Primjena bespilotne letjelice u geomorfološkoj analizi ponikava

Karčić, Dominik

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:983208

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-23**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

Dominik Karčić

Primjena bespilotne letjelice u geomorfološkoj analizi ponikava

Diplomski rad

Zagreb

2023

Dominik Karčić

Primjena bespilotne letjelice u geomorfološkoj analizi ponikava

Diplomski rad

predan na ocjenu Geografskom odsjeku

Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu

radi stjecanja akademskog zvanja

magistra geografije

Zagreb

2023

Ovaj je diplomski rad izrađen u sklopu diplomskog sveučilišnog studija *Geografija; smjer: Geografski informacijski sustavi* na Geografskom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, pod vodstvom prof. dr. sc. Sanje Faivre

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Diplomski rad

Primjena bespilotne letjelice u geomorfološkoj analizi ponikava

Dominik Karčić

Izvadak: U radu je ispitana primjena bespilotne letjelice u geomorfološkoj analizi ponikava s pretpostavkom njene jednostavne upotrebe, visoke preciznosti i relativne brzine procesa u odnosu na tradicionalne načine analize prostora. Podaci za generiranje modela prikupljeni su pomoću bespilotne letjelice i GNSS uređaja, a konačni model imao je prostornu rezoluciju od 2.8 cm. Generirani modeli su međusobno uspoređeni, a za daljnju analizu odabran je model koji prikazuje istraživani prostor s najmanjom greškom. Unutar odgovarajućih softvera provedena je detaljna geomorfološka analiza, a dobiveni rezultati su uspoređeni s postojećim podacima s TK25 i HOK-a. Poluautomatskim izdvajanjem oboda ponikava pomoću modificirane MDTA metode (mMDTA) i metode nagiba padina (MNP) detektirano je preko 50% više ponikava od onih na dostupnim kartografskim izvorima, bez obzira na otežavajući faktor prisutne vegetacije. Izdvojene ponikve detektirane su na modelu koji ima prosječno odstupanje nadmorske visine od 37 cm u odnosu na kontrolne točke prikupljene pomoću GNSS uređaja. Metodom nagiba padina izdvojeno je 18,4% više ponikava nego modificiranom MDTA metodom, uz značajnu razliku u njihovim morfometrijskim pokazateljima. Analizom rezultata utvrđenu je kako je MNP metoda pogodnija za detektiranje ponikava dok mMDTA metoda pruža kvalitetnije podatke za geomorfološku analizu. Utvrđeno je kako se bespilotnom letjelicom na brz i jednostavan način mogu napraviti modeli prostora visoke razlučivosti koji su pogodni za detaljnu geomorfološki analizu.

80 stranica, 56 grafičkih priloga, 14 tablica, 65 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: Bespilotna letjelica, geomorfološka analiza, ponikve, DEM

Voditelj: prof. dr. sc. Sanja Faivre

Povjerenstvo: prof. dr. sc. Sanja Faivre
doc. dr. sc. Luka Valožić
mag. geog. Marin Mićunović

Tema prihvaćena: 13. 1. 2022.

Rad prihvaćen: 9. 2. 2023.

Rad je pohranjen u Središnjoj geografskoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19, Zagreb, Hrvatska.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Master Thesis

The application of unmanned aerial vehicles (UAV) in geomorphological analysis of dolines

Dominik Karčić

Abstract: This thesis examines the use of an unmanned aerial vehicle (UAV) in the geomorphological analysis of dolines assuming that it is easy to use, has high precision and can be processed relatively quickly compared to traditional methods of spatial analysis. Data for creation of the model was collected using UAV and GNSS receiver. The final model achieves a spatial resolution of 2.8 cm. The generated models were compared and the model with the lowest error was selected for further analysis. A detailed geomorphological analysis was carried out in the appropriate software and the results were compared with the existing data from TK25 and HOK. Semi-automatic extraction of the doline edges using the modified MDTA method (mMDTA) and the slope method (MNP) detected more than 50% of dolines compared to the available cartographic sources, regardless of the presence of vegetation. Separated dolines were detected on the DEM, which has an average height deviation of 37 cm compared to the control points collected using the GNSS device. The slope method extracted 18.4% more dolines than the modified MDTA method, with a significant difference in morphometric characteristics. Analysis of the results revealed that the MNP method was better for doline detection, while the mMDTA method provided better data quality for geomorphological analysis. It was found that spatial models with high spatial resolution suitable for detailed geomorphological analyses can be created quickly and easily with a UAV.

80 pages, 56 figures, 14 tables, 65 references; original in Croatian

Keywords: Unmanned aerial vehicle, geomorphological analysis, dolines, DEM

Supervisor: Sanja Faivre, PhD, Full Professor

Reviewers: Sanja Faivre, PhD, Full Professor
Luka Valožić, PhD, Assistant Professor
Marin Mićunović, mag. geogr.

Thesis title accepted: 13/01/2022

Thesis accepted: 09/02/2023

Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19, Zagreb, Croatia.

Zahvaljujem se mentorici prof.dr.sc. Sanji Faivre na vremenu, trudu, savjetima i komentarima koji su mi pomogli u izradi ovog rada. Zahvaljujem se i asistentu Marinu Mićunoviću na pomoći pri terenskom radu, modeliranju i analizi. Također, hvala članovima ispitnog povjerenstva na komentarima i savjetima vezanim uz rad.

Zahvaljujem se i supruzi Dori te sinovima Šimunu i Tomi, kao i svojoj obitelji na podršci i razumijevanju tijekom mojeg akademskog obrazovanja.

Ovaj diplomski rad izrađen je uz podršku HRZZ SEA LeveL projekta "Promjena relativne morske razine i klimatske promjene duž istočne obale Jadrana" HRZZ-IP-2019-04-9445.

SADRŽAJ

1. UVOD 1

2. PODRUČJE ISTRAŽIVANJA 4

2.1. Hipsometrija 5

2.2. Nagibi padina 7

2.3. Vertikalna raščlanjenost reljefa 9

2.4. Orijentacija padina 11

2.5. Geološka obilježja 14

3. METODE I MATERIJALI 15

3.1. TERENSKO PRIKUPLJANJE PODATAKA 17

3.1.1. Odabir područja pogodnog za analizu 17

3.1.2. Prikupljanje podataka o kontrolnim točkama 18

3.1.3. Snimanje bespilotnom letjelicom 23

3.2. SOFTVERSKA OBRADA PRIKUPLJENIH PODATAKA 27

3.2.1. ArcGIS Online i ArcGIS Field Maps 27

3.2.2. Geomatički program T7D 29

3.2.3. Agisoft Metashape Professional 31

3.2.3.1. Structure from Motion 31

3.2.3.2. Provjera kvalitete fotografija 32

3.2.3.3. Spajanje fotografija 33

3.2.3.4. Dodavanje kontrolnih točaka 33

3.2.3.5. Izgradnja gustog oblaka točaka, poligonalne mreže i teksture 34

3.2.3.6. Generiranje DEM-a i DOF-a 37

3.2.4. Izdvajanje ponikava (ArcGIS Pro) 38

3.2.4.1. Digitalizacija postojećih podataka 38

3.2.4.2. Modificirana MDTA metoda (mMDTA) 39

3.2.4.3. Metoda nagiba padina (MNP) 45
3.2.5. Morfometrijska analiza (ArcGIS Pro) 47
3.2.5.1. Nadmorska visina, nagib padina, vertikalna raščlanjenost reljefa i orijentacija padina 47
3.2.5.2. Tip ponikava 49
3.2.5.3. Dubina ponikava 49
3.2.5.4. Volumen ponikava 50
3.2.5.5. Indeks kružnosti 51
3.2.6. Usporedba sa postojećim podacima (ArcGIS Pro) 51
4. REZULTATI 53
4.1. DEM, DSM i DOF 53
4.2. Nadmorska visina, nagib padina, vertikalna raščlanjenost reljefa i orijentacija padina 55
4.3. Postojeći podaci (HOK i TK25) 58
4.4. „Zaglađeni“ DEM 59
4.5. Rezultat izdvajanja ponikava modificiranom MDTA metodom (mMDTA) i metodom nagiba padina (MNP) 62
4.6. Detaljna morfometrijska analiza 64
4.6.1. Tip izdvojenih ponikava 64
4.6.2. Dubina izdvojenih ponikava 64
4.6.3. Volumen izdvojenih ponikava 66
4.6.4. Indeks kružnosti 68
4.7. Rezultati usporedbe s postojećim podacima 68
5. RASPRAVA 71
6. ZAKLJUČAK 74
7. LITERATURA 75
8. PRILOZI VII

1. UVOD

Bespilotne letjelice (engl. Unmanned Aerial Vehicles – UAV) postale su dio svakodnevnog života, te su mnoge stvari danas bez njih gotovo nezamislive. Njihova primjena rasprostranjena je od poljoprivrednih djelatnosti sve do poštanskih usluga. Sve se češće koriste i u znanstvenim istraživanjima, npr. u geografiji, geomorfologiji i geologiji. Napretkom znanosti i tehnologije njihova upotreba postala je relativno jednostavna te ne iziskuje kompleksan proces izgradnje, korištenja i održavanja. Mogućnost opremanja bespilotnih letjelica različitim senzorima (RGB, multispektralni, termalni, itd.) omogućava prikupljanje različitih vrsta podataka bez konkretnog doticaja sa samim objektom istraživanja (Śledź i dr., 2021). Početak korištenja bespilotnih letjelica seže u vrijeme Hladnog rata kada su se koristile za nadziranje teritorija, dok se njihova znanstvena primjena pojavljuje početkom 90-ih godina prošlog stoljeća, prvenstveno za nadziranje vegetacije (Watts i dr., 2012). Komercijalna upotreba bespilotnih letjelica naglo je porasla posljednjih desetak godina zbog sve bržeg razvoja tehnologije koja omogućava proizvodnju uređaja visokih performansi, dostupnih velikom broju korisnika.

Tradicionalna daljinska istraživanja u geografiji (aerofotogrametrija, satelitski snimci) omogućila su spoznaju novih informacija i oblikovanje postojećih na novi način. Ipak, podaci prikupljeni tradicionalnim putem imaju određena ograničenja i nedostatke. Pružaju zadovoljavajuću prostornu i vremensku rezoluciju za analiziranje većih prostora i pojava na njima. Kada je potrebno prikupiti detaljnije podatke o površini Zemlje prednost dobivaju bespilotne letjelice kojima se prostorna razlučivost i vremenska frekvencija snimanja bitno povećavaju (Hackney i Clayton, 2015). U kombinaciji s tehnologijama modeliranja prostora baziranim na preklapanju više stereoparova, moguće je kreirati guste oblake točaka (engl. *dense point cloud*), te potom digitalne modele reljefa visoke prostorne razlučivosti koji su pogodni za analizu (Śledź i dr., 2021). Prvi satelitski sustavi za prikupljanje podataka o zemljinoj površini javljaju se 70-ih godina, a kontinuitet njihove upotrebe nastavlja se sve do danas (Walsh i dr., 1998). Intenzivnija primjena komercijalnih bespilotnih letjelica započela je upotrebom *fiksnog krila* (engl. fixed wing), a tek kasnije *kvadkoptera* (engl. quadcopter, drone), koji se i danas najčešće upotrebljava.

Geomorfologija je znanstvena disciplina u kojoj primjena bespilotnih letjelica postaje od velike važnosti. U geomorfološkim istraživanjima omogućava jednostavno korištenje, visoku preciznost i relativnu neovisnost u odnosu na tradicionalne metode daljinskih istraživanja.

Čak i letjelice ograničenih performansi mogu pružiti iznenađujuće kvalitetne rezultate ukoliko se pravilno koriste. Primjene li se kvalitetniji sustavi, opremljeni dodatnim tehnologijama (npr. RTK moduli – engl. *real time kinematics*) rezultati ispitivanja postaju još pouzdaniji. Hackney i Clayton (2015) smatraju kako je primjena bespilotnih letjelica u geomorfologiji budućnost istraživanja, pogotovo kada se kombinira s već postojećim metodama. Analiziranje takvih podataka pomoću geografskih informacijskih sustava (GIS) predstavlja moćan alata za istraživanje prostornih procesa koji oblikuju čovjekov život (Walsh i dr., 1998). Na temelju navedenih tehnologija napravljeni su mnogi radovi o periglacijalnim i glacijalnim prostorima (Śledź i dr., 2021; Bhardwaj i dr. 2016; Gindraux i dr. 2017), monitoringu posljedica prirodnih nepogoda (Giordan i dr., 2017; Gómez i Purdie, 2016), praćenju promjena marinskog reljefa (Mićunović i Faivre, 2020), te njihova upotreba svakim danom sve više raste.

Ponikve su kao reljefni oblik već dugi niz godina predmet istraživanja brojnih znanstvenika. Zbog svoje rasprostranjenosti predstavljaju dijagnostički reljefni oblik krškog područja (Ford i Williams, 2007). Jednu od najranijih klasifikacija ponikava započeo je Cvijić (1895), te su prema njegovoj metodologiji napravljeni mnogi radovi (Faivre, 1992). Daljnja istraživanja ponikava najčešće su se odnosila na njihovu morfogenezu i morfometriju (Bahtijarević i Faivre, 2012; Marković i dr., 2016), a zbog karakterističnih geomorfoloških obilježja, brojna istraživanja ponikava rađena su upravo na području Hrvatske (Klein, 1976; Mihljević, 1995; Faivre, 1992; Faivre i Reiffsteck, 1999, 2002; Pahernik, 2000; Buzjak, 2006; Faivre i Pahernik, 2007; Bočić, 2009; Ballut i Faivre, 2012; Lončar i Grcić, 2022). Ramsey i dr. (2014) među prvima istražuju mogućnost praćenja promjena na krškom reljefu uz pomoć bespilotne letjelice i kompaktne kamere visoke razlučivosti. Čeru i dr. (2017) analiziraju geomorfološko datiranje pleistocenskih konglomerata na temelju analize uzoraka sa dna ponikava, a za izračunavnje morfometrijskih pokazatelja koriste digitalni model reljefa stvoren pomoću LiDAR tehnologije. Moreno-Gómez i dr. (2019) također istražuju povezanost korištenja zemljišta i ranjivosti podzemnih voda na temelju analize ponikava. U svojem istraživanju predlažu novu metodologiju identifikacije ponikava unutar digitalnih analiza reljefa uz značajno povećanje točnosti.

U ovom radu će se pomoću bespilotne letjelice prikupiti podaci potrebni za geomorfološku analizu ponikava na otoku Cresu koja će biti provedena u odgovarajućim softverima. Cilj ovog rada je ispitati primjenu i učinkovitost bespilotne letjelice kao osnovnog sredstva prikupljanja podataka, te kvalitetu dobivenih rezultata nakon provedene analize. Shodno napisanim ciljevima, proizašle su sljedeće hipoteze:

H1: Primjena bespilotne letjelice pokazala se kao vrlo korisna metoda u geomorfološkim istraživanjima.

H2: Poluautomatska detekcija ponikava prikazuje veći broj ponikava od onih kartiranih na HOK-u i TK25.

H3: Model reljefa visoke prostorne razlučivosti predstavlja najkvalitetniji ulazni podatak za morfometrijsku analizu.

2. PODRUČJE ISTRAŽIVANJA

Otok Cres najveći je otok hrvatskog primorja, nalazi se na Sjevernom Jadranu unutar cresko-lošinjske skupine otoka (sl. 1). Površina otoka iznosi 405,78 km², dužina 66 km, širina između 2 i 12 km, a visina 648 m. U geomorfološkom smislu, otok Cres nastavak je Učke i Ćićarije čiji su dijelovi preplavljeni tijekom posljednje transgresije (Stražičić, 1997).

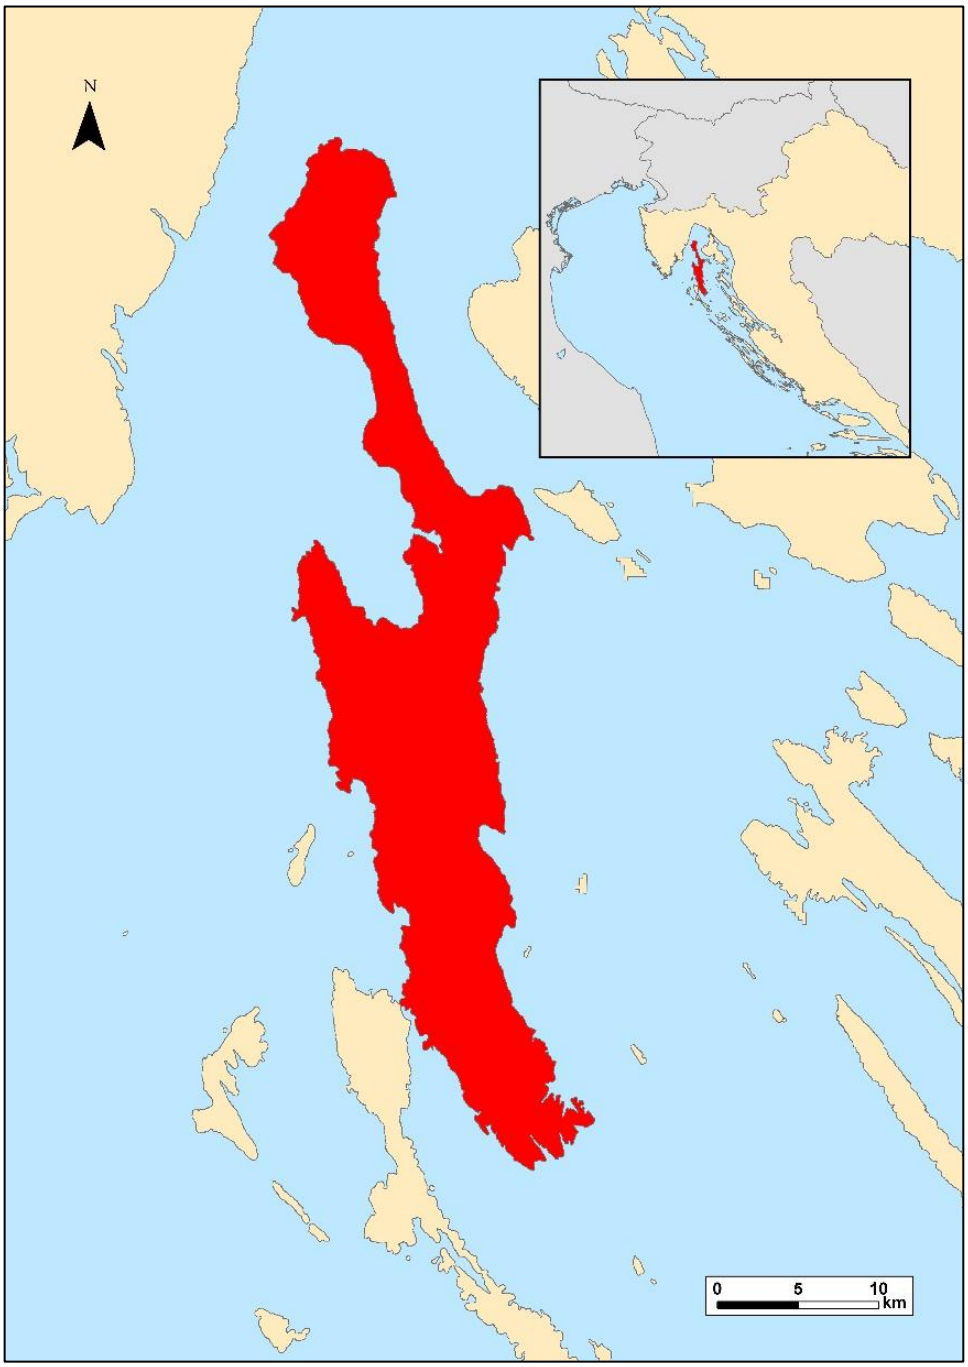

Sl. 1. Geografski položaj otoka Cresa

Zbog zanimljive povijesti i biološke raznolikosti, otok Cres bio je predmet mnogih istraživanja. Dosadašnja istraživanja bazirana su uglavnom na društvenim (npr. Lajić, 1993; Poropat, 2020; Crkvenčić, 1992), ili biološkim značajkama (Tomec, 2003; Cubric-Curik, 2011; Geissler i Grabert, 2019). Od ostalih prirodoslovnih istraživanja važno je istaknuti klimatološka (Pandžić i dr., 1993), a zbog povezanosti sa ovim radom na osobit način geomorfološka (Tandarić, 2011; Brkljača, 2022; Otoničar i dr., 2010; Duplančić, 2004).

2.1. Hipsometrija

Na južnom dijelu otoka Cresa prevladavaju niže nadmorske visine, što je vidljivo na slici 2, kao i u tablici 1, koja prikazuje kako najveći dio površine zauzimaju dijelovi niži od 30 m. Smješteni su u krajnjem južnom dijelu otoka, neposredno uz liniju obale (sl. 2). Površine od 30 do 50 m i od 50 do 70 m nadmorske visine zauzimaju gotovo podjednake udjele (svaka po 18%), dok su najmanje zastupljene površine više od 100 m (oko 15%). Kretanjem u smjeru S i SZ nadmorska visina postupno se povećava, kao i kut nagiba padina.

Tab. 1. Površinski udio hipsometrijskih razreda na južnom dijelu otoka Cresa

Hipsometrijski razredi (m)	**Udio u ukupnoj površini (%)**
< 30	31,4
30 - 50	18,9
50 - 70	18,4
70 - 100	16,7
> 100	14,7

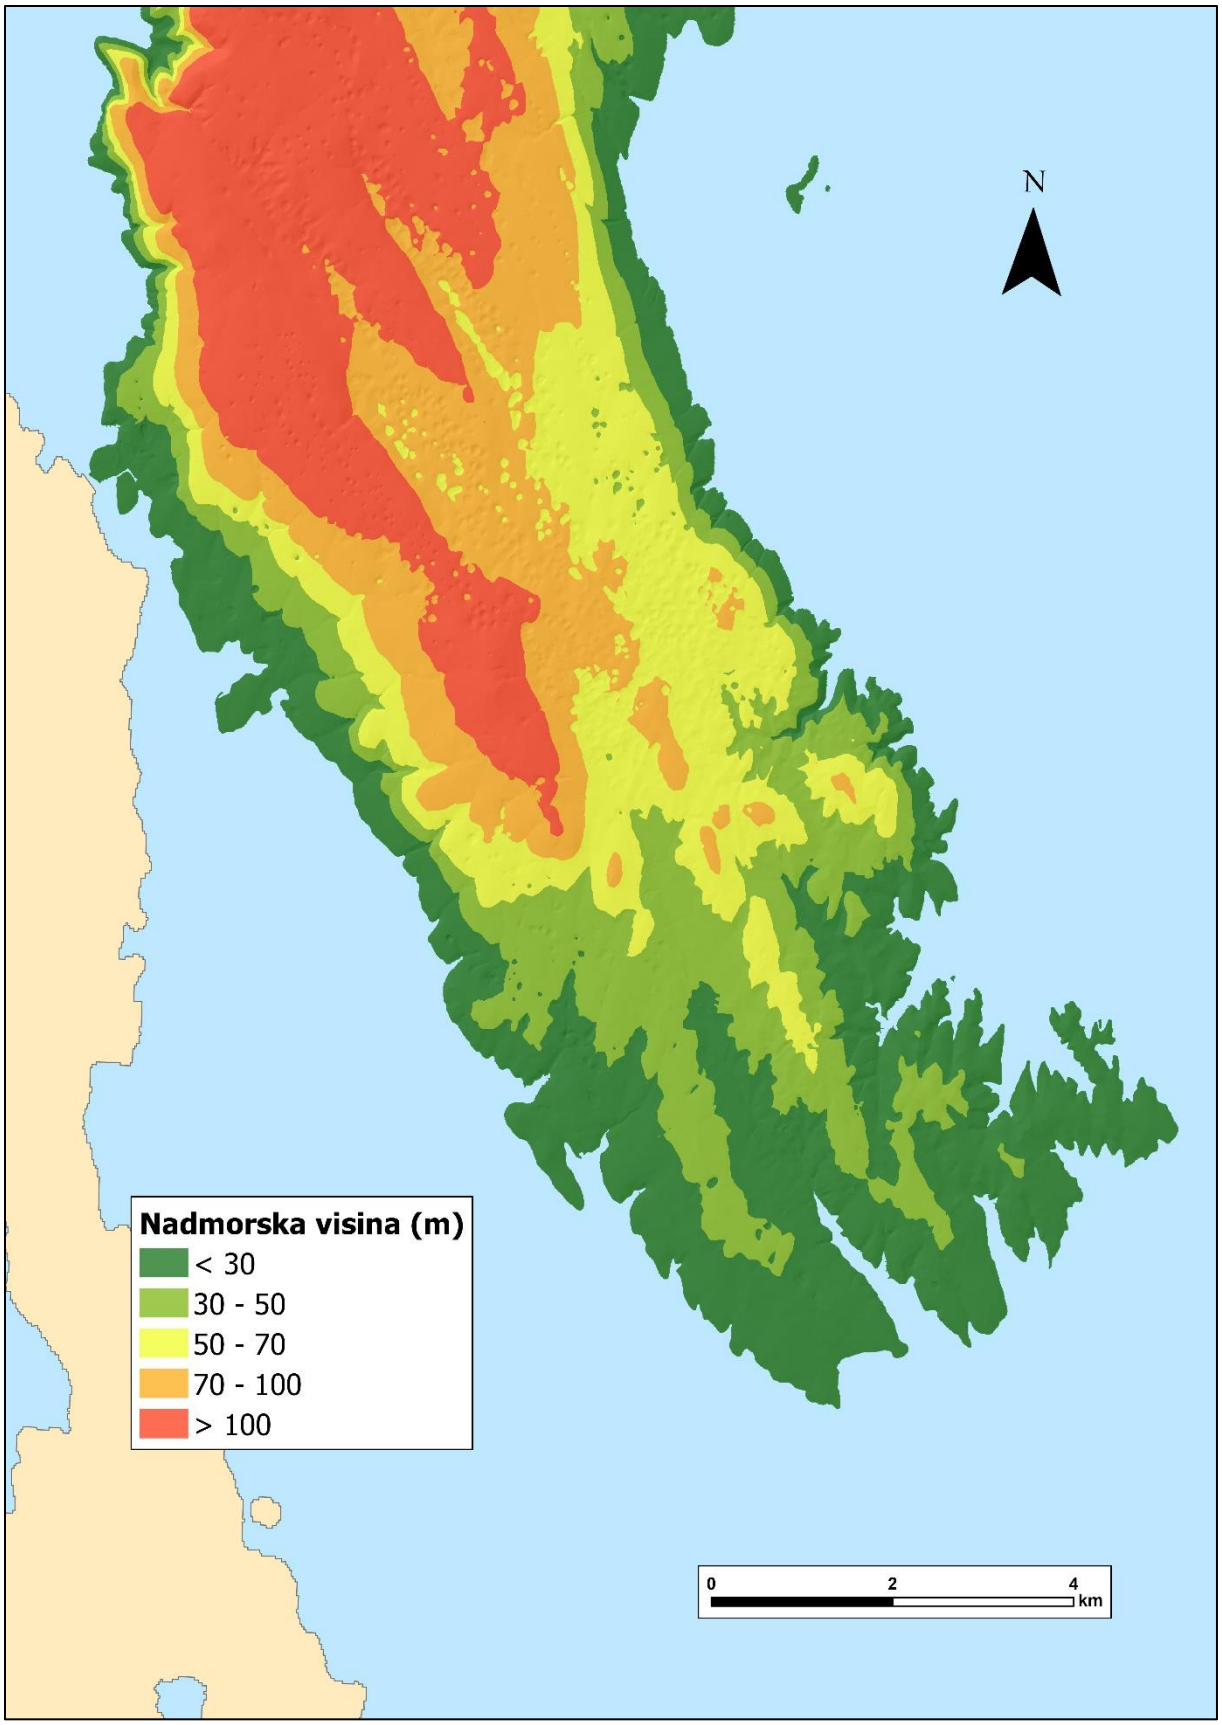

Sl. 2. Hipsometrijska karta južnog dijela otoka Cresa

2.2. Nagibi padina

Nagibi padina istraživanog područja klasificirani su po standardnoj geomorfološkoj klasifikaciji (Demek, 1972). Od postojećih šest kategorija nagiba padina na južnom dijelu otoka Cresa zastupljeno je njih četiri. Nagibi od 32° i više nisu zastupljeni što upućuje na područje s blagim nagibom padina (tab. 2).

Tab. 2. Površinski udio pojedinih razreda nagiba na južnom dijelu otoka Cresa

Nagib padina (°)	**Udio u ukupnoj površini (%)**
0 - 2	17,0
2 - 5	44,4
5 - 12	33,3
12 - 32	5,2
32 - 55	0,0
> 55	0,0

Površinskim udjelom dominira razred nagiba od 2° do 5° (oko 44%), dok je najmanje zastupljen razred onaj sa najvećim nagibima (12 - 32°) za analizirano područje (oko 5%). Slično kao i kod hipsometrijskih razreda, slika 3 prikazuje kako strmije padine postaju zastupljenije u smjeru S, dok su one blaže najzastupljenije u samom obalnom pojasu. Također, najzastupljenijem razredu nagiba padina pripadaju i padine strmijih ponikava u središnjem dijelu južnog Cresa.

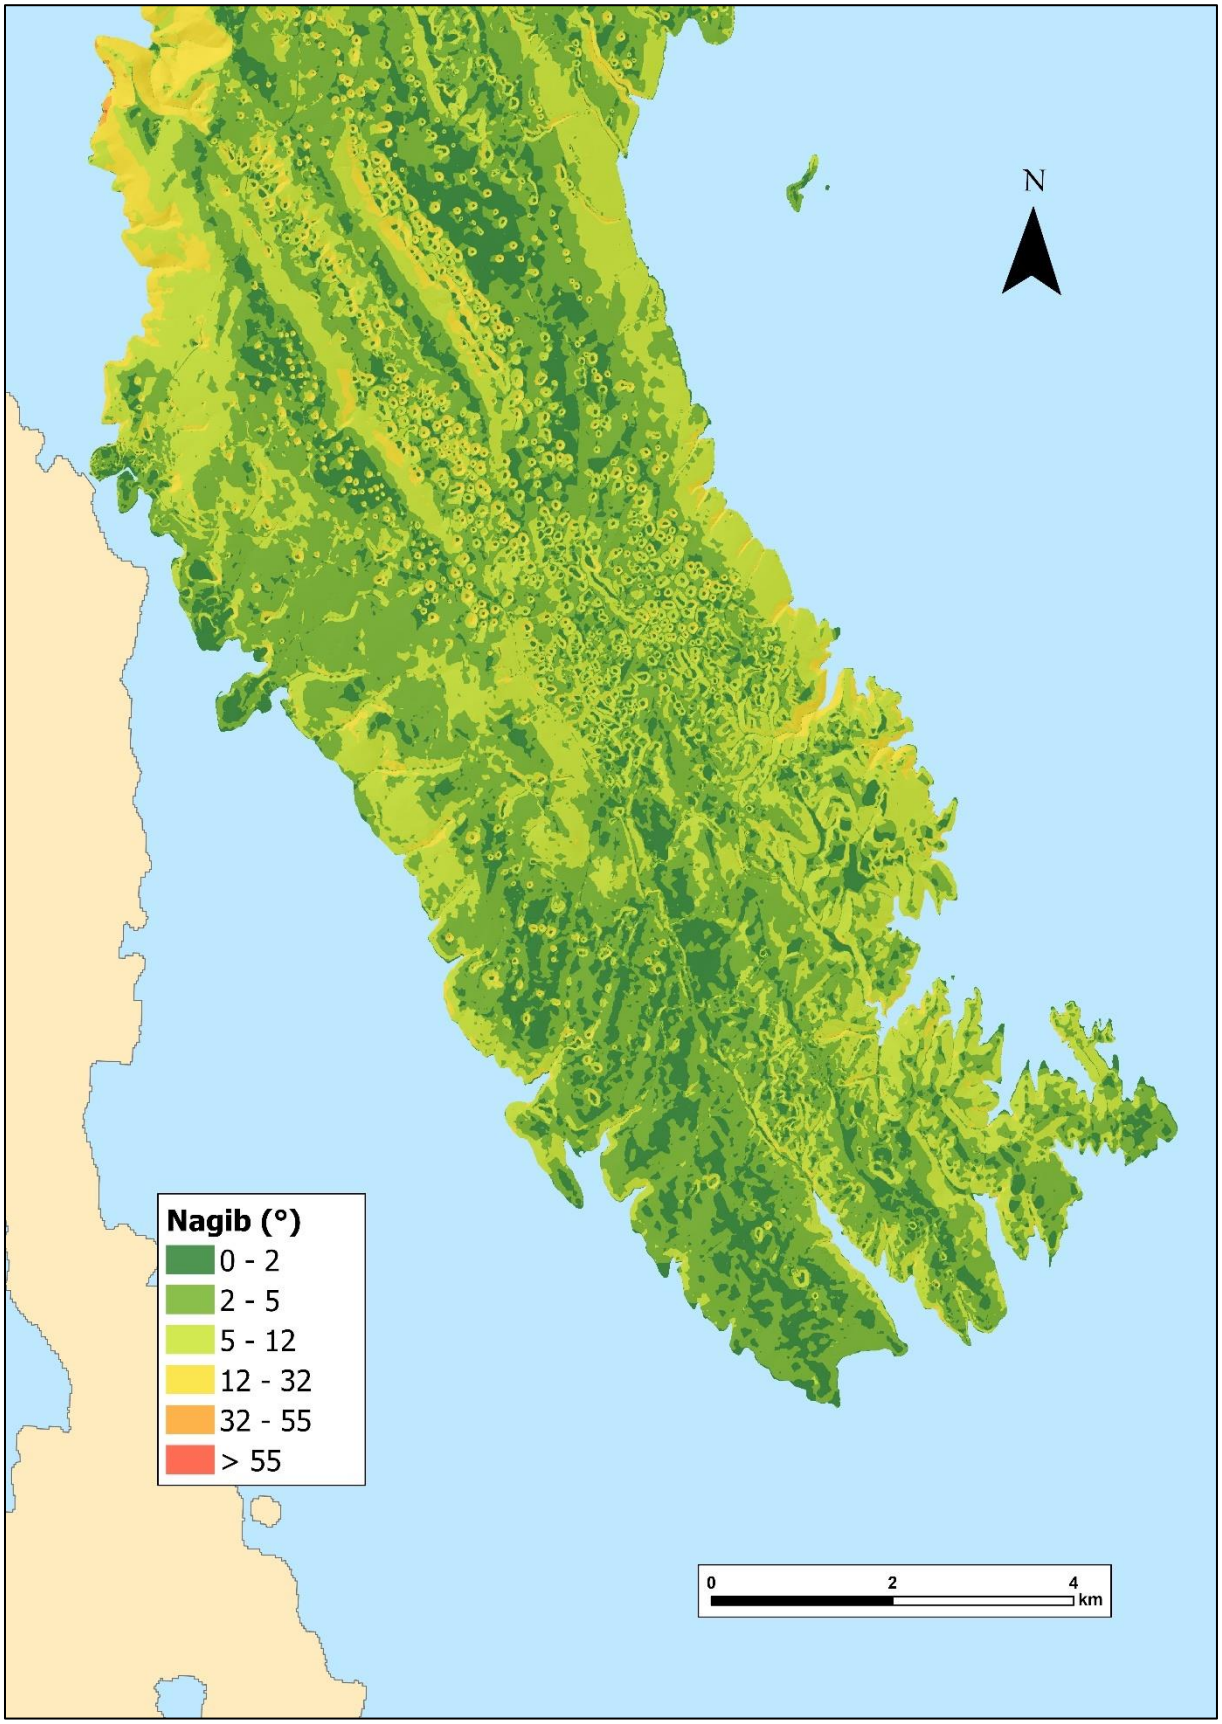

Sl. 3. Karta nagiba padina južnog dijela otoka Cresa

2.3. Vertikalna raščlanjenost reljefa

Standardne kategorije raščlanjenosti reljefa za Hrvatsku prema Bognaru (1992) su: 0-5 m/km² predstavlja zaravnjeni reljef, 5-30 m/km² slabo raščlanjene ravnice, 30-100 m/km² slabo raščlanjen reljef, 100-300 m/km² umjereno raščlanjen reljef, 300-800 m/km² izrazito raščlanjen reljef te više od 800 m/km² vrlo izrazito raščlanjen reljef. Prikazom vertikalne raščlanjenosti reljefa na karti moguće je uvidjeti posebnosti reljefnih oblika.

Od navedenih šest kategorija na analiziranom području zastupljeno je njih četiri. Slabo raščlanjen reljef je dominantna kategorija koja zauzima više od polovice južnog dijela otoka Cresa (tab. 3). Također, na slici 4 vidljivo je kako se upravo u toj kategoriji i nalazi najveći broj ponikava.

Tab. 3. Površinski udio pojedinih razreda vertikalne raščlanjenosti reljefa na južnom dijelu otoka Cresa

Vertikalna raščlanjenost reljefa (m/km²)	**Udio u ukupnoj površini (%)**
0 - 5	6,2
5 - 30	25,6
30 - 100	53,6
100 - 300	14,6
> 300	0,0

U smjeru S raščlanjenost reljefa raste, a najviša kategorija raščlanjenosti zastupljena je s nešto manje od 15 %. Usporedbom podataka o nadmorskoj visini i raščlanjenosti reljefa lako se uočava kako je reljef najviše raščlanjen unutar viših razreda nadmorske visine (sl. 4). Preostale dvije kategorije – izrazito i vrlo izrazito raščlanjen reljef zastupljene su isključivo na sjevernijim dijelovima otoka Cresa.

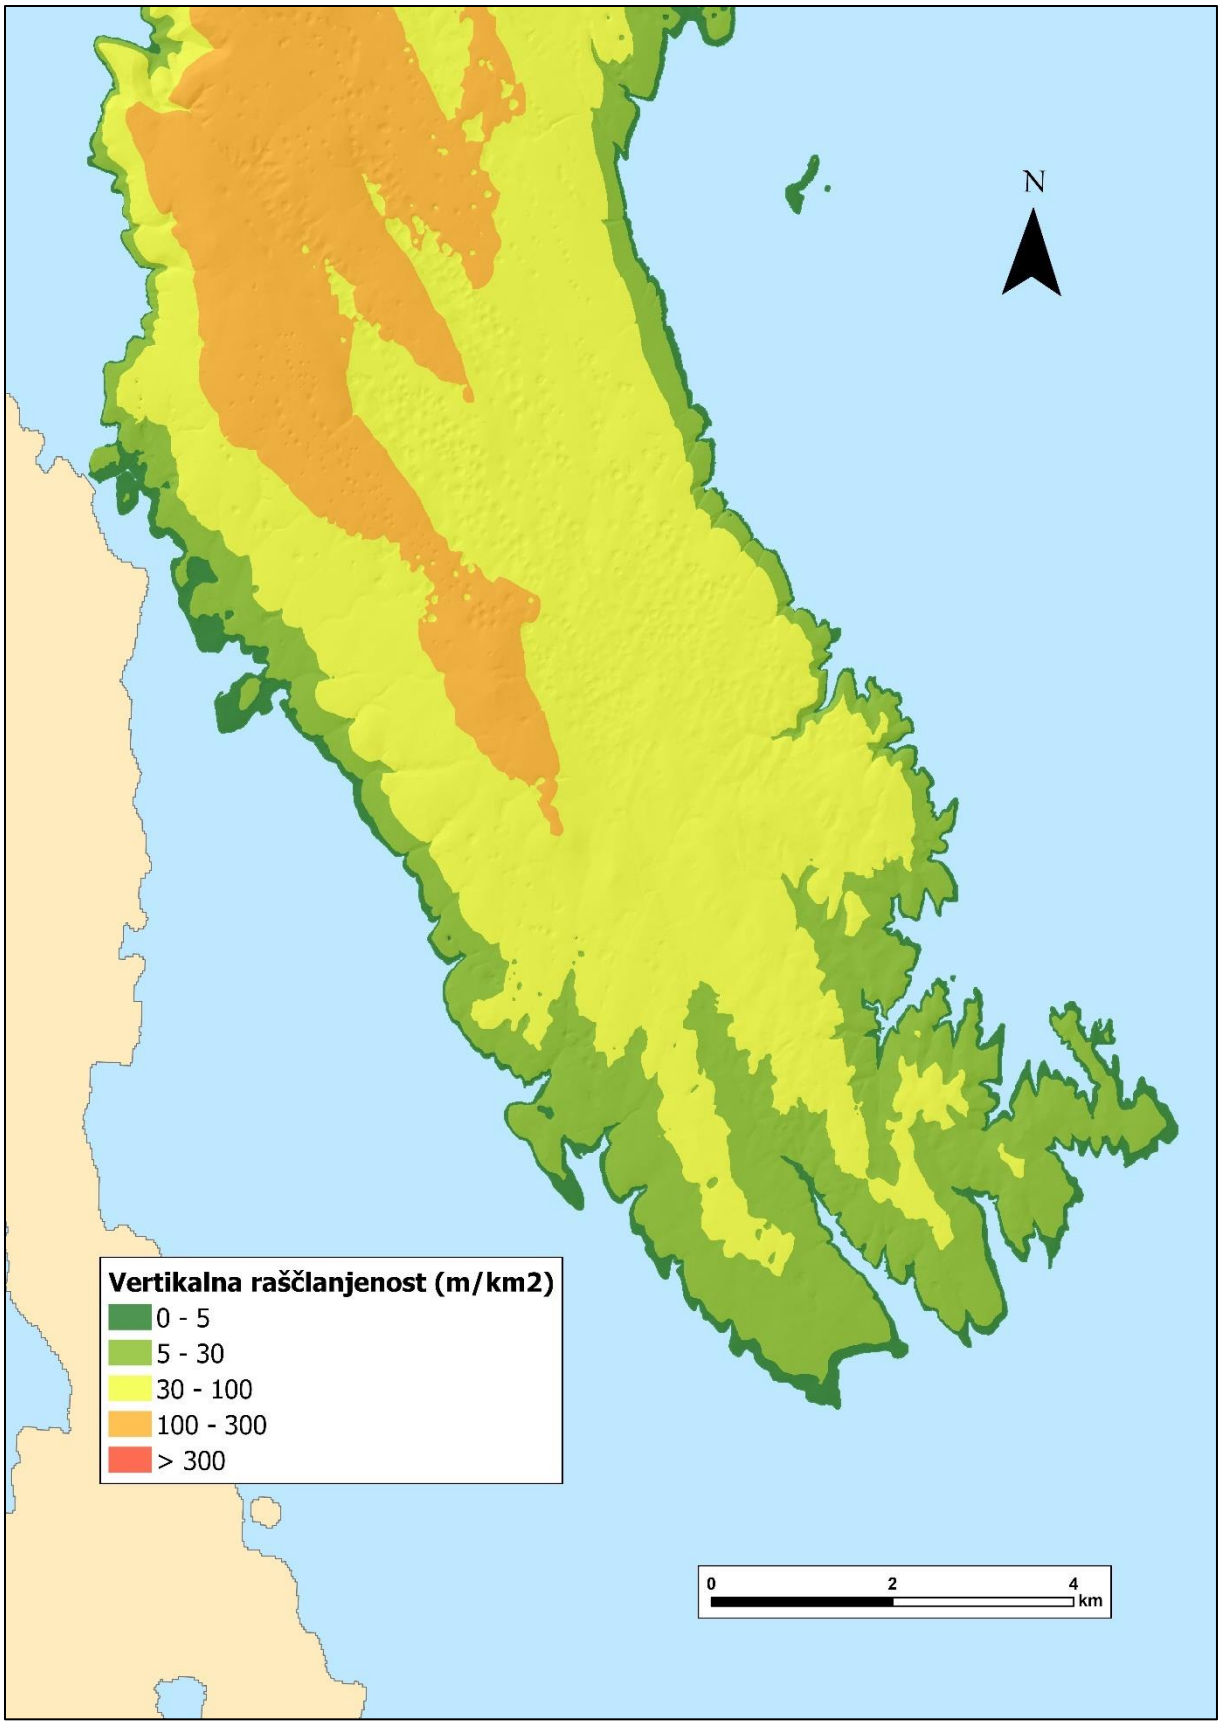

Sl. 4. Karta vertikalne raščlanjenosti južnog dijela otoka Cresa

2.4. Orijentacija padina

Orijentacija padina podijeljena je u 8 razreda prema glavnim i sporednim stranama svijeta. O njoj ovise insolacija, utjecaj glavnih vjetrova, i drugi klimatski utjecaji koji imaju veliku važnost za geomorfološke procese i oblikovanje reljefa (Mićunović, 2019). Npr. južna strana, koja je prisojna, imat će veće temperaturne amplitude koje mogu utjecati na pojačano trošenje (Faivre i Mićunović, 2017).

Prema karti orijentacije padina južnog dijela Cresa (sl. 5) lako se uočava nekoliko paralelnih hrptova koji dijele otok na zapadnu i istočnu stranu. Ipak, analiziranim područjem dominira istočna orijentacija padina (nešto više od 20% ukupne površine), dok zapadna zauzima oko 16% (tab. 4). Reljefno viši i nagibom strmiji dijelovi analiziranog područja imaju pretežito SZ i Z orijentaciju padina, dok blaži i niži dijelovi imaju pretežito I i SI orijentaciju.

Tab. 4. Površinski udio pojedinih razreda orijentacije padina južnog dijela otoka Cresa

Orijentacija padine	Udio u ukupnoj površini (%)
SI	14,7
I	20,4
JI	10,4
J	11,2
JZ	18,1
Z	16,1
SZ	6,7
S	2,4

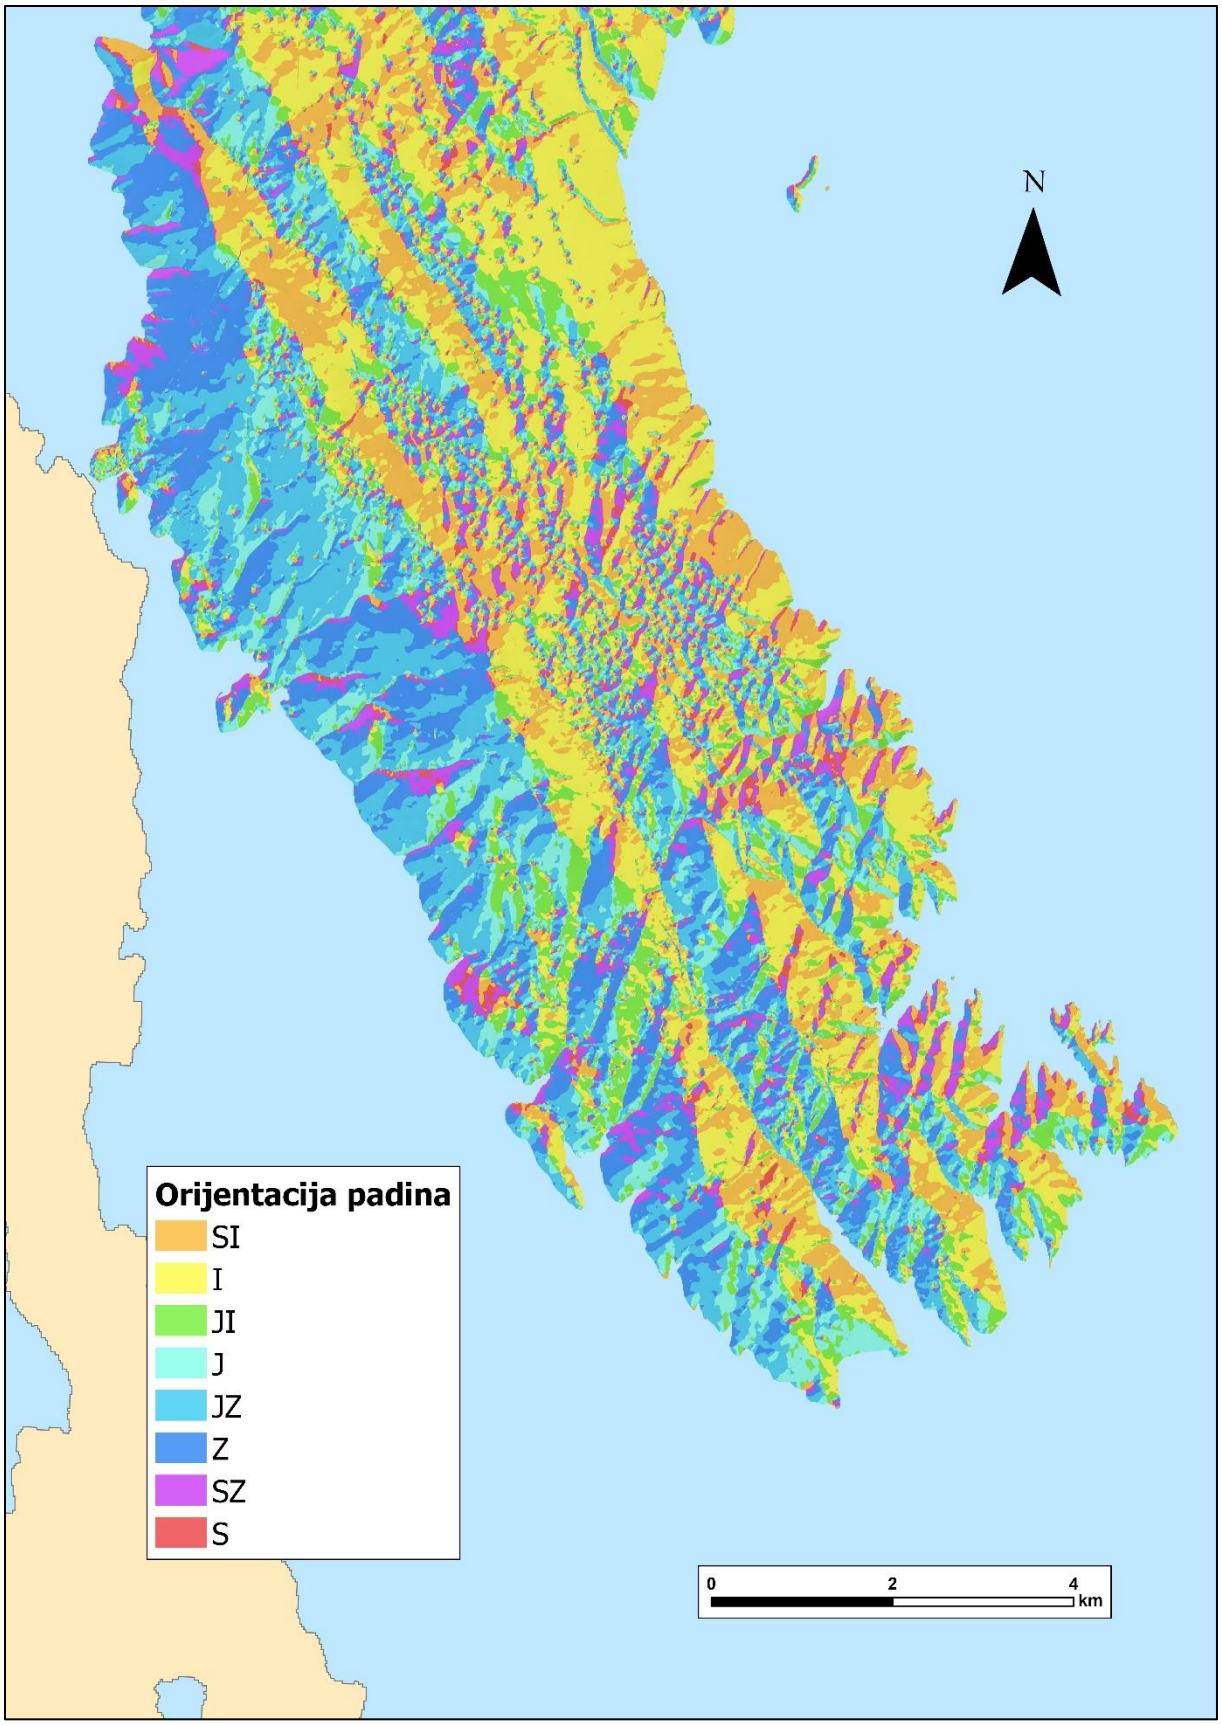

Sl. 5. Karta orijentacije padina južnog dijela otoka Cresa

Uže područje istraživanja ovog rada odnosi se na manji dio južnog dijela otoka Cresa koji je relativno gusto prekriven ponikvama. Preciznije, radi se o području površine 0,4 km^2 smještenog SI od naselja Osor koje se nalazi na granici sa susjednim otokom Lošinjem (sl. 6). Većina površine je umjereno prekrivena vegetacijom, odnosno s ponešto makije i nekoliko vrsta tipične mediteranske flore. Područjem dominira krški reljef bogat ponikvama i ostalim tipičnim krškim oblicima poput škrapa i kamenica. Istraživanom području moguće je pristupiti nerazvrstanom cestom (makadam) koja se spaja na cestu D100 koja povezuje otoke Cres i Lošinj.

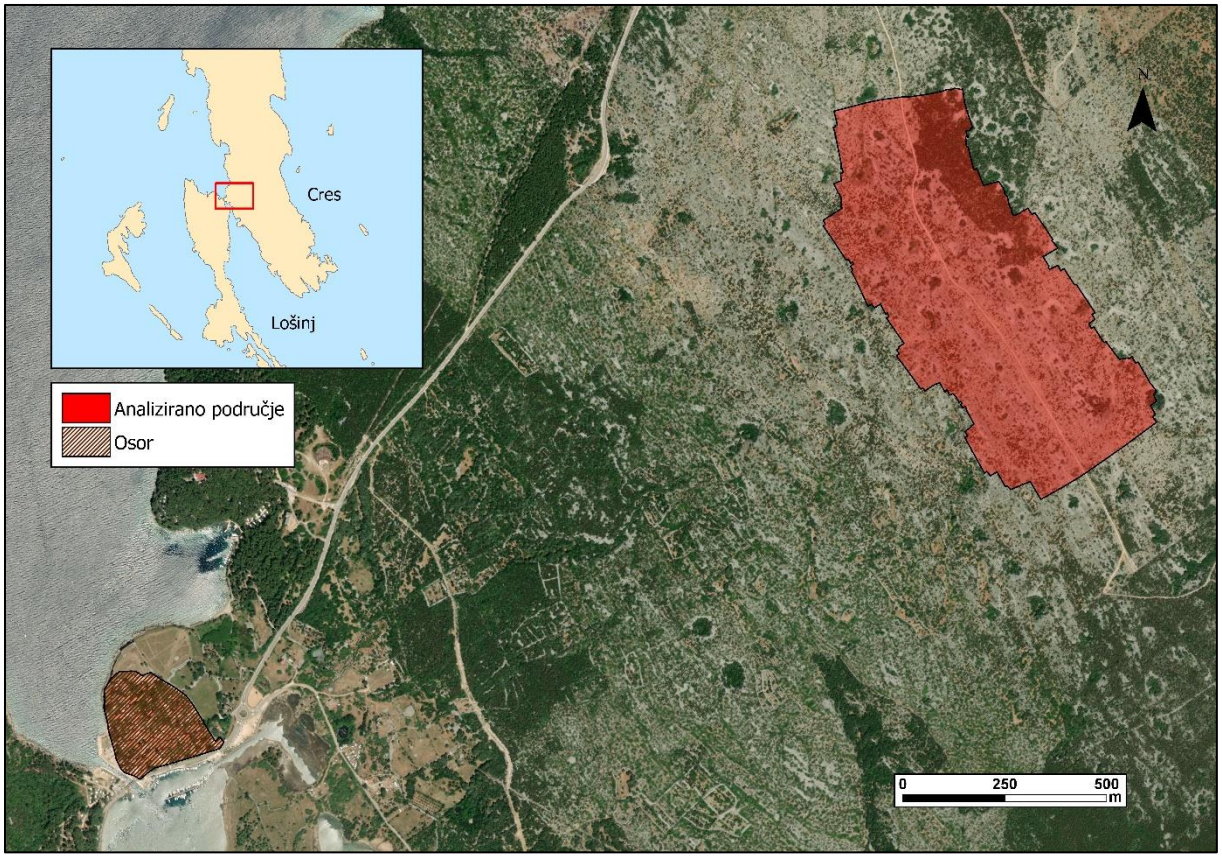

Sl. 6. Uže područje istraživanja

2.5. Geološka obilježja

Otok Cres karakterizira krški reljef koji je najvažniji čimbenik svih ostalih geomorfoloških fenomena. U sjevernom djelu otoka prevladavaju vapnenci, dok u središnjem i južnom prevladavaju dolomiti. Takva raspodjela sastava stijena odražava se i u izgledu reljefa – većina uzvišenja nalazi se na sjeveru otoka, dok su najveće depresije i zaravnjeni reljefni oblici zastupljeni u središnjem i južnom djelu otoka (Stražičić, 1975). Obalni reljef uglavnom je mlađeg postanka sastavljen djelomično od strmih, stjenovitih obala na istočnoj strani otoka i niskih, blagih obala na južnom djelu (Stražičić, 1997). Zbog svoje ljuskave strukture, uzdužnih rasjeda i pukotina, otok Cres je pogodan za razvoj ponikava. Njihov oblik izravno je određen podlogom na kojoj se nalaze stoga su ponikve na vapnencima uže i dublje, dok su one na dolomitima pliće i šire (Slukan, 1992). Ponikve unutar istraživanog područja nastale su na vapnenačkoj podlozi, uglavnom na debeloslojevitim i masivnim pelagičkim vapnencima iz Gornje krede (sl. 7).

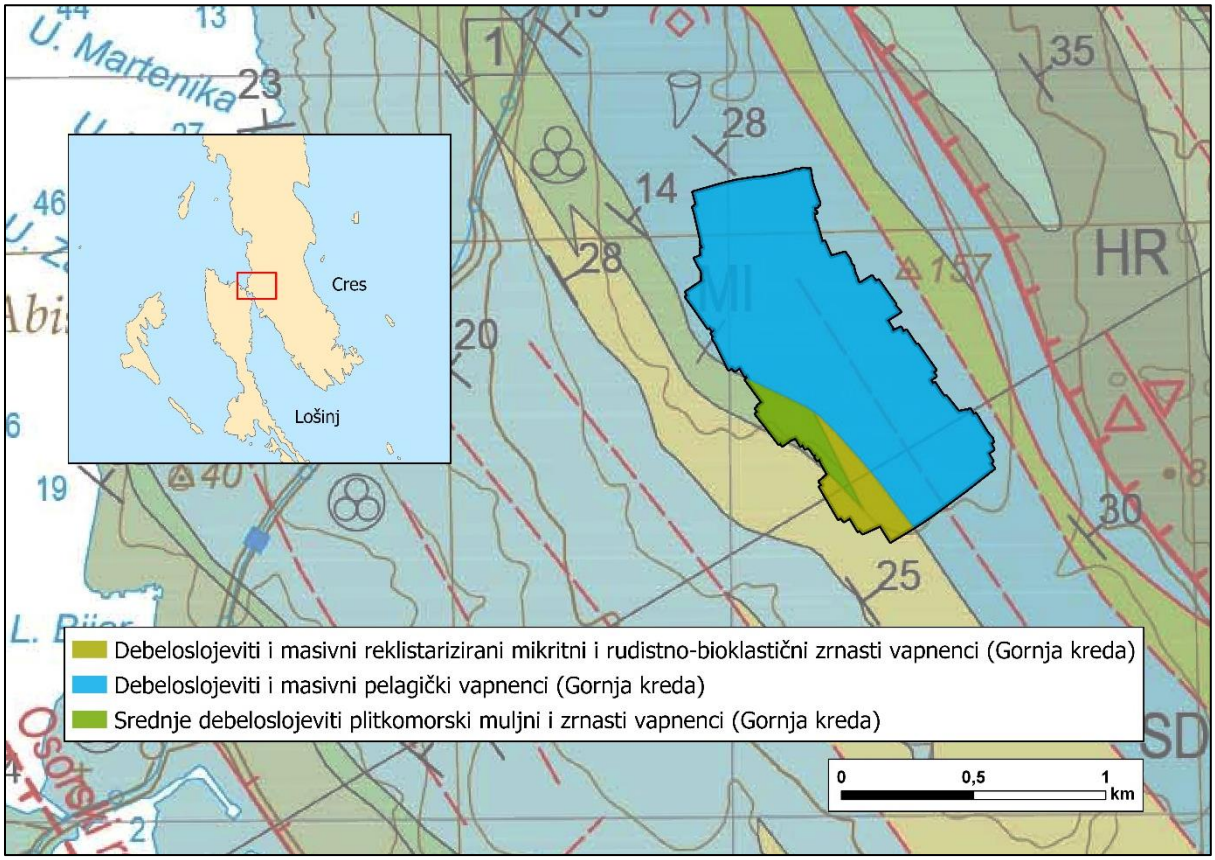

Sl. 7. Geološka karta analiziranog područja

3. METODE I MATERIJALI

U ovom radu korišteno je više različitih metoda, prikupljanja i analize podataka – terensko kartiranje, snimanje bespilotnom letjelicom, izrađivanje različitih prostornih modela, te analiza dobivenih rezultata i njihova vizualizacija pomoću GIS softvera.
Odabir područja za terensko kartiranje, snimanje bespilotnom letjelicom i kasniju analizu podataka napravljeni su pomoću Geoportala Državne geodetske uprave i dostupnih digitalnih karata. Za odabir pogodnog područja korišten je digitalni ortofoto snimak (DOF) iz 2019. i 2020. godine i topografska karta mjerila 1:25 000 (TK25). Kako bi analiza prikupljenih podataka bila što objektivnija, za analizirano područje odabrana je površina umjereno prekrivena vegetacijom. Tim pristupom nastojala se osigurati što veća objektivnost analize. Analizom DOF-a i TK25 odabrano je područje SI od naselja Osor koje ima dovoljan broj ponikava različitih dimenzija, te zadovoljavajuću prisutnost vegetacije.

Terensko prikupljanje podataka provedeno je u dva navrata u travnju 2022. godine. Prvi korak odnosio se na označavanje područja istraživanja pomoću kontrolnih točaka (engl. *ground control points*, *GCP*), te prikupljanje podataka o njihovoj geografskoj lokaciji kako bi se podaci prikupljeni bespilotnom letjelicom mogli što preciznije georeferencirati. Oznake s arapskim brojevima raspoređene su ravnomjerno unutar analiziranog područja, a podaci o njihovoj geografskoj lokaciji prikupljeni su pomoću Trimble Catalyst DA2 digitalnog GNSS prijamnika i CROPOS sustava (Croatian Positioning System). Podaci o lokaciji prikupljani su unutar ArcGIS Field Maps mobilne aplikacije koja je dio ArcGIS Online sustava GIS tvrtke Esri.
Drugi korak prikupljanja podataka odnosio se na snimanje analiziranog područja bespilotnom letjelicom DJI Phantom 4 Pro projekta HRZZ-IP-2019-04-9445 Relativna promjena morske razine i klimatske promjene duž istočne obale Jadrana - SEALeveL Geografski odsjek Prirodoslovno-matematički fakultet Zagreb. Nakon postavljanja kontrolnih točaka i prikupljanja podataka o lokaciji, bespilotnom letjelicom je fotografirano analizirano područje uz odgovarajuće preklapanje i postavke kamere na visini od 100 metara od točke polijetanja.

Prikupljeni podaci obrađivali su se pomoću nekoliko različitih softvera. Kontrolne točke analizirane su pomoću ArcGIS Pro 2.3.0 softvera (Geografski odsjek Prirodoslovno – matematičkog fakulteta u Zagrebu) i pripremljene za izvoz u obliku teksta koji sadrži informacije o geografskoj širini, dužini i nadmorskoj visini.

Tako uređena datoteka (tablica odvojena tabulatorom) sa svim točkama obrađena je pomoću T7D web aplikacije za transformaciju koordinata Republike Hrvatske u vlasništvu Hrvatske geodetske uprave. Time su geografska širina, dužina i nadmorska visina prikupljeni GNSS prijemnikom na WGS84 elipsoidu (World Geodetic System 1984) transformirani u HTRS96/TM kartografsku projekciju (Terestrički Referentni Sustav za epohu 1995.55/ Transverse Mercator Projection), službeni koordinatni sustav Republike Hrvatske. Nova, transformirana datoteka upotrjebljena je u daljnjoj analizi podataka.

Sljedeći korišteni softver bio je Agisoft Metashape Professional 1.8.4. pomoću kojega su iz snimljenih fotografija izrađeni različiti modeli prostora – digitalni model reljefa (engl. *digital elevation model*, *DEM*), digitalni model površina (engl. *digital surface model*, *DSM*) i digitalni ortofoto snimak (engl. *digital orto photo, DOF*) koji su georefencirani pomoću ranije pripremljenih kontrolnih točaka.

Njihovoj izradi prethodilo je generiranje gustog oblaka točaka koji je temelj za njihovo stvaranje. Nakon provedene obrade modeli su izvezeni u TIF obliku datoteke koji je pogodan za daljnju softversku analizu.

Konačno, preostala analiza provedena je pomoću ArcGIS Pro 2.3.0. softvera na temelju ranije dobivenih rasterskih datoteka. Radi jednostavnije predodžbe prostora napravljena je osnovna morfometrijska analiza reljefa. Izrađena je pomoću Spatial Analyst paketa alata, a uključuje nagib padina (engl. *slope*), vertikalnu raščlanjenost reljefa (engl. *focal statistics*), orijentacija padina (engl. *aspect*), te upotrebu sjenčanja (engl. *hillshade*) radi što bolje vizualizacije. Izdvajanje ponikava tj. njihovih oboda iz generiranih modela prostora napravljeno je pomoću dvije različite metodologije koje su prikazane u nastavku ovog rada. Zbog visoke prostorne razlučivosti i preciznih podataka prikupljenih pomoću GNSS prijamnika i bespilotne letjelice provedene su detaljne analize modela prostora. Svakoj izdvojenoj ponikvi dodijeljen je broj (engl. ID), određena joj je tip, te su izračunati morfometrijski pokazatelji – relativna dubina, minimalna i maksimalna nadmorska visina, volumen, površina, opseg i indeks kružnosti. Za kontrolu kvalitete modeliranih podataka napravljena je usporedba visina dobivenih pomoću bespilotne letjelice i onih prikupljenih pomoću GNSS prijamnika.

Nadalje, nakon izdvajanja detektiranih ponikava iz ranije generiranih modela provedena je usporedba s već postojećim izvorima podataka. Za usporedbu s postojećim stanjem korištena je topografska karta mjerila 1: 25000 (TK 25) i hrvatska osnovna karta (HOK) mjerila 1:5000. Pomoću vektoriziranih podataka napravljena je usporedba točnosti s rezultatima dobivenim pomoću bespilotne letjelice.

3.1. TERENSKO PRIKUPLJANJE PODATAKA

3.1.1. Odabir područja pogodnog za analizu

Prvi korak planiranja istraživanja ovog rada bio je odabir adekvatnog područja za analizu koja se temelji na podacima prikupljenim pomoću bespilotne letjelice, odnosno pasivnim senzorom kojeg ona nosi. Kod ovog istraživanja korišten senzor dio je bespilotne letjelice kojeg nije moguće odvojiti. Bilježi tri kanala unutar vidljivog djela spektra – crveni, zeleni i plavi (engl. *RGB – red, green, blue*) te kombiniranjem prikupljenih podataka stvara fotografije (DJI, 2021). Za razliku od aktivnih senzora koji imaju mogućnost odašiljanja i registriranja emitiranog signala, pasivni senzori imaju mogućnost isključivo registriranja signala – u ovom istraživanju to je reflektirana sunčeva svjetlost s objekta istraživanja. Zbog toga nemaju mogućnost „prodiranja“ kroz vegetaciju, odnosno ne mogu zabilježiti informaciju o prostoru koji je zaklonjen vegetacijom (Hackney i Clayton, 2015). Upravo je to bio ključni kriterij pri odabiru prostora za analizu – djelomična prisutnost vegetacije u ponikvama. Na taj način moguće je osigurati relativnu objektivnost istraživanja zbog sveprisutnosti vegetacije u prostoru koji nas okružuje. Konkretni odabir mikrolokacije na otoku Cresu napravljen je pomoću Geoportala Državne geodetske uprave (sl. 8). Korišteni slojevi su digitalni ortofoto (DOF) iz 2019. i 2020. godine i topografska karta (TK25). Prvi korak bio je lociranje dijelova otoka Cresa s ponikvama kao i relativno jednostavan pristup mjestu istraživanja. Pomoću topografske karte odabran je južni dio otoka zbog relativne blizine državne ceste D100 i dovoljnog broja ponikava različitih veličina. Drugi korak podrazumijevao je utvrđivanje mikrolokacije gdje je glavni kriterij bio prisutnost vegetacije. Odabrana mikrolokacija tipičan je primjer krškog reljefa, uz prisutnost tipične mediteranske vegetacije koja je relativno jednoliko rasprostranjena po istraživanom području. Intenzivnija prisutnost vegetacije vidljiva je u SI dijelu analiziranog područja (sl. 8). Takva konfiguracija reljefa i vegetacije odabrano područje čini pogodnim za predviđenu analizu.

Sl. 8. Odabir mikrolokacije istraživanja pomoću Geoportala DGU

3.1.2. Prikupljanje podataka o kontrolnim točkama

Prvi korak odnosi se na pravilno postavljanje kontrolnih točaka unutar istraživanog područja. Kontrolne točke izrađene su od plastificiranog papira crvene boje (radi bolje uočljivosti), a na sebi imaju bijele oznake u obliku arapskih brojeva od 1 do 9 te prigodne znakove radi lakšeg raspoznavanja. Postavljene su nesimetrično unutar istraživanog područja kako bi preciznost kasnijeg georferenciranja bila jednaka u središtu i na rubnim dijelovima modela (Glavačević, 2021).

Ukupno je postavljeno deset kontrolnih točaka, a prilikom postavljanja opterećene su dodatnom težinom kako ih vjetar ne bi pomaknuo, što može rezultirati netočnim podacima o geografskoj lokaciji prilikom daljnje obrade. Nakon što su sve točke postavljenje njihove pozicije su prikupljene pomoću GNSS uređaja (sl. 9).

Sl. 9. Prikupljanje podataka o geografskoj lokaciji kontrolnih točaka

Za prikupljanje podataka o lokaciji korišteni su Trimble Catalyst DA2 digitalni GNSS prijamnik (projekta HRZZ-IP-2019-04-9445-SEALeveL), CROPOS usluga preciznog pozicioniranja i ArcGIS Field Maps mobilna aplikacija. Trimble Catalyst DA2 digitalni GNSS prijamnik odlikuje mogućnost centimetarske preciznosti uz odgovarajući paket pretplate (Potpora Sveučilišta u Zagrebu, 2021). Bez korištenja pretplate za precizno pozicioniranje preciznost podatka emitiranih na kontrolni uređaj je oko 2 m. Maksimalna moguća preciznost (koje je primijenjena u ovom istraživanju) iznosi 1 cm horizontalno i 2 cm vertikalno, što je zadovoljavajuće prilikom određivanja nadmorskih visina i geografskih lokacija ponikava (Trimble, 2021). Uređaj komunicira putem *Bluetooth* veze sa bilo kojim Android ili iOS uređajem što omogućava integraciju drugih softvera za prikupljanje podataka o lokaciji. Izuzetno je pogodan za terenski rad zbog malene težine koja omogućava jednostavno rukovanje (sl. 10). Također, podržava sve svjetske GNSS sustave što rezultira nesmetanim radom u bilo kojem djelu svijeta gdje takva podrška postoji (Trimble, 2021).

GNSS PERFORMANCE

SBAS
Horizontal accuracy ..... 0.6 m RMS
Vertical accuracy ..... 1.2 m RMS

Code Differential (DGPS)
Horizontal accuracy ..... 0.3 m + 1 ppm RMS
Vertical accuracy ..... 0.6 m + 1 ppm RMS

Single baseline (<30 km) RTK
Horizontal accuracy ..... 10 mm + 1 ppm RMS
Vertical accuracy ..... 20 mm + 1 ppm RMS

Network RTK
Horizontal accuracy ..... 10 mm + 0.5 ppm RMS
Vertical accuracy ..... 20 mm + 0.5 ppm RMS

Trimble RTX™ (using Trimble Corrections Hub)
Horizontal accuracy ..... 2 cm RMS
Vertical accuracy ..... 5 cm RMS

Post-processed
Horizontal accuracy ..... 10 mm + 1 ppm RMS
Vertical accuracy ..... 20 mm + 1 ppm RMS

Positioning rate ..... 1 Hz, 5 Hz, 10 Hz

SIGNAL TRACKING
- Trimble ProPoint GNSS positioning technology for improved accuracy and productivity in challenging GNSS conditions[1]
- GPS: L1C/A, L2C, L5
- GLONASS: L1C/A, L2C/A
- SBAS: L1C/A, L2C, L5
- Galileo: E1, E5A
- BeiDou: B1, B2A
- QZSS: L1C/A, L2C, L5
- NavIC (IRNSS): L5
- Digital channels: Software controlled by Catalyst dynamic signal tracking using mathematical channels

MECHANICAL
Dimensions (Diameter x Depth) ..... 128 x 55 mm
Weight ..... 330 g (11.6 oz)
Ingress protection level ..... IP65 (dust proof, rain proof)
Drop, shock, & vibration ..... Survives 2 m tipping falls
Survives 1.2 m free falls to concrete
Survives vibrations & mechanical shocks (MIL-STD-810G test method)

Supported Platforms
Android ..... Android 5.0 (Pie) and higher
iOS ..... iOS 13.0 and higher

COMMUNICATIONS/CONNECTIVITY
Bluetooth 4.2
Apple ..... Made for iOS certified
Ports ..... USB-A (Power only)
Data protocols ..... NTRIP, VRS, RTCM 3.x, CMRx , DCOL
Position output ..... NMEA (LLH), DCOL
Android Location Service
Apple Location Service
Android Location Extras

BATTERY AND POWER
Requires external USB battery pack
External power input ..... USB-A (5 Vdc 1 A)
Power consumption ..... 0.5–2.5 W

ENVIRONMENTAL
Operating ambient temperature ..... −20 °C to 60 °C (−4 °F to 140 °F)
Storage temperature ..... −40 °C to 70 °C (−40 °F to 158 °F)
Operating humidity ..... 95% RH, non-condensing
Operating altitude ..... Tested to 9,000 m (29,500 ft)

COMPLIANCE
USA: FCC Part 15 (Class B device), Canada: ICES-003; Europe: CE; UK: UKCA; Australasia: RCM.
For latest compliance status geospatial.trimble.com/DA2-compliance

Sl. 10. Trimble Catalyst DA2 GNSS prijamnik i njegove tehničke specifikacije

Izvor: https://upgsolutions.com/catalyst/

CROPOS sustav (engl. CROatian POsitioning System) je državna mreža referentnih GNSS stanica Republike Hrvatske koja omogućuje poboljšano pozicioniranje i navigaciju na cijelom teritoriju države 24 sata dnevno, 7 dana u tjednu, 365 dana u godini. Uspostavljen je 2008. godine od strane Države geodetske uprave (CROPOS, 2022).

U okviru CROPOS sustava postavljeno je 30 referentnih GNSS stanica na međusobnoj udaljenosti od 70 km, tako da ravnomjerno prekrivaju područje države koje prikupljaju podatke mjerenja i kontinuirano ih šalju u kontrolni centar. U kontrolnom centru se podaci mjerenja provjeravaju, obrađuju te se obavlja izjednačenje mjerenja i računanje korekcijskih parametara. Korekcijski parametri dostupni su korisnicima na terenu putem mobilnog interneta i standardiziranog NTRIP protokola (sl. 11) (Marjanović, 2010). Na području istraživanja, najbliža referentna stanica nalazi se u centru Malog Lošinja, čime se zbog blizine omogućuju podaci sa što manjom greškom. Za pristup sustavu potrebno je imati korisničko ime i lozinku, odnosno obvezna je registracija korisnika u Državnoj geodetskoj upravi. Korisnički podaci koji su se upotrebljavali u ovome istraživanju ustupljeni su posredovanjem Geografskog odsjeka Prirodoslovno-matematičkog fakulteta u Zgrebu.

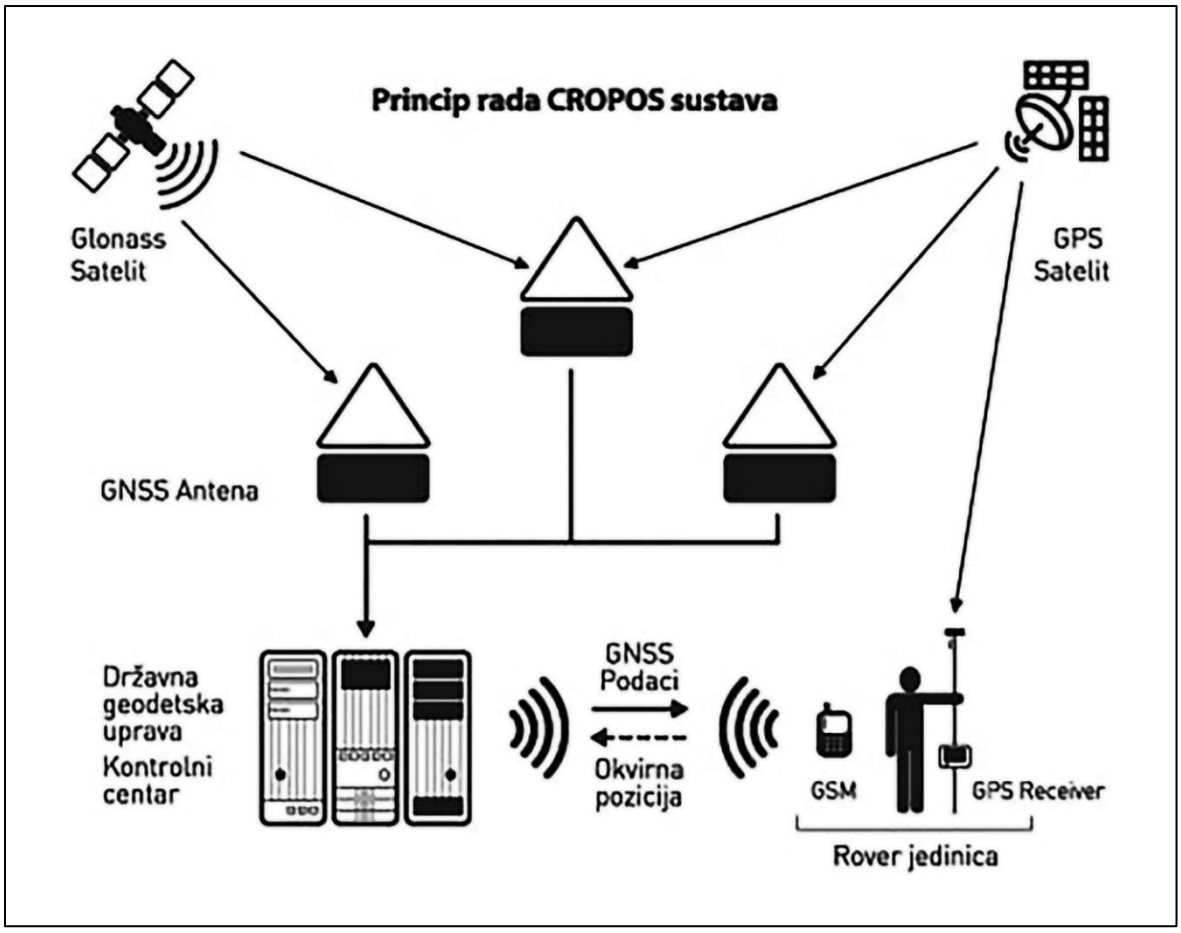

Sl. 11. Princip rada CROPOS sustava

Izvor: https://www.cropos.hr/o-sustavu/koncept-umrezenih-referentnih-stanica

CROPOS sustav pruža korisnicima tri usluge koje se međusobno razlikuju po metodi rješenja, točnosti, načinu prijenosa podataka i formatu podataka: DPS - diferencijalni pozicijski servis u realnom vremenu – namijenjen za primjenu u geoinformacijskim sustavima, upravljanju prometom, preciznoj navigaciji, zaštiti okoliša, poljoprivredi, šumarstvu i slično; VPPS - visokoprecizni pozicijski servis u realnom vremenu – namijenjen za primjenu u državnoj izmjeri, katastru, inženjerskoj geodeziji, izmjeri državne granice, hidrografiji i slično, te GPPS - geodetski precizni pozicijski servis - namijenjen za primjenu u osnovnim geodetskim radovima, znanstvenim i geodinamičkim istraživanjima i slično (Marjanović, 2010). Za potrebe ovog istraživanja korišten je VPPS servis.

Treći korak rada s kontrolnim točkama podrazumijeva konkretno bilježenje geografske lokacije svake pojedine točke. On je izveden pomoću Esri softverskog paketa za GIS. Konkretnije, za samo prikupljanje upotrjebljena je Esri mobilna aplikacija ArcGIS Field Maps koja se koristi za terensko prikupljanje podataka i njihovu kasniju obradu.

Aplikacija se pomoću Bluetooth veze povezuje sa GNSS stanicom koja joj na temelju odabrane pretplate šalje podatke o preciznoj lokaciji na uređaj koji se koristi. Također, unutar same aplikacije unose se korisnički podaci potrebni za povezivanje na CROPOS sustav. Nakon završetka navedenih procedura slijedi terensko prikupljanje podataka – odlazak na lokaciju kontrolne točke, ispravno postavljanje GNSS uređaja i odabir funkcije koja bilježi informacije o lokaciji unutar ArcGIS Field Maps aplikacije (sl. 12). Podaci o lokaciji prikupljeni su u WGS84 koordinatnom sustavu u decimalnim stupnjevima (engl. *decimal degrees*, *DD*), u vremenu od 2 minute (10 epoha mjerenja) za svaku kontrolnu točku. Postupak bilježenja ponovljen je za svih 10 lokacija kontrolnih točaka.

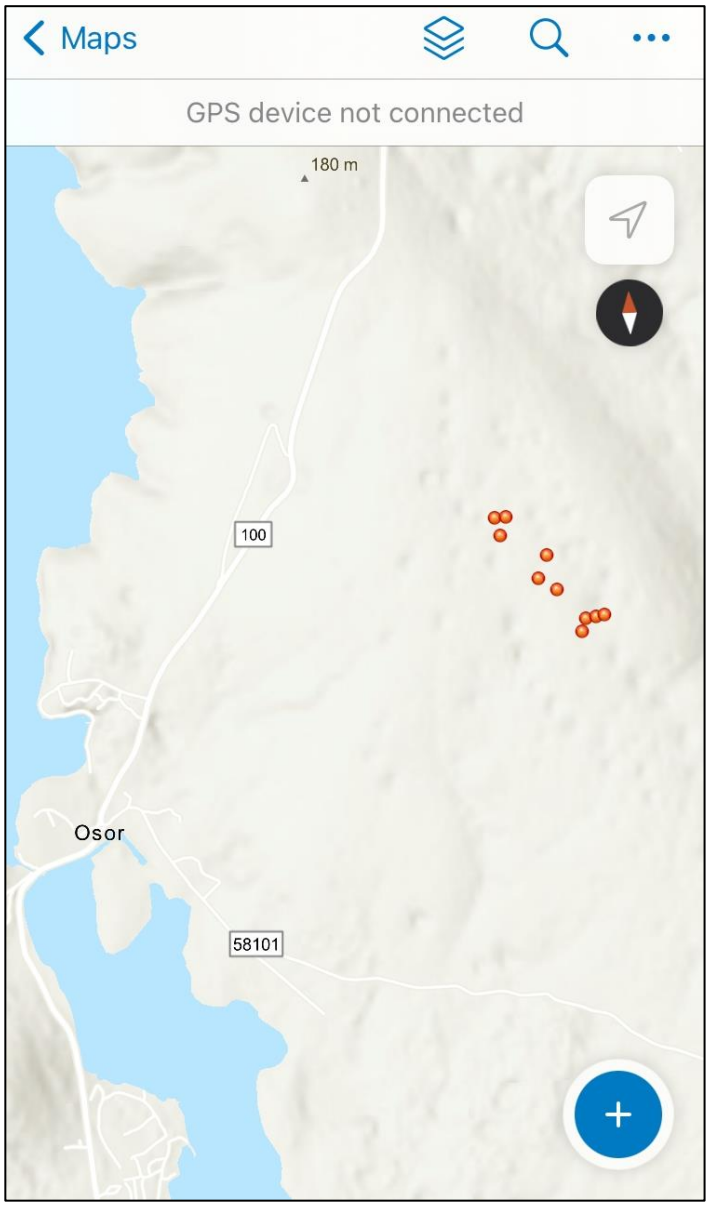

Sl.12. Korisničko sučelje mobilne aplikacije ArcGIS Field Maps (krugovi predstavljaju kontrolne točke)

3.1.3. Snimanje bespilotnom letjelicom

Za izradu ovog diplomskog rada korištena je bespilotna letjelica DJI Phantom 4 Pro, projekta HRZZ-IP-2019-04-9445 Relativna promjena morske razine i klimatske promjene duž istočne obale Jadrana - SEALeveL (sl. 13). Bespilotna letjelica opremljena je kamerom visoke razlučivosti (senzor veličine 1 inča) koja može fotografirati objekte u maksimalnih 20 megapiksela razlučivosti. Sustav *OcuSync 2.0* omogućava prijenos slike visoke razlučivosti (engl. *high definition, HD*) na upravljački uređaj na maksimalnoj udaljenosti od 7 kilometara. U normalnim vremenskim uvjetima osigurana joj je autonomija leta od 30 minuta sa jednim punjenjem baterije. Sigurnosni sustav opremljen je sa senzorima prepreka u pet smjerova kako bi se jednostavno izbjegla neželjena kolizija sa drugim objektima u prostoru (DJI, 2021). Bespilotnom letjelicom upravlja se pomoću DJI GO 4 mobilne aplikacije. Detaljnije tehničke specifikacije korištene bespilotne letjelice i kamere nalaze se u tablici 5.

Sl. 13. Bespilotna letjelica DJI Phantom 4 Pro

Izvor: https://dgdrone.com

Tab. 5. Tehničke specifikacije bespilotne letjelice DJI Phantom 4 Pro

Model	**Phantom 4 Pro V2.0**
Proizvod	Dron
EAN	6,95827E+12
Dizajn	
Tip	Kvadkopter
Boja proizvoda	Bijela
Značajke	
Broj rotora	4 rotora
Maksimalna brzina	72 m/s
Maksimalan radni domet	7000 m
Frekvencijski opseg	2.400 - 2.483/5.725 - 5.850 GHz
Horizontalna točnost lebdjenja	0.3 m
Vertikalna točnost lebdjenja	0.1 m
Maksimalna brzina uspinjanja	6 m/s
Maksimalna brzina spuštanja	4 m/s
Maksimalni kut nagiba	42 °
Maksimalni otpor na vjetar	10 m/s
Maksimalno vrijeme leta	30 min
GPS	Da
GLONASS	Da
Integrirani senzori	Infracrveni (IR) senzor
Težina i dimenzije	
Težina (uključujući bateriju)	1375 g
Težina baterije	468 g
Radni uvjeti	
Raspon radne temperature (T-T)	0 - 40 °C
Kamera	
Tip senzora	CMOS
Megapiksela	20 MP
Kut vidnog polja (FOV)	84 °
Brzina okidanja	8 - 1/8000 s
Veličina optičkog senzora	1 "
Maksimalni broj sličica u sekundi	120 fps
Maksimalna razlučivost videozapisa	4096 x 2160 pikseli
Video razlučivosti	1280 x 720,1920 x 1080,2720 x 1530,3840 x 2160,4096 x 2160 piksela
Propusnost pri maksimalnoj video razlučivosti	100 Mbit/s
Podržani formati slika	DNG, JPEG, RAW

Podržani video formati	AVC, H.264, H.265, HEVC, MOV, MP4
Memorija	
Utor(i) za memorijsku karticu	Da
Kompatibilne memorijske kartice	MicroSD (TransFlash)
Maksimalna veličina memorijske kartice	128 GB
Napajanje	
Snaga AC adaptera	100 W
Ulazni napon AC adaptera	17.4 V
Baterija	
Tehnologija baterije	Litij-polimer (LiPo)
Kapacitet baterije	5870 mAh
Napon baterije	15.2 V
Kapacitet baterije	89.2 Wh

Izvor: DJI, 2021.

Snimanje analiziranog područja izvršeno je u ručnom načinu rada bez korištenja drugih aplikacija za planiranje rute leta. Snimanje cijelog područja istraživanja napravljeno je s visine od 100 m od točke polijetanja čime je kasnijom obradom fotografija dobiven digitalni ortofoto snimak prostorne razlučivosti od 2,8 cm. Pošto se bespilotnom letjelicom upravljalo u ručnom načinu rada bez korištenja aplikacija za planiranje rute, brzina leta bila je zanemariv čimbenik iz razloga što se letjelica zaustavila kako bi snimila svaku pojedinačnu fotografiju (sl. 14). Samo snimanje nastojalo se izvesti uz maksimalan mogući preklop fotografija kako bi kasnija softverska obrada rezultirala što kvalitetnijim podacima.

Postavke kamere podešene su prema primjerima dobre prakse koji su analizirani prije samog prikupljanja podataka. O'Conor i dr. (2017) navode kako bi ISO osjetljivost trebala biti postavljena na minimalnu vrijednost radi što veće kvalitete fotografije. Ipak, prihvatljive vrijednosti kreću se u rasponu od 100 do 800. Sve više od navedenoga pridonosi stvaranju „šuma“ na fotografijama, odnosno nepoželjne zrnate strukture koja može otežati daljnju softversku obradu. Kod prikupljanja podataka potrebnih za ovo istraživanje vrijednost ISO osjetljivosti bila je postavljena na 100. Nadalje, radi konstantnog podrhtavanja bespilotne letjelice za vrijeme leta izrazito važna postavka je brzina zatvarača (engl. *shutter speed*). Ukoliko je brzina zatvarača prilikom fotografiranja preniska moguća je prisutnost zamućenja uslijed pokreta koje onemogućava daljnju analizu. Suprotno navedenome, ukoliko je brzina zatvarača previsoka senzor kamere neće dovoljno dugo biti izložen reflektiranoj svjetlosti stoga fotografije neće imati zadovoljavajuću ekspoziciju.

Optimalne vrijednosti brzine okidača nalaze se između 1/250 i 1/1000 (O'Conor i dr., 2017). U ovom primjeru vrijednost brzine zatvarača bila je postavljena na 1/400. Treći nezaobilazan parametar podešavanja kamere jest otvor blende (engl. *aperture*) koji regulira dubinu vidnog polja (engl. *depth of field*). Preciznije, što je otvor blende veći, to su objekti koji se nalaze u pozadini (u odnosu na subjekt fotografije) zamućeniji. Kod izrade digitalnog ortofoto snimka poželjno je da svi subjekti budu podjednako izoštreni, odnosno, da ne dolazi do zamućenja fotografija zbog relativne razlike u visini snimanih objekata. Zbog toga se u literaturi preporuča optimalan otvor blende kamere u vrijednostima od f/5.6 do f/11 (O'Conor i dr., 2017). S obzirom na visinu leta bespilotnom letjelicom, odnosno udaljenosti od snimanog subjekta, otvor blende postavljen je na f5.6. Konačno, opcija fokusiranja prilikom snimanja postavljena je na ručno (engl. *manual*) kako za vrijeme snimanja svake nove fotografije ne bi došlo do eventualnog nastanka neizoštrenih snimaka. Sve navedene postavke kamere rezultirale su izoštrenim snimcima koji su bili kvalitetan temelj za njihovu softversku obradu.

Sl. 14. Izvođenje letačke operacije

3.2. SOFTVERSKA OBRADA PRIKUPLJENIH PODATAKA

Nakon terenskog prikupljanja podataka uz pomoć GNSS prijamnika, bespilotne letjelice i mobilne aplikacije provedena je softverska obrada prikupljenih podataka koja je temelj daljnje analize. Softverska analiza provedena je unutar Laboratorija za geoprostornu analitiku i vizualizacije Geografskog odsjeka Prirodoslovno-matematičkog fakulteta u Zagrebu prema koracima koji su opisani u nastavku rada.

3.2.1. ArcGIS Online i ArcGIS Field Maps

Kao što je ranije navedeno, podaci o lokaciji kontrolnih točaka prikupljeni su pomoću ArcGIS Field Maps mobilne aplikacije. Ona je dio umrežene Esri platforme koja funkcionira i kao softver u oblaku (ArcGIS Online) s ograničenom funkcionalnošću, ali i kao uobičajeni softver na osobnom računalu – tzv. *desktop* verzija (ArcGIS Pro). Cjelokupnom sustavu pristupa se pomoću jedinstvenih korisničkih podataka dodijeljenih jednoj osobi ili cijeloj organizaciji (Esri, 2022). Navedenim softverima za izradu ovog diplomskog rada pristupalo se pomoću ArcGIS Online organizacije: Geografski odsjek PMF-a; članovi organizacije: Marin Mićunović i Dominik Karčić (sl. 15).

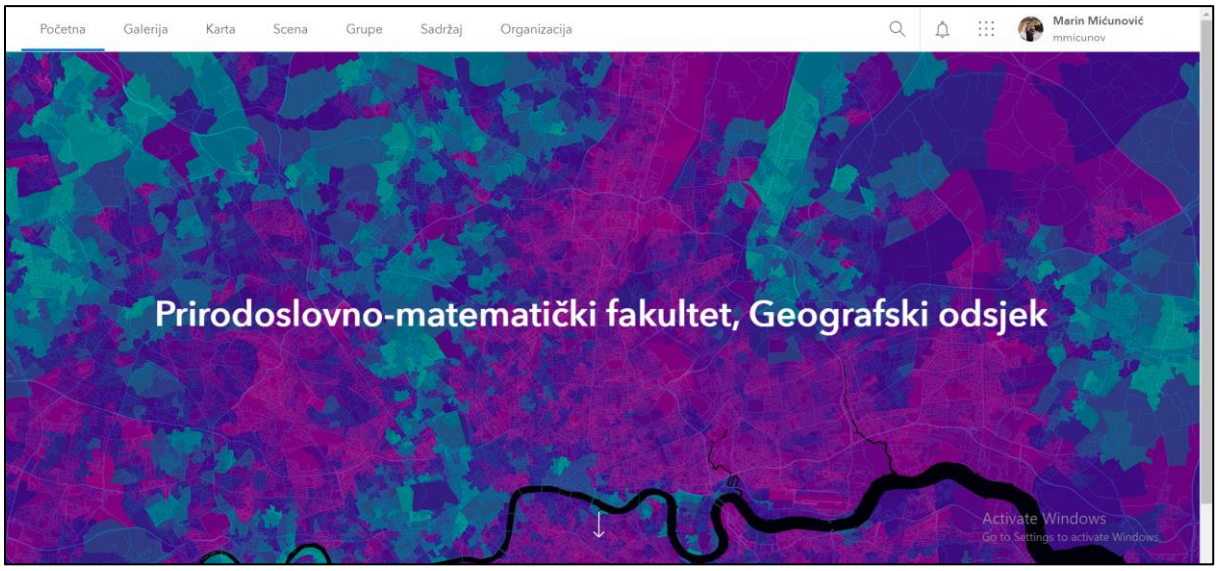

Sl. 15. Prikaz ArcGIS Online korisničkog sučelja

Nakon prikupljanja informacija o lokaciji pomoću ArcGIS Field Maps mobilne aplikacije podacima su analizirani i vizualizirani koristeći ArcGIS Online web aplikaciju. Kontrolne točke pregledane su unutar Map Viewer opcije, a za daljnju obradu pristup je izvršen pomoću ArcGIS Pro desktop 2.3.0 verzije softvera (sl. 16).

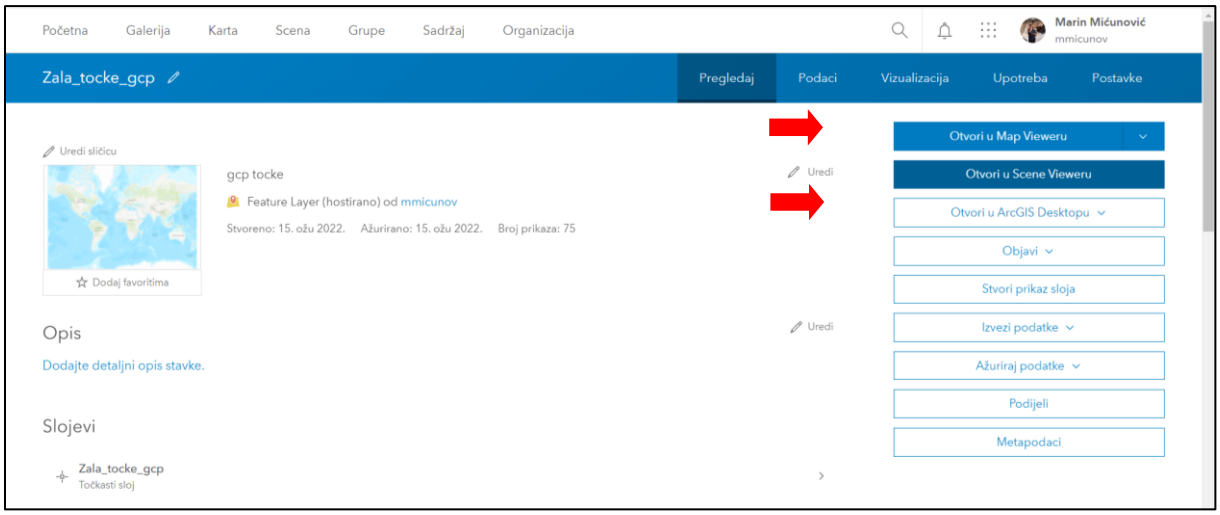

Sl. 16. Pristup prikupljenim podacima pomoću ArcGIS Online

Budući da su kontrolne točke prikupljene pomoću GNSS prijamnika u WGS84 koordinatnom sustavu potrebno ih je pretvoriti u projekcijsku verziju tog sustava, odnosno WGS84 Auxiliary Sphere kako bi se mogle koristiti unutar Esri ArcGIS Pro softvera u daljnjoj obradi (ArcGIS, 2022). Konverzija je učinjena unutar samog softvera pomoću *Calculate Geometry* funkcije iz *Data Managament* paketa alata (sl. 17).

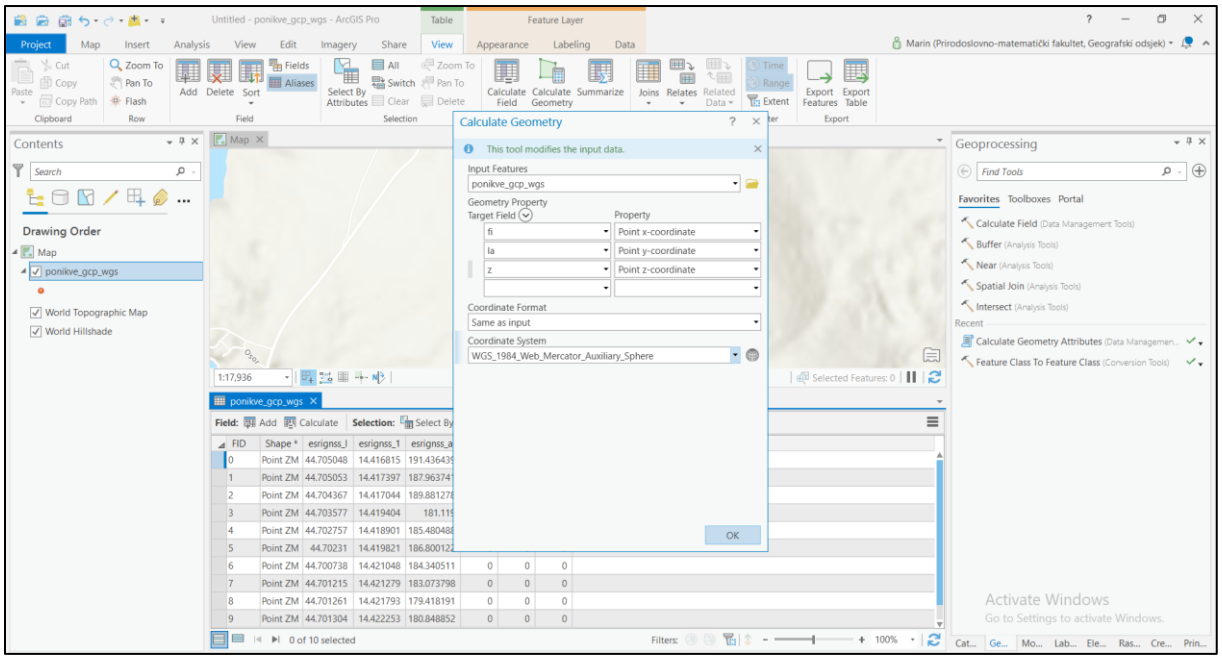

Sl. 17. Preračunavanje vrijednosti koordinata u WGS84 Auxiliary Sphere koordinatni sustav

Ulazni podatak za preračunavanje vrijednosti bio je *shapefile* stvoren pomoću GNSS prijamnika i Arc GIS Field Maps mobilne aplikacije. Preračunate su vrijednosti geografske širine, dužine i nadmorske visine. Po završetku preračunavanja podaci su izvezeni iz atributivne tablice sloja u tekstni dokument u obliku teksta odvojenog tabulatorom te su transformirani pomoću geomatičkog programa T7D.

3.2.2. Geomatički program T7D

Projekcijska verzija WGS84 koordinatnog sustava pogodna je za prikazivanje podataka na globalnoj razini. Ipak, za područje Republike Hrvatske najpogodniji projekcijski koordinatni sustav je Hrvatski Terestrički Referentni Sustav za epohu 1995.55 u poprečnoj Mercatorovoj projekciji – skraćeno HTRS96/TM (DGU, 2022). Za što precizniju transformaciju podataka korišten je T7D geomatički program za transformaciju koordinata u Republici Hrvatskoj (sl. 18). Osnovna namjena programa je jednostavna i pouzdana transformacija svih geodetsko-katastarskih i ostalih prostornih podataka, te lakša implementacija novih službenih geodetskih datuma Republike Hrvatske od strane korisnika (Premužić i Šljivarić, 2010).

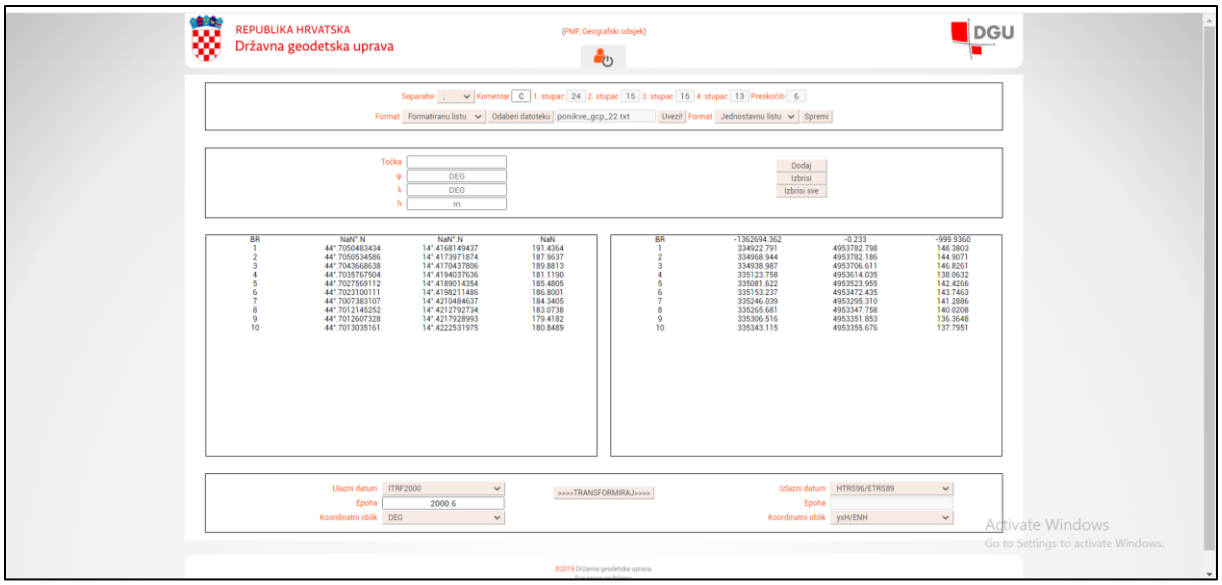

Sl. 18. Konverzija podataka pomoću T7D programa

Ulazni podaci za program T7D ranije su definirani uz pomoć ArcGIS Pro softvera. Ulazni datum podataka bio je ITRF2000, epoha 2000.6, a koordinatni oblik DEG (decimalni stupnjevi). Formatirana tablica morala je sadržavati podatke o nazivu točke, geografskoj širini, dužini i nadmorskoj visini (sl. 18). Konvertirani podaci prikazali su se u istom redosljedu – ENH (engl. *easting, northing, height*). Nakon konverzije podataka oni su izvezeni u istom tekstualnom formatu (sl. 19). Konačno, ovim korakom kontrolne točke su u potpunosti prilagođene HTRS96/TM koordinatnom sustavu i mogu se koristiti kao kvalitetna baza za georeferenciranje digitalnih prostora modela koji su generirani u daljnjoj analizi.

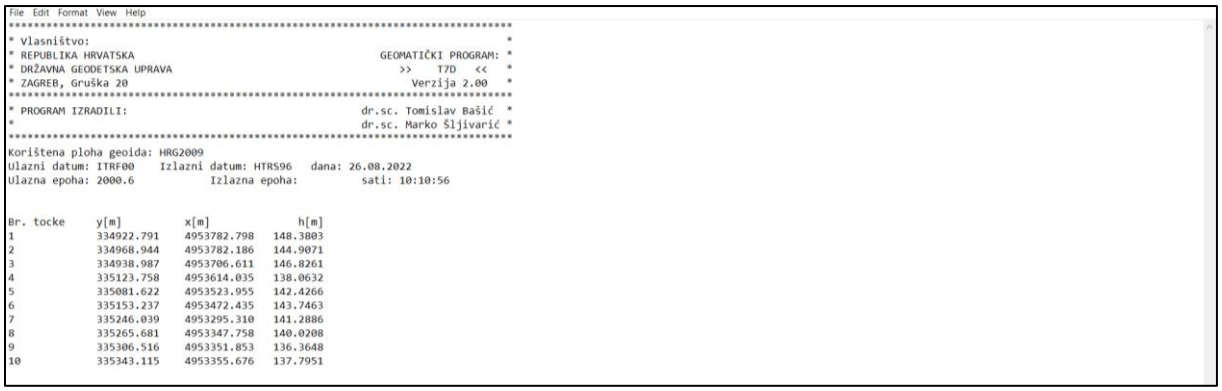

```
File  Edit  Format  View  Help
*****************************************************************************
* Vlasništvo:                                                               *
* REPUBLIKA HRVATSKA                                GEOMATIČKI PROGRAM:     *
* DRŽAVNA GEODETSKA UPRAVA                             >>    T7D   <<       *
* ZAGREB, Gruška 20                                     Verzija 2.00       *
*****************************************************************************
* PROGRAM IZRADILI:                                 dr.sc. Tomislav Bašić   *
*                                                   dr.sc. Marko Šljivarić  *
*****************************************************************************
Korištena ploha geoida: HRG2009
Ulazni datum: ITRF00    Izlazni datum: HTRS96   dana: 26.08.2022
Ulazna epoha: 2000.6            Izlazna epoha:          sati: 10:10:56


Br. tocke     y[m]          x[m]              h[m]
1             334922.791    4953782.798   148.3803
2             334968.944    4953782.186   144.9071
3             334938.987    4953706.611   146.8261
4             335123.758    4953614.035   138.0632
5             335081.622    4953523.955   142.4266
6             335153.237    4953472.435   143.7463
7             335246.039    4953295.310   141.2886
8             335265.681    4953347.758   140.0208
9             335306.516    4953351.853   136.3648
10            335343.115    4953355.676   137.7951
```

Sl. 19. Konvertirana lista kao produkt T7D programa

3.2.3. Agisoft Metashape Professional

Podaci prikupljeni bespilotnom letjelicom obrađeni su pomoću Agisoft Metashape Professional 1.8.4. programa za 3D modeliranje. Takvo modeliranje rezultat je preklapanja fotografija na temelju istih preklopnih točaka. Tehnologija zadužena za identifikaciju i preklapanje naziva se *Structure from Motion* (SfM) i pozadina je većine fotogrametrijskih softvera današnjice. Na temelju preklapanja unutar softvera modeliraju se oblak točaka, poligonalna mreža (DSM), tekstura, digitalni model reljefa (DEM) i konačno digitalni ortofoto snimak (DOF), koji se koriste u daljnjoj morfometrijskoj analizi.

3.2.3.1. Structure from Motion

Structure from motion (SfM) tehnologija temelj je većine softvera za 3D modeliranje. Generalno gledajući, ona primjenjuje isti način kao i klasična metoda stereoskopskog para – trodimenzionalna interpretacija dviju snimaka dobivenih s različitih mjesta snimanja (Hrvatska enciklopedija, 2021). Ipak, bitna razlika i prednost u odnosu na klasičnu metodu preklapanje stereoparova podrazumijeva automatsko pronalaženje i preklapanje podudarnih točaka bez potrebe za ranijim određivanjem pozicije snimanja istraživanog objekta (sl. 20). To uvelike olakšava i ubrzava proces prikupljanja i obrade takve vrste podataka (Fonstad i dr., 2013).

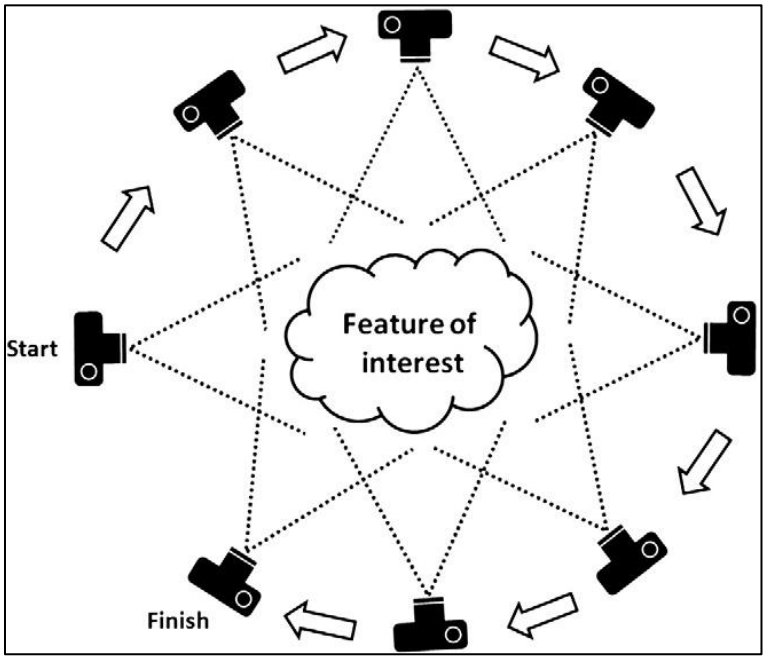

Sl. 20. Princip rada SfM tehnologije

Izvor: Westoby i dr., 2012.

Budući da pozicije snimanja objekta nisu unaprijed definirane, točke preklapanja pozicioniraju se unutar vlastitog (relativnog) koordinatnog sustava. Relativni koordinatni sustav zadovoljava potrebe morfometrijskih mjerenja unutar samog modela, ali, za potrebe geomorfološke analize model je potrebno smjestiti u realan prostor (apsolutni koordinatni sustav) kako bi se mogle provesti željene analize. To se izvodi pomoću podataka o lokaciji kontrolnih točaka (engl. *ground control points*, *GCP*) koje se naknadno dodaju unutar fotogrametrijskog softvera.

Osnovni problem koji fotogrametrijski softveri poput Agisoft Matashape Professional-a adresiraju jest određivanje trodimenzionalnih lokacija podudarnih točaka na preklopljenim fotografijama snimljenih iz različitih pozicija. Najpopularnije rješenje danas jest sustav za prepoznavanje objekata - *Scale Invariant Feature Transform* (SIFT) (Westoby i dr., 2012). SIFT sustav identificira značajke fotografija (piksele) koji su nepromjenjivi u odnosu na susjedne fotografije uzimajući u obzir promijene skaliranja, rotacije i osvjetljenja. Jednostavnije, SIFT algoritmi nastoje identificirati ista područja na fotografijama bez obzira na promjenu pozicije snimanja. Kada su takva područja identificirana algoritam stvara jedinstvene značajke (engl. *keypoints*) koje se pohranjuju u registar značajki te se one potom koriste za identifikaciju velikih skupova podataka (ulaznih fotografija) (Westoby i dr., 2012). Nakon identifikacije jedinstvenih značajki SIFT algoritam pomoću CMVS (engl. *Clustering View for Multi-view Stereo*) protokola stvara oblak točaka malene gustoće. Na temelju njega PMVS2 (engl. *Patch-based Multi-view Stereo*) protokol koristi inicijalne ulazne fotografije kako bi stvorio oblak točaka mnogo veće gustoće (Westoby i dr., 2012). Pojednostavljeno, CMVS protokol stvara oblak točaka na temelju registra izdvojenih značajki, dok PMVS2 protokol potom kao ulazni podatak koristi inicijalne fotografije snimljene prilikom prikupljanja podataka. Konačni produkt jest oblak točaka velike gustoće na temelju kojega se kasnijom obradom generiraju digitalni model površina, reljefa i digitalni ortofoto.

3.2.3.2. Provjera kvalitete fotografija

Prvi korak podrazumijeva provjeru kvalitete snimljenih fotografija. Kako bi generirani modeli bili što kvalitetniji tijekom njihove izrada potrebno je isključiti fotografije koje nemaju zadovoljavajuću oštrinu. Agisoft nudi automatsku provjeru kvalitete fotografija, kao i izdvajanje fotografija niže kvalitete.

U fotogrametrijskoj obradi preporuča se izuzimanje svih fotografija čije su vrijednosti kvalitete manje od 0,5 jedino ako se preklopom ostalih fotografija obuhvatilo istraživano područje (Glavačević, 2021). Sve fotografije niže kvalitete su izostavljene.

3.2.3.3. Spajanje fotografija

Nakon uvoza i provjere kvalitete fotografija slijedi njihovo poravnanje odnosno spajanje (engl. *align photos*). U ovom dijelu obrade dolazi do aktivacije SHIFT sustava koji na fotografijama pronalazi zajedničke vezne točke (engl. *tie points*) te ih pohranjeuje u registar koji će se koristiti za stvaranje oblaka točaka malene gustoće (sl. 21). Opcija *key point limit* omogućava definiranje gornje granice broja veznih točaka koje se koriste prilikom poravnanja. Opcija *tie point* označava gornju granicu zajedničkih veznih točaka. Za *key point limit* vrijednost je postavljena na 0 što rezultira najvećim brojem točaka, a za *tie point* također 0 čime je taj filter zanemaren (Agisoft, 2023).

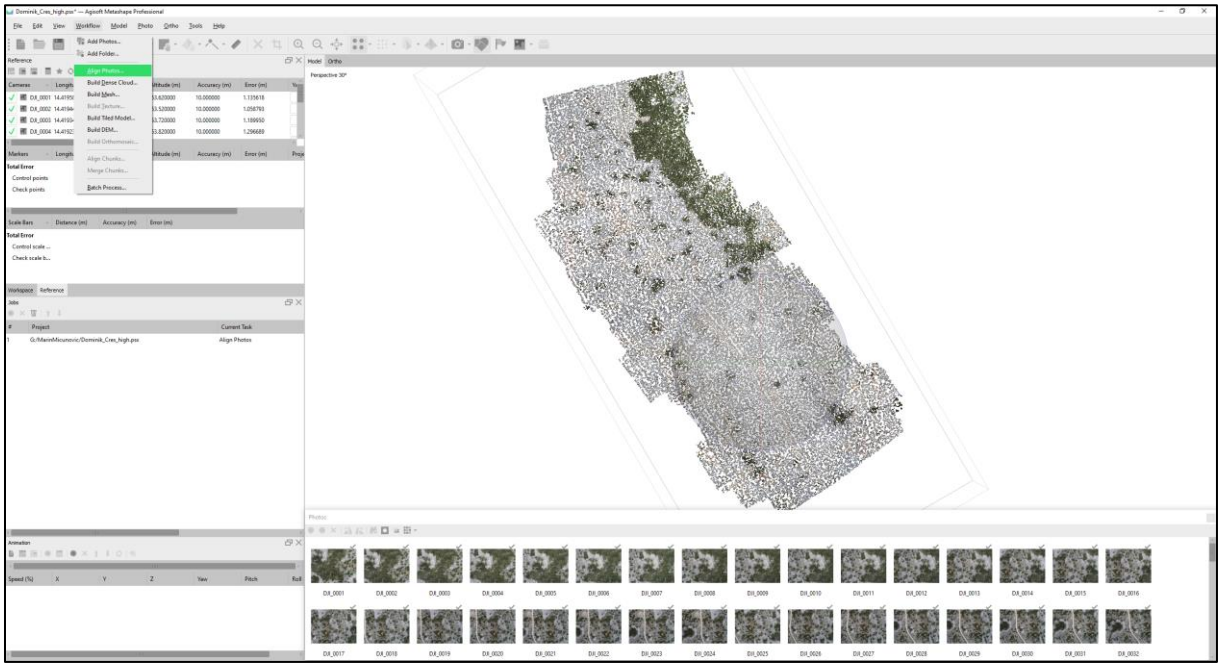

Sl. 21. Spajanje fotografija u Agisoft Metashape Professional softveru

3.2.3.4. Dodavanje kontrolnih točaka

Nakon stvaranja rijetkog oblaka točaka unutar relativnog koordinatnog sustava model je potrebno smijesiti u realan prostor (apsolutni koordinatni sustav) kako bi se mogla provesti morfometrijska mjerenja.

To je izvedeno pomoću ranije prikupljenih i obrađenih kontrolnih točaka i opcije programa *Filter Photo by Marker*. Točke su dodane u Agisoft Metashape program u obliku formatirane liste te su automatski iscrtane u okviru namijenjenom za pregledavanje podataka. Ipak, radi postizanja što veće preciznosti potrebno je ručno smijesiti svaku točku u centar plastificiranog papira vidljivog na fotografiji (sl. 22).

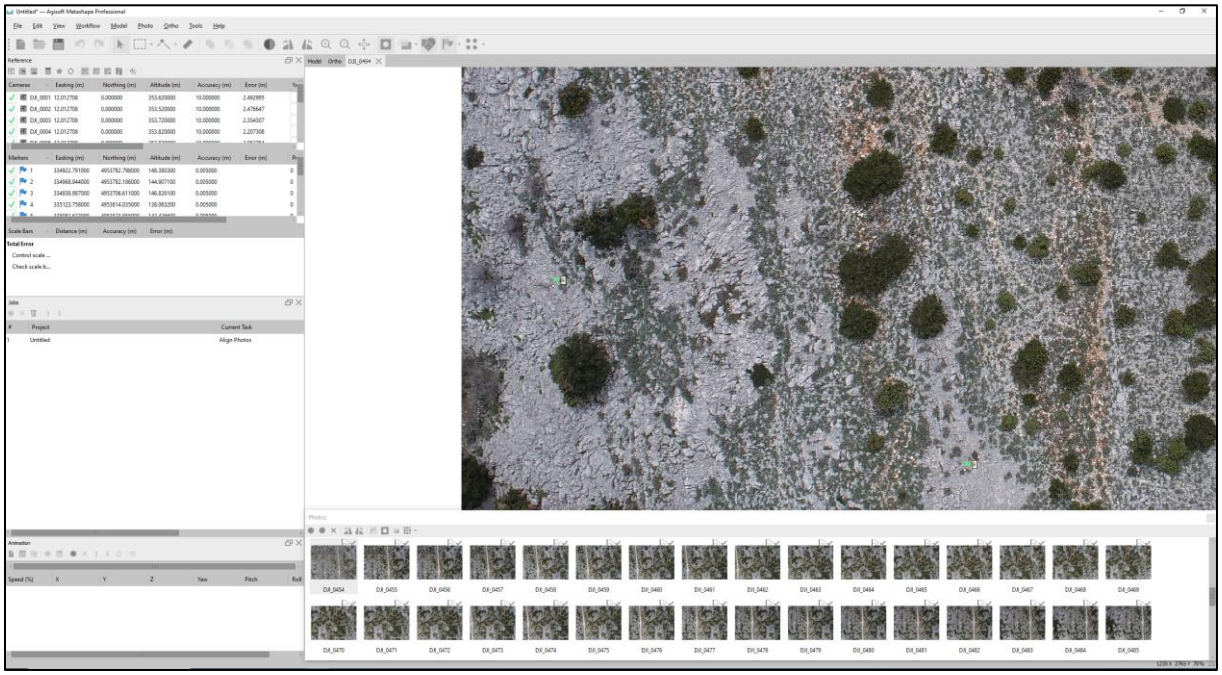

Sl. 22. Dodavanje kontrolnih točaka u Agisoft Metashape Professional softveru

Nakon dodavanja kontrolnih točaka izvršeno je ažuriranje položaja rijetkog oblaka točaka. Pojedine fotografije (točke) imale su relativno veliko odstupanje od ostalih (podatak vidljiv u prozoru *Reference*), stoga su obrisane kako bi preciznost georeferenciranja modela bila što veća. Radi se o manjem broju fotografija pretežito na rubnim dijelova modela koje su zanemarive u odnosu na provedene analize.

3.2.3.5. Izgradnja gustog oblaka točaka, poligonalne mreže i teksture

Sljedeći korak izgradnje modela je generiranje gustog oblaka točaka. Opisuje ga vrlo visoka gustoća točaka kao i mogućnost klasificiranja i uređivanja, a primarno služi kao temelj za daljnju izgradnju modela. Prilikom iniciranja izgradnje gustog oblaka točaka moguće je odabrati željeni parametar izlazne kvalitete. Odabirom najveće kvalitete postiže se vrlo precizna geometrija, ali i dugačko vrijeme obrade fotografija.

Opcija ultra visoke kvalitete (engl. *ultra high quality*) podrazumijeva obradu izvornih fotografija snimljenih bespilotnom letjelicom (Glavačević, 2021). Za potrebe ovog rada odabrane su opcije najveće kvalitete i *aggressive depth filter* (sl. 23).

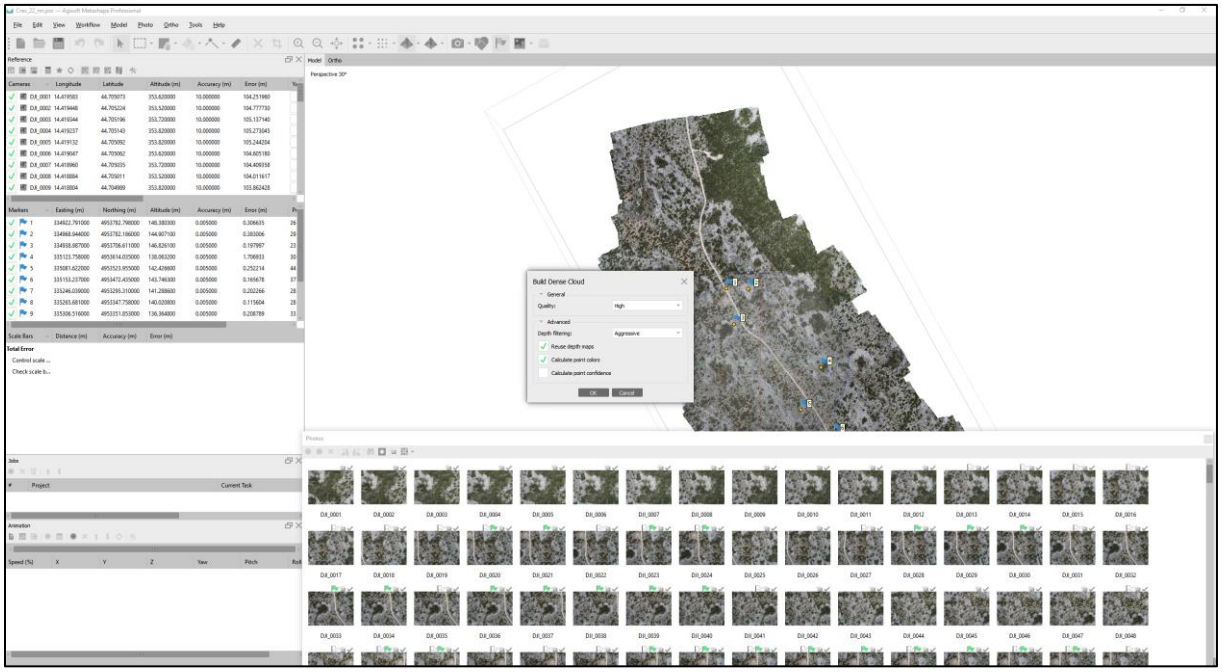

Sl. 23. Izgradnja gustog oblaka točaka u Agisoft Metashape Professional softveru

Nakon definiranja gustog oblaka točaka slijedi stvaranje digitalnog modela površine (DSM), odnosno poligonalne mreže (engl. *mesh*). U ovom koraku vektorima se povezuju sve točke unutar gustog oblaka točaka kako bi se stvorila neprekinuta trodimenzionalna površina. U područjima gdje je gustoća točaka manja one se interpoliraju kako bi prikaz bio što vjerniji. Opcija *Calculate Vertex Colors* omogućava „bojanje“ verteksa prema boji piksela fotografije na kojem se nalazi (Agisoft, 2023). Ta opcije ne treba biti aktivirana ukoliko je sljedeći korak teksturiranje modela (sl. 24).

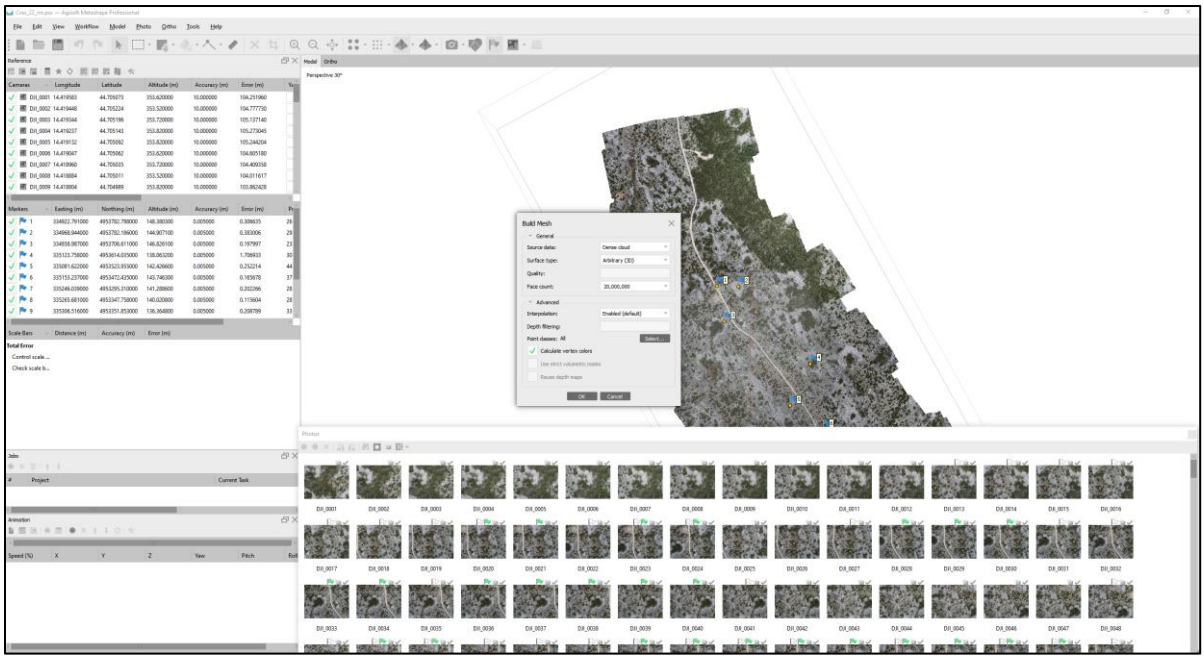

Sl. 24. Izgradnja DEM-a u Agisoft Metashape Professional softveru

Teksturiranje DEM-a (engl. *textures*) za cilj ima „razvući“ inicijalne fotografije preko ranije stvorene poligonalne mreže kako bi tekstura objekta bila što vjernije prikazana. Agisoft Metashape tu naredbu izvodi kombinirajući nekoliko zasebnih algoritama. Dodatnim postavkama *Hole filling* i *Ghosting filling* omogućava se interpoliranje podataka za prostore gdje nastaju praznine (zbog nemogućnosti korelacije najmanje dvije fotografije), odnosno eliminiranje stvaranja duplikata teksture na istom području (Agisoft, 2023) (sl. 25).

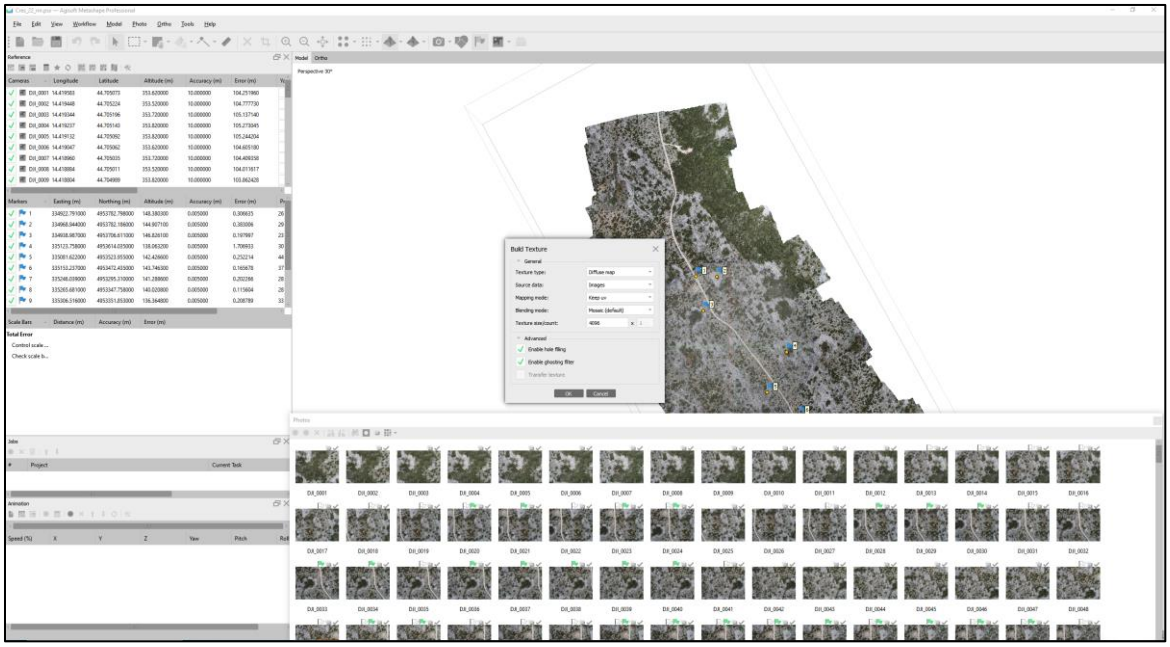

Sl. 25. Teksturiranje točaka u Agisoft Metashape Professional softveru

3.2.3.6. Generiranje DEM-a i DOF-a

Digitalni model reljefa (engl. *digital elevation model*, *DEM*), konačni je produkt Agisoft Metashape softvera na temelju kojega će biti izvršene sve daljnje analize. To je rasterska datoteka unutar koje su pikseli organizirani u stupce i retke, a svaki piksel ima podatak o visini. Odabrani koordinatni sustav bio je HTRS96/TM, a metoda projekcije geografska. Kao izvor podataka odabrana je poligonalna mreža jer se time postiže najpreciznija prezentacija stvarnog prostora (Agisoft, 2023). Kako bi se izbjegle praznine u stvaranju modela omogućena je automatska interpolacija za prostore gdje nedostaju podaci. Prilikom generiranja DEM-a softver nastoji eliminirati podatke koji nisu reprezentacija reljefa, tj. podatke o visini vegetacije (sl. 26).

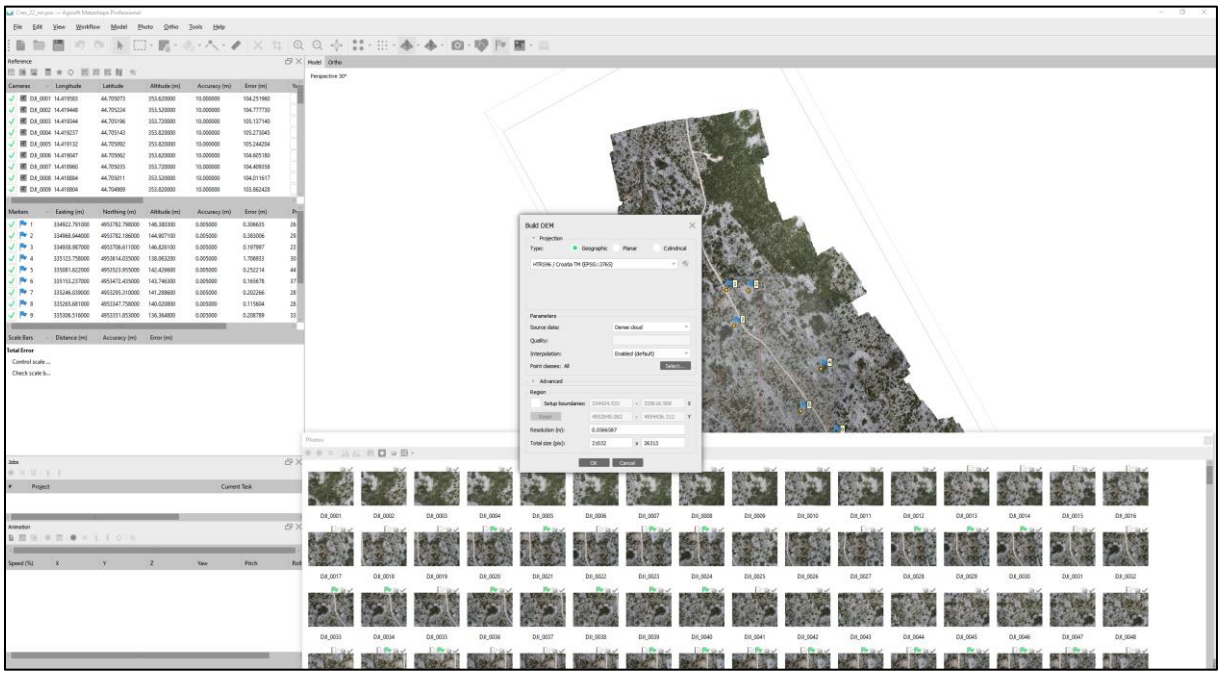

Sl. 26. Izgradnja DEM-a u Agisoft Metashape Professional softveru

Digitalni ortofoto najsličniji je teksturiranoj poligonalnoj mreži. Osnovna razlika je da se fotografije ne prilagođavaju poligonalnoj mreži već se linearno slažu duž preklopnih slojeva. Geografski koordinatni sustav određen je prema onome iz ranije generiranog DEM-a, a veličina piksela određena je ulaznim fotografijama i ranijim koracima obrade (sl. 27).

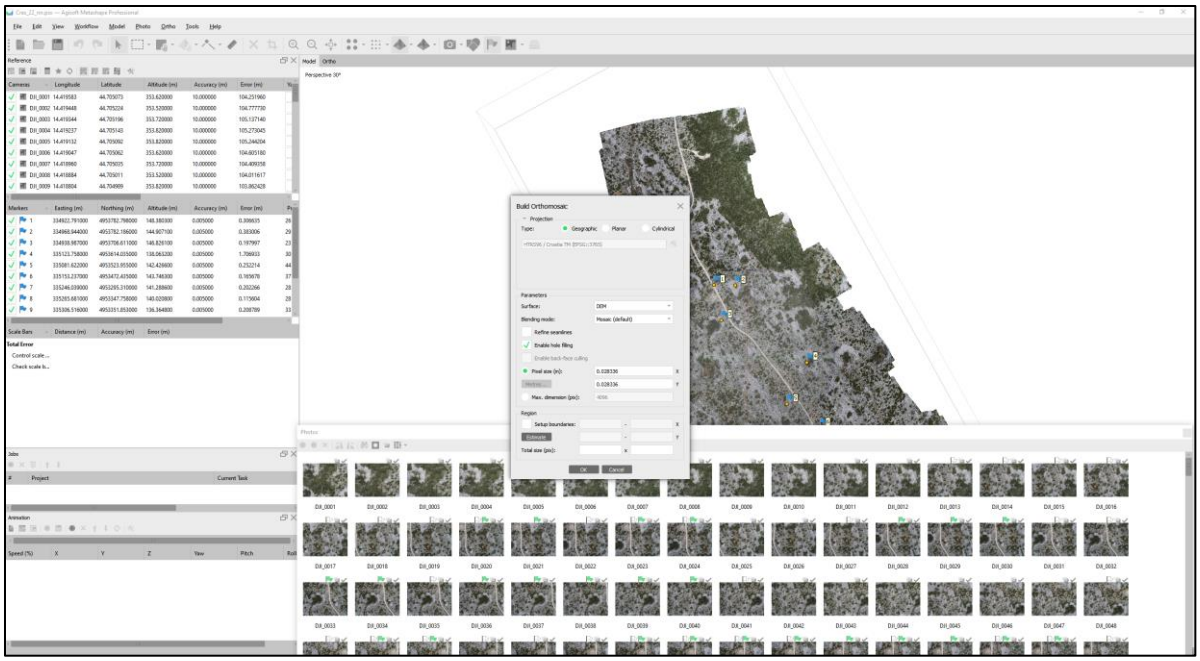

Sl. 27. Izgradnja DOF-a u Agisoft Metashape Professional softveru

3.2.4. Izdvajanje ponikava (ArcGIS Pro)

Ponikve su izdvojene na temelju generiranog DEM-a pomoću dvije metode koje su detaljno opisane u nastavku. Najdetaljniji prikaz ponikava trenutno je Hrvatska osnovna karta (HOK) u mjerilu 1:5000 te topografska karta u mjerilu 1:25000 (TK25). Kako bi se rezultati istraživanja mogli usporediti s već postojećim podacima ponikve sa HOK-a i TK25 su digitalizirane te su im izračunati morfometrijski pokazatelji. Nakon izdvajanja ponikava iz generiranog DEM-a podaci su uspoređeni te su utvrđena različita opažanja.

3.2.4.1. Digitalizacija postojećih podataka

Prije početka digitalizacije pomoću ArcGIS Catalog-a stvorene su dvije nove *shapefile* datoteke, jedna za digitalizaciju sa HOK-a, a druga sa TK25. Datotekama je definiran oblik poligona, a kao koordinatni sustav odabran je HTRS96/TM. Slojevi pomoću kojih se digitaliziralo učitani su pomoću WMS-a (engl. *web map service*) koristeći podatke za anonimni pristup sa Geoportala Državne geodetske uprave.

Kako bi se digitalizirale ponikve isključivo unutar istraživanog područja dodan je sloj ruba područja koji je ranije stvoren pomoću digitalnog ortofoto snimka i funkcije *Raster to Polygon*. Zbog što vjernijeg prikaza ponikava njihovi obodi su zaobljeni pomoću funkcije *Smooth Polygon*.

Kako bi se digitalizirale ponikve mogle koristiti u detaljnoj morfometrijskoj analizi u atributivnoj tablici je svakoj ponikvi dodijeljen identifikacijski broj (ID) te su izračunati podaci o opsegu i površini (sl. 28).

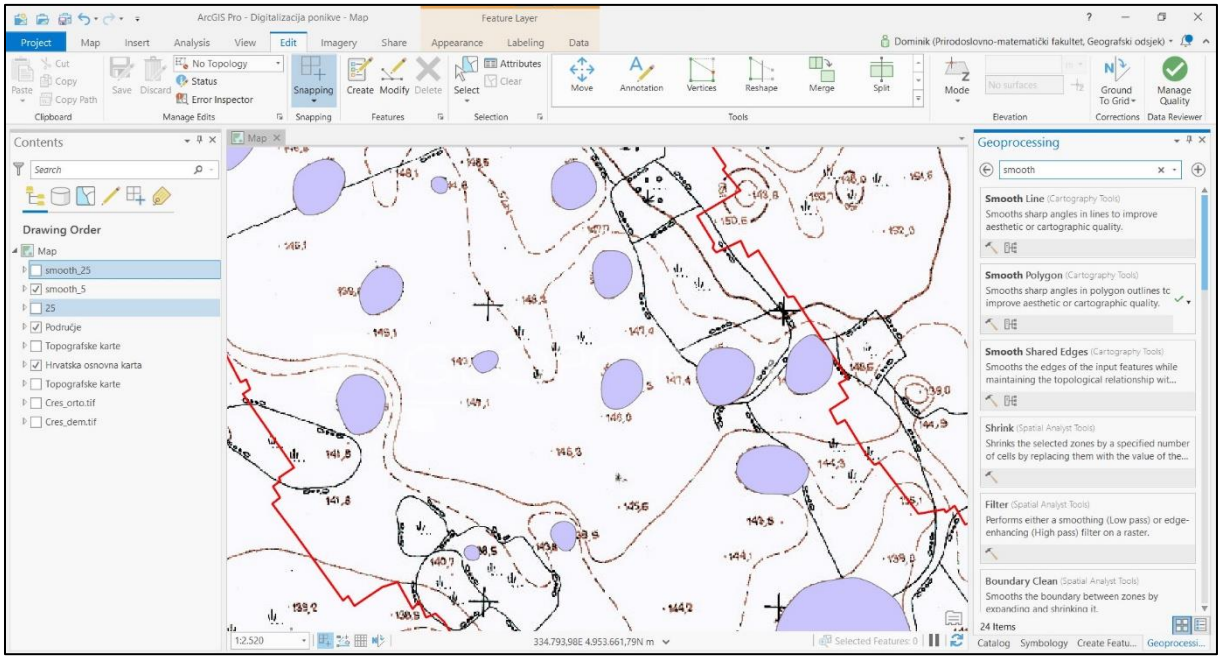

Sl. 28. Digitalizacija ponikava pomoću HOK-a i ArcGIS Pro softvera

3.2.4.2. Modificirana MDTA metoda (mMDTA)

Izdvajanje ponikava iz digitalnog modela reljefa je proces koji se često koristi unutar geomorfoloških istraživanja. Temelj većine metoda jest rezultat oduzimanja dvije rasterske datoteke unutar određenog GIS softvera. Od rasterske datoteke (DEM-a) na kojoj su udubljenja ispunjena pomoću *Fill* funkcije oduzima se prvotna rasterska datoteka (originalni DEM). Time nastaje novi raster koji prikazuje isključivo popunjene depresije, odnosno ponikve. Ipak, takva metoda često pruža nezadovoljavajuće rezultate jer izostavlja ponikve unutar većih depresija, odnosno ponikve koje se nalaze ispod dubine koja je postavljena kao prag na DEM-u (Moreno-Gómez i dr., 2019). Iz tog razloga Moreno-Gómez i dr. (2019) predstavljaju novu poluautomatsku MDTA (engl. *multi depth treshold approach*) metodologiju kojom je moguće izolirati ponikve na nekoliko razina različite nadmorske visine unutar istraživanog područja. Navedeni pristup predstavlja kombinaciju nekoliko različitih funkcija unutar ArcGIS Pro softvera koja rezultira točnošću od 85%, što predstavlja značajni napredak poluautomatskih metoda u odnosu na klasični pristup izdvajanja ponikava (Moreno-Gómez i dr., 2019).

Detaljni modeli s visokom rezolucijom pogodni su za detekciju i analiziranje geomorfoloških oblika malih dimenzija, a s druge strane omogućava prikaz informacija koje nisu poželjne za morfometrijsku analizu. To se prvenstveno odnosi na vegetaciju koja nije stvarna reprezentacija reljefa, već nezaobilazan element prostora koji često geomorfološka istraživanja čini izazovnima. Također, Moreno-Gómez i dr. (2019) u svojem radu istražuju mnogo veće područje manje prostorne razlučivosti, stoga metodologija koju su razvili pruža vrlo zadovoljavajuće rezultate na njihovom primjeru. Za potrebe ovog istraživanja metodologija je prilagođena manjem području istraživanja i većoj prostornoj razlučivosti analiziranih podataka, te je tako nastala *modificirana MDTA metoda (mMDTA)*.

Agisoft Metashape fotogrametrijski softver prilikom generiranja DEM-a vegetaciju nastoji eliminirati, ali rezultati nisu zadovoljavajući za nesmetanu morfometrijsku analizu. Iz tog razloga generirani DEM je „zaglađen“ pomoću funkcija dostupnih u ArcGIS Pro softveru. Prilikom izvođenja „zaglađivanja“ cilj je bio što vjernije prikazati prostor uz zadržavanje visoke prostorne razlučivosti te eliminirati neželjene informacije o visini vegetacije. Taj proces izveden je u dva koraka te predstavlja modifikaciju korištene MDTA metodologije.
Prvi korak „zaglađivanja“ DEM-a izveden je pomoću funkcije *Focal Statistics* iz *Spatial Analyst* paketa funkcija. Funkcija Focal Statistics izračunava vrijednost ćelije ulaznog rastera na temelju definiranog susjedstva oko nje (ArcGIS Pro). Za ulazni raster odabran je DEM, a susjedstvo je definirano oblikom kruga veličine radijusa 70 piksela. Pošto je cilj „zaglađivanja“ rastera eliminacija vegetacije, za statističku vrijednost ćelija izlaznog rastera odabrana je opcija „najmanja vrijednost“ (engl. *minimum*). Odabirom navedenih parametara nastojala se očuvati stvarna nadmorska visina reljefa te neutralizirati visina vegetacije na njemu (sl. 29).

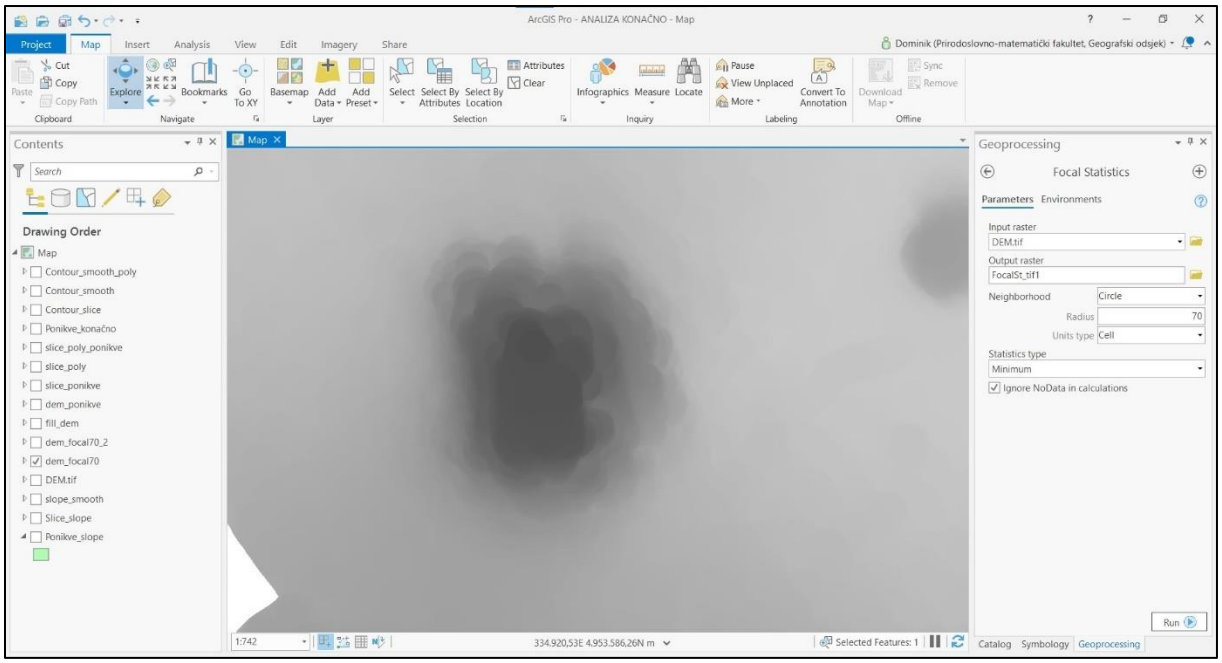

Sl. 29. Prvi korak „zaglađivanja“ DEM-a pomoću ArcGIS Pro softvera

Nakon završetka prvog koraka „zaglađivanja“ stvorena je nova rasterska datoteka koja u sebi ima pohranjene nove visinske vrijednosti temeljene na minimalnim vrijednostima definiranog susjedstva. Zbog definiranja susjedstva oblikom kruga na izlaznom rasteru uočljivi su novi, kružni oblici pojedinih visinskih razreda. Kako bi se izbjegao takav prikaz visina proveden je drugi korak „zaglađivanja“ rastera (DEM-a), također pomoću funkcije *Focal Statistics*.

U drugom koraku kao ulazni raster korišten je ranije „zaglađeni“ DEM, a oblik susjedstva definiran je pravokutnikom (engl. *rectangle*) kako bi se ispravili kružni oblici visinskih razreda. Veličina susjedstva pravokutnika postavljena je na 70 piksela u oba smjera. Za statistički oblik novih vrijednosti ćelija odabrana je opcija „prosjek“ (engl. *mean*), jer je najniža vrijednost piksela susjedstva definirana u prethodnom koraku (sl. 30). Nakon provođenja drugog koraka „zaglađivanja“ rastera stvoren je DEM koji je korišten u daljnjem procesu izdvajanja ponikava.

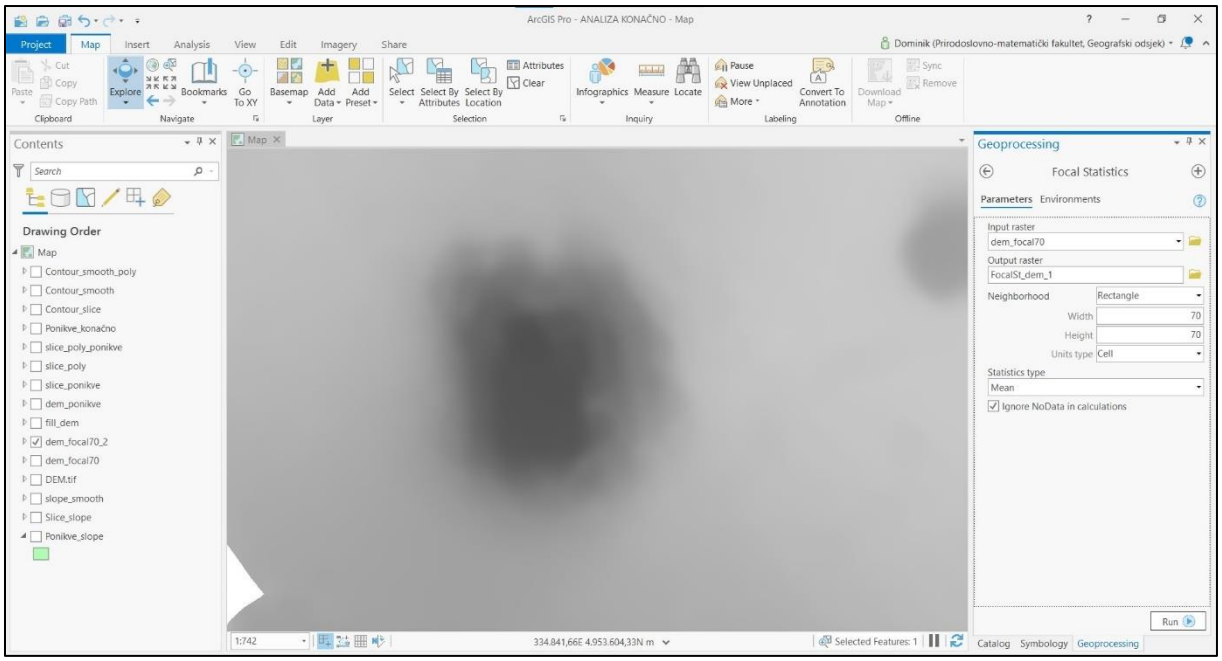

Sl. 30. Drugi korak „zaglađivanja“ DEM-a pomoću ArcGIS Pro softvera

Sljedeći korak temelji se na MDTA metodologiji, odnosno na klasičnom pristupu izdvajanja depresija na digitalnom modelu reljefa (DEM-u). To podrazumijeva popunjavanje svih depresija pomoću funkcije *Fill*. Nakon završetka popunjavanja novonastali rasterski sloj nema depresija, odnosno svaka ćelija rastera pored sebe ima drugu ćeliju manje vrijednosti (sl. 31).

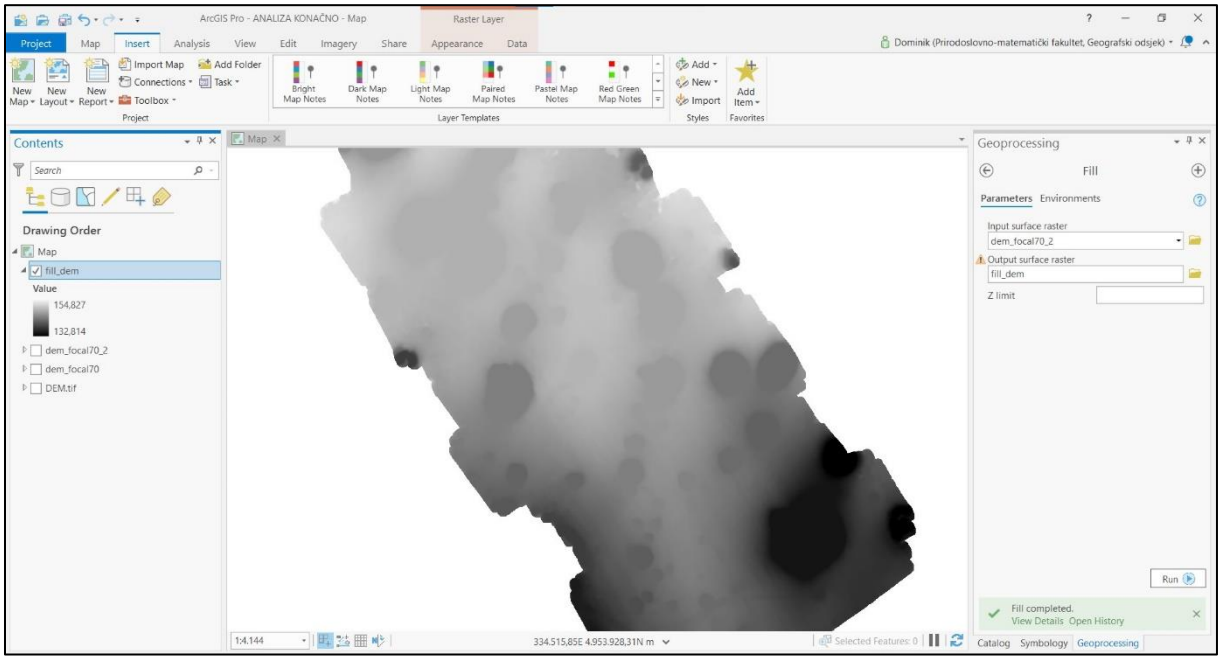

Sl. 31. Popunjavanje depresija pomoću funkcije Fill unutar ArcGIS Pro softvera

Od „ispunjenog“ digitalnog modela reljefa pomoću funkcije *Raster Calculator* oduzet je model reljefa prije ispunjavanja te su time izdvojene sve depresije. Svaka ćelija unutar depresije sadrži podatak o dubini, a okolni prostor ima vrijednost 0 (sl. 32).

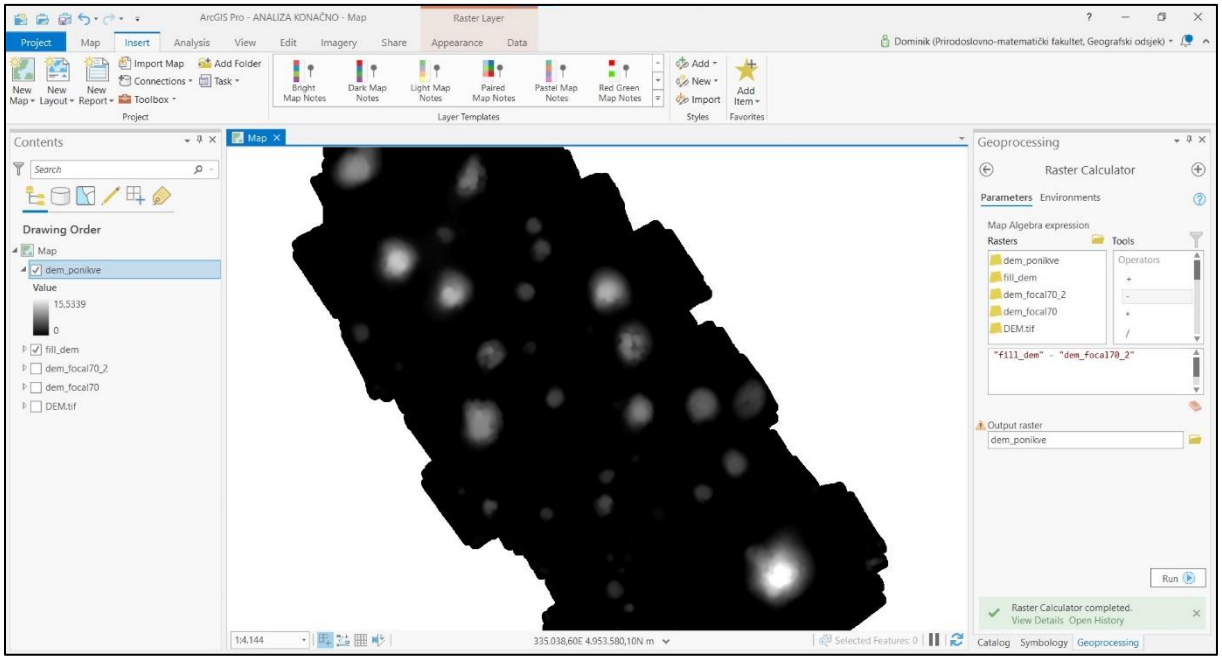

Sl. 32. Raster s depresijama nakon oduzimanja pomoću funkcije Raster Calculator unutar ArcGIS Pro softvera

Sljedeći korak MDTA metodologije predlaže klasifikaciju depresija u različite kategorije pomoću funkcije *Slice*. Kako bi se smanjila varijanca između depresija unutar iste kategorije, a povećala između pojedinih kategorija odabrana je *Jenks* metoda optimizacije (sl. 33). Time su uspješno izdvojene i depresije manje dubine koje nisu vidljive na trenutno dostupnim podacima (Moreno-Gómez i dr., 2019). Zbog relativno malenog područja istraživanja te malene razlike u nadmorskoj visini broj kategorija postavljan je na 20. Time se postiže preciznost izdvajanja i najmanjih udubljena, uz mogućnost eliminacije okolnog prostora. Nastala rasterska datoteka prikazuje udubljenja kategorizirana u 20 razreda.

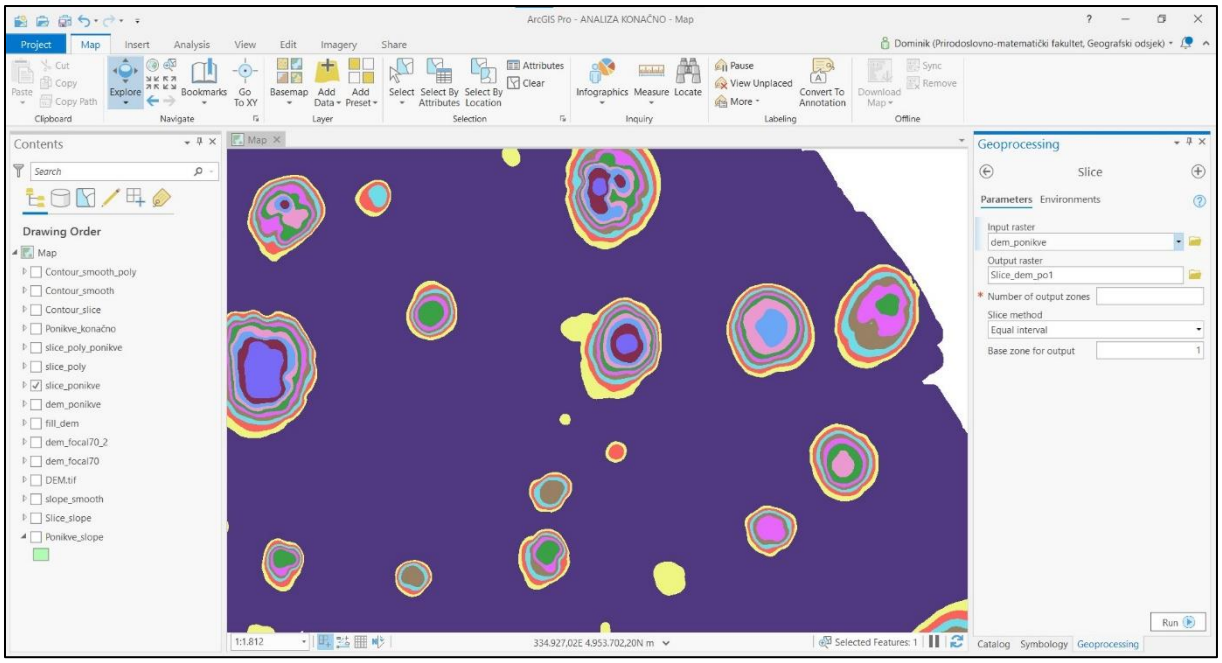

Sl. 33. Klasifikacija depresija pomoću funkcije *Slice* unutar ArcGIS Pro softvera

Klasificirani DEM je pretvoren u poligon pomoću funkcije *Raster to Polygon*. Time je stvorena *shapefile* datoteka unutar koje svaki poligon ima vrijednost kategorije koja mu je ranije dodijeljena pomoću funkcije *Slice*. Prilikom izdvajanja ponikava potrebno je definirati njihov obod, stoga su nakon pretvaranja rastera u poligon pomoću funkcije *Merge* svi poligoni koji imaju vrijednost veću ili jednaku od 3 spojeni u jedan poligon. Poligon s vrijednosti 1 predstavlja okolni prostor, a poligon s vrijednosti 2 uglavnom predstavlja pogreške na DEM-u koje se nisu uspjele „zagladiti“, te su izostavljeni iz daljnje analize. Preostali poligoni zaobljeni su funkcijom *Smooth Polygon* kako bi što vjernije reprezentirali oblik depresija. Time je stvorena *shapefile* datoteka poligona koja predstavlja sve izdvojene ponikve pomoću modificirane MDTA metodologije (sl. 34). Svakoj pojedinačnoj ponikvi dodijeljen je identifikacijski broj (ID), te su izračunati podaci o opsegu i površini.

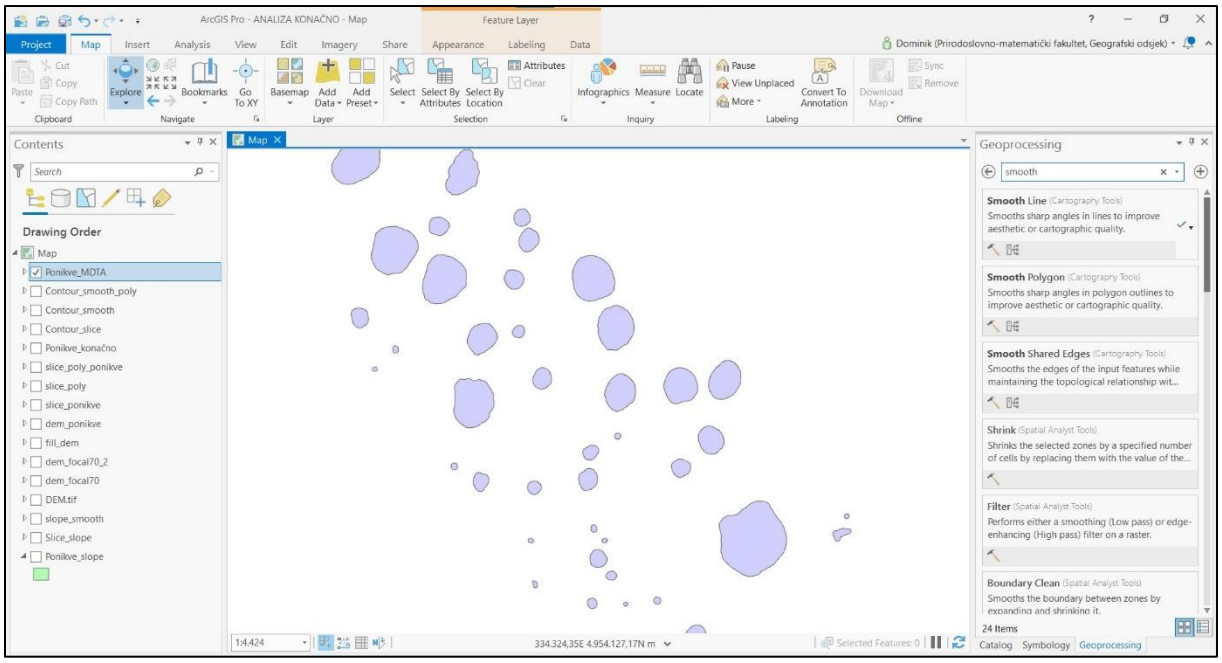

Sl. 34. Ponikve izdvojene nadopunjenom MDTA metodologijom

3.2.4.3. Metoda nagiba padina (MNP)

Druga metoda izdvajanja ponikava na temelju podataka prikupljenih pomoću bespilotne letjelice i ostalih ranije opisanih alata temelji se na intenzitetu nagiba padina generiranog DEM-a. Nagibi padina, odnosno zone različitog nagiba, korištene su kao faktor razlučivanja depresija (ponikava) od ostatka modela reljefa. Zbog prevelike prostorne razlučivosti odnosno radi nepoželjnih informacija o visini vegetacije, DEM generiran pomoću Agisoft Metashape softvera nije bilo moguće upotrijebiti. Zbog toga, kao ulazni podatak korišten je isti DEM kao i za modificiranu MDTA metodu – dvaput „zaglađeni“ DEM.

U prvom koraku generirana je rasterska datoteka s nagibima padina pomoću funkcije *Slope*. Kao ulazni raster korištena je rasterska datoteka nastala „zaglađivanjem“, za mjernu jedinicu intenziteta odabrani su stupnjevi, a metoda izračuna bila je planarna. Novonastali raster zorno prikazuje intenzitet nagiba, odnosno depresije na digitalnom modelu reljefa (sl. 35). Ipak, kako bi digitaliziranje ponikava bilo preciznije, u drugom koraku su nagibi padina raspoređeni u kategorije pomoću funkcije *Slice*.

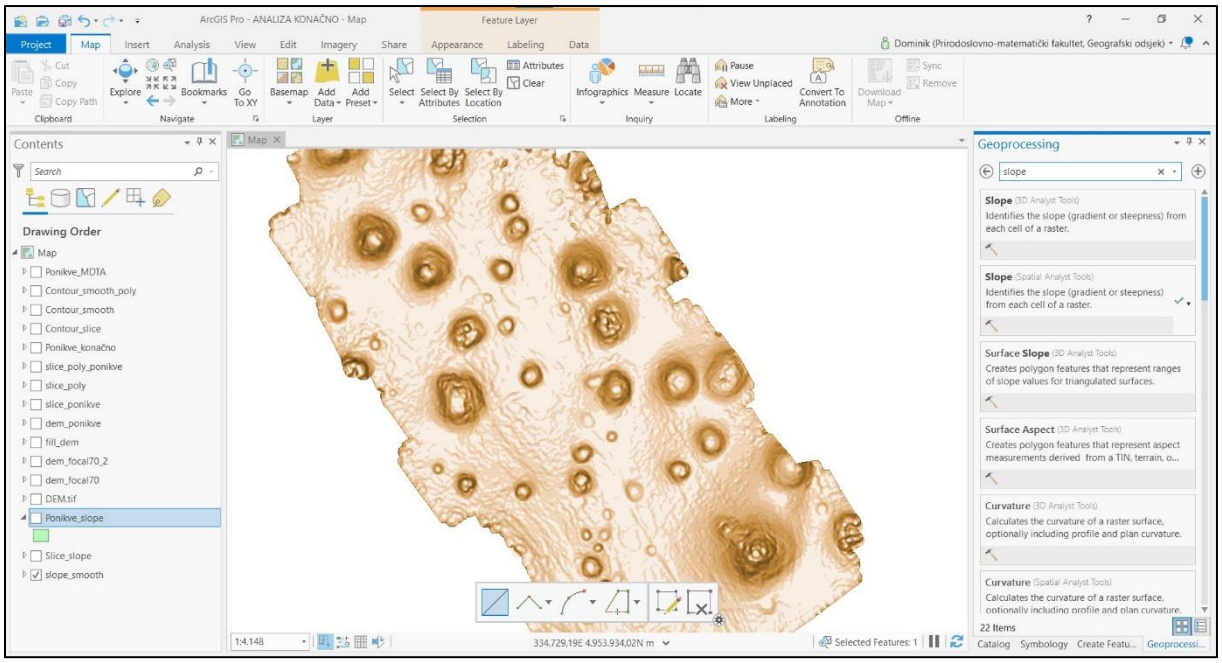

Sl. 35. Nagibi padina generirani unutar ArcGIS Pro softvera

Prilikom izrade klasificiranog rastera pomoću funkcije *Slice* broj razreda postavljen je na 20. Time je osigurana objektivnost prilikom izdvajanja najmanjih nagiba na prostoru sa relativno malenom visinskom razlikom. Odabrana metoda izdvajanja bila je metoda jednakih intervala. Na generiranom rasteru isključene su tri kategorije najmanjeg nagiba (koje su aproksimirale zaravnjeni dio analiziranog područja) te su preostale kategorije jasno iscrtale oblik depresija (sl. 36).

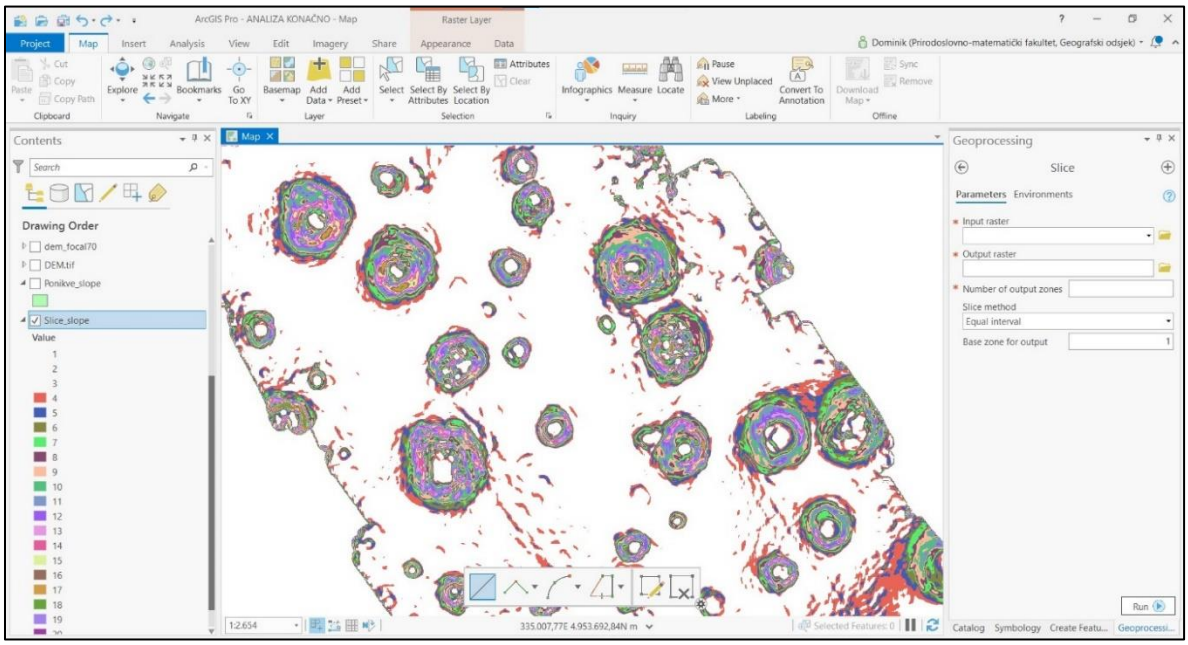

Sl. 36. Klasifikacija nagiba padina pomoću funkcije *Slice* unutar ArcGIS Pro softvera

Oblici depresija digitalizirani su unutar novog *shapefilea* stvorenog pomoću *Catalog* funkcije (sl. 37). Nakon digitalizacije novonastali poligoni zaobljeni su pomoću funkcije *Smooth Polygon*, a svakom poligonu izračunati su opseg i površina.

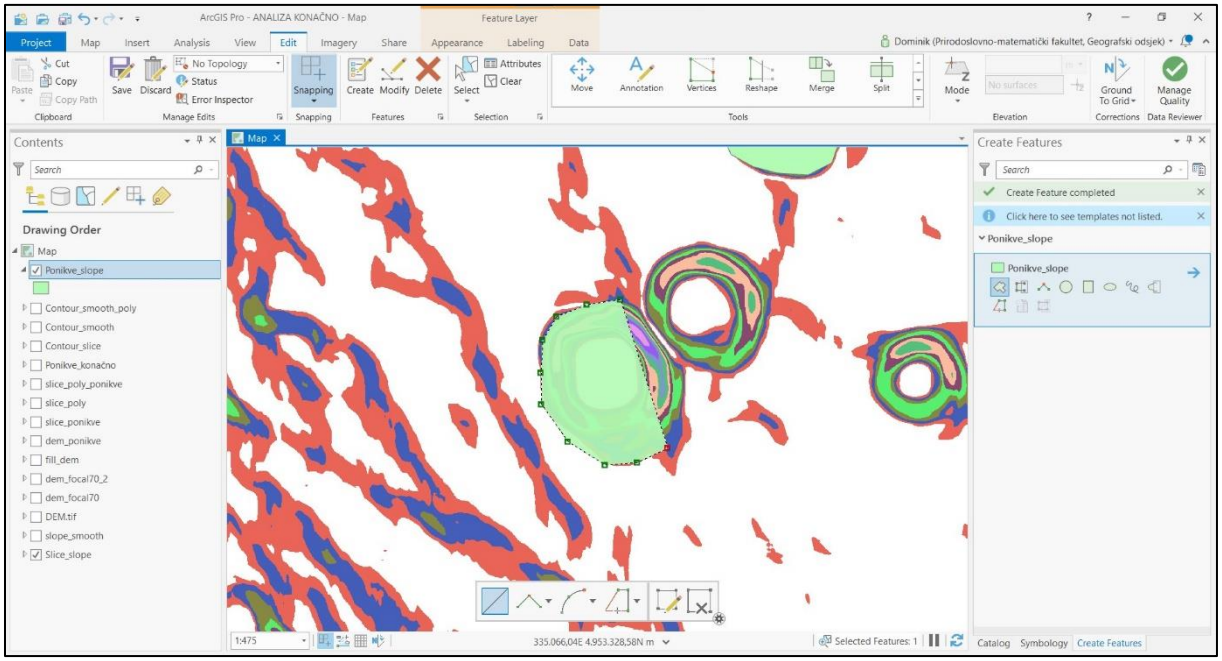

Sl. 37. Izdavanje ponikava pomoću metode nagiba padina unutar ArcGIS Pro softvera

3.2.5. Morfometrijska analiza (ArcGIS Pro)

Za rezultate obadvije metode izdvajanja ponikava iz „zaglađenog“ DEM-a napravljena je detaljna morfometrijska analiza. Ponikvama su određeni tip, dubina, volumen i indeks kružnosti pomoću ArcGIS Pro softvera.

3.2.5.1. Nadmorska visina, nagib padina, vertikalna raščlanjenost reljefa i orijentacija padina

Za potrebe analize nadmorske visine, nagiba padina, vertikalne raščlanjenosti i orijentacije padina korišten je digitalni model reljefa („nezaglađeni“ DEM). Morfometrijska analiza izrađena je pomoću ArcGIS Pro 2.3.0. softvera uz pomoć funkcija iz paketa *Spatal Analyst*. Nadmorska visina prikazana je prilagođavanjem simbologije (engl. *symbology*) osnovne rasterske datoteke. Analizirano područje ima relativno malenu visinsku razliku stoga su visinski razredi prilagođeni u odnosu na one za tradicionalnu upotrebu. Radi što bolje vizualizacije primijenjen je efekt sjenčanja (engl. hillshade), također iz Spatal Analist paketa.

Nagib padina izračunat je pomoću funkcije *Slope*. Za jedinicu mjere izabrani su stupnjevi, a metoda izračuna bila je planarna. Razredi nagiba podijeljeni su u 6 kategorija prema uobičajenoj klasifikaciji (sl. 38).

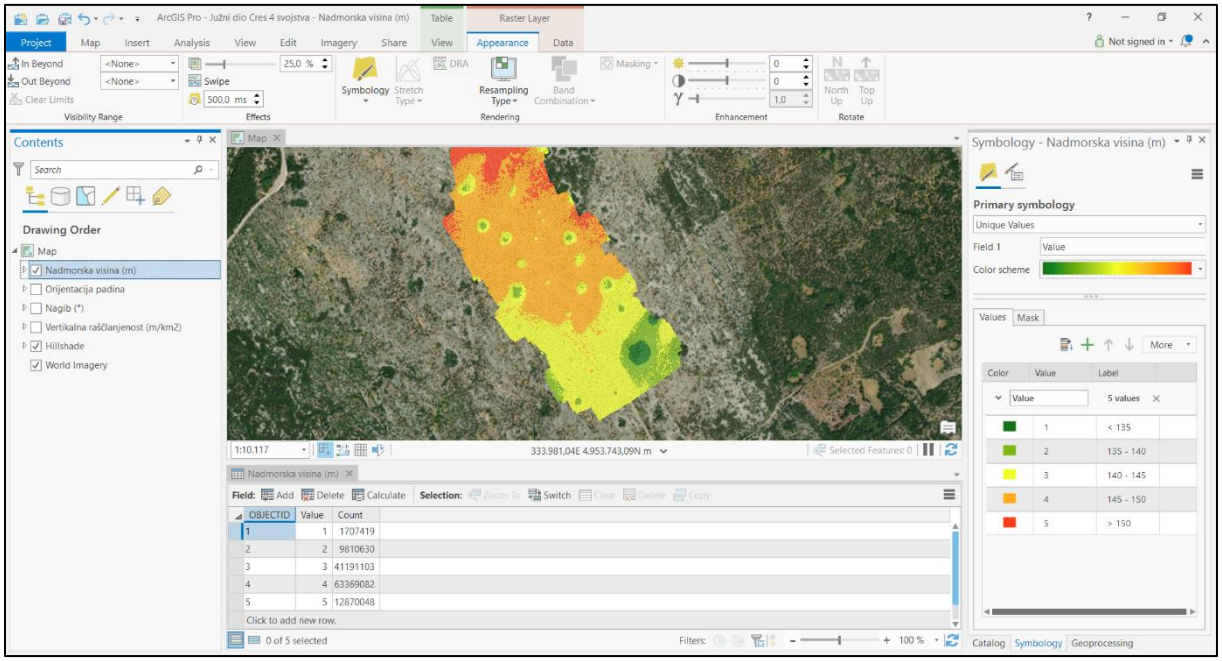

Sl. 38. Morfometrijska analiza unutar ArcGIS Pro softvera

Vertikalna raščlanjenost reljefa izračunata je pomoću funkcije *Focal statistics*. korištene su kategorije raščlanjenosti prema Bognar (1992), a radi bolje vizualizacije također je primijenjen efekt sjenčanja (engl. *hillshade*). Zbog visoke prostorne razlučivosti DEM-a za funkciju susjedstva odabrana je metoda pravokutnika (engl. *rectangle*). Konačno, za izračunavanje orijentacije padina korištena je funkcija *Aspect*. Odabrana je planarna (engl. *planar*) metoda izvođenja zbog relativno malene analizirane površine. Konačni rezultati razvrstani su u razrede prema glavnim i sporednim stranama svijeta. Kako bi se pomoću rezultata sve četiri analize mogli izračunati statistički pokazatelji oni su reklasificirani (engl. *reclassify*) u nove vrijednosti, a potom je izvršena statistička obrada unutar samog ArcGIS Pro softvera.

3.2.5.2. Tip ponikava

Tip ponikava prema presjeku određen je prema podijeli koju je predložio Cvijić (1893) - tanjuraste, ljevkaste i bunaraste ponikve. Za svaku izdvojenu ponikvu stvorena je linija koja je korištena za određivanje njezina profila. Pomoću funkcije *Interpolate Shape* svakoj liniji profila dodijeljen je podatak o visini iz „zaglađenog“ DEM-a, a profili ponikava generirani su pomoću funkcije *Profile Graph* (sl. 39). Postupak je ponovljen za ponikve izdvojene pomoću obje metode.

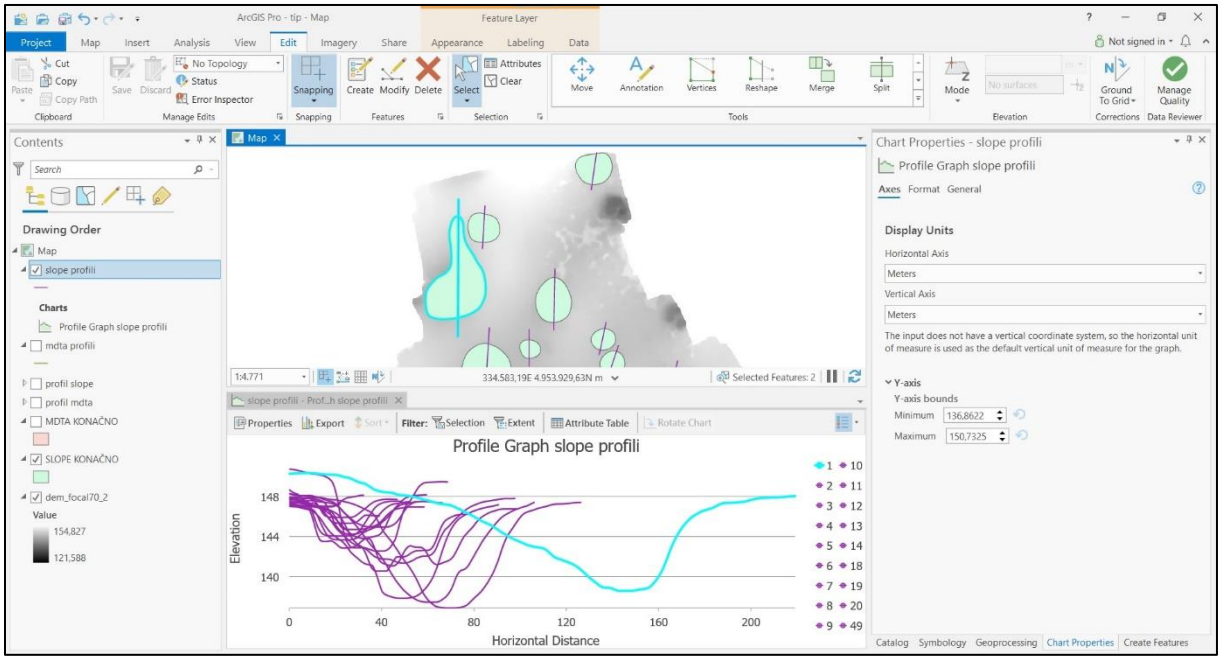

Sl. 39. Određivanje tipa ponikava unutar ArcGIS Pro softvera

3.2.5.3. Dubina ponikava

Dubina ponikava određena je svim izdvojenim ponikvama, a definirana je kao visinska razlika maksimalnih i minimalnih vrijednosti rasterskih ćelija. Pomoću funkcije *Zonal Statistics* i poligona izdvojenih ponikava definirane su zone na „zaglađenom“ DEM-u. Za svaku ponikvu (zonu) izračunali su se statistički pokazatelji minimalne i maksimalne vrijednosti DEM-a (najviša i najniža točka unutar svake ponikve). Pomoću funkcije *Raster Calculator* od rastera s maksimalnim visinama oduzet je raster s minimalnim visinama, a izlazni rezultat je rasterska datoteka u obliku ponikava u kojem svaka ćelija pojedine ponikve sadrži podatak o njezinoj dubini (sl. 40).

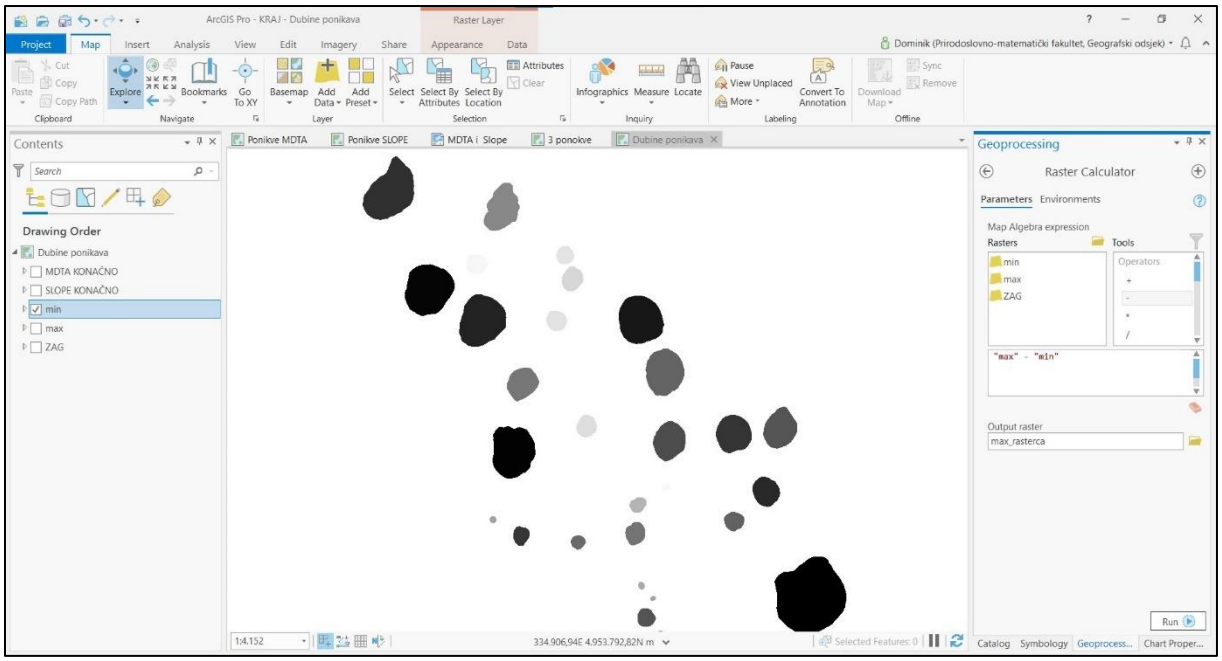

Sl. 40. Oduzimanje vrijednosti pomoću funkcije *Raster Calculator*

Ćelije s dubinama ponikava su pretvorene u poligone pomoću funkcije *Raster to Polygon*, a u svakom poligonu (ponikava) pohranjen je podatak o njegovoj dubini. Statistički pokazatelji poput prosjeka, minimalnih i maksimalnih vrijednosti također su izračunati unutar ArcGIS Pro softvera. Isti postupak proveden je za ponikve izdvojene pomoću obje metodologije. Dubina ponikava koristila se za izračunavanje ostalih morfometrijskih pokazatelja.

3.2.5.4. Volumen ponikava

Volumen ponikava je važan morfometrijski pokazatelj te se često koristi za međusobnu usporedbu analiziranih objekata. U ovom radu koristio se za usporedbu rezultata izdvajanja ponikava pomoću dvije različite metodologije. Za izračun volumena ponikava korištena je modificirana jednadžba za izračun volumena stošca (Bauer, 2015).

$$V=1/2*(\text{površina}*\text{dubina})$$

Podaci o površini i dubini ponikava izračunati su u prethodnim koracima ovoga rada, također unutar ArcGIS Pro softvera. Radi zornosti prikaza jedna ponikva je vizualizirana u trodimenzionalnom prostoru (sl. 52).

3.2.5.5. Indeks kružnosti

Indeks kružnosti (engl. *circularity indeks*, *Ci*) ponikve izražava vrijednost odstupanja oboda ponikve od pravilne kružnice. Formula za izračun indeksa kružnosti je

$$Ci = Ad/\pi(2*(Ad/Pd))$$

gdje Ad predstavlja površinu ponikve, a Pd predstavlja opseg ponikve. Što je vrijednost indeksa kružnosti bliža broju 1, to je obod ponikve pravilnijeg, kružnog oblika. Što je vrijednost dalja od broja 1, oblik ponikve je nepravilniji (Bauer, 2015). Vrijednosti indeksa manje od 1,2 predstavljaju kružni oblik ponikava, vrijednosti između 1,2 i 1,65 predstavljaju eliptične ponikve, a vrijednosti iznad 1,65 predstavljaju izdužene ponikve (Basso i dr, 2013).

3.2.6. Usporedba s postojećim podacima (ArcGIS Pro)

Izdvojene ponikve uspoređene su s postojećim podacima digitaliziranim s HOK-a i TK25 pomoću različitih funkcija unutar ArcGIS Pro softvera. Osnovni cilj usporedbe jest utvrđivanje odstupanja postojećih podataka od izdvojenih ponikava, odnosno utvrđivanje preciznosti obadviju metodologija korištenih za izdvajanje ponikava.
Prvi korak identificiranja odstupanja podrazumijevao je pretvaranje izdvojenih ponikava u linijske elemente (obode) pomoću funkcije *Polygon to Line*. Nakon stvaranja linijskih elemenata oni su pretvoreni u točke pomoću funkcije *Generate Points Along Lines*. Time se omogućava izračun udaljenosti svake pojedine točke od odabranog entiteta (HOK-a i TK25) (sl. 41).

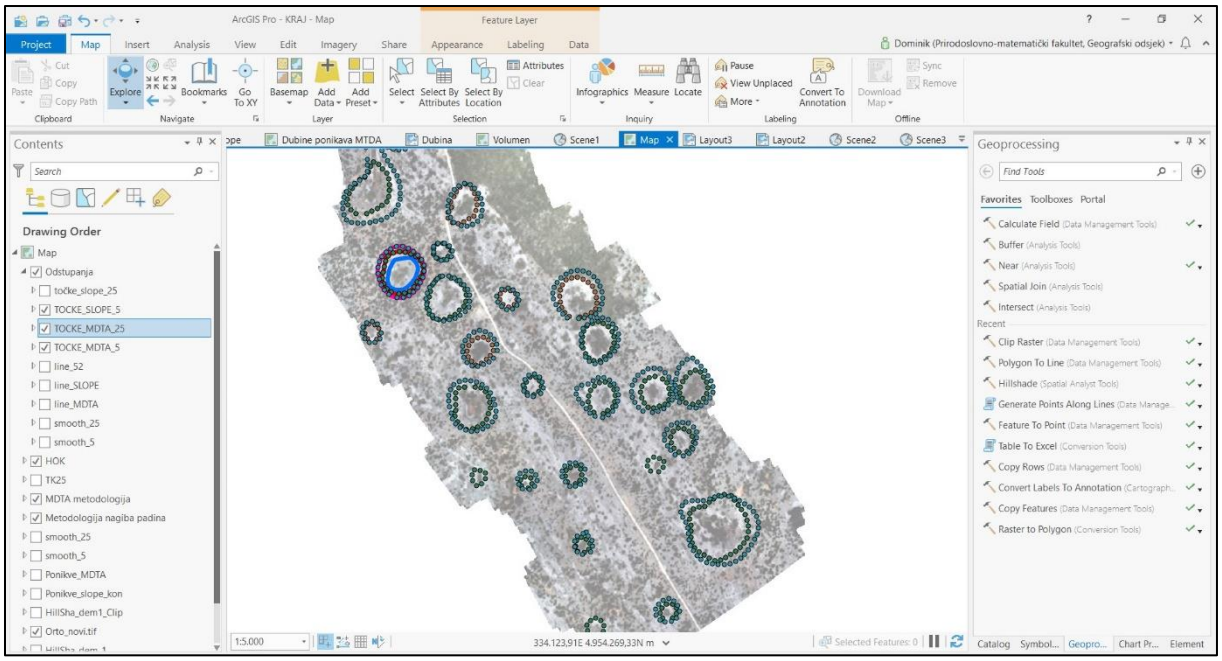

Sl. 41. Pretvaranje oboda u točkaste elemente unutar ArcGIS Pro softvera

Koristeći funkciju *Near* određene su udaljenosti svake pojedine točke od željenog elementa. Time su u atributivnoj tablici generirane udaljenosti između oboda kod ponikava izdvojenih pomoću ranije opisanih metoda i ponikava digitaliziranih sa HOK-a i TK25 (sl. 42). Navedene udaljenosti korištene su za izračune prosječnih vrijednosti koji nam pružaju informaciju o kvaliteti postojećih i generiranih podataka.

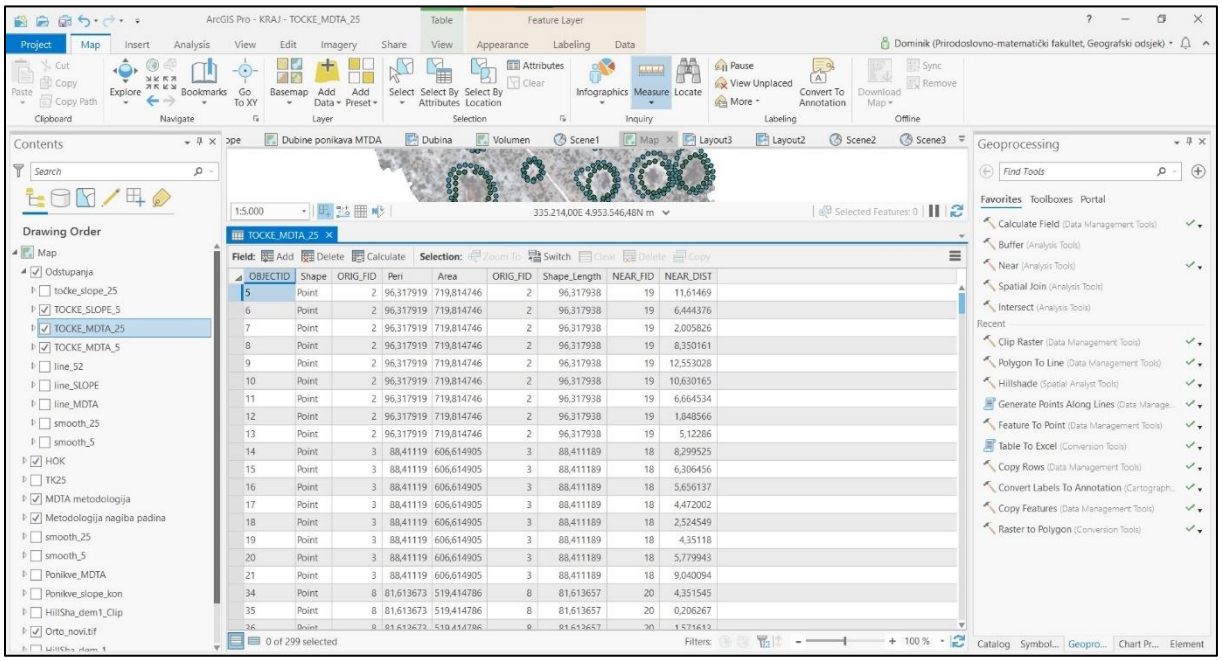

Sl. 42. Atributivna tablica sa generiranim udaljenostima između analiziranih entiteta

4. REZULTATI

4.1. DEM, DSM i DOF

Konačni rezultati terenskog prikupljanja podataka pomoću bespilotne letjelice i kasnije fotogrametrijske obrade su digitalni model reljefa (DEM), digitalni model površina (DSM) i digitalni ortofoto snimak (DOF). Njihova prostorna razlučivost iznosila je 2.8 cm čime spadaju u skupinu visokokvalitetnih prostornih podataka. Slika 43 prikazuje sva tri generirana modela.

Digitalni model površina (engl. *digital surface model, DSM*) (a) najvjernija je reprezentacija stvarnosti. Generiran je iz gustog oblaka točaka te sadržava informacije o svim područjima koje su obuhvaćene snimanjem pomoću bespilotne letjelice. Upravo zbog toga na njemu je izrazito dobro uočljiva vegetacija (svijetlije nijanse), preciznije informacija o visinskoj vrijednosti ćelije koja sadrži vegetaciju. Tako velika prostorna rezolucija koja obuhvaća i vegetaciju otežava precizne morfometrijske izračune, stoga predstavlja podatak upitne kvalitete za direktnu morfometrijsku analizu.

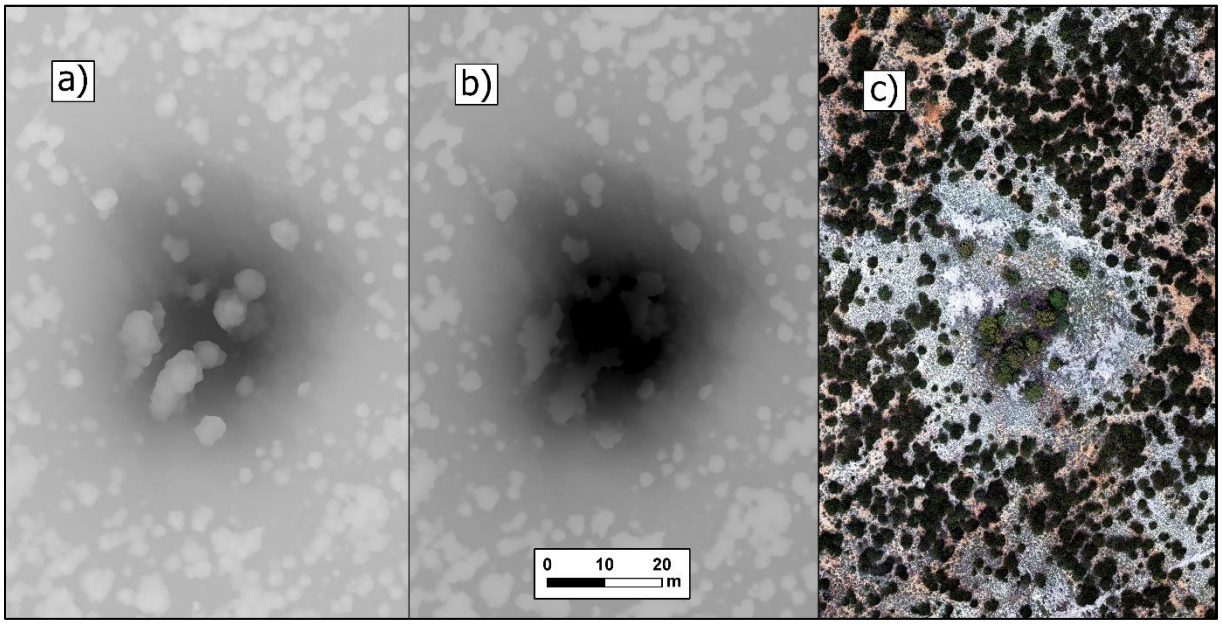

Sl. 43. DSM (a), DEM (b) i DOF (c)

Drugi generirani model je digitalni model reljefa (engl. *digital elevation model, DEM*) (b). Prilikom njegove izrade algoritmi Agisoft Metashape-a nastoje što vjernije prikazati reljef eliminirajući informacije o visini vegetacije. Rezultat modeliranja nije savršen stoga postoji vidljivo odstupanje od stvarnog modela reljefa.
Ipak, digitalni model reljefa predstavlja kvalitetniji ulazni podatak od digitalnog modela površina stoga je on odabran za sve daljnje analize. Treći generirani model je digitalni ortofoto snimak (engl. *digital orto-foto, DOF*) (c) koji je korišten za bolju vizualizaciju konačnih rezultata analize i tumačenje nejasnoća prilikom modeliranja podataka.

Za ispravne rezultate i iz njih izvedene zaključke kvaliteta ulaznih podataka mora biti osigurana. Pregledavanjem gotovih modela prostora uočene su nepravilnosti koje su utjecale na konačne rezultate analize. To se prvenstveno odnosi na nenamjerne pogreške nastale prilikom modeliranja unutar fotogrametrijskog softvera zbog njegove ograničenosti. Na rubnim dijelovima modela prostora prisutna su izobličena koja rezultiraju iskrivljenim podacima o reljefu, a samim time i neispravnim rezultatima (sl. 44). Iz tog razloga rubni prostori modela i njihovi rezultati isključeni su iz analize, a svi prikazani rezultati odnose se na dijelove modela koji se ne nalaze u neposrednoj blizini rubnog prostora.

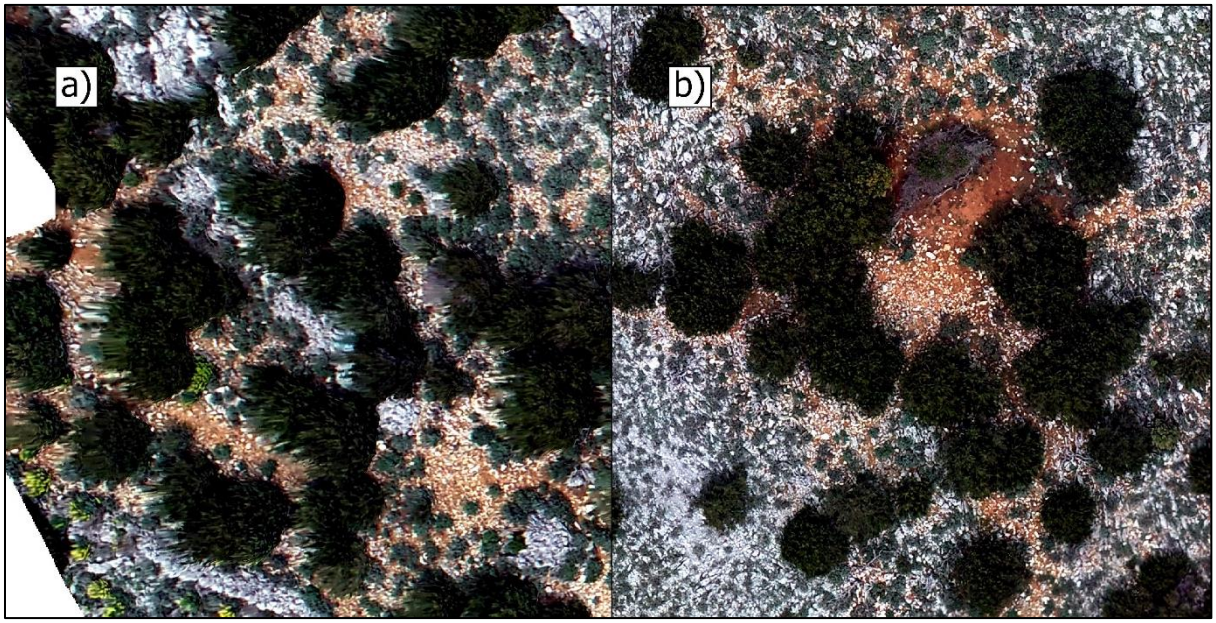

Sl. 44. Iskrivljeni (a) i ispravni (b) prikaz vegetacije na DOF-u

4.2. Nadmorska visina, nagib padina, vertikalna raščlanjenost reljefa i orijentacija padina

Na temelju generiranog DEM-a provedena je analiza osnovnih morfometrijskih pokazatelja. Za osnovnu morfometrijsku analizu korišten je DEM generiran pomoću Agisoft Metashape softvera bez procesa „zaglađivanja“.

Prema uobičajenoj klasifikaciji nadmorske visine cijelo istraživano područje bilo bi svrstano u visinski razred od 100 do 300 metara. Zbog relativno malenog područja istraživanja nadmorska visina podijeljena je u 5 novih razreda (sl. 45). Gotovo polovina površine pripada razredu od 145 do 150 metara nadmorske visine, a najmanji dio površine pripao je najnižem visinskom razredu (samo najdublji dijelovi pojedinih ponikava) (tab. 6). Kao i cijeli južni dio otoka Cresa, analizirano područje je relativno zaravnjeno, a nadmorska visina raste u smjeru S i SZ.

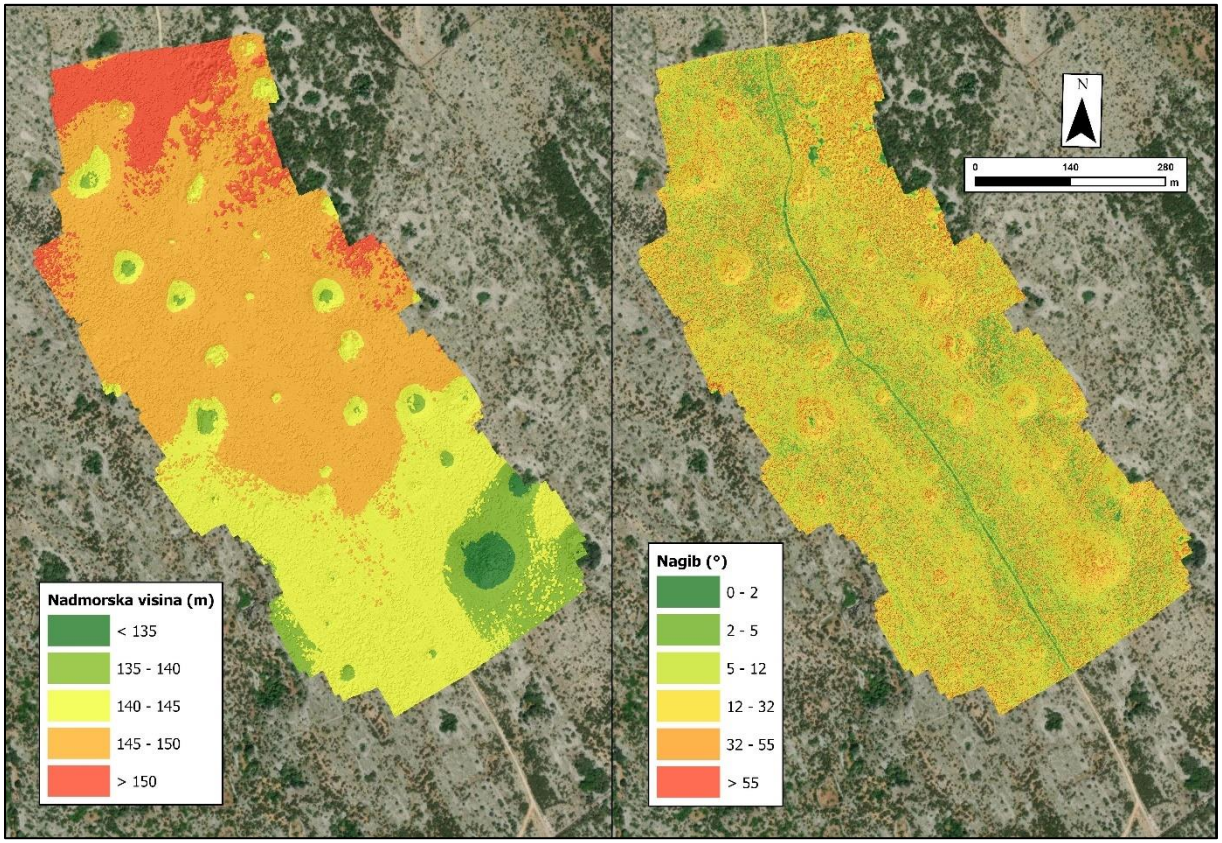

Sl. 45. Hipsometrijska karta i karta nagiba padina analiziranog područja

Tab. 6. Površinski udio hipsometrijskih razreda unutar analiziranog područja

Hipsometrijski razredi (m)	Udio u ukupnoj površini (%)
< 135	1,3
135 - 140	7,6
140 - 145	31,9
145 - 150	49,1
> 150	10,0

Nagibi padina analiziranog područja klasificirani su po standardnoj geomorfološkoj klasifikaciji (Demek, 1972) (sl. 45). U tablici 7 vidljivo je da su zastupljeni svi razredi nagiba padina, a dominira razred od 12° do 32° (37,6%). Ipak, na umu valja imati kako je za ulazni podatak korišten „nezaglađeni“ DEM na kojem je prisutna informacija o visini vegetacije. Radi velike prostorne razlučivosti ArcGIS Pro softver rubove krošanja stabala tumači kao padine strmije od 32°, što u stvarnosti nije tako. Usporede li se karte nagiba padina na sl. 45. i sl. 3. jasno je uočljivo da toliko strmi nagibi nisu česti unutar istraživanog područja. Stoga, navedenim rezultatima osnovne morfometrijske analize treba pristupati s dozom opreza.

Tab. 7. Površinski udio pojedinih razreda nagiba unutar analiziranog područja

Nagib padina (°)	Udio u ukupnoj površini (%)
0 - 2	3,7
2 - 5	12,0
5 - 12	27,2
12 - 32	37,6
32 - 55	13,7
> 55	5,9

Standardne kategorije raščlanjenosti reljefa za Hrvatsku prema Bognaru (1992) također nisu mogle biti primijenjene zbog relativno malenog područja istraživanja. Prema tim kategorijama cijelo područje pripada umjereno raščlanjenom reljefu. Za potrebe ove analize određene su nove kategorije (tab. 8), a najveći dio područja pripada kategoriji od 145 do 150 m/km² (49,1%). Kategorija vertikalne raščlanjenosti reljefa od 122 m/km² i manje zastupljena je isključivo na dnu najveće ponikve (sl. 46).

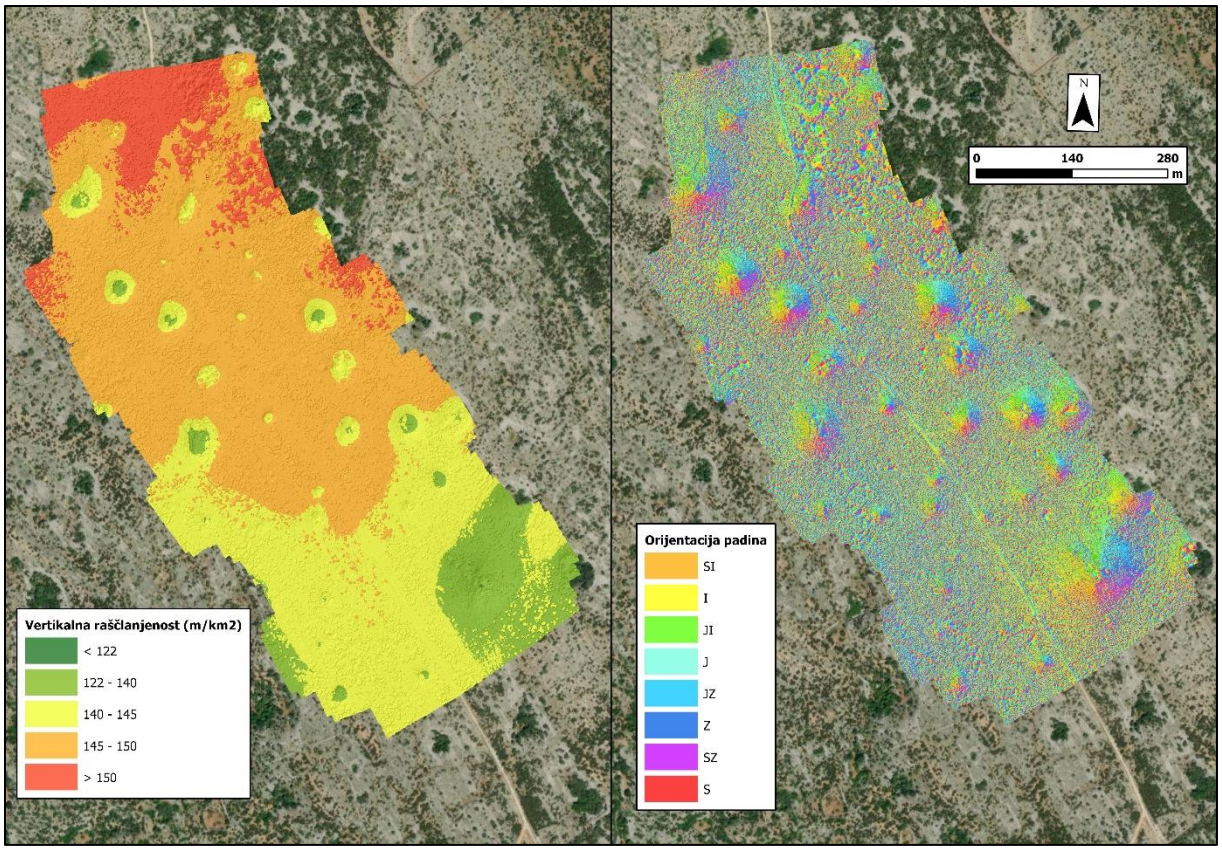

Sl. 46. Karta vertikalne raščlanjenosti i orijentacije padina analiziranog područja

Tab. 8. Površinski udio pojedinih razreda vertikalne raščlanjenosti reljefa unutar analiziranog područja

Vertikalna raščlanjenost reljefa (m/km²)	Udio u ukupnoj površini (%)
< 122	0,0
122 - 140	8,9
140 - 145	31,9
145 - 150	49,1
> 150	10,0

Orijentacija padina podijeljena je u 8 razreda prema glavnim i sporednim stranama svijeta. Zbog izrazito viskoze prostorne razlučivosti DEM-a svi razredi su gotovo jednako zastupljeni. Najmanji dio analiziranog područja ima S i SZ orijentaciju, a najveću površinu zauzimaju dijelovi s I i JI orijentacijom (tab. 9).

Tab. 9. Površinski udio pojedinih razreda orijentacije padina unutar analiziranog područja

Orijentacija padine	Udio u ukupnoj površini (%)
SI	13,2
I	14,1
JI	13,3
J	12,3
JZ	12,8
Z	12,4
SZ	11,5
S	10,4

4.3. Postojeći podaci (HOK i TK25)

Digitalizacijom ponikava s HOK-a unutar analiziranog područja obuhvaćene su ukupno 23 ponikve na kojima je provedena detaljna morfometrijska analiza (sl. 47). Zbog pogrešaka koje su nastale prilikom generiranja prostornih modela, a koje su ranije obrazložene, iz analize su isključene četiri ponikve čiji se centar nalazi u neposrednoj blizini ili na samoj granici područja istraživanja.

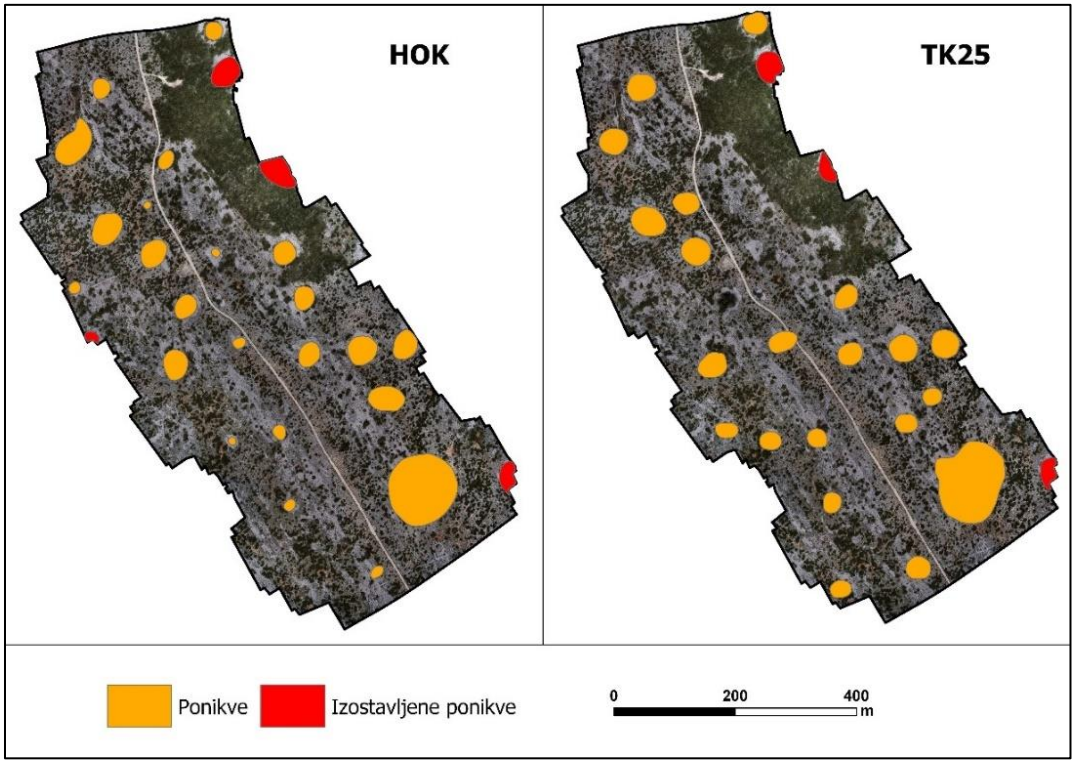

Sl. 47. Ponikve digitalizirane sa HOK-a i TK25

Prosječna veličina površine ponikava iznosi 1428,4 m², najveća površina iznosi 10607,8 m², a najmanja 124,3 m². Prosječna duljina oboda ponikava iznosi 117, 9 m, najdulji obod 367,0 m, a najkraći 39,8 m (tab. 10).

Digitalizacijom ponikava s TK25 također unutar analiziranog područja obuhvaćena je ukupno 21 ponikva na kojima je provedena detaljna morfometrijska analiza. Zbog ranije obrazloženih pogrešaka iz analize su isključene tri ponikve koje se podudaraju sa svim izostavljenim ponikvama digitaliziranim s HOK-a. Prosječna veličina površine ponikava iznosi 1793,2 m², najveća površina iznosi 11728,1 m², a najmanja 749,8 m². Prosječna duljina oboda ponikava iznosi 140,8 m, najdulji obod 404, 1 m, a najkraći 97,7 m (tab. 10).

Unutar okvira analiziranog područja na HOK-u je ucrtano 8,7% više ponikava nego na TK25. Morfometrijski pokazatelji imaju veće vrijednosti kod ponikava digitaliziranih sa TK25.

Tab. 10. Morfometrijski pokazatelji digitaliziranih ponikava

	HOK	**TK25**
Ukupan broj ponikava	23	21
Prosječna površina (m²)	1428,4	1793,2
Najveća površina (m²)	10607,8	11728,1
Najmanja površina (m²)	124,3	749,8
Prosječna duljina oboda (m)	117, 9	140,8
Najveća duljina oboda (m)	367,0	404, 1
Najmanja duljina oboda (m)	39,8	97,7

4.4. „Zaglađeni“ DEM

Visoka prostorna razlučivost podataka prikupljenih pomoću bespilotne letjelice omogućava vrlo preciznu morfometrijsku analizu. Ipak, zbog prisutnosti vegetacije na generiranom DEM-u kroz ArcGIS Pro softver pomoću dostupnih funkcija proveden je proces njegovog „zaglađivanja“. Slika 48 prikazuje ulazni DEM (a) i model prostora nakon ranije opisanog postupka (b). Prikazom u trodimenzionalnom (3D) okruženju jasno su vidljive prisutne razlike, odnosno odsutnost vegetacije koja omogućava detaljnu morfometrijsku analizu.

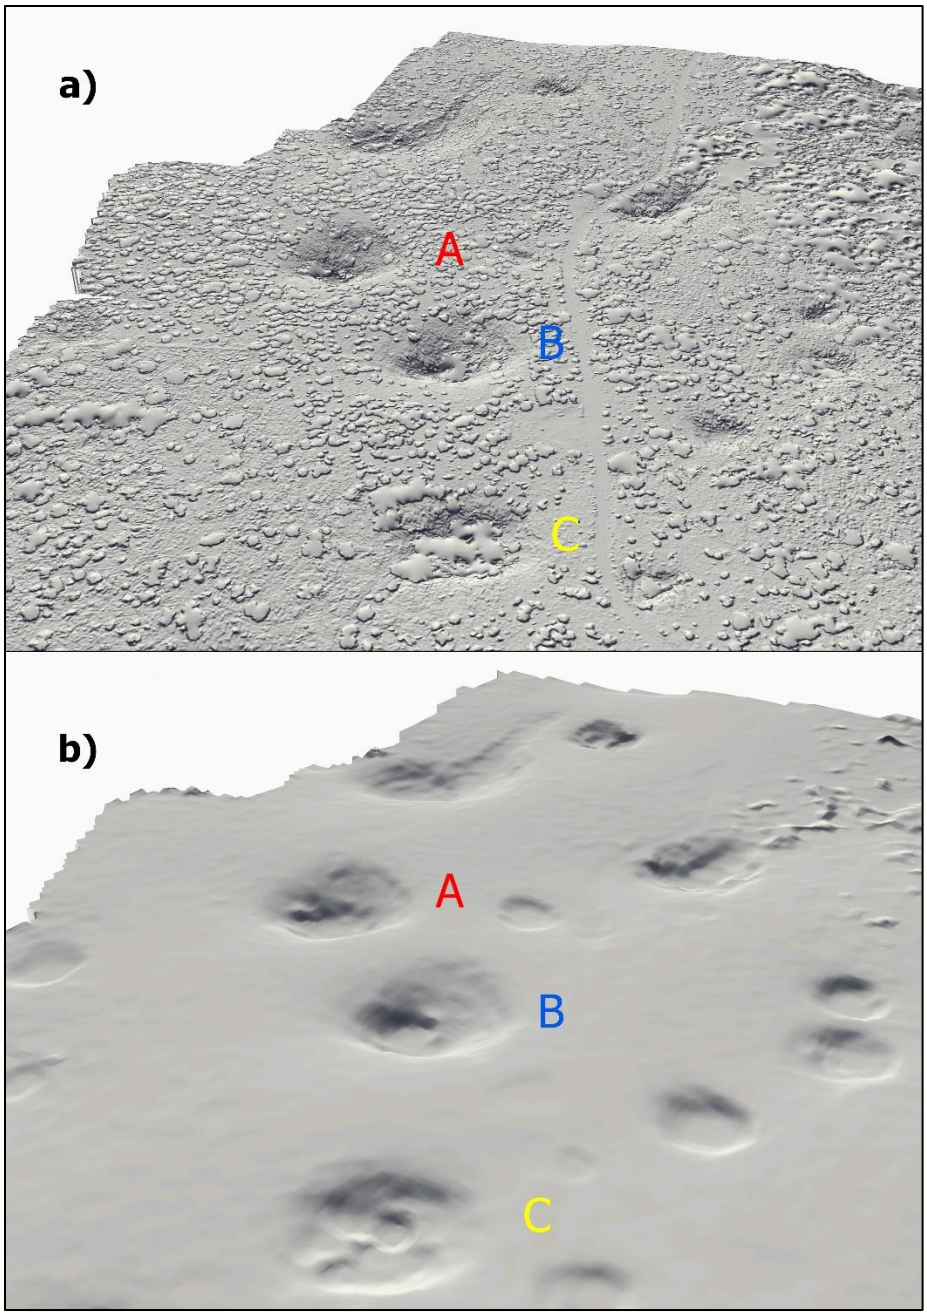

Sl. 48. DEM prije (a) i poslije (b) procesa „zaglađivanja“

Slika 49 prikazuje dvije nasumično odabrane ponikve u kojima je prisutna vegetacija. Usporedbom profila ponikava prije i poslije procesa „zaglađivanja“ uočljivo je kako vegetacija ima presudnu ulogu u detaljnoj morfometrijskoj analizi.

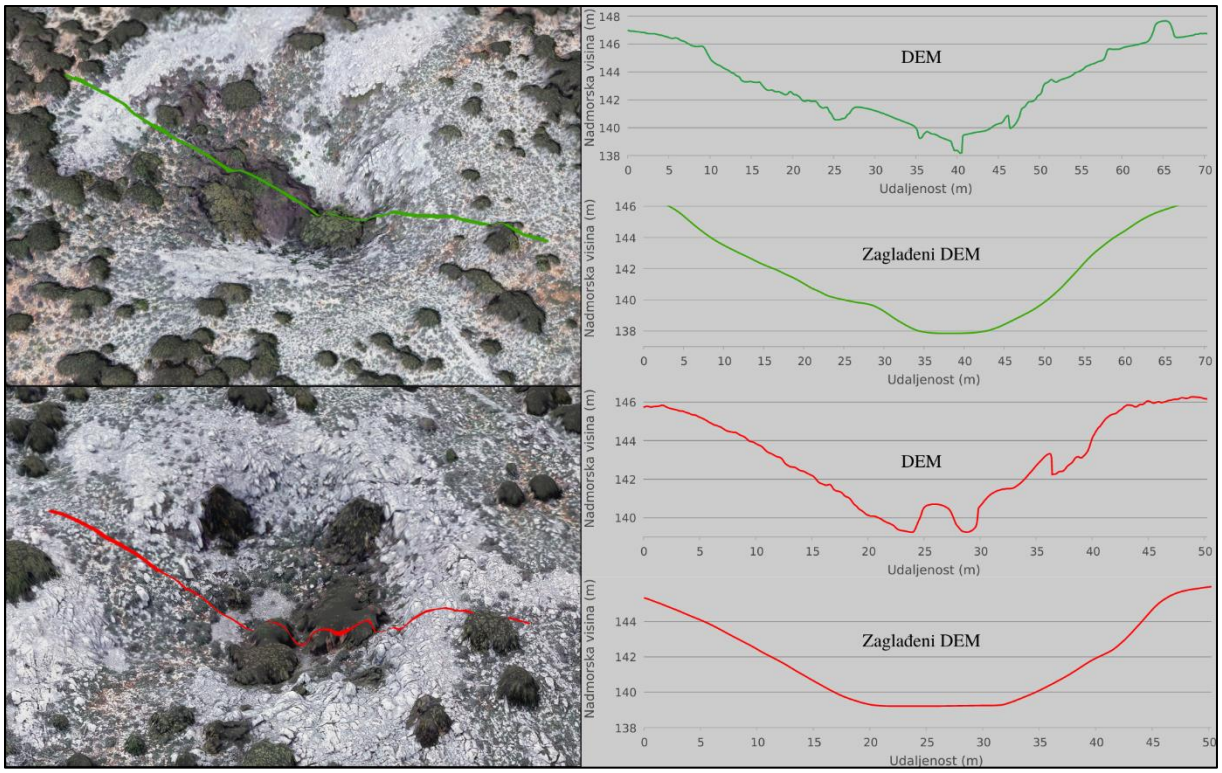

Sl. 49. Profili ponikava prije i nakon procesa „zaglađivanja“

Eliminacijom vegetacije postiže se realan uvid u tip, visinu oboda i dubinu dna pojedinačnih ponikava. Također, to je jedina ispravna osnova za precizno izračunavanje ostalih pokazatelja. Podaci o nadmorskoj visini prikupljenih kontrolnih točaka (engl. *groung control point, GCP*) još su jedan način provjere vjerodostojnosti podataka na „zaglađenom“ DEM-u. Unutar ArcGIS pro softvera preklopljeni su slojevi DEM-a, „zagleđenog“ DEM-a i kontrolnih točaka. ispitivanjem elemenata, tj. atributivne tablice napravljena je usporedba visina prikazana u tablici 11.

Tab. 11. Usporedba nadmorske visine (m) kontrolnih točaka, DEM-a i „zaglađenog“ DEM-a

Br.	GCP	DEM	Zaglađeni DEM
1	148,4	147,9	147,9
2	144,9	144,1	144,0
3	146,8	146,7	145,5
4	138,1	139,7	139,2
5	142,4	142,6	142,6
6	143,7	143,7	143,6
7	141,3	141,8	141,7
8	140,0	139,9	139,3
9	136,4	135,8	135,4
10	137,8	137,3	136,9

Podaci o nadmorskoj visini prikupljeni su za 10 kontrolnih točaka koje su nasumično raspoređene cijelim istraživanim područjem. Nadmorska visina na DEM-u generirana je unutar fotogrametrijskog softvera Agisoft Metashape te je dodatno ispravljena dodavanjem kontrolnih točaka. Visine na „zaglađenom“ DEM-u su interpolirane postupkom zaglađivanja i predstavljaju osnovu za izdvajanje ponikava. Usporedbom razlika u nadmorskim visinama mogu se jednostavno utvrditi eventualna odstupanja. Prosječno odstupanje DEM-a od visina kontrolnih točaka iznosi 3 cm, a prosječno odstupanje „zaglađenog“ DEM-a od osnovnog DEM-a iznosi 34 cm. Konačno, prosječno odstupanje „zaglađenog“ DEM-a od kontrolnih točaka iznosi 37 cm. Bez obzira na navedena odstupanja generirani modeli prostora i dalje predstavljaju ulazni podatak visoke kvalitete za detaljnu morfometrijsku analizu.

4.5. Rezultat izdvajanja ponikava modificiranom MDTA metodom (mMDTA) i metodom nagiba padina (MNP)

Modificiranom MDTA metodom iz „zaglađenog“ DEM-a izdvojeno je ukupno 40 ponikava na kojima je provedena detaljna morfometrijska analiza, a isključeno je njih 8. Većina isključenih ponikava nalazi se u neposrednoj blizini granice analiziranog područja (njih 7), a jedna izdvojena ponikva predstavlja pogrešku prilikom izdvajanja koja je nastala zbog veće prisutnosti vegetacije (sl. 50).

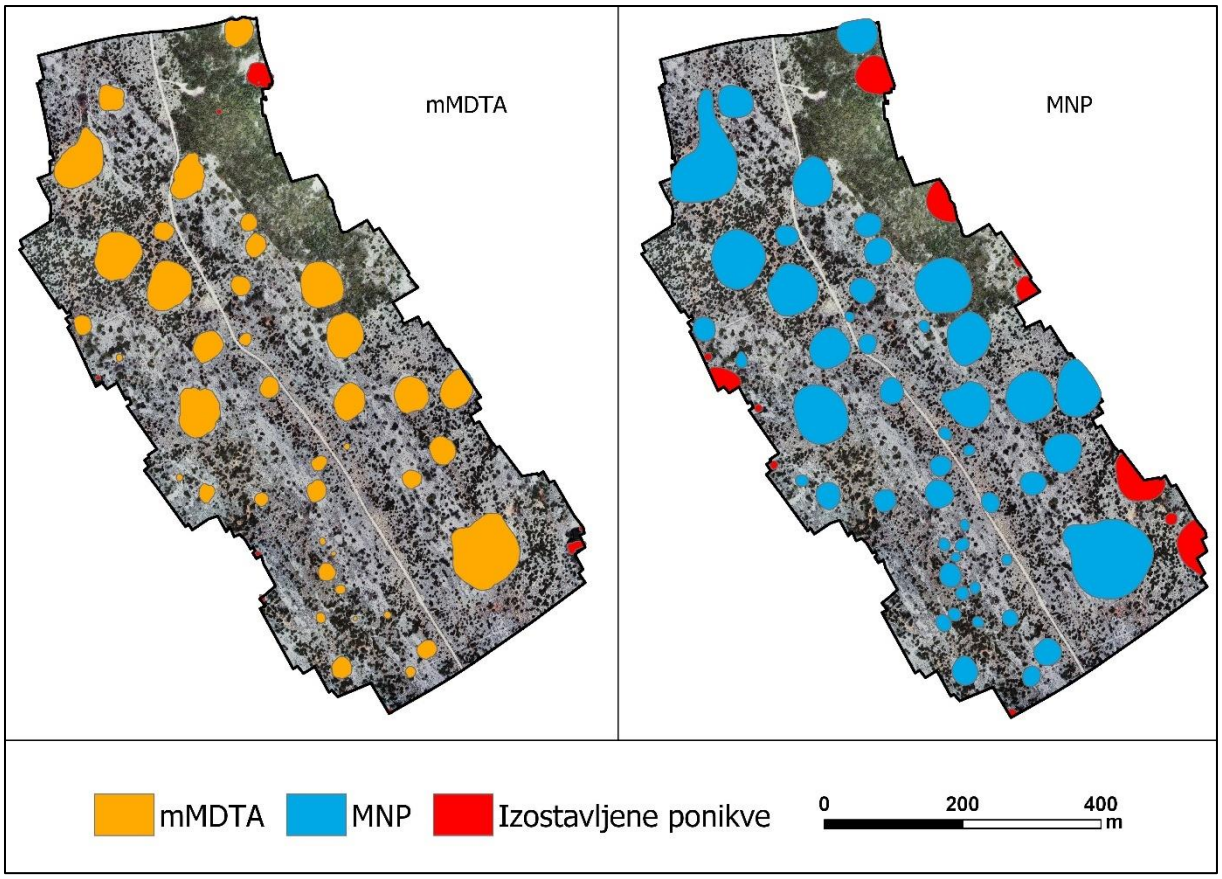

Sl. 50. Prikaz ponikava izdvojenih modificiranom MDTA metodom i metodom nagiba padina

Prosječna površina izdvojenih ponikava iznosi 1302,3 m², najveća površina 8081,9 m², a najmanja 30,8 m². Prosječna duljina oboda iznosi 111,2 m, najveća duljina 332,0 m, a najmanja duljina 19,8 m (tab. 12).

Tab. 12. Morfometrijski pokazatelji izdvojenih ponikava

	mMDTA	**MNP**
Ukupan broj ponikava	40	49
Prosječna površina (m²)	1302,3	1798,8
Najveća površina (m²)	8081,9	11364,5
Najmanja površina (m²)	30,8	151,4
Prosječna duljina oboda (m)	111,2	131,0
Najveća duljina oboda (m)	332,0	429,8
Najmanja duljina oboda (m)	19,8	43,8

Metodom nagiba padina iz „zaglađenog“ DEM-a izdvojeno je ukupno 49 ponikava (18,4% ponikava više od modificirane MDTA metode) na kojima je provedena detaljna morfometrijska analiza, a isključeno je njih 13. Sve isključene ponikve nalaze se u neposrednoj blizini granice analiziranog područja (sl. 50). Prosječna površina izdvojenih ponikava iznosi 1798,8 m², najveća površina 11364,5 m², a najmanja 151,4 m². Prosječna duljina oboda iznosi 131,0 m, najveća duljina 429,8 m, a najmanja duljina 43,8 m (tab. 11).

4.6. Detaljna morfometrijska analiza

Na temelju podataka prikupljenih bespilotnom letjelicom i modela prostora koji su iz njih generirani na izdvojenim ponikvama provedena je detaljna morfometrijska analiza.

4.6.1. Tip izdvojenih ponikava

Od ukupno 40 ponikava izdvojenih modificiranom MDTA metodom 31 ponikva ima tanjurasti tip profila, a 9 ponikava ima ljevkasti tip. Metodom nagiba padina izdvojeno je 49 ponikava od kojih 40 ima tanjurasti oblik, a 9 ponikava ima ljevkasti oblik (tab. 13).

Tab. 13. Tip profila izdvojenih ponikava

	Ljevkaste	Tanjuraste
mMDTA	9	31
MNP	9	40

4.6.2. Dubina izdvojenih ponikava

Prosječna dubina ponikava izdvojenih Modificiranom MDTA metodom iznosi 3,4 m, najmanja dubina iznosi 0,1 m, a najveća 14,9 m. Prosječna dubina ponikava izdvojenih metodom nagiba padina iznosi 4,4 m, najmanja dubina 0,5 m, a najveća 18,7 m. Slika 51 prikazuje usporedbu i prostorni raspored dubina za obadvije metode.

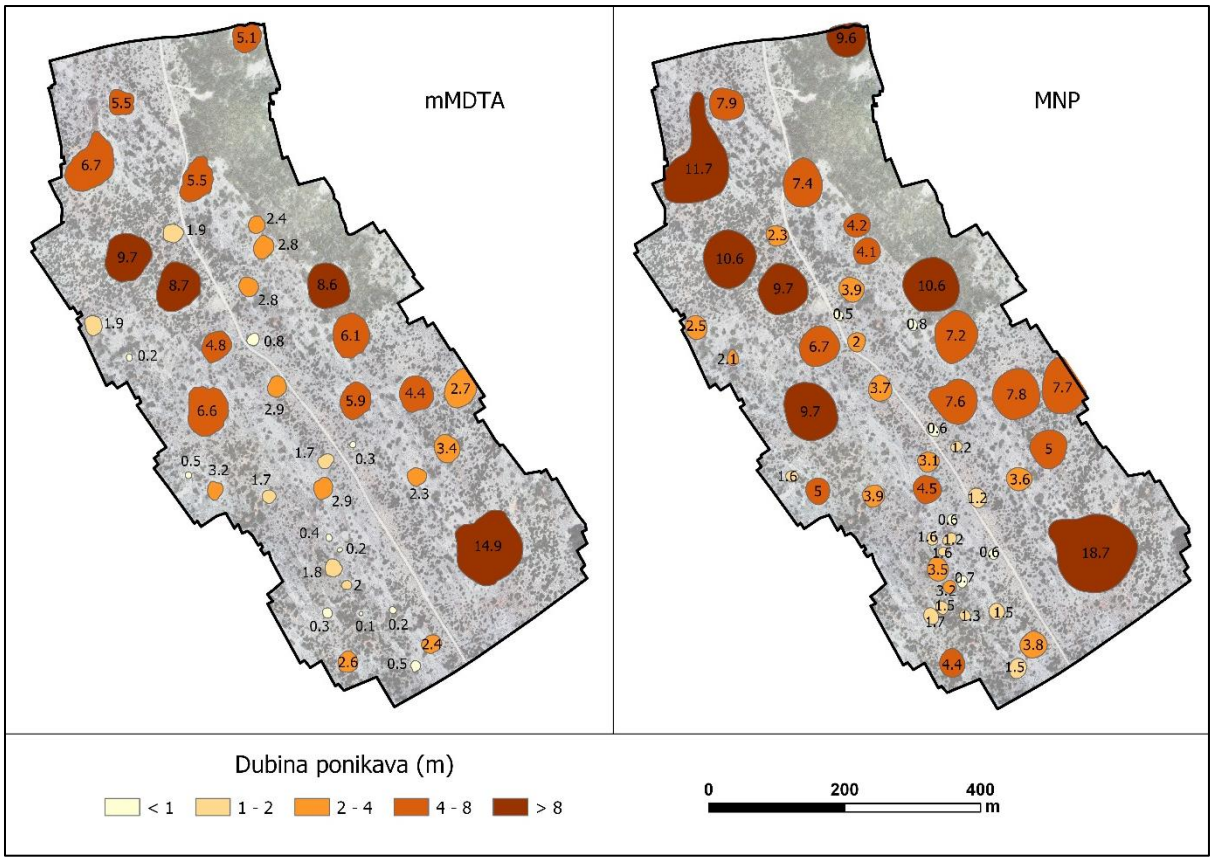

Sl. 51. Usporedba i prostorni raspored dubina ponikava

Površinom manje ponikve ujedno su i one pliće, dok su površinom veće ponikve dublje. Razlika u dubini ponikava između dvije opisane metodologije nastaje zbog većeg oboda ponikava izdvojenih metodom nagiba padina. Nadmorske visine koje ulaze u kalkulaciju dubine imaju više vrijednosti upravo zbog šireg oboda, nego ponikve izdvojene modificiranom MDTA metodom. Prikupljanjem podataka pomoću bespilotne letjelice i izdvajanjem modificiranom MDTA metodom detektirano je 17 manjih i plićih ponikava koje nisu vidljive na ranije dostupnim podacima (na HOK-u). Izdvajanjem ponikava metodom nagiba padina detektirane su 24 ponikve koje nisu vidljive na HOK-u. Veće ponikve uglavnom su prisutne na dostupnim podacima, uz značajnu razliku u veličini morfometrijskih pokazatelja.

4.6.3. Volumen izdvojenih ponikava

Prosječni volumen ponikava izdvojenih modificiranom MDTA metodom iznosi 4605,5 m^3, najmanji volumen je 1,1 m^3, a najveći iznosi 60156,1 m^3. Prosječni volumen ponikava izdvojenih metodom nagiba padina iznosi 8040,2 m^3, najmanji volumen je 43,7 m^3, a najveći iznosi 106195,6 m^3. Razlika između prosječnih volumena iznosi 42, 7% (sl. 52).

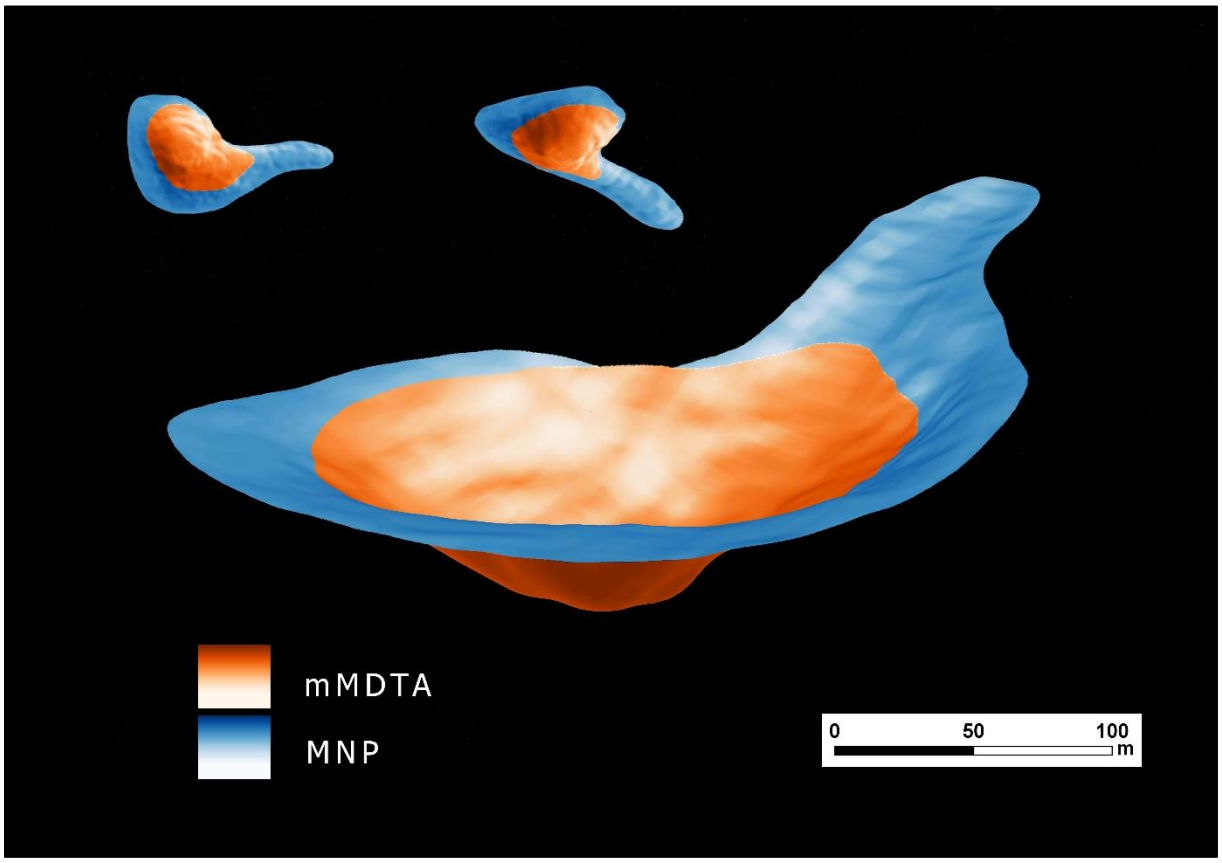

Sl. 52. 3D vizualizacija volumena iste ponikve izdvojene različitom metodologijom

Zanimljivo je usporediti odnos volumena ponikava i njihove dubine. Statističkom analizom utvrđeno je kako postoji statistički značajna korelacija između parametara dubine ponikava i njihovog volumena za obadvije metode izdvajanja ($R^2 = 0.9$) (sl. 53 i sl. 54).

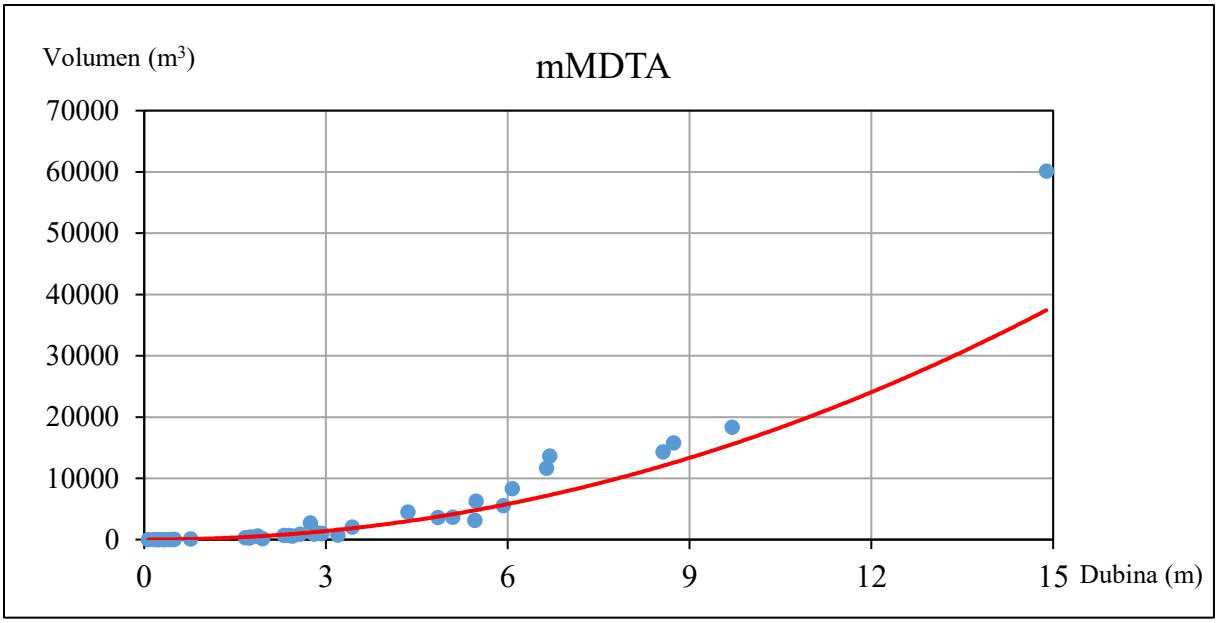

Sl. 53. Prikaz korelacije parametara dubine i volumena ponikava izdvojenih modificiranom MDTA metodom

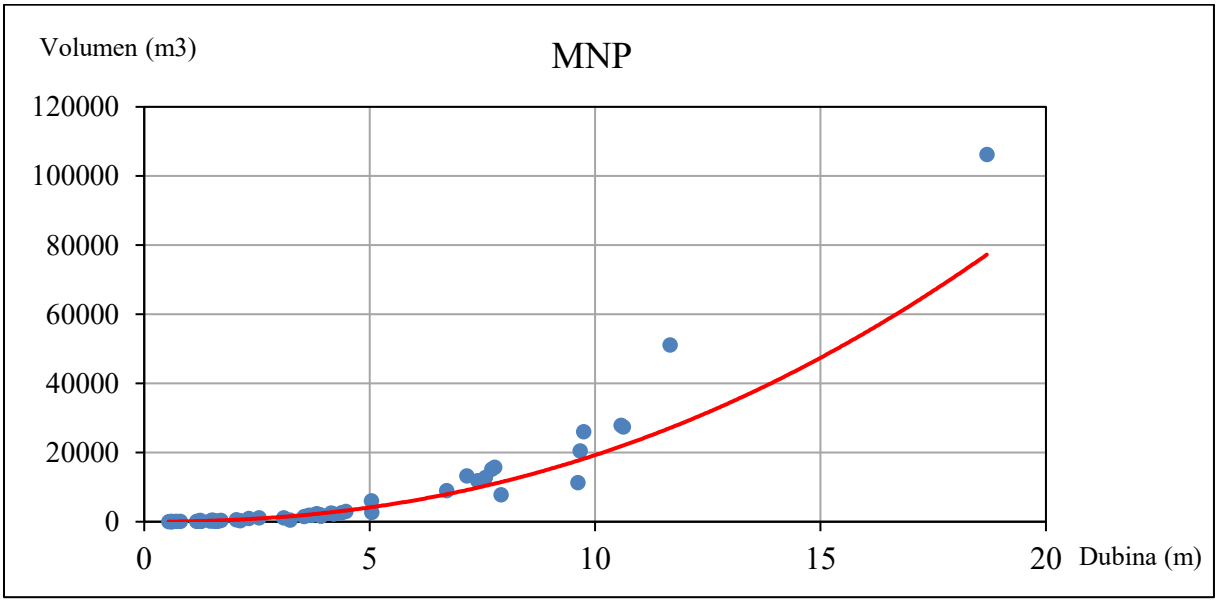

Sl. 54. Prikaz korelacije parametara dubine i volumena ponikava izdvojenih metodom nagiba padina

4.6.4. Indeks kružnosti

Indeks kružnosti (engl. *circularity indeks*, *Ci*) klasificiran je u 3 kategorije prema Basso i dr. (2013). Ponikva je okrugla ukoliko *Ci* iznosi do 1,2, eliptična između 1,2 i 1,65 te izdužena ukoliko je *Ci* veći od 1,65. Prosječan indeks kružnosti za ponikve izdvojene modificiranom MDTA metodom iznosi 1,05, a za one izdvojene metodom nagiba padina iznosi 1,03. Dakle, sve izdvojene ponikve imaju izrazit kružni oblik. Samo jedna ponikva izdvojena metodom nagiba padina izduženi oblik, odnosno vrijednost indeksa kružnosti 1,68.

4.7. Rezultati usporedbe s postojećim podacima

Izdvajanjem ponikava pomoću modificirane MDTA metode izdvojeno je ukupno 40 ponikava, odnosno 42,5% više nego što ih je prikazano na HOK-u (njih 23). U usporedbi s podacima digitaliziranim s TK25, istom metodom izdvojeno je 47,5% više ponikava. Nadalje, izdvajanjem ponikava pomoću metode nagiba padina izdvojeno je ukupno 49 ponikava, odnosno 53,1% više nego što ih je prikazano na HOK-u (njih 23). U usporedbi s podacima digitaliziranim s TK25, istom metodom izdvojeno je 57,1% više ponikava.
Navedeni rezultati ukazuju na nepotpunost informacija, odnosno relativno visoku razinu generalizacije podataka prisutnih na najdetaljnijim dostupnim podacima o ponikvama u Republici Hrvatskoj.

Između ponikava koje su prisutne na HOK-u i TK25, a koje su izdvojene pomoću obadviju metoda provedena je analiza odstupanja. Time je utvrđena preciznost prikazivanja, tj. točnost dostupnih podataka na HOK-u i TK25. Izračunavanjem prosječnih vrijednosti generiranih pomoću funkcije *Near* utvrđena je razlika između oboda izdvojenih ponikava i postojećih podataka.

Tab. 14. Prosječna odstupanja (m) između izdvojenih ponikava i postojećih podataka

	mMDTA	**MNP**
HOK	7,3	13,5
TK25	8,2	11,2

Prosječno odstupanje oboda ponikava izdvojenih pomoću modificirane MDTA metode u odnosu na HOK iznosi 7,3 m, a u odnosu na TK25 8,2 m. Prosječno odstupanje oboda ponikava izdvojenih pomoću metode nagiba padina od HOK-a iznosi 13,2 m, a od TK25 11,2 m (tab. 14). Iz navedenoga proizlazi kako rezultate koji su najbliži HOK-u predstavljaju ponikve izdvojene pomoću modificirane MDTA metode. Generalno gledajući, modificirana MDTA metoda ima 37,2 % manje odstupanje od postojećih podataka nego metoda nagiba padina.

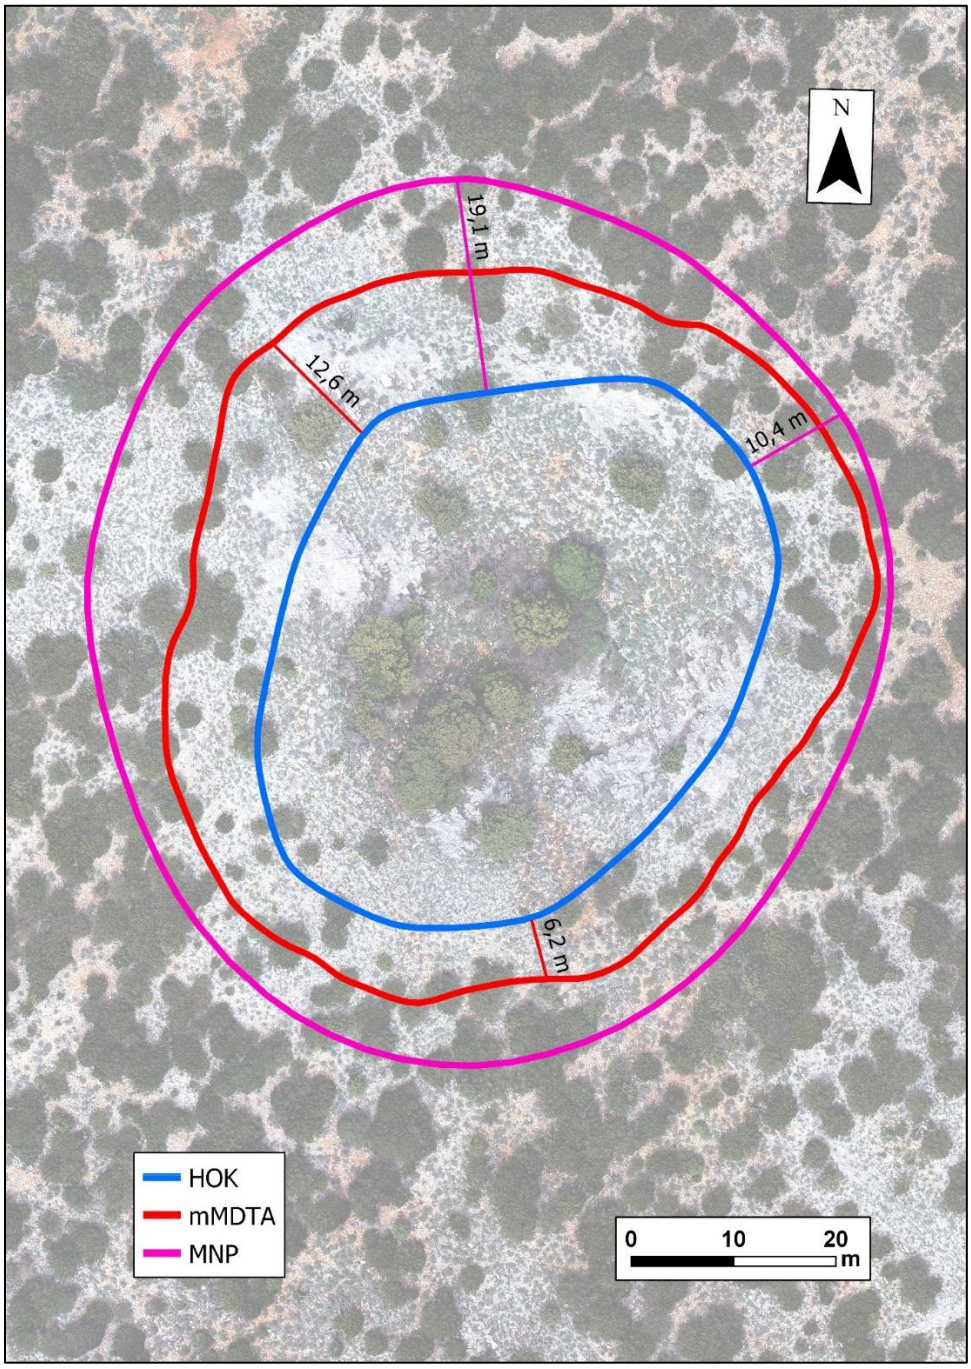

Sl. 55. Prikaz odstupanja izdvojene ponikve od postojećih podataka

Slika 55 prikazuje minimalno i maksimalno odstupanje nasumično izdvojene ponikve od HOK-a. Najmanju duljinu oboda ima ponikva digitalizirana s HOK-a, dok su obodi izdvojenih ponikava širi te obuhvaćaju veći prostor. Veća odstupanja od HOK-a prisutna su kod oboda izdvojenog metodom nagiba padina, nego kod modificirane MDTA metode.

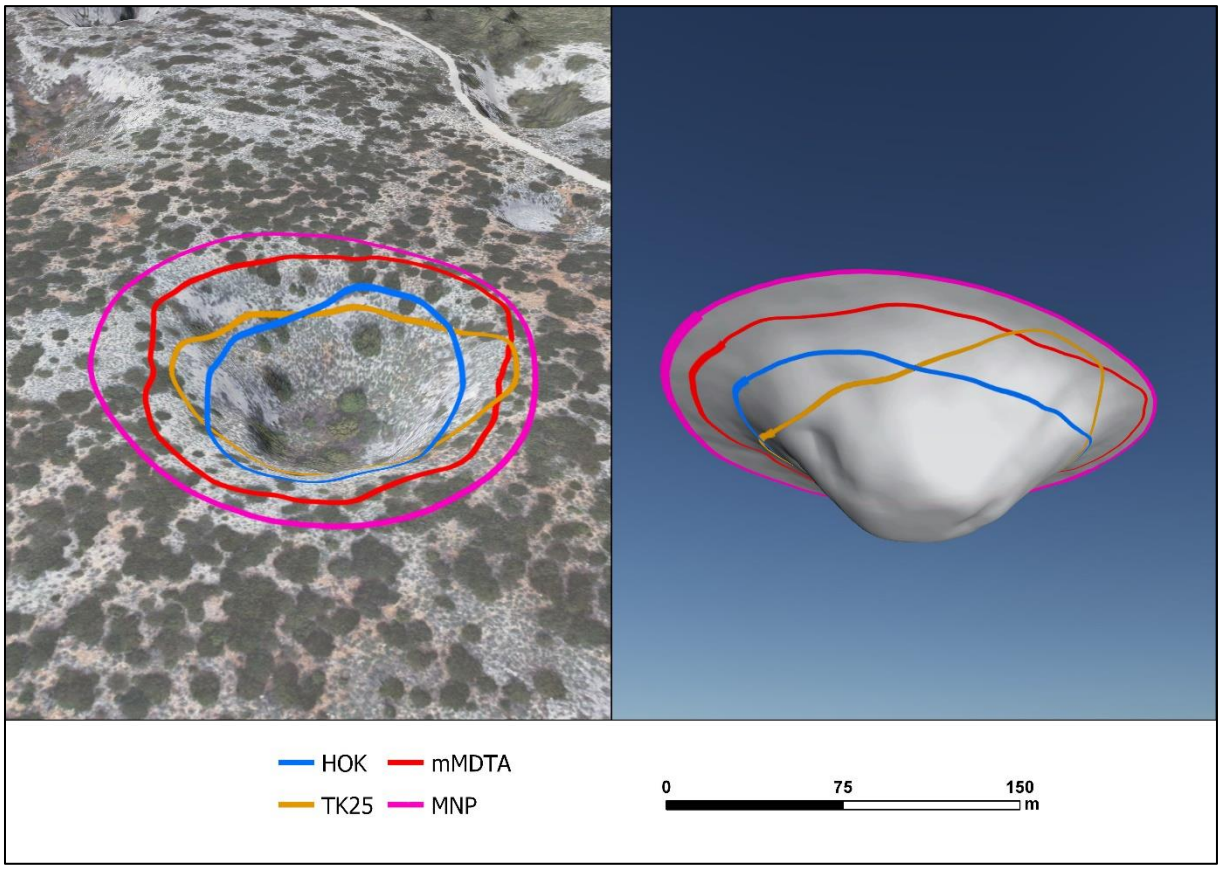

Sl. 56. 3D prikaz odstupanja izdvojene ponikve u odnosu na kartografske izvore

Radi jasnije predodžbe o konkretnoj lokaciji oboda izdvojene ponikve, sva četiri oboda prikazana su u 3D prostoru (sl. 56). Obodi digitalizirani s HOK-a i TK25 relativno neprecizno opisuju gornju granicu ponikve te na taj način pružaju nepotpunu informaciju o njezinom stvarnom obliku, veličini i smještaju. Obod generiran metodom nagiba padina obuhvaća i široko područje oko same ponikve koje je zaravnjeno te kao takvo ne predstavlja geomorfološku cjelinu ponikve. Obod izdvojen modificiranom MDTA metodom relativno dobro opisuje stvarni obod te kao takav predstavlja najkvalitetniji podatak za vjerodostojnu morfometrijsku analizu.

5. RASPRAVA

Većina istraživanja geomorfoloških obilježja ponikava u novije vrijeme uključuje daljinska istraživanja. Dosadašnja istraživanja ponikava na području Hrvatske uključivala su uglavnom terensko kartiranje i analizu ponikava iz kartografskih izvora (TK25 i HOK). U nekim od prvih istraživanja Faivre (1992) analizira gustoću ponikava metodama piktograma i izolinija upravo iz kartografske podloge TK25 iz čega povezuje dobivenu gustoću i prostorni raspored ponikava s utjecajem rasjednih zona. Dostupni kartografski izvori pokazali su se primjenjivim i preciznim, pogotovo za neka veća, regionalna područja. Početkom 21. stoljeća u Hrvatskoj, razvojem tehnologije i novih metoda, GIS sustav unaprijedio je i olakšao istraživanja ponikava (Pahernik, 2000; Faivre i Pahernik, 2007). Pahernik (2000) je GIS analizama susjedstva istraživao ponikve na SZ dijelu Velike Kapele te utvrđuje korelaciju između gustoće pojave ponikava i rasjednih zona, Faivre i Pahernik (2007) pomoću GIS-a su istražuju razvoj ponikava na Braču i također ih povezuju sa strukturnim obilježjima područja, Šegina (2018) je pomoću DOF-a u GIS softveru analizirala ponikve na Krku u krupnom mjerilu i zaključuje kako je ručno izdvajanje ponikava najprecizniji mogući način. GIS softver ubrzao je analize ponikava te pružio nove mogućnosti i funkcije za istraživanja. Također, primjena suvremenih kartografskih podloga, poput satelitskih snimaka i ortofoto snimka pružaju nove mogućnosti izdvajanja i istraživanja ponikava u zadovoljavajućoj rezoluciji.

Najprecizniji način prikupljanja podataka o reljefu uz eliminaciju prisutne vegetacije i dalje predstavlja upotreba LiDAR senzora koji dominiraju u radovima na svjetskoj razini istraživanja (Moreno-Gómez i dr., 2019; Čeru i dr., 2017). U Hrvatskoj su slabije zastupljeni zbog javno nedostupnog LiDAR oblaka točaka. Kožar (2020) u svom je radu istraživala ponikve na području NP Plitvička jezera te je provela detaljnu analizu reljefnih atributa i prostornih statistika na temelju LiDAR snimka, a konačni rezultat bio je visoke prostorne razlučivosti i mnogo veće kvalitete nego ranije dostupni DEM. Analizama na temelju LiDAR snimaka posebno se ističu Slovenci koji u velikom broju radova provode kompleksne analize (Čeru i dr., 2017; Mihvec i Mihvec, 2021, Popit i dr., 2014). U svojim radovima naglašavaju kako su topografske karte relevantne uglavnom za izračunavanje gustoće ponikava, odnosno globalnih morfometrijskih pokazatelja. Za detaljnu morfometrijsku analizu naglašavaju preciznost korištenja DEM-a i GIS alata, odnosno LiDAR podataka koji predstavljaju najprecizniji podatak. Ističu kako za regionalne analize nije potrebno ništa više od topografskih karata, ali, ukoliko se analiza obavlja na mikrolokaciji LiDAR podaci pružaju najvjernije rezultate.

Ipak, postupak modeliranja prostora pomoću LiDAR senzora predstavlja zahtjevnije pripreme i složeniji postupak generiranja modela, a sami uređaji su osjetljivi, vrlo skupi i često nedostupni.Za razliku od LiDAR-a, bespilotna letjelica opremljena RGB senzorom lako je dostupna i omogućuje brz i jednostavan način prikupljanja podataka (Śledź i dr., 2021).

U ovom radu, terenskim prikupljanjem podataka pomoću bespilotne letjelice i GNSS uređaja te kasnijom fotogrametrijskom obradom generirani su modeli reljefa visoke prostorne razlučivosti (2.8 cm). Analize rađane iz DEM-a Državne geodetske uprave uglavnom su rezolucije 5 ili 10 m, dok je Kožar (2020) koristila LiDAR snimak u vlasništvu NP Plitvička jezera prostorne rezolucije 0,5 m. S obzirom da se radi o generiranju modela iz RGB kamere u centimetarskoj prostornoj rezoluciji, vegetacija i neki objekti predstavljaju izazov i potencijalnu grešku u odnosu na LiDAR tehnologiju (u kojoj je vrlo jednostavno eliminirati vegetaciju). Structure from Motion (SfM) tehnologija, koja je korištena u ovom radu, onemogućuje rekonstrukciju reljefa koji je zaklonjen vegetacijom stoga se dodatnim metodama vegetacija treba ukloniti iz digitalnog modela reljefa. Iz tog razloga generirani DSM nije korišten u analizi, već je umjesto njega korišten DEM. Procesom „zaglađivanja“ DEM-a iz analize je eliminirana preostala vegetacija te je tako stvoren najvjerniji prikaz reljefa. Usporedbom nadmorske visine „zaglađenog“ DEM-a i kontrolnih točaka utvrđeno je prosječno odstupanje od 34 cm što predstavlja podatak visoke kvalitete za detaljnu analizu. Bez provedenih korekcija pomoću kontrolnih točaka modeli reljefa ne bi pružali zadovoljavajuće rezultate za njezino provođenje.

Izdvajanje ponikava iz generiranog modela provedeno je pomoću dvije metode – mMDTA i MNP. Obadvije metode predstavljaju poluautomatski način izdvajanja ponikava s bitnom razlikom u vremenskom trajanju svake metode. Modificirana MDTA (mMDTA) metoda provedena je prema istraživanju Moreno-Gómez i dr. (2019), dok je metoda nagiba padina (MNP) osmišljena prilikom izrade ovog rada na temelju dostupnih podataka. MNP metodom izdvojeno je 18,4 % više ponikava u odnosu na mMDTA metodu, uz značajno dulji vremenski period izdvajanja. S obzirom da su Moreno-Gómez i dr. (2019) u svom radu koristili DEM prostorne rezolucije 5m za znatno veće područje istraživanja, njihov ulazni podatak već je bio ispravljen i bez grešaka vegetacije ili objekata. U ovom radu bilo je potrebno modificirati njihovu metodologiju dodajući nekoliko koraka za eliminaciju vegetacije i „zaglađivanje“ ulaznog DEM-a.

Detaljnom usporedbom dobivenih rezultata i stvarnog stanja na istraživanom području uočeno je kako mMDTA metoda izdvajanja pruža mnogo precizniji način definiranja oboda u odnosu na MNP metodu koja zahvaća bitno širi prostor od realnog entiteta ponikve.

Prosječno odstupanje oboda između HOK-a i mMDTA metode iznosi 7,3 m, dok između mMDTA metode i TK 25 ono iznosi 13,5 m. Iz tog razloga mMDTA metoda izostavlja manje ponikve prilikom definiranja oboda, dok MNP metoda pruža vidno nerealne morfometrijske pokazatelje. Jednostavnije, MNP metoda se može koristiti za detekciju i najmanjih depresija na određenom prostoru, dok je mMDTA metoda pogodnija za preciznije određivanje oboda i detaljnu morfometrijsku analizu.

Suprotno navedenom, Šegina i dr. (2018) navode kako bilo koja automatska ili poluautomatska metoda izdvajanja oboda ponikava na temelju DEM-a ne pruža zadovoljavajuće rezultate. Napominju kako obod generiran na temelju slojnica ne predstavlja stvarni obod ponikve zbog eventualne visinske razlike u stvarnom obodu koja ne može biti obuhvaćena automatskim ili poluautomatskim metodama.

Kao najprecizniju metodu izdvajanja oboda predlažu kombinirano upotrebljavanje HOK-a i zračnih ortofoto snimaka prostorne rezolucije 0,5 m koji se koriste za ručno izdvajanje na temelju varijabilnosti vegetacije i reljefnih oblika (Šegina i dr., 2018).

U ovoj analizi mMDTA metodom izdvojeno je 42,5% više ponikava nego što ih je prisutno na HOK-u, odnosno 47,5% više ponikava nego što ih je prisutno na TK25. MNP metodom izdvojeno je 53,1% više ponikava nego što ih je prikazano na HOK-u, tj. 57, 1% više ponikava nego na TK25. Uzme li se u obzir činjenica da oba načina predstavljaju poluautomatsku metodu izdvajanja ponikava temeljenu na DEM-u generiranom pomoću bespilotne letjelice, navedeni rezultati predstavljaju izuzetan napredak u odnosu na podatke dostupne na HOK-u i TK25. Zbog različitih metoda izdvajanja oboda, a samim time i različitih izlaznih rezultata analize, morfometrijski pokazatelji obadviju metoda rezultiraju relativno značajnim odstupanjima. Važno je istaknuti kako je iz generiranog DEM-a stvorenog pomoću bespilotne letjelice uspješno provedena detaljna morfometrijska analiza za sve izdvojene ponikve, uključujući i one koje nisu prisutne na HOK-u ili TK25.

6. ZAKLJUČAK

U ovom radu su pomoću bespilotne letjelice prikupljeni podaci o ponikvama na jugozapadnom dijelu otoka Cresa te su na temelju njih generirani modeli prostora na kojima je provedena detaljna morfometrijska analiza i usporedba s dostupnim izvorima podataka: TK25 i HOK. Poluautomatsko izdvajanje ponikava iz generiranog modela omogućilo je detekciju preko 50% više ponikava od dostupnih kartografskih izvora na istraživanom području. Na temelju dobivenih rezultata može se zaključiti da je upotreba bespilotne letjelice dala dobre rezultate za sva navedena istraživanja. Nadalje, korištenje bespilotne letjelice u svrhu analize ponikava predstavlja potencijal za daljnji razvoj metodologije. Stoga možemo potvrditi i prvu i drugu hipotezu istraživanja. Korištenje bespilotne letjelice omogućilo je brzi postupak detekcije ponikava, čime se izbjegava dugotrajni tradicionalni način njihove analize. Ipak, prisutnost vegetacije onemogućuje direktnu analizu stoga je potrebno provesti korake eliminacije iste kako bi rezultati bili vjerodostojni, čime je treća hipoteza djelomično potvrđena. Druge tehnologije prikupljanja podataka omogućuju kvalitetniju eliminaciju vegetacije, ali zahtijevaju znatno više resursa za provedbu analiza. Modeli manje prostorne razlučivosti ne prikazuju vegetaciju detaljno kao i modeli generirani prilikom ovog istraživanja, ali izostavljaju pojedine specifičnosti analiziranog područja .

7. LITERATURA

1. Agisoft Metashape, 2023: User Manual. Professional Edition, Version 1.5.
2. ArcGIS, 2022: ArcGIS Documentation, https://doc.arcgis.com/en/data-appliance/6.4/reference/common-attributes.htm, 14.12.2022.
3. Bahtijarević, A., Faivre, S., 2016: Quantitative comparative geomorpholgical analysis of fluvial and karst relief of Florida. Environ Earth Sci 75, 428. https://doi.org/10.1007/s12665-016-5397-8
4. Ballut, C., Faivre, S., 2012: New data on the dolines of Velebit mountain: An evaluation of their sedimentary archive potential in the reconstruction of landscape evolution, Acta Carsologica 41/1, 59-74. https ://doi.org/10.3986/ac.v41i1 .48
5. Basso, A., Bruno, E., Parise, M., Pepe, M., 2013: Morphometric analysis of sinkholes in a karst coastal area of southern Apulia (Italy), Environmental Earth Sciences, DOI: DOI 10.1007/s12665-013-2297-z.
6. Bauer, C., 2015: Analysis of dolines using multiple methods applied to airborne laser scanning data, Geomorphology, 250, 78–88.
7. Bhardwaj, A., Sam, L., Akanksha, Martín-Torres, F. J., & Kumar, R., 2016: UAVs as remote sensing platform in glaciology: Present applications and future prospects. Remote Sensing of Environment, 175, 196–204. doi:10.1016/j.rse.2015.12.029
8. Bočić, N., 2009: Geomorfološke značajke prostora Slunjske zaravni, Doktorska disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek, Zagreb, pp. 270.
9. Bognar, A., 1992: Inženjersko geomorfološko kartiranje, Acta Geographica Croatica, 27(1), 173-185.
10. Brkljača, A., 2022: 'Geomorfološka obilježja ponikava sjevernog dijela otoka Cresa', Završni rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, citirano: 08.02.2023., https://urn.nsk.hr/urn:nbn:hr:217:304329
11. Buzjak, N., 2006: Geomorfološke i speleomorfološke značajke Žumberačke gore i geoekološko vrednovanje endokrškog reljefa, Doktorska disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek, Zagreb, pp. 200.
12. Crkvenčić, I., 1992: 'Neki pokazatelji društveno-geografskih promjena na otoku Cresu u zadnjih dvadesetak godina', Acta Geographica Croatica, 27.(1.), str. 35-46.
13. CROPOS, 2022: Državna geodetska uprava, CROPOS: „O sustavu“, https://www.cropos.hr/o-sustavu, 12.12.2022.

14. Cubric-Curik, V., Atlija, M., Šprem, N., Curik, I., 2011: Mitochondrial DNA Diversity in Wild Boars from the Istria and Cres Island, Agriculturae Conspectus Scientificus, 76 (4), 321-324.
15. Cvijić, J., 1893: Das Karstphanomen. Versuch einer morphologischen Monographie. Geographischen Abhandlung, Wien V, 3, 218-329.
16. Cvijić, J., 1895: Karst, geografska monografija, Beograd,1-135.
17. Čeru, T., Šegina, E., Gosar, A., 2017: Geomorphological Dating of Pleistocene Conglomerates in Central Slovenia Based on Spatial Analyses of Dolines Using LiDAR and Ground Penetrating Radar. Remote Sens., 9, 1213. https://doi.org/10.3390/rs9121213
18. Demek, J., 1972: Manual of Detailed Geomorphological Mapping, IGU-Comission on Geomorphological survey and mapping, Chechoslovak Academy of Science, Prague.
19. DJI, 2021: Phantom 4 Pro User Manual, https://dl.djicdn.com/downloads/phantom_4_pro/20211129/UM/Phantom_4_Pro_Pro_Plus_Series_User_Manual_EN.pdf
20. Državna geodetska uprava (DGU), 2022: Novi projekcijski koordinatni referentni sustav Republike Hrvatske (HTRS96/TM), https://dgu.gov.hr/novi-projekcijski-koordinatni-referentni-sustav-republike-hrvatske-htrs96-tm/5245
21. Duplančić, L. T., Ujević, T., Čala, M., 2004: 'Duljine obalne crte i površine otoka na hrvatskom dijelu Jadranskog mora određene sa topografskih karata mjerila', Geoadria, 9(1), str. 5-32.
22. Esri, 2022: Esri Products, https://www.esri.com/en-us/arcgis/products/index, 14.12.2022.
23. Faivre, S., 1992: Analiza gustoće ponikava na Sjevernom Velebitu i Senjskom bilu, Senjski zbornik, 19(1), str. 13-24.
24. Faivre, S., Mićunović, M., 2017: Rekostrukcija recentnih morfoloških promjena žala uz pomoć metode ponovljene fotografije – primjer žala Zogon na otoku Hvaru (Srednji Jadran), Geoadria 22(2), 165-192.
25. Faivre, S., Pahernik, M., 2007: Structural influences on the spatial distribution of dolines, Island of Brač, Croatia, Zeitschrift fur Geomorphologie, 51 (4), 487-503.
26. Faivre, S., Reiffsteck, P., 1999: Spatial distribution of dolines as an indicator of recent deformations on the Velebit mountain range (Croatia), Géomorphologie: relief, processus, environnement, 2, 129-142.

27. Faivre, S., Reiffsteck, P., 2002: From Doline Distribution to Tectonics Movements Example of the Velebit Mountain Range, Croatia, Acta Carsologica. Ljubljana, Slovenija, 31(3). doi: 10.3986/ac.v31i3.384.
28. Fonstad, M. A., Dietrich, J. T., Courville, B. C., Jensen, J. L., Carbonneau, P. E., 2013: Topographic structure from motion: a new development in photogrammetric measurement, *Earth Surface Processes and Landforms*, 38(4), 421–430, doi:10.1002/esp.3366
29. Ford, D.C., Williams, P., 2007: Karst Hydrogeology and Geomorphology, John Wiley, Chichester, 562, https://doi.org/10.1002/9781118684986
30. Geissler, P., Grabert, M., 2019: 'Novi herpetofaunistički podaci s otoka Cresa, Hrvatska', Natura Croatica, 28(1), str. 161-165.
31. Gindraux, S., Boesch, R., Farinotti, D., 2017: Accuracy Assessment of Digital Surface Models from Unmanned Aerial Vehicles' Imagery on Glaciers, Remote Sensing, 9(2):186. https://doi.org/10.3390/rs9020186
32. Giordan, D., Manconi, A., Remondino, F., Nex, F., 2017: Use of unmanned aerial vehicles in monitoring application and management of natural hazards. Geomatics, Natural Hazards and Risk, 8(1), 1–4. doi:10.1080/19475705.2017.1315619
33. Glavačević, K., 2021: 'Procjena točnosti izravnog georeferenciranja bespilotne letjelice Matrice 210 RTK na primjeru jaruge Santiš (otok Pag)', Master's thesis, University of Zadar, accessed 12 December 2022, https://urn.nsk.hr/urn:nbn:hr:162:870950
34. Gómez, C., Purdie, H., 2016: UAV- based Photogrammetry and Geocomputing for Hazards and Disaster Risk Monitoring – A Review. Geoenviron Disasters 3, 23
35. Hackney, C., Clayton, A. I., 2015: Unmanned Aerial Vehicles (UAVs) and their application in geomorphic mappin,. Geomorphol. Technol. 7, 1–12.
36. Hrvatska enciklopedija (mrežno izdanje), 2021: Stereofotogrametrija, Leksikografski zavod Miroslav Krleža, http://www.enciklopedija.hr/Natuknica.aspx?ID=58027 https://doi.org/10.1186/s40677-016-0060-y
37. Klein, V., 1976: Gustoća ponikva Ličko-goranske regije, Geografski glasnik, 38 (1), 357-377.
38. Kožar, L.,2020: 'Morfometrijska analiza krških reljefnih oblika temeljena na LiDAR-skim podacima - primjer NP Plitvička jezera', Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, citirano: 08.02.2023., https://urn.nsk.hr/urn:nbn:hr:217:263210

39. Lajić, I., 1993: 'Utjecaj migracija na novije ukupno kretanje pučanstva cresko-lošinjskog otočnog područja', Migracijske i etničke teme, 9(2), str. 165-177.
40. Lončar, N, Grcić, I., 2022: GIS-based analysis of doline density on Miljevci karst plateau (Croatia) // Acta carsologica, 51 (2022), 1; 9-21 doi:10.3986/ac.v51i1.10465
41. Marjanović, M., 2010: 'CROPOS hrvatski pozicijski sustav', Ekscentar, (12), str. 28-34. Preuzeto s: https://hrcak.srce.hr/50661 (Datum pristupa: 13.12.2022.)
42. Marković, J., Bočić, N., i Pahernik, M., 2016: Prostorni raspored i gustoća ponikava jugoistočnog Velebita, Geoadria, 21(1), str. 1-28.
43. Mićunović, M., 2019: 'Geomorfološka obilježja žala otoka Hvara', Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, citirano: 26.01.2023., https://urn.nsk.hr/urn:nbn:hr:217:679489
44. Mićunović, M., i Faivre, S., 2020: Morfološke promjene žala Zogon (otok Hvar) od sredine 20. stoljeća do danas, Geografski horizont, 66.(1.), str. 92-93., https://hrcak.srce.hr/252549
45. Mihljević, D., 1995: Geomorfološke značajke gorskog hrpta Učke, gorske skupine Ćićarije i Istarskog pobrđa, Doktorska disertacija, Sveučilište u Zagreb Prirodoslovno-matematički fakultet, Geografski odsjek, Zagreb, pp. 377.
46. 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).
47. Moreno-Gómez, M., Liedl, R., Stefan, C., 2019: A New GIS-Based Model for Karst Dolines Mapping Using LiDAR; Application of a Multidepth Threshold Approach in the Yucatan Karst, Mexico. Remote Sens., 11, 1147. https://doi.org/10.3390/rs11101147
48. O'Connor, J., Smith, M. J., James, M. R., 2017: Cameras and settings for aerial surveys in the geosciences: Optimising image data. Progress in Physical Geography, 41(3), 325-344.
49. Otoničar, B., Buzjak, N., Mylroie, J., Mylroie, J., 2010: Flank Margin Cave Development in Carbonate Talus Breccia Facies: An Example from Cres Island, Croatia. Acta Carsologica, 39(1).
50. Pahernik, M., 2000: Prostorni raspored i gustoća ponikava SZ dijela Velike Kapele – rezultati računalne analize susjedstva, Geoadria, 5, 105-120.

51. Pandžić, K., Juras, V., Gajić-Čapka, M., Sijerković, M., Zaninović, K., 1993: Climatic conditions on the islands of Cres and Lošinj within the global climate changes, Hrvatski meteorološki časopis, 28 (28), 43-58.
52. Popit, T., Rožič, B., Šmuc, A., Kokalj, Ž., Verbovšek, T., Košir, A., 2014: A LiDAR, GIS and basic spatial statistic application for the study of ravine and palaeo-ravine evolution in the upper Vipava valley, SW Slovenia. Geomorphology, 204, 638-645.
53. Poropat, M. P., 2020: 'Matična knjiga krštenih župe Cres (1571. – 1596.)', Vjesnik Istarskog arhiva, 27((2020)), str. 133-165.
54. Premužić, M. i Šljivarić, M., 2010: T7D korisnička aplikacija, Zbornik radova, 2, 87-100.
55. Ramsey, C., Griffiths, P. A., Stokes, T. R., 2014: Multi-rotor unmanned aerial vehicles (UVAs) and high-resolution compact digital cameras: a promising new method for monitoring changes to surface karst resources, Acta Carsologica, vol. 43, br. 2-3, 269-286.
56. Śledź, S., Ewertowski, M. W., Piekarczyk, J., 2021: Applications of unmanned aerial vehicle (UAV) surveys and Structure from Motion photogrammetry in glacial and periglacial geomorphology, *Geomorphology*, 378, 107620, doi:10.1016/j.geomorph.2021.10762010.1016/j.geomorph.2021.107620
57. Slukan, M., 1992: Geomorfološke značajke Cresa, diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek
58. Stražičić, N., 1975: Cresko-lošinjska otočna skupina, u Otočki ljetopis Cres-Lošinj 2 (ur. Marković, V.), 143-190, Mali Lošinj
59. Stražičić, N., 1997: Cresko - lošinjsko otočje – geografska obilježja, Geografski horizont 43 (2), 63-86
60. Tandarić, N., 2011: Geomorfološka obilježja ponikava na otoku Cresu, Završni rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, citirano: 19.07.2022., https://urn.nsk.hr/urn:nbn:hr:217:950376
61. Tomec, M., 2003: 'Mikrofitobentos vranskog jezera (otok Cres)', Croatian Journal of Fisheries, 61(2), str. 55-73.
62. Trimble, 2021: Trimble DA2 GNSS reciever for the Trimble Catalyst service, https://geospatial.trimble.com/sites/geospatial.trimble.com/files/2022-06/022516-524C_Trimble_DA2_DS_USL_0622_LRsec.pdf, 12.12.2022.

63. Walsh, S. J., Butler, D. R., Malanson, G. P., 1998: An overview of scale, pattern, process relationships in geomorphology: a remote sensing and GIS perspective, Geomorphology, 21(3-4), 183–205, doi:10.1016/s0169-555x(97)00057-3
64. Watts, A.C., Ambrosia, V.G., Hinkley, E.A., 2012: Unmanned aircraft systems in remote sensing and scientific research: classification and considerations of use, *Remote Sens.* 4, 1671–1692., https://doi.org/10.3390/rs4061671
65. Westoby, M. J., Brasington, J., Glasser, N. F.,Hambrey, M. J., Reynolds, J. M., 2012: 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications, *Geomorphology* 179, 300-314, ISSN 0169-555X, https://doi.org/10.1016/j.geomorph.2012.08.021.

8. PRILOZI

Popis slika:

Sl. 1. Geografski položaj otoka Cresa (str. 4)
Sl. 2. Hipsometrijska karta južnog dijela otoka Cresa (str. 6)
Sl. 3. Karta nagiba padina južnog dijela otoka Cresa (str. 8)
Sl. 4. Karta vertikalne raščlanjenosti južnog dijela otoka CresaSl. 5. Karta orijentacije padina južnog dijela otoka Cresa (str. 10)
Sl. 5. Karta orijentacije padina južnog dijela otoka Cresa (str. 12)
Sl. 6. Uže područje istraživanja (str. 13)
Sl. 7. Geološka karta analiziranog područja (str. 14)
Sl. 8. Odabir mikrolokacije istraživanja pomoću Geoportala DGU Sl. 9. Prikupljanje podataka o geografskoj lokaciji kontrolnih točaka (str. 18)
Sl. 9. Prikupljanje podataka o geografskoj lokaciji kontrolnih točaka (str. 19)
Sl. 10. Trimble Catalyst DA2 GNSS prijamnik i njegove tehničke specifikacije (str. 20)
Sl. 11. Princip rada CROPOS sustava (str. 21)
Sl.12. Korisničko sučelje mobilne aplikacije ArcGIS Field Maps (krugovi predstavljaju kontrolne točke) (str. 22)
Sl. 13. Bespilotna letjelica DJI Phantom 4 Pro (str. 23)
Sl. 14. Izvođenje letačke operacije (str. 26)
Sl. 15. Prikaz ArcGIS Online korisničkog sučelja (str. 27)
Sl. 16. Pristup prikupljenim podacima pomoću ArcGIS Online (str. 28)
Sl. 17. Preračunavanje vrijednosti koordinata u WGS84 Auxiliary Sphere koordinatni sustav (str. 29)
Sl. 18. Konverzija podataka pomoću T7D programa (str. 30)
Sl. 19. Konvertirana lista kao produkt T7D programa (str. 30)
Sl. 20. Princip rada SfM tehnologije (str. 31)
Sl. 21. Spajanje fotografija u Agisoft Metashape Professional softveru (str. 33)
Sl. 22. Dodavanje kontrolnih točaka u Agisoft Metashape Professional softveru (str. 34)
Sl. 23. Izgradnja gustog oblaka točaka u Agisoft Metashape Professional softveru (str. 35)
Sl. 24. Izgradnja DEM-a u Agisoft Metashape Professional softveru (str. 36)
Sl. 25. Teksturiranje točaka u Agisoft Metashape Professional softveru (str. 36)
Sl. 26. Izgradnja DEM-a u Agisoft Metashape Professional softveru (str. 37)

Sl. 27. Izgradnja DOF-a u Agisoft Metashape Professional softveru (str. 38)
Sl. 28. Digitalizacija ponikava pomoću HOK-a i ArcGIS Pro softvera (str. 39)
Sl. 29. Prvi korak „zaglađivanja“ DEM-a pomoću ArcGIS Pro softvera (str. 41)
Sl. 30. Drugi korak „zaglađivanja“ DEM-a pomoću ArcGIS Pro softvera (str. 42)
Sl. 31. Popunjavanje depresija pomoću funkcije Fill unutar ArcGIS Pro softvera (str. 42)
Sl. 32. Raster s depresijama nakon oduzimanja pomoću funkcije Raster Calculator unutar ArcGIS Pro softvera (str. 43)
Sl. 33. Klasifikacija depresija pomoću funkcije *Slice* unutar ArcGIS Pro softvera (str. 44)
Sl. 34. Ponikve izdvojene nadopunjenom MDTA metodologijom (str. 45)
Sl. 35. Nagibi padina generirani unutar ArcGIS Pro softvera (str. 46)
Sl. 36. Klasifikacija nagiba padina pomoću funkcije *Slice* unutar ArcGIS Pro softvera (str. 46)
Sl. 37. Izdavanje ponikava pomoću metode nagiba padina unutar ArcGIS Pro softvera (str. 47)
Sl. 38. Morfometrijska analiza unutar ArcGIS Pro softvera (str. 48)
Sl. 39. Određivanje tipa ponikava unutar ArcGIS Pro softvera (str. 49)
Sl. 40. Oduzimanje vrijednosti pomoću funkcije *Raster* (str. 50)
Sl. 41. Pretvaranje oboda u točkaste elemente unutar ArcGIS Pro softvera (str. 52)
Sl. 42. Atributivna tablica sa generiranim udaljenostima između analiziranih entiteta (str. 52)
Sl. 43. DSM (a), DEM (b) i DOF (c) (str. 53)
Sl. 44. Iskrivljeni (a) i ispravni (b) prikaz vegetacije na DOF-u (str. 54)
Sl. 45. Hipsometrijska karta i karta nagiba padina analiziranog područja (str. 55)
Sl. 46. Karta vertikalne raščlanjenosti i orijentacije padina analiziranog područja (str. 57)
Sl. 47. Ponikve digitalizirane sa HOK-a i TK25 (str. 58)
Sl. 48. DEM prije (a) i poslije (b) procesa „zaglađivanja“ (str. 60)
Sl. 49. Profili ponikava prije i nakon procesa „zaglađivanja“ (str. 61)
Sl. 50. Prikaz ponikava izdvojenih modificiranom MDTA metodom i metodom nagiba padina (str. 63)
Sl. 51. Usporedba i prostorni raspored dubina ponikava (str. 65)
Sl. 52. 3D vizualizacija volumena iste ponikve izdvojene različitom metodologijom (str. 66)
Sl. 53. Prikaz korelacije parametara dubine i volumena ponikava izdvojenih modificiranom MDTA metodom (str. 67)
Sl. 54. Prikaz korelacije parametara dubine i volumena ponikava izdvojenih metodom nagiba padina (str. 67)

Sl. 55. Prikaz odstupanja izdvojene ponikve od postojećih podataka (str. 69)
Sl. 56. 3D prikaz odstupanja izdvojene ponikve u odnosu na kartografske izvore (str. 70)

Popis tablica:

Tab. 1. Površinski udio hipsometrijskih razreda na južnom dijelu otoka Cresa (str. 5)
Tab. 2. Površinski udio pojedinih razreda nagiba na južnom dijelu otoka Cresa (str. 7)
Tab. 3. Površinski udio pojedinih razreda vertikalne raščlanjenosti reljefa na južnom dijelu otoka Cresa (str. 9)
Tab. 4. Površinski udio pojedinih razreda orijentacije padina južnog dijela otoka Cresa (str. 11)
Tab. 5. Tehničke specifikacije bespilotne letjelice DJI Phantom 4 Pro (str. 24)
Tab. 6. Površinski udio hipsometrijskih razreda unutar analiziranog područja (str. 56)
Tab. 7. Površinski udio pojedinih razreda nagiba unutar analiziranog područja (str. 56)
Tab. 8. Površinski udio pojedinih razreda vertikalne raščlanjenosti reljefa unutar analiziranog područja (str. 57)
Tab. 9. Površinski udio pojedinih razreda orijentacije padina unutar analiziranog područja(str. 58)
Tab. 10. Morfometrijski pokazatelji digitaliziranih ponikava (str. 59)
Tab. 11. Usporedba nadmorske visine (m) kontrolnih točaka, DEM-a i „zaglađenog“ DEM-a(str. 62)
Tab. 12. Morfometrijski pokazatelji izdvojenih ponikava (str. 63)
Tab. 13. Tip profila izdvojenih ponikava (str. 64)
Tab. 14. Prosječna odstupanja (m) između izdvojenih ponikava i postojećih podataka (str. 68)