posamezne razrezane planote –

Velika špica (660 m) in Tolsta gora (734 m). Jugovzhodni del preučevanega območja gradita dolomit in roženec, vzhodni in zahodni del glinasti skrilavec in drobnik, pretežno pa je območje sestavljeno iz apnenca (Premru, 1983). Ekspozicija preučevanega območja je južna, kar pomeni, da se teren rahlo nagiba proti jugu. Proti severu se pobočje strmo spušča v Tuhinjsko dolino.


Pri analizi kakovosti avtomatske zaznave vrtač smo obravnavali:

- celotno območje 3 x 6 km,
- posebej ožje območje, na katerem se nahajajo vrtače in
- individualno tudi območje skupine Rampolje in Zapolje, kjer je gostota vrtač največja. Zanimalo nas je, koliko na kakovost zaznavanja vpliva, če območje, kjer vemo, da so vrtače, dobro definiramo, oziroma koliko napak naredimo, če preiskujemo tudi predele, kjer sploh ni vrtač.

Pregled dosedanjih raziskav

V literaturi je za avtomatsko zaznavanje vrtač največkrat uporabljena metoda zalivanja kotanj. Gre za uporabo orodja v GIS, ki je primarno namenjeno hidrološkim analizam (Anurag Srivastava, 2000; Clark Labs, 2001; Grimaldi, Nardi, Benedetto, Istanbuluoğlu, in Bras, 2007; Jenson in Dominique, 1988; Planchon in Darboux, 2002). Algoritem v modelu reliefa zapolni vse kotanje, ki predstavljajo lokalni minimum terena na način, da iz njih ni nižjega izhoda, po katerem bi hipotetično odtekala voda. Z odštevanjem zapolnjenega modela površja od originalnega zlahka identificiramo območja kotanj. Metodo so tudi uporabili:

V literaturi je za avtomatsko zaznavanje vrtač največkrat uporabljena metoda zalivanja kotanj. Poleg te metode smo zasledili tudi iskanje lokalnih minimumov v terenu, za iskanje vrtač pa se uporablja tudi (računalniško) nevronska mrežo z globokim učenjem.



Slika 1: Obravnavano območje in dve podobmočji

Avtor: J. Pančur; vir podlage: Geopedia – interaktivni spletni atlas in zemljevid Slovenije, splet: www.geopedia.si

Pardo-Igúzquiza, Durán, in Dowd (2013) za zaznavanje in določanje orientacije vrtač ter uval na območju Sierra de las Nives v Španiji; Doctor in Young (2013) na območju doline Shenandoah v Virginiji, ZDA; ter Grlj in Grigillo (2014) za zaznavanje kotanj in brezstropih jam na območju Podgorskega krasa, Slovenija. Slednja sta postopek nadgradila s postopnim povečevanjem globin zaznavanja ter tako zmogla zaznati tudi kotanje znotraj večjih kotanj.

Pri drugem načinu, ki smo ga zasledili (Rahimi in Alexander, 2013), gre za iskanje lokalnih minimumov v terenu. Pri tem uporabljamo funkcijo »erozije« podobe: z okvirjem (masko) izbrane dimenzije prečesemo vse položaje na podobi. Pri vsakem položaju si zabeležimo najmanjšo vrednost znotraj okvirja. Kadar sredina okvirja naleti na lokalni minimum (nikjer v okvirju ni manjše vrednosti), se v erodirano sliko zapiše ta vrednost na isto mesto, kot je na originalni sliki. V piksljih, kjer je razlika med originalno in erodirano sliko enaka nič, imamo lokalne minimume.

Pred kratkim je bila predstavljena še tretja metoda avtomatske zaznave vrtač (Mihevc in Mihevc, 2019), ki za iskanje vrtač uporablja nevronska mreža z globokim učenjem. Umetna nevronska mreža je računalniški model, ki temelji na posnemanju delovanja možganov. Nevroni so urejeni v sloje, ki so med seboj povezani s sinapsami. Pomembna sta vhodni in izhodni sloj nevronov. Informacija v mrežo vstopa preko vhodnega sloja nevronov. S sistemom uteži, ki so pripisane vsem sinapsam, se na izhodu pojavi izračunani rezultat. Glede na to, ali je rezultat pravilen ali napačen, v fazi učenja prilagajamo uteži sinapsam. V fazi učenja moramo mreži podati dovolj testnih podatkov, da se nauči pravila, ki ga bomo od nje pričakovali na novih podatkih, za katere ne poznamo pravega rezultata. O globokih mrežah govorimo, kadar v mrežah nastopa veliko slojev nevronov. Mreži moramo sicer ročno pokazati dovolj primerkov vrtač, da se na njih nauči pravila za iskanje, naučena mreža pa je sposobna zaznavati vrtače raznih oblik in velikosti, in to celo na ogromnih površinah. Avtorja (Mihevc in Mihevc, 2019) sta na takšen način locirala vrtače po vsej Sloveniji.

Prvi dve metodi v modelu površja iščeta geometrijske značilnosti (zaprto kotanjo ali lokalni minimum). Takšne metode na območjih, kjer ni vrtač, lahko naredijo veliko lažnih zadetkov, najdejo kotanje ali minimume, ki niso vrtače. Tretja metoda je pristranska, ker zahteva ročni vnos ogromnega vzorca vrtač.


Oris nove metode

Predlagamo alternativno metodo iskanja vrtač z uporabo algoritma slikovnega ujemanja. Ta metoda bo v modelu reliefa iskala območje, ki je po obliki podobno vrtači. Kakovost zaznavanja predlagane metode bomo ocenili s primerjavo rezultatov s položaji vrtač, popisanimi na terenu.

Metode

Kartiranje

Pripravimo si ustrezen zemljevid, ki nam je v pomoč pri pregledovanju terena. Pri našem delu se je še najbolj izkazal zemljevid naklonov, izračunanih iz DMR-ja lidarskih podatkov, prekrit z barvno skalo višin DMR-ja, kar prikazuje Slika 2. Primeri vizualizacij lidarskih podatkov za različne namene so zbrani v Kokalj in Hesse (2017).



Slika 2: Primera zemljevidov, ki sta nam bila v pomoč na terenu.

Avtor: J. Pančur; vir zemljevidov: Geodetski inštitut Slovenije, 2015


Takšno karto uporabimo za kartiranje opaženih vrtač. Terenski popis vrtač s pomočjo takšne karte ni povsem objektivni, saj že iz karte vidimo, kje vrtače iskati. Kljub temu je za raziskavo pomembno, da obstoj vrtač potrdimo na terenu.

Logistična krivulja

V nadaljevanju prispevka bomo obliko vrtač opisovali s pomočjo logistične krivulje. Gre za tipično predstavnicu sigmoidnih krivulj, ki jo podamo z enačbo:

$$y(x) = a / (1 + e^{-(x-b)c})$$

Funkcija se od vrednosti 0 zvezno dvigne do vrednosti a . Parameter b določa, kje na osi x vrednost y doseže polovico višine a , pri $x = b$ je »sredina klanca«. Parameter c določa strmino klanca – večji c , strmejši klanec. Slika 3 prikazuje, kako parametri a , b in c določajo položaj in obliko krivulje.



Slika 3: Določitev oblike krivulje za iskalno tarčo
Avtor: N. Lanišek

Slikovno ujemanje

Slikovno ujemanje (angl. *image matching*) je metoda, s katero na podobi iščemo območje končne velikosti, ki je najbolj podobno iskani podobi – tarči – iste velikosti (Kraus, 2000). Stopnjo podobnosti merimo s korelacijskim koeficientom, ki je razmerje med kovarianco in produktom standardnih odklonov podatkovnih nizov, ki ju med seboj primerjamo:


$$\rho = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

V prvi fazi se s tarčo premikamo piksel za pikselom po podobi ter za vsak položaj tarče izračunamo korelacijo med prekritim delom podobe ter tarčo (Kraus, 2000). Na ta način odkrijemo položaj tarče na podobi, kjer je ujemanje največje. V drugi fazi lahko s postopkom izravnavo določimo točko najboljšega ujemanja s podpikselsko ločljivostjo (Höhle, 1997), vendar za iskanje vrtač takšna podrobnost ni potrebna.

V postopku iskanja vrtač z metodo slikovnega ujemanja (Kraus, 2000) smo preiskovali rastrsko podobo višin terena na obravnavanem območju, to je digitalni model reliefa z ločljivostjo 1 m, izdelan iz podatkov lidarskega snemanja Slovenije (Geodetski inštitut Slovenije, 2015).

Iskalna tarča je kvadratna matrika dimenzije in oblike, ki naj čim bolj predstavlja dimenzijo in obliko vrtač, ki jih iščemo. Poskuse smo izvedli s kvadratnimi tarčami dimenzij 30, 40 in 50 m. Tudi nekoliko prevelika ali premajhna tarča bo pri prekrivanju z vrtačo, ki ne ustreza prav

dobro njenim dimenzijam, vrnila mnogo večjo korelacijo kot pri prekrivanju z ostalim terenom.



Slika 4: Oblika iskalne tarče
Avtor: N. Lanišek

Vrednosti v matriki smo določili tako, da predstavljajo vrtačo: majhne vrednosti v centru tarče in vedno večje proti robom. Vrednost vsakega piksla tarče izračunamo z oddaljenostjo piksla od centra tarče po enačbi logistične krivulje (enačba (1)). Tako dobimo skledasto obliko, ki ponazarja obliko vrtače. Izris uporabljene tarče je na Sliki 4.

Ker smo slikovno ujemanje ponavljali večkrat z različnimi dimenzijami iskalnih tarč, smo parametre krivulje določili eksperimentalno v odvisnosti od velikosti tarče. Izkazalo se je, da rezultati niso nič boljši, če uporabimo parametre, določene iz dejanske oblike vrtač. Računanje korelacije je zelo robusten postopek, ki bo, kljub ne povsem ustrezni obliki ali dimenziji tarče, pri prekrivanju z vrtačo vrnil mnogo višje vrednosti korelacije kot pri prekrivanju z ostalim terenom.

Z računanjem korelacij dobimo korelacijsko podobo, kot je prikazana na Sliki 5.

Na karti korelacij se lepo vidijo lege vrtač na območju Rampolj, Tolste gore in Velike špice. Poleg njih so z nekoliko temnejšo obarvani jarki, z najtemnejšo pa grebeni. Naša naloga je poiskati točke, kjer je korelacija največja. Za prvo vrtačo brez težave v programu uporabimo funkcijo *max*. S tem ugotovimo položaj največje vrednosti v matriki in tako položaj »centra« vrtače, ki se je najboljše ujemala s tarčo. Nato iščemo naslednjo vrtačo. Če poiščemo drugo največjo vrednost korelacije, ugotovimo, da leži v sosednjem pikslu največje korelacije, torej pripada isti vrtači. Iste vrtače pa nočemo označiti dvakrat.

Za vsako najdeno največjo vrednost korelacije je torej potrebno okolico najdene vrednosti (velikosti takšne, kot je velikost tarče) zamenjati z majhnimi vrednostmi. Tako v okolici vrtače, ki smo jo že našli in shranili, ne moremo ponovno najti vrtače.

V postopku iskanja vrtač z metodo slikovnega ujemanja smo preiskovali rastrsko podobo višin terena na obravnavanem območju, to je digitalni model reliefa z ločljivostjo 1 m, izdelan iz podatkov lidarskega snemanja Slovenije.



Slika 5: Korelacijska podoba: svetlejša so območja velikega sovpadanja tarče s podobo.

Avtor: J. Pančur

Potrebno se je odločiti, do katere vrednosti korelacij bomo še iskali. Če nastavimo previsoko vrednost, bomo nekatere vrtače izpustili, če nastavimo prenizko vrednost, bomo vrtače zaznali tudi tam, kjer jih v resnici ni, na primer v grapah.

Zmogljivost predlaganega postopka – kakovost zaznavanja vrtač

Izvedli smo več iskanj vrtač na obravnavanem območju. Poskušali smo z različno velikostjo kvadratne tarče: 30, 40 in 50 m. Vsak poskus smo izvedli na:

- (i) celotnem območju (18 listov lidarskih podatkov, to je 6 x 3 km),
- (ii) na območju višje ležečih planot obravnavanega območja (to pomeni brez južnih pobočij masiva Palovč, na zahodu brez Kamnika, na severu pa brez Tuhinjske doline in predelov severno od nje) in
- (iii) na zaključenem območju platoja (Rampolje, Zapolje in Podhruškovska gora). Območja so prikazana na Sliki 1. Za vsako od devetih kombinacij velikosti vrtač in območja smo izvedli analizo kakovosti zaznavanja.

Za vsak poskus smo primerjali seznam vrtač, popisanih na terenu, s seznamom vrtač, dobljenim s slikovnim ujemanjem. Prešteti smo morali, koliko se avtomatsko zaznane vrtače (njihovo število naj bo N) ujemajo z našo referenco – pridobljeno s terenskim popisom (njihovo število naj bo M).

Izračunali smo horizontalne razdalje od vsake zaznane vrtače do vsake referenčne vrtače. Vse razdalje smo zapisali v tabelo (matriko) dimenzije $N \times M$. Potem smo prešteli, koliko vrednosti v matriki je manjših od izbrane tolerance (izbrali smo 15 m). Mesto (i, j) v matriki, kjer je razdalja manjša od 15 m, pomeni, da je i -ta zaznana vrtača dovolj blizu j -te referenčne vrtače. Ker je razdalja med njima manjša od standardne velikosti vrtač, rečemo, da gre za isto vrtačo: j -to vrtačo smo pravilno zaznali.

Po zgledu matrike napake (angl. *Confusion matrix*) iz teorije strojnega učenja (Fawcett, 2006; Ting, 2017) smo podatke o številu zaznanih in nezaznanih vrtač razvrstili v 3 razrede:

- število pravilno zaznanih vrtač p
- število referenčnih vrtač, ki jih nismo zaznali $n_1 = M - p$
- število vrtač, ki smo jih zaznali narobe $n_2 = N - p$

Četrty razred v matriki bi pomenil vrtače, ki jih nismo zaznali in jih tudi v resnici ni (takih primerov je poljubno mnogo).

Iz teh treh števil bomo izračunali deleža, preko katerih bomo najbolj razumljivo opisali uspešnost posameznega poskusa.

- delež zaznanih referenčnih vrtač $d_1 = p/M$
- delež napačno zaznanih vrtač $d_2 = (N - p)/N$



Slika 6: Terenski popis vrtač

Avtor: J. Pančur; vir podlage: Geodetski inštitut Slovenije, 2015

Rezultati

Terenski ogled

Na obravnavanem območju smo s terenskim kartiranjem identificirali 182 vrtač (Slika 6).

Zmogljivost predlaganega postopka – glede na kakovost zaznavanja vrtač

Pri uporabi metode slikovnega ujemanja je uspešnost odvisna od mejne korelacije, do katere iščemo. Če mejo postavimo zelo visoko, bomo zaznali majhen delež vrtač in nič napačnih. Če mejo spuščamo, bomo zaznavali vedno večji delež vrtač, med njimi pa bo tudi vedno več napačnih. Na Sliki 7 prikazujemo 9 grafov uspešnosti zaznave vrtač s slikovnim ujemanjem za tri območja s tremi dimenzijami tarče.

Slika 7 kaže, da s povečevanjem mejne korelacije upada delež napačnih zaznav. Žal hkrati pada tudi delež pravih zaznav. Prvi pada sprva hitreje in nato položneje, drugi pa ravno obratno. Pri kateri mejni korelaciji dosežemo najboljši uspeh, smo poskusili določiti s kriterijema, kje je med krivuljama največje razmerje in kje največja razlika. Izkaže se, da je največja razlika bolj smiseln kriterij. Na Sliki 7 je pri največji razliki med krivuljama izrisana črtkana navpičnica, ob njej pa so podatki o deležu pravilno in napačno zaznanih vrtač ter razlika med njima.

Sklep

Ugotavljamo, da so lidarski podatki (Geodetski inštitut Slovenije, 2015) idealni za raziskave in analize morfoloških oblik, kot so vrtače. Ob

deklarirani gostoti vsaj 5 točk/m² brez težav prepoznavamo oblike, ki so velike več metrov. Za raziskave površinskih kraških oblik, kot so škraplje ali žlebiči, pa lidarski podatki zaradi nezadostne gostote in natančnosti ne bi bili primerni.

Ob ustrezni pripravi podatkov, v našem primeru zemljevid višin terena v kombinaciji z izračunanimi nakloni terena, lahko rečemo, da vrtače dovolj dobro zaznamo že vizualno iz karte brez terenskega dela. Kljub temu se pogosto pojavijo primeri, pri katerih je terenska validacija vendarle potrebna. Zato mislimo, da imajo terenski podatki, zbrani med izdelavo raziskovalne naloge, veliko vrednost kot referenčni podatki za morebitne nadaljnje raziskave avtomatskega zaznavanja vrtač, tudi za druge avtorje.


Predlagani postopek je boljši od postopkov zaznavanja kotanj in lokalnih minimumov, ker v modelu terena išče površje, ki je vrtači podobno po obliki, ne pa le po eni geometrični značilnosti. V prihodnjih raziskavah bomo na obravnavanem nizu referenčnih vrtač preverjali še kakovost ostalih treh postopkov, ki so opisani v uvodu.

Preverjali smo zmogljivost predlaganega postopka v odvisnosti od območja, velikosti tarče ter mejne korelacije.

Pričakovano je, da na celotnem območju naredimo več napačnih zadetkov, kot če se omejimo zgolj na območje, kjer vemo, da vrtače so, in to se je v rezultatih seveda potrdilo.

Izkazalo se je, da z manjšo tarčo zaznamo večji delež vrtač. Hkrati naredimo tudi več napak,

Lidarski podatki so idealni za raziskave in analize morfoloških oblik, kot so vrtače. Za raziskave površinskih kraških oblik, kot so škraplje ali žlebiči, pa lidarski podatki zaradi nezadostne gostote in natančnosti ne bi bili primerni.



Slika 7: Uspešnost zaznavanja vrtač s slikovnim ujemanjem za tri območja in tri dimenzije tarč

ampak delež pravilnosti se z manjšanjem tarče bolj povečuje kot delež napak.

Optimalna mejna korelacija se na celotnem območju (i) ne spreminja z velikostjo tarče in znaša nekaj manj kot 0,8. Optimalna mejna korelacija se tudi na območju Palovč (ii) ne spreminja z velikostjo tarče in znaša okrog 0,7. Na zelo dobro definiranem območju vrtač (iii) pa se optimalna korelacija spreminja v odvisnosti od velikosti tarče, in sicer med 0,65, 0,7 in 0,8.

Prednost predlaganega postopka je, da z izbiro korelacije lahko vplivamo na delež zaznanih in napačno zaznanih vrtač. Če proučujemo nova območja, kjer nimamo referenčnih podatkov, se lahko odločimo, ali nam je več do tega, da zaznamo čim več vrtač, tudi če bo dobršen del zadetkov napačen, ali pa si želimo najti vsaj nekaj vrtač, za katere hočemo biti prepričani, da so zares vrtače.

V nadaljnjih raziskavah bomo primerjali uspešnost zaznavanja predlagane metode z ostalimi znanimi metodami zaznavanja vrtač, kot jih navajajo: Grlj in Grigillo (2014), Rahimi

in Alexander (2013) in Mihevc in Mihevc (2019). Samo zaznavanje lege vrtač pa za geologe in krasoslovce še ne bo dovolj. Poleg položaja jih bodo zanimale še druge lastnosti vrtač, kot so: globina, širina, obseg, strmina, prostornina ... Z uporabo lidarskih podatkov in z modernimi orodji GIS pa bo mogoče vse skupaj izračunati ter tudi lepo izrisati in razumljivo grafično predstaviti. Raziskovanju vrtač se obeta še svetla prihodnost.

Viri in literatura

1. Anurag Srivastava. (2000). *Comparison of two Algorithms for Removing Depressions and Delineating Flow Networks from Grid Digital Elevation Models*. Faculty of the Virginia Polytechnic Institute and State University. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.538.4854&rep=rep1&type=pdf>
2. Clark Labs. (2001). The Idrisi Project. Worcester, MA, USA.
3. Doctor, D. H., in Young, J. a. (2013). An evaluation of Automated Gis Tools for Delineating Karst Sinkholes and Closed Depressions From 1-Meter

- Lidar-Derived Digital Elevation Data. *13th Multidisciplinary Conference on Sinkholes and the Engineering and Environmental Impacts of Karst*, 449–458. <https://doi.org/PNR61>
4. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
 5. Geodetski inštitut Slovenije. (2015). *Izvedba laserskega skeniranja Slovenije*. Ljubljana.
 6. Grimaldi, S., Nardi, F., Benedetto, F. Di, Istanbuluoglu, E., & Bras, R. L. (2007). A physically-based method for removing pits in digital elevation models. *Advances in Water Resources*. <https://doi.org/10.1016/j.advwatres.2006.11.016>
 7. Grlj, A., in Grigillo, D. (2014). Uporaba digitalnega modela višin in satelitskega posnetka RapidEye za zaznavanje kraških kotanj in brezstropih jam Podgorskega krasa. *Dela – Oddelek za geografijo Filozofske fakultete v Ljubljani*, (42), 129–147. <https://doi.org/10.4312/dela.42.7.129-147>
 8. Höhle, J. (1997). The Automatic Measurement of Targets. *Photogrammetrie Fernerkundung Geoinformation*, 1997(1), 13–21.
 9. Jenson, S. K., in Dominique, J. O. (1988). Extracting topographic structure from digital elevation data for geographic information system analysis. *Photogrammetric Engineering and Remote Sensing*, 54(11), 1593–1600. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.138.6487&rep=rep1&type=pdf%5Cnpapers2://publication/uuid/4398A0F0-60F3-4AB2-BA29-4C786C202277>
 10. Kokalj, Ž., in Hesse, R. (2017). *Airborne Laser Scanning Raster Data Visualization: A Guide to Good Practice*. (N. G. Bon, Ed.). Ljubljana: Založba ZRC. Retrieved from <http://zalozba.zrc-sazu.si/p/P14>
 11. Kraus, K. (2000). *Photogrammetry* (2nd Englis). Berlin ; New York : Walter De Gruyter, 2007.
 12. Mihevc, A., in Mihevc, R. (2019). Distribution and morphological characteristics of dolines in Slovenia defined by lidar data sets and machine learning. In *EGU General Assembly 2019* (Vol. 21, p. 9315).
 13. Pardo-Igúzquiza, E., Durán, J. J., in Dowd, P. A. (2013). Automatic detection and delineation of karst terrain depressions and its application in geomorphological mapping and morphometric analysis. *Acta Carsologica*, 42(1), 17–24. <https://doi.org/10.3986/ac.v42i1.637>
 14. Planchon, O., & Darboux, F. (2002). A fast, simple and versatile algorithm to fill the depressions of digital elevation models. In *Catena*. [https://doi.org/10.1016/S0341-8162\(01\)00164-3](https://doi.org/10.1016/S0341-8162(01)00164-3)
 15. Rahimi, M., in Alexander, E. C. (2013). Locating Sinkholes in Lidar Coverage Of A Glacio-Fluvial Karst, Winona County, MN. *13th Multidisciplinary Conference on Sinkholes and the Engineering and Environmental Impacts of Karst*, 469–480. <https://doi.org/PNR61>
 16. Sauro, U. (2013). Reliefne oblike gorskega krasa srednjih geografskih širin: razmišljanja, trendi in raziskovalni problemi. *ACTA CARSOLOGICA*, 42(1), 5–16.
 17. Ting, K. M. (2017). Confusion Matrix. In C. Sammut & G. I. Webb (Eds.), *Encyclopedia of Machine Learning and Data Mining* (p. 260). Springer. https://doi.org/10.1007/978-1-4899-7687-1_50