Višerezolucijsko modeliranje erozije tla korištenjem geoprostornih tehnologija

Domazetović, Fran

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:349211

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Sveučilište u Zadru
Universitas Studiorum
Jadertina | 1396 | 2002 |

Repository / Repozitorij:

University of Zadar Institutional Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

JADRAN - POVEZNICA MEĐU KONTINENTIMA

Fran Domazetović

VIŠEREZOLUCIJSKO MODELIRANJE EROZIJE TLA KORIŠTENJEM GEOPROSTORNIH TEHNOLOGIJA

Doktorski rad

Zadar, 2021.

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

JADRAN - POVEZNICA MEĐU KONTINENTIMA

Fran Domazetović

VIŠEREZOLUCIJSKO MODELIRANJE EROZIJE TLA KORIŠTENJEM GEOPROSTORNIH TEHNOLOGIJA

Doktorski rad

Mentor

Izv. prof. dr. sc. Ante Šiljeg

Komentorica

Izv. prof. dr. sc. Nina Lončar

Komentor

Izv. prof. dr. sc. Nedim Tuno

Zadar, 2021.

SVEUČILIŠTE U ZADRU

TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Fran Domazetović

Naziv studijskog programa: Sveučilišni studij Jadran – poveznica među kontinentima

Mentor Izv. prof. dr. sc. Ante Šiljeg

Komentorica 1: Izv. prof. dr. sc. Nina Lončar

Komentor 2: Izv. prof. dr. sc. Nedim Tuno

Datum obrane: 12.07.2021.

Znanstveno područje i polje u kojem je postignut doktorat znanosti: interdisciplinarne znanosti, geografija

II. Doktorski rad

Naslov: Višerezolucijsko modeliranje erozije tla korištenjem geoprostornih tehnologija

UDK oznaka: 004.414.2:623.125(497.5)

Broj stranica: 329

Broj slika/grafičkih prikaza/tablica: 171

Broj bilježaka: 57

Broj korištenih bibliografskih jedinica i izvora: 311

Broj priloga: 0

Jezik rada: hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu doktorskog rada:

1. Prof. dr. sc. Uroš Stepešnik, predsjednik
2. Izv. prof. dr. sc. Sanja Lozić, članica
3. Izv. prof. dr. sc. Mateo Gašparović, član

Stručno povjerenstvo za obranu doktorskog rada:

1. Prof. dr. sc. Uroš Stepešnik, predsjednik
2. Izv. prof. dr. sc. Sanja Lozić, članica
3. Izv. prof. dr. sc. Mateo Gašparović, član

UNIVERSITY OF ZADAR

BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Fran Domazetović

Name of the study programme: Postgraduate doctoral study Adriatic - a link between the continents

Mentor: Izv. prof. dr. sc. Ante Šiljeg

Co-mentor 1: Izv. prof. dr. sc. Nina Lončar

Co-mentor 2: Izv. prof. dr. sc. Nedim Tuno

Date of the defence: 12.07.2021.

Scientific area and field in which the PhD is obtained: interdisciplinary science, geography

II. Doctoral dissertation

Title: Multiresolution modeling of soil erosion through the use of geospatial technologies

UDC mark: 004.414.2:623.125(497.5)

Number of pages: 329

Number of pictures/graphical representations/tables: 171

Number of notes: 57

Number of used bibliographic units and sources: 311

Number of appendices: 0

Language of the doctoral dissertation: Croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Prof. dr. sc. Uroš Stepešnik, chair
2. Izv. prof. dr. sc. Sanja Lozić, member
3. Izv. prof. dr. sc. Mateo Gašparović, member

Expert committee for the defence of the doctoral dissertation:

1. Prof. dr. sc. Uroš Stepešnik, chair
2. Izv. prof. dr. sc. Sanja Lozić, member

Izv. prof. dr. sc. Mateo Gašparović, member

Izjava o akademskoj čestitosti

Ja, **Fran Domazetović,** ovime izjavljujem da je moj **doktorski** rad pod naslovom **Višerezolucijsko modeliranje erozije tla korištenjem geoprostornih tehnologija** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 15. ožujka 2021.

ZAHVALA

Zahvaljujem se dragom prijatelju i mentoru izv. prof. dr. sc. Anti Šiljegu na neiscrpnoj pomoći i podršci te trudu, usmjeravanju i brojnim savjetima pruženim tijekom pisanja moje doktorske disertacije. Zahvaljujem se mojoj prijateljici i komentorici izv. prof. dr. sc. Nini Lončar, te komentoru izv. prof. dr. sc. Nedimu Tuni na svoj pomoći i konstruktivnim savjetima pruženim tijekom pisanja disertacije.

Veliko hvala prijateljima i kolegama dr. sc. Ivanu Mariću, Lovri Panđi i Rini Milošević, posebice na značajnoj pomoći pruženoj oko izvođenja zahtjevnih terenskih istraživanja. Zahvaljujem se dr. sc. Nevenu Cukrovu s Instituta Ruđer Bošković na velikoj pomoći pruženoj prilikom izrade geološke karte i uzorkovanja naslaga tla. Veliko hvala Marinu Lovriću i Tomislavu Bulatu s Instituta Ruđer Bošković na pomoći pruženoj prilikom obrade i analiziranja prikupljenih uzoraka tla.

Hvala tvrtki Prehnit d.o.o., te posebice Vlatku Rolandu, Draganu Tasiću i Lazaru Popoviću na ustupljenoj pomoći i brojnim savjetima vezanim za obradu prikupljenih laserskih podataka. Hvala ProHeritage (UIP-2017-05-2152) projektu, te Vedrani Glavaš i Nedi Kulenović na ustupljenim zračnim fotografijama otoka Paga. Ovaj je rad izrađen u sklopu projekta Hrvatska zaklade za znanost (UIP-2017-05-2694). Veliko hvala Hrvatskoj zakladi za znanost na financiranju cijelog projekta, a posebice na sredstvima osiguranim za nabavu potrebnih geoprostornih tehnologija i izvođenje terenskih istraživanja.

Hvala mojim dragim prijateljima na pružanju potpore prilikom pisanja ove disertacije.

Na kraju najveće hvala mojoj obitelji, majci Barbari, ocu Hrvoju, bratu Dinku i sestri Ladi, te zaručnici Kristini, čija potpora, razumijevanje i strpljenje su mi neizmjerno pomogli prilikom izrade ove disertacije.

SADRŽAJ

ZAHVALA **6**
1. UVOD **10**
1.1. Ciljevi i svrha istraživanja **13**
1.2. Temeljne hipoteze istraživanja **14**
1.3. Pregled prethodnih istraživanja **15**
1.4. Obuhvat i prirodno-geografske značajke istraživanog područja **20**
1.4.1. Makro razina istraživanja – otoka Pag 21
1.4.2. Mezo razina istraživanja – poluotok Santiš 25
1.4.3. Mikro razina istraživanja – čelo jaruge Santiš 28
2. TEORIJSKA OSNOVA **30**
2.1. Erozija tla – pojmovno određenje **30**
2.1.1. Negativne posljedice erozije tla 34
2.1.2. Klasifikacija potprocesa erozije tla uzrokovane djelovanjem vode 36
2.1.3. Predisponirajući čimbenici erozije tla 41
2.1.4. Specifičnost procesa erozije tla u krškim područjima 44
2.2. Teorijska osnova višerezolucijskog proučavanja erozije tla **47**
2.3. Primjena suvremenih geoprostornih tehnologija u proučavanju erozije tla . **52**
2.4. Razine detaljnosti proučavanja erozije tla **58**
2.5. Kvantitativne mjere za praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla **62**
3. METODOLOGIJA ISTRAŽIVANJA **65**
3.1. Pregled metodologije makro razine istraživanja **65**
3.1.1. Predobrada WV multispektralnih satelitskih snimaka 71
3.1.2. Izrada digitalnog modela površina otoka Paga iz WV stereo snimaka 76
3.1.3. Izrada digitalnog modela reljefa otoka Paga 87
3.1.4. Izrada višekriterijskog GIS modela podložnosti eroziji tla 92
3.2. Pregled metodologije mezo razine istraživanja **113**

3.2.1. Izrada modela iz aerofotogrametrijskih podataka Državne geodetske uprave 114

3.2.2. Aerofotogrametrijsko snimanje užeg prostora jaruge Santiš 122

3.2.3. Detekcija i kvantifikacija prostorno-vremenskih promjena (PVP) uzrokovanih erozijom tla na temelju izrađenih intervalnih digitalnih modela površina 133

3.2.4. Prikupljanje i obrada meteoroloških podataka 136

3.2.5. Izrada litološke karte užeg dijela mezo razine 141

3.3. Pregled metodologije mikro razine istraživanja **144**

3.3.1. LiDAR lasersko skeniranje prostora čela jaruge Santiš 144

3.3.2. Procjena točnosti izrađenog inicijalnog aerofotogrametrijskog modela .. 161

3.3.3. Izdvajanje užeg prostornog obuhvata mikro razine istraživanja 164

3.3.4. Razvoj kvantitativnog alata za praćenje pomaka čela jaruge 166

3.3.5. Detekcija i kvantifikacija PVP uzrokovanih erozijom tla unutar užeg prostornog obuhvata mikro razine istraživanja 170

4. REZULTATI I RASPRAVA **172**

4.1. Rezultati makro razine istraživanja **172**

4.1.1. Odabrani kriteriji podložnosti eroziji tla 172

4.1.2. Rezultat validacije izrađenih GIC-MCDA modela 188

4.1.3. Utvrđena podložnost prostora otoka Paga eroziji tla 196

4.2. Rezultati mezo razine istraživanja **201**

4.2.1. Višegodišnje prostorno-vremenske promjene uzrokovane erozijom tla na prostoru poluotoka Santiš 201

4.2.2. Jednogodišnje prostorno-vremenske promjene uzrokovane erozijom tla detektirane na prostoru jaruge Santiš 216

4.2.3. Odnos između intenziteta erozije tla i prikupljenih meteoroloških indikatora 248

4.3. Rezultati mikro razine istraživanja **252**

4.3.1. Uspješnost razvijene metodologije za optimizaciju intervalnih TLS izmjera 252

4.3.2. Procijenjena točnost izrađenog aerofotogrametrijskog (UAV) modela 260

4.3.3. Detektirane jednogodišnje PVP unutar užeg prostora mikro razine 268

5. POTVRDA TEMELJNIH HIPOTEZA ISTRAŽIVANJA **282**

6. ZAKLJUČAK **293**

SAŽETAK **297**

SUMMARY **299**

Literatura i izvori **301**

Pregled korištenih kratica **329**

Životopis **330**

Popis radova **331**

Poglavlja u knjigama i radovi u zbornicima radova **331**

1. UVOD

Erozija tla predstavlja proces postupne degradacije i denudacije površinskih slojeva tla, koji na globalnoj razini uzrokuje dugoročno smanjivanje poljoprivredne produktivnosti i značajne financijske gubitke[1] (Morgan, 2009; Erkossa i dr., 2015; Montanarella, 2015; Panagos i dr., 2015b; Borelli i dr., 2017.). Prema konvenciji Ujedinjenih naroda za borbu protiv dezertifikacije (*United Nations Convention to Combat Desertification* - UNCCD) erozija tla uzrokovana vodom i vjetrom predstavlja primarni uzrok degradacije tla na globalnoj razini (Panagos i Borelli, 2017). Unutar Europske Unije erozija tla je prepoznata kao primarna ugroza za postojeće naslage tla, čije djelovanje negativno utječe na stabilnost ekosustava, poljoprivrednu proizvodnju, opskrbu pitkom vodom i povećanje globalnih emisija ugljika (Boardman i Poesen, 2007; Panagos i dr., 2015a; Panagos i dr., 2015b). Iako erozija tla predstavlja prirodan proces, rapidne klimatske promjene (npr. dezertifikacija, ekstremni oborinski događaji, toplinski valovi, itd.) i različiti izraženi antropogeni pritisci (npr. deforestacija, prekomjerna ispaša, neprimjerene poljoprivredne prakse i obrada tla, itd.) u zadnjim desetljećima utječu na značajno intenziviranje i širenje prostornog obuhvata ovog procesa (Pimentel i Burgess, 2013; Borelli i dr., 2017.). Mnogobrojni povijesni izvori iz različitih dijelova svijeta svjedoče da je erozija tla prisutna tijekom gotovo cijelog holocena, ali i da su klimatske promjene i antropogeni učinci postepeno postali glavni propagatori ovog procesa (Dotterweich, 2013.).

Generalno gledano Hrvatska je prema vrijednostima prosječne stope gubitka tla[2] među srednje ugroženim zemljama Europske Unije (Panagos i dr., 2015a). Unatoč tome, pojedini dijelovi Hrvatske su zbog različitih mikrolokacijskih značajki znatno podložniji i ugroženiji od procesa erozije tla, s vrlo visokim vrijednostima prosječne stope gubitka tla (Sl. 1.). Posebice visoke vrijednosti prosječne stope gubitka tla prisutne su na prostoru uz Velebitski kanal, gdje ugrožena područja obuhvaćaju dijelove otoka Krka, Raba i Paga, te niže dijelove Velebitske primorske padine. Mjestimice ovi prostori bilježe vrijednosti prosječne stope gubitka tla i iznad 50 $\mathrm{t\,ha^{-1}\,y^{-1}}$, dok većina prostora bilježi vrijednosti iznad 10 $\mathrm{t\,ha^{-1}\,y^{-1}}$ (Panagos i dr., 2015a). Takve stope gubitka tla znatno nadilaze prosječne hrvatske vrijednosti, te su sličnije pojedinim aridnim dijelovima Mediterana; npr. Grčka (Kouli i dr., 2009), Španjolska (de Vente

[1] Procijenjeni globalni financijski gubitci uzrokovani erozijom tla iznose i do 400 milijardi $ godišnje (FAO & ITPS, 2015; Borelli i dr., 2017), dok procjene za prostor Europske Unije iznose do 20 milijardi $ godišnje (Panagos i dr., 2015c).

[2] Prosječna stopa gubitka tla u Hrvatskoj iznosi 3.1 $t\ ha^{-1}\ y^{-1}$ (Panagos i dr., 2015a)

i dr., 2008), Italija (Capolongo i dr., 2008), Maroko (Gourfi i Daoudi, 2019; Bou-imajjane i dr., 2020), itd.) i svijeta (npr. Iran (Fathizad i dr., 2014; Zakerinejad i Maerker, 2015), Kina (Pan i Wen, 2014; Tang i dr., 2015; Duan i dr., 2020), Indija (Thomas i dr., 2018), subsaharska Afrika (Tamene i Le, 2015) itd., poznatim po izraženoj podložnosti intenzivnoj eroziji tla. Upravo zbog toga, problem erozije tla u Hrvatskoj ne smije biti zanemaren, već da je znanstveno proučavanje nužno za sustavno suzbijanje negativnih posljedica ovog procesa.

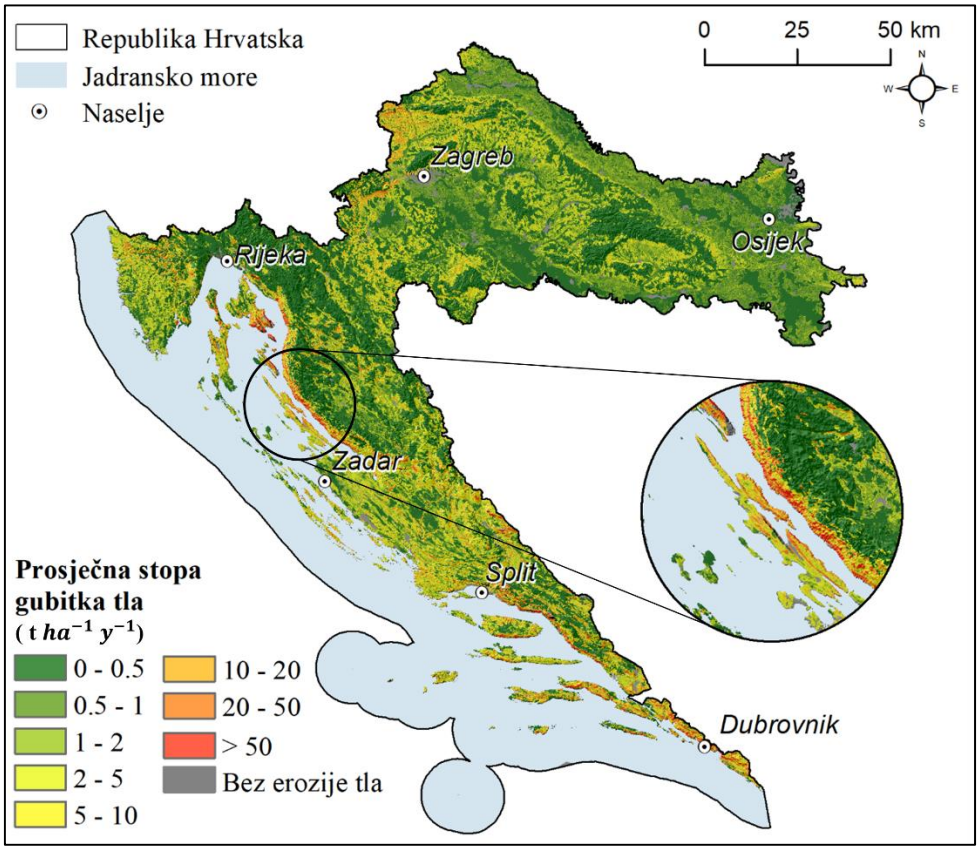

Slika 1. Prosječna godišnja stopa gubitka tla u Hrvatskoj prema RUSLE metodi (*preuzeto iz* Panagos i dr., 2015a; ESDAC, 2020)

Unatoč očitoj potrebi za podrobnijim proučavanjem prostorne rasprostranjenosti i značajki procesa erozije tla, znanstveno-istraživački rad vezan za proučavanje erozije tla se u Hrvatskoj tek aktualizira unazad nekoliko posljednjih godina (Lončar, 2009; Faivre i dr., 2011; Domazetović i dr., 2019a; Đomlija i dr., 2019; Šiljeg i dr., 2021). Velika prostornu rasprostranjenost i raznolikost erozijskih oblika, prisutnost specifičnih klimatskih i reljefnih predisponirajućih čimbenika te izrazito slabo razvijen vegetacijski pokrov čine otok Pag idealnim prostorom za sustavno proučavanje pojavnosti, intenziteta i negativnih učinaka erozije tla. Pri tome ranije započeta istraživanja na prostoru otoka Paga (Domazetović i dr., 2018; 2019a; Šiljeg i dr., 2021) predstavljaju začetak sustavnijih istraživanja, baziranih na proučavanju različitih aspekata procesa erozije tla, od modeliranja podložnosti eroziji tla

(Domazetović i dr., 2019a), sve do praćenja prostorno-vremenskih promjena uzrokovanih erozijom tla (Domazetović i dr., 2020; Šiljeg i dr., 2021.).

Erozija tla predstavlja kompleksan proces koji obuhvaća čitav niz potprocesa različitog prostornog obuhvata i intenziteta (Morgan, 2009), pri čemu prostorni obuhvat i intenzitet različitih potprocesa erozije tla variraju od mikro razine i centimetarskih morfoloških formi (npr. kišne brazde), sve do makro razine i kilometarskih morfoloških formi (npr. jaruge). Zbog toga se u slučaju većine ranije provedenih znanstvenih istraživanja vezanih za eroziju tla, cilj istraživanja najčešće veže za proučavanje samo jednog segmenta procesa erozije tla (npr. modeliranje podložnosti eroziji tla). Osnovni cilj ove doktorske disertacije je razvoj višerezolucijskog metodološkog pristupa za sustavno proučavanje procesa erozije tla, zasnovanog na upotrebi više istraživačkih razina, različitog prostornog obuhvata i rezolucije (prostorna, ekonomska, spektralna i vremenska) te različitih ciljeva istraživanja. Osnova ovakvog istraživačkog pristupa su geoprostorne tehnologije, odnosno skup tehnologija koji omogućava modeliranje kompleksnih procesa i oblika različite razine detaljnosti ovisno o svrsi istraživanja (Šiljeg, 2013.). U sklopu višerezolucijskog modeliranja primijenjene su različite geoprostorne tehnologije, postižući pritom maksimalnu moguću razinu detaljnosti istraživanja unutar svake pojedine istraživačke razine.

1.1. Ciljevi i svrha istraživanja

Osnovni cilj ove doktorske disertacije je razvoj metodološkog pristupa za sustavno proučavanje procesa erozije tla kroz primjenu višerezolucijskog modeliranja, zasnovanog na korištenju različitih geoprostornih tehnologija za izradu modela različite prostorne, spektralne i vremenske rezolucije. Izrađeni modeli omogućiti će detektiranje, kvantifikaciju i praćenje prostorno-vremenskog preoblikovanja prostora zahvaćenih erozijom tla. Detaljnije se ciljevi istraživanja mogu raščlaniti po razinama istraživanja, na ciljeve makro, mezo i mikro razine istraživanja:

A. Ciljevi makro razine istraživanja:

C.1. Izraditi model podložnosti eroziji tla korištenjem višekriterijskog GIS pristupa za modeliranje podložnosti.

C.2. Izdvojiti zone najveće podložnosti eroziji tla i utvrditi najpogodnije područje za longitudinalno praćenje prostorno-vremenskih promjena.

B. Ciljevi mezo razine istraživanja:

C.3. Utvrditi prostorno-vremenske promjene uzrokovane erozijom tla unutar odabrane testne plohe.

C.4. Ustanoviti utjecaj geoloških i morfometrijskih značajki na intenzitet erozije tla.

C. Ciljevi mikro razine istraživanja:

C.5. Razvoj metodološkog pristupa za optimizaciju intervalnog praćenja erozije tla korištenjem aerofotogrametrije i terestričkog laserskog skeniranja.

C.6. Razvoj alata za automatsku kvantifikaciju prostorno-vremenskih promjena u čelu jaruge.

1.2. Temeljne hipoteze istraživanja

Na temelju navedenih ciljeva istraživanja definirano je ukupno devet temeljnih hipoteza istraživanja, koje je sukladno razini istraživanja moguće podijeliti na:

A. Temeljne hipoteze makro razine istraživanja:

H.1. *Točnost modela podložnosti eroziji tla izvedenog isključivo na temelju WV podataka visoke rezolucije (DMR i MS) iskazana vrijednostima AUC biti će iznad 0.8.*

H.2. *Najveću vrijednost AUC imati će model kod kojega je najveći težinski koeficijent dodijeljen grupi morfometrijskih predisponirajućih kriterija.*

B. Temeljne hipoteze mezo razine istraživanja:

H.3. *Višegodišnji volumetrijski (m^3) intenzitet erozije tla unutar istraživanog područja mezo razine biti će najveći unutar jaruge Santiš.*

H.4. *Utvrđene jednogodišnje stope PVP uzrokovane erozijom tla će značajno (> 10%) odstupati od utvrđenih višegodišnjih vrijednosti.*

H.5. *Višegodišnji intenzitet erozije tla zabilježen unutar jaruge Santiš biti će u skladu s vrijednostima RUSLE2015 modela.*

H.6. *Najveći volumetrijski (m^3) intenzitet erozije tla biti će zabilježen unutar naslaga smeđeg tla.*

C. Temeljne hipoteze razine istraživanja:

H.7. *Optimizacija intervalnog laserskog skeniranja omogućiti će pokrivenost > 90% kompleksne morfologije testnog područja.*

H.8. *Točnost aerofotogrametrijskog modela iskazana srednjom kvadratnom pogreškom odstupati će manje od ±4 cm u odnosu na referentni model.*

H.9. *Izrađeni alat omogućiti će automatiziranu kvantifikaciju linearnih i površinskih prostorno-vremenskih promjena u čelu jaruge.*

1.3. Pregled prethodnih istraživanja

Višestruke negativne posljedice koje pogađaju velik broj ljudi i uzrokuju znatne financijske gubitke doveli su do toga da erozija tla postane predmet velikog broja različitih sustavnih znanstvenih istraživanja (Zhuang i dr., 2015; Castillo i Gómez, 2016).

Istraživanja provedena u sklopu ove doktorske disertacije bave se erozijom tla kroz primjenu višerezolucijskog pristupa, pri čemu se i ciljevi i istraživačke metode razlikuju ovisno o razini istraživanja. Sukladno tome za izradu ove doktorske disertacije bilo je potrebno proučiti raznolik spektar ranije objavljenih interdisciplinarnih znanstvenih radova, koji su se bavili proučavanjem erozije tla s različitih aspekata. U nastavku je dan pregled dosadašnjih istraživanja podijeljenih prema razini istraživanja ove doktorske disertacije u kojoj su primijenjena:

i. Prethodna istraživanja korištena unutar makro razine

Prethodna istraživanja unutar makro razine ove doktorske disertacije vezana su pretežito za predobradu komercijalnih Worldview satelitskih i stereo snimaka (A), te za višekriterijsko modeliranje podložnosti eroziji tla (B).

***Predobrada komercijalnih Worldview satelitskih i stereo snimaka* (A)**

Aguilar i dr. (2013a) proučavaju kvalitetu digitalnih modela površina izrađenih iz komercijalnih Worldview i Geoeye satelitskih snimaka. U radu je poseban naglasak stavljen na proučavanje utjecaja različitih korisničko-definiranih parametara, broja i rasporeda orijentacijskih točaka, radiometrijskih i spektralnih značajki snimaka i brojnih drugih čimbenika na sveukupnu kvalitetu izrađenih modela. Zaključci ovog rada doprinose lakšem odabiru optimalnih parametara za obradu stereo satelitskih snimaka.

Aguilar i dr. (2019) u radu daju opsežnu procjenu vertikalne točnosti i detaljnosti digitalnih modela površina generiranih na temelju Worldview stereo podataka. U radu je detaljno analiziran utjecaj različitih senzora (WV-2 i WV-3), softvera za obradu (OrthoEngine (PCI) i RPC Stereo Processor (RSP)) te različitih tipova zemljišnog pokrova na kvalitetu i točnost generiranih modela. Rezultati istraživanja bili su ključni za odabir optimalne metodologije za obradu WV stereo snimaka za prostor otoka Paga.

Wang i dr. (2019) istražuju točnost digitalnih modela reljefa generiranih iz komercijalnih Worldview-2 stereo snimaka, za primjenu u geomorfološkim istraživanjima. U radu se analizira utjecaj broja i rasporeda orijentacijskih točaka te utjecaj različitih korisničko-definiranih parametara na točnost i vjernost prikaza reljefnih formi. Rezultati rada pokazali su da DMR generiran iz WV-2 stereo podataka može postići točnost vrijednosti visina do 0.25 m.

Modeliranje podložnosti eroziji tla (B)

Arabameri i dr. (2020b) u svom radu daju opsežnu usporedbu primjene deset različitih metoda statističkog modeliranja, višekriterijskih GIS analiza i metoda strojnog učenja za modeliranje podložnosti jaruženju (engl. *gully erosion-susceptibility mapping* – GESM). Pri tome su sve uspoređene metode primijenjene za modeliranje podložnosti jaruženju na temelju istih 15 predisponirajućih kriterija, koji pozitivno utječu na pojavnost jaruga. Na temelju usporedbe generiranih modela i zona podložnosti jaruženju autori zaključuju da Random Forest (RF) metoda strojnog učenja generira najtočniji model podložnosti jaruženju, prema ROC krivuljama i izračunatoj AUC vrijednosti.

Castillo i Gómez (2016) daju detaljan pregled glavnih predisponirajućih čimbenika, koji utječu na pojavnost i intenzitet jaruženja, kao najdominantnije i najintenzivnije forme procesa erozije tla. Osim toga, autori u ovom radu pojašnjavaju različite metodološke pristupe za proučavanje jaruženja i naglašavaju potrebu za rješavanjem određenih istraživačkih problema**.**

Domazetović i dr. (2019a) su uz pomoć višekriterijske GIS analize i 10 predisponirajućih kriterija raspoređenih u tri grupe kriterija (primarni morfometrijski kriteriji, sekundarni morfometrijski kriteriji, ostali kriteriji) izradili prvi model podložnosti prostora otoka Paga jaruženju. Točnost izrađenog modela podložnosti ispitana je s dva seta referentnih podataka o lokacijama postojećih jaruga (AUC = 0.89). Izrađeni model pokazao je da gotovo trećinu ukupne površine otoka Paga obuhvaćaju zone visoke i vrlo visoke podložnosti jaruženju. Međutim, iako su točnost i detaljnost izrađenog modela dovoljni za generalnu raščlambu prostora otoka Paga prema različitim klasama podložnosti jaruženju, prostorna rezolucija (15 m) i mjerilo (npr. pedologija – 1: 50 000) korištenih kriterija nisu omogućavali detaljniju analizu podložnosti pojedinih dijelova otoka. Zbog toga se i u zaključku samog rada ističe potreba za izradom detaljnijeg modela, zasnovanog na podacima prikupljenim u krupnijem mjerilu (npr. 1: 5000).

Gómez-Gutiérrez i dr. (2015) bave se modeliranjem podložnosti jaruženju unutar dva odvojena drenažna bazena (SanGioergio (Italija) i Mula River (Španjolska)) na temelju istih morfometrijskih i hidroloških kriterija. U radu je poseban naglasak stavljen na proučavanje utjecaja prostorne rezolucije na točnost modela podložnosti, na temelju čega je zaključeno da korištenje modela bolje rezolucije ne rezultira nužno boljom točnošću izrađenih modela podložnosti.

Saha i dr. (2020) uspoređuju modele podložnosti jaruženju izrađene korištenjem četiri različite ML metode i 14 predisponirajućih kriterija unutar slivnog područja rijeke Hinglo u istočnoj Indiji. Kao i u istraživanju kojega su proveli Arabameri i dr. (2020b) na prostoru Irana, i u ovom istraživanju se RF metoda pokazala kao optimalna metoda za izradu modela podložnosti jaruženju. Točnost izrađenih modela podložnosti jaruženju ispitana je s pet različitih kvantitativnih mjera, koje su sve pokazale da model izrađen RF algoritmom ima najveću točnost i kvalitetu.

ii. Prethodna istraživanja korištena unutar mezo razine

***Primjena intervalne UAV fotogrametrije i izrada modela vrlo visoke rezolucije* (C)**

Cook (2017) ispituje točnost intervalnih modela napravljenih iz podataka prikupljenih jeftinim UAV sustavom uz pomoć SfM algoritma, u odnosu na referentni TLS model. Usporedba je napravljena unutar testne plohe koja obuhvaća riječni kanjon kompleksne morfologije. Rezultati istraživanja pokazali su da je UAV model postigao zadovoljavajuću točnost, ali da kompleksna morfologija reljefa (strmci i prevjesne padine), te prisutnost vegetacije i vodenih površina mogu znatno utjecati na smanjenje točnosti modela.

James i dr. (2019) daju detaljne upute i smjernice za primjenu SfM fotogrametrije u geomorfološkim istraživanjima. Smjernice obuhvaćaju gotovo sve segmente procesa izrade modela primjenom SfM fotogrametrije, od odabira i opisa specifikacije korištene opreme, planiranja prikupljanja podataka (npr. broj i raspored orijentacijskih (OT) i kontrolnih (KT) točaka), značajke provedenog prikupljanja podataka, itd.

Stöcker i dr. (2015) istražuju mogućnost primjene UAV fotogrametrije u kombinaciji s terestričkom fotogrametrijom za modeliranje kompleksne morfologije jaruga. Kombinirana primjena ovih tehnika omogućila je izradu modela prostorne rezolucije 0.5 cm, uz točnost od 1 cm, pri čemu su praznine u modelu napravljenom iz podataka prikupljenih UAV

fotogrametrijom uspješno nadopunjene podacima prikupljenim terestričkom fotogrametrijom. Prvenstveno se kombinirana primjena ova dva tipa fotogrametrije pokazala uspješnom u prostorima kompleksne morfologije, poput strmih i prevjesnih dijelova čela jaruge.

***Kvantifikacija prostorno-vremenskih promjena uzrokovanih erozijom tla* (D)**

Eltner i dr. (2013) uspoređuju točnost modela odabrane testne poljoprivredne plohe (500 m^2) zahvaćene erozijom tla, napravljenog uz pomoć UAV fotogrametrije u odnosu na referentni model napravljen iz podataka prikupljenih terestičkim laserskim skeniranjem. Prema rezultatima istraživanja točnost UAV fotogrametrije ne odstupa značajnije od referentnog TLS modela. Na temelju izrađenih intervalnih modela detektirane su prostorno vremenske promjene uzrokovane djelovanjem erozije tla, poput nastanka brazdi i transportiranja erodiranog materijala.

Fernández i dr. (2020) bave se proučavanjem prostorno-vremenskih promjena uzrokovanih dugotrajnom erozijom tla na temelju niza intervalnih modela napravljenih iz aerofotogrametrijskih i LiDAR-skih podataka prikupljenih između 1980. i 2016. godine. Na temelju niza izrađenih intervalnih modela autori su izračunali da je u razdoblju između 1980. i 2016. prosječno erodirano 0.5 m materijala, odnosno gledano kroz volumen oko 8500 m^3 materijala godišnje. Ovo istraživanje predstavlja jedno od najsustavnijih longitudinalnih istraživanja erozije tla, te će kao takvo poslužiti kao osnova za provođenje analiza na mezo razini ove doktorske disertacije.

Šiljeg i dr. (2021) razvili su novu metodu, VERTICAL, koja omogućava praćenje vertikalnog pomaka uzrokovanog djelovanjem erozije u velikom broju poprečnih presjeka. VERTICAL metoda primijenjena je za praćenje dvogodišnjih prostorno vremenskih promjena unutar jaruge Santiš. Pri tome je VERTICAL metoda primijenjena na intervalnim modelima jaruge napravljenim na temelju snimaka prikupljenih intervalnom UAV fotogrametrijom.

Vanmaercke i dr. (2016) analizirali su i dali pregled rezultata više od 70 različitih radova koji su se bavili proučavanjem intenziteta uzmaka čela jaruge (engl. *gully headwall retreat* – GHR) u različitim dijelovima svijeta. U analiziranim radovima obrađeno je ukupno 933 jaruga različitih dimenzija. Iako su stope uzmaka čela jaruge znatno varirale, autori su uspjeli izdvojiti i statistički obraditi stope linearnog, površinskog i volumetrijskog pomaka. Izdvojene stope

dovedene su u odnos s različitim predisponirajućim čimbenicima, koji su uvjetovali pojavu erozije tla tog intenziteta.

iii. Prethodna istraživanja korištena unutar mikro razine

Neugirg i dr. (2016) primjenjuju intervalnu UAV fotogrametriju i TLS izmjere za praćenje intenziteta erozije tla unutar odabranog testnog područja u periodu od godinu dana. Na temelju prikupljenih intervalnih podataka utvrđene su značajne sezonalne razlike u intenzitetu erozije i akumulacije materijala, dok je unutar čitavog promatranog razdoblja u konačnici zabilježeno erodiranje 8 700 m^3 i akumuliranje 2000 m^3 materijala. U radu se ističe važnost utjecaja minimalnog praga detekcije (min_{LOD}) na potencijalnu detekciju i kvantifikaciju nastalih PVP, gdje je primijećeno da pojedine posljedice erozije tla nisu detektirane zbog previsokog praga minimalne detekcije. Rezultati ovog rada iskorišteni su za planiranje provedbe prikupljanja podataka uz pomoć intervalne UAV fotogrametrije na mezo razini, te uz pomoć TLS izmjera na mikro razini istraživanja.

Lague i dr. (2013) predstavljaju M3C2 algoritam, koji je razvijen kao novi algoritam za izravnu usporedbu dva oblaka točaka unutar 3D okruženja. U radu je na primjeru intervalnih oblaka točaka prikupljenih uz pomoć TLS-a demonstrirano kako M3C2 algoritam može biti korišten za detekciju i kvantifikaciju nastalih PVP. Pri tome su pojašnjene sve prednosti i nedostaci razvijenog algoritma, ali i svi korisničko-definirani parametri koji utječu na izlazne rezultate. S obzirom da je M3C2 algoritam korišten za usporedbu oblaka točaka unutar mikro razine ove disertacije, rezultati i smjernice dane u ovom radu uvelike su olakšali pravilno podešavanje parametara M3C2 algoritma.

Perroy i dr. (2010), Rengers i Tucker (2015) i Goodwin i dr. (2017) proučavaju prednosti i nedostatka primjene terestričkog laserskog skeniranja unutar prostora kompleksne morfologije uzrokovane djelovanjem erozije tla. Rezultati ova dva istraživanja ukazala su na moguće poteškoće i probleme koje se javljaju prilikom laserskog skeniranja vertikalno raščlanjenih prostora. Sva tri istraživanja ukazala su na značajnu potrebu za detaljnim planiranjem prikupljanja podataka uz pomoć TLS-A. Zbog toga su zaključci ovih radova korišteni prilikom razvoja i optimizacije metodologije intervalnih TLS izmjera primijenjenih u sklopu ove disertacije.

1.4. Obuhvat i prirodno-geografske značajke istraživanog područja

Područje istraživanja je prema postavljenom višerezolucijskom metodološkom okviru moguće podijeliti na tri zasebne razine istraživanja (Sl. 2.), koje se osim po prostornom obuhvatu razlikuju i po postavljenim ciljevima i hipotezama istraživanja, ali i primijenjenoj metodologiji istraživanja. U nastavku su ukratko pojašnjeni prostorni obuhvat i značajke sve tri razine istraživanja, pri čemu je poseban naglasak dan pojašnjenju važnosti svake pojedine razine unutar primijenjenog višerezolucijskog pristupa proučavanju erozije tla.

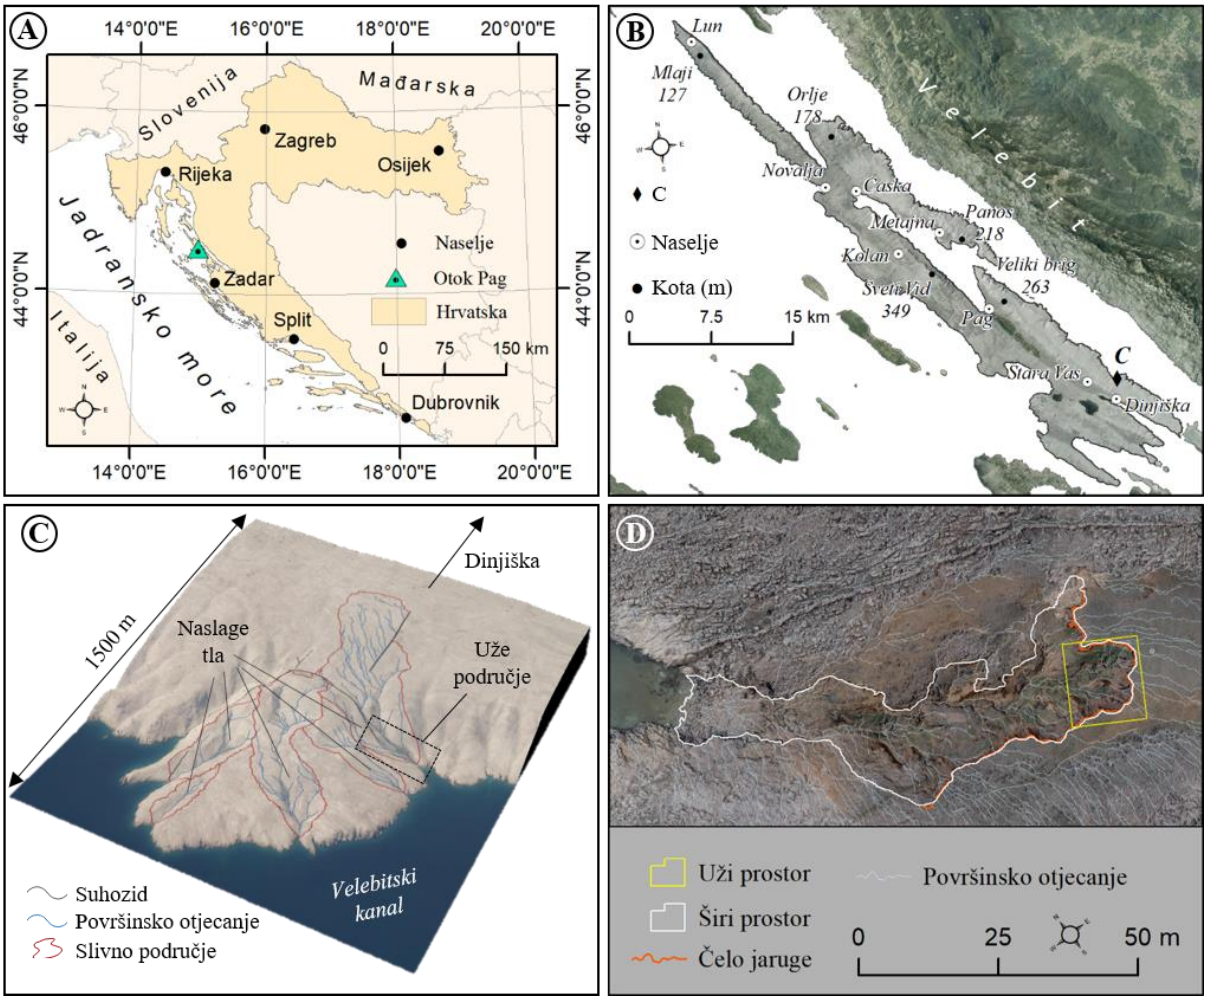

Slika 2. Raščlamba prostornog obuhvata istraživanja
(A – lokacija otoka Paga unutar Hrvatske; B – makro razina istraživanja;
C – mezo razina istraživanja; D – mikro razina istraživanja)

1.4.1. Makro razina istraživanja – otoka Pag

Makro razina istraživanja obuhvaća čitav otok Pag, ukupne površine oko 284 km² (Sl. 2.B). Zahvaljujući specifičnom ogoljenom krškom krajoliku i surovim klimatskim uvjetima gotovo 30% ukupne površine otoka podložno je eroziji tla (Domazetović i dr., 2019a), o čemu svjedoči i nekoliko stotina postojećih jaruga (Lončar, 2009; Domazetović, 2018). Rasprostranjenost i raznolikost erozijskih formi unutar ogoljenih dijelova otoka Paga rezultat je višestoljetne interakcije između različitih prirodnih i antropogenih utjecaja.

Pojavnost i intenzitet erozije tla unutar otoka Paga uvelike je uvjetovan značajkama geološke podloge, odnosno reljefa otoka. Strukturno gledano današnji izgled otoka Paga rezultat je kompleksnih tektonskih procesa i odnosa, što se posebice ističe kroz izmjenu usporednih antiklinalnih i sinklinalnih nizova, uvjetovanih istaknutim rasjednim linijama Dinarskog pravca pružanja (SZ – JI) (Mamužić i Sokač, 1973; Mittempergheri dr. 2019). Generalno unutar uzdignutih antiklinalnih otoka Paga prevladavaju rudistni i foraminiferski vapnenci gornje krede i eocena (Marriner i dr., 2014), dok su unutrašnji sinklinalni dijelovi otoka prekriveni deluvijalnim, aluvijalnim i flišnim naslagama (Sl. 4.). Naslage fliša su pretežito eocenske starosti, taloženje deluvijalnih naslaga odvijalo se tijekom pleistocena, dok su najnoviji holocenski slojevi na otoku Pagu zastupljeni u obliku aluvijalnih naslaga i organogenih močvara (Sokač i dr., 1976.). Od navedenih slojeva erozija tla je naročito prisutna u eroziji podložnim naslagama fliša, unutar kojih su zabilježene vrlo velike erozijske forme. Osim unutrašnjosti otoka, posebice velike jaruge formirane su na poluotoku Metajna (Sl. 3.).

Slika 3. Jaruge formirane u flišnim naslagama poluotoka Metajna

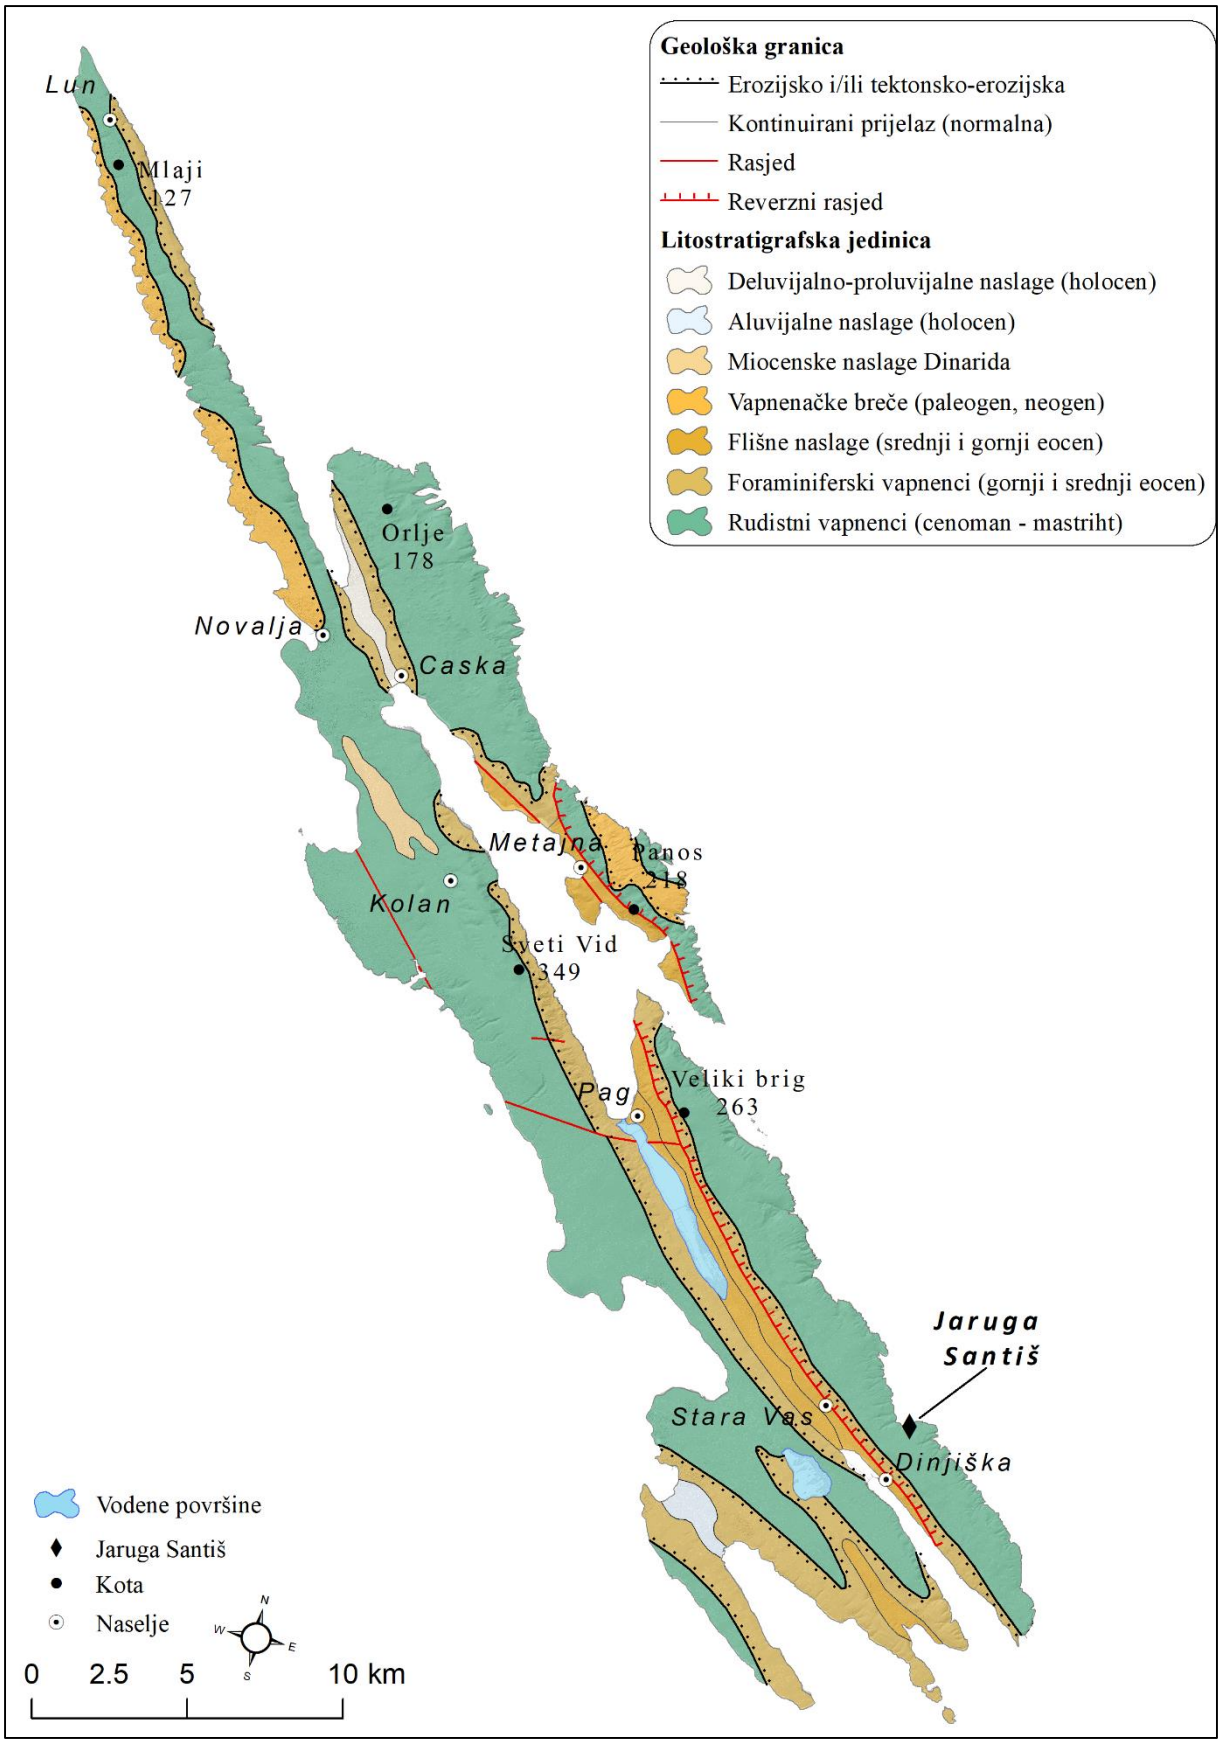

Slika 4. Generalna geološka karta otoka Paga (prema Velić i Vlahović, 2009)

Osim naslaga fliša za eroziju tla bitne su povremene, disperzno rasprostranjene manje površine naslaga *smeđeg tla na vapnencu*, koje je moguće naći u udubljenim dijelovima reljefa, unutar ogoljenih sjeveroistočnih i istočnih dijelova otoka Paga (Sl. 5.). Smeđe tlo na vapnencu predstavlja poseban tip tla koji nastaje dugotrajnim djelovanjem vode na otapanje izloženih slojeva vapnenca i dolomita, pri čemu dolazi do postupnog taloženja netopivih tvari u reljefnim udubljenjima, zaštićenim od erozivnog djelovanja vode i vjetra (Bašić, 2013).

Unutar ogoljenih dijelova otoka Paga slojevi vapnenca i dolomita su zbog vrlo slabo razvijenog vegetacijskog pokrova izravno izloženi djelovanju različitih erozivnih agenata (Meda i dr., 2019). Njihovim postupnim otapanjem dolazi do formiranja smeđeg tla, koje se daljnjim djelovanjem površinskog i podzemnog otjecanja postupno transportira s prostora cijelih slivnih područja prema postojećim manjim udubljenjima u reljefu (Bašić, 2013). Dugotrajnom sedimentacijom smeđeg tla, postupno dolazi do zapunjavanja reljefnih udubljenja, pri čemu nastaju naslage smeđeg tla različite debljine. Prema debljini naslaga tla mogu se razlikovati *plitke* (< 35 cm), *umjereno duboke* (35 – 70 cm) te d*uboke* (> 70 cm) naslage smeđeg tla (Bašić, 2013), pri čemu su sve tri vrste zabilježene na prostoru otoka Paga tijekom terenskih istraživanja. Nataložene naslage tla izrazito su podložne eroziji tla, zbog čega pretežito uspijevaju opstati isključivo u izoliranim i od erozije zaštićenim udubljenjima, rasprostranjenim duž ogoljenog istočnog i jugoistočnog dijela otoka Paga (Sl. 5.).

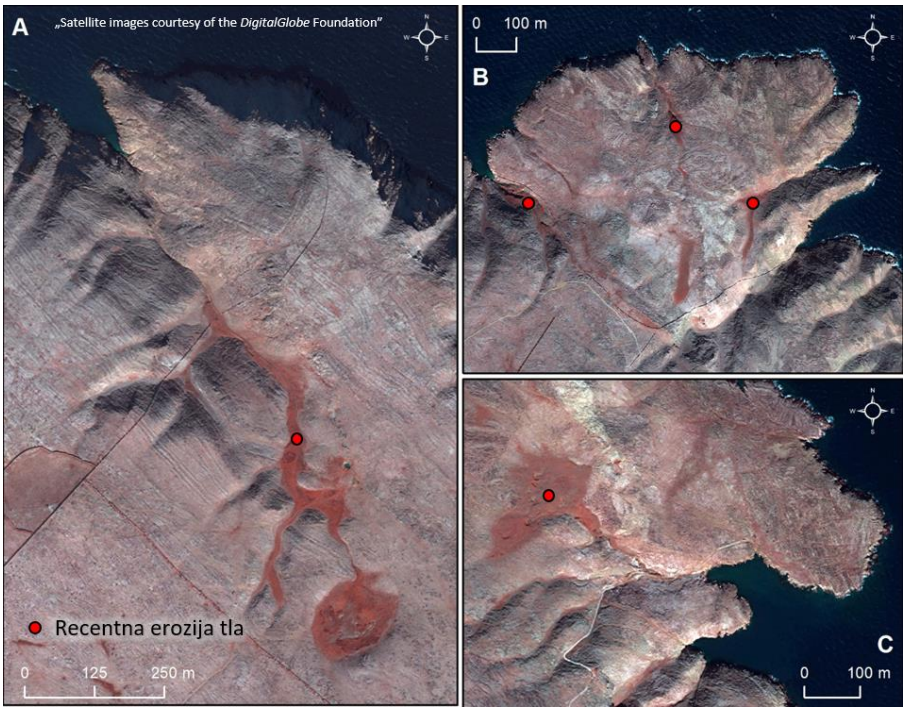

Slika 5. Disperzne naslage smeđeg tla i tragovi erozije tla
(A – uvala Movra; B – poluotok Santiš; C – uvala Čista)

Velik utjecaj na pojavnost i intenzitet erozije tla na prostoru otoka Paga imaju i klimatske značajke otoka. Prostor otoka Paga predstavlja prijelazni prostor između sredozemne klime s vrućim ljetom (*Csa*) i umjerene tople vlažne klime (*Cfa*) (Magaš, 2011). Tridesetogodišnje vrijednosti ukupne količine oborina variraju od 497.60 mm do 1680.2 mm, pri čemu prosječna godišnja količinom oborina iznosi 1047.79 mm.[3] Godišnja raspodjela oborina je izraženog sezonalnog karaktera, s naglašenim zimskim (*siječanj-veljača*) i jesenskim (*rujan – studeni*) maksimumom. Izražena sezonalnost oborina i izmjene sušnijih i vlažnijih razdoblja odražavaju se i na varijabilnost intenziteta erozije tla. Otok Pag vjerojatno je najpoznatiji po izraženoj vjetrovitosti, a posebice utjecaju olujnog sjeveroistočnog vjetra bure koji je značajno utjecao na oblikovanje specifičnog krškog ogoljenog krajolika (Magaš, 2011). Bura je hladan olujni vjetar, koji se u snažnim udarima spušta s Velebita iz pravca sjeveroistočnog kvadranta prema otoku Pagu, pri čemu pojedini udari mogu dosezati brzinu vjetra od čak 60 m s^{-1} (Grisogono i Belušić, 2009; Babić i dr., 2016). Upravo zbog olujnih udara bure i utjecaja burom nošene posolice izloženi sjeveroistočni i istočni dijelovi otoka su pretežito ogoljeni i izloženi erozivnom djelovanju vjetra i drugih agensa. Pri tome bura ne samo da uzrokuje erodiranje izloženih naslaga tla, već postepeno zbog posolice uzrokuje zaslanjivanje tla (Škoda, 2017).

Među povijesnim izvorima koji svjedoče o utjecaju klimatskih čimbenika, a posebice bure na oblikovanje ogoljenog paškog krajolika treba istaknuti zapise putopisca Alberta Fortisa, koji je u svom djelu *Put po Dalmaciji* (tal. *Viagghio di Dalmazia*) iz 1774. godine zapisao (Fortis, 1774):

„Podneblje otoka je isto kao na Morlačkoj gori (Velebit, op. a.) i morskoj obali u njenom podnožju. Zima je strahovito hladna, a ljeto užasno vruće. Olujno more bijesno udara u kamenitu obalu otoka nasuprot planini; s te su strane vrhovi i padine brjegova pusti zbog vjetra, tako da na njima nema ni šume, ni pašnjaka, ni njiva, osim na nekoliko mjesta; nego strašno golo kamenje, pusto i nenaseljeno, pokriva gotovo svu površinu.“

[3] Podaci s klimatološke postaje Pag za period od 1988. do 2018. godine (DHMZ, 2020).

1.4.2. Mezo razina istraživanja – poluotok Santiš

Prostorni obuhvat mezo razine istraživanja moguće je raščlaniti na dvije podrazine, širi prostor mezo razine, koji obuhvaća poluotok Santiš (Sl. 6.A), te na uži prostor mezo razine, koji obuhvaća prostor jaruge Santiš (Sl. 6.B).

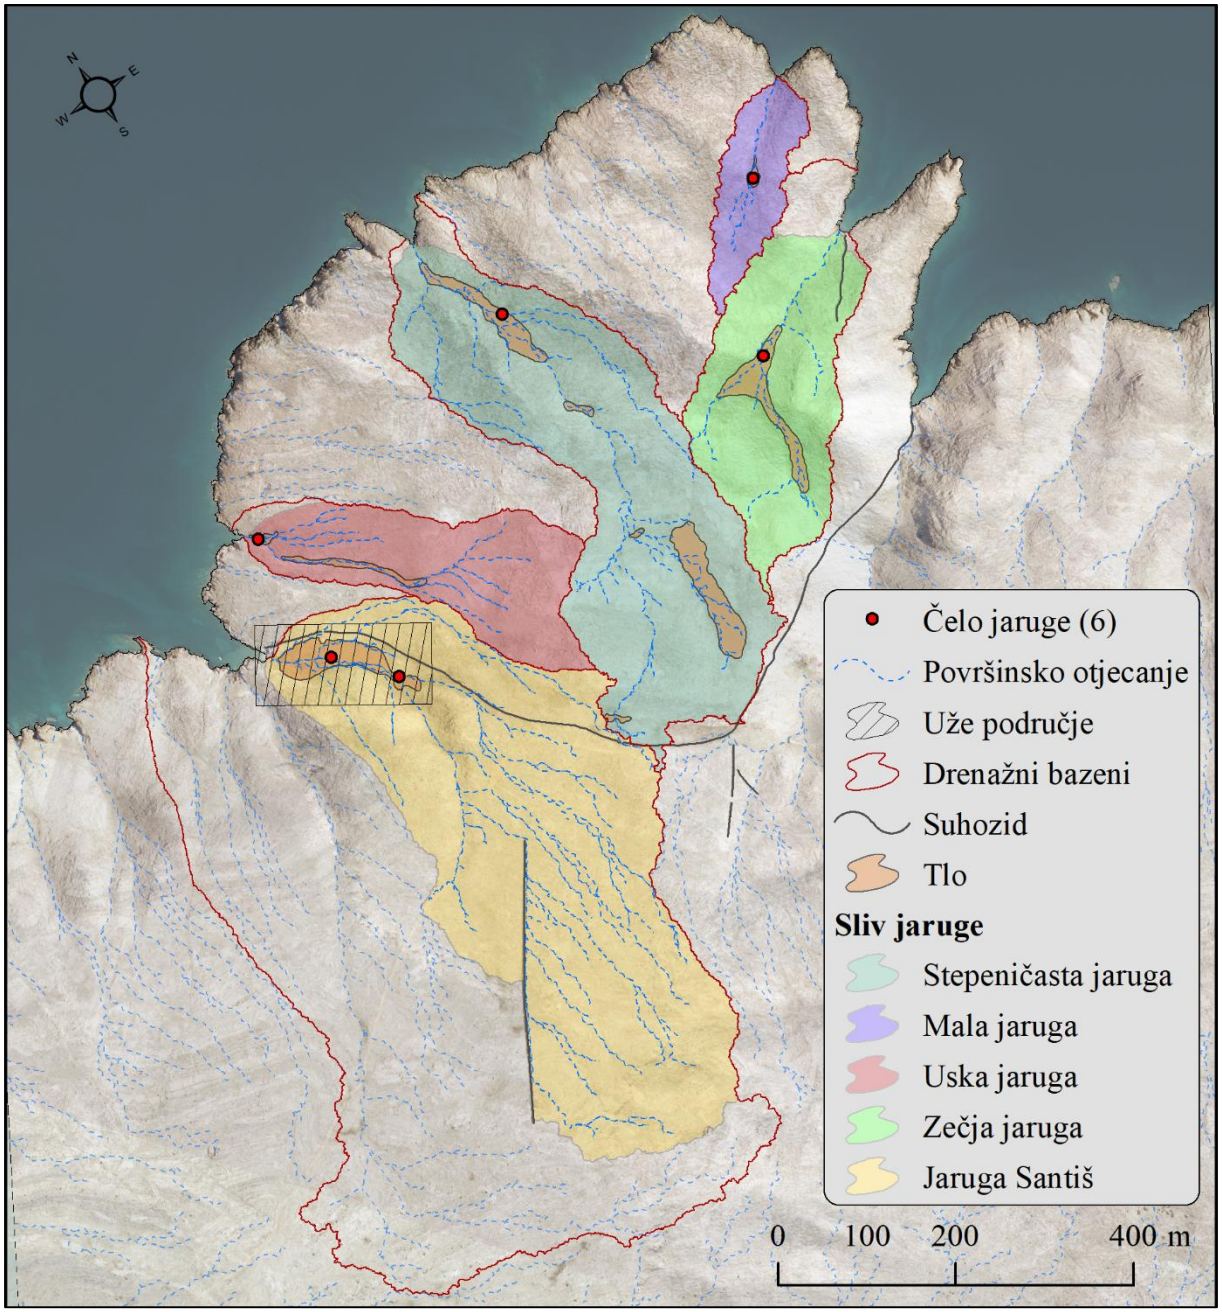

Slika 6. Prostorni obuhvat šireg (A) i užeg (B) prostora mezo razine istraživanja

Šire područje mezo razine istraživanja obuhvaća poluotok Santiš, smješten u JI dijelu otoka Paga, ukupne površine od oko 2.1 km² (Sl. 2.C). Prostor poluotoka Santiš znakovit je po izraženoj prisutnosti izoliranih naslaga smeđeg tla na vapnencu (Sl. 7.), unutar kojih su prilikom

ranijih terenskih istraživanja zabilježeni intenzivni recentni tragovi erozije tla (Šiljeg i dr., 2021). Iako se naslage smeđeg tla s recentnim tragovima aktivne erozije tla mogu pronaći i u drugim dijelovima istočnog i jugoistočnog dijela otoka Paga, njihova velika koncentracija unutar relativno malog prostora čine poluotok Santiš jedinstvenom lokacijom unutar otoka. Prednost poluotoka Santiš je i njegova nedostupnost, zbog čega je antropogeni utjecaj na eroziju tla znatno manji nego u nekim drugim dijelovima otoka.

Slika 7. Zračni snimak jaruga poluotoka Santiš (foto: Šime Vrkić)

Izražena podložnost eroziji tla prostora poluotoka Santiš potvrđena je i na temelju ranijih istraživanja (Domazetović i dr., 2019A), u sklopu kojih se na temelju izrađenog višekriterijskog GIS modela gotovo čitav poluotok pokazao visoko ili vrlo visoko podložnim eroziji tla. Naime, iako se radi o relativno malom prostoru (2.1 km²), unutar njega je detektirano osam odvojenih površina prekrivenih naslagama *smeđeg tla,* te pet aktivnih jaruga (Sl. 6; 7). Površina slivnog područja i razgranatost mreže površinskog otjecanja uvelike variraju od jaruge do jaruge, što se vjerojatno odražava i na intenzitet erozije unutar pojedinih jaruga. Sukladno tome i debljina naslaga sedimentiranog tla unutar pojedinih slivnih područja varira od svega nekoliko cm (npr. unutar Uske jaruge), pa i do nekoliko metara (npr. unutar Stepeničaste jaruge i jaruge Santiš). Posebice velika slivna područja imaju jaruga Santiš i jaruga Stepeničasta, unutar kojih prilikom intenzivnijih oborinskih događaja dolazi do formiranja značajnijeg

površinskog i podzemnog otjecanja sposobnog za erodiranje i ispiranje značajnijih količina materijala. U prilog takvom izraženom otjecanju ide i postojanje povremenog izvora, koji se aktivira nakon intenzivnijih oborinskih događaja, a što je zabilježeno prilikom ranijih terenskih istraživanja (Šiljeg i dr., 2021). Iako je za sada prisutnost takvog povremenog izvora zabilježena jedino u dnu jaruge Santiš, znatno češće su vrulje, koje su zabilježene gotovo uz svaku od pet postojećih jaruga poluotoka Santiš.

Uže područje mezo razine obuhvaća čitav prostor jaruge Santiš i naslaga smeđeg tla unutar kojih je došlo do formiranja jaruge, ukupne površine od 13 881.63 m^2. U sklopu ranijih istraživanja (Domazetović, 2018; Šiljeg i dr., 2021) proučavan isključivo prostor od glavnog čela jaruge Santiš do njezinog završetka, na prostoru žala (Sl. 8.E). Međutim, prilikom terenskih istraživanja recentni tragovi erozije tla zabilježeni su i unutar prostora iznad glavnog čela jaruge, posebice na sporednom čelu jaruge (Sl. 8.A) i blagoj travnatoj padini (Sl. 8.B). Kako bi se omogućilo proučavanje svih PVP uzrokovanih erozijom tla prostorni obuhvat istraživanja u sklopu ove disertacije proširen je na čitav prostor naslaga smeđeg tla.

Unutar proučavanog prostora jasno se ističu dva čela jaruge (Sl. 8. A i C), od kojeg veće čelo (C) s ukupnom duljinom od 92.5 m predstavlja jedno od najvećih čela jaruge na prostoru otoka Paga. Osim ovih većih erozijskih oblika unutar jaruge Santiš prisutni su i brojni manji erozijski oblici, nastali djelovanjem brazdanja i spiranja materijala.

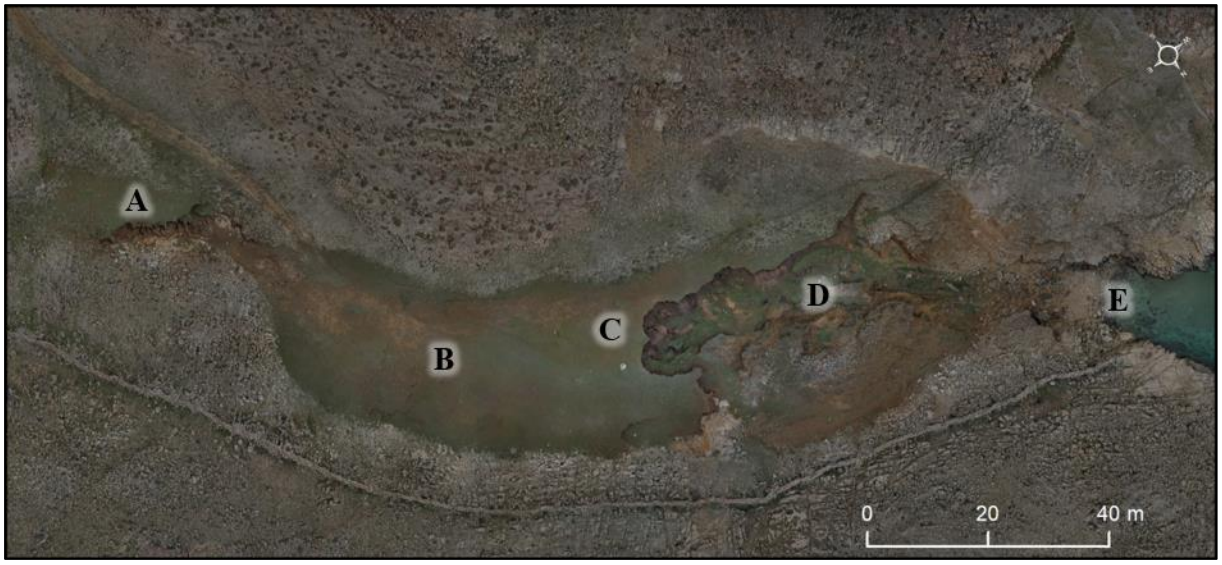

Slika 8. Prostorni obuhvat užeg područja mikro razine istraživanja
(A – sporedno čelo jaruge; B – travnata padina; C – glavno čelo jaruge;
D – glavni kanal jaruge Santiš; E – žalo)

1.4.3. Mikro razina istraživanja – čelo jaruge Santiš

Mikro razina istraživanja također može biti raščlanjena na dvije podrazine, pri čemu širi prostor obuhvaća glavno čelo i glavni kanal jaruge Santiš (Sl. 9.A), a uži prostor manji dio čela jaruge Santiš, ukupne površine 200 m², izdvojenog zbog kompleksne morfologije reljefa i intenzivnih stopa erozije tla (Sl. 9.B).

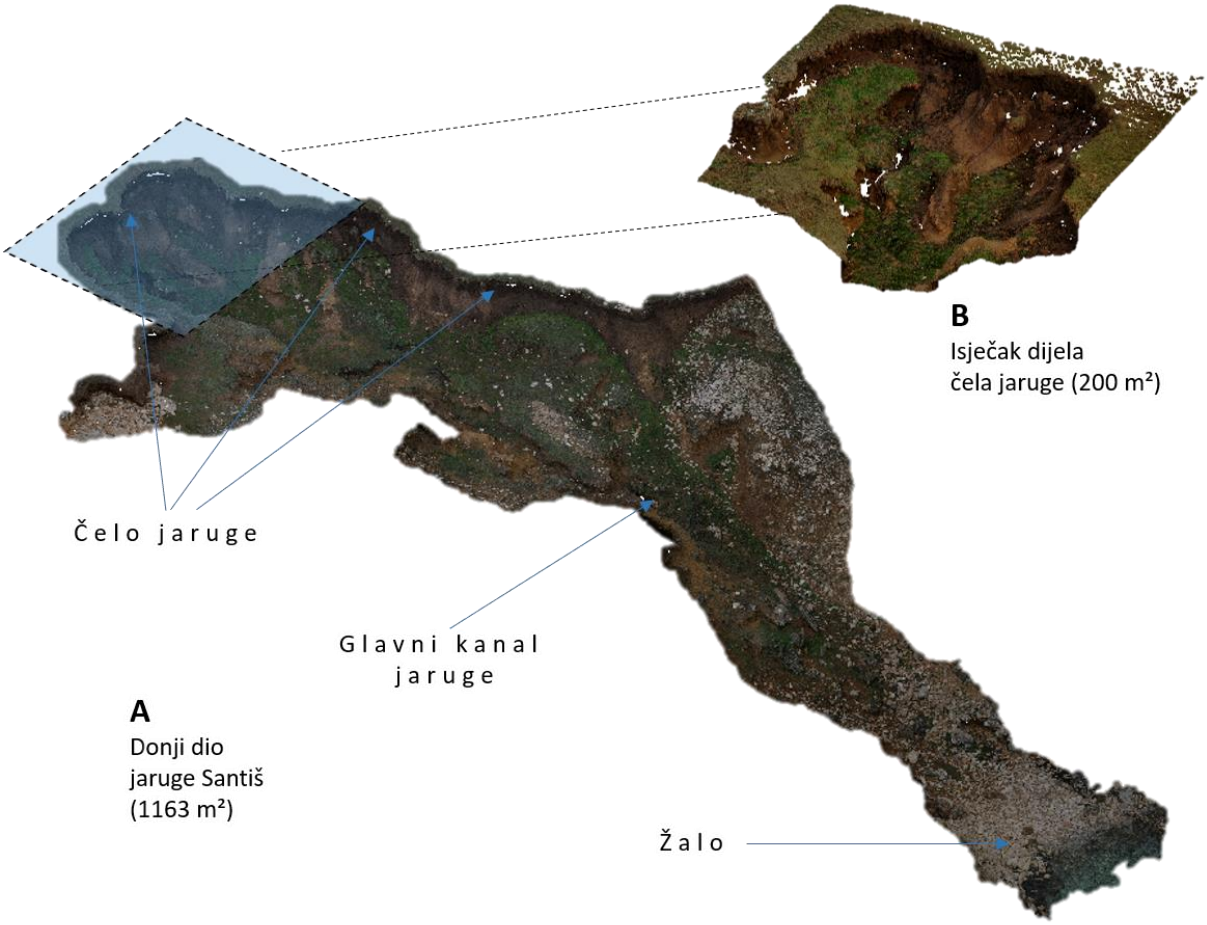

Slika 9. Prostorni obuhvat šireg (A) i užeg (B) prostora mikro razine istraživanja

Širi prostor mikro razine obuhvaća prostor od glavnog čela jaruge Santiš, preko središnjeg glavnog kanala, sve do završnog dijela na prostoru žala. Ovaj prostor ukupne površine od 1163 m^2 karakterizira vrlo kompleksna i raznolika morfologija. Stoga je upravo ovaj prostor odabran za procjenu uspješnosti provedene inicijalne TLS izmjere i procjenu točnosti izrađenog inicijalnog aerofotogrametrijskog modela.

Uži prostor mikro razine obuhvaća dio glavnog čela jaruge Santiš, unutar kojega su zabilježene najintenzivnije PVP uzrokovane djelovanjem erozije tla. Zbog toga je ovaj prostor odabran za praćenje PVP uz pomoć naprednih algoritama za detekciju i kvantifikaciju PVP.

2. TEORIJSKA OSNOVA

2.1. Erozija tla – pojmovno određenje

Erozija tla (engl. *soil erosion*) je zajednički naziv za kombinaciju egzogenih procesa, različitog prostornog obuhvata i intenziteta, koji svojim djelovanjem uzrokuju postupno odvajanje i pokretanje čestica tla s jedne lokacije na Zemljinoj površini te prenošenje i taloženje materijala na drugoj lokaciji (SSSA, 2008; Benac, 2016; Torresani i dr., 2019). Najjednostavnija definicija eroziju tla definira kao mehaničko trošenje tla pod utjecajem različitih erozivnih agensa, poput vode ili vjetra (Zachar, 2011), koje se sastoji od tri glavne faze: *odvajanje čestica tla* (1), *prenošenje erodiranih čestica tla* (2) i *taloženje čestica tla* (3) (Šurda i dr., 2007, u Dragičević, 2016). Ove tri faze karakteristične su za sve procese erozije tla, neovisno o prostornom obuhvatu (od nekoliko mm^2 do nekoliko stotina km^2) i intenzitetu procesa (Roose, 1996).

Glavni prirodni pokretači erozije tla su voda i vjetar, no na pojavnost i intenzitet erozije značajan utjecaj imaju i različiti drugi predisponirajući prirodni, a posebice antropogeni uzročnici (Morgan, 2009). Sukladno tome, u znanstvenoj literaturi ustalila se podjela erozije tla na **prirodnu eroziju tla** (engl. *natural erosion*) i **ubrzanu eroziju tla** (engl. *accelerated erosion*) (Morgan, 2009; Boardman i Poesen, 2007; USDA, 2017; Bashir i dr., 2018). Pri tome se prirodna erozija tla odnosi na eroziju čiji intenzitet je uvjetovan prirodnim procesima i čimbenicima, dok se ubrzanom erozijom smatra ona erozija čiji intenzitet je ubrzan u odnosu na prirodni intenzitet, pod utjecajem različitih antropogenih utjecaja (Morgan, 2009).

Postoje brojne različite definicije termina **tlo** (engl. *soil*) (Hartemink, 2016), koje se prema najčešće korištenoj definiciji može definirati kao nekonsolidirani mineralni ili organski materijal na površini Zemlje, koji služi kao prirodni medij za rast kopnenih biljaka (SSSA, 2008). Tlo predstavlja ograničeni, sporo-obnovljivi resurs, od ključne socijalne, ekonomske i ekološke važnosti, čija zaštita je ključna za opstanak ljudske civilizacije (Panagos i dr., 2018).

I. Primjeri erozije tla uzrokovane djelovanjem prirodnih čimbenika

Erozija tla uzrokovana djelovanjem vode

Erozija tla uzrokovana djelovanjem vode (engl. *water erosion*) obuhvaća različite potprocese kojima voda postupno utječe na odvajanje, prenošenje i taloženje čestica tla

(Valentin i dr., 2005). Globalno gledano, u odnosu na druge prirodne erozijske agense, poput vjetra ili leda, erozija tla uzrokovana djelovanjem vode uzrokuje najintenzivniji gubitak tla (Panagos i dr., 2015; Bashir i dr., 2018; Dube i dr., 2020; Borrelli i dr., 2020). Pojedini potprocesi erozije tla djelovanjem vode dodatno su pojašnjeni u poglavlju 2.1.2.

Erozija tla uzrokovana djelovanjem vjetra

Erozija tla vjetrom (engl. *aeolian erosion*; *wind erosion*) poznata kao i eolska erozija i deflacija, predstavlja proces odvajanja, prenošenja i taloženja čestica tla uzrokovan erozivnim djelovanjem vjetra (Morgan, 2009; USDA, 2017). Erozija tla vjetrom može zahvatiti vrlo velika područja i imati znatan intenzitet posebice u ogoljenim područjima sa malom količinom oborina i izraženim periodima suše (USDA, 2017; Bashir i dr., 2018). Kod erozije tla vjetrom glavni čimbenik erozivnosti je brzina vjetra, koja uvjetuje intenzitet trošenja čestica tla, ali i transportnu snagu vjetra i mjesto akumuliranja erodiranih čestica (Morgan, 2009). Prostor otoka Paga poznat je po oskudnoj vegetaciji i izraženim periodima suše te izrazito jakom utjecaju vjetra, posebice sjeveroistočnog vjetra bure, koji izravno utječe na preoblikovanje površinskog pokrova i reljefa (Domazetović i dr., 2019a). Za vrijeme terenskih istraživanja provedenih na području otoka Paga i jaruge Santiš primijećeni su različiti tragovi eolske erozije (Sl. 10.).

Slika 10. Posolica (A) i erozija tla (B) uzrokovani udarima bure – jaruga Santiš

Organogena erozija tla

Organogena erozija tla (engl. *organogenic erosion*) predstavlja specifičan tip erozije tla, kod kojega do erozije tla dolazi uslijed djelovanja različitih organskih organizama, pri čemu se mogu razlikovati fitogena erozija tla (engl. *phytogenic erosion*) i zoogena erozija tla (engl. *zoogenic erosion*) (Zachar, 2011). Zoogena erozija tla znatno je češća, a najčešće uključuje ili eroziju tla uzrokovanu kretanjem životinja po naslagama tla, ili pak eroziju tla uzrokovanu izradom nastambi u naslagama tla. Prilikom terenskih istraživanja na prostoru poluotoka Santiš primijećeni su različiti oblici zoogene erozije tla, poput zečjih (Sl. 11.A) i ptičjih nastambi (Sl. 11.B) u izloženim dijelovima čela i bočnim strmim padinama jaruga, ili pak utjecaja ovaca (Sl. 121. i 122.).

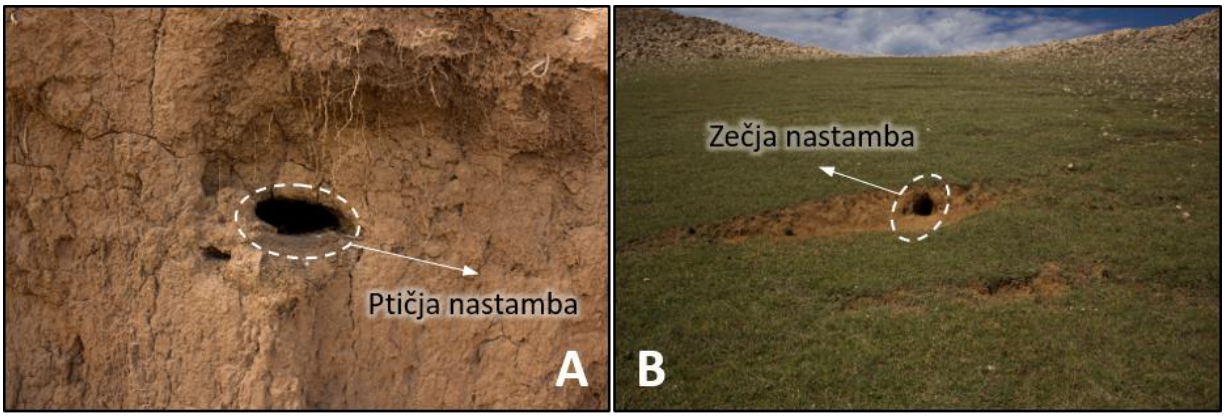

Slika 11. Primjeri zoogene erozije tla (A – zečje nastambe formirane u čelima Zečje jaruge; B – ptičje nastambe formirane u čelu Stepeničaste jaruge)

II. Erozija tla uzrokovana antropogenim utjecajima

Čovjek svojim djelovanjem utječe na povećanu pojavnost i intenziviranje prirodnih stopa procesa erozije tla (Valentin i dr., 2005; Morgan, 2009; Zachar, 2011; Desta i Adugna, 2012; Borelli i dr., 2017). Iako postoje različiti oblici izravnog i neizravnog utjecaja antropogenog djelovanja na proces erozije tla (Morgan, 2009), generalno je moguće izdvojiti sljedeće oblike antropogenog utjecaja:

Erozija tla uzrokovana prekomjernom ispašom

Prekomjerna ispaša (engl. *overgrazing*) predstavlja oblik ispaše kod kojega uklanjanje biomase s pašnjaka od strane stoke znatno nadilazi sposobnost prirodne obnove pašnjaka (Gutiérrez i dr., 2009; Morgan, 2009; Torresani i dr., 2019). Uklanjanjem vegetacijskog pokrova prekomjernom ispašom dolazi do povećanja brzine i intenziteta površinskog

otjecanja, te ujedno i veće izloženosti naslaga tla erozivnom djelovanju (Morgan, 2009). Osim uklanjanja vegetacijskog pokrova, stoka svojim kretanjem po rastresitim naslagama tla utječe na intenzivno erodiranje i odnošenje naslaga tla (Gómez-Gutiérrez i dr., 2018), što je evidentirano i tijekom terenskih istraživanja provedenih u sklopu ove doktorske disertacije (Sl. 12.1 i 12.2).

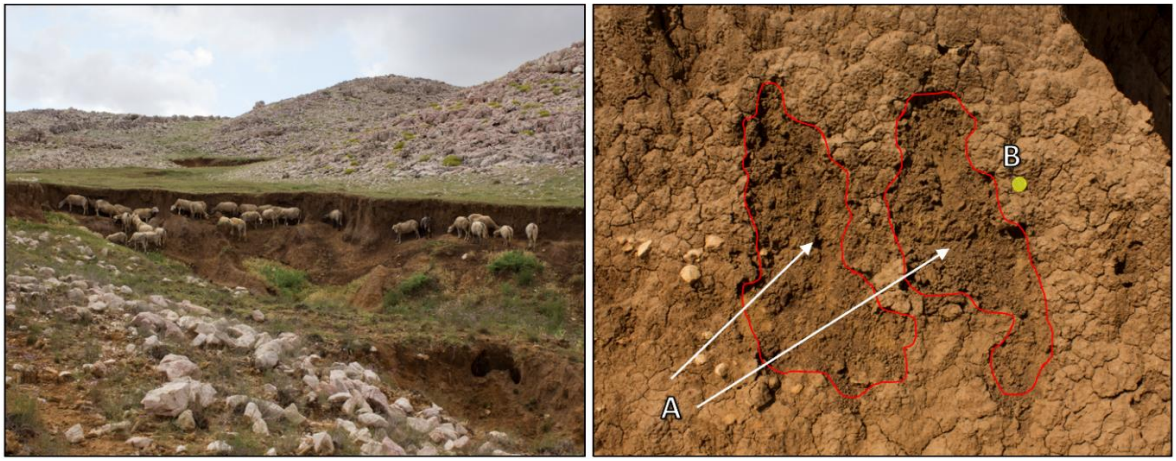

Slika 12.1 Utjecaj ovaca na ubrzanje erozije tla

Ovce ispod čela jaruge Santiš (*lijevo*); recentni tragovi kretanja ovce po isušenom tlu čela jaruge Santiš (A) u odnosu na kovanicu od 2 HRK (B) (*desno*)

Na otoku Paga ovčarstvo je već stoljećima temeljna gospodarska djelatnost otočkog stanovništva (Gugić i dr., 2012). Brojnost ovaca na relativno maloj površini otoka (105 ovaca/km²)[4] predstavlja znatno opterećenje za oskudne paške krške pašnjake. Samim time, intenzivno ovčarstvo zasigurno pridonosi stopama erozije tla.

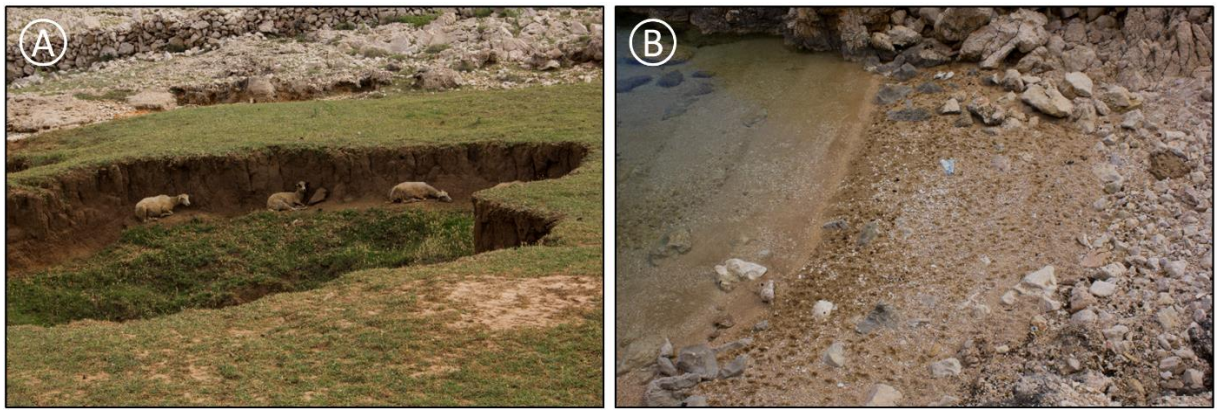

Slika 12.2 Utjecaj ovaca na akceleraciju erozije – ovce ispod čela jaruge Santiš (*A*); recentni tragovi kopita ovaca na žalu na dnu jaruge Santiš (B)

[4] Prema procjenama na otoku Pagu (284,29 km²) nalazi se oko 30 000 ovaca (Barać i dr., 2007; Gugić i dr., 2012)

Brojne studije su dokazale da kontrola prekomjerne ispaše kroz primjenu različitih mjera (npr. smanjenja ukupnog broja stoke, rotacija ispaše, itd.) odnosno **održivog upravljanja stočarenjem** (engl. *sustainable livesock managament*) može značajno smanjiti intenzitet erozije tla na određenom području (Wilkinson i dr., 2018; Dong i dr., 2020a).

Erozija tla uzrokovana promjenama u načinu korištenju zemljišta

Promjene u načinu korištenja zemljišta se mogu svrstati među glavne antropogene pokretače procesa erozije tla (Sun i dr., 2014; Torri i Poesen, 2014; Castillo i Gómez, 2016; Borelli i dr., 2020). Različiti antropogeni utjecaji i pritisci dovode do postupnog nestajanja prirodnog okoliša (npr. šumske površine) i paralelnog širenja antropogeno valoriziranih površina (npr. poljoprivredne površine, urbane površine, itd.), pri čemu izmijenjeni okoliš karakterizira veća podložnost eroziji tla (Borelli i dr., 2017). Posebice treba istaknuti širenje poljoprivrednih površina, koje su zbog povezanosti s različitim drugim negativnim procesima (npr. deforestacija, prekomjerna ispaša, neodrživa poljoprivreda, itd.) odgovorne i za do 80% povećanja intenziteta erozije tla (Borelli i dr., 2017).

Erozija tla uzrokovana izravnim antropogenim zahvatima

Izravni antropogeni zahvati poput šumarskih aktivnosti, izgradnje prometnica i građevinskih aktivnosti također mogu dovesti do pojave i intenziviranja erozije tla (Valentin i dr., 2005; Vanmaercke i dr., 2016). Građevinski zahvati i izgradnja prometnica utječu na promjenu hidroloških značajki određenog područja, zbog čega brojni radovi uzimaju upravo udaljenost od prometnica kao bitan kriterij u modeliranju podložnosti određenog prostora jaruženju (Arabameri i dr., 2020b).

2.1.1. Negativne posljedice erozije tla

Unutar EU erozija tla predstavlja jednu od glavnih ugroza za naslage tla, koja rezultira raznovrsnim negativnim posljedicama (Panagos i dr., 2015c). Nepoželjne posljedice erozije tla mogu se podijeliti na izravne (engl. *on-site*) i neizravne (engl. *off-site*) negativne posljedice (Telles i dr., 2013; Erkossa i dr., 2015).

I. Izravne (On-site) posljedice erozije tla

Izravne negativne posljedice, poput degradacije i odnošenja površinskih slojeva tla te gubitka hranjivih sastojaka i smanjenja produktivnosti tla, pogađaju površine neposredno zahvaćene procesom erozije tla (Erkossa i dr., 2015; Morgan, 2009). Izravne posljedice erozije tla lokalnog su karaktera jer neposredno pogađaju poljoprivrednike i stočare, čija produktivnost i isplativost proizvodnje ovise o zahvaćenom području (Morgan, 2009). Intenzitet izravnih negativnih posljedica erozije tla često nadilazi financijske mogućnosti pojedinaca za saniranje nastalih šteta, zbog čega sanacijske troškove moraju snositi različite organizacije iz javnog ili privatnog sektora (Schmiedel i dr., 2017).

II. Indirektne posljedice (Off-site) erozije tla

Neizravne negativne posljedice obuhvaćaju višestruke neželjene učinke, uzrokovane transportiranjem i sedimentacijom erodiranog tla nizvodno od erozijskih zona (Morgan, 2009.). Uslijed toga dolazi do posljedica, čiji učinci znatno nadilaze lokalni karakter izravnih posljedica erozije tla te pogađaju društvo u cjelini (Telles i Dechen, 2011; Telles i dr., 2013.). Prema Morgan (2009) neizravne negativne posljedice erozije tla generalno pridonose:

- *Taloženju erodiranog tla* – sedimentacija nizvodno od mjesta erodiranja može uzrokovati niz problema, poput: smanjenje kapaciteta rijeka, povećanje rizika od poplava, blokiranje kanala za navodnjavanje, smanjenje kapaciteta hidrocentrala, itd.
- *Onečišćenju vodenih površina* – erodiranjem i transportiranjem naslaga tla osim sedimenta u vodenim površinama završavaju i određene količine dušika i fosfora, koje mogu uzrokovati različite probleme, poput eutrofikacije.
- *Klimatskim promjenama* – erozija tla uzrokuje razgradnju čestica tla na primarne tvari (glinu, pijesak i mulj), pri čemu dolazi do oslobađanja CO_2 iz organske tvari u tlu.

III. Financijski gubitci uzrokovani erozijom tla

Izravne i neizravne negativne posljedice erozije tla uzrokuju svake godine značajne financijske gubitke na globalnoj razini (Kuhlman i dr., 2010; Ionita i dr., 2015; FAO i ITPS, 2015; Borelli i dr., 2017; Panagos i dr., 2018). Prema procjenama godišnji financijski gubitci uzrokovani erozijom tla na svjetskoj razini iznose i do 400 milijardi $ godišnje (FAO i ITPS,

2015; Borelli i dr., 2017), dok na razini Europske Unije samo gubici prouzrokovani erozijom tla uzrokovanom djelovanjem vode iznose do 20 milijardi $ godišnje (Panagos i dr., 2015c). Međutim, treba napomenuti da procijenjeni iznosi financijskih gubitaka znatno variraju, ovisno o izravnim i neizravnim posljedicama koje su uzete u obzir prilikom izrade procjena (Telles i Dechen, 2011), ali i o fizičko-geografskim i socio-ekonomskim značajkama određenog područja (Enters, T., 1998).

Na slici 13. dana je usporedba država EU prema procijenjenom godišnjem utjecaju erozije tla na smanjenje BDP-a.

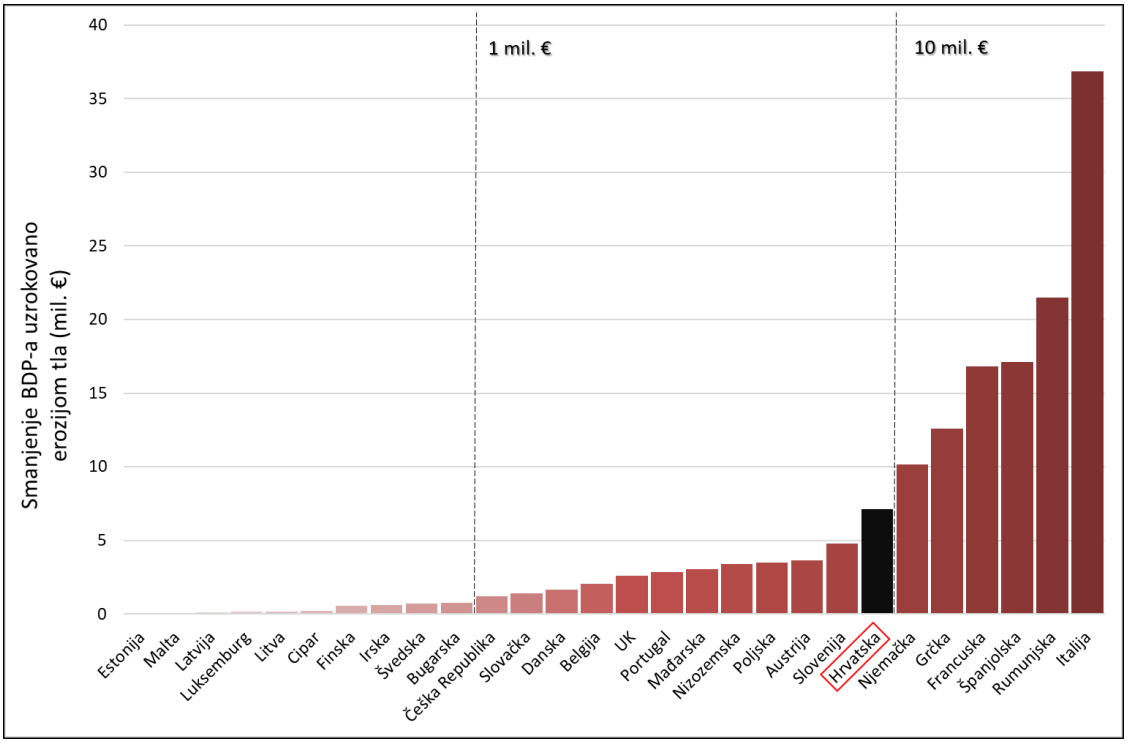

Slika 13. Usporedba godišnjeg smanjenja BDP-a (mil. €) uzrokovanog erozijom tla unutar EU (*preuzeto iz* Panagos i dr., 2018)

Hrvatska spada među najugroženije države Europske Unije, u kojoj prema procjenama erozija tla osim na smanjenje poljoprivredne proizvodnje (10.78 mil. €) i gubitak produktivnosti tla (0.72 %), utječe i na znatno smanjenje bruto domaćeg proizvoda (7.1 mil. €) (Panagos i dr., 2018).

2.1.2. Klasifikacija potprocesa erozije tla uzrokovane djelovanjem vode

Erozija tla djelovanjem vode se može podijeliti na različite potprocese (Boardman i Poesen, 2007). Trenutačno su u upotrebi različiti načini klasifikacije različitih erozivnih procesa koji nastaju pod erozivnim djelovanjem vode. U nastavku je dan pregled različitih tipova

procesa erozije tla uzrokovanih erozivnim djelovanjem vode, zajedno s odgovarajućim morfološkim oblicima, koji nastaju kao rezultat kontinuiranog djelovanja tog procesa. Pri tome su erozijski procesi i pripadajući morfološki oblici raščlanjeni prema intenzitetu erozije i veličini morfoloških oblika, od manjih ka većim. Općenito moguće je diferencirati sljedeće različite tipove erozijskih procesa uzrokovanih erozivnim djelovanjem vode:

I. Erozija kišnim kapljicama

Erozija kišnim kapljicama (EKK) (engl. *splash erosion*; *raindrop erosion*) predstavlja inicijalni oblik erozije tla vodom, kod kojega do erozivnog djelovanja dolazi uslijed udaranja kišnih kapi u površinski sloj tla (SSSA, 2008; Bashir i dr., 2018). Prilikom udara u površinski sloj tla kišne kapi uništavaju površinsku strukturu tla i utječu na pomicanje čestica tla, pri čemu udari kišnih kapi mogu pomaknuti čestice tla i preko 0.6 m od mjesta udara (SSSA, 2008). Iako ovaj oblik erozije intenzitetom ne utječe na odnošenje znatnijih količina tla, itekako utječe na inicijalnu dekonsolidaciju površinske strukture tla, čime tlo postaje podložnije daljnjem erozivnom djelovanju različitih prirodnih i/ili antropogenih erozivnih agensa.

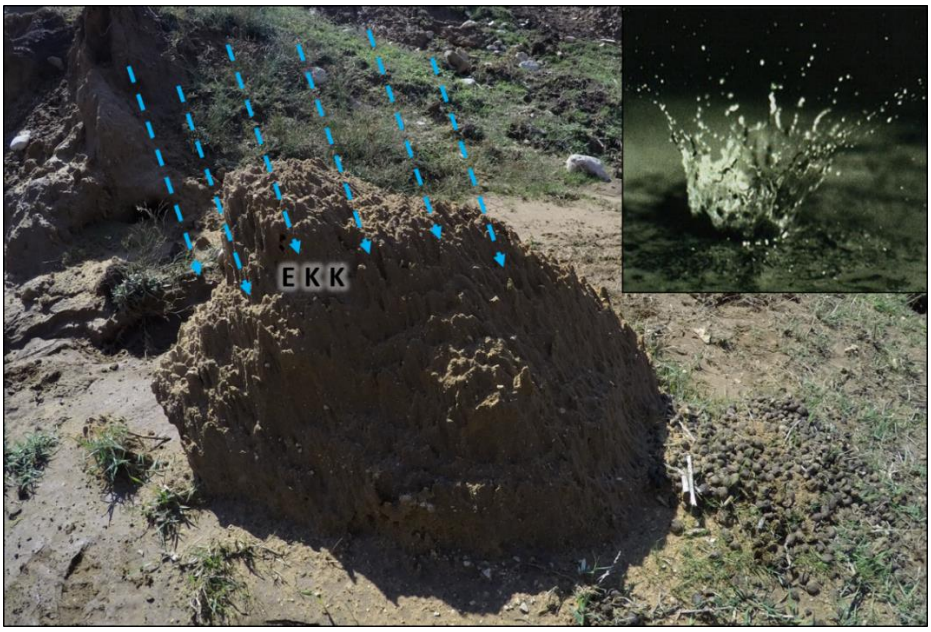

Slika 14. Formiranje subcentimetarskih udubljenja pod utjecajem EKK u izloženim naslagama tla unutar jaruge Santiš

II. Spiranje

Spiranje (engl. *sheet wash*) predstavlja proces trošenja i odnošenja tankog površinskog tla pod utjecajem kontinuiranog plošnog površinskog otjecanja po površini padine, pri čemu

intenzitet otjecanja nije dovoljno jak i usmjeren da bi došlo do nastanka brazdi i/ili jaruga (Benac, 2016).

Erozija kišnim kapljicama i spiranje mogu imati značajniji utjecaj na erodiranje površinskih slojeva tla nakon dužih perioda suše, kada uslijed isušivanja tla dolazi do pojave **krustacije** (engl. *soil crusting*), odnosno procesa stvrdnjavanja površinskog sloja tla i formiranja kore, debljine od nekoliko mm do nekoliko cm (Boardman i Poesen, 2007). Naime, takav stvrdnuti i ispucali površinski sloj tla onemogućava značajnije poniranje vode, zbog čega nastaje jače površinsko otjecanje koje lako odnosi razlomljenu koru (Morgan, 2009). Pojava krustacije zabilježena je i na prostoru otoka Paga, unutar prostora obuhvaćenog terenskim istraživanjima, te je vrlo vjerojatno da do značajnije erozije dolazi nakon izraženog ljetnog sušnog razdoblja.

Slika 15. Pojava krustacije na prostoru gornjeg čela jaruge Santiš (GH-2) (19.06.2020.)

III. Brazdanje

Brazdanje (engl. *rill erosion*; *rilling*) predstavlja proces postupnog odnošenja površinskog sloja tla uslijed koncentriranog linearnog površinskog otjecanja vode niz padinu. Kontinuiranim

djelovanjem brazdanja nastaju izdužene **brazde** (engl. *rills*; *ephermal gully*) u naslagama tla, čija dubina varira od nekoliko cm do maksimalno 30 cm (Benac, 2016).

IV. Jaruženje

Jaruženje (engl. *gullying*; *gully erosion*) predstavlja vjerojatno najreprezentativniji i najproučavaniji oblik erozije tla (Kirkby i Bracken, 2009), koji uzrokuje intenzivno preoblikovanje površinskog sloja tla, uzrokovano periodičkim djelovanjem koncentriranog linearnog površinskog otjecanja vode na kosini (Benac, 2016). Kontinuiranim erozivnim djelovanjem jaruženja na određenoj površini nastaju **jaruge** (engl. *gully*), odnosno izduženi kanali usječeni u podlogu, različitih dimenzija i prostornog obuhvata (SSSA, 2008). Ovisno o intenzitetu i prostornom obuhvatu, jaruge mogu varirati od jednostavnih oblika duljine nekoliko m, pa sve do razgranatih i kompleksnih jaruga, duljine i preko nekoliko km. Prvotno se smatralo da jaruge nastaju postupnim proširivanjem brazdi, no daljnja istraživanja pokazala su da je postanak jaruga rezultat međusobnog djelovanja daleko kompleksnijih procesa (Morgan, 2009). Ono što posebice razlikuje jaruge od drugih erozijskih formi je njihova dubina, koja može znatno nadilaziti 30 cm, odnosno konvencionalnu granicu između brazdi i jaruga, (Castillo i Gómez, 2016.). Iako je nastanak jaruga uvjetovan kompleksnom interakcijom različitih predisponirajućih čimbenika, uz što treba istaknuti veliku važnost mikrolokacijskih utjecaja, generalno se proces nastanka jaruga može podijeliti u sljedećih pet glavnih faza (Sl. 16.) (Morgan, 2009):

a) Uklanjanje vegetacijskog pokrova - u ovoj fazi na određenim lokacijama na padini dolazi do postupnog slabljenja i/ili nestajanja vegetacijskog pokrova uzrokovanog izraženim povremenim površinskim otjecanjem[5]. Pojavom ovakvih "prekida" u vegetacijskom pokrovu naslage tla se izlažu daljnjem erozivnom djelovanju površinskog otjecanja.

b) Formiranje inicijalnog udubljenja – nakon uklanjanja vegetacijskog pokrova naslage tla izložene kontinuiranom erozivnom djelovanju povremenog površinskog otjecanja se znatno brže troše od okolnih naslaga zaštićenih preostalim vegetacijskim pokrovom. Zbog toga postupno dolazi do nastanka inicijalnog udubljenja na mjestu uklonjenog vegetacijskog pokrova.

[5] Uklanjanje vegetacijskog pokrova može biti uzokovano i djelovanjem drugih agensa (npr. ispaša, požari, itd.).

c) Začetak formiranja čela jaruge – daljnjim djelovanjem površinskog otjecanja nastalo udubljenje se postupno produbljuje, pri čemu se formira "stepenica", odnosno skoro vertikalan usjek u padini, poznat kao **čelo jaruge** (engl. *gully headcut*).

d) Početak odronjavanja materijala uz čelo jaruge – daljnjim erozivnim djelovanjem površinskog otjecanja dolazi do postupnog potkopavanja baze čela jaruge i pojave odronjavanja, čime se čelo jaruge postupno postaje sve strmije i veće.

e) Uzmak čela jaruge – kontinuiranim potkopavanjem i odronjavanjem naslaga tla dolazi do postepenog uzmaka čela jaruge uz padinu, koji uvjetuje daljnji "rast", odnosno evoluciju jaruge.

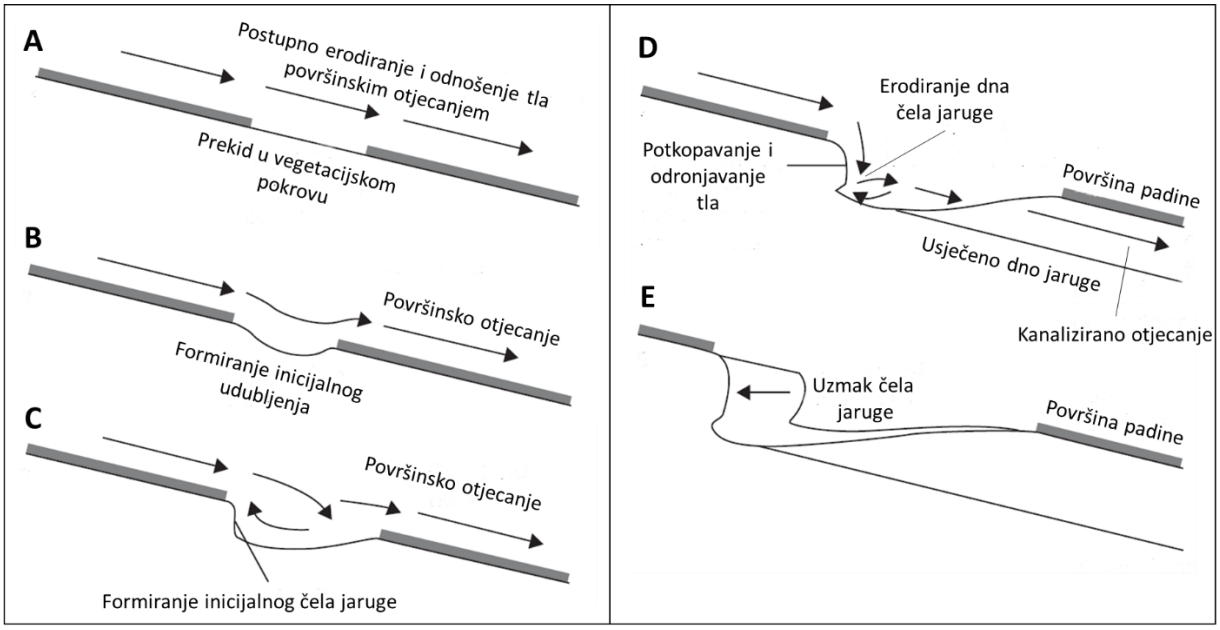

Slika 16. Shematski prikaz pet glavnih faza nastanka jaruga (Morgan, 2009)

Dugotrajnim izraženim djelovanjem jaruženja na određenom području nastaju **ogoline** (engl. *badlands*), odnosno reljef strmih ogoljenih padina, na kojima prevladavaju različiti erozijski potprocesi. Na ogoljenim padinama dolazi do formiranja hidrografske mreže velike gustoće, s brojnim brazdama i jarugama. Uslijed kontinuiranog erodiranja naslaga tla mjestimice može doći do izbijanja stijenske osnove (Benac, 2016.).

2.1.3. Predisponirajući čimbenici erozije tla

Pojavnost i intenzitet erozije tla ovisi o velikom broju različitih prirodnih i antropogenih predisponirajućih čimbenika (Borrelli i dr., 2020). Kada se govori o predisponirajućim čimbenicima koji utječu na pojavu i intenzitet erozije tla na nekom području treba razlikovati erodibilnost podloge i erozivnost različitih egzogenih čimbenika.

I. Čimbenici erodibilnosti podloge

Erodibilnost (engl. *erodibility*) predstavlja podložnost određene podloge (stijene ili tla) djelovanju erozije (Benac, 2016), odnosno otpornost tla trošenju i transportiranju uzrokovanom djelovanjem različitih erozivnih agensa (Lal i Elliot, 1994; Morgan, 2009). Čimbenici koji utječu na erodibilnost određene podloge u prvom redu obuhvaćaju ***svojstva tla*** (npr. struktura tla, poroznost tla, kohezija tla, itd.) te ***prisutnost i razvijenost vegetacijskog pokrova*** (Vanmaercke i dr., 2016). Kohezija tla predstavlja međusobnu povezanost i kompaktnost čestica tla, kao odraza teksture, sadržaja organske tvari i kemijskih značajki tla (Yokoi, 1968), gdje tla s većim stupnjem kohezije generalno karakterizira manja erodibilnost (Poesen, 1992). Prisutnost i razvijenost vegetacijskog pokrova utječu na stabilizaciju i učvršćivanje naslaga tla, gdje vegetacija izravno smanjuje erozivnost različitih egzogenih čimbenika (npr. površinskog otjecanja ili vjetra) (Valentin i dr., 2005; Poesen i dr., 2006; Poesen, 2011; Vannoppen, i dr., 2015).

II. Čimbenici erozivnosti procesa erozije tla

Erozivnost predstavlja sposobnost određenog erozivnog agensa (npr. vode ili vjetra) za uzrokovanje erodiranja i transportiranja čestica tla (Lal i Elliot, 1994). Na erozivnost procesa erozije tla utječu raznovrsni predisponirajući čimbenici koji svojim značajkama uvjetuju pojavnost i intenzitet erozije na određenom području (Valentin i dr., 2010). Različiti predisponirajući čimbenici erozivnosti procesa erozije tla su zasebni predmet proučavanja brojnih znanstvenih istraživanja (Meusburger i dr., 2012). Zbog toga su u nastavku pojašnjeni neki od u literaturi najčešće spominjanih čimbenika, koji su podjeljeni u: ***klimatske čimbenike*** (1) i ***topografske čimbenike*** (2).

Klimatski čimbenici

Određeni aspekti procesa erozije tla prisutni su u praktički svim klimatskim zonama i dijelovima svijeta, među kojima se zbog izražene sezonalne varijabilnosti u količini oborina po ugroženosti ističe prostor Mediterana (Castillo i Gomez, 2016).

Oborine (engl. *rainfall*), odnosno intenzitet oborina smatra se jednim od glavnih klimatskih pokretača erozije tla (Valentin i dr., 2005; Alexakis i dr., 2013; Panagos i dr., 2015a), čiji erozivni utjecaj na pojavnost i intenzitet erozije tla se izražava kroz mjeru prosječne godišnje erozivnosti oborina ((MJ mm ha^{-1} h^{-1} yr^{-1}) (Brown i Foster, 1987. u Panagos i dr., 2015a). Prema erozivnosti oborina[6] cijela Hrvatska, a posebice priobalni prostor unutar kojega se nalazi i otok Pag, može se svrstati među dijelove Europe s najvećom erozivnosti oborina (Panagos i dr., 2015a). Pridoda li se tome izražena sezonalnost oborina na prostoru otoka Paga (Magaš, 2011), s izmjenama dužih suhih i vlažnih perioda, postižu se optimalni uvjeti za pojavu erozije tla (Ballabio i dr., 2017). U sklopu ove doktorske disertacije oborine su klasificirane po intenzitetu (I) korištenjem klasifikacije predložene u Llasat i dr. (2001): *slabe oborine* ($I \leq 2$ mm/h), *umjerene oborine* ($2 < I \leq 15$ mm/h), *obilne oborine* ($15 < I \leq 30$ mm/h), *vrlo obilne oborine* ($30 < I \leq 60$ mm/h) te *bujične oborine* ($I > 60$ mm/h).

Osim oborina, važan klimatski čimbenik je i **vjetar** (engl. *wind*), koji također izravno utječe na pojavnost i intenzitet erozije tla (Morgan, 2009). Otok Pag poznat je po izraženom utjecaju bure, sjeveroistočnog vjetra čiji olujni udari izravno i neizravno utječu na proces erozije tla. Dok se izravni utjecaj erozivnosti bure odražava kroz odnošenje čestica tla s buri izloženih površina, neizravni utjecaj bure se odražava kroz degradaciju vegetacijskog pokrova. Naime, naslage tla na ogoljenim sjeveroistočnim padinama otoka Paga obilježava slabo razvijeni vegetacijski pokrov mediteranskih travnjaka, kojega karakterizira podložnost eroziji tla.

Manje bitan, ali ne i zanemariv klimatski čimbenik je **temperatura zraka** (engl. *temperature*), koja indirektno utječe na erozivnost procesa erozije tla. Naime, visoke temperature u kombinaciji sa sušnim razdobljima mogu dovesti do isušivanja naslaga tla i površinske pojave krustacije (vidi 2.1.2.), oslabljujući time koheziju površinskih naslaga tla. Ovakav utjecaj temperature zraka na naslage tla posebice je učestal na prostoru otoka Paga za

[6] Erozivnost oborina odnosi se na sposobnost oborina da inicira eroziju tla, a izražava se u intenzitetu oborina (mm/h).

vrijeme ljetnih mjeseci (lipanj – kolovoz), kada uslijed visokih temperatura (> 37 ºC) i suše (< 20 mm) dolazi do izražene pojave krustacije (*vidi str.*251.).

Topografski čimbenici

Topografski čimbenici erozivnosti procesa erozije tla obuhvaćaju sve značajke reljefa koje utječu na pojavnost i intenzitet erozije tla, iz kojih je kao ključne topografske čimbenike moguće u prvom redu izdvojiti ***nagib, dužinu i orijentaciju padine*** (Morgan, 2005). Iako postoje osnovne zakonitosti vezane za utjecaj topografskih čimbenika na proces erozije tla, vrlo su bitne i specifične mikrolokacijske značajke.

Nagib i duljina padine izravno kontroliraju brzinu i volumen površinskog otjecanja (Morgan, 2005; Gómez-Gutiérrez i dr., 2015), ali i utječu na razvoj i gustoću drenažne mreže te pojavnost i intenzitet erozije tla (Valentin i dr., 2005; Conforti i dr., 2011). ***Nagib padine*** (engl. *slope gradient/steepnes*) u prvom redu utječe na brzinu površinskog otjecanja, pri čemu se brzina generalno povećava s povećanjem nagiba padine (Morgan, 2005). S druge strane, ***dužina padine*** (engl. *slope lenght*) kontrolira volumen površinskog otjecanja, gdje duže padine generalno imaju veći potencijal za generiranje volumenom izdašnijeg površinskog otjecanja (Morgan, 2005).

Orijentacija padine utječe prvenstveno na varijabilnost različitih klimatskih značajki, poput količine i intenziteta oborina, temperature, ili pak količine sunčevog zračenja) (Dewitte i dr., 2015), što se odražava na razvijenost vegetacijskog pokrova, a zatim neizravno i na pojavnost i intenzitet erozije tla (Morgan, 2005). Također, tome treba pridodati različite mikrolokacijske specifičnosti, poput utjecaja bure na ogoljenost sjeveroistočnih i istočnih padina otoka Paga, ali i na pojavu erozije tla uzrokovane djelovanjem olujnih udara bure.

2.1.4. Specifičnost procesa erozije tla u krškim područjima

Proces erozije tla u krškim područjima je zbog interakcije između naslaga tla i karbonatne krške osnove vrlo kompleksan, koji osim o uobičajenim predisponirajućim čimbenicima (vidi 2.1.3.) ovisi i o specifičnim značajkama krških područja (Dai i dr., 2017; Zeng i dr., 2017; Dai i dr., 2018; Gao i Wang, 2019). Specifičnost procesa erozije tla na krškim područjima najbolje se odražava kroz raznolikost erozijskih oblika koji nastaju na ovakvim područjima, što je vidljivo i na primjeru morfologije čela jaruga evidentiranih tijekom terenskih istraživanja na prostoru poluotoka Santiš (Sl. 17.).

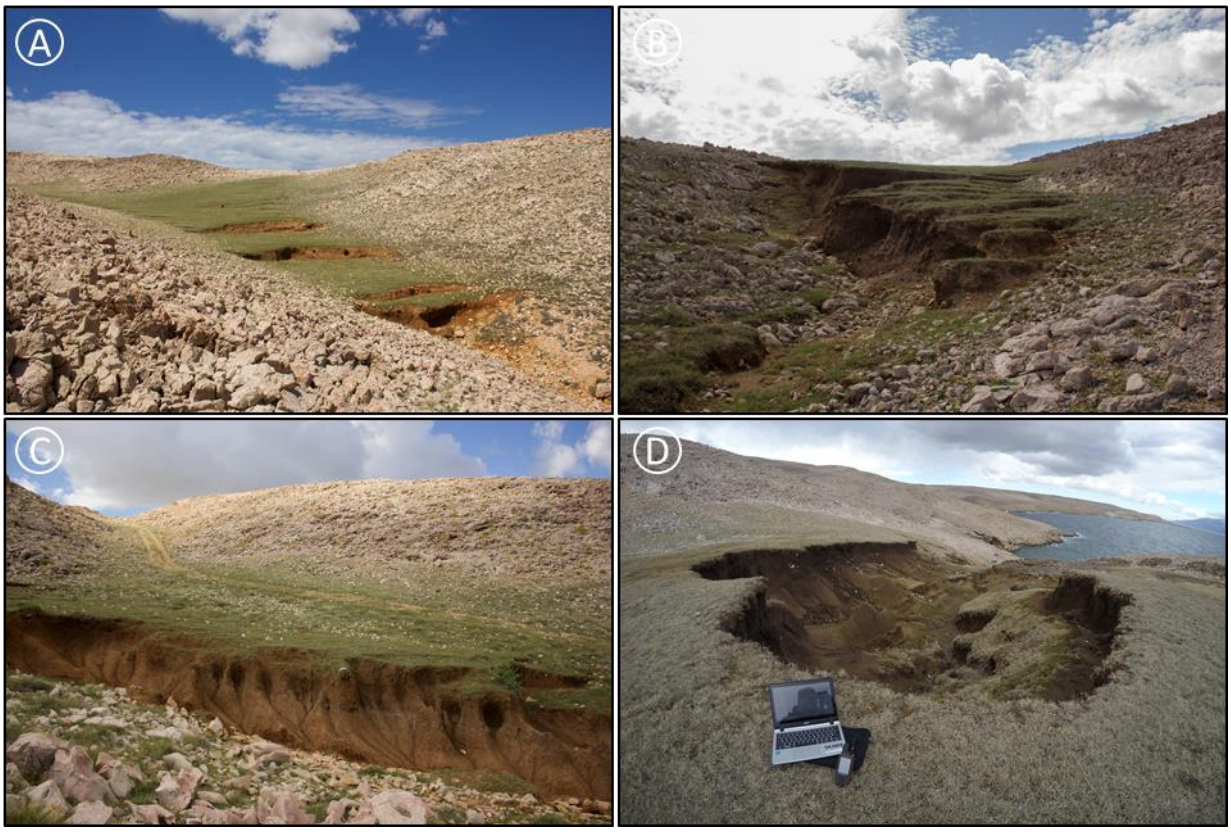

Slika 17. Raznolikost morfologije čela jaruge na prostoru poluotoka Santiš

Kompleksna interakcija između erozije tla i krške osnove može se ogledati kroz:

I. Utjecaj podzemnog otjecanja na eroziju tla

Osnovna značajka krških područja su površinska bezvodnost i izraženo podzemno otjecanje, uzrokovano ispucanošću karbonatne podloge i razvijenom hidrološkom funkcijom brojnih podzemnih pukotina (Ford i Williams, 2013). Razvijeni sustav podzemnih pukotina uvjetuje da se naslage tla ne ispiru samo površinski, izravnim djelovanjem površinskog

otjecanja, već i podzemno, djelovanjem podzemnog otjecanja (Zhang i dr., 2011; Dai i dr., 2017). Ispucala krška osnova omogućava poniranje oborinske vode, zbog čega na krškim područjima podzemno otjecanje može biti jednako, ili čak veće od površinskog otjecanja (Ford i Williams, 2013). Također, sustavi podzemnih pukotina često omogućavaju podzemno otjecanje sa znatno većih površina, pri čemu takvo otjecanje nije ograničeno granicama površinskih topografskih bazena. Izdašnosti i mogući utjecaj na eroziju tla takvog podzemnog otjecanja najbolje je vidljiv na primjeru povremenog izvora, koji se u dnu jaruge Santiš aktivira nakon izdašnijih oborinskih događaja (Šiljeg i dr., 2021). Osim izvora nedaleko od jaruge Santiš primijećeno je i nekoliko vrulja, koje se također aktiviraju nakon intenzivnijih oborinskih događaja (Sl. 18.).

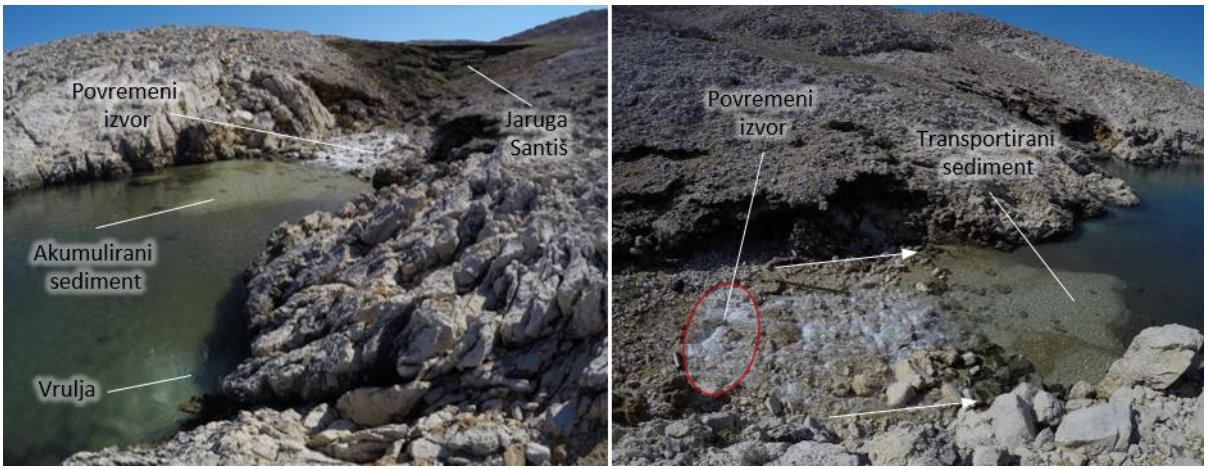

Slika 18. Aktivacija povremenog izvora u dnu jaruge Santiš (žalo) nakon izrazito jakog oborinskog događaja (13. rujna 2017.)

II. Puzanje naslaga tla

Zahvaljujući izraženoj razlici u propusnosti na kontaktu naslaga tla i karbonatne osnove, na krškim područjima često dolazi do pojave puzanja, pa čak i kliženja naslaga tla (Zhang i dr., 2011). Puzanje naslaga tla uvjetovano izraženim podzemnim otjecanjem zabilježeno je i na više lokacija tijekom terenskih istraživanja provedenih na prostoru poluotoka Santiš (Sl. 19.).

III. Pojava selektivne erozije

Erozija tla je selektivan proces, kod kojega je u pravilu intenzitet erozije višestruko veći na podlogama veće erodibilnosti (Lal, 2003; Morgan, 2005). Pojava selektivne erozije posebice je značajna za krška područja, na kojima su česte izmjene slojeva različite erodibilnosti. Pojava

selektivne erozije posebice se dobro vidi na prostoru jaruge Santiš, gdje su erodiranjem mekših dijelova karbonatnih pijesaka i pješčenjaka nastali različiti erozijski oblici (Sl. 20).

Slika 19. Izlomljenost naslaga tla čela jaruge (GH-4) uzrokovana puzanjem tla unutar lokacije Stepeničasta jaruga

Slika 20. Selektivna erozija u središnjem dijelu jaruge Santiš

2.2. Teorijska osnova višerezolucijskog proučavanja erozije tla

Višerezolucijsko modeliranje predstavlja istraživački pristup zasnovan na primjeni različitih geoprostornih tehnologija za proučavanje određenog procesa ili pojave unutar dvije ili više istraživačkih razina, različitog prostornog obuhvata i rezolucije (prostorna, ekonomska, spektralna i vremenska) te različitih ciljeva istraživanja. Osnova višerezolucijskog proučavanja erozije tla su geoprostorne tehnologije, odnosno skup tehnologija koji omogućava modeliranje kompleksnih procesa i oblika različite razine detaljnosti ovisno o svrsi istraživanja (Šiljeg, 2013.). U slučaju većine ranije provedenih znanstvenih istraživanja, koja se bave proučavanjem erozije tla, cilj istraživanja najčešće obuhvaća isključivo jednu razinu istraživanja, odnosno jedan segment procesa erozije tla (npr. detekcija postojećih erozijskih formi, modeliranje podložnosti eroziji tla, kvantifikacija prostorno-vremenskih promjena, itd.) Za razliku od takvih istraživanja, višerezolucijski metodološki pristup omogućava sveobuhvatno i sustavno proučavanje različitih aspekata procesa erozije tla, postižući pritom maksimalnu moguću razinu detaljnosti istraživanja unutar svake pojedine istraživačke razine (Brasington i dr., 2012; Ferrer i dr., 2017.). Kod višerezolucijskog proučavanja erozije tla moguće je izdvojiti sljedeće razine istraživanja: *makro razina*, *mezo razina*, *mikro razina* i *nano razina* (Sl. 21.) (Neef, 1963. u Schmidt, 2013.).

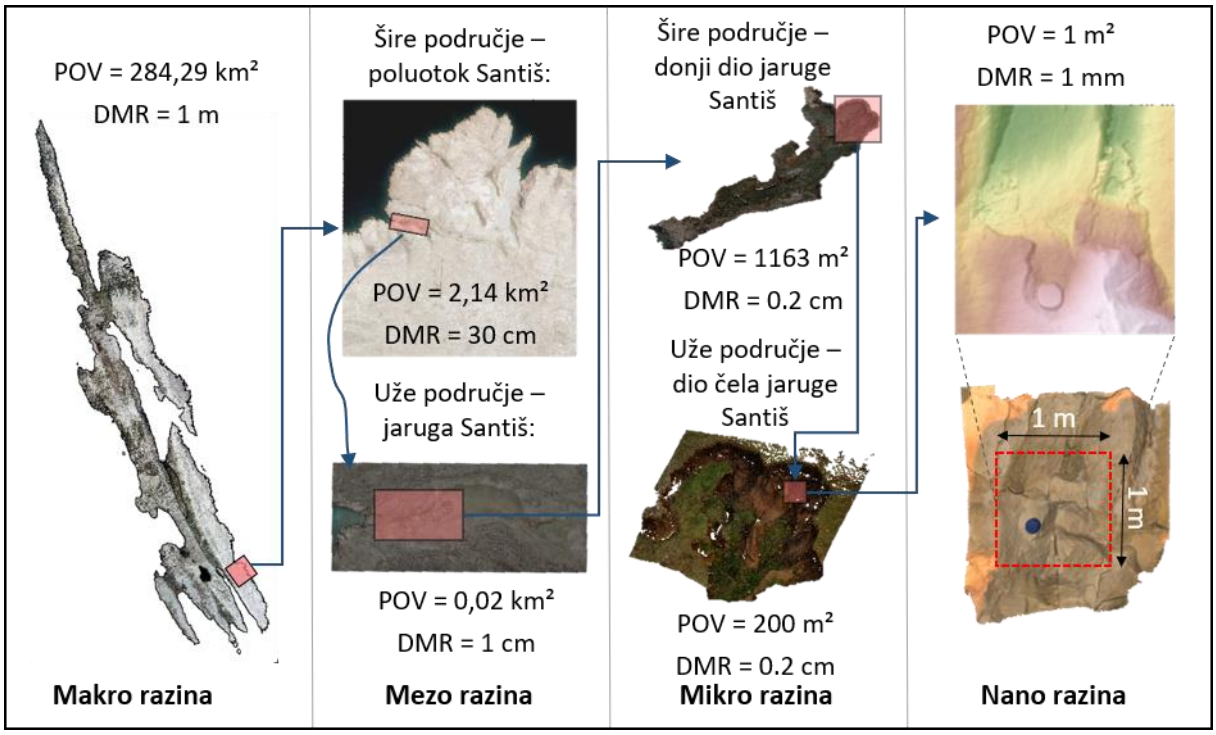

Slika 21. Primjeri različitih razina višerezolucijskog proučavanja erozije tla

U sklopu ove doktorske disertacije predložen je metodološki okvir, unutar kojega se različite geoprostorne tehnologije koriste za ostvarivanje određenih istraživačkih ciljeva, u sklopu tri osnovne razine istraživanja (makro, mezo i mikro) (Sl. 21.). Predložene razine istraživanja unutar ove doktorske disertacije razlikuju se prvenstveno po zadanim istraživačkim ciljevima i detaljnosti proučavanja odabranih aspekata procesa erozije tla, te sukladno tome i po primjeni različitih geoprostornih tehnologija i prostornoj rezoluciji izrađenih modela.

Makro razina predstavlja razinu istraživanja unutar koje se određeni aspekti procesa erozije tla proučavaju na regionalnoj razini, gdje regija reprezentira homogeni prostor sa sličnim obilježjima procesa erozije tla (Schmidt, 2013.). U slučaju otoka Paga makro razina obuhvaća čitav prostor otoka, koji se po pojavnosti i značajkama erozije tla značajno razlikuje od okolnog kopnenog prostora (Domazetović i dr., 2019a.). S obzirom da makro razina istraživanja obuhvaća površinom najveće područje (284,29 km^2), ciljevi i metode istraživanja su morali biti prilagođene prvenstveno dostupnim podacima, ali i mogućnostima njihove obrade (Sl. 21.). Površina makro razine prevelika je za terensko prikupljanje podataka, ali i za izradu modela dovoljne rezolucije (prostorne i vremenske) za intervalno praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla. Zbog toga su unutar ove razine primijenjeni dostupni komercijalni satelitski snimci (*Worldview*), koji su omogućili izradu ne-intervalnih modela, prostorne rezolucije od 1 m. Na temelju izrađenih modela provedeno je *modeliranje podložnosti eroziji tla* (C.1), čime je postignut uvid u generalne značajke postojećih erozijskih formi te izdvajanje dijelova otoka podložnijih pojavi erozije tla (C.2).

Unutar mezo razine višerezolucijskih istraživanja proces erozije tla proučava se unutar pojedinih cjelina, poput određenih slivnih područja, koje karakteriziraju iste ili slične značajke procesa erozije tla (Schmidt, 2013.). Unutar ove doktorske disertacije mezo razina istraživanja može se podijeliti na širu i uži mezo razinu. Dok šire područje mezo razine obuhvaća cijeli poluotok Santiš, sa nekoliko odvojenih erozijskih zona (jaruga), uže područje mezo razine obuhvaća jednu jarugu s najizraženijim značajkama procesa erozije tla (jaruga Santiš) (Sl. 21.). Manja površina mezo razine istraživanja omogućila je upotrebu drugih, detaljnijih geoprostornih tehnologija te sukladno tome i postavljanje kompleksnijih ciljeva istraživanja vezanih za izradu intervalnih modela i detekciju PVP. Šire područje mezo razine svojom površinom (2,14 km^2) ipak nadilazi površinu koja bi bila prihvatljiva za provođenje ponovljenih topografskih izmjera detaljnijim metodama, poput TLS-a ili intervalne UAV fotogrametrije. Zbog toga su unutar ove razine intervalni modeli izrađeni na temelju dostupnih

aerofotogrametrijskih snimaka Državne geodetske uprave (DGU). S druge strane, uže područje mezo razine obuhvaća samo jednu jarugu, ukupne površine oko 0,02 km^2, zbog čega je ova razina bila pogodna za provođenje ponovljenih topografskih izmjera uz pomoć intervalne UAV fotogrametrije. Osnovni cilj istraživanja kod oba područja istraživanja mezo razine temelji se na *kvantifikaciji intenziteta prostorno-vremenskih promjena uzrokovanih erozijom tla* (C.3) kroz izradu digitalnih modela diferencije (DMD). Također, unutar užeg prostora mezo razine izvedeno je detaljno kartiranje geoloških značajki odabranog područja istraživanja, pri čemu je cilj bio *ustanoviti utjecaj geoloških i morfometrijskih značajki na intenzitet erozije tla* (C.4.).

Mikro razina istraživanja kod višerezolucijskog proučavanja erozije tla površinom je znatno manja od mezo razine, te najčešće obuhvaća pojedine erozijske oblike, unutar erozijskih većih cjelina (Schmidt, 2013.). Unutar ove doktorske disertacije mikro razina istraživanja se također može podijeliti na šire i uže područje (Sl. 21). Šire područje obuhvaća glavni prostor jaruge Santiš, od glavnog čela jaruge do njezinog završetka (žalo). Kako bi se omogućilo lakše provođenje sličnih istraživanja u budućnosti, osnovni cilj provedenih istraživanja na ovoj razini vezan je za *razvoj metodološkog pristupa za optimizaciju intervalnog praćenja erozije tla korištenjem aerofotogrametrije i terestričkog laserskog skeniranja* (C.5.). U sklopu provedenih istraživanja isti prostor snimljen je s dvije različite geoprostorne tehnologije (UAV fotogrametrija i TLS izmjera), uz korištenje lokalnog koordinatnog sustava, zasnovanog na izradi i korištenju stalnih geodetskih oznaka. Pri tome je u radu razvijen i primijenjen novi metodološki okvir za sustavno provođenje ponovljenih TLS izmjera, koji se sastoji od četiri faze: *izrada plana intervalnih TLS izmjera* (A), *terenska izrada lokalnog koordinatnog sustava* (B), *intervalna terenska laserska izmjera* (C) te *izrada i validacija intervalnih modela* (D). Za uže područje mikro razine istraživanja odabran je manji dio čela jaruge Santiš (200 m^2), unutar kojega je i u sklopu ranijih istraživanja (Domazetović, 2018; Šiljeg i dr., 2021.) zabilježena vrlo intenzivna erozija tla. Unutar ovog prostora korišteni su isključivo podaci prikupljeni u sklopu provedene ponovljene topografska izmjere, zasnovane na intervalnoj primjeni terestričkog laserskog skenera (TLS-a). Detekcija i kvantifikacija PVP unutar odabranog užeg prostora napravljena je na temelju postojećih alata za usporedbu oblaka točaka. Osim toga dio istraživanja bio je vezan i za *razvoj alata za automatsku kvantifikaciju prostorno-vremenskih promjena u čelu jaruge* (C.6.).

Nano razina obuhvaća manje površine (maksimalno nekoliko m^2) unutar kojih se proces erozije tla prati u vrlo kratkim vremenskim intervalima, čime je moguće utvrditi pravilnosti i

odnose između različitih čimbenika koji utječu na intenzitet i pojavnost erozije tla (Schmidt, 2013.). Vrlo malo područje istraživanja omogućava primjenu najveće razine detaljnosti, zasnovane na korištenju geoprostornih tehnologija subcentimetarske rezolucije, poput 3D ručnog skenera. Odabirom odgovarajućih testnih ploha (npr. 1 x 1 m) unutar određenih erozijskih zona (npr. čelo jaruge) i primjenom takvih geoprostornih tehnologija omogućila bi se detekcija i kvantifikacija PVP subcentimetarskog intenziteta. S obzirom da bi testne plohe obuhvaćale vrlo malu površinu (npr. 1 m^2) znatno lakše bi bilo odrediti i pratiti različite čimbenike koji utječu na intenzitet erozije tla (npr. meteorološki uvjeti, značajke tla, itd.). Istraživanja predložena u sklopu nano razine istraživanja nije bilo moguće provesti u sklopu ove doktorske disertacije, prvenstveno radi vremenskih ograničenja i obuhvata makro, mezo i mikro razina istraživanja. Ta će istraživanja zasigurno biti provedena u sklopu daljnjih istraživanja, van ove disertacije. U konačnici je unutar ove doktorske disertacije primijenjen metodološki okvir višerezolucijskog pristupa proučavanju erozije tla zasnovan na korištenju makro (1), mezo (2) i mikro (3) razine istraživanja (Sl. 22.).

Slika 22. Metodološki okvir višerezolucijskog pristupa proučavanju erozije tla zasnovanom na korištenju makro (1), mezo (2) i mikro (3) razine istraživanja

2.3. Primjena suvremenih geoprostornih tehnologija u proučavanju erozije tla

U nastavku je dan pregled različitih ne-destruktivnih geoprostornih tehnologija koje se koriste za poučavanje procesa erozije tla, s posebnim naglaskom na mogućnost izravne primjene te prednosti i nedostatke pojedine tehnologije.

2.3.1 Podatci u otvorenom pristupu

Podatci u otvorenom pristupu (engl. *open-source data*) predstavljaju različite besplatno dostupne izvore podataka prikupljene određenim senzorima iz sfere daljinskih istraživanja (npr. Sentinel, Landsat, ASTER DEM, EU DEM, itd.). Primarne prednosti ovakvih podataka su **ekonomičnost**, te **visoka spektralna i vremenska rezolucija dostupnih podataka** (npr. Sentinel-2 - 13 spektralnih kanala i vremenska rezolucija od 5 dana (Gatti i Bertolini, 2013)). Međutim, zbog **niske prostorne rezolucije** (>10 m) ovakvi podaci pogodni su isključivo za proučavanje generalnih značajki procesa erozije tla unutar vrlo velikih površina makro razine istraživanja (npr. RUSLE (Atoma i dr., 2020; Santarsiero i dr., 2020)). Podatci iz otvorenog pristupa nisu korišteni u sklopu ove doktorske disertacije, jer su za cijelu makro razinu bili dostupni komercijalni satelitski snimci.

2.3.2 Komercijalni satelitski snimci

Komercijalni satelitski snimci (engl. *commercial satellite imagery*) predstavljaju snimke sub-metarske prostorne rezolucije, koje na zahtjev korisnika prikupljaju napredne satelitske platforme (Worldview, Geoeye, Ikonos, itd.) (Shean i dr., 2016). Za razliku od open-source izvora podataka, komercijalne satelitske snimke karakterizira značajno **viša prostorna rezolucija** izvornih podataka (npr. WV-3 – 30 cm) i generiranih modela (npr. DMP – 60 cm), uz zadržavanje **visoke spektralne** i **vremenske rezolucije** (Sl. 24.). Zahvaljujući prosječnom vremenu revizije od svega nekoliko dana (ili čak unutar jednog dana), ovakvi snimci omogućavaju detaljno praćenje određenih aspekata procesa erozije tla, na većim površinama, s vrlo visokom vremenskom, spektralnom i prostornom rezolucijom (Aguilar i dr., 2013a; Barbarella i dr., 2017). Postizanje takve vremenske rezolucije znatno je teže ostvarivo uz pomoć ostalih geoprostornih tehnologija, koje zahtijevaju opsežna terenska istraživanja za svakodnevno prikupljanje podataka (Barbarella i dr., 2017; Boulton i dr., 2018). Glavni nedostaci ovakvih snimaka su prvenstveno **vrlo visoka cijena ovakvih komercijalnih snimaka**, ali i neophodna **zahtjevna predobrada i obrada podataka**. Primjerice, ukupna

komercijalna vrijednost satelitskih snimaka korištenih u sklopu ove doktorske disertacije za prostor otoka Paga iznosi 10 803 $[7]. Uz visoku cijenu i zahtjevnu obradu, nedostatak ovakvih podataka je i nedovoljna detaljnost snimka za proučavanje intenzitetom i obuhvatom manjih **procesa erozije tla.**. Naime, iako ovakvi satelitski snimci omogućavaju izradu modela visoke prostorne rezolucije (do 60 cm), detaljnost takvih modela ipak nije dovoljna za praćenje prostornim obuhvatom manjih potprocesa erozije tla (npr. spiranje, brazdanje, itd.) (vidi 2.4.).

2.3.3 Aerofotogrametrijska izmjera

Aerofotogrametrijska izmjera (engl. *aerophotogrammetric survey*) predstavlja sustavno snimanje iz zraka, koje se unutar RH izvodi mjernom fotogrametrijskom kamerom, prema specifikacijama Državne geodetske uprave definiranim u članku 5. Zakona o državnoj izmjeri i katastru nekretnina (»Narodne novine«, broj 16/07, 152/08, 124/10 i 56/13) (DGU, 2016). Prema navedenim specifikacijama aerofotogrametrijska izmjera se na prostoru RH provodi u mjerilu snimanja ne sitnijem od 1: 15 000, odnosno s prostornom veličinom slikovnog elementa na terenu do 30 cm (GSD ≤ 30 cm), te poštujući pritom sve definirane korisničko-definirane parametre aerofotogrametrijskog snimanja (npr. uzdužni preklop = min 55 %; poprečni preklop = 15 %, itd.) (DGU, 2016). Aerofotogrametrijska izmjera se provodi uz pomoć visokorezolucijske fotogrametrijske multispektralne kamere, postavljene na zrakoplovu, pri čemu nastaju stereo i multispektralni (RGB + NIR) zračni snimci.

Osnovna prednost ovakvih zračnih snimaka je mogućnost izrade intervalnih modela **vrlo visoke prostorne rezolucije (GSD < 30 cm)**, za područja velikog prostornog obuhvata (nekoliko desetaka km^2). Sustavne aerofotogrametrijske izmjere se na prostoru RH provode svakih nekoliko godina, što omogućava izradu intervalnih modela za isto područje s **višegodišnjom vremenskom rezolucijom**. Slični podaci su uspješno korišteni za praćenje višegodišnjih trendova procesa erozije tla u drugim zemljama (npr. Španjolska (Fernández i dr., 2020), Italija ((Aucelli i dr., 2016), itd.), dok u Hrvatskoj puni znanstveni potencijal ovih podataka još uvijek nije u potpunosti istražen i iskorišten.

Nedostaci ovakvih zračnih snimaka su **relativno niska točnost pozicioniranja** (do 0.5 m), te uporaba **različitih visokorezolucijskih fotogrametrijskih kamera**. Naime, iako su za prostor RH dostupni snimci za vremenski period od gotovo 60 godina (1959. – 2018.), njihovo

[7] Okvirna cijena ustupljenih podataka izračunata je na temelju dostupnih cjenika (Landinfo, 2020).

prikupljanje izvršeno je korištenjem različitih fotogrametrijskih kamera. Zbog toga prilikom same obrade snimaka treba voditi računa o tipu i značajkama korištene fotogrametrijske kamere, odnosno o korištenju odgovarajućih kalibracijskih parametara prilikom obrade snimaka u Agisoft Metashape softveru.

2.3.4 Intervalna UAV fotogrametrija

Intervalna UAV fotogrametrija (engl. *repeat UAV photogrammetry*) je specifična grana aerofotogrametrije, zasnovana na primjeni specijaliziranih bespilotnih letjelica, za ponovljeno (intervalno) prikupljanje zračnih snimaka, potrebnih za provođenje različitih mjerenja i istraživanja (Brus i dr., 2014). Primjena intervalne UAV fotogrametrije, u kombinaciji sa suvremenim softverima za procesiranje prikupljenih snimaka s integriranim struktura-iz-pokreta (SfM) i 3D-multiview algoritmima, omogućava izradu digitalnim modela reljefa sub-decimetarske preciznosti (Marzolff i dr., 2011; Peter i dr., 2014; Ouédraogo i dr., 2014).

Prednosti primjene UAV fotogrametrije za provođenje ponovljenih topografskih izmjera su višestruke (Sl. 24.). Osnovna prednost UAV fotogrametrije je njezina **ekonomičnost (1)**. Naime, UAV fotogrametrije predstavlja jeftin i dostupan oblik tehnologije, čija je početna cijena višestruko manja od cijene osnovnih LiDAR sustava (Cook, 2017). Sljedeća bitna prednost je **mobilnost (2)** bespilotne letjelice, koje su znatno pokretnije od terestričkih LiDAR sustava, zbog čega su primjenjivije za snimanje kompleksnih, odnosno raščlanjenijih terena, gdje terenski pristup može biti težak ili čak opasan (Hugenholtz i dr., 2013; Cook, 2017). Prednost UAV fotogrametrije je i u **mogućnosti ponavljanja snimanja (3)** s istim parametrima, čime se osigurava metodološka vjerodostojnost i susljednost provedenih istraživanja (Eltner i dr., 2013). Zahvaljujući različitim dostupnim aplikacijama (npr. Pix4D, DJI GO, DroneDeploy, itd.) snimanje prostora jaruge je moguće gotovo u potpunosti automatizirati, a izrađene misije leta spremiti, kako bi se mogle koristiti pri sljedećem snimanju jaruge.

Osnovni nedostatak UAV fotogrametrije za praćenje trošenja materijala je **utjecaj vegetacijskog pokrova (1)**, koji opstruira direktno snimanje topografije terena (Giménez i dr., 2009; Marzolff i Poesen, 2009; Cook, 2017). Za razliku od laserskih zraka koje imaju mogućnost prodiranja kroz vegetacijski pokrov i snimanja reljefne podloge, fotografije snimljene bespilotnom letjelicom ograničene su na snimanje vršne površine vegetacijskog

pokrova. Zbog toga na područjima s razvijenim vegetacijskim pokrovom model neće predstavljati površinu terena, već površinu vrha vegetacijskog pokrova (Marzolff i Poesen, 2009). Ovaj nedostatak UAV fotogrametrije potvrđen je na slučaju jaruge Santiš, gdje je sezonalni rast mediteranskog čička (lat. *arctium lappa)* utjecao na konačni izlazni rezultat (Sl. 23.). Intervalna UAV fotogrametrija pokazuje određene nedostatke i prilikom primjene za snimanje izrazito kompleksnih i vertikalno raščlanjenih terena, poput **snimanja prevjesnih dijelova terena (2)**. S obzirom da bespilotna letjelica prikuplja fotografije iz ptičje perspektive, prevjesni dijelovi jaruge opstruiraju snimanje dna jaruge, zbog čega može doći do pojave sjene ispod prevjesnog dijela (Marzolff i Poesen, 2009; Stöcker i dr., 2015). Još jedan bitan nedostatak UAV fotogrametrije je njezina izražena **ovisnost o utjecaju meteoroloških čimbenika (3)**, poput vjetra i kiše. Prilikom provođenja snimanja na prostoru jaruge Santiš velik problem su predstavljali specifični meteorološki uvjeti, koji su više puta odgađali zakazana snimanja. Zbog mikrolokacijskih specifičnih značajki jaruge Santiš, koja je izložena učestalim udarima bure istraživanja su nekoliko puta morala biti otkazana nakon samog dolaska na teren.

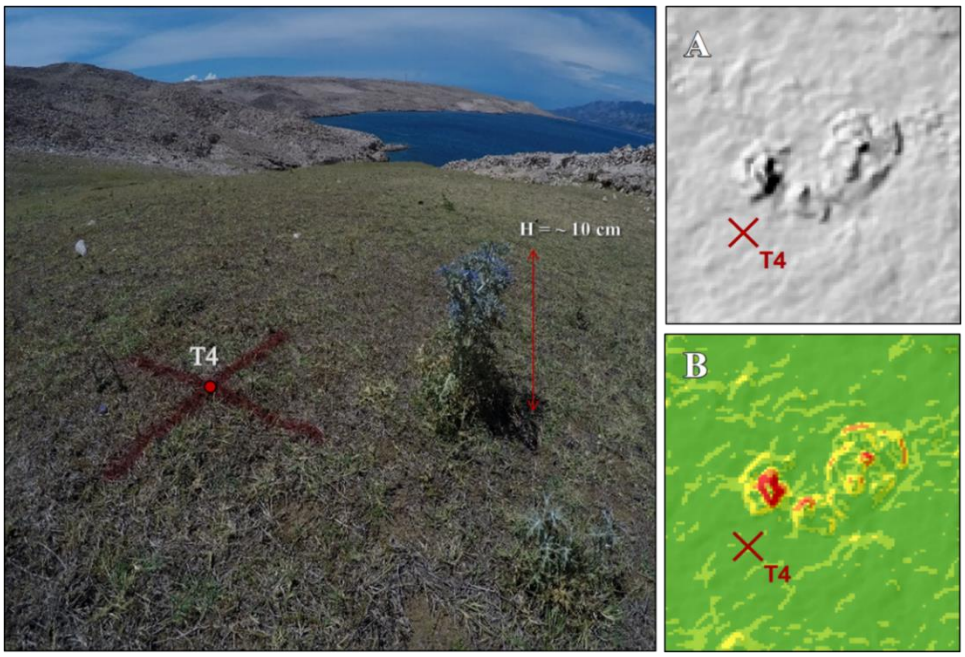

Slika 23. Utjecaj vegetacije na pojavu artefakata na izrađenom DMP-u
(A - artefakti na prikazu reljefa sjenčanjem; B - artefakti na modelu nagiba padina)

2.3.5 Terestričko lasersko skeniranje (TLS)

Terestričko lasersko skeniranje (engl. *terrestrial laser scanning* - TLS) predstavlja jednu od najsuvremenijih tehnika za topografsko modeliranje, koja ima široku primjenu u

različitim geomorfološkim istraživanjima, s posebnim naglaskom na primjenu za detekciju, kvantifikaciju i praćenje različitih prostorno-vremenskih promjena (npr. klizišta (Kromer i dr., 2017), odrona (van Veen i dr., 2017), glacijalne dinamike (Fischer i dr., 2016), vulkanizma (de Zeeuw-van Dalfsen i dr., 2017). Kao takvo, terestričko lasersko skeniranje se godinama uspješno koristi za praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla (npr. praćenje uzmaka čela jaruge (Eltner i dr., 2013; Rengers i Tucker, 2015; Goodwin i dr., 2017), izračun volumena erodiranog materijala (Perroy i dr., 2010; Castillo i dr., 2012; Goodwin i dr., 2017; Taylor i dr., 2018, itd.).

Intervalna TLS izmjera predstavlja ponovljenu topografsku izmjeru, kod koje se TLS primjenjuje za intervalno prikupljanje podataka na određenom području, s ciljem detekcije PVP. Osnovna prednost ovakvih izmjera je **vrlo visoka točnost prikupljenih podataka**, koja nadilazi točnost koju je moguće postići ranije pojašnjenim geoprostornim tehnologijama. Naime, za razliku od ranije pojašnjenih geoprostornih tehnologija koje se zasnivaju na korištenju koordinatnog referentnog sustava, TLS najčešće prikuplja oblak točaka u lokalnom koordinatnom sustavu, postižući pritom centimetarsku točnost pozicioniranja podataka (Altuntas i dr., 2014; Zhang i dr., 2016). Zatim prednost ovakvih izmjera je i **automatizirano prikupljanje oblaka točaka vrlo velike gustoće**. Naime, TLS izmjera omogućava u potpunosti automatizirano prikupljanje velikog broja i gustoće uzoraka, pri čemu brzina prikupljanja podataka iznosi i nekoliko stotina tisuća točaka po sekundi. Također, TLS izmjera pogodna je za **izradu detaljnih 3D intervalnih modela**, odnosno za prikupljanje podataka na vertikalnim dijelovima erozijskih oblika (npr. čelo jaruge), gdje se kod drugih metoda (npr. fotogrametrija) često javlja preuveličavanje ili podcjenjivanje morfologije reljefa.

Nedostaci TLS izmjere su prvenstveno **visoka cijena (ekonomska rezolucija) izmjere** te **dugo trajanje skeniranja**. Naime, cijena TLS izmjere daleko nadilazi cijenu UAV fotogrametrije, ili drugih ranije pojašnjenih tipova geoprostornih tehnologija, zbog čega ova tehnologija često nije dostupna za provođenje istraživanja. Problem dugog trajanja skeniranja posebice je aktualan prilikom skeniranja površinom većih i reljefno kompleksnijih područja, koja zahtijevaju skeniranje s većeg broja stajališta. Konačni nedostatak TLS izmjere je primjena na područjima kompleksne morfologije, gdje zbog raščlanjenog terena često nije jednostavno postaviti i fiksirati stativ ili tronožac s TLS-om na željenu lokaciju.

2.3.6 Ručno 3D skeniranje

Ručno 3D skeniranje (engl. *3D handheld scanning*) predstavlja beskontaktnu metodu prikupljanja podataka koja na temelju kombinacije tehnologije strukturiranog svijetla (engl. *structured light technology*), tehnologije mjerenja faza (engl. *phase measurement technology*) te tehnologije računalnog vida (engl. *computer vision technology*) omogućava prikupljanje detaljne 3D geometrije i teksture određenog oblika ili površine (Wang i dr., 2018; 2019).

Prednosti 3D skeniranje su prvenstveno **milimetarska prostorna rezolucija i točnost izrađenih modela**, gdje je zahvaljujući primjeni ove tehnologije moguće napraviti detaljnije modele i najsitnijih erozijskih formi. Također, vrlo bitna prednost je i **vrlo velika brzina prikupljanja podataka**, pri čemu se prikupljeni podaci automatski prikazuju u stvarnom vremenu (engl. *real-time*) na prijenosnom računalu.

Glavni nedostaci ručnog 3D skeniranja su prije svega kao i kod TLS-a vrlo **visoka ekonomska rezolucija** istraživanja, ali i **ograničenost primjene na manje plohe** (do nekoliko m^2). Također, primjena ručnog 3D skeniranja ovisna je i o vremenskim uvjetima, gdje prekomjerna vlažnost i/ili osunčanost mogu znatno utjecati na proces skeniranja.

	3D skeniranje	Intervalna TLS izmjera	Intervalna UAV fotogrametrija	Aerofotogrametrijska izmjera	Komercijalni satelitski podaci
PREDNOSTI	▪ Milimetarska prostorna rezolucija modela ▪ Milimetarska točnost modela ▪ Brzo prikupljanje podataka i jednostavna izrada modela	▪ Visoka točnost prikupljenih podataka ▪ Automatizirano prikupljanje podataka ▪ Izrada 3D modela → vertikalni dijelovi terena (čelo jaruge)	▪ Brzo automatizirano prikupljanje podataka ▪ Centimetarska točnost izrađenih modela ▪ Automatizirano planiranje intervalnih letačkih misija → ponovljene izmjere	▪ Vrlo visoka prostorna (< 0.5 m) i temporalna rezolucija (niz > 10 god.) ▪ Podaci dostupni za velika područja (nekoliko km²) ▪ Jednostavna i brza obrada	▪ Izrada modela visoke spektralne (8 kanala) rezolucije za vrlo velika (makro) područja (nekoliko stotina km²) ▪ Vrlo visoka vremenska rezolucija → gotovo svakodnevno prikupljanje podataka
NEDOSTACI	▪ Ograničena primjena - plohe manjih dimenzija Ovisnost o vremenskim uvjetima (osunčanost, vlažnost) ▪ Visoka ekonomska rezolucija (cijena)	▪ Otežano snimanje vertikalno raščlanjenih terena i ploha većih dimenzija ▪ Dugo trajanje skeniranja ▪ Visoka ekonomska rezolucija (cijena)	▪ Utjecaj vegetacije ▪ Velika osjetiljivost i ovisnost o vremenskim uvjetima: - Osvjetljenje - Oborine - Vjetar	▪ Podaci prikupljeni različitim aerofotogra-metrijskim kamerama → otežana obrada snimaka ▪ Točnost pozicioniranja unutar 0,5 m	▪ Visoka ekonomska rezolucija (cijena snimaka) ▪ Kompleksna predobrada i obrada satelitskih snimaka → velika količina podataka ▪ Točnost pozicioniranja unutar 5 m

Slika 24. Prednosti i nedostaci ne-destruktivnih geoprostornih tehnologija korištenih u sklopu ove doktorske disertacije za proučavanje erozije tla[8]

[8] 3D skeniranje uz pomoć 3D ručnog skenera nije korišteno u sklopu disertacije, već će biti primijenjeno u sklopu daljnjih istraživanja.

2.4. Razine detaljnosti proučavanja erozije tla

Unutar višerezolucijskog modeliranja geografski prostorni podaci i modeli se izrađuju u različitim mjerilima, ovisno o odabranoj razini detaljnosti (engl. *level of details* - LOD) i raspoloživim sredstvima (ekonomskoj rezoluciji) (Biljecki i dr., 2018), koji pak izravno uvjetuju prostornu, vremensku i spektralnu rezoluciju istraživanja. Odabir optimalne razine detaljnosti istraživanja ključan je za uspješno proučavanje željenih aspekata procesa erozije tla i postizanje postavljenih ciljeva istraživanja (Lu i dr., 2017; Boulton i dr., 2018; Dai i dr., 2019). Unutar višerezolucijskog pristupa proučavanju erozije tla odabrana razina detaljnosti se može izravno povezati s određenom geoprostornom tehnologijom, koja omogućava prikupljanje podataka dovoljne gustoće za postizanje željene razine detaljnosti praćenja određenog segmenta procesa erozije tla (Ferrer i dr., 2017). Pri tome je odnos između prostornog obuhvata određenog erozijskog procesa i gustoće prikupljenih podataka obrnuto proporcionalan, pri čemu je najveća detaljnost istraživanja potrebna kod proučavanja dimenzijama najmanjih oblika. Odnos između pojedine razine detaljnosti proučavanja određenih potprocesa erozije tla i različitih odgovarajućih geoprostornih tehnologija vidljiv je na slici 25.

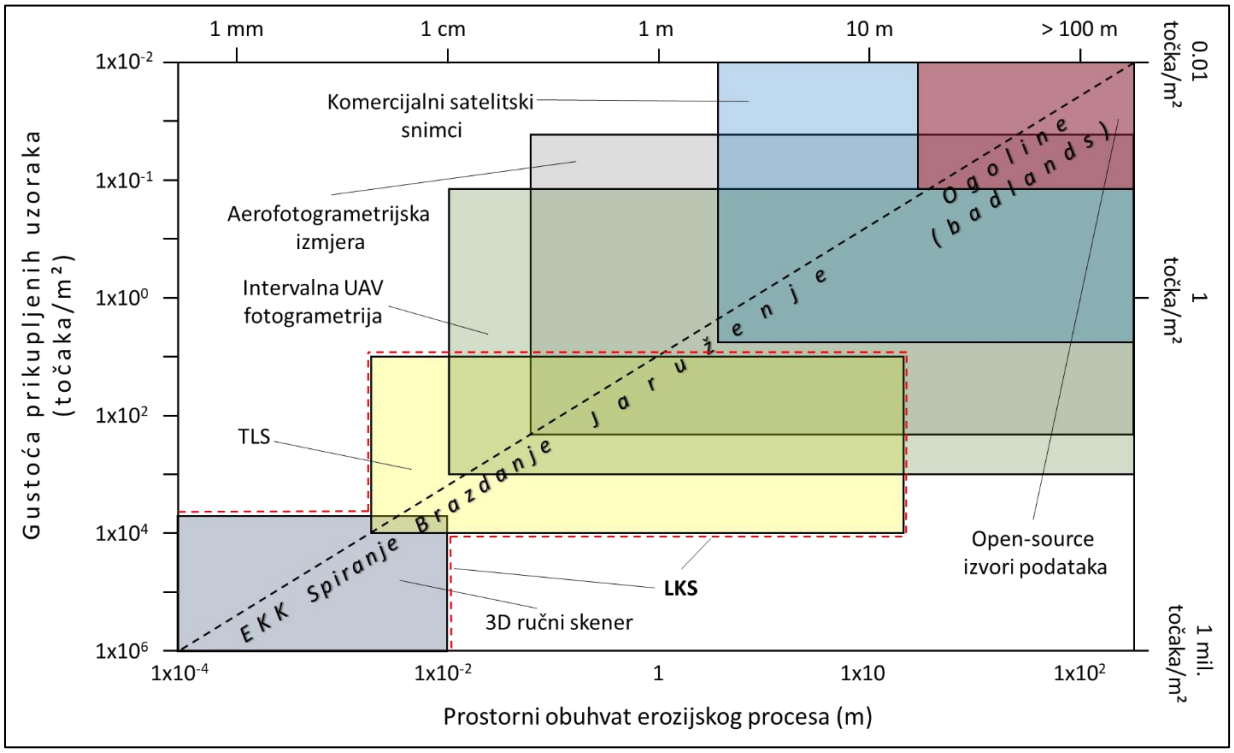

Slika 25. Detaljnost proučavanja erozije tla korištenjem različitih geoprostornih tehnologija (*modificirano prema* Ferrer i dr. (2017) i Brashington i dr. (2012))

U istraživanju erozije tla sukladno željenoj razini detaljnosti i dostupnim geoprostornim tehnologijama moguće je izdvojiti šest različitih razina detaljnosti (Tabl. 1.).

Tablica 1. Predloženih šest razina detaljnosti višerezolucijskog modeliranja erozije tla

Razina detaljnosti	Prostorna rezolucija	Mjerilo podatka[9]	Minimalna širina kartiranja (m)	Minimalna jedinica kartiranja ($m^{2)}$	Potproces erozije tla	Predložena metoda prikupljanja podataka
LOD1	> 10 m	> 1: 20 000	> 20 m	> 100	Ogoline	Open-source DMR i MS snimci
LOD2	1 m – 10 m	1: 2000 – 1: 20 000	2 m – 20 m	1 – 100	Ogoline / Jaruženje	Komercijalni satelitski snimci/ Aerofotogrametrijska izmjera
LOD3	10 cm – 1 m	1: 200 - 1: 2000	20 cm – 2 m	10^{-2} – 1	Ogoline / Jaruženje	Aerofotogrametrijska izmjera / Intervalna UAV fotogrametrija
LOD4	1 cm – 10 cm	1: 20 – 1: 200	2 cm – 20 cm	10^{-4} – 10^{-2}	Ogoline / Jaruženje / Brazdanje	Intervalna UAV fotogrametrija / TLS izmjera
LOD5	1 mm – 1 cm	1: 2 – 1: 20	2 mm – 2 cm	10^{-6} – 10^{-4}	Jaruženje / Brazdanje / Spiranje	TLS izmjera / 3D ručno skeniranje
LOD6	< 1 mm	< 1: 2	< 2 mm	< 10^{-6}	Brazdanje/ Spiranje / EKK	Ručno 3D skeniranje

Razina detaljnosti	Primjer tehnologije	Primjer istraživanja
LOD1	Aster, SRTM, EUDEM, Alos Palsar	Aiello i dr., 2015; Seutloali i dr., 2017; Sepuru i Dube, 2018; Domazetović i dr., 2019a
LOD2	WV-1, WV-2, WV-3, WV-4 / DGU snimci	Campo-Bescó i dr., 2013; Aucelli i dr., 2016; Shruthi i dr., 2015; Conforti i Buttafuoco, 2017
LOD3	DGU snimci / RAPS	Fernández i dr., 2020; Wang i dr., 2016; Liu i dr., 2017; Koci i dr., 2017
LOD4	RAPS / Faro M70	Perroy i dr., 2010; Eltner i dr., 2013; Neugirg i dr., 2016; Koci i dr., 2017; Liu i dr., 2019; Šiljeg i dr., 2021; Cheng i dr., 2019
LOD5	Faro M70 / Artec Eva	Greenbaum i dr., 2020;; Li i dr., 2020
LOD6	Artec Eva	Wang, P. i dr., 2018; 2019b

[9] Mjerilo i minimalna jedinica kartiranja preračunati su iz prostorne rezolucije podataka prema Toblerovom pravilu (Tobler, 1987; 1988).

Najniža razina detaljnosti (LOD1) prikladna je za podatke prostorne rezolucije iznad 10 m, pri čemu je minimalna jedinica kartiranja veća od 100 m^2. Ovakva razina detaljnosti prikladna je za proučavanje isključivo prostornim obuhvatom najvećih erozijskih formi, poput ogolina. Prostorna rezolucija LOD1 razine detaljnosti nije dovoljna za kompleksnije analize, poput detekcije i kvantifikacije PVP, ali je za različite analize regionalnog karaktera, primjerice izradu modela podložnosti eroziji tla (npr. Domazetović i dr., 2019a). S obzirom da se radi o vrlo niskoj razini detaljnosti za izradu potrebnih modela dovoljni su i različiti open-source podaci (npr. DMR (Aster, SRTM, EUDEM, Alos Palsar); MS (Landsat, Sentinel).

LOD2 razina detaljnosti obuhvaća modele prostorne rezolucije od 1 do 10 m, uz minimalnu jedinicu kartiranja od 1 – 100 m^2. Prostorni obuhvat modela LOD2 razine može obuhvaćati i nekoliko stotina km^2. Kao i u slučaju LOD1 razine detaljnosti, LOD2 omogućava proučavanje velikih erozijskih formi, poput ogolina ili većih pojedinačnih jaruga. Uz izradu modela podložnosti eroziji tla, modeli LOD2 razine detaljnosti omogućavaju i objektno-orijentirano kartiranje obuhvata erozijskih formi (d'Oleire-Oltmanns i dr., 2014; Ding i dr., 2020). Primjena LOD2 modela za detekciju i kvantifikaciju PVP je zbog niske detaljnosti vrlo rijetka. Podaci potrebni za izradu modela LOD2 razine detaljnosti uključuju različite komercijalne satelitske snimke (npr. Worldview, Ikonos, Quickbird, itd.), te različite povijesne aerofotogrametrijske snimke (npr. aerofotogrametrijski DGU snimci). Istraživanja provedena unutar makro razine istraživanja ove doktorske disertacije, zasnovana na primjeni Worldview komercijalnih satelitskih snimaka (PR = 1 m) spadaju u LOD2 razinu detaljnosti.

Sljedeća razina detaljnosti (LOD3) predstavlja prijelaz iz generalnih istraživanja LOD1 i LOD2 razine detaljnosti regionalnog karaktera, prema modelima centimetarske i subcentimetarske detaljnosti. Prostorni obuhvat modela LOD3 razine može varirati ovisno o primijenjenoj geoprostornoj tehnologiji od nekoliko km^2 do nekoliko desetaka km^2. LOD3 razina detaljnosti obuhvaća modele prostorne rezolucije od 10 cm do 1 m, pri čemu minimalna jedinica kartiranja varira od 10^{-2} do $1m^2$. Modeli ove razine detaljnosti pogodni su za širok raspon primjena u istraživanju erozije tla. Osim izrade modela podložnosti eroziji tla, te kartiranja obuhvata erozijskih formi, modeli LOD3 razine detaljnosti pogodni su i za detekciju PVP (npr. Aucelli i dr., 2016; Fernández i dr., 2020). Pri tome treba napomenuti da je detaljnost LOD3 modela dovoljna za praćenje generalnih PVP, dok promjene manjeg intenziteta i prostornog obuhvata najčešće nije moguće detektirati. Od geoprostornih tehnologija pogodnih za prikupljanje podataka unutar LOD3 razine treba istaknuti povijesne aerofotogrametrijske

snimke, te UAV fotogrametriju. Istraživanja provedena unutar šireg područja mezo razine istraživanja ove doktorske disertacije, zasnovana na primjeni dostupnih aerofotogrametrijskih historijskih snimaka (PR = 30 cm) spadaju u LOD3 razinu detaljnosti.

LOD4 razina detaljnosti obuhvaća modele prostorne rezolucije od 1 do 10 cm, uz minimalnu jedinicu kartiranja od 10^{-4} do 10^{-2} m^2. Zbog vrlo velike detaljnosti i ograničenja primjene potrebnih geoprostornih tehnologija prostorni obuhvat modela LOD4 razine varira od nekoliko tisuća m^2 do 1 km^2. Primarna primjena modela LOD4 razine detaljnosti je detekcija i kvantifikacija PVP, gdje ovi modeli omogućavaju praćenje intenzitetom i obuhvatom vrlo malih promjena unutar većih erozijskih zona. Tako primjerice modeli LOD4 razine detaljnosti omogućavaju praćenje intenziteta erozije tla unutar različitih tipova geološke podloge u određenoj testnoj plohi (npr. jaruga Santiš). Izrada LOD4 modela zahtijeva primjenu naprednijih geoprostornih tehnologija, poput UAV fotogrametrije i/ili TLS izmjere. Istraživanja provedena unutar užeg područja mezo razine istraživanja ove doktorske disertacije, zasnovana na primjeni intervalne UAV fotogrametrije (PR = 1 cm) spadaju u LOD4 razinu detaljnosti.

LOD5 razina detaljnosti obuhvaća modele prostorne rezolucije od 1 mm do 1 cm, gdje minimalna jedinica kartiranja varira od 10^{-6} do 10^{-4} m^2. Postizanje ovakve subcentimetarske rezolucije modela moguće je isključivo uz primjenu najnaprednijih geoprostornih tehnologija poput intervalnih TLS izmjera, ili 3D ručnog skeniranja. Samim time, prostorni obuhvat modela LOD5 razine varira od nekoliko m^2 do nekoliko stotina m^2. Vrlo visoka detaljnost LOD5 modela omogućava detekciju i praćenje kompleksnih PVP, poput brazdanja i spiranja materijala unutar većih erozijskih zona. Modeli LOD5 razine detaljnosti stoga su pogodni isključivo za područja i istraživanja unutar kojih se želi postići maksimalna detaljnost praćenja PVP. Istraživanja provedena unutar užeg područja mikro razine istraživanja ove doktorske disertacije, zasnovana na primjeni intervalnih TLS izmjera (PR = 2 mm) spadaju u LOD5 razinu detaljnosti.

LOD6 razina detaljnosti obuhvaća modele prostorne rezolucije ispod 1 mm. Trenutačno modele ovakve rezolucije moguće je napraviti isključivo primjenom 3D ručnog skeniranja, pri čemu je prostorni obuhvat istraživanja ograničen na maksimalno nekoliko m^2. Iako su modeli LOD6 razine ograničeni na vrlo mali prostorni obuhvat, njihova detaljnost nadilazi sve ostale razine detaljnosti. Zbog toga je ovakve modele moguće koristiti za proučavanje najsitnijih erozijskih formi i oblika. U sklopu ove disertacije nisu izrađivani modeli LOD6 razine.

2.5. Kvantitativne mjere za praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla

Osnovna kvantitativna mjera vezana za praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla je promjena volumena u naslagama tla na određenoj površini, koja je odraz zajedničkog erodiranja, transportiranja i akumuliranja materijala. Međutim osim volumena (m^3) materijala zahvaćenog djelovanjem erozije tla postoje različite druge specifičnije mjere za praćenje intenziteta erozije tla. S obzirom da je kontinuirani **uzmak čela jaruge** (engl. *gully headcut retreat* - *GHR*) osnovna karakteristika svih aktivnih jaruga, ne čudi da se velik broj znanstvenih istraživanja bavi upravo kvantifikacijom prostorno-vremenskih promjena nastalih postupnim erozivnim djelovanjem na prostoru čela jaruge (Vanmaercke i dr., 2016). Pri tome se najčešće koriste sljedeće kvantitativne mjere za praćenje prostorno-vremenskog uzmaka čela jaruge:

I. Stopa linearnog uzmak čela jaruge

Stopa linearnog pomak čela jaruge (engl. *linear gully headcut retreat rate*) predstavlja linijsku udaljenost (m) unutar koje se čelo jaruge pomaklo duž padine u određenom vremenskom razdoblju (Vanmaercke i dr., 2016). Prema opsežnoj analizi ranije objavljenih istraživanja Vanmaercke i dr. (2016) utvrdili su da stopa linearnog uzmaka čela jaruge varira između 0.01 m i 135.2 m godišnje, dok je srednja vrijednost linearnog pomaka 0.89 m godišnje, a prosječna vrijednost 5.0 m godišnje. Pri tome treba napomenuti da su linearne stope uzmaka čela jaruge izračunate na temelju 822 jaruge, iz različitih dijelova svijeta i različitih klimatskih okruženja.

II. Stopa površinskog uzmaka čela jaruge

Stopa površinskog uzmaka čela jaruge (engl. *aereal gully headcutt retreat rate*) se odnosi na površinski uzmak (m^2) čela jaruge u određenom vremenskom razdoblju (Vanmaercke i dr., 2016). U radu Vanmaercke i dr. (2016) utvrđeno je na temelju 714 jaruga iz različitih dijelova svijeta da stopa površinskog uzmaka čela jaruge varira između 0.01 i 3628 m^2 godišnje, pri čemu srednja vrijednost površinskog uzmaka iznosi 3.1 m^2 godišnje, a prosječna vrijednost 131 m^2 godišnje. Kao i kod podataka o linearnom uzmaku čela jaruge, tako i kod površinskog uzmaka treba uzeti u obzir da se radi o vrijednostima dobivenim korištenjem rezultata istraživanja provedenih u različitim klimavegetacijskim zonama.

III. Stopa volumetrijskog uzmaka čela jaruge

Stopa volumetrijskog uzmaka čela jaruge (engl. *volumetric gully headcut retreat rate*) predstavlja volumetrijski uzmak (m^3) čela jaruge u određenom vremensko razdoblju (Vanmaercke i dr., 2016). Utvrđena stopa volumetrijskog uzmaka čela jaruge izračunata na temelju 672 različite jaruge varira između 0.002 i 47 430 m^3 godišnje, sa srednjom vrijednosti od 2.2 m^3 godišnje i prosječnom vrijednosti od 358.6 m^3 godišnje (Vanmaercke i dr., 2016).

IV. Stopa masenog uzmaka čela jaruge

Stopa masenog uzmaka čela jaruge (engl. *mass gully headcut retreat rate*) predstavlja masu (t) materijala erodiranog uslijed uzmaka čela jaruge u određenom vremenskom razdoblju (Vanmaercke i dr., 2016). Ovaj način praćenja intenziteta erozije tla se rjeđe koristi, prvenstveno jer zahtijeva poznavanje gustoće tla u kojemu je došlo do pojave erozije (Vanmaercke i dr., 2016).

Velika varijabilnost stopa uzmaka koje su utvrdili Vanmaercke i dr. (2016) rezultat je izražene varijabilnosti između različitih predisponirajućih čimbenika, u prvom redu količine i intenzitetu oborina te vrste i sastava tla, u područjima u kojima su provođenja analizirana istraživanja. Primjerice, dok humidna tropska područja karakteriziraju velike količine oborina i izrazito velike stope uzmaka čela jaruga, u semi-aridnim i/ili aridnim područjima količine oborina, ali i stope uzmaka su višestruko manje. Varijabilnost intenziteta erozije tla vidljiva je iz usporedbe značajki i rezultata recentnih relevantnih istraživanja, koja su se bavila primjenom geoprostornih tehnologija za praćenje intenziteta erozije tla (Tabl. 2.).

Tablica 2. Pregled intenziteta erozije tla u relevantnijim recentnim istraživanjima

#	Studija slučaja (Autori)	Površina područja istraživanja (tip erozijske forme)	Količina erodiranog materijala (m^3)	Korištena geoprostorna tehnologija	Vremenska rezolucija istraživanja	Vrsta podloge	Količina oborina (mm) / (Köppen)
1	Cândido i dr. (2020)	530 m^2 (jaruga)	54.22 m^3	Intervalna UAV fotogrametrija	8 mjeseci	Tlo	1,530 (Cw)
2	Fernández i dr. (2020)	7.5 km^2	100 000 (2800 m^3 godišnje)	Aerofotogrametrijska izmjera / aeroLiDAR izmjera	36 godina (1980–2016)	Tlo	/ (Csa)
3	Alfonso-Torreño i dr. (2021)	0.995 km^2 (jaruga)	30 m^3 (9.44 m^3 godišnje)	Intervalna UAV fotogrametrija	34 mjeseci	Tlo (leptosol/ kambisol)	513 mm (Csa)
4	Aucelli i dr. (2016)	4.4 km^2 (ogoline)	6.2 cm godišnje	Aerofotogrametrijska izmjera	49 godina (1954. – 2003.)	Tlo	700 mm (Csa)
5	Stark i dr. (2020)	0.109 km^2 (ogoline)	109 894 m^3 (2747.35 m^3 godišnje)	Aerofotogrametrijska izmjera/ Intervalna UAV fotogrametrija	40 godina (1976. – 2016.)	Tlo	831.2 mm (Csa)
6	Neugirg i dr. (2016)	0.125 km^2 (ogoline)	8700 m^3 (5.3 cm godišnje)	Aerofotogrametrijska izmjera / TLS izmjera	12 mjeseci	Tlo	700 mm (Csa)
7	Gómez-Gutiérrez id r. (2014)	0.995 km^2 (jaruga)	1.15 m^3	Fotogrametrijska izmjera / TLS izmjera	54 dana	Tlo (leptosol/ kambisol)	289 mm (Csa)

3. METODOLOGIJA ISTRAŽIVANJA

3.1. Pregled metodologije makro razine istraživanja

Istraživanja provedena na makro razini istraživanja doktorske disertacije temelje se na korištenju komercijalnih WorldView (u nastavku WV) satelitskih snimaka vrlo visoke prostorne rezolucije. Za potrebe izrade ove doktorske disertacije navedeni satelitski snimci su besplatno preuzeti od američke kompanije DigitalGlobe, kroz stipendiju osiguranu od strane DigitalGlobe fondacije (engl. *DigitalGlobe Fondation*, u nastavku DGF). Sateliti iz WV konstelacije omogućavaju prikupljanje trenutačno najkvalitetnijih komercijalno dostupnih satelitskih snimaka, čija vrlo visoka prostorna, vremenska i spektralna rezolucija omogućavaju primjenu snimaka u širokom spektru znanstvenih područja (Maglione i dr., 2014; Waser i dr., 2014; Alexakis i dr., 2018; Hively i dr., 2019; Wang, S. i dr., 2019; Coffer i dr., 2020; Newall i dr., 2020). U sklopu DGF stipendije su besplatno bili dostupni isključivo arhivski WV satelitski snimci, starosti veće od 90 dana. Zbog izražene razvedenosti i izduženosti (SZ-JI) otoka Paga niti jedan jedinstveni dostupni WV snimak nije obuhvaćao cijelo područje istraživanja. Zbog toga je bilo potrebno naručiti nekoliko snimaka, koji obuhvaćaju pojedine dijelove otoka. Prilikom naručivanja WV satelitskih snimaka vodilo se računa da se snimci pojedinih dijelova otoka međusobno preklapaju te su odabrani samo oni snimci na kojima područje istraživanja nije bilo zahvaćeno oblacima. Satelitski snimci koje je ustupio DGF prikupljeni su različitim satelitima iz Worldview konstelacije, koji prekrivaju znatno veće područje od područja istraživanja ove doktorske disertacije (Sl. 26.).

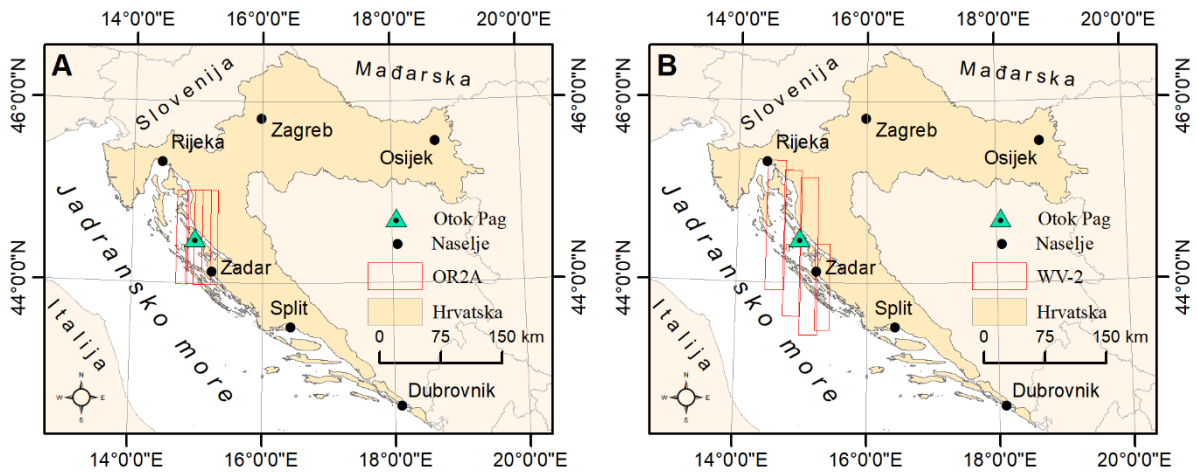

Slika 26. Prostorni obuhvat satelitskih snimaka dobivenih od DGF

(A – OR2A Stereo snimci; B – Standard 2A WV-2 MS snimci)

WorldView-1 satelitski snimci

WorldView-1 satelitske snimke (u nastavku WV-1) prikuplja istoimeni komercijalni satelit u vlasništvu američke kompanije DigitalGlobe. Satelit je lansiran 18. rujna 2007. godine, a opremljen je sa pankromatskim pasivnim senzorom (400-900 nm), koji omogućava prikupljanje snimaka prostorne rezolucije 0.5 m. Za razliku od kasnijih inačica satelita iz Worldview konstelacije, WV-1 nije opremljen senzorima za prikupljanje multispektralnih snimaka. Satelit se kreće u orbiti sinkroniziranoj sa Suncem na visini od 496 km iznad Zemljine površine s ophodnim vremenom od 95 minuta, pri čemu prikuplja i do 1 000 000 km² satelitskih snimaka po danu (Maxar, 2020a). Uz visoku prostornu rezoluciju, WV-1 se ističe i po visokoj vremenskoj rezoluciji, gdje prosječno vrijeme revizije (engl. *average revision time*) iznosi 1.7 dana (Maxar, 2020a). S geolokacijskom točnosti ispod 5 m CE90 i vrlo velikim područjem snimanja (Mono snimak – 112 km x 111 km; Stereo snimak 112 km x 51 km) WV-1 satelit omogućava brzo prikupljanje podataka na velikim površinama. Satelit WV-1 omogućava prikupljanje stereo-parova pankromatskih snimaka, koji se mogu koristiti za stereorestitucijsku obradu i izradu detaljnih DMP-a.

Slika 27. WorldView-1 satelit

WorldView-2 satelitski snimci

WorldView-2 (u nastavku WV-2) satelitske snimke prikuplja komercijalni multispektralni Worldview-2 satelit (Sl. 28.) vrlo-visoke rezolucije, koji u kružnoj orbiti, sinkroniziranoj sa Suncem, kruži oko Zemlje na visini od otprilike 770 km s ophodnim vremenom od 100.2 minute, što omogućuje ovom satelitu da snimi preko 1 000 000 km² Zemljine površine u jednom danu (DigitalGlobe, 2010c; Updake i Comp, 2010; DigitalGlobe, 2018). WV-2 lansiran u listopadu 2009. godine je prvi komercijalni satelit opremljen s visoko-rezolucijskim multispektralnim senzorom s 8 spektralnih kanala. Satelit WV-2 prikuplja podatke u 8 različitih spektralnih kanala i jednom pankromatskom kanalu (Sl. 29.), pri čemu osam multispektralnih kanala (Coastal, Blue, Green,

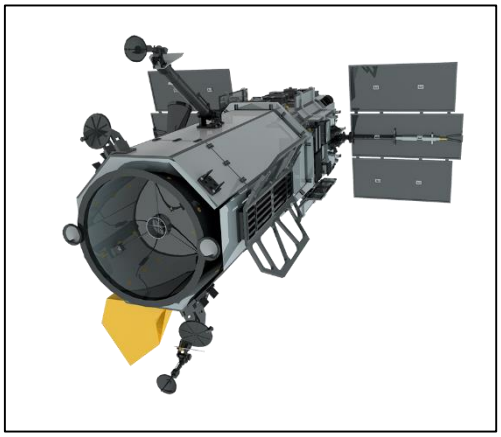

Slika 28. WorldView-2 satelit

Yellow, Red, Red Edge, NIR1 i NIR2) ima prostornu rezoluciju od 1.84 m, dok pankromatski kanal ima prostornu rezoluciju od 0.46 m (DigitalGlobe, 2010c; Maxar, 2020b). Međutim, sukladno regulativi vlade SAD-a prostorna rezolucija komercijalno dostupnih podataka prikupljenih WV-2 satelitom mora biti umanjena na 0.5 m za pankromatski snimak i 2 m za multispektralne snimke (DigitalGlobe, 2010b). Vremenska rezolucija (vrijeme revizije = 1.1 dan) i vidno polje satelita (Mono snimak – 112 km x 138 km; Stereo snimak 112 km x 63 km) su zahvaljujući unaprjeđenju pasivnih senzora i višoj orbiti poboljšani u odnosu na WV-1 satelit, čime se omogućuje još brže prikupljanje veće količine satelitskih podataka.

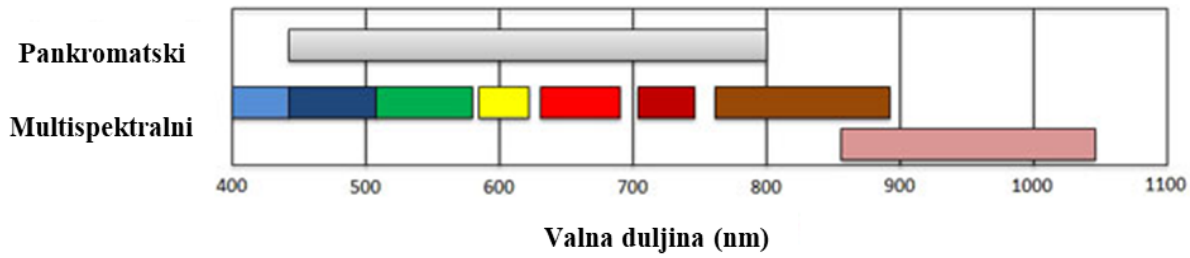

Slika 29. Različiti spektralni kanali WV-2 satelita (Maxar, 2019.)

WorldView-3 satelitski snimci

WorldView-3 (u nastavku WV-3) satelitske snimke prikuplja komercijalni multispektralni Worldview-3 satelit (Sl. 30.), lansiran 13. kolovoza 2014. godine. Trenutačno WV-3 satelit predstavlja najmoderniji komercijalni satelit s najvećim rasponom multispektralnih kanala. Osim pankromatskog kanala prostorne rezolucije 0.31 m, WV-3 satelit prikuplja 8 multispektralnih kanala iz vidljivog i bliskog infracrvenog dijela spektra, prostorne rezolucije 1.24 m, 8 kanala prostorne rezolucije 3.70 m iz kratkovalnog infracrvenog (engl. *shortwave-infrared (SWIR)*) dijela spektra, te 12 CAVIS (engl. *Clouds, Aerosols, Water Vapor, Ice and Snow*) kanala prostorne rezolucije 30 m.

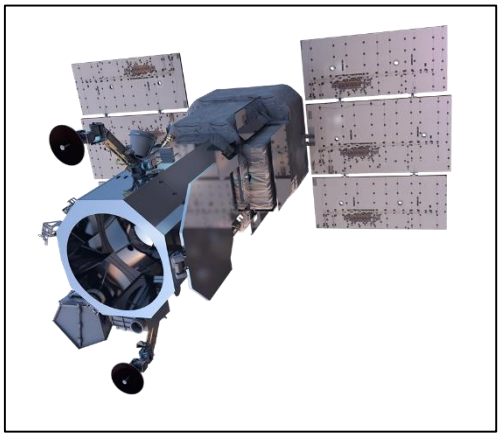

Slika 30. WorldView-3 satelit

WV-3 satelit prikuplja snimke u kružnoj orbiti, sinkroniziranoj sa Suncem, kruži oko Zemlje na visini od otprilike 617 km s ophodnim vremenom od 97 minute (Maxar, 2020c). Vremenska rezolucija iznosi 1 dan, dok vidno polje WV-3 satelita obuhvaća 112 km x 65.5 km kod mono snimaka te 112 km x 26.2 km.

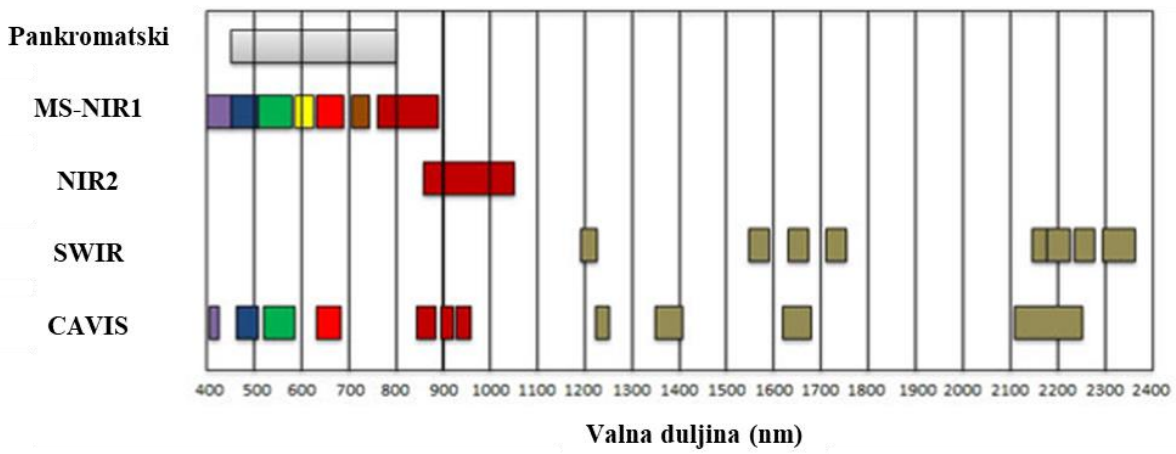

Slika 31. Različiti spektralni kanali WV-3 satelita (Maxar, 2019.)

Isporučeni Worldview snimci

WorldView satelitski snimci isporučuju se, ovisno o primijenjenoj predobradi i korekcijama, u sljedećih 6 različitih osnovnih tipova proizvoda: *osnovni snimci* (engl. *Basic 1B Imagery*) (1), *osnovni stereo snimci* (engl. *Basic (1B) Stereo Imagery*) (2), *standardni snimci* (engl. *Standard 2A Imgery*) (3), orthoready snimci (engl. *OrthoReady (OR2A) Imagery*) (4), orthoready stereo snimci (engl. *OrthoReady Stereo (OR2A Stereo) Imagery)* (5) te *ortorektificirani snimci* (engl. *Orthorectified imagery*) (6) (DigitalGlobe, 2010b).

Osnovni (1B) snimci (1) predstavljaju osnovni satelitski proizvod sa minimalnom primijenjenom predobradom, koja uključuje tek ispravke radiometrijskih i optičkih distorzija te distorzija uzrokovanih unutrašnjom geometrijom senzora. Za razliku od ostalih, naprednijih tipova satelitskih snimaka, 1B snimci nisu georeferencirani, te su zbog toga pogodni za sofisticiranu daljnju predobradu, ali i za korištenje u kompleksnim znanstvenim istraživanjima (DigitalGlobe, 2010b). *Osnovni (1B) stereo snimci (2)* predstavljaju stereo-par osnovnih satelitskih snimaka prikupljenih unutar iste orbite, pri čemu kut prikupljanja snimaka omogućava snimanje istog područja sa dvije različite pozicije sa stopostotnim preklapanjem i vrlo malim vremenskim intervalom između dva prikupljena snimka. Zahvaljujući ovakvom prikupljanju, stereo snimci su pogodni za daljnju stereorestituciju i izradu detaljnih DMP-ova visoke rezolucije (DigitalGlobe, 2010b).

Standardni (Standard 2A) snimci (3) također uključuju ispravke radiometrijskih i senzorski uzrokovanih distorzija, ali su za razliku od osnovnih snimaka georeferencirani uz pomoć određene korisničko definirane geografske projekcije. U slučaju snimaka koje besplatno

ustupa DGF, standardni (2A) snimci se isporučuju u poprečnom Mercatorovom rešetkastom projekcijskom koordinatnom sustavu (engl. *Universal Transverse Mercator* - UTM) zasnovanom na WGS84 geodetskom datumu. Za razliku od ostalih tipova satelitskih snimaka *standardni 2A snimci* dolaze s već primijenjenom topografskom korekcijom, zasnovanom na primjeni DMR-a sitnijeg mjerila za normalizaciju utjecaja reljefa na prikupljene satelitske snimke (DigitalGlobe, 2010b). Iako je na ovakvim snimcima primijenjena topografska korekcija, oni se ne smatraju ortorektificiranim, prvenstveno jer je zbog niske rezolucije intenzitet normalizacije vrlo slab. Također, s obzirom da je na ovakvim snimcima već primijenjena topografska korekcija oni nisu pogodni za daljnju ortorektifikaciju od strane korisnika (Cheng i Chaapel, 2010.).

OrthoReady (OR2A) satelitski snimci (4) sadrže sve značajke kao i Standardni (2A) snimci, međutim nemaju primijenjenu topografsku korekciju zasnovanu na DMR-u sitnog mjerila. Zbog toga su OR2A satelitski snimci pogodni za daljnju obradu i ortorektifikaciju uz pomoć korisničko definiranog DMP-a visoke rezolucije (DigitalGlobe, 2010b). OR2A satelitski snimci su projicirani na konstantnu visinsku bazu, koja je izračunata kao prosjek visine terena unutar određenog poligona (DigitalGlobe, 2010b). Drugi oblik OR2A snimaka su stereo OR2A snimci (5), koji su pogodni za daljnju stereorestituciju i izradu detaljnog digitalnog modela površina. Prednost stereo OR2A snimaka je mogućnost izrade digitalnog modela površina visoke rezolucije, kojega se zatim može koristiti za ortorektifikaciju multispektralnog WV snimka.

Ortorektificirani snimci (6) predstavljaju krajnji, najviše obrađeni tip satelitskih snimaka, koji uz sve ostale, ranije napomenute dijelove procesa predobrade, uključuje i ortorektifikaciju (DigitalGlobe, 2010b).

U okviru DGF stipendije nije bilo moguće naručiti osnovne (1B) WV satelitske snimke, koji bi omogućili veću fleksibilnost procesa predobrade i obrade snimaka. Također, u DigitalGlobe arhivi u vrijeme narudžbe satelitskih snimaka (prosinac, 2018. godine) nije bilo dostupnih stereo multispektralnih snimaka za prostor cijelog otoka. Zbog toga su odvojeno naručeni dostupni OR2A stereo snimci prikupljeni WV-1 i WV-3 satelitima te standardni 2A multispektralni snimci s 8 spektralnih kanala prikupljeni WV-2 satelitom. Ustupljeni OR2A stereo snimci iskorišteni su za izradu DMP-a otoka Paga visoke rezolucije, dok su ustupljeni standardni 2A multispektralni snimci iskorišteni za izradu jedinstvenog multispektralnog

snimka za cijeli otoka Pag. Pregled preuzetih WV snimaka s detaljnim pojašnjenjem tehničkih specifikacija dan je u tablici 3.

Tablica 3. Pregled specifikacija satelitskih snimaka vrlo visoke rezolucije preuzetih od DGF-a

Rd. Br.	Tip snimka	Satelit	PAN	MS	Spektralni kanali	Točnost (CE90[10]/ LE90[11])	Cijena ($/km²)[12]
1.	OR2A Stereo	WorldView-1	0.5 m	-	PAN	5 m	38
2.	OR2A Stereo	WorldView-3	0.3 m	1.2 m	8 MS + PAN	5 m	48
3.	Standard 2A	WorldView-2	0.5 m	2 m	8 MS + PAN	5 m	19

[10] LE90 – devedeset postotna linearna pogreška, gdje najmanje 90% svih vertikalnih pogrešaka spade unutar navedene LE90 vrijednosti.
[11] CE90 predstavlja kružnu pogrešku na 90 percentila, što znači da najmanje 90% svih izmjerenih točaka ima manju pogrešku od navedene vrijednosti.
[12] Vrijednost snimaka je izražene prema cjeniku tvrtke Landinfo za arhivske satelitske snimke (Landinfo, 2020).

3.1.1. Predobrada WV multispektralnih satelitskih snimaka

Predobrada (engl. *preprocessing*) predstavlja skup postupaka čija osnovna svrha je uklanjanje određenih deformacija i distorzija u prikupljenim satelitskim snimcima (Campbell i Wynne, 2011). Satelitski snimci izloženi su različitim deformacijama i distorzijama koje mogu biti uzrokovane različitim čimbenicima, poput topografskih i atmosferskih utjecaja, solarnih uvjeta ili par pogreški uvjetovanih značajkama senzora (Young i dr., 2017.). Minimaliziranje navedenih deformacija i distorzija vrši se prethodnom predobradom satelitskih snimaka, čiji osnovni cilj je smanjivanje neželjenih efekata i poboljšanje ukupne kvalitete izvornih satelitskih podataka. Međutim, predobrada često predstavlja zahtjevan i dugotrajan proces, kojega treba obaviti pažljivo, kako ne bi došlo do pojave korisničko-uzrokovanih pogrešaka. Primijenjena metodologija predobrade standardnih multispektralnih WV-2 snimaka može se podijeliti na sljedeće korake:

Izdvajanje područja istraživanja iz WV-2 snimaka (1)

S obzirom na to da četiri WV-2 multispektralna snimka pokrivaju znatno šire područje od područja istraživanja ove doktorske disertacije, bilo je potrebno ukloniti sve nepotrebne dijelove satelitskih snimaka. Četiri multispektralna WV-2 snimka prekrivaju ukupnu površinu od 12.954,55 km^2, što znatno nadilazi ukupnu površinu područja istraživanja (284,29 km^2). Kada bi se procesi predobrade i obrade WV-2 snimaka izvršili na cijelim snimcima potrebno vrijeme obrade bilo bi znatno veće, nego da se obrada vrši isključivo na onim dijelovima snimaka koji prikazuju područje istraživanja. Zbog toga su četiri originalna WV-2 snimka izrezana prema prostornom obuhvatu otoka Paga. Pri tome je zbog vizualizacijskih potreba prilikom izrezivanja snimaka ostavljena tampon zona od 1000 m oko otoka Paga. Izrezivanjem originalnih WV-2 snimaka ukupna površina snimaka nad kojom će se vršiti predobrada i obrada smanjena je na 494,95 km^2, što predstavlja tek 3.82 % početne površine snimaka.

Izoštravanje WV-2 snimaka (2)

Izoštravanje (engl. *pansharpening*) satelitskih snimaka predstavlja proces spajanja pankromatskih snimaka visoke rezolucije s multispektralnim snimcima manje rezolucije, pri čemu se generira jedinstveni multispektralni snimak, čija rezolucija odgovara rezoluciji pankromatskog snimka (Belfiore i dr., 2016). U slučaju WV-2 snimaka prostorna rezolucija multispektralnog snimka je 2 m, dok pankromatski snimak ima rezoluciju od 0.5 m. Postoje brojne različite metode izoštravanja satelitskih snimaka, koje u konačnici utječu na izgled i kvalitetu izoštrenih snimaka (Belfiore i dr., 2016; 1. Ghahremani i Ghassemian, 2016;

He i dr., 2019; Rajput i dr., 2019). Treba napomenuti da svaka metoda izoštravanja u određenoj mjeri devalvira ulazni multispektralni snimak, prvenstveno kroz deformaciju oblika ili spektralnih vrijednosti originalnog snimka, radi poboljšanja prostorne rezolucije konačnog snimka (Cheng i Chaapel, 2010). Iako je samo za potrebe izoštravanja WV snimaka razvijena posebna metoda Hipersferične prostorne boje (engl. *Hyperspherical Color Space* - HCS) (DigitalGlobe, 2010a), vizualnom usporedbom različitih algoritama za izoštravanje ova metoda se nije pokazala najboljim rješenjem (Sl. 32.). Umjesto navedenog algoritma, za izoštravanje WV-2 snimaka korišten je PANSHARP2 algoritam iz Geomatica 2018 softvera, koji je uzrokovao znatno manju distorziju spektralnih vrijednosti, u odnosu na HCS algoritam i ostale isprobane algoritme (Sl. 32. IHS, HPF).

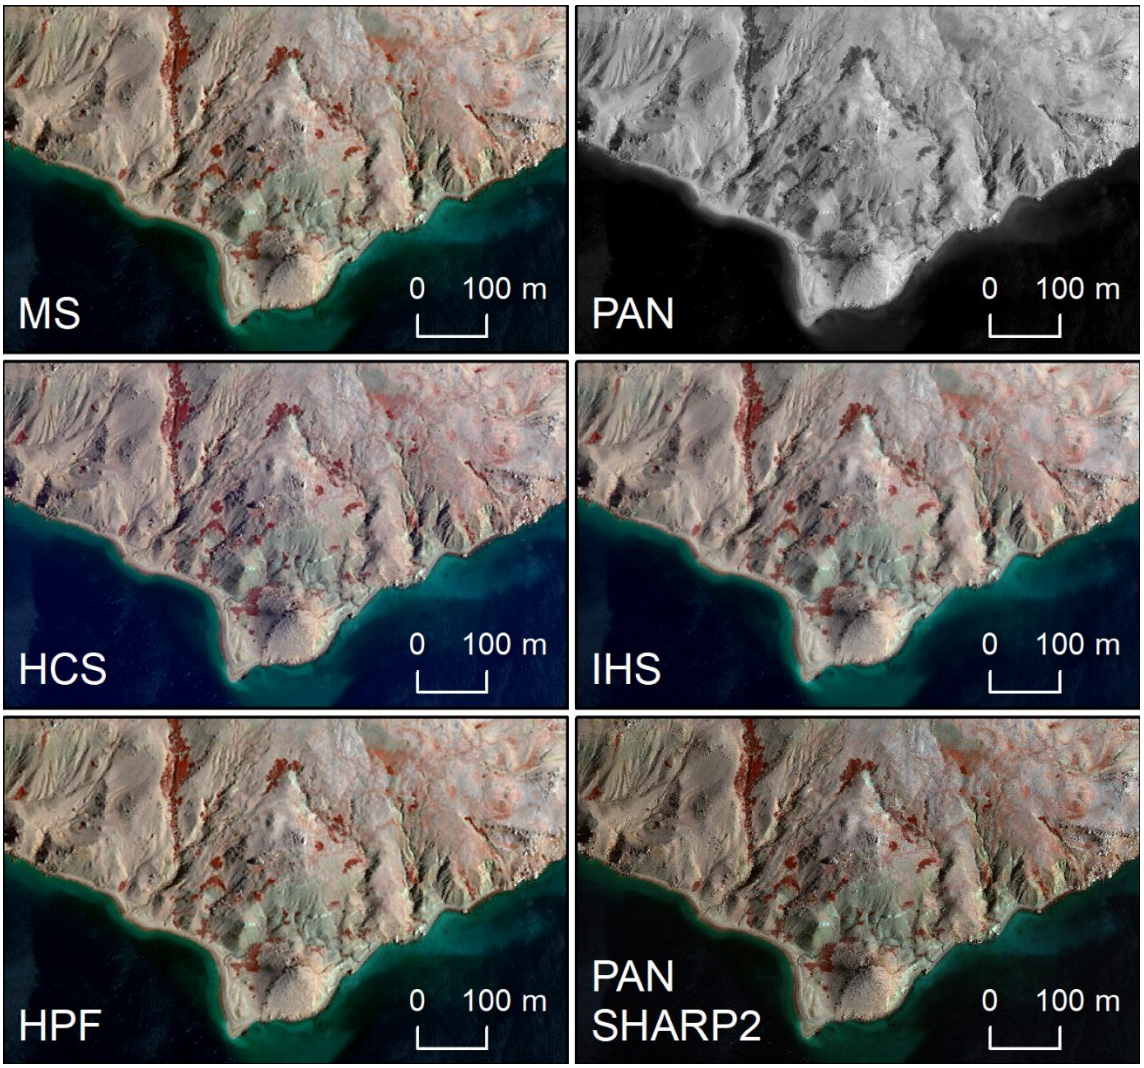

Slika 32. Usporedba različitih algoritama za izoštravanje WV snimaka

Geometrijska korekcija WV-2 snimaka (3)

Geometrijska korekcija (engl. *geometric correction*) predstavlja proces ispravljanja geometrijskih pogreški na satelitskim snimcima, pri čemu se određene značajke sa satelitskih snimaka dovode u odnos sa stvarnim objektima na Zemljinoj površini (Aguilar i dr., 2013b). Prema specifikacijama standardni WV snimci (Standard 2A) imaju geometrijsku točnost od 5 m (DigitalGlobe, 2010b; Aguilar i dr. 2013a). Međutim, prilikom pripreme snimaka za prostor otoka Paga, primijećeno je znatno veće horizontalno odstupanje od navedenih 5 m, posebice na uzvišenim i vertikalno raščlanjenijim dijelovima otoka. Naime, na svim standardnim (Standard 2A) WV snimcima napravljena je automatska korekcija utjecaja terena uz pomoć grubog DMR-a, krupnije prostorne rezolucije. Navedena korekcija uzrokovala je deformaciju pojedinih dijelova snimaka, zbog čega ovaj tip podataka nije pogodan za daljnju ortorektifikaciju (DigitalGlobe, 2010c). Kako bi se minimalizirali učinci primijenjene korekcije, provedena je ručna geometrijska korekcija svih multispektralnih WV snimaka, zasnovana na georeferenciranju multispektralnih WV snimaka preko veznih točaka povezanih s predloškom veće horizontalne točnosti (Sl. 33.). Geometrijska korekcija napravljena je u mjerilu 1: 1000, korištenjem digitalnog ortofoto snimka Državne geodetske uprave (DGU), prostorne rezolucije 0.5 m (DGU, 2018). Ručno dodavanje veznih točaka između predloška (DOF) i WV snimaka izvršeno je korištenjem alata za ručno georeferenciranje snimaka, unutar ArcGIS 10.1 softvera. Za transformaciju WV snimaka prema zadanim veznim točkama korištena je *Spline* transformacija, koja omogućava ispravno uklanjanje neravnomjernih lokalnih geometrijskih distorzija satelitskog snimka, bez mijenjanja globalne točnosti čitavog satelitskog snimka (Zhang i dr., 2016.). Od različitih metoda transformacije implementiranih unutar ArcGIS 10.1 softvera jedino *spline* transformacija predstavlja pravu rubber sheeting[13] metodu transformacije snimaka. Da bi se postigla ravnomjerna prostorna raspodjela veznih točaka unutar čitavog prostora otoka Paga napravljena je mreža kvadrata (engl. *fishnet*), gdje je pri dodavanju veznih točaka unutar svakog kvadrata dodana barem jedna vezna točka (Sl. 33.). Na mjestima gdje su primijećene veće distorzije WV snimaka dodan je veći broj veznih točaka. Također, dodatno su vezne točke progušćene uz obalnu liniju otoka, gdje je maksimalni razmak između dvije vezne točke iznosio 250 m.

[13] Rubber sheeting – odnosi se na postupak kojim se određeni sloj iskrivljuje kako bi se omogućilo njegovo neprimjetno spajanje sa odabranim geografskim slojem (npr. satelitski snimci).

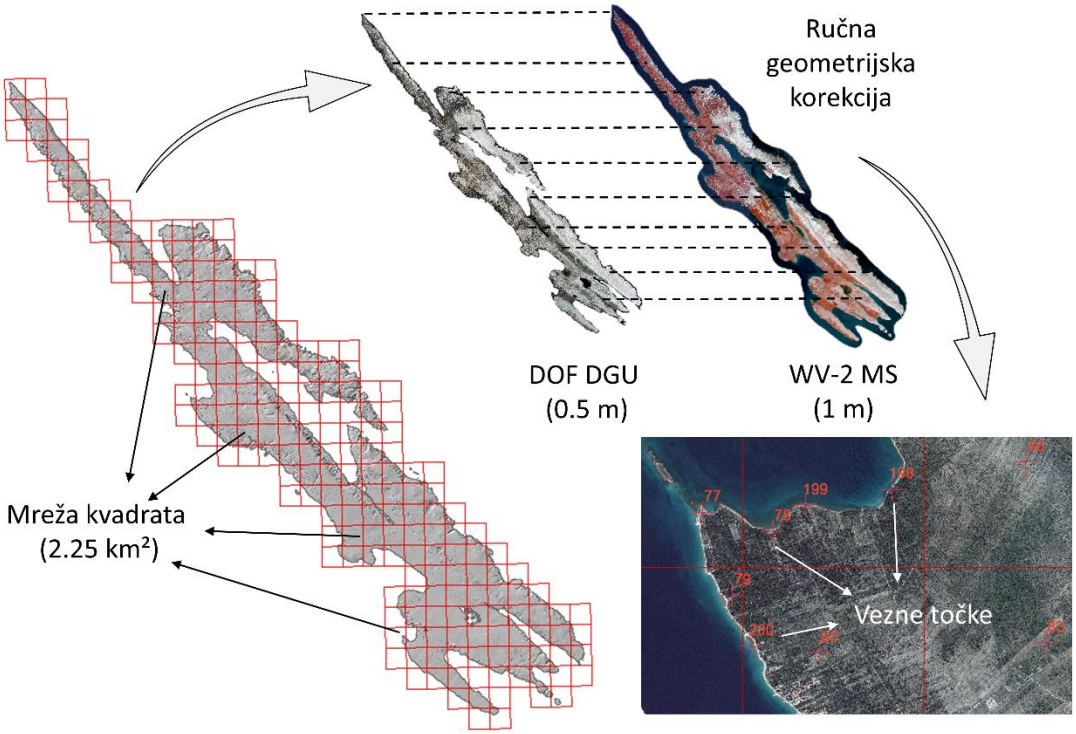

Slika 33. Prikaz procesa ručne geometrijske korekcije WV multispektralnih snimaka

Ručna geometrijska korekcija WV snimaka izvršena je na temelju ukupno 671 vezne točke. distribuiranih ravnomjerno unutar čitavog prostora otoka Paga. Tablični pregled broja veznih točaka iskorištenih za geometrijsku korekciju pojedinog satelitskog snimka dan je u tablici 4.

Tablica 4. Broj veznih točaka iskorišten za geometrijsku korekciju pojedinog WV2 snimka

Naziv	Satelitski snimak	Površina (km²)	Broj veznih točaka	Predložak
PAG - A	WV2-A	1.58	43	DOF - DGU
PAG - B	WV2-B	202.27	289	DOF - DGU
PAG - C	WV2-C	277.43	272	DOF - DGU
PAG - D	WV2-D	12.80	87	DOF - DGU
UKUPNO		494.07	691	-

Spajanje obrađenih satelitskih snimaka (4)

Spajanje (engl. *mosaic*) izoštrenih multispektralnih WV-2 multispektralnih snimaka u jedinstveni snimak koji pokriva prostor cijelog otoka Paga predstavljalo je složen zadatak, prvenstveno zbog velikih spektralnih kontrasta među originalnim ustupljenim satelitskim snimcima. Spektralni kontrasti mogu biti posljedica čitavog niza različitih čimbenika, od razlika u atmosferskim prilikama, položaj satelita prilikom prikupljanja snimka, položaj sunca, doba dana i godine, prisutnost sjena na snimcima, itd. (PCI Geomatics Enterprises, 2018.). U konačnici su korištenjem *Mosaic tool-a* u Geomatica 2018 softveru svi obrađeni WV satelitski snimci spojeni u jedinstveni multispektralni snimak otoka Paga (MS WV) (Sl. 34).

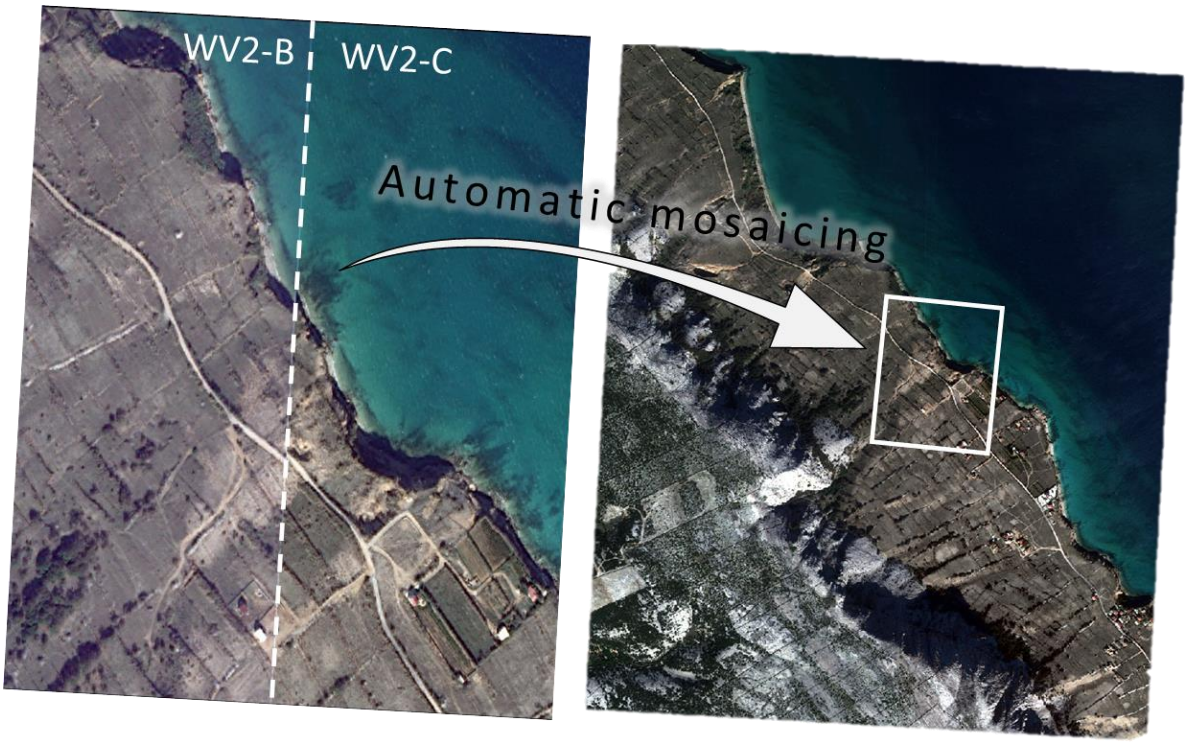

Slika 34. Automatsko spajanje izoštrenih WV-2 multispektralnih snimaka

3.1.2. Izrada digitalnog modela površina otoka Paga iz WV stereo snimaka

Kao što je ranije napomenuto, niti jedan arhivski dostupan par satelitskih WV stereo snimaka nije obuhvaćao cijeli otok Pag. Zbog toga je DMP morao biti izrađen na temelju četiri različita stereo-para satelitskih snimaka. Pregled značajki ustupljenih stereo WV snimaka dan je u tablici 5.

Tablica 5. Specifikacije ustupljenih stereo WV satelitskih snimaka

ID	Stereo par	Tip snimka	Datum prikupljanja	Vremenski period prikupljanja	Off-NADIR (º)	Pokrivenost oblacima (%)
1	WV3-A	Stereo OR2A	04.12.2018.	A – 14:20:46 B – 14:28:40	A – 12.1 B – 27.1	A – 0 B – 0
2	WV1-B	Stereo OR2A	07.12.2015.	A – 12:12:10 B – 12:12:57	A – 16.2 B – 26.3	A – 0.133 B – 0.140
3	WV1-C	Stereo OR2A	28.03.2017.	A – 13:03:08 B – 13:04:01	A – 23.2 B – 22.6	A – 0 B – 0
4	WV1-D	Stereo OR2A	13.09.2016.	A – 12:53:42 B – 12:54:26	A – 25.7 B – 13.4	A – 0.118 B – 0.149
ID	Položaj snimanja	Azimut sunca (º)	Visina sunca (º)	DMR korekcija	GSD (PAN)	GSD (MS)
1	A – Forward B - Backward	A - 157.1 B - 157.6	A – 62 B – 62.1	Stalna visina baze	0.3 m	1.2 m
2	A – Forward B - Backward	A - 199.9 B - 200.1	A - 20.6 B - 20.5	Stalna visina baze	0.5 m	-
3	A – Forward B - Backward	A – 221.1 B - 221.3	A – 41.3 B - 41.2	Stalna visina baze	0.5 m	-
4	A – Forward B - Backward	A – 221.4 B - 221.6	A – 41.5 B - 41.5	Stalna visina baze	0.5 m	-

Dostupni snimci prikupljeni su različitim satelitima (WV-3 i WV-1), u različitim razdobljima (od 2015. do 2018. godine), što je otežalo proces izrade DMP-a. Da bi se minimalizirale moguće pogreške u izrađenom DMP-u prostorna i vremenska rezolucija trebali

bi biti identični kod svih korištenih stereo snimaka. Razlika u prostornoj rezoluciji korištenih snimaka može dovesti do pojave pogrešaka u izrađenom modelu vezanim za nerazmjer u veličini piksela u originalnim stereo snimcima (npr. WV-1 = 0.5 m; WV-3 = 0.3 m). Nadalje, razlika u vremenskoj rezoluciji može uvjetovati pojavu pogrešaka uzrokovanih prostorno-vremenskim promjenama, nastalim na određenom području između vremena prikupljanja dva satelitska snimka (npr. izgradnja antropogenih objekata (kuće, prometnice, industrijska postrojenja, kamenolomi, itd.), različiti prirodni procesi (npr. erozija i akumulacija tla). Svi korišteni stereo snimci su OR2A Stereo tipa, što ih čini pogodnim za daljnju stereorestitucijsku obradu. Iako snimci nisu prikupljeni u isto vrijeme, preklapanje između četiri odabrana stereo-para WV snimaka dovoljno je za izradu kontinuiranog DMP-a cijelog otoka Paga (Sl. 37.).

DMP otoka Paga napravljen je iz ustupljenih WV stereo snimaka u *OrthoEngine 2018* ekstenziji *Geomatica 2018* softvera. Cijeli proces izrade DMP-a u OrthoEngine ekstenziji može se podijeliti u sljedeće korake: odabir matematičkog modela (1), dodavanje orijentacijskih, kontrolnih potrebnih za orijentaciju stereo snimaka (2), dodavanje veznih točaka (3), grupna optimizacija (4), izrada epipolarnog snimka (5), automatska izrada DMP-a (6), ručna filtracija pogrešaka (7) te provjera točnosti modela (8) (Sl. 35.).

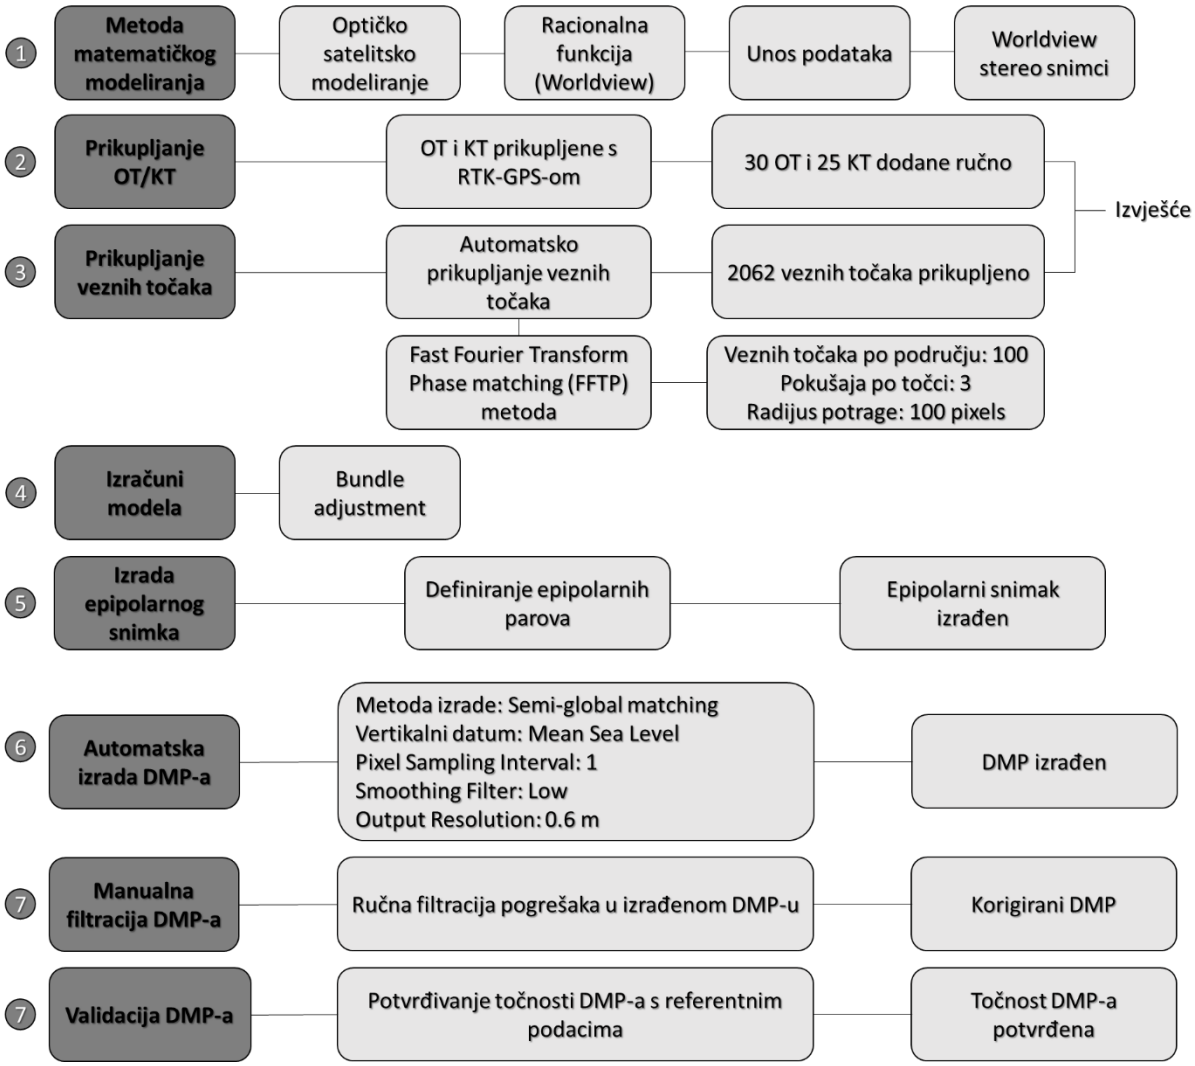

Slika 35. Koraci izrade DMP-a iz WV stereo snimaka uz pomoć Orthoengine ekstenzije

Odabir odgovarajućeg matematičkog modela (1)

Prvi korak izrade DMP-a uključuje odabir odgovarajućeg matematičkog modela (1) koji služi kao matematička osnova za korelaciju dvodimenzionalnih (2D) piksela stereo snimaka sa točnim trodimenzionalnim (3D) lokacijama (*X*, *Y*, *Z*) na Zemljinoj površini (Barazzetti i dr., 2016.). Za odgovarajući matematički model odabrano je *optičko satelitsko modeliranje* (engl. *Optical Satellite modeling*) zasnovano na ustupljenim racionalnim polinomnim koeficijentima (engl. *rational polynomial coefficients* - RPC) i polinomna prilagodba nultog reda (engl. *zero-order polynomial adjustment*), kao jedan od najčešće korištenih matematičkih modela za izradu DMP-a iz WV stereo snimaka (Aguilar i dr., 2013a; Aguilar i dr., 2019; Goldbergs i dr., 2019.).

Dodavanje orijentacijskih i kontrolnih točaka (2)

Da bi se napravio DMP visoke točnosti potrebno je uz ustupljene RPC dodati i integrirati orijentacijske i kontrolne točke (2), čije koordinate su, da bi bile određene sa dovoljnom preciznošću za potrebe istraživanja na makro razini, prikupljene na terenu *real-time kinematic* (RTK) GNSS-om. Orijentacijske točke (OT) (engl. *ground control points* – GCPs) služe za poboljšanje sveukupne točnosti georeferenciranja stereo snimaka, kroz sistematsku kompenzaciju RPC uzrokovanih pogrešaka (Aguilar i dr., 2013a; Goldbergs i dr., 2019.). Za razliku od OT koje se koriste za izračun matematičkog modela, kontrolne točke (KT) (engl. *Check points* – CPs) služe za provjeru točnosti izrađenog modela, pri čemu algoritam provjerava odstupanje između pozicije KT i odgovarajuće pozicije na izrađenom modelu (PCI Geomatics Enterprises, 2018.).

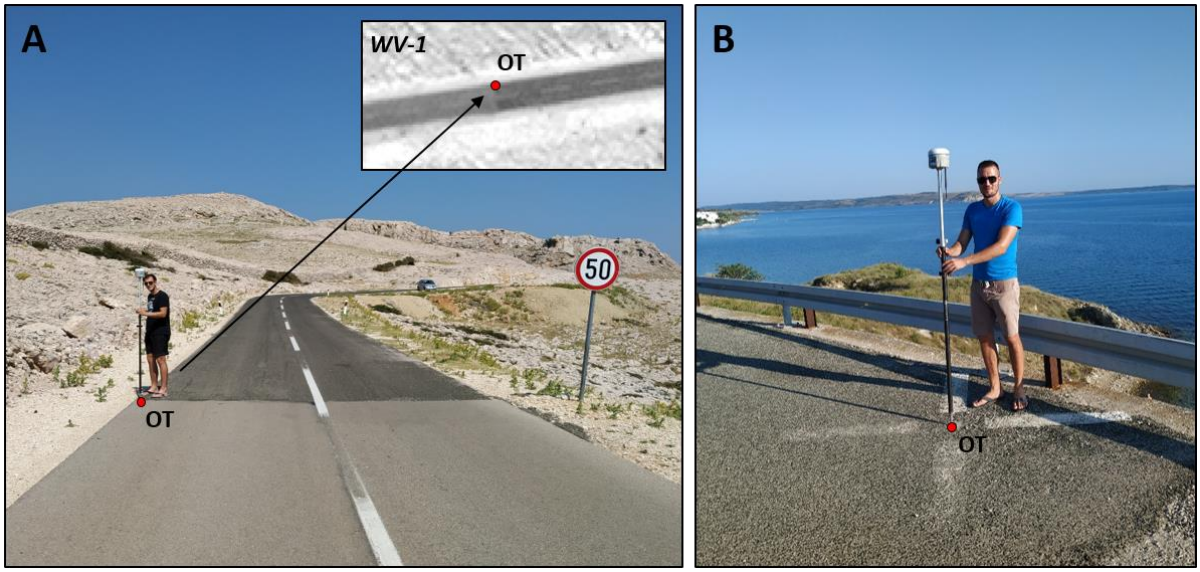

Slika 36. Terensko prikupljanje OT i KT sa Stonex S10 RTK GNSS-om
(A – specifične oznake; B – postojeće geodetske oznake)

Prije terenskog prikupljanja, odabrane su optimalne lokacije za OT i KT na WV stereo snimcima, koje pretežito čine različite specifične oznake (Sl. 36. A) te od ranije postojeće geodetske oznake (Sl. 36. B). Specifične oznake predstavljaju različite elemente krajolika koje je moguće jednostavno i precizno izdvojiti u prostoru, a vidljivi su i prepoznatljivi i na WV stereo snimcima. Uglavnom su kao prepoznatljive specifične oznake korišteni različiti antropogeni elementi krajolika (npr. cestovne oznake, ribarski molovi, kontrasti u asfaltu, itd.) koje je bilo moguće detektirati na WV snimcima te kasnije pronaći i prikupiti precizne *XYZ* koordinate na terenu. Određivanje koordinata OT i KT obavljeno je 6. srpnja 2019. godine RTK metodom, upotrebom GNSS prijemnika Stonex S10, pri čemu su ukupno prikupljene *XYZ*

koordinate na 44 različite lokacije, raspodijeljene po cijeloj površini otoka Paga (Sl. 37.). S obzirom da se Stereo WV snimci preklapaju, pojedine OT i KT iskorištene su na nekoliko snimaka, zbog čega je u konačnici iskorišteno 30 OT i 25 KT.

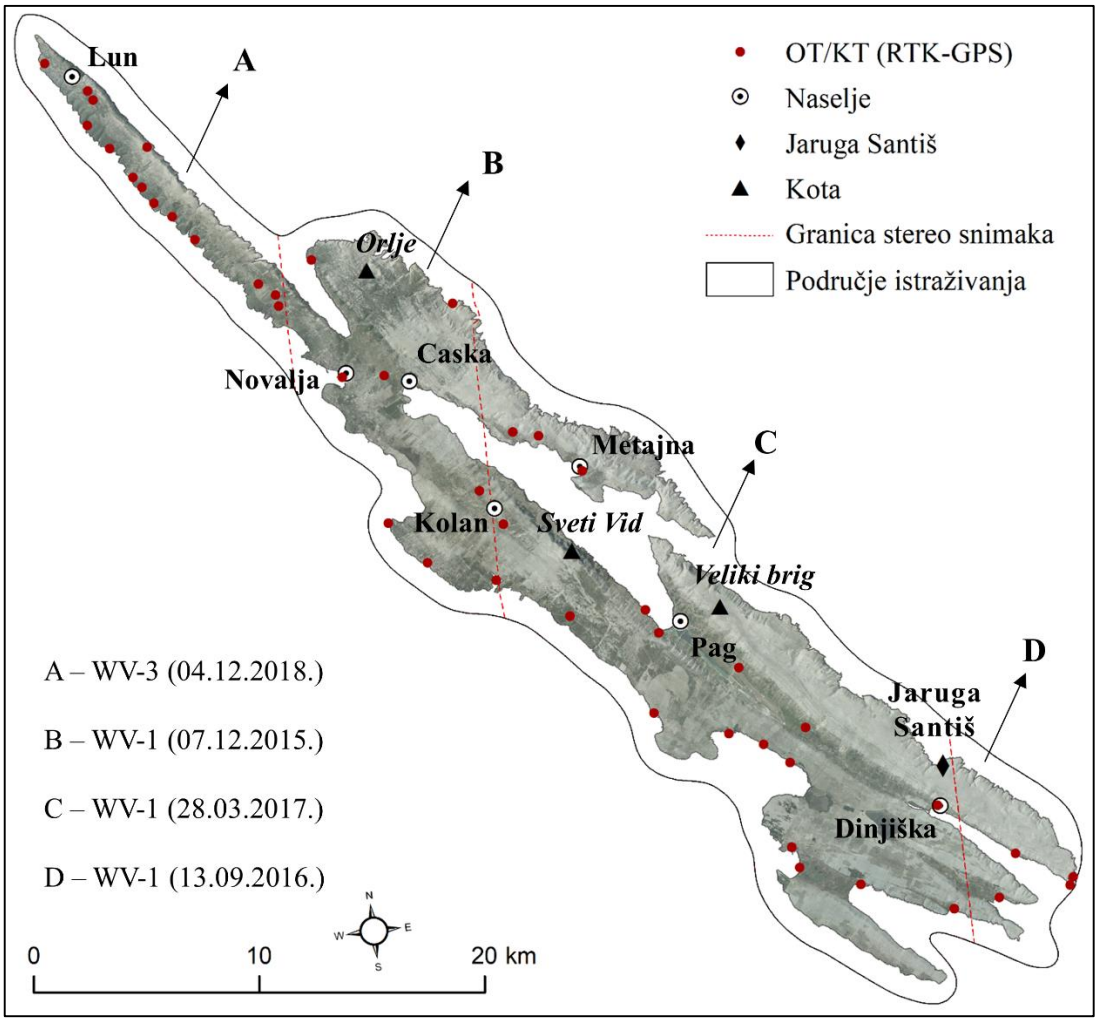

Slika 37. Prostorni raspored korištenih WV snimaka i prikupljenih RTK-GNSS podataka (OT/KT)

Svaki stereo par WV snimaka ima minimalno 7 OT, čime su zadovoljene preporuke dane u istraživanjima koja su proučavala optimalan raspored i broj OT za izradu točnih modela iz WV stereo snimaka (Aguilar i dr., 2013a). U tablici 6. dan je pregled RMSE za korištene OT i KT po pojedinim stereo parovima i ukupno za cijeli izrađeni DMP. Prosječna vrijednosti RMSE za izrađeni DMP iznosi 0.59 m, što je u skladu sa vrijednostima navedenim u sličnim istraživanjima (Hobi i Ginzler, 2012; Aguilar i dr., 2013a; Wang S. i dr., 2019).

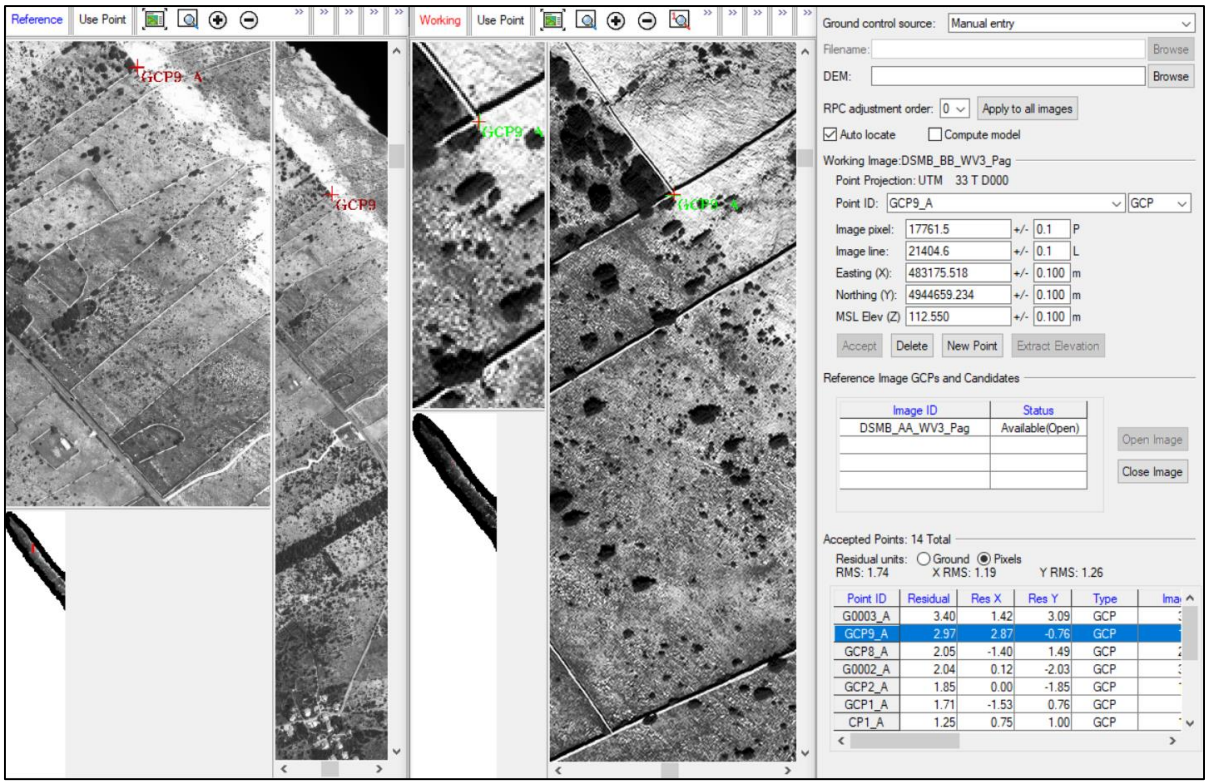

Slika 38. Ručno prikupljanje OT na stereo satelitskim snimcima

Automatsko dodavanje veznih točaka (3)

Nakon dodavanja OT i KT uslijedilo je automatsko dodavanje veznih točaka (engl. *tie points* - TPs), referentnih točaka, koje je moguće jasno detektirati na dva ili više snimka, a služe sveukupnom poboljšavanju međusobnog poravnanja stereo snimaka (PCI Geomatics Enterprises, 2018.). Za razliku od OT i KT, vezne točke nemaju poznate XYZ koordinate, već služe za poboljšanje georeferenciranja snimaka u područjima gdje OT nisu dostupne.

Zahvaljujući implementiranim algoritmima za korelaciju piksela stereo snimaka, Orthoengine omogućava automatsko prikupljanje velikog broja veznih točaka (PCI Geomatics Enterprises, 2018.). Pri tome algoritam za korelaciju snimaka koristi hijerarhijski pristup za pronalaženje odgovarajućih veznih točaka na dva ili više stereo snimka. Automatsko prikupljanje veznih točaka izvršeno je unutar preklopa zadanih stereo snimaka, pri čemu je korištena *Fast Fourier Transfer Phase (FFTP) metoda korelacije snimaka*. U konačnici je ukupno prikupljeno preko 2000 TP. Nakon što su TP automatski prikupljene, uklonjeno je nekoliko desetaka točaka sa najvećim vrijednostima RMSE. Ove točke odnosile su se pretežito na pokretne točke (npr. automobili, brodice, itd.), koje je algoritam za automatsko

prepoznavanje točno detektirao na dva snimka, ali se lokacija ovih točaka u međuvremenu promijenila. Vrijednosti RMSE za prikupljene TP dani su u tablici 6.

Tablica 6. Srednja kvadratna pogreška za OT, KT i TP korištene u izradi DMP-a otoka Paga

Naziv modela	N_0 OT	RMSE X (m)	RMSE Y (m)	RMSE Z (m)	MEAN RMSE (m)
DSM A	7	0.37	0.19	0.50	0.36
DSM B	8	0.53	0.72	0.53	0.59
DSM C	8	0.22	1.46	0.54	0.74
DSM D	7	0.46	0.72	0.94	0.71
UKUPNO	30	0.39	0.77	0.63	0.60
Naziv modela	N_0 KT	RMSE X (m)	RMSE Y (m)	RMSE Z (m)	MEAN RMSE (m)
DSM A	5	0.32	0.52	0.74	0.52
DSM B	7	0.59	0.60	0.49	0.56
DSM C	7	0.70	1.56	0.58	0.94
DSM D	6	0.60	0.95	0.47	0.67
UKUPNO	25	0.55	0.91	0.57	0.68
Naziv modela	N_0 VT	RMSE X (m)	RMSE Y (m)	RMSE Z (m)	MEAN RMSE (m)
DSM A	487	0.07	0.02	0.001	0.03
DSM B	511	0.07	0.02	0.01	0.04
DSM C	467	0.12	0.03	0.02	0.06
DSM D	597	0.06	0.01	0.01	0.03
UKUPNO	2062	0.08	0.02	0.01	0.04

Grupna optimizacija (4)

Nakon ručnog dodavanja OT i KT te automatskog prikupljanja VT slijedi grupna optimizacija modela (engl. *bundle adjustment*). U ovom koraku dodane OT se koriste, zajedno sa geometrijom senzora generiranom iz ustupljenih RPC koeficijenata, za izračun točne pozicije satelita za vrijeme prikupljanja satelitskih snimaka i korekciju poznatih distorzija u s prikupljenim snimcima (Gašparović i dr., 2019.).

Izrada epipolarnog snimka (5)

Sljedeći korak obuhvaća izradu epipolarnog snimka (engl. *epipolar image*), koja reprezentira stereo par snimaka, kod kojega su oba snimka reprojecirana tako da imaju zajedničku orijentaciju i distribuciju duž zajedničke x osi (PCI Geomatics Enterprises, 2018.). Izrada epipolarnog snimka ubrzava cijeli proces korelacije stereo snimaka te smanjuje mogućnost pojave nepodudarnosti među snimcima. Na temelju izrađenog epipolarnog snimka moguće je započeti proces automatske izrade DMP-a.

Automatsko generiranje DMP-a (6)

Na temelju izrađenog epipolarnog snimka izvršen je proces automatskog generiranja DMP-a, koji je unutar Orthoengine ekstenzije Geomatica softvera moguće izvršiti uz pomoć različitih metoda za korelaciju stereo snimaka. Pri tome je korištena metoda polu globalnog usklađivanja (engl. *semi global matching*) DMP-a. Da bi se postigla maksimalna moguća prostorna rezolucija izrađenog DMP-a, interval prikupljanja piksela (engl. *pixel sampling interval*) je podešen na vrijednost 1. Time je korelacija stereo snimaka i izrada DMP-a izvršena sa maksimalnom rezolucijom snimaka, omogućavajući generiranje modela s detaljnim prikazom različitih elemenata DMP-a (npr. vegetacija, zgrade, prometnice, itd.) (PCI Geomatics Enterprises, 2018.). Na temelju podešenih parametara i zadanog epipolarnog snimka izrađen je jedinstveni DMP otoka Paga prostorne rezolucije 60 cm.

Ručna filtracija pogrešaka u izrađenom DMP-u (7)

Zadnji korak vezan za generiranje konačnog DMP-a otoka Paga uključivao je filtraciju pogrešaka prisutnih na izrađenom modelu. Pogreške u izrađenom modelu prvenstveno su se javljale na prostorima prekrivenim vodenim površinama (npr. more, jezera, solane), gdje zbog jednoličnosti površine stereorestitucijski algoritmi OrthoEngine softvera nisu mogli provesti korelaciju i povezivanje piksela WV stereo snimaka. Pojava artefakata i pogrešaka nad vodenim površinama karakteristična je za izradu DMP-a iz stereo satelitskih snimaka, zbog čega je filtriranje vodenih površina dio standardnog procesa post-obrade modela (Poli i Caravaggi, 2012.). Da bi se napravilo uklanjanje pogrešaka u modelu nad prostorima prekrivenim vodenim površinama (Sl. 39.A), bilo je potrebno napraviti Boolean rasterski prikaz svih vodenih površina unutar područja istraživanja. S obzirom da detaljnost dostupnih podataka o vodenim površinama (npr. OpenStreetMap, DGU, itd.) nije bila dovoljna za filtriranje izrađenog DMP-a visoke rezolucije, sve vodene površine su izdvojene iz obrađenog WV-2 MS snimka korištenjem nenadzirane klasifikacije. Kroz nenadziranu klasifikaciju izdvojene su sve klase

koje predstavljaju vodene površine (Sl. 39.B), kojima je zatim kroz reklasifikaciju dodijeljena vrijednost 0. Svim ostalim klasama, koje predstavljaju kopneni dio područja istraživanja dodijeljena je vrijednost 1. Spajanjem izrađenog Boolean prikaza vodenih površina s generiranim DMP-om otoka Paga napravljen je model s uklonjenim artefaktima i pogreškama na područjima prekrivenim vodenim površinama (Sl. 39. C)

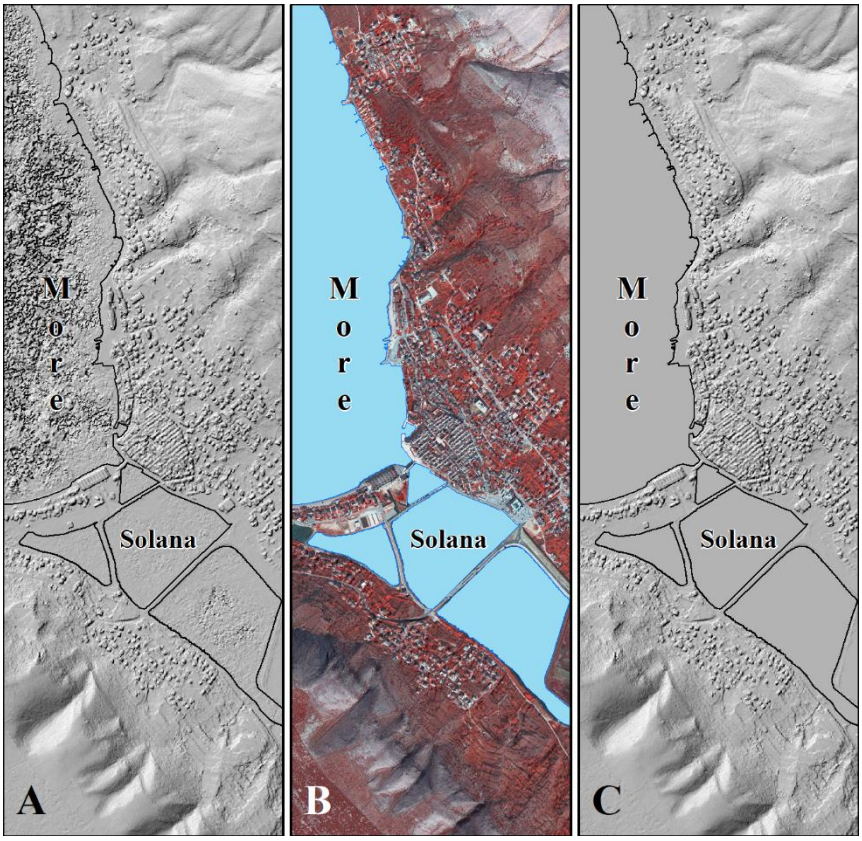

Slika 39. Automatsko uklanjanje artefakata (A) uz pomoć vodenih površina izdvojenih nenadziranom klasifikacijom (B); filtrirani DMP (C)

Nakon filtracije i uklanjanja artefakata nad područjima prekrivenim vodenim površinama, uslijedilo je ručno uklanjanje pogrešaka uzrokovanih pojavom sjena (Sl. 40. A i B) na originalnim WV stereo snimcima te pogrešaka koje su se javile u područjima preklapanja (Sl. 40. C i D). Za razliku od artefakata na vodenim površinama, koji obuhvaćaju kontinuirane dijelove modela, pogreške uzrokovane pojavom sjene ili preklapanjem stereo-parova predstavljaju pojedinačne, prostorno heterogene pogreške, koje nije moguće automatski ukloniti. Zbog toga je primijenjeno ručno uklanjanje pogrešaka uz pomoć filtera za korekciju DMP-a iz *DEM Editing* ekstenzije Geomatica 2018 softvera (Tabl. 7.).

Tablica 7. Filteri korišteni za ručnu korekciju izrađenog DMP-a

#	Filter	Primjena filtera
1.	*Remove bumps*	Uklanjanje izbočina uzrokovanih pojavom sjene
2.	*Remove pits*	Uklanjanje udubljenja (rupa) uzrokovanih pojavom sjene
3.	*Constant elevation*	Poravnanje reljefa na zadanu visinu (vodene površine = 0 m)
4.	*Clamp filter*	Zaglađivanje neravnina uzrokovanih sjenom na WV snimcima

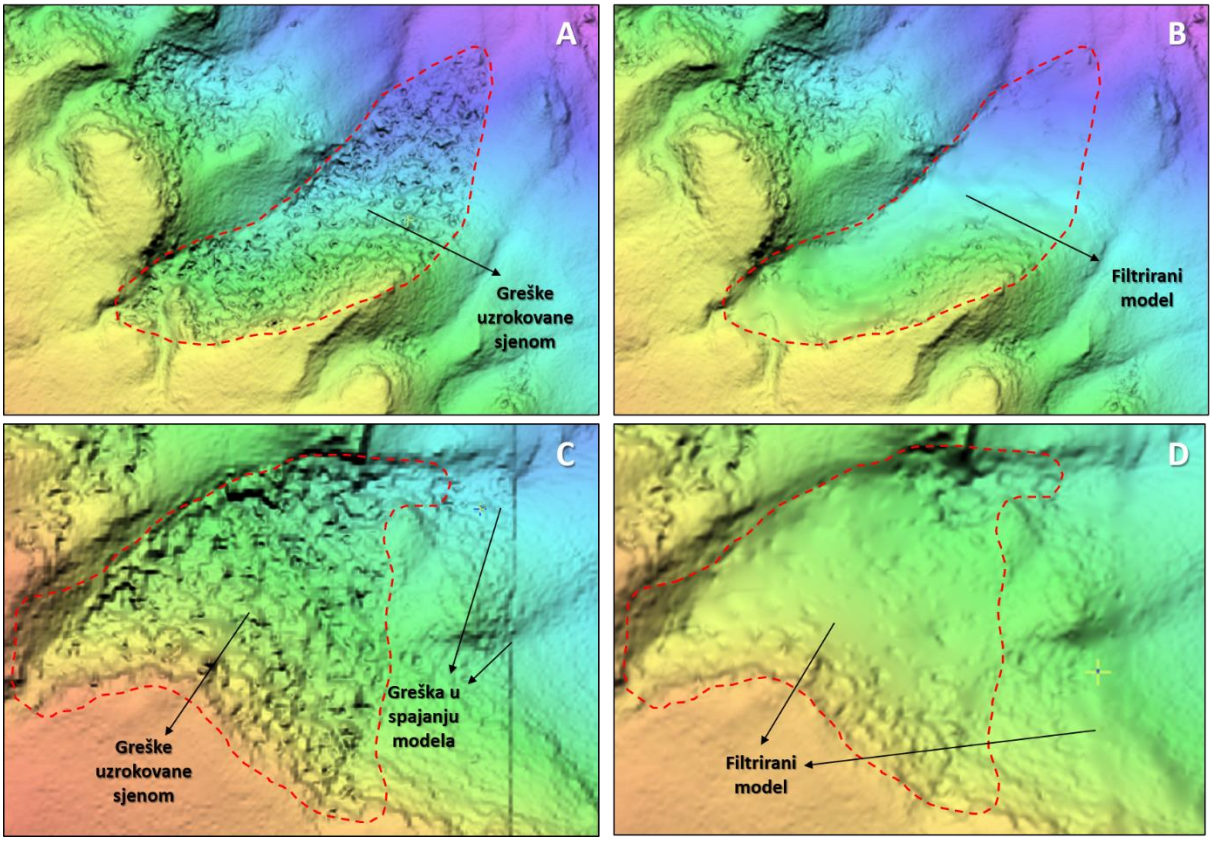

Slika 40. Ručna filtracija pogrešaka u generiranom DMP-u otoka Paga
(A i B – filtracija pogrešaka uzrokovanih prisustvom sjene na stereo WV1 snimku;
C i D – filtracija grešaka uzrokovanih spajanjem izrađenih DSM-ova)

Provjera točnosti konačnog DMP-a otoka Paga (8)

Konačni korak procesa izrade DMP-a otoka Paga uključuje provjeru točnosti izrađenog modela, koja je provjerena uz pomoć dostupnih referentnih geodetskih točaka, prikupljenih na terenu uz pomoć Stonex S10 RTK GNSS-a. Dostupne geodetske točke, njih ukupno 273, distribuirane diljem cijelog otoka Paga iskorištene su za provjeru apsolutne visinske točnosti izrađenog modela (Šiljeg, 2013.), pri čemu su vrijednosti visine (*Z*) referentnih geodetskih točaka uspoređene s odgovarajućim visinama na izrađenom modelu prema formuli:

$$h_{\Delta} = h_{REF} - h_{DMP} \quad (1)$$

gdje je:

h_{REF} = visina referentne geodetske točke; h_{DMP} = visina točke na izrađenom modelu;

$h_{\Delta} = visinska\ razlika.$

Vrijednost RMSE utvrđena na temelju 273 geodetske točke za izrađeni DMP otoka Paga iznosi 0.87 m, dok se detaljni pregled vrijednosti vezanih za provjeru visinske točnosti pojedinih dijelova modela dane u tablici 8.

Tablica 8. Visinska točnost DMP-a procijenjena na temelju dostupnih geodetskih točaka

Naziv modela	Satelit	Izvorni podatak	N_0 geodetskih točaka	MEAN RMSE (m)	Prostorna rezolucija modela (cm)
DSM A	WV3	Stereo OR2A	54	0.95	60
DSM B	WV1	Stereo OR2A	199	0.77	100
DSM C	WV1	Stereo OR2A	24	1.08	100
DSM D	WV1	Stereo OR2A	3	0.72	100
DSM Pag	WV3; WV1	Stereo OR2A	273	0.87	100

Utvrđena apsolutna visinska točnost izrađenog DMP-a odgovara vrijednostima RMSE (XYZ) za OT i KT točke korištenim ranije pri georeferenciranju stereo snimaka. Također, ako se u obzir uzme da je prostorna rezolucija originalnih stereo WV snimaka 0.5 m, utvrđena apsolutna visinska točnost izrađenog DMP-a se može smatrati izvrsnom te više nego zadovoljavajućom za potrebe ovog istraživanja. Nadalje, treba napomenuti kako utvrđena apsolutna visinska točnost odgovara točnosti sličnih modela izrađenih u sklopu drugih istraživanja iz OR2A stereo WV snimaka (Aguilar i dr., 2013a).

3.1.3. Izrada digitalnog modela reljefa otoka Paga

Za razliku od digitalnog modela reljefa (DMR), koji reprezentira isključivo površinu reljefa, DMP osim reljefa reprezentira i sve prirodne (npr. vegetacija) i antropogene (npr. stambeni objekti, prometnice, industrijska postrojenja, itd.) površine, koje se nalaze na površini reljefa (Šiljeg, 2013). Zbog toga zadnji korak izrade konačnog modela otoka Paga obuhvaća generiranje DMR-a, kroz korekciju i filtraciju izrađenog DMP-a.

Proces korekcije i filtriranja DMP-a i izrade DMR-a može se generalno podijeliti na *automatsku korekcija DMP-a u DMR* (1) i *ručno filtriranje preostalih pogrešaka* (2). Automatska i ručna filtracija DMP-a i izrada DMR-a izvršeni su uz pomoć Geomatica 2018 softvera.

I. Automatska konverzija DMP-a u DMR (1)

Prvi korak izrade DMR-a je automatska korekcija DMP-a u DMR, kojom se iz zadanog DMP-a automatski uklanja većina površina koje ne reprezentiraju površinu reljefa. Automatska korekcija DMP-a u DMR je unutar Geomatica 2018 softvera izvršena uz pomoć *DSM2DTM* algoritma, koji omogućava automatsku filtraciju DMP-a prema zadanim korisničko-definiranim parametrima. DSM2DTM algoritam automatski konvertira DMP u DMR primjenom niza filtracijskih koraka koji postupno uklanjaju antropogene i prirodne elemente te uglačavaju konačni model uklanjanjem preostalih nepravilnosti, poput udubljenja i ispupčenja, koje ne reprezentiraju površinu reljefa. Korisnik može kontrolirati proces konvertiranja DMP-a u DMR kroz definiranje različitih korisničko-definiranih parametara za svaki filter (npr. size – veličina, gradient – nagib, itd.). S obzirom da korisničko-definirani parametri DSM2DTM algoritma uvjetuju uspješnost automatske filtracije, potrebno ih je prilagoditi lokalnim značajkama reljefa odabranog područja. Detaljan prikaz odabranih korisničko-definiranih parametara dan je u tablici 9., dok je svaki pojedini parametar detaljnije pojašnjen u nastavku.

Tablica 9. Parametri automatske filtracije DMP-a uz pomoć DSM2DTM algoritma

Parametar	Zadana vrijednost	Opis
Elevation failure value	0	Definira piksele u DMP-u koji će se zanemariti tijekom obrade i biti interpolirani.
Background elevation value	0	Definira vrijednost piksela bez podataka (No Data), koji će biti izuzeti tijekom obrade i kopirani u završni DMR.
Object removal dimension units	Geocoded	Definira mjernu jedinicu za parametar object size (m ili pix).
Object size	25	Veličina filtera koji se koristi za uklanjanje površina.
Gradient treshold	55	Značajke s nagibima manjim od ovog praga smatrat će se prirodnim značajkama i neće se uklanjati tijekom obrade.
Terrain type	Hilly	Određuje prevladavajući tip reljefa reprezentiranog na zadanom modelu.
Bump filter: *size, gradient*	6, 4	Određuje filtere za uklanjanje izbočina preostalih nakon uklanjanja zgrada i drugih velikih značajki.
Pits filter: *size, gradient*	6, 4	Određuje filtere za uklanjanje udubljenja preostalih nakon uklanjanja zgrada i drugih velikih značajki.
Median filter: *size (pixels)*	3	Definira intenzitet uglačavanja konačnog modela.
Clamp filter: *size, gradient*	-	Fino uglačavanje - korigira sve piksele unutar zadanog područja do vrijednosti manje od prostorne rezolucije modela.

Prostor otoka Paga predstavlja reljefno vrlo heterogen prostor, unutar kojega se postupno izmjenjuju zaravnjeni dijelovi flišom ispunjenih sinklinala i antiklinalna krška uzvišenja. Zbog toga je bilo potrebno korisničko-definirane parametre DSM2DTM algoritma podesiti na način da uklone sve neželjene površine, a da pri tome ne devalviraju reljef na vertikalno raščlanjenijim dijelovima reljefa.

Dva najvažnija korisničko-definirana parametra DSM2DTM algoritma su *veličina objekta* (*object size*) i *prag nagiba* (*gradient treshold*). Veličina objekta definira dimenzije površina koje će biti uklonjene iz zadanog DMP-a, gdje se preporučuje da zadana vrijednost odgovara dimenzijama najvećih objekata (npr. zgrade, industrijska postrojenja), koje se želi ukloniti (PCI Geomatics Enterprises, 2018). Međutim, tako definirani parametar veličine objekta može utjecati na previše intenzivno filtriranje stvarne površine reljefa. U takvim slučajevima treba smanjiti vrijednost ovog parametra i prilagoditi ju prevladavajućoj veličini objekata koje se želi ukloniti. Drugi parametar je prag nagiba, koji definira vrijednost nagiba

ispod koje se sve padine smatraju prirodnima, te se kao takve izostavljaju iz procesa korekcije i filtracije. Kako bi se uklonili antropogeni objekti sa strmim, vertikalnim bočnim stranama, poput stambenih i industrijskih objekata, a sačuvala većina prirodnih padina, zadan je odgovarajući prag nagiba (n = 55).

Prostor otoka Paga karakterizira izmjena krških uzvisina i zaravnjenih flišnih udolina, zbog čega je u konačnici odabran *hilly* prevladavajući tip reljefa. Filterima za uklanjanje preostalih nepravilnosti (*bump filter* i *pits filter*) i filterima za završno uglačavanje modela (*median filter* i *clamp filter*) zadane su odgovarajuće vrijednosti iterativnog uklanjanja nepravilnosti, od većih prema manjima. U konačnici je izrađen digitalni model reljefa, kojega je bilo potrebno dodatno popraviti kroz ručnu filtraciju. Najviše pogrešaka prisutno je na mjestima uklonjenih većih objekata ili razvijenijeg vegetacijskog pokrova.

II. Ručna filtracija preostalih pogrešaka (2)

Uslijedilo je ručno uklanjanje pogrešaka preostalih nakon automatske korekcije DMP-a u DMR. Pogreške preostale nakon uklanjanja vegetacije i antropogenih objekata predstavljaju pojedinačne, prostorno heterogene pogreške, koje nije moguće automatski ukloniti. Zbog toga je primijenjeno ručno uklanjanje pogrešaka uz pomoć filtera za korekciju DMR-a iz *DEM Editing* ekstenzije Geomatica 2018 softvera (Tabl. 10.). Pogreške u izrađenom DMR-u uglavnom su činili različiti artefakti preostali nakon uklanjanja gušće vegetacije (Sl. 41.), ili pak većih antropogenih objekata (Sl. 42.). Primjenom navedenih različitih filtera uspješno su uklonjeni preostali artefakti, dok je izrađeni konačni DMR šireg prostora dodatno zaglađen uz pomoć *average* filtera (Sl. 43.).

B

A

Tablica 10. Filteri korišteni za ručnu korekciju izrađenog DMR-a

#	Filter	Primjena filtera
1	*Remove bumps*	Uklanjanje izbočina preostalih nakon korekcije DMP-a
2	*Remove bumps (keep linear)*	Uklanjanje nelinearnih izbočina
3	*Remove pits*	Uklanjanje udubljenja (rupa)
4	*Terrain (flat)*	Filter za uklanjanje vegetacije i antropogenih objekata na zaravnjenim područjima
5	*Terrain (hilly)*	Filter za uklanjanje vegetacije i antropogenih objekata na brežuljkastim područjima
6	*Average filter*	Zaravnjavanje reljefa prema prosječnoj vrijednosti unutar zadanog poligona
7	*Median filter*	Zaravnjavanje reljefa prema srednjoj vrijednosti unutar zadanog poligona
8	*Fill from edges*	Zapunjavanje reljefa prema rubovima definiranog poligona
9	*Average elevation*	Poravnjanje reljefa na prosječnu visinu
10	*Constant elevation*	Poravnanje reljefa na zadanu visinu
11	*Clamp filter*	Zaglađivanje manjih neravnina

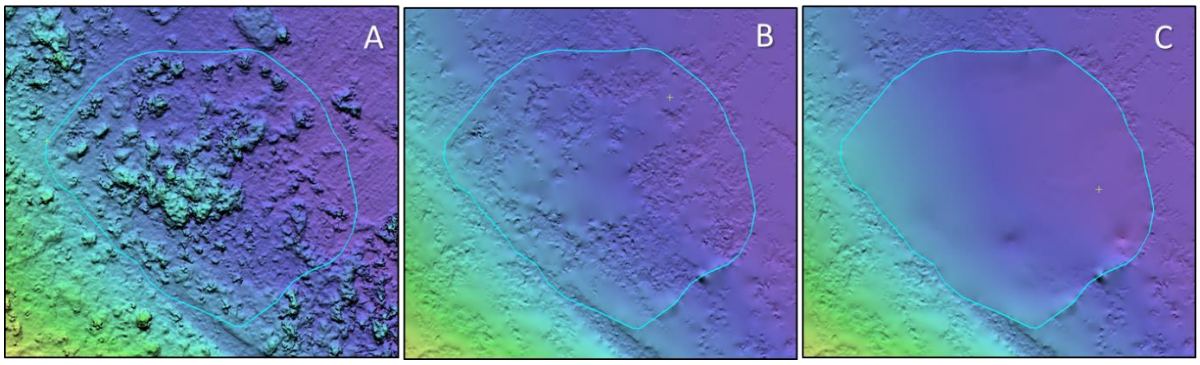

Slika 41. Ručna filtracija pogrešaka preostalih nakon uklanjanja vegetacije iz generiranog DMR-a (A – izvorni DMP; B – automatska korekcija; C – ručna filtracija)

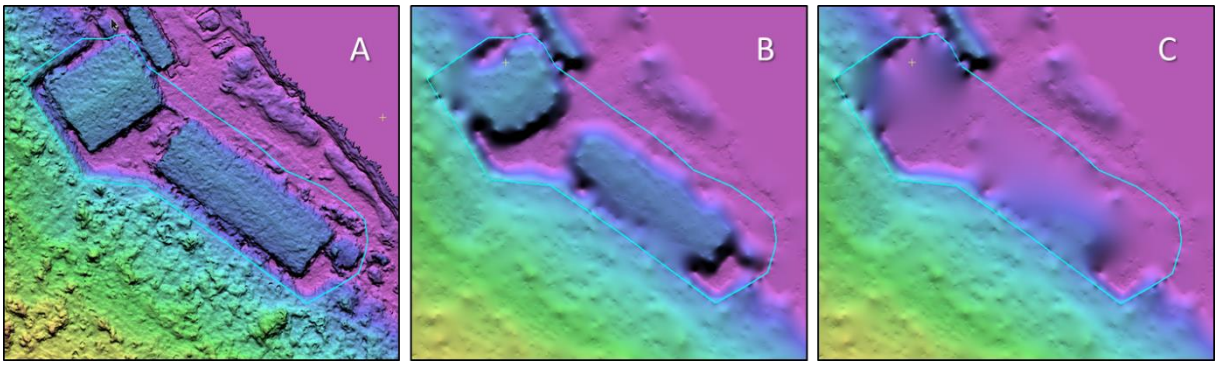

Slika 42. Ručna filtracija pogrešaka preostalih nakon uklanjanja antropogenih objekata iz generiranog DMR-a (A – izvorni DMP; B – automatska korekcija; C – ručna filtracija)

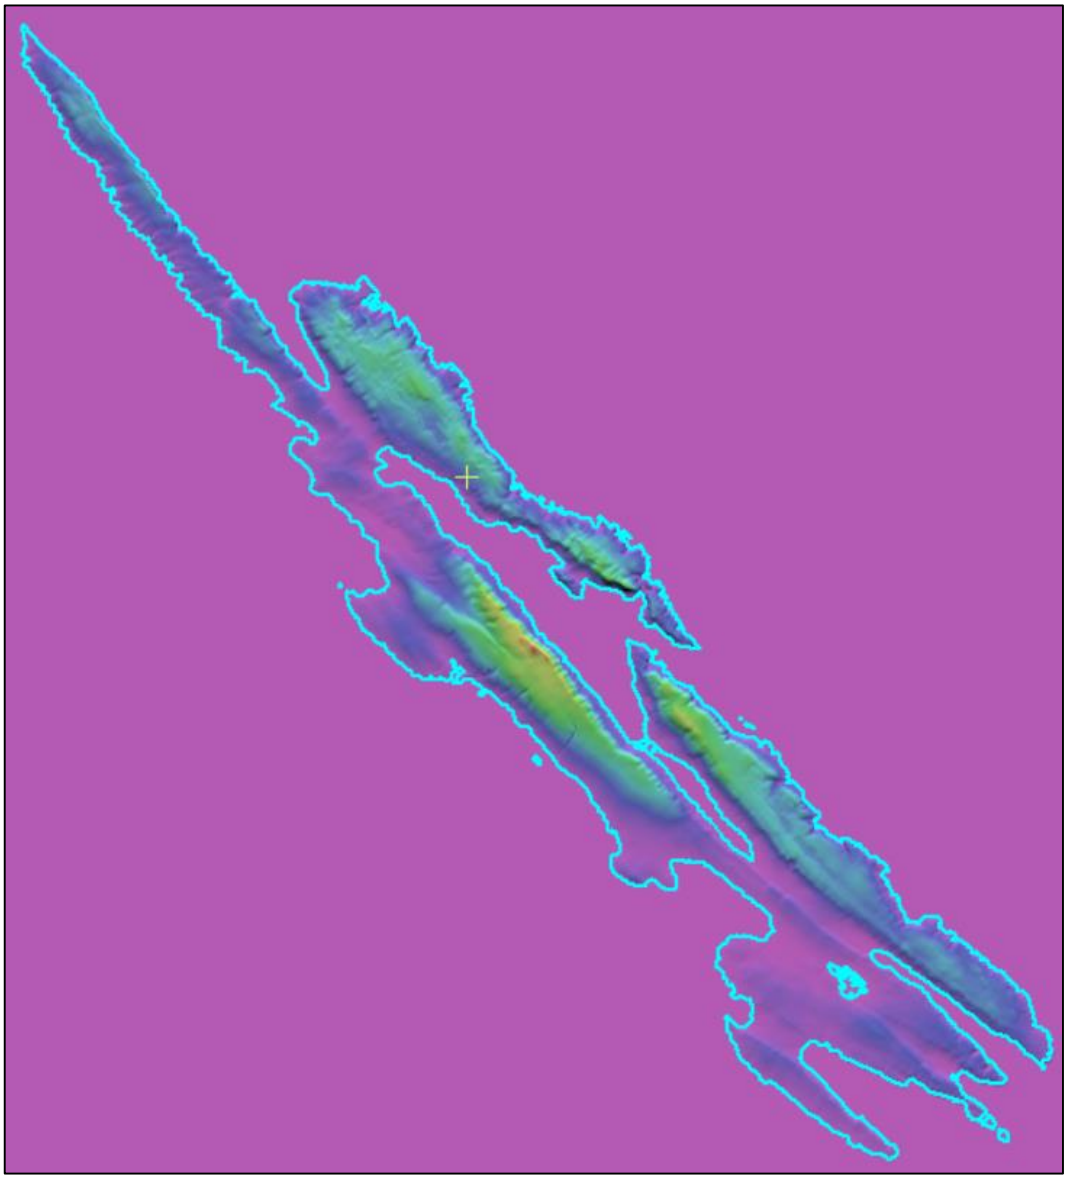

Slika 43. Završna filtracija sitnih pogreški uz pomoć *average* filtera unutar poligonske maske otoka Paga

3.1.4. Izrada višekriterijskog GIS modela podložnosti eroziji tla

Višekriterijska GIS analiza (engl. *Multicriteria GIS Decision Analysis* - GIS-MCDA) jedna je od najčešće korištenih metoda za modeliranje podložnosti (Malczewski, 2006; Malczewski i Rinner, 2015., koja ima primjenu u brojnim različitim znanstvenim poljima (Cegan i dr., 2017; de Almeida i dr., 2017). Stoga ne čudi da je u zadnjih nekoliko godina broj znanstvenih istraživanja koja koriste višekriterijsku GIS analizu za modeliranje podložnosti u stalnom porastu (Cegan i dr., 2017). Posebice se trend porasta primjene višekriterijske GIS analize očituje u različitim geomorfološkim istraživanjima (Erener i dr., 2016), među kojima treba istaknuti i sve češću primjenu ove metode za modeliranje podložnosti različitim aspektima erozije tla (Gómez-Gutiérrez i dr., 2015; Arabameri i dr., 2020a; 2020b; 2020c; 2020d; Nhu i dr., 2020). Osobito je česta primjena višekriterijskih GIS analiza za modeliranje podložnosti jaruženju (Arabameri i dr., 2020a; 2020b; 2020d; Nhu i dr., 2020; Magliulo i dr., 2010; Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; 2014; Rahmati i dr., 2016; Domazetović i dr., 2019a; 2019b), kao najintenzivnijem obliku manifestiranja procesa erozije tla.

Automatizacija višekriterijskog GIS modeliranja uz pomoć GAMA metode

Međutim, unatoč širokoj primjeni, tradicionalna primjena GIS-MCDA za modeliranje podložnosti i dalje predstavlja proces koji zahtjeva znatne količine vremena i rada, pri čemu je uspješnost modeliranja pod izravnim utjecajem različitih korisničko-definiranih odluka, te iskustva i znanja korisnika. Zbog toga je u sklopu ove doktorske disertacije, a za potrebe provođenja višekriterijskog modeliranja podložnosti prostora otoka Paga eroziji tla, razvijen i primijenjen set alata za pojednostavljenje cijelog GIS-MCDA procesa. Razvijena GAMA metoda omogućila je automatizaciju 3., 4. i 5. koraka GIS-MCDA procesa (Sl. 44.). Detaljno pojašnjenje razvijene GAMA metode dano je u Domazetović i dr. (2019a; 2019b.). Proces višekriterijskog GIS modeliranja podložnosti eroziji tla može se raščlaniti na šest osnovnih koraka (Sl. 44.).

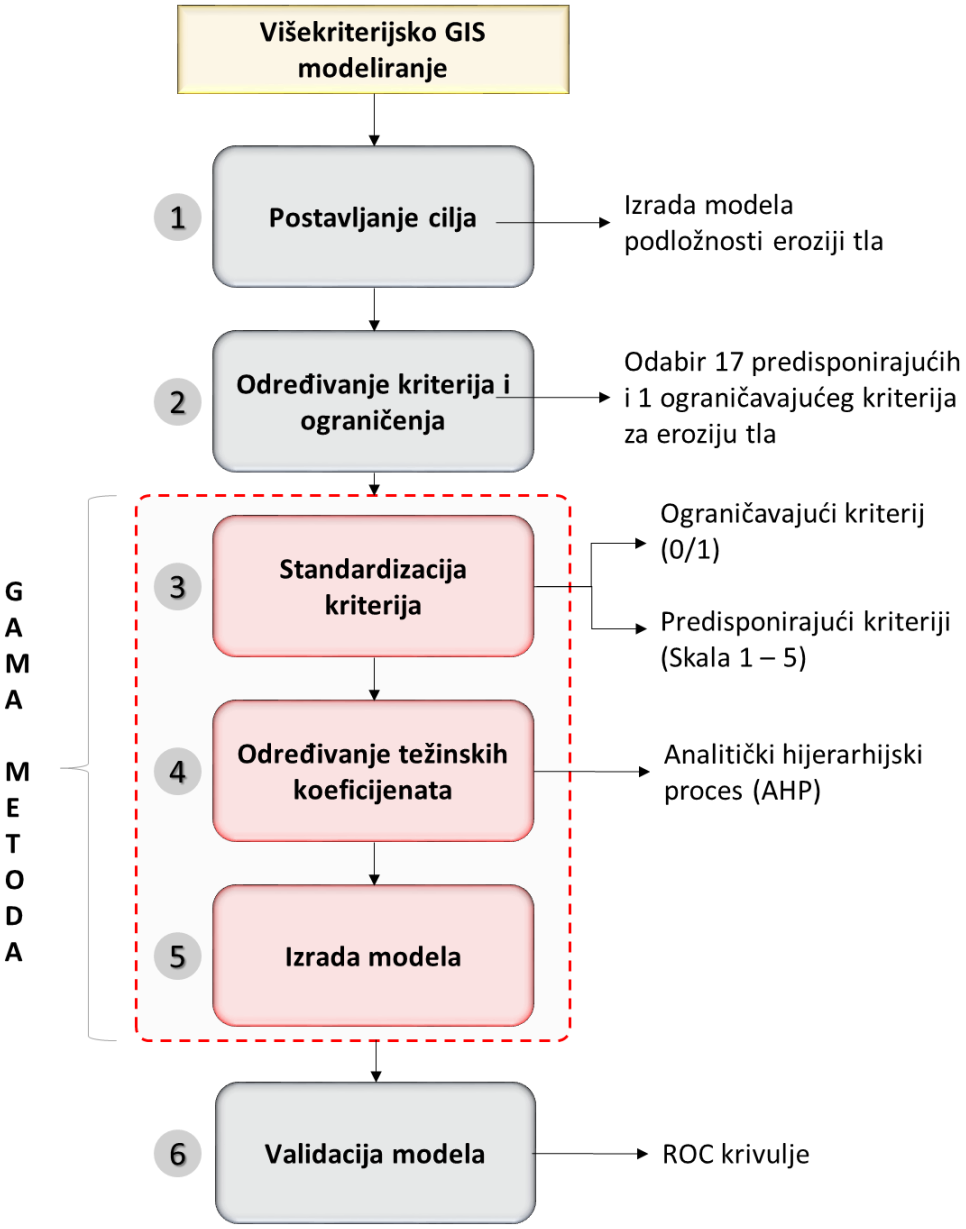

Slika 44. Shematski prikaz pojedinih koraka procesa izrade modela podložnosti eroziji tla

I. Postavljanje cilja višekriterijske GIS analize (GIS-MCDA)

Cilj (1) višekriterijskog GIS modeliranja je izrada *višekriterijskog modela podložnosti eroziji tla* (VMPET) čitave makro razine istraživanja, odnosno otoka Paga. Kroz izradu modela podložnosti biti će moguće raščlaniti zone veće ugroze od daljnjeg procesa erozije tla, unutar kojih postoji veća vjerojatnost za pojavu intenzivne erozije tla u budućnosti.

II. Odabir i grupiranje predisponirajućih kriterija i ograničenja

Osnova GIS-MCDA su odabrani kriteriji (2) na temelju kojih se provodi modeliranje podložnosti. Odabir i grupiranje predisponirajućih kriterija napravljeno je na temelju ranije započetih i provedenih istraživanja (Domazetović i dr., 2019a; Domazetović i dr., 2019b), te na temelju detaljne analize postojeće literature vezane za modeliranje podložnosti eroziji tla (Tabl. 11.). Ukupno je odabrano 17 različitih predisponirajućih kriterija, koje je moguće prema vrsti podijeliti u tri grupe kriterija. Uz sedamnaest predisponirajućih kriterija odabran je i jedan ograničavajući (*Boolean*) kriterij, koji predstavlja sve površine unutar kojih pojava erozije tla nije moguća (npr. vodene površine). Pregled odabranih kriterija i njihovih kraćih specifikacija dan je u tablici 1, dok je pojašnjenje svakog kriterija i njegovog značaja za pojavnost erozije tla na određenom prostoru dana u poglavlju 4.1.1. Proces generiranja pojedinih kriterija GIS-MCDA (Sl. 45.) detaljnije je opisan u nastavku.[14]

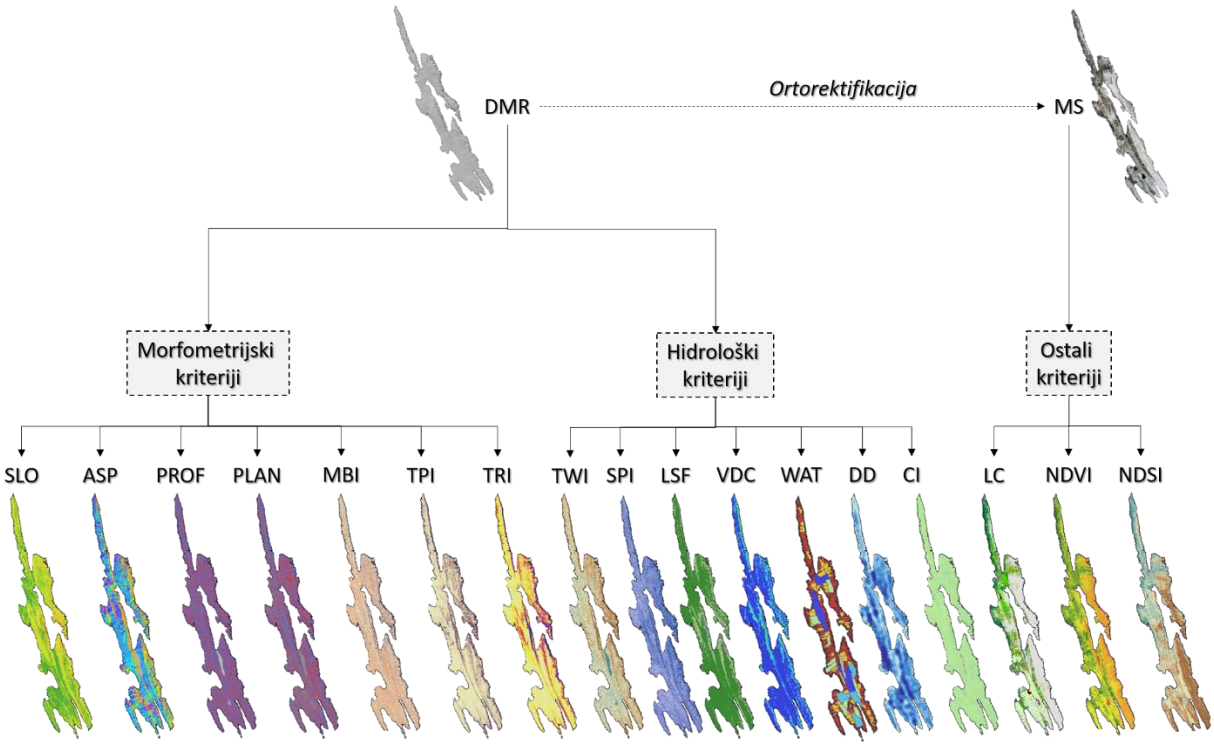

Slika 45. Proces kreiranja odabranih kriterija GIS-MCDA

[14] Ista metodologija generiranja pojedinih morfometrijskih i hidroloških kriterija primijenjena je unutar cijele doktorske disertacije, odnosno unutar sve tri istraživačke razine (npr. nagib padina – Hornova metoda (Horn, 1981)).

Tablica 11. Pregled odabranih kriterija GIS-MCDA podložnosti eroziji tla

Grupa	#	Naziv kriterija	Kratica	Algoritam	Istraživanje
1. Morfometrijski kriteriji	1.1	Nagib padine	SLO	Horn (1981)	Magliulo i dr., 2010; Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; 2014; Rahmati i dr., 2016; Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b
	1.2	Orijentacija padine	ASP	Horn (1981)	Conforti i dr., 2011; Rahmati i dr., 2016; Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b
	1.3	Profilna zakrivljenost	PROF	Zevenbergen i Thorne (1987)	Conoscenti i dr., 2013; Nhu i dr., 2020; Arabameri i dr., 2020b
	1.4	Planarna zakrivljenost	PLAN	Zevenbergen i Thorne (1987)	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; Rahmati i dr., 2016; Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b
	1.5	Indeks ravnoteže mase	MBI	Möller i dr. (2008)	Kriterij prvi put korišten u ovom istraživanju.
	1.6	Topografski indeks pozicije	TPI	Wilson i Gallant (2000)	Arabameri i dr., 2020a; 2020b
	1.7	Indeks vertikalne raščlanjenosti	TRI	Riley i dr. (1991)	Arabameri i dr., 2020a; 2020b
2. Hidrološki kriteriji	2.1	Topografski indeks vlažnosti	TWI	Moore i dr. (1991)	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; Rahmati i dr., 2016; Arabameri i dr., 2019; 2020a; 2020b
	2.2	Indeks snage toka	SPI	Moore i dr. (1991)	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscentii dr., 2013; Rahmati i dr., 2016; Arabameri i dr., 2019; 2020a; 2020b
	2.3	LS Faktor	LSF	Moore i dr. (1991)	Conforti i dr., 2011; Lucà i dr., 2011; Arabameri i dr., 2020b
	2.4	Vertikalna udaljenost od tokova	VDC	SAGA GIS	Kriterij prvi put korišten u ovom istraživanju.

	2.5	Velićina slivnog područja	WAT	Watershed[15]	Domazetović i dr., 2019a
	2.6	Gustoća tokova (km/km²)	DD	Line density[16]	Arabameri i dr., 2019; 2020a; 2020b
	2.7	Indeks konvergencije	CI	Kiss (2004)	Arabameri i dr., 2020a; 2020b
3. Ostali kriteriji	3.1	Zemljišni pokrov	LC	Nadzirana klasifikacija [17]	Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b
	3.2	Normalizirani indeks različitosti vegetacije	NDVI	Maglione i dr. (2014)	Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b
	3.3	Normalizirani indeks različitosti tla	NDSI	Kriterij uveden u sklopu ovog istraživanja	Kriterij prvi put korišten u ovom istraživanju.

A) Generiranje morfometrijskih kriterija

Grupa morfometrijskih kriterija obuhvaća sve kriterije koji definiraju određeni segment morfometrije reljefa. Morfometrijski kriteriji generirani su na temelju izrađenog DMR-a otoka Paga prostorne rezolucije 1 m. Unutar grupe morfometrijskih kriterija ukupno je generirano sljedećih sedam kriterija: nagib padine (engl. *slope* - SLO), orijentacija padine (engl. *aspect* - ASP), profilna zakrivljenost padine (engl. *profile curvature* - PROF), planarna zakrivljenost padine (engl. *planar curvature* - PLAN), indeks ravnoteže mase (engl. *mass balance index* - MBI), topografski indeks pozicije (engl. *topographic position index* - TPI) te indeks vertikalne raščlanjenosti (engl. *terrain ruggedness index* - TRI).

A1. Nagib padine (SLO)

Nagib padine (engl. *slope*) predstavlja mjeru zakošenosti svake ćelije rasterske površine, odnosno površine terena (Wilson i Gallant, 2000.). Za generiranje kriterija nagiba padina korištena je Spatial Analyst ekstenzija ArcGIS 10.1 softvera, unutar koje je integriran *Slope* alat zasnovan na Hornovoj metodi za izračun nagiba padine (Horn, 1981.). Vrijednosti nagiba padine su u sklopu ove disertacije izračunati u stupnjevima (0 – 90º) te su klasificirani prema standardnoj geomorfološkog klasifikaciji nagiba padina (IGU, 1968.).

[15] WAT je generiran uz pomoć standardnih *Hydrology* alata unutar ArcGIS 10.1 softvera
[16] DD je generiran uz pomoć *Line Density* alata unutar ArcGIS 10.1 softvera
[17] LC je napravljen uz pomoć *Maximum Likelihood Classification* alata unutar ArcGIS 10.1 softvera

A2. Orijentacija padine (ASP)

Orijentacija padine (engl. *aspect*) predstavlja ekspoziciju padine određenu prema azimutu kojega zatvaraju pravac padine i pravac sjevera, pri čemu se kut ekspozicije određuje u smjeru kazaljke na satu (Wilson i Gallant, 2000.). Vrijednost kriterija orijentacije padine su iskazane u stupnjevima (0 – 360º), pri čemu su vrijednosti automatski grupirane u osam klasa određenih prema dominantnoj strani svijeta (S, SI, I, JI, J, JZ, Z, SZ) i jednu klasu za zaravnjeni prostor (-1). Kriterij orijentacije padina generiran je uz pomoć *Aspect* alata iz Spatial Analyst ekstenzije, unutar koje je integrirana Hornova metoda za izračun orijentacije padine (Horn, 1981.).

A3. Profilna zakrivljenost (PROF)

Profilna zakrivljenost padine (engl. *Profile curvature*) predstavlja zakrivljenost padine paralelnu sa smjerom padine, pri čemu odražava smjer najvećeg nagiba (Wilson i Gallant, 2000). Negativne vrijednosti planarne zakrivljenosti predstavljaju konveksne, odnosno ispupčene padine, a pozitivne vrijednosti označavaju konkavne, odnosno udubljene padine. Vrijednosti profilne zakrivljenosti klasificirane su u konveksne, zaravnjene i konkavne padine prema formuli predloženoj u Dikau (1989.). Kriterij profilne zakrivljenosti generiran je uz pomoć *Curvature* alata iz Spatial Analyst ekstenzije, unutar koje se integriran Zevenbergen i Thorne pristup (Zevenbergen i Thorne, 1987.).

A4. Planarna zakrivljenost (PLAN)

Planarna zakrivljenost padine (engl. *Planar curvature*) predstavlja zakrivljenost padine u sekanti okomitoj na pravac najveće strmine (Wilson i Gallant, 2000.). Negativne vrijednosti profilne zakrivljenosti predstavljaju konkavne, odnosno udubljene padine, dok pozitivne vrijednosti predstavljaju konveksne, odnosno ispupčene padine. Kao i ranije kod profilne zakrivljenosti, vrijednosti planarne zakrivljenosti klasificirane su u konveksne, zaravnjene i konkavne padine prema formuli predloženoj u Dikau (1989.). Kriterij planarne zakrivljenosti generiran je uz pomoć *Curvature* alata iz Spatial Analyst ekstenzije, unutar koje se integriran Zevenbergen i Thorne pristup (Zevenbergen i Thorne, 1987.).

A5. Indeks ravnoteže mase (MBI)

Indeks masne bilance (engl. *Mass balance index*) predstavlja mjeru ravnoteže između procesa erozije i akumulacije (Sena i dr., 2020). Udubljenja u terenu, unutar kojih generalno prevladava proces akumulacije materijala, reprezentirana su negativnim vrijednostima ovog indeksa, dok s druge strane pozitivne vrijednosti indeksa reprezentiraju uzvišenja, odnosno prostore na kojima prevladava erozija materijala (Möller i dr., 2012). Vrijednosti bliže 0 označavaju prostor na kojima su procesi akumulacije i erozije približno u ravnoteži (Möller i Volk, 2015). Kriterij indeksa ravnoteže mase generiran je iz DMR-a otoka Paga uz pomoć alata *Mass Balance Indeks* iz Saga GIS ekstenzije za ArcGIS 10.1.

A6. Topografski indeks pozicije (TPI)

Topografski indeks pozicije (engl. *Topographic position index*) predstavlja odstupanje određenog područja od prosječne visine reljefa, kod kojega se visina središnjeg piksela uspoređuje s prosječnom visinom zadanog okružujućeg susjedstva (Wilson i Gallant, 2000; De Reu i dr., 2013.). Dok negativne vrijednosti ovog reljefa predstavljaju reljef koji je niži od prosječne visine zadanog susjedstva, pozitivne vrijednosti predstavljaju reljef viši od prosječne visine zadanog susjedstva (Riley i dr., 2017.). Dva najvažnija korisničko-definirana parametra kod generiranja TPI su veličina i oblik susjedstva (De Reu i dr., 2013.). Unutar ove disertacije TPI je izračunat korištenjem *Topographic position index* alata iz Saga GIS ekstenzije za ArcGIS 10.1. Pri tome je veličina susjedstva postavljena na 3 x 3 ćelije, uz odabrani pravokutni oblik susjedstva.

A7. Indeks vertikalne raščlanjenosti (TRI)

Indeks vertikalne raščlanjenosti (engl. *Terrain Ruggedness Index*) predstavlja kvantifikaciju heterogenosti i raščlanjenosti reljefa, kod koje se visina središnjeg piksela dovodi u odnos s apsolutnom visinom reljefa unutar zadanog okružujućeg susjedstva (Riley i dr., 1999; Różycka i dr., 2017). S povećanjem raščlanjenosti reljefa povećava se i vrijednost TRI (m/m^2). Unutar ove disertacije TRI je izračunat korištenjem *Terrain Ruggedness Indeks alata* iz Saga GIS ekstenzije za ArcGIS 10.1.

B) Generiranje hidroloških kriterija

Grupa hidroloških kriterija obuhvaća sve kriterije koji definiraju hidrološke značajke reljefa. Hidrološki kriteriji generirani su na temelju izrađenog DMR-a otoka Paga prostorne rezolucije 1 m. Unutar grupe hidroloških kriterija ukupno je generirano sljedećih sedam kriterija: *topografski indeks vlažnosti* (engl. *topographic wetness index* - TWI), *indeks snage toka* (engl. *stream power index* - SPI), *LS faktor* (engl. *lenght-slope* factor - LSF), *vertikalna udaljenost od tokova* (engl. *vertical distance to channel network* - VDC), *veličina slivnog područja* (engl. watershed - WAT), *gustoća drenažne mreže* (engl. *drainage* density - DD) te *indeks konvergencije* (engl. *convergence index* - CI).

B1. Topografski indeks vlažnosti (TWI)

Topografski indeks vlažnosti (engl. *Topographic Wetness Index*) predstavlja hidrološku mjeru potencijalne vlažnost određenog terena, koja definira sklonost određenog prostora akumuliranju vode (Różycka i dr., 2017; Raduła i dr., 2018). TWI omogućava detekciju i raščlambu različitih vodom zasićenih prostora (npr. močvare, ponikve, jaruge, riječne doline, itd.) koje karakteriziraju visoke vrijednosti ovog indeksa, od sušnijih područja (npr. strmije padine i uzvisine) s niskim vrijednostima ovog indeksa (Wilson i Gallant, 2000). Unutar ove disertacije TWI je izračunat korištenjem *Topographic Wetness Index alata* iz Saga GIS ekstenzije za ArcGIS 10.1. Pri tome su ulazni podaci za izračun SPI bili nagib padine (SLO) i veličina slivnog područja (WAT).

B2. Indeks snage toka (SPI)

Indeks snage toka (engl. *Stream power index*) predstavlja mjeru potencijalne erozivne snage površinskog otjecanja, pri čemu veće vrijednosti ovog indeksa reprezentiraju veću erozivnu snagu (Conforti i dr., 2011; Florinsky, 2016). SPI se temelji na pretpostavci da je snaga površinskog otjecanja proporcionalna veličini odgovarajućeg specifičnog slivnog područja (Moore i dr., 1991). S obzirom da SPI predstavlja potencijalnu erozivnu energiju površinskog otjecanja, može ga se smatrati jednim od ključnih kriterija za izdvajanje eroziji podložnih područja (Conforti i dr., 2011). Unutar ove disertacije SPI je izračunat korištenjem S*tream power index alata* iz Saga GIS ekstenzije za ArcGIS 10.1. Pri tome su ulazni podaci za izračun SPI bili nagib padine (SLO) i veličina slivnog područja (WAT).

B3. LS faktor (LSF)

LS faktor (engl. *Lenght-slope factor*) predstavlja indeks koji na temelju značajki nagiba padine i slivnog područja određuje sposobnost potencijalnog erodiranja i transporta sedimenta (Zhang i dr., 2013; Rodríguez-Caballero i dr., 2019). Unutar ove disertacije LSF je izračunat korištenjem Lenght-slope factor *alata* iz Saga GIS ekstenzije za ArcGIS 10.1, gdje su ulazni podaci za izračun LSF bili nagib padine (SLO) i veličina slivnog područja (WAT).

B4. Vertikalna udaljenost od tokova (VDC)

Vertikalna udaljenost od tokova (engl. *Vertical distance to channel network*) predstavlja indeks čije vrijednosti ukazuju na vertikalni položaj pojedinog piksela u odnosu na zadanu linearnu mrežu površinskih tokova. Izračun VDC indeksa napravljen je uz pomoć alata unutar SAGA GIS softvera, koji na temelju zadane mreže površinskih tokova generira interpoliranu površinu, odnosno tzv. baznu razinu drenažne mreže (Möller i dr., 2012.). Oduzimanjem interpolirane bazne razine drenažne mreže od DMR-a otoka Paga dobiven je vertikalna udaljenost svih pojedinih piksela, pri čemu veće vrijednosti označavaju da je piksel udaljeniji od mreže površinskih tokova (npr. grebeni i uzvišenja).

B5. Veličina slivnog područja (WAT)

Veličina slivnog područja (engl. *Watershed*) predstavlja indeks koji ukazuje na površinu svih slivnih područja otoka Paga, kod kojega povećanje vrijednosti ukazuju na povećanje ukupne površine slivnih područja. WAT je generiran uz pomoć standardnih Hydrology alata, iz *Spatial Analyst* ekstenzije. Pri tome su za sve tokove izdvojene iz DMR-a otoka Paga uz pomoć alata *Watershed* izdvojena njihova odgovarajuća slivna područja. Svim generiranim slivnim područjima izračunata je ukupna površina (km^2), nakon čega su slivovi klasificirani *Jenksovom* metodom u 4 različite klase.

B6. Gustoća drenažne mreže (DD)

Gustoća drenažne mreže (engl. *Drainage density*) predstavlja mjeru gustoće površinskih tokova unutar određene površine (Dobos i Daroussin, 2005). Veće vrijednosti ovog indeksa ukazuju na prostore povećane gustoće površinskih tokova, unutar kojih je i vjerojatnost za pojavu erozije uzrokovane djelovanjem vode veća. Unutar ove disertacije DD je izračunat korištenjem *Line density alata* iz *Spatial Analyst* ekstenzije za ArcGIS 10.1. Kao ulazni podatak za izračun DD korišteni su svi površinski tokovi otoka Paga, generirani na temelju izrađenog

DMR-a otoka. Pri tome je za izračun indeksa korištena kružna orijentacija susjedstva, s radijusom od 564.19 m (*površina kruga = 1km*^{2}).

B7. Indeks konvergencije (CI).

Indeks konvergencije (engl. *Convergence Index*) predstavlja mjeru divergencije i/ili konvergencije površinskog otjecanja, koja koristi orijentaciju ili nagib padine za određivanje stupnja utjecaja susjedstva na otjecanje prema središnjoj rasterskoj ćeliji (Kiss, 2004). Dok negativne vrijednosti ovog indeksa ukazuju na konvergentno površinsko otjecanje, pozitivne ukazuju na divergentno, odnosno otjecanje od središnje ćelije prema rubovima analiziranog susjedstva. Unutar ove disertacije CI je izračunat korištenjem *Convergence index alata* iz Saga GIS ekstenzije za ArcGIS 10.1. Pri tome je za potrebe izračuna indeksa za korisničko-definirani parametar tipa susjedstva (engl. *neighborhood type*) odabrano kružno (engl. *circle*) susjedstvo, radijusa od 564.19 m (*površina kruga = 1km*^{2}).

C) Generiranje ostalih kriterija

Ostali kriteriji generirani su na temelju izrađenog Worldview-2 multispektralnog snimka otoka Paga, prostorne rezolucije 1 m. Unutar grupe ostalih kriterija ukupno su generirana sljedeća tri kriterija: *zemljišni pokrov* (engl. *land cover* - LC), *normalizirani indeks različitosti vegetacije* (engl. *normalized difference vegetation index* - NDVI) te *normalizirani indeks različitosti tla* (engl. *normalized difference soil index* - NDSI).

C1. Zemljišni pokrov (LC)

Zemljišni pokrov (engl. *Land Cover*) označava vidljive zemljišne značajke, koje su klasificirane po vrsti (npr. šuma, kamenjar, urbana površina, itd.) na temelju razlike u spektralnoj refleksiji određene površine, odnosno materijala od kojega je ona sačinjena (Fisher i Unwin, 2005). Kriterij zemljišnog pokrova generiran je za prostor otoka Paga na temelju nadzirane klasifikacije (engl. *supervised classification*), pri čemu je kao osnova za klasifikaciju korišten izrađeni multispektralni Worldview snimak (*vidi 3.1.1.*). Nadzirana klasifikacija izrađenog Worldview multispektralnog snimka napravljena je u ArcGIS 10.1 softveru, koristeći *Maximum Likelihood Classification* alat. Ukupno je izdvojeno 9 različitih klasa zemljišnog pokrova (Tabl. 11). Kompleksnost spektralnih otisaka (engl. *spectral footprint*) pojedinih klasa zemljišnog pokrova zahtijevala je prikupljanje većeg broja uzoraka, zbog čega je ukupni broj uzoraka po pojedinim klasama vrlo heterogen (Tabl. 12.). Primjerice, iako klasa kamenjara

pokriva značajne dijelove otoka Paga, unutar nje postoji određena spektralna varijabilnost. Ta varijabilnost uzrokovana je prvenstveno razlikama u teksturi i vrsti stijene (npr. vapnenac i dolomit), ali i meteorološkim uvjetima prilikom prikupljanja inicijalnih snimaka (npr. osunčanost, pojava sjena, itd.). Zbog toga je za takve "kompleksnije" klase zemljišnog pokrova bilo potrebno prikupiti znatno više uzoraka. U konačnici su za izdvojenih 9 klasa zemljišnog pokrova izračunata površina (km²), te udio u ukupnoj površini otoka Paga.

Tablica 12. Klase zemljišnog pokrova izdvojene kroz nadziranu klasifikaciju WV MS

#	Klasa zemljišnog pokrova	Broj uzoraka	Broj piksela
1	Kamenjar	126	11573
2	Urbano	59	6783
3	Voda	62	7685
4	Močvarno	51	5674
5	Tlo	75	8547
6	Niski travnjak	67	7273
7	Visoki travnjak	85	8478
8	Makija	87	9475
9	Šuma	93	10483

Primjeri različitih klasa zemljišnog pokrova izdvojenih nadziranom klasifikacijom na temelju WV multispektralnog snimka vidljivi su na slici 46.

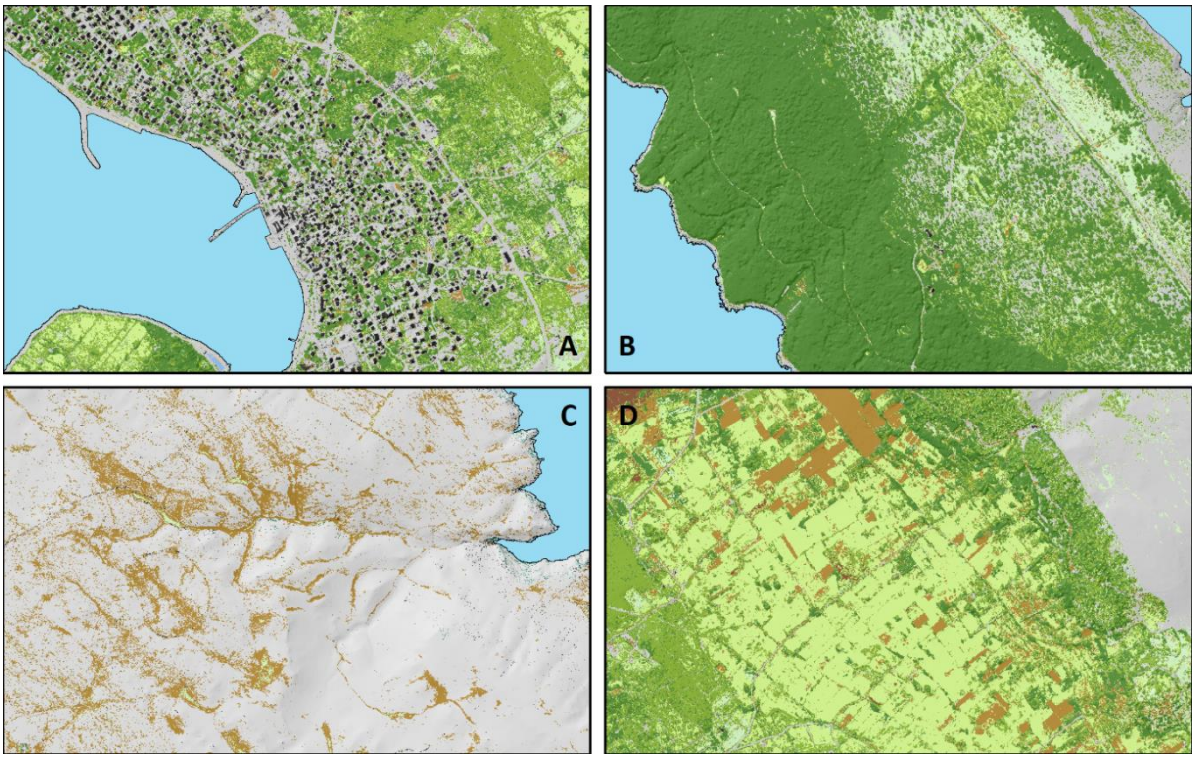

Slika 46. Primjeri različitih prevladavajućih klasa zemljišnog pokrova izdvojenih nadziranom klasifikacijom iz WV multispektralnog snimka otoka Paga (A – urbana područja; B – šumska područja; C – kamenjar; D – heterogeni pokrov)

C2. Normalizirani indeks različitosti vegetacije (NDVI)

Normalizirani indeks različitosti vegetacije (engl. *Normalized Difference Vegetation Index*) predstavlja mjeru stanja, odnosno zdravlja vegetacije na određenom području, određenu na temelju reflektiranja određenih spektralnih vrijednosti (Sharma, 2010; Maglione i dr., 2014; Moody i dr., 2014). Zdrava vegetacija smanjuje podložnost određenog područja procesu erozije tla, jer biljke svojim korijenjem stabiliziraju naslage tla i pospješuju infiltraciju površinskog otjecanja u tlo (Arabameri i dr., 2020a). Zbog toga viske vrijednosti NDVI-a, koje reprezentiraju zdravu vegetaciju, ujedno reprezentiraju i područja manje podložna eroziji tla. NDVI je generiran na temelju spektralnih kanala WV-2 multispektralnog snimka otoka Paga prema sljedećoj formuli (Maglione i dr., 2014.):

$$NDVI = \frac{NIR2 - Red}{NIR2 + Red} \quad (2)$$

C3. Normalizirani indeks različitosti tla (NDSI)

Normalizirani indeks različitosti tla (engl. *Normalized Difference Soil Index*) predstavlja spektralni indeks na temelju kojega je moguće detektirati i izdvojiti područja na kojima prevladava tlo, ali i utvrditi razlike u pojedinim vrstama naslaga tla (Wolf, 2012; Moody i dr., 2014.). Negativne i blago pozitivne vrijednosti NDSI karakteriziraju izložene i ogoljene naslage tla, vegetaciju slabijeg zdravlja te poplavljena područja, dok s druge strane visoke vrijednosti NDSI označuju područja zdrave vegetacije (Berhane i dr., 2018.). NDSI je generiran na temelju spektralnih kanala WV-2 multispektralnog snimka otoka Paga prema sljedećoj formuli (Wolf, 2012):

$$NDSI = \frac{Green - Yellow}{Green + Yellow} \tag{3}$$

D) Ograničavajući kriteriji

D1. Boolean kriterij

Ograničavajući Boolean kriterij obuhvaća sve metodom nadzirane klasifikacije izdvojene vodene i urbane površine kojim je dodijeljena vrijednost 0. Unutar urbanih površina okupljeni su svi stambeni i industrijski prostori te sve asfaltirane prometnice unutar otoka Paga. Dok unutar vodenih površina ne može doći do pojave erozije tla, unutar urbanih površina je zbog antropogenih intervencija pojava erozije tla vrlo kompleksna, te je zbog toga izostavljena iz modeliranja podložnosti.

III. Standardizacija kriterija

Nakon odabira kriterija za modeliranje podložnosti eroziji tla, uslijedio je korak standardizacije svih kriterija, odnosno ujednačavanja vrijednosti kriterija na jednaku brojčanu skalu (npr. 1 – 5) (Malczewski, 2015; Domazetović i dr., 2019a). Standardizacija kriterija je izvršena *metodom donosioca odluka*, uz pomoć alata *Decision maker standardization* (DMS) razvijenog u sklopu GAMA metode (Domazetović i dr., 2019b). Uz pomoć DMS alata svi odabrani predisponirajući kriteriji standardizirani su na skalu 1 – 5 (Sl. 47.), gdje su klase pojedinih kriterija s najmanjim utjecajem na podložnost eroziji tla dobile ocjenu 1, a klase s najvećim ocjenu 5.

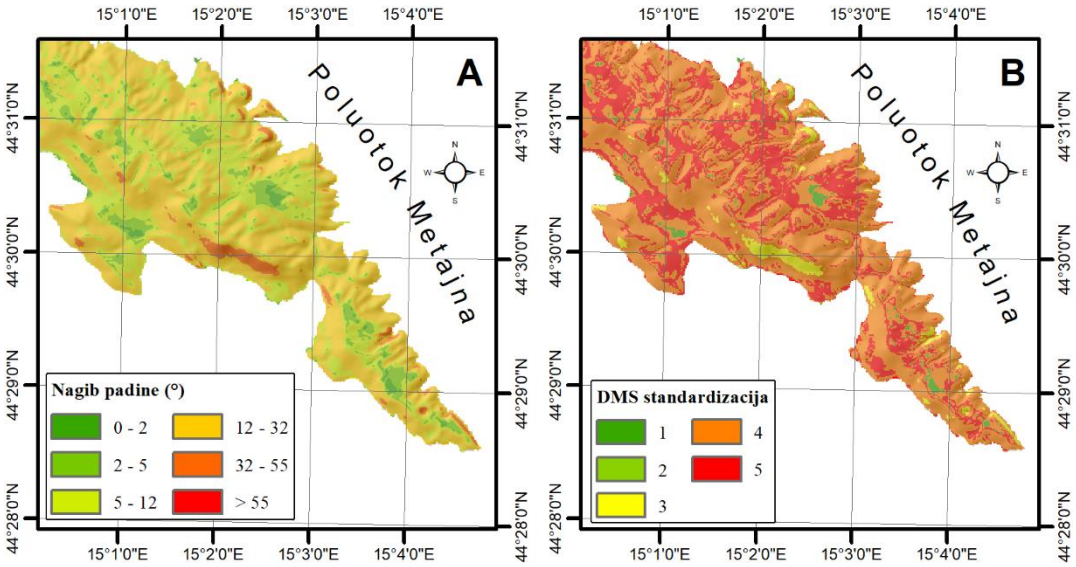

Slika 47. Primjer standardizacije kriterija nagiba padina uz pomoć DMS alata (*preuzeto iz* Domazetović i dr., 2019b).

Ocjene pojedinih klasa odabranih kriterija su u sklopu standardizacije metodom donosioca odluka odabrane na temelju primjera dobre prakse, zasnovanog na temeljitoj analizi vrijednosti standardizacije kriterija u postojećoj relevantnoj literaturi vezanoj za modeliranje podložnosti eroziji tla (Tabl. 10.).

Da bi se dodatno provjerio utjecaj specifičnih mikrolokacijskih značajki otoka Paga na podložnost eroziji tla, standardizirane klase odabranih kriterija su uspoređene s referentnim podacima o pojavnosti erozije tla. Za određivanje mikrolokacijskog utjecaja pojedinih klasa na podložnost eroziji tla korišten je točkasti vektorski sloj koji reprezentira 54 lokacije, unutar kojih su za vrijeme terenskih istraživanja utvrđeni recentni tragovi erozije tla. Referentne lokacije prikupljene su metodom ručne vektorizacije prema izrađenom multispektralnom WV-2 snimku, u mjerilu 1: 500. Međutim, kod kriterija izrađenih iz modela visoke prostorne rezolucije (1 m) točkasti referentni uzorci mogu dovesti do pojave subjektivnih vrijednosti uzrokovanih lokacijom prikupljenog uzorka (Sl. 48.B). Da bi se smanjila navedena subjektivnost točkastih uzoraka, vrijednosti pojedinih klasa određenog kriterija su za svaku lokaciju referentnog podatka određivane unutar tampon zone od 15 m, unutar koje je izdvojena najdominantnija klasa odabranog kriterija (Sl. 48.).

Navedeni princip površinskog određivanja dominantne vrijednost određenih kriterija vezanih za lokaciju referentnog uzorka pokazao se prikladnim za većinu odabranih kriterija, poput SLO, TPI ili pak PROF (Sl. 48.A; C; D). Međutim, kod pojedinih kriterija s vrlo velikom

prostornom varijabilnosti vrijednosti kriterija (npr. SPI ili TWI) i unutar poligonskog susjedstva može doći do pogrešnih vrijednosti. Na primjeru SPI kriterija (Sl. 48.B) vidljivo je da je unutar zadanog poligonskog susjedstva najdominantnija vrijednost klase 3, iz čega proizlazi da bi ona trebala dobiti najveću ocjenu prilikom standardizacije. S obzirom da u slučaju erozije tla kod SPI kriterija najveća ocjena mora biti dodijeljena prostorima najveće snage toka (klase 4 i 5), takva standardizacija ne bi bila ispravna. Zbog toga je u konačnici ipak prednost prilikom standardizacije stavljena na ocjene dodijeljene sukladno primjerima dobre prakse (Tabl. 10.), dok su vrijednosti dobivene navedenim principom određivanja dominantnih vrijednosti korištene isključivo za dodatnu provjeru dodijeljenih ocjena.

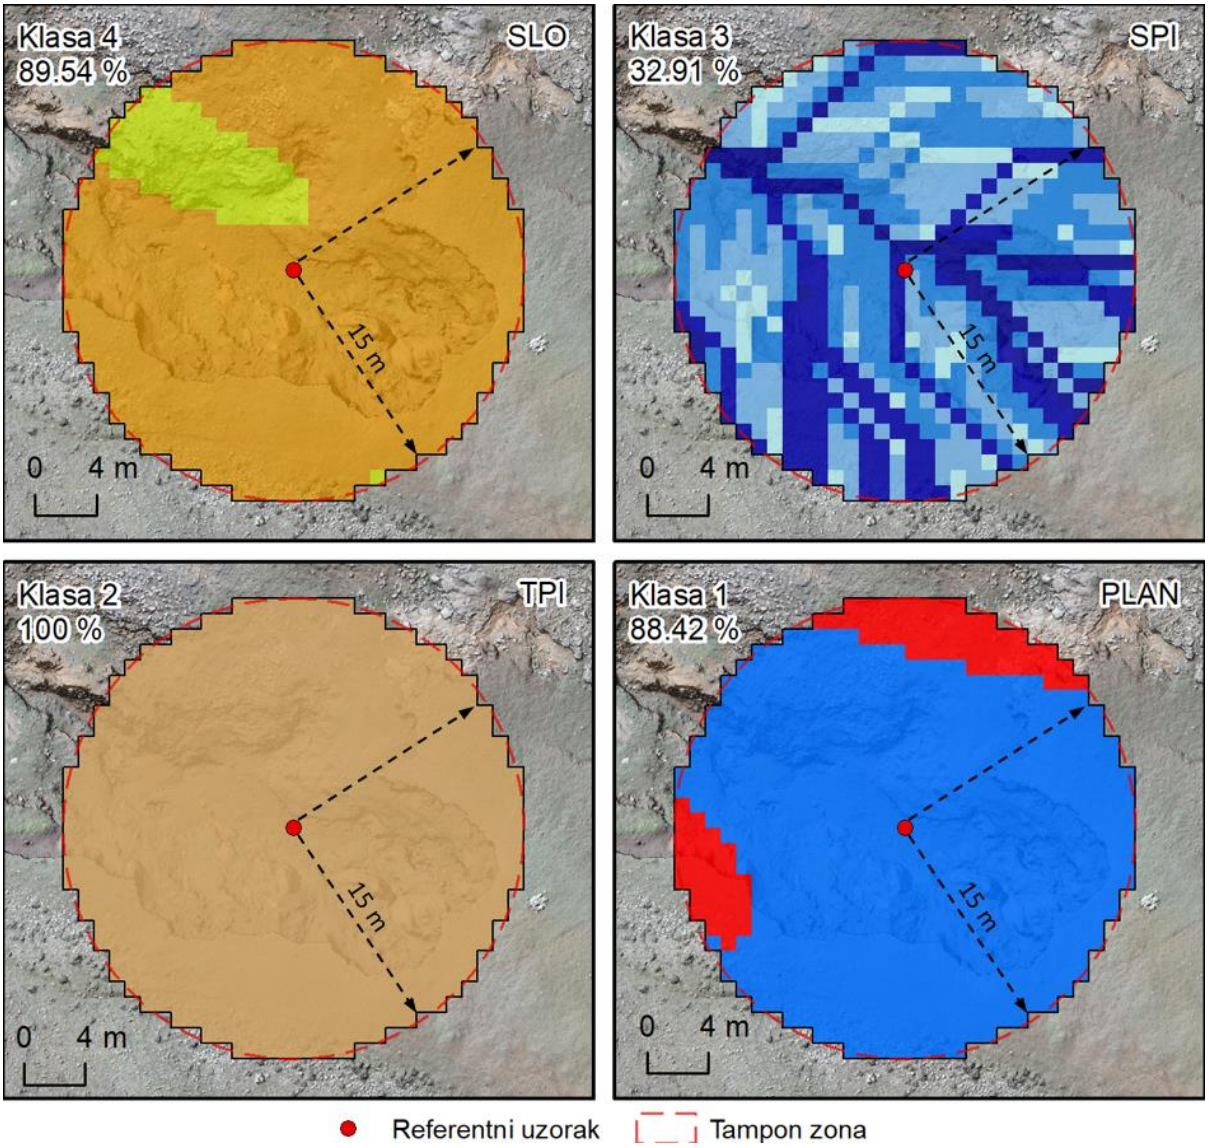

Slika 48. Princip određivanja dominantnih vrijednosti pojedinog kriterija unutar odabranog susjedstva oko referentnog erozijskog uzorka (A – SLO; B – TPI; C – PROF; D – LC)

Za procjenu utjecaja klasa svakog kriterija na podložnost eroziji tla iskorišteno je 70% svih prikupljenih referentnih lokacija (engl. *training dataset*), a preostalih 30% referentnih jaruga iskorišteno je za validaciju izrađenog modela (engl. *validation dataset*) (Sl. 49).

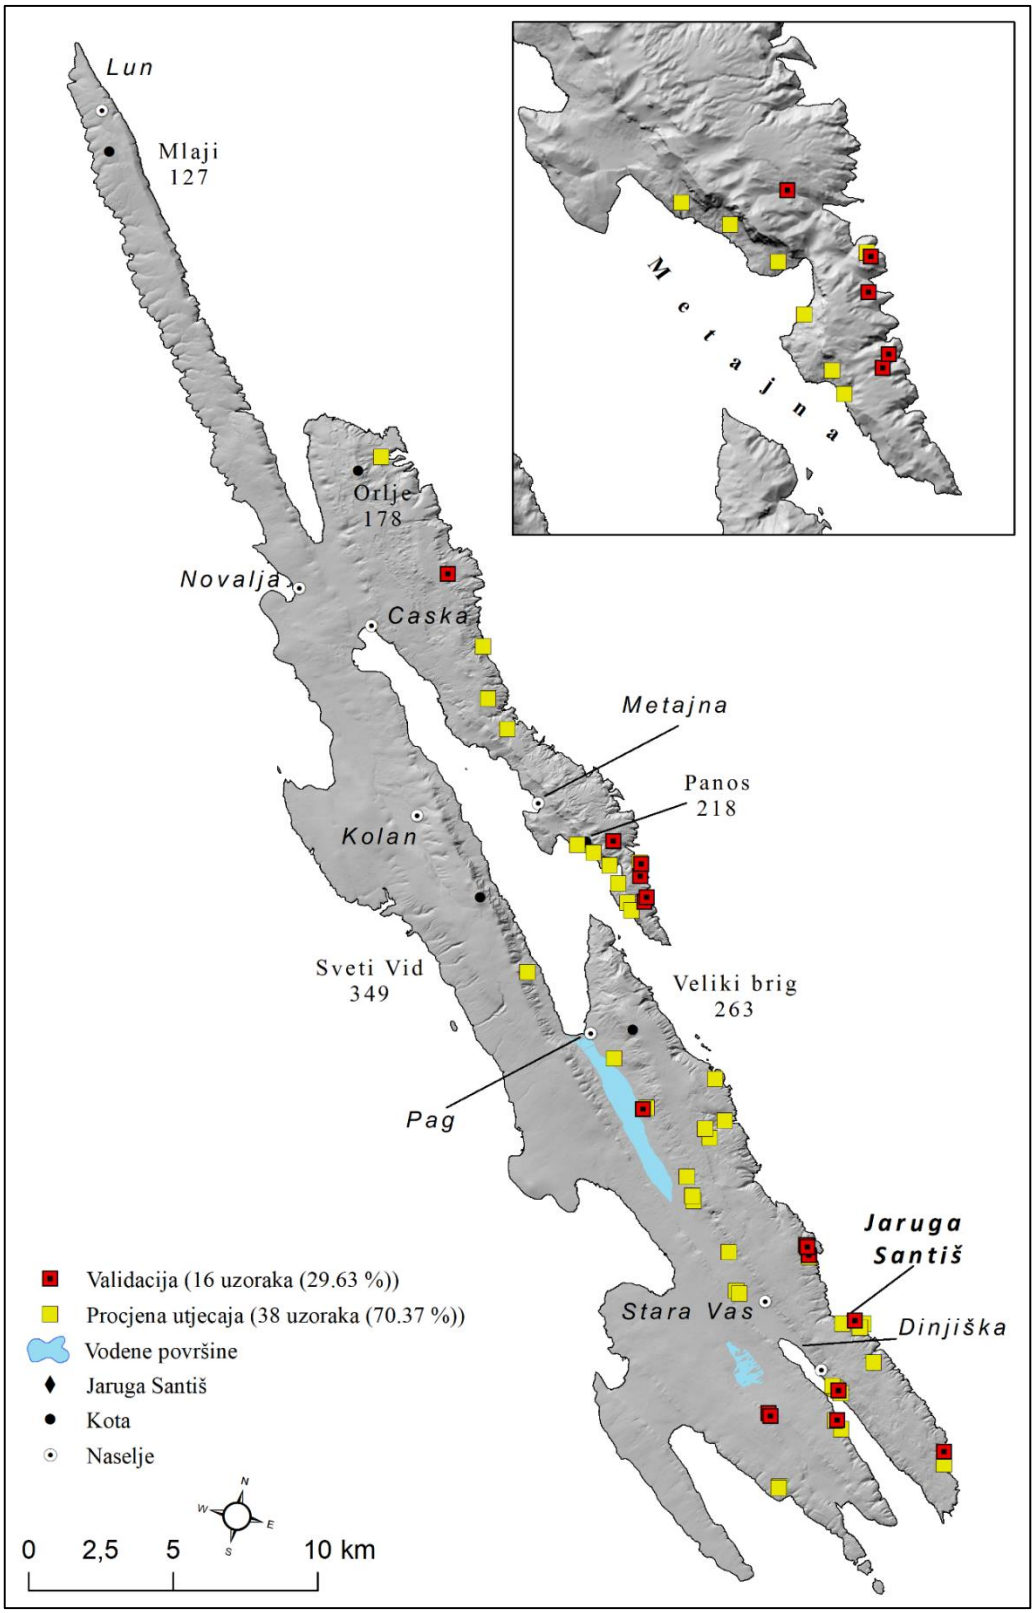

Slika 49. Prostorni raspored referentnih podataka unutar makro razine istraživanja

IV. Određivanje i dodjeljivanje težinskih koeficijenata

Određivanje težinskih koeficijenata pojedinih kriterija izvršeno je uz pomoć *analitičkog hijerarhijskog procesa* (engl. *analytical hierarchy process* - AHP) (Saaty, 2004; Saaty, 2008), koji se i u ranijim istraživanjima pokazao pouzdanom metodom za dodjeljivanje težinskih koeficijentima većem broju kriterija (Rahmati i dr., 2017b; Arabameri i dr., 2018; Domazetović i dr., 2019a; Igwe i dr., 2020).

Kriteriji raspoređeni unutar pojedine grupe se hijerarhijski uspoređuju i rangiraju po važnosti za modeliranje podložnosti, pri čemu se važnost pojedinog kriterija izražava kroz dodijeljeni težinski koeficijent (Taherdoost, 2017). Tablični prikaz matrica dvostruke usporedbe odabranih kriterija uz pomoć AHP-a dan je po grupama kriterija u tablicama 13., 14. i 15.

Tablica 13. Matrica dvostruke usporedbe grupe morfometrijskih kriterija uz pomoć AHP-a

Kriterij	SLO	ASP	PROF	PLAN	MBI	TPI	TRI
SLO	**1**	2	5	5	4	2	7
ASP	1/2	**1**	3	3	1	3	5
PROF	1/5	1/3	**1**	1	1	1/3	1/2
PLAN	1/5	1/3	1	**1**	1	1/3	1/2
MBI	1/4	1	1	1	**1**	1/3	2
TPI	1/2	1/3	3	3	3	**1**	5
TRI	1/7	1/5	2	2	1/2	1/5	**1**

Tablica 14. Matrica dvostruke usporedbe grupe hidroloških kriterija uz pomoć AHP-a

Kriterij	TWI	SPI	LSF	VDC	WAT	DD	CI
TWI	**1**	1	6	3	9	6	9
SPI	1	**1**	6	3	9	6	9
LSF	1/6	1/6	**1**	1/3	3	1	3
VDC	1/3	1/3	3	**1**	6	3	6
WAT	1/9	1/9	1/3	1/6	**1**	1/3	1
DD	1/6	1/6	1	1/3	3	**1**	1
CI	1/9	1/9	1/3	1/6	1	1	**1**

Tablica 15. Matrica dvostruke usporedbe grupe ostalih kriterija uz pomoć AHP-a

Kriterij	LC	NDVI	NDSI
LC	**1**	3	6
NDVI	1/3	**1**	3
NDSI	1/6	1/3	**1**

Zbroj svih težinskih koeficijenata unutar jedne grupe kriterija mora biti jednak 1, a vrijednost *indeksa konzistencije* (engl. *Consistency Indeks* (CI)) mora biti ispod 0.1 (Saaty, 2008; Franek i Kresta, 2014). Vrijednosti težinskih koeficijenata i indeksa konzistencije za pojedine grupe kriterija dan je u tablicama 16. i 17.

Tablica 16. Težinski koeficijenti kriterija iz grupe morfometrijskih (lijevo) i hidroloških (desno) kriterija izračunati uz pomoć AHP-a

ID	Kriterij	Težinski koeficijent	Postotak (%)	ID	Kriterij	Težinski koeficijent	Postotak (%)
1.1	SLO	0.33	33.2	2.1	TWI	0.34	33.1
1.2	ASP	0.21	21.3	2.2	SPI	0.34	33.1
1.3	PROF	0.07	6.0	2.3	LSF	0.06	6.6
1.4	PLAN	0.07	6.0	2.4	VDC	0.15	15.4
1.5	MBI	0.09	9.1	2.5	WAT	0.02	2.8
1.6	TPI	0.17	17.9	2.6	DD	0.06	5.6
1.7	TRI	0.06	6.5	2.7	CI	0.03	3.4
UKUPNO		1	100	UKUPNO		1	100
CI		0.082		CI		0.044	

Tablica 17. Težinski koeficijenti kriterija iz grupe ostalih kriterija izračunati uz pomoć AHP-a

ID	Kriterij	Težinski koeficijent	Postotak (%)
3.1	LC	0.65	65.3
3.2	NDVI	0.25	25.1
3.3	NDSI	0.09	9.6
UKUPNO		1	100
CI		0.023	

V. Agregiranje kriterija i izrada modela

Agregiranje kriterija i izrada konačnog višekriterijskog modela napravljena je uz pomoć alata razvijenih u sklopu GAMA metode kroz sljedeće dvije razine agregiranja: *agregiranje kriterija i njihovih težinskih koeficijenata unutar grupa kriterija* (**1**) te *agregiranje grupa kriterija i njihovih težinskih koeficijenata* (**2**).

Agregiranje kriterija unutar tri određene grupe kriterija (**1**) napravljeno je uz pomoć *Criteria grouping and weight assignment* (CGW) alata. CWG omogućava raspoređivanje odabranih kriterija u dvije ili više grupa kriterija, pritom pridodajući pripadajuće jedinstvene izračunate težinske koeficijente svakom kriteriju unutar određene grupe (Domazetović i dr., 2019b). U sklopu ove disertacije CGW alat je korišten za agregiranje kriterija i njihovih težinskih koeficijenata unutar tri odabrane grupe kriterija (morfometrijski, hidrološki i ostali kriteriji). Time je u konačnici izrađen po jedan agregirani rasterski model za svaku od tri odabrane grupe kriterija.

Zatim je uslijedilo agregiranje *grupa kriterija i njihovih težinskih koeficijenata* (**2**), koje je napravljeno uz pomoć *Susceptibility model aggregation* (SMA) alata. SMA alat omogućava završno agregiranje izrađenih grupa kriterija s odabranim ograničavajućim *Boolean* kriterijem, pri čemu je također grupama kriterija moguće pridodati odgovarajuće težinske koeficijente (Domazetović i dr., 2019b). Prilikom primjene SMA alata grupe kriterija su agregirane s pripremljenim BLN kriterijem, koji predstavlja sve vodene i urbane površine unutar otoka Paga. U konačnici su uz pomoć SMA alata izrađena četiri različita finalna višekriterijska modela podložnosti eroziji tla, pri čijoj izradi su korišteni različiti težinski koeficijenti (Tabl. 18.). Dok je kod modela VMPET-2 naglasak stavljen na grupu morfometrijskih kriterija, kod modela VMPET-3 naglasak je stavljen na grupu hidroloških kriterija, a kod VMPET-4 modela na grupu

ostalih kriterija. Model VMPET-1 predstavlja model kod kojega su sve tri grupe kriterija jednako važne.

Tablica 18. Težinski koeficijenti dodijeljeni pojedinim grupama kriterija

Naziv modela	Težinski koeficijent G1 (%)	Težinski koeficijent G2 (%)	Težinski koeficijent G3 (%)	Ukupno (%)	CI
VMPET-1	0.333 (33.3)	0.333 (33.3)	0.333 (33.3)	1 (100)	-
VMPET-2	0.595 (59.5)	0.277 (27.7)	0.129 (12.9)	1 (100)	0.006
VMPET-3	0.274 (27.4)	0.639 (63.9)	0.087 (8.7)	1 (100)	0.039
VMPET-4	0.251 (25.1)	0.096 (9.6)	0.653 (65.3)	1 (100)	0.013

VI. Procjena pouzdanosti i točnosti modela

Procjena pouzdanosti i točnost izrađenih GIS-MCDA modela podložnosti prostora otoka Paga eroziji tla napravljena je na temelju preklapanja modela s dostupnim referentnim podacima. U prvom redu su za procjenu točnosti iskorišteni preostali (30 %) referentni podaci o lokacijama postojećih erozijskih oblika, nastali vizualnom interpretacijom i ručnom vektorizacijom multispektralnog WV snimka (1: 500). Pri tome je radi smanjenja subjektivnosti točnost procjenjivana unutar tampon zone od 15 m oko svakog točkastog uzorka (Sl. 50.). Nadalje, radi usporedivosti izrađenog modela s rezultatima ranije provedenog istraživanja, za procjenu pouzdanosti i točnosti su iskorišteni referentni vektorski poligonski podaci, koji su korišteni za provjeru točnosti modela u sklopu ranijeg istraživanja (Sl. 51; Domazetović i dr., 2019a). Navedeni referentni podaci predstavljaju 10 referentnih jaruga, ručno vektoriziranih prema VHR digitalnom ortofoto predlošku (DGU, 2018) (Domazetović i dr., 2019a).

Procjena točnosti izrađenih modela temeljila se na izradi *operativnih karakterističnih krivulja* (engl. *receiver operating characteristics curve – ROC curve*) i izračunu površine ispod krivulje (engl. *area under curve – AUC*), koji predstavljaju jednu od najčešće korištenih metoda za provjeru točnosti izrađenih GIS-MCDA modela (Arabameri i dr., 2018; Domazetović i dr., 2019a; Arabameri i dr., 2020b). Pri tome vrijednosti AUC variraju između 0 i 1, gdje vrijednosti ovog parametra ukazuju na razinu točnosti modela: *loša točnost* (<0.6), *srednja točnost* (0.6 – 0.7), *dobra točnost* (0.7 – 0.8), *vrlo dobra točnost* (0.8 – 0.9) te *odlična točnost* (>0.9) (Arabameri i dr., 2018; Arabameri i dr., 2020b). Izrada ROC krivulja automatizirana je unutar besplatno dostupnog **Dinamica EGO 5.2.1.** softvera (Mas i dr., 2013).

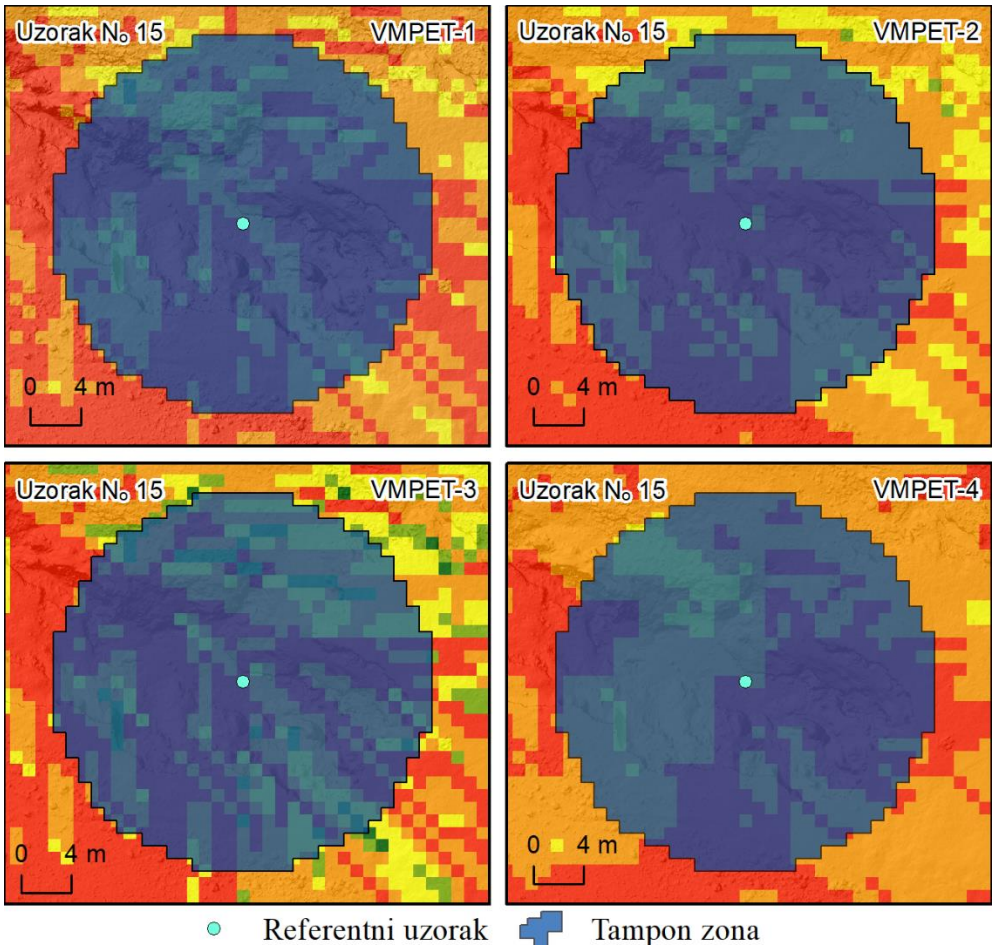

Slika 50. Validacija izrađenih GIS-MCDA modela unutar tampon zone od 15 m oko referentnog točkastog uzorka

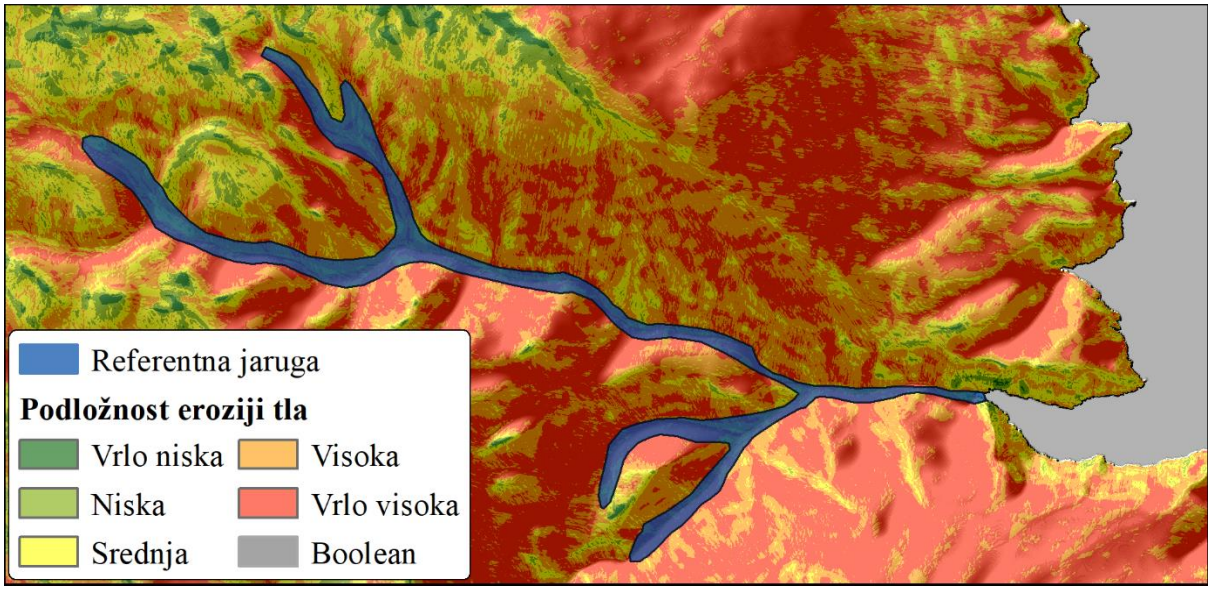

Slika 51. Validacija izrađenog GIS-MCDA modela uz pomoć referentnih vektorskih poligonskih podataka

3.2. Pregled metodologije mezo razine istraživanja

Unutar mezo razine metodologija istraživanja bazirala se na *prikupljanju dostupnih aerofotogrametrijskih podataka Državne geodetske uprave za širi prostor poluotoka Santiš* (**A**) te *terenskoj primjeni različitih suvremenih geoprostornih tehnologija za intervalno prikupljanje podataka unutar prostora jaruge Santiš* (**B**). Prikupljani aerofotogrametrijski podaci (A i B) omogućili su izradu modela vrlo visoke rezolucije, na temelju kojih su kvantificirane i interpretirane prostorno-vremenske promjene nastale unutar proučavanog razdoblja.

Prikupljeni dostupni aerofotogrametrijski podaci Državne geodetske uprave nisu zahtijevali provođenje nikakvih terenskih aktivnosti, već se odmah nakon nabavljanja podataka moglo pristupiti njihovoj obradi i izradi modela šire mezo razine istraživanja.

Terenska istraživanja u sklopu užeg dijela mezo razine istraživanja zasnivala su se na primjeni intervalne UAV fotogrametrije za snimanje prostora jaruge Santiš. Longitudinalno terensko istraživanje, koje je unutar užeg dijela mezo razine započelo 17. prosinca 2019. godine, trajalo je ukupno godinu dana, do 17. prosinca 2020. godine. Navedena terenska istraživanja su nastavak ranijih istraživanja koja su unutar istog prostora istraživanja započela još početkom 2017. godine (Domazetović, 2018; Šiljeg i dr., 2021). Treba napomenuti da će se započeto longitudinalno istraživanje nastaviti i izvan ove doktorske disertacije, pri čemu će se za potrebe ove disertacije koristiti isključivo rezultati navedenog jednogodišnjeg razdoblja. Hodogram provedenih terenskih istraživanja i dostupnih podataka vidljiv je na slici 52.

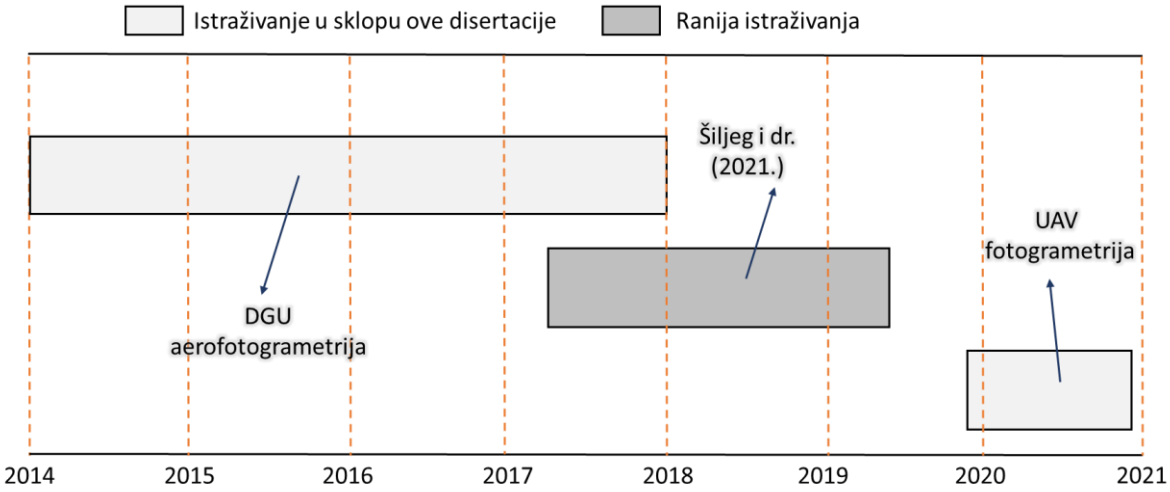

Slika 52. Hodogram istraživanja provedenih unutar mezo razine istraživanja

3.2.1. Izrada modela iz aerofotogrametrijskih podataka Državne geodetske uprave

Intervalni modeli poluotoka Santiš napravljeni su na temelju arhivskih aerofotogrametrijskih snimaka Državne geodetske uprave (DGU). Aerofotogrametrijski snimci nastaju u sklopu sustavnih zračnih snimanja cijelog teritorija Republike Hrvatske, koja Državna geodetska uprava provodi periodički svakih nekoliko godina (DGU, 2018). Iako prva zračna snimanja određenih dijelova Hrvatske započinju još početkom 1930-tih godina, prva sustavna aerofotogrametrijska snimanja izvode se tek nakon II. svjetskog rata (Biočić, 2014.). Tijekom godina mijenjali su se sukladno dostupnosti i svrsi snimanja mjerilo aerofotogrametrijskih snimanja te tip korištenih aerofotogrametrijskih kamera. Postupno su se razvijale kamere sa sve boljim tehničkim specifikacijama, koje su omogućile postizanje kvalitetnije rezolucije prikupljenih snimaka i detekciju sitnijih detalja na snimcima. Stoga prilikom korištenja dostupnih arhivskih aerofotogrametrijskih snimaka treba voditi računa o tehničkim specifikacijama korištenih kamera.

Od 2009. godine aerofotogrametrijski snimci Državne geodetske uprave nastaju periodičkim zračnim snimanjima s digitalnom kamerom pričvršćenom na žiroskopski stabilizirana postolja, fiksirana iznad otvora u dnu zrakoplova (Sl. 53.) (DGU, 2018; Landeka i Vilus, 2012.).

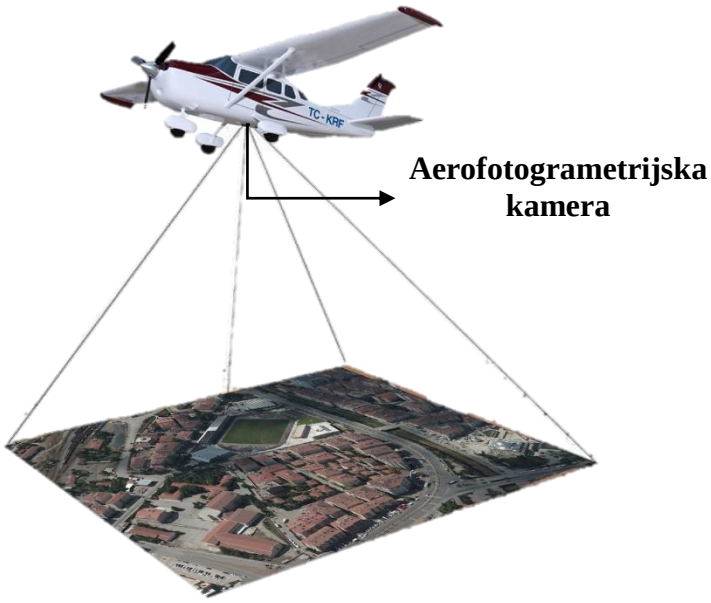

Slika 53. Princip prikupljanja aerofotogrametrijskih podataka uz pomoć digitalne kamere fiksirane u dnu zrakoplova (*preuzeto iz* DGU, 2018)

I. Dostupni aeroftogorametrijski podaci Državne geodetske uprave

Za potrebe izrade ove doktorske disertacije kupljeni su svi dostupni aerofotogrametrijski podaci *Državne geodetske uprave* za širi prostor poluotoka Santiš, koji su omogućili provođenje intervalnog praćenja prostorno-vremenskih promjena nastalih u razdoblju od gotovo 60 godina (1959. – 2018.). Međutim, zbog velike količine dostupnih snimaka i dugotrajne obrade, ali i razlike u rezoluciji dostupnih snimaka, u sklopu ove disertacije obrađeni su isključivo najrecentniji aerofotogrametrijski snimci (2014; 2018.), prikupljeni s najmodernijim UltraCam aerofotogrametrijskim kamerama. Pregled svih ustupljenih aerofotogrametrijskih snimaka i obrađenih podataka dan je u tablici 19.

Tablica 19. Pregled aerofotogrametrijskih podataka preuzetih za mezo razinu istraživanja

ID	Tip podatka	Model kamere	Godina prikupljanja	Broj snimaka
1	Digitalizirani analogni aerofotogrametrijski snimak	Nema podatka [18]	1959	4
2	Digitalizirani analogni aerofotogrametrijski snimak	Nema podatka	1973	4
3	Digitalizirani analogni aerofotogrametrijski snimak	Leica RC-20 15/4 UAGA-F	1997	4
4	Digitalizirani analogni aerofotogrametrijski snimak	Carl Zeiss RMK Top 15	2001	3
5	Digitalizirani analogni aerofotogrametrijski snimak	Leica RC-20 15/4 UAGA-F	2006	7
6	Digitalni aerofotogrametrijski snimak	Intergraph Z/I Imaging Digital Mapping Camera (DMC)	2007	4
7	Digitalni aerofotogrametrijski snimak	Vexcel Imaging GmbH UltraCam X	2011	4
8	Digitalni aerofotogrametrijski snimak	Vexcel Imaging GmbH UltraCam Condor M1 f80	2014	4
9	Digitalni aerofotogrametrijski snimak	Vexcel Imaging GmbH UltraCam Eagle M3 f100	2018	5

Od 2011. godine aerofotogrametrijska snimanja su na prostoru otoka Paga provedena multispektralnim digitalnim aerofotogrametrijskim UltraCam kamerama, razvijenim od strane austrijske tvrtke Vexcel Imaging GmbH (Vexcel Imaging, 2020a; Vexcel Imaging, 2020b).

[18] Aerofotogrametrijska snimanja nakon završetka II. svjetskog rata obavljao je Geografski institut JNA, a kasnije Vojnogeografskog institut iz Beograda (Biočić, 2014.), zbog čega točni podaci o korištenom modelu kamere nisu dostupni.

UltraCam aerofotogrametrijske kamere istovremeno prikupljaju pankromatski snimak, vidljivi dio spektra (crvena-zelena-plava (engl. *red-green-blue* - *RGB*) te blisko infracrveni spektar (engl. *Near InfraRed – NIR*) u vrlo visokoj prostornoj rezoluciji (Tonković, 2006; Gruber i dr., 2008; Landeka i Vilus, 2012; DGU, 2018.). Aerofotogrametrijski sustav opremljen UltraCam kamerom moguće je raščlaniti na četiri osnovne komponente (Sl. 54.).

Slika 54. Komponente aerofotogrametrijskog sustava opremljenog UltraCam Eagle multispektralnom kamerom (A – zrakoplov; B – multispektralna kamera; C – stabilizator kamere; D – promjenjivi objektivi)

UltraCam aerofotogrametrijska kamera (Sl. 54. B) postavljena je iznad posebno izrađenog otvora u trupu zrakoplova (Sl. 54. A) na UltraMount stabilizator ((Sl. 54. C), čija svrha je postizanje oštrih snimaka, odnosno uklanjanje zamućenja i distorzija uzrokovanih trešnjom kamere prilikom prikupljanja snimaka (Vexcel Imaging, 2020c). Dok je objektiv UltraCam Condor mutlispektralne kamere, korištene za aerofotogrametrijsko snimanje iz 2014. godine, nepromjenjiv (fiksan), objektiv UltraCam Eagle kamere korištene 2018. godine je promjenjiv (Sl. 54. D). Sukladno tome i tehničke specifikacije korištenih kamera nisu jednake, o čemu je bilo potrebno voditi računa prilikom izrade intervalnih modela.

Detaljne tehničke specifikacije različitih korištenih modela UltraCam Eagle aerofotogrametrijskih kamera dane su u tablici 20, a značajke aerofotogrametrijskih snimaka u tablici 21.

Tablica 20. Tehničke specifikacije UltraCam multispektralnih aerofotogrametrijskih digitalnih kamera korištenih za prikupljanje snimaka (Vexcel Imaging, 2020a; 2020b)

Model kamere	**UltraCam Condor M1 f80**	**UltraCam Eagle M3 f100**
Pankromatski kanal		
Veličina snimka (pix)	13 280 x 9000	26 460 x 17 004
Veličina snimka (mm)	104,05 x 68,02	68,01 x 105,84
Veličina piksela	5.2 µm	4 µm
Žarišna duljina	79.8 mm	100.5 mm
Otvor leće	f = 1/5.6	f = 1/6.7
Multispektralni kanali		
Spektralni kanali	R; G; B, NIR	R; G; B, NIR
Veličina snimka (pix)	38 000 x 9000	8820 x 5668
Veličina piksela	4.6 µm	4 µm
Žarišna duljina	27	33
Otvor leće	f = 1/5.6	f = 1/4.8
Generalne značajke		
Masa	64 kg	61 kg
Dimenzije kamere (cm)	43 x 43 x 76	43 x 43 x 76
GSD pri visini leta od 1000 m (500 m)	6.5 cm (3.25 cm)	3.95 cm (1.97 cm)
Minimalni interval između fotografija	1.75 sekunde	1.8 sekunde
Radiometrijska rezolucija u svakom kanalu	12 bit	12 bit
Potrošnja energije	350 W	350 W

Tablica 21. Značajke snimaka upotrebljenih za izradu intervalnih modela

ID	Godina	Broj snimaka	Žarišna duljina (mm)	Širina snimke (m)	Duljina snimke (m)	Visina leta (m)	GSD (cm)
DGU-1	2014	6	79.8	6080	3974	4598	29.96
DGU-2	2018	5	100.5	4866	7572	7189.9	28.62

II. Obrada aerofotogrametrijskih podataka Državne geodetske uprave

Aerofotogrametrijski snimci obrađeni su u Agisoft Metashape 1.5.1. softveru, pri čemu je cijeli proces obrade generalno moguće podijeliti u osam koraka (Sl. 55.). Proces obrade snimaka proveden je prema smjernicama danim u relevantnim sličnim istraživanjima (Eltner i dr., 2015; Aucelli i dr., 2016; Eltner i dr., 2016; James i dr.,2017a; 2017b; 2019; Bates, 2019; Fernández i dr., 2020; Marić i dr., 2020).

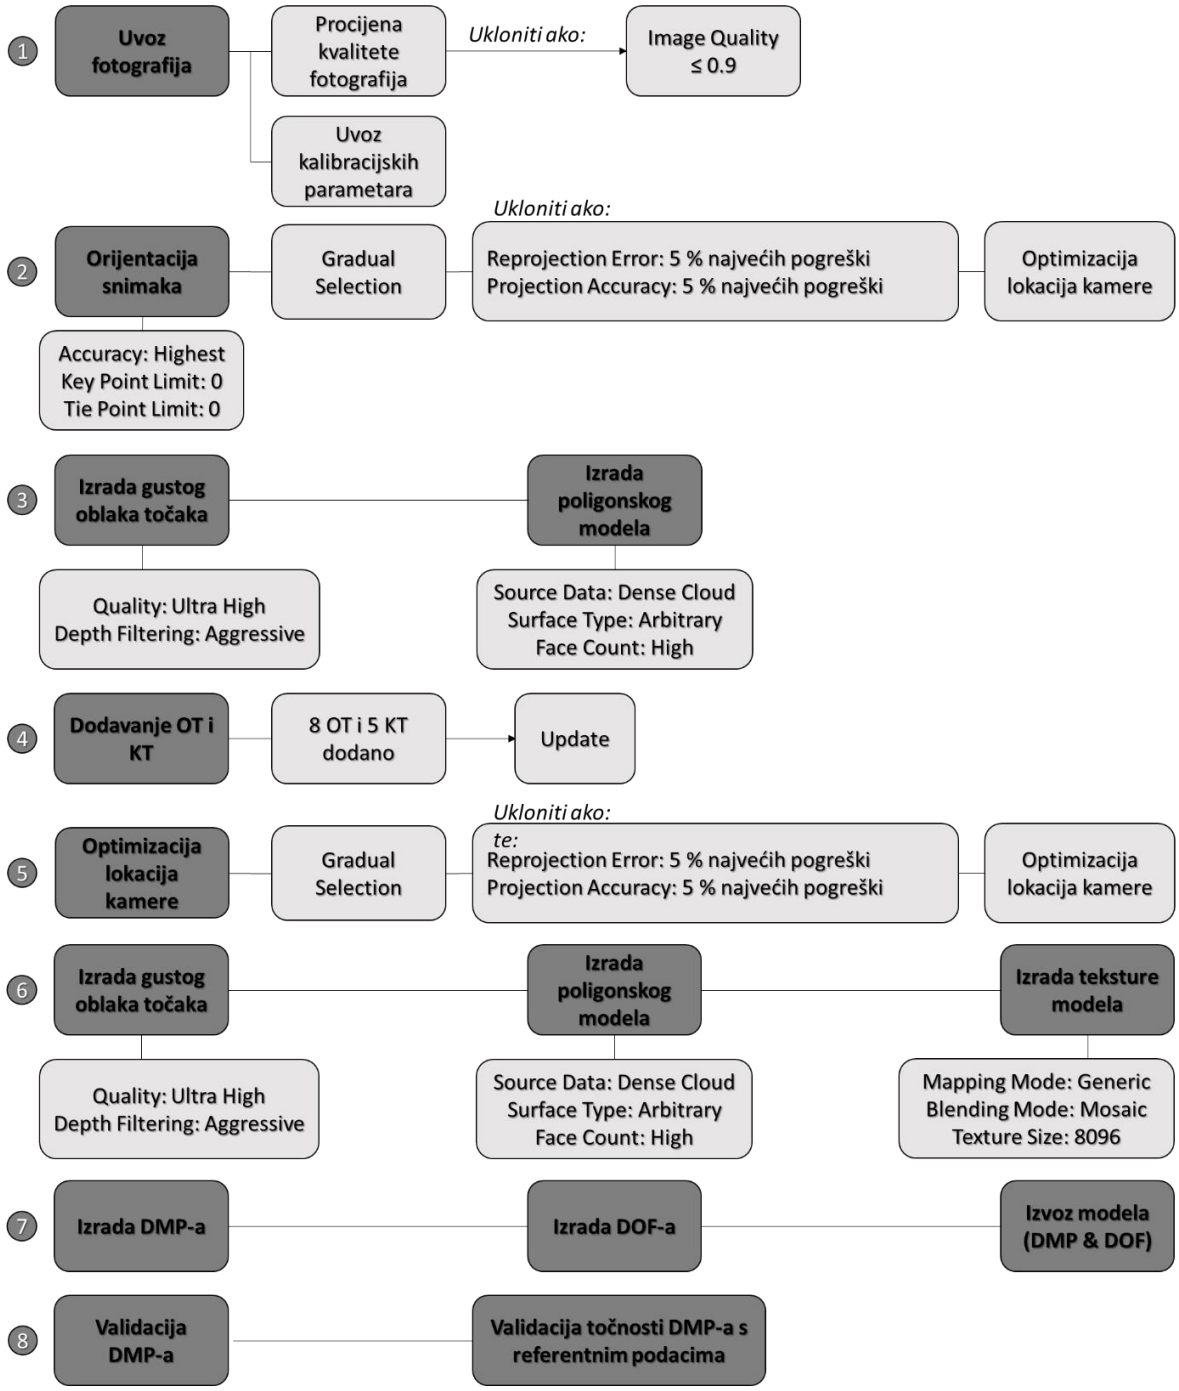

Slika 55. Koraci i parametri obrade aerofotogrametrijskih snimaka u Agisoft Metashape-u (prema Marić i dr., 2020., modificirano)

Prvi korak obuhvaćao je dodavanje aerofotogrametrijskih snimaka te provjeru njihove inicijalne kvalitete (engl. *estimate image quality*), pri čemu je izvršena filtracija svih snimaka, odnosno uklanjanje snimaka s kvalitetom ≤ 0.9. Nakon filtriranja snimaka lošije kvalitete uslijedilo je dodavanje kalibracijskih parametara kamere, u prvom redu veličine piksela (mm) te žarišne udaljenosti objektiva (mm) kamere. Kako su za prikupljanje aerofotogrametrijskih snimaka korištene različite kamere, bilo je potrebno unijeti različite kalibracijske parametre za svaki intervalni model[19].

Uklanjanjem snimaka manje kvalitete omogućena je relativna orijentacija snimaka (engl. *Align Photos*), preko koje se na temelju aerotriangulacije (engl. *aerial triangulation*) i podešavanja modela (engl. *bundle block adjustment*) određuje orijentacija svakog snimka u prostoru te pronalaze isti oblici, odnosno vezne točke unutar područja preklopa susjednih snimaka (Agisoft, 2020; Marić, 2020). Kao rezultat relativne orijentacije snimaka napravljen je rijetki oblak točaka (engl. *sparse point cloud*), koji predstavlja sve vezne točke pronađene na zadanim aerofotogrametrijskim snimcima, pri zadanim korisničko-definiranim parametrima. S obzirom da se prilikom izrade intervalnih modela htjela postići maksimalna prostorna rezolucija modela, bilo je potrebno postići maksimalnu gustoću rijetkog oblaka točaka, odnosno trebalo je korisničko-definirane postavke postaviti na maksimalne vrijednosti (*Accuracy = Highest; Key point limit = 0; Tie point limit = 0*).

Nakon izrade rijetkog oblaka točaka uslijedilo je smanjenje reprojekcijske pogreške (engl. *reprojection error*) i povećanje točnosti pozicioniranja (engl. *position accuracy*) pomoću alata postupne selekcije (engl. *gradual selection*). Pri tome je iz rijetkog oblaka točaka uklonjeno 5% svih veznih točaka s najvećim vrijednostima reprojekcijske pogreške, odnosno najmanjim vrijednostima točnosti pozicioniranja. Poslije izvršenih korekcija napravljena je optimizacija (engl. *Optimize Camera Locations*) rijetkog oblaka točaka (Sl. 55. – 2. korak)..

Iz optimiziranog rijetkog oblaka točaka napravljeni su preliminarni gusti oblak točaka (engl. *Build Dense Cloud*) i mreža poligona (engl. *Build Mesh*), pri čemu su za oba koraka korištene maksimalne vrijednosti korisničko-definiranih parametara (*Quality = Ultra High*; *Depth Filtering = Aggresive*) (Sl. 55. – 3. korak).

Nakon izrade preliminarnog gustog oblaka i mreže poligona uslijedilo je ručno dodavanje markera, odnosno oznake koje predstavljaju orijentacijske i kontrolne točke potrebne za apsolutnu orijentaciju modela (OT), odnosno provjeru točnosti modela (KT). Prostorni

[19] Kalibracijski parametri za pojedina aerofotogrametrijska snimanja ustupljeni su od strane DGU u obliku detaljnih izvještaja pojedinih aerofotogrametrijskih izmjera.

raspored OT i KT korištenih za izradu modela iz dostupnih aerofotogrametrijskih snimaka vidljiv je na slici 56.

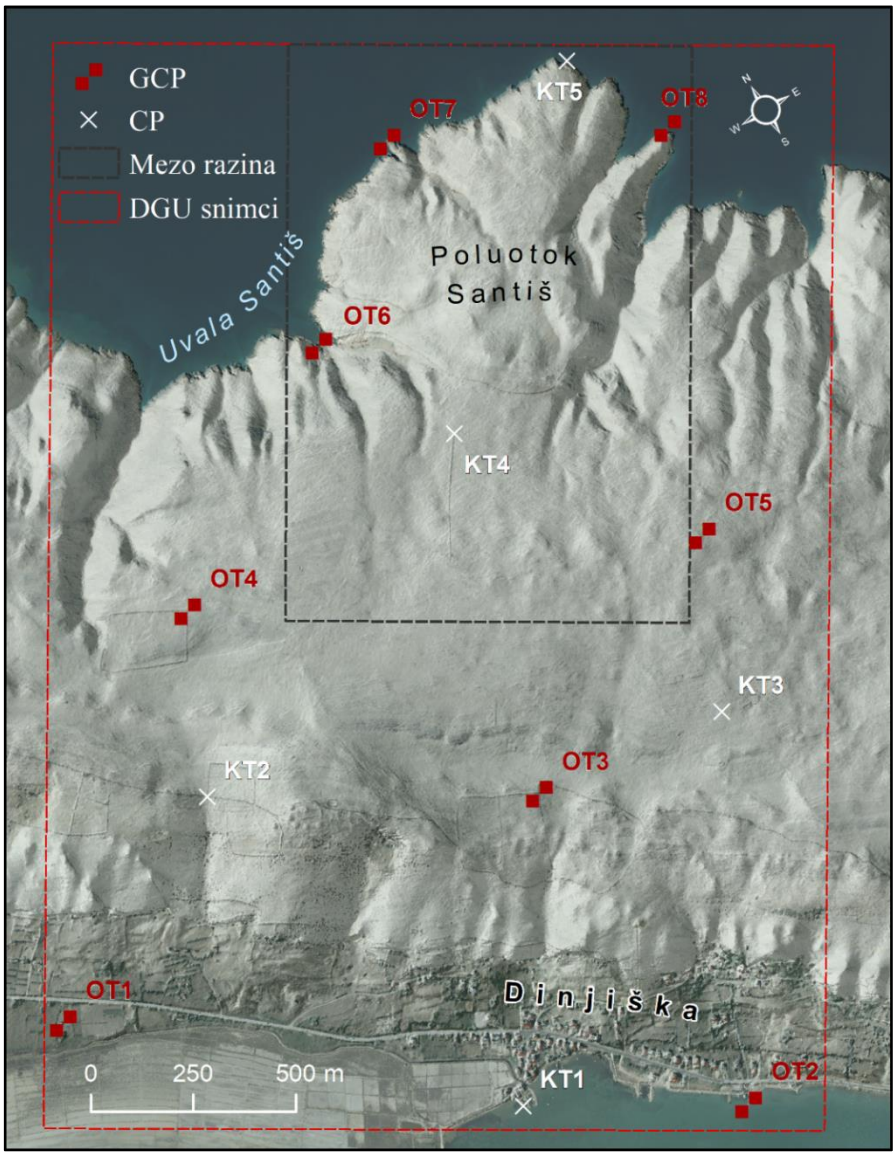

Slika 56. Prostorni raspored OT i KT unutar područja za koje su izrađeni modeli iz dostupnih aerofotogrametrijskih snimaka

Ukupno je dodano 8 OT i 5 KT, raspoređenih ravnomjerno unutar čitavog prostornog obuhvata ustupljenih aerofotogrametrijskih snimaka. Gdje je bilo moguće koordinate OT i KT prikupljene su na terenu uz pomoć Stonex S10 RTK-GNSS-a, prema metodologiji istovjetnoj makro razini (3.1.2.). Pri tome treba napomenuti da su za oba modela (DGU-1 i DGU-2) korištene identične OT i KT, jer se na taj način osigurala homogenost i točnost apsolutne orijentacije modela. Nakon dodavanja svih OT i KT uslijedila je ponovna korekcija gustog oblaka točaka, uz pomoć alata postupne selekcije (uklanjanje točaka s 5% s najvećim vrijednostima reprojekcijske pogreške, odnosno najmanjim vrijednostima točnosti

pozicioniranja) te optimizacija oblaka točaka. Poslije ponovljene optimizacije uslijedila je izrada konačnog gustog oblak točaka i konačne mreže poligona sa maksimalnim vrijednostima korisničko-definiranih parametara. U sklopu ovog koraka izrađena je i tekstura modela (engl. *Build texture*) (Sl. 55. – 6. korak).

Iz konačnog izrađenog gustog oblaka točaka napravljeni su digitalni model površina (engl. *Build DEM*) i digitalni ortofotosnimak (engl. *Build Orthomosaic*), koji su zatim eksportirani za daljnju obradu u HTRS96 projekciji.

Validacija točnosti izrađenih intervalnih modela

Provjera visinske točnosti izrađenih intervalnih modela (DGU-1 i DGU-2) napravljena je na temelju usporedbe 22 referentne točke, prikupljene u sklopu ranijih terenskih istraživanja unutar prostornog obuhvata izrađenih modela (Sl. 57.).

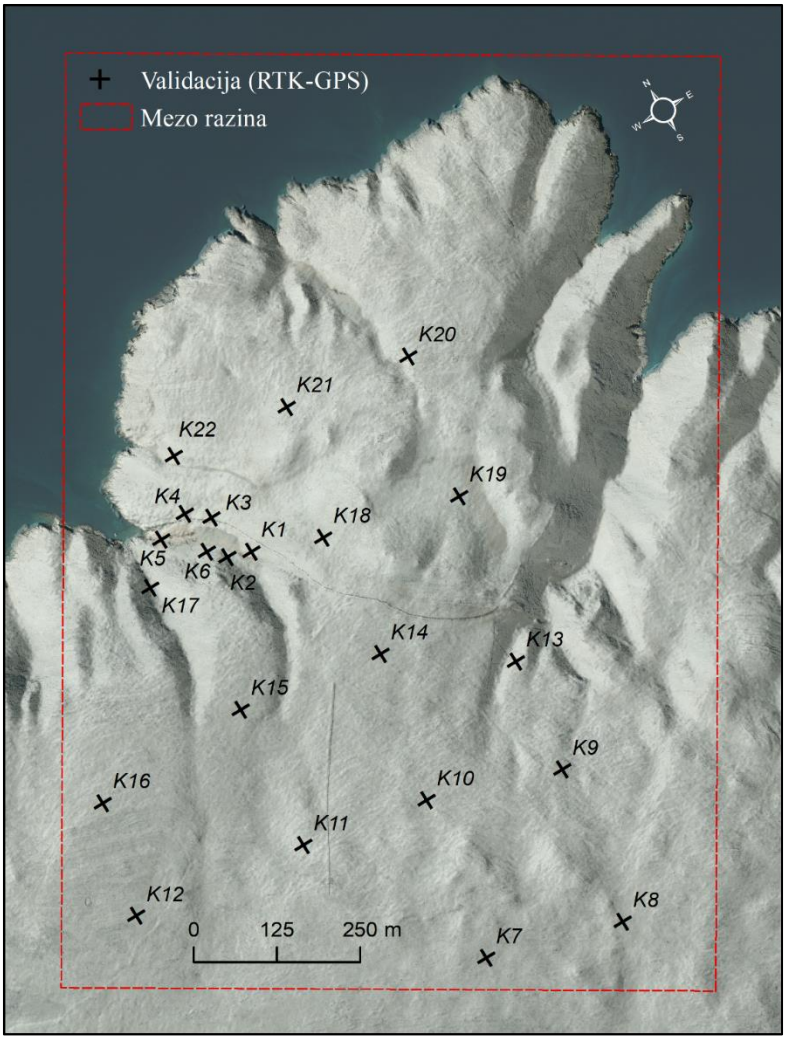

Slika 57. Referentne točke (RTK-GNSS) iskorištene za validaciju točnosti intervalnih modela

3.2.2. Aerofotogrametrijsko snimanje užeg prostora jaruge Santiš

Aerofotogrametrijsko snimanje užeg prostora jaruge Santiš zasnivalo se na višestrukoj, intervalnoj primjeni bespilotne letjelice (engl. *unmanned aerial vehicle* - UAV) opremljene DSLR kamerom namijenjenom prikupljanju aerofotogrametrijskih podataka te kasnijoj obradi prikupljenih snimaka i izradi VHR modela. Intervalna UAV fotogrametrija je odabrana kao praktična i relativno jeftina metoda za periodičko prikupljanje aerofotogrametrijskih podataka (Ryan i dr., 2014; Dewez i dr., 2016; Rossini i dr., 2018). Kao takva primjenjuje se u širokom spektru znanstvenih istraživanja, a u posljednjih nekoliko godina sve se više koristi i za detekciju prostorno-vremenskih promjena u različitim geomorfološkim istraživanjima (Westoby i dr., 2012; Clapuyt i dr., 2016; Eltner i dr., 2016; Cook, 2017; James i dr., 2017), pa tako i za praćenje intenziteta erozije tla (Stöcker i dr., 2015; Koci i dr., 2017).

I. Karakteristike razvijenog RAPS sustava

Osnovna aerofotogrametrijska snimanja zasnovana na intervalnoj UAV fotogrametriji izvršena su korištenjem RAPS (engl. *repeat aerophotogrammetry system*) aerofotogrametrijskog sustava, koji je za potrebe istraživanja razvijen u sklopu Laboratorija za geoprostorne tehnologije (GAL), Sveučilišta u Zadru (Sl. 58.).

Slika 58. Komponente razvijenog RAPS-a (*lijevo*); primjena RAPS-a za aerofotogrametrijsko snimanje jaruge (*desno*)

RAPS predstavlja napredni aerofotogrametrijski sustav, koji se sastoji od DJI Matrice 600 PRO bespilotne letjelice (Sl. 58. A), s kojom su funkcionalno integrirani Gremsy T3 stbilizator (engl. *gimbal*) (Sl. 58. B), Sony Alpha A7RII (42 MP) DSLR kamera s objektivom od 20 mm (Sl. 58. C) i Reach M+ GNSS modul za UAV kartiranje (Sl. 58. D) (Domazetović i dr., 2020; Šiljeg i dr., 2021).

DJI Matrice 600 PRO bespilotna letjelica profesionalne klase, razvijena za komercijalne potrebe od strane kineske *Dà-Jiāng Innovations* (DJI) kompanije (DJI, 2019). Zahvaljujući čvrstoj i laganoj konstrukciji izrađenoj od kevlara te snažnom pogonu kojega čini šest identičnih motora i propelera, ovu bespilotnu letjelicu karakterizira izrazita letačka sposobnost i upravljivost, te mogućnost integriranja različitih pasivnih i aktivnih senzora (npr. profesionalne DSLR kamere, multispektralne i termovizijske kamere, aeroLiDAR senzori, itd.) ukupne mase do 5.9 kg (DJI, 2019). S bespilotnom letjelicom je integriran sofisticirani Gremsy T3 stabilizator, koji omogućava naprednu stabilizaciju kamere, horizontalnu rotaciju kamere od 360º i vertikalnu rotaciju od 90º. Gremsy T3 stabilizator je kompatibilan s različitim profesionalnim DSLR kamerama i objektivima (Gremsy, 2019). Okosnica razvijenog RAPS-a je integrirana profesionalna DSLR Sony Alpha A7RII kamera koja zahvaljujući rezoluciji od 42 MP omogućava prikupljanje aerofotogrametrijskih snimaka s izrazito velikom oštrinom i detaljnosti prikaza. Posljednja komponenta RAPS-a je Reach M+ GNSS modul za UAV kartiranje, koji omogućava dodavanje xyz koordinate svakom prikupljenom aerofotogrametrijskom snimku (Emlid, 2019). Detaljan pregled tehničkih specifikacija razvijenog RAPS sustava dan je u tablici 22.

Tablica 22. komponente (A), parametri (B) i specifikacije (C) RAPS-a

#	Komponenta (A)	Parametar (B)	Vrijednost (C)
1.	DJI Matrice 600 PRO	Vrijeme leta (min)	16 – 32 min
2.		Maksimalna masa pri uzlijetanju (kg)	15.5
3.		Maksimalna otpornost na vjetar (m/s)	8
4.		Maksimalna visina leta (mnm)	2500
5.		Maksimalna daljina transmisije signala (m)	5000
6.	Sony Alpha A7RII	Veličina senzora	861.6 mm² (35.90mm x 24.00mm)

7.		Masa kamere (kg)	0.64
8.		Otvor blende	f/3.5 - f/22
9.		Senzor (px)	7952 x 5304
10.		Osjetljivost senzora na svjetlo (ISO)	100 - 25600
11.		Brzina zatvarača	1/8000 - 30 sec
12.		Žarišna duljina (mm)	28 - 70

II. Planiranje i priprema aerofotogrametrijskih snimanja šireg prostora jaruge Santiš

Planiranje i priprema aerofotogrametrijskog snimanja je ključna faza primjene intervalne UAV fotogrametrije, o kojoj ovisi uspješnost i usporedivost intervalnih modela (James i dr., 2017a). Kako bi se osigurala dosljednost i ponovljivost intervalnih aerofotogrametrijskih snimanja provedenih nad širim prostorom jaruge Santiš, ali i postigla maksimalna kvaliteta izrađenih modela, izrađen je detaljan plan snimanja. Planiranje intervalnih aerofotogrametrijskih snimanja uključivalo je *određivanje prostornog obuhvata aerofotogrametrijskog snimanja* (1), *odabir broja i optimalnih lokacija za OT i KT* (2) te *planiranje i automatiziranje letačkih misija* (3). Pri tome je metodologija planiranja i pripreme intervalnih aerofotogrametrijskih snimanja slijedila smjernice dane u relevantnim sličnim istraživanjima (Clapuyt i dr., 2016; Cook, 2017; Eltner i dr., 2015; 2016; James i dr.,2017a; 2017b; 2019).

Prije svega bilo je potrebno *odrediti prostorni obuhvat aerofotogrametrijskih snimanja* (1), koji je direktno ovisio o ciljevima i svrsi istraživanja, odnosno provođenja intervalnih snimanja. S obzirom da je unutar ovog dijela mezo razine istraživanja osnovni cilj istraživanja detekcija prostorno-vremenskih promjena na širem prostoru jaruge Santiš, određeno je da će područje snimanja osim jaruge Santiš obuhvaćati i ostatak naslaga tla, koje se nalaze iznad glavnog dijela jaruge (Sl. 59). Time je u sklopu ove disertacije prostorni obuhvat intervalnih aerofotogrametrijskih snimanja znatno proširen u odnosu na ranija istraživanja provedena na prostoru jaruge Santiš (Domazetović, 2018; Šiljeg i dr., 2021.).

Sljedeća faza planiranja i pripreme intervalnih snimanja uključivala je *odabir broja i optimalnih lokacija za OT i KT* (2), odnosno izradu stalnog lokalnog koordinatnog sustava unutar prostora budućih aerofotogrametrijskih snimanja. Dok OT služe za relativno[20] i

[20] Relativno georeferenciranje - georeferenciranje u odnosu na druge izrađene intervalne modele

apsolutno[21] georeferenciranje izrađenih modela, KT služe za neovisnu provjeru točnosti modela. Pogreške u georeferenciranju modela rastu s proporcionalno udaljavanju od lokacije OT, zbog čega generalno veći broj OT utječe na bolju točnost modela (Clapuyt i dr., 2016). Proučavanjem dostupne literature, a posebice iskustava iz sličnih istraživanja (James i dr., 2017a), unutar područja istraživanja je odabrano 7 lokacija za OT i 6 za KT. S obzirom da je gotovo cijeli prostor naslaga tla zahvaćen nekim oblikom erozije tla, OT i KT su morale biti postavljene izvan prostora na kojemu može doći do pojave prostorno-vremenskih promjena unutar promatranog razdoblja. Zbog toga su sve OT i KT postavljene na čvrstu karbonatnu podlogu, izvan nekonsolidiranih naslaga tla (Sl. 59.).

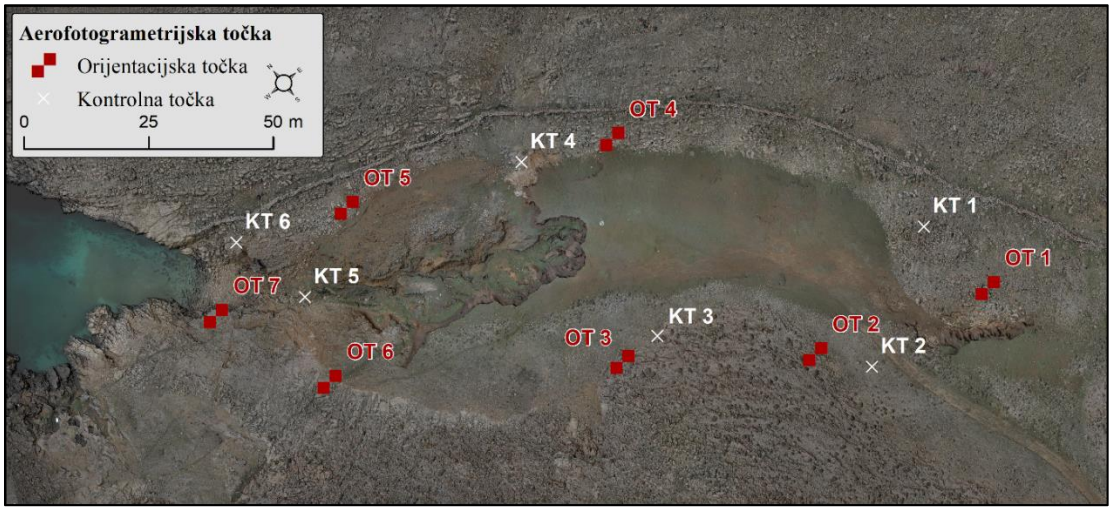

Slika 59. Prostorni raspored orijentacijskih i kontrolnih točaka unutar užeg dijela mezo razine područja istraživanja

Sve odabrane lokacije za OT i KT označene su na ranije poravnatoj karbonatnoj podlozi izradom trajnih oznaka (šahovnica), koje se sastoje od dva kvadrata površine 25 cm² (Sl. 60.). Oznake za OT i KT obilježene su crvenom i bijelom bojom, otpornom na vremenske uvjete, koja se jasno ističe od okolne svijetle karbonatne podloge. U samom sjecištu dva kvadrata izbušena je Bosch udarnom bušilicom mala rupa, čiji promjer (Ø = 5 mm) odgovara širini igle na nosaču antene RTK-GNSS-a (Sl. 60.B). Gdje je bilo moguće OT i KT su postavljene na istoj lokacije (OT3; OT4; OT5; OT6; OT7; KT4; KT6) kao i stalna fiksirana postolja za mete (sfere) potrebne za terestričko lasersko skeniranje, unutar mikro razine istraživanja (*podpoglavlje 3.3.1.*).

Koordinate svake lokacije OT i KT određene su sa Stonex S10 RTK-GNSS-om, pri čemu je svaka pozicija određena iz opažanja koja su trajala 5 minuta (300 epoha). Identične

[21] Apsolutno georeferenciranje - georeferenciranje u odnosu na zadani geografski koordinatni sustav

koordinate istih 7 OT i 6 KT korišteno je za oba intervalna aerofotogrametrijska snimanja. Prikupljene koordinate prikazane su u tablici 23.

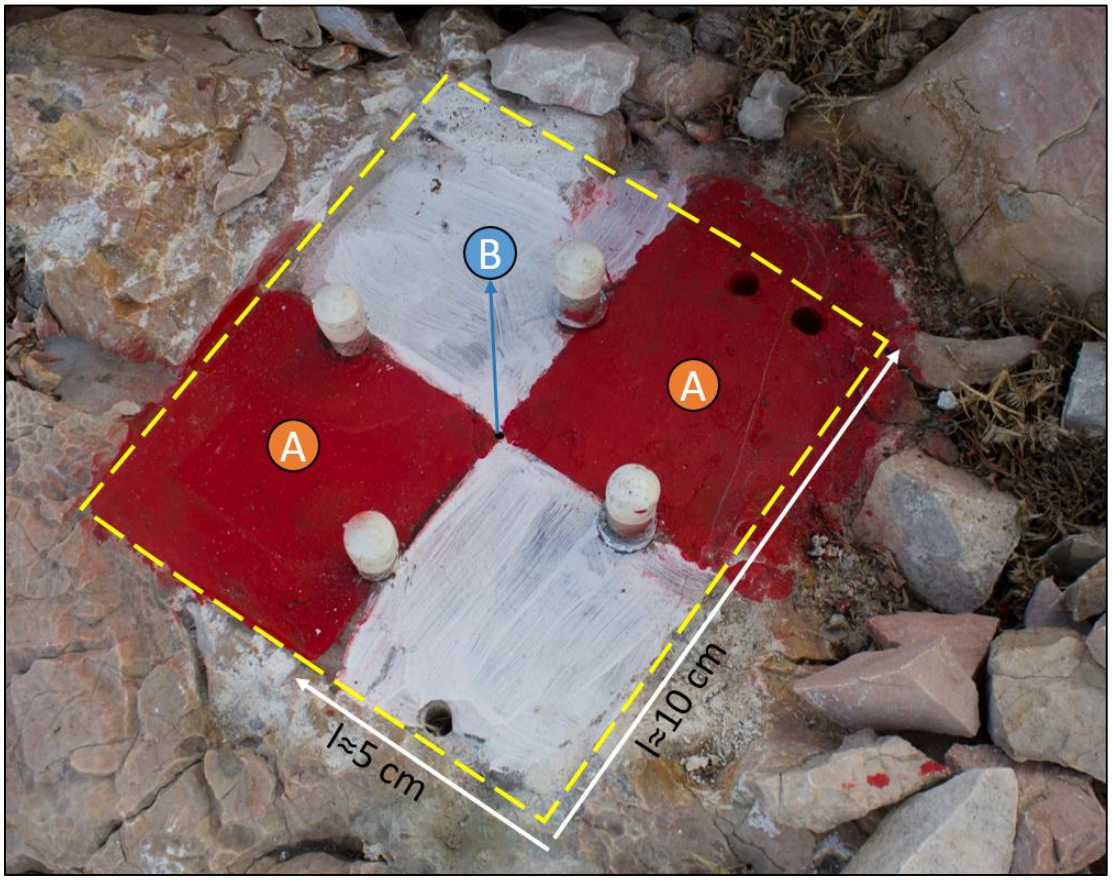

Slika 60. Signal aerofotogrametrijske orijentacijske točke (B) označen u sjecištu dva kvadrata površine 25 cm² (A) na izrađenom stalnom stajalištu

Tablica 23. Koordinate prikupljenih OT i KT intervalnih aerofotogrametrijskih snimanja

ID	Naziv	X (E)	Y (N)	Z (H)
1	OT1	395894.60	4915737.53	35.44
2	OT2	395857.91	4915755.21	31.14
3	OT3	395827.31	4915778.60	24.66
4	OT4	395854.37	4915814.36	22.61
5	OT5	395804.71	4915838.27	11.92
6	OT6	395779.42	4915812.93	13.52
7	OT7	395771.3	4915836.88	4.08
8	KT1	395897.51	4915747.57	34.97
9	KT2	395867.59	4915773.41	27.35
10	KT3	395843.05	4915776.43	24.64

11	KT4	395837.50	4915822.23	19.60
12	KT5	395781.46	4915847.58	5.29
13	KT6	395766.79	4915817.45	12.80

Zadnja faza planiranje i pripreme intervalnih aerofotogrametrijskih snimanja obuhvaća automatizaciju letačkih operacija. Aerofotogrametrijska snimanja isplanirana su i automatizirana (3) u komercijalnoj aplikaciji za planiranje letačkih operacija, *Universal Ground Control Software* (UgCS), koja omogućava korisničko definiranje različitih značajki letačkih operacije (npr. profili leta, visina leta, bočni i prednji preklop snimaka, itd.) (UGCS, 2020). Detaljan pregled parametara isplaniranih uz pomoć UgCS-a dan je u tablici 24.

Tablica 24. Parametri isplaniranih misija aerofotogrametrijskog snimanja jaruge Santiš

ID	Parametar	Planirana vrijednost (UgCS)
1	Brzina leta (m/s)	4.70
2	GSD[22] (cm)	0.44
3	Prednje preklapanje (%)	75
4	Bočno preklapanje (%)	75
5	Visina leta (m)	26.2
6	Određivanje visine leta	AGL[23]
7	Tip letačke misije	Double grid

Parametri aerofotogrametrijskih misija usklađeni su s tehničkim specifikacijama RAPS-a (Tabl. 23.) te s potrebnim prostornim obuhvatom snimanja i željenom prostornom rezolucijom izrađenih modela. S obzirom da se željela postići subcentimetarska prostorna rezolucija izrađenih modela jaruge Santiš, ali i da se istovremeno trebalo voditi računa o sigurnosti letačkih operacija, vrijednost parametra GSD je podešena na 0.44 cm, što je rezultiralo visinom leta RAPS sustava od 26.2 m iznad površine jaruge. Pri tome treba napomenuti da je zbog odabranog AGL (engl. *above ground level*) parametra visina leta RAPS sustava konstantna, jer je unutar UgCS aplikacije zadano da RAPS prati površinu ranije generiranog 2D rasterskog modela jaruge (Model UAV-TEST) prostorne rezolucije 10 cm. Na taj način RAPS tijekom izvođenja aerofotogrametrijskog snimanja prati morfologiju jaruge, osiguravajući pritom stalnu visinu leta od 26.2 m i posljedično stalnu subcentimetarsku prostornu rezoluciju svih dijelova

[22] Ground sampling distance – udaljenost između centroida dva susjedna piksela
[23] Above ground level – visina leta bespilotne letjelice određena je u odnosu na površinu Zemlje

izrađenih modela. Prednje i bočno preklapanje između susjednih aerofotogrametrijskih snimaka podešeno je na 75%.

Zbog nedostatnog trajanja jednog seta baterija, bilo je potrebno podijeliti snimanje odabranog područja s RAPS-om na dvije identične aerofotogrametrijske misije (Sl. 61.). Identične misije leta generirane uz pomoć UgCS aplikacije korištene su za oba intervalna aerofotogrametrijska snimanja s RAPS-om (Tabl. 23; Sl. 61.).

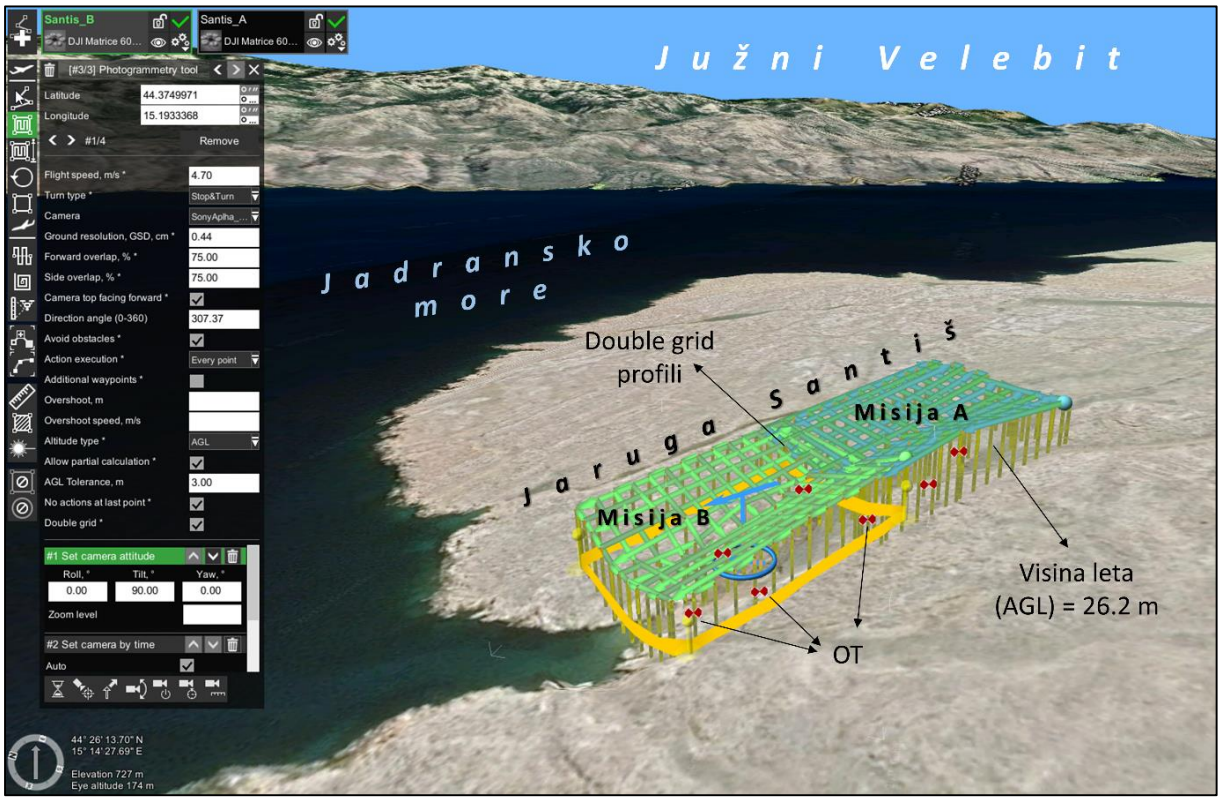

Slika 61. Prostorni obuhvat aerofotogrametrijskog snimanja isplaniranog uz pomoć UgCS aplikacije

III. Terensko prikupljanje aerofotogrametrijskih podataka

Preliminarno snimanje prostora jaruge Santiš obavljeno je 11. ožujka, 2019. godine, pri čemu su uz pomoć RAPS-a prikupljene ukupno 233 fotografije, iz kojih je kasnije izveden preliminarni model jaruge Santiš (Model UAV-TEST).

Inicijalno aerofotogrametrijsko snimanje šireg prostora jaruge Santiš (Model UAV-A) izvršeno je prema dvije ranije isplanirane misije (Sl. 61.) dana 17. prosinca 2019. godine, u razdoblju od 11 h do 13 h. Za vrijeme aerofotogrametrijskog snimanja (ukupno trajanje 36 minute) vremenski uvjeti su bili vrlo povoljni (Tabl. 24.). Ukupno su kroz inicijalno

aerofotogrametrijsko snimanje prikupljena 1534 zračna snimka prostora jaruge Santiš. Pregled značajki provedenog inicijalnog snimanja dan je u tablici 24.

Završno aerofotogrametrijsko snimanje šireg prostora jaruge Santiš (Model UAV-B) izvršeno je prema iste dvije isplanirane misije (Sl. 62.) dana 17. prosinca 2020. godine, između 11 i 13 h. S obzirom da su korištene identične misije ukupno su u sklopu završnog aerofotogrametrijskog snimanja prikupljena 1534 zračna snimka prostora jaruge Santiš. Pregled značajki provedenog završnog snimanja dan je u tablici 25.

Tablica 25. Uvjeti provedenih intervalnih aerofotogrametrijskih snimanja

ID	ID modela	Trajanje snimanja (min)	Vremenski uvjeti	Brzina vjetra (m/s)	Oborine (mm/h)	Temperatura zraka (ºC)	Prisustvo sjena (DA/NE)
1	UAV-A	23:34	Oblačno	1.2	0	5	NE
2	UAV-B	23:39	Oblačno	2	0	9	NE

Slika 62. Inicijalno aerofotogrametrijsko snimanje jaruge Santiš s razvijenim RAPS sustavom

IV. Izrada VHR modela iz prikupljenih aerofotogrametrijskih podataka

Zračni snimci prikupljeni RAPS sustavom na prostoru jaruge Santiš u dva intervalna aerofotogrametrijska snimanja obrađeni su koristeći istovjetnu metodologiju i korisničko-definirane parametre u Agisoft Metashape 1.5.1. softveru (Sl. 63.). Prvi korak obrade uključivao je procjenu inicijalne kvalitete snimaka i uklanjanje svih snimaka s kvalitetom manjom ili jednakom utvrđenom pragu (0.7)[24]. Također, postavljeni su inicijalni kalibracijski parametri sukladno značajkama kamere s kojom su prikupljeni snimci (*Sony Alpha A7RII – pixel size = 0.00452646 mm; focal lenght = 28 mm*). Uslijedio je korak relativne orijentacije (*Align photos*) svih snimaka te izrada rijetkog oblaka točaka, koji je da bi se generirala maksimalna gustoća oblaka točaka napravljen s maksimalnim vrijednostima korisničko-definiranih parametara (*Accuracy = Highest; Key point limit = 0; Tie point limit = 0*). Uz pomoć alata postupne selekcije napravljena je filtracija rijetkog oblaka točaka, na način da je uklonjeno 15 % svih točaka s najvećim vrijednostima reprodukcijske pogreške i 15 % svih točaka s najvećim vrijednostima nesigurnosti rekonstrukcije (engl. *reconstruction uncertainty*), kao i 15 % svih točaka s najmanjim vrijednostima točnosti pozicioniranja. Poslije uklanjanja navedenih točaka, filtrirani rijetki oblak točaka je optimiziran, nakon čega je uslijedila izrada gustog oblaka točaka i mreže poligona. S obzirom da se radi o izradi inicijalnog gustog oblaka i mreže poligona, za procesiranje su korišteni manje zahtjevni parametri obrade (Sl. 63. – 3. korak), čime je skraćeno ukupno trajanje obrade ova dva potkoraka.

U sklopu četvrtog koraka (Sl. 63. – 4. korak) uslijedila je apsolutna orijentacija modela, zasnovana na ručnom dodavanju orijentacijskih i kontrolnih točaka, prema ranije na terenu označenim i prikupljenim (XYZ) lokacijama (Sl. 63.). Ukupno je dodano 7 OT i 6 KT, čija lokacija je bila identična kod izrade oba intervalna modela (UAV-A; UAV-B) (Sl. 59; 64). Svim ručno dodanim OT i KT dodane su na terenu prikupljene koordinate (Tabl. 22), nakon čega su izrađeni modeli ažurirani (engl. *Update*). Prije daljnje obrade napravljena je dodatna filtracija i optimizacija oblaka točaka, prema ranije navedena tri kriterija, pri čemu je za svaki kriterij uklonjeno 10 % točaka s najlošijim vrijednostima (Sl. 63. – 5. korak).

[24] Prag inicijalne kvalitete zračnih snimaka procjenjen je na temelju izračunatih vrijednosti kvalitete za sve prikupljene snimke.

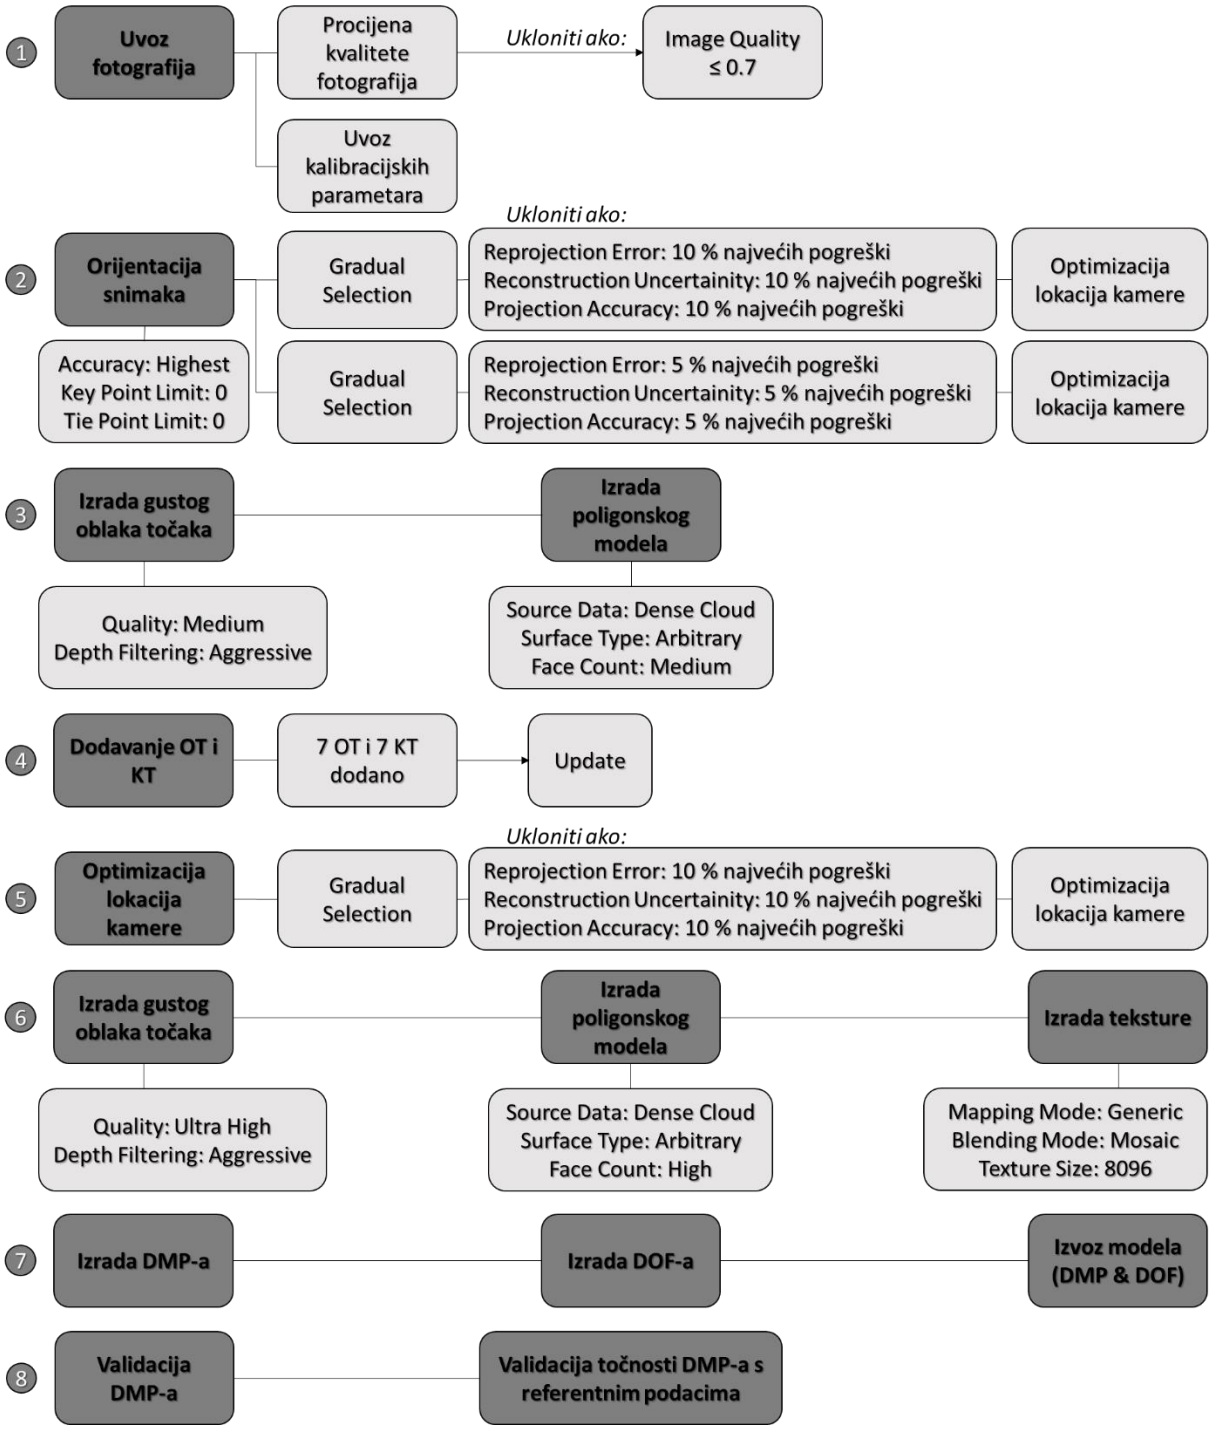

Slika 63. Koraci i parametri obrade aerofotogrametrijskih podataka u Agisoft Metashapeu (prema Marić i dr., 2020., modificirano)

Nakon apsolutne orijentacije te dodatne filtracije i optimizacije modela uslijedili su potkoraci izrade konačnog gustog oblaka točaka i mreže poligona. Da bi se postigla maksimalna moguća gustoća izraženog oblaka točaka te posljedično maksimalna prostorna rezolucija modela, ovaj put su pri obradi korištene maksimalne vrijednosti korisničko-definiranih parametara (Sl. 63. – 6. korak). Time je znatno produženo vrijeme obrade, ali je postignuta

maksimalna gustoća oblaka točaka i prostorna rezolucija konačnih modela (DMP i DOF). U sklopu ovog koraka napravljena je i tekstura modela, koja izravno poboljšava detaljnost izrađenog DOF-a (Agisoft, 2020).

Na temelju izrađenog gustog oblaka točaka generirani su digitalni model površina (engl. *Build DEM*) i digitalni ortofotosnimak (engl. *Build Orthomosaic*), koji su zatim eksportirani za daljnju obradu u HTRS96 projekciji.

Validacija izrađenih intervalnih modela

Validacija izrađenih intervalnih modela (UAV-A i UAV-B) napravljena je na temelju usporedbe generiranih oblaka točaka s oblakom točaka prikupljenim TLS-om. Detaljnije pojašnjenje cijelog postupka validacije dano je u poglavlju 3.3.3.

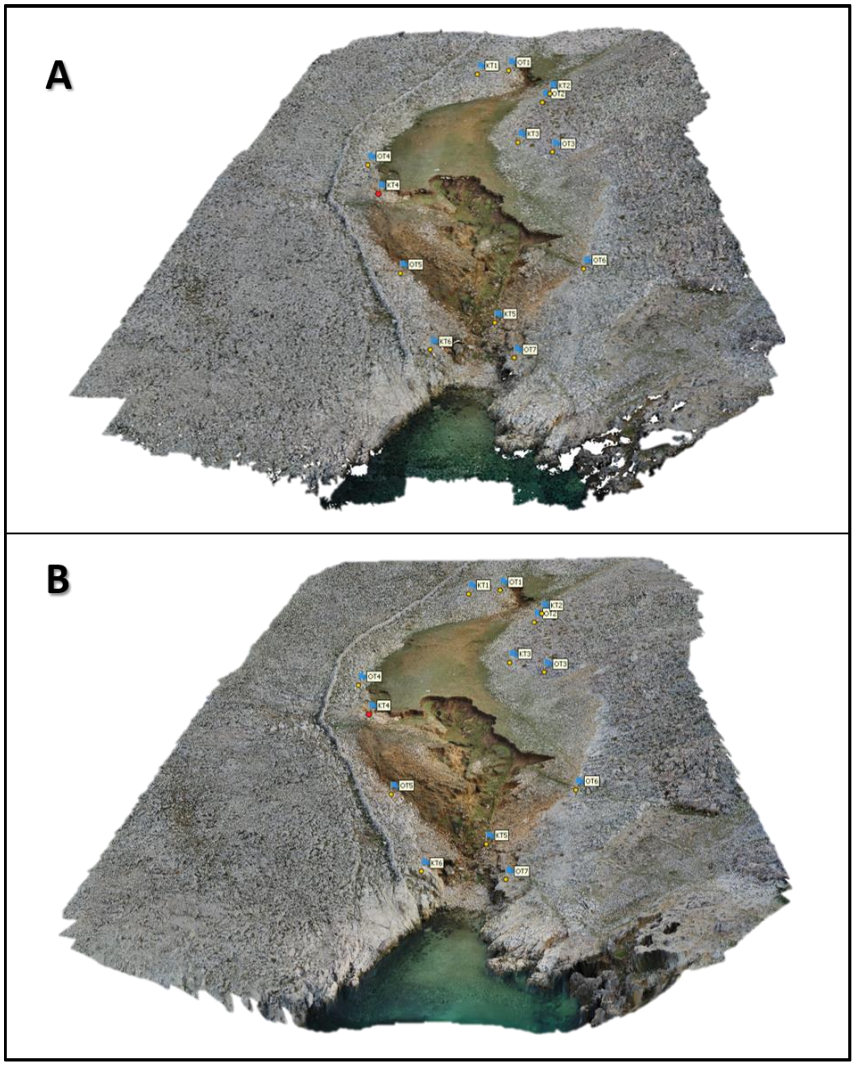

Slika 64. Gusti oblak točaka (A) i mesh (B) te ručno dodane OT i KT tijekom obrade snimaka inicijalnog aerofotogrametrijskog snimanja u Agisoft Metashape 1.5.1. softveru

3.2.3. Detekcija i kvantifikacija prostorno-vremenskih promjena (PVP) uzrokovanih erozijom tla na temelju izrađenih intervalnih digitalnih modela površina

Detekcija prostorno-vremenskih promjena uzrokovanih erozijom tla unutar mezo razine istraživanja napravljena je na temelju **digitalnih modela diferencije** (DMD). Izrada DMD uz pomoć GCD7 softvera temeljila se na intervalnim digitalnim modelima površina mezo razine istraživanja, izrađenim na temelju aerofotogrametrijskih snimaka[25].

Proces izrade diferencijalnih modela te kvantifikacije i interpretacije nastalih PVP uvelike ovisi o kvaliteti intervalnih modela (Brasington i dr., 2000; 2012; Neverman i dr., 2016; Fernández i dr., 2017). Zbog toga je za izradu DMD mezo razine korištena *Geomorphic Change Detection 7* (GCD7) nadogradnja za ArcGIS 10.1. softver (Riverscapes Consortium, 2020), koja omogućava detekciju prostorno-vremenskih promjena uzimajući pritom u obzir nepouzdanost intervalnih modela koji se koriste za detekciju promjena (Wheaton i dr., 2010; Williams, 2012). **Nepouzdanost** (engl. *uncertainty*) modela odraz je prvenstveno različitih artefakata i pogreški prisutnih u intervalnim modelima, koje su najčešće odraz tehničkih ograničenja korištene geoprostorne tehnologije i/ili korisničko-definiranih parametara i procesa izrade modela (Brasington i dr., 2000;). Ukoliko se nepouzdanost intervalnih modela ne uzme u obzir, onemogućava se diferencijacija stvarnih prostorno-vremenskih promjena, uzrokovanih djelovanjem erozije tla, od promjena koje su rezultat pogreški u intervalnim modelima (Wheaton i dr., 2010; Williams, 2012; James i dr., 2012). Mogućnost diferencijacije stvarnih prostorno-vremenskih promjena od promjena uzrokovanih pogreškama intervalnih modela može se iskazati kao omjer varijabilnosti stvarnih promjena (V_c) i varijabilnosti pogreške modela (V_e) (Williams, 2012):

$$\frac{V_c}{V_e} \tag{4}$$

Nepouzdanost intervalnih modela se najčešće pri izradi DMD-a uzima u obzir kroz određivanje **praga minimalne detekcije** promjena (engl. *minimal level of detection treshold* ($_{min}LoD$), koji predstavlja minimalnu promjenu visine koja se može pouzdano smatrati stvarnom prostono-vremenskom promjenom, a ne rezultatom nepouzdanosti modela (Neverman i dr., 2016.). Pri tome se nepouzdanost može iskazati kroz prag minimalne detekcije

[25] Ista metodologija za detekciju i kvantifikaciju prostorno-vremenskih promjena primijenjena je i za intervalne modele izrađene iz aerofotogrametrijskih snimaka Državne geodetske uprave (3.2.1.) i za intervalne modele izrađene iz aerofotogrametrijskih snimaka prikupljenih uz pomoć RAPS sustava (3.2.2.).

ili kao uniformna varijabla[26], koja ima jedinstvenu vrijednost unutar cijelog intervalnog modela, ili kao prostorno promjenljiva varijabla (npr. *Fuzzy Inference System* (FIS) (Wheaton i dr., 2010.), čija vrijednost varira unutar određenog intervalnog modela ovisno o nagibu i vertikalnoj raščlanjenosti reljefa, te gustoći prikupljenih točaka (Wheaton i dr., 2010; Neverman i dr., 2016.).

U sklopu ove doktorske disertacije prag minimalne detekcije primijenjen je kao uniformna varijabla, izračunata zasebno kao srednja kvadratna pogreška svakog izrađenog intervalnog modela, na temelju usporedbe visinskih vrijednosti referentnih podataka i vrijednosti u određenom intervalnom modelu.

$$LoD_{min} = \sqrt{\frac{\sum|Z_{REF}-Z_M|^2}{n}} \tag{5}$$

gdje je:

Z_{REF} – visina referentnog podatka Z_M – visina izrađenog modela

Izračunata vrijednost LoD_{min} primjenjena je kao apsoluti prag za detekciju PVP, gdje svaka promjena u izrađenom DMD-u koja je manja od izračunatog praga nije uzeta u obzir kao stvarna geomorfološka promjena.

Uz korištenje nepouzdanosti, odnosno praga minimalne detekcije, GCD 7 nadogradnja omogućava dodatnu provjeru rezultata izrade DMD-a kroz primjenu **praga vjerojatnosti** (engl. *probabilistic thresholding*) zasnovanog na izračunu **različitih stupnjeva razine pouzdanosti detektiranih promjena** (engl. *confidence level*) (Riverscapes Consortium, 2020). Pri tome razina pouzdanosti može varirati od 0 do 1, gdje 0 označava najmanju moguću pouzdanost rezultata, a 1 najveću (100%) razinu pouzdanosti rezultata, izračunatu na temelju zadanog minimalnog praga detekcije (LoD_{min}) pojedinih modela. Razlika u konačnim diferencijalnim modelima izrađenim prema različitim stupnjevima razine pouzdanosti vidljiva je na slici 65. S obzirom da DMD izrađen s nultom razinom pouzdanosti (0.0) sadrži sve detektirane prostorno-vremenske promjene, gotov je nemoguće razlikovati stvarne promjene od promjena uzrokovanih nesigurnosti modela (Sl. 65. A).

[26] Uniformna vrijednost *nepouzdanosti* modela određuje se prema nekoj od ustaljenih metrika za procjenu točnosti modela (npr. RMSE, SD, MAE, itd.), gdje se najčešće uzima vrijednost SD određena na temelju kontrolnih točaka (KT) prikupljenih s RTK-GNSS-om na terenu (Fernández i dr., 2017.).

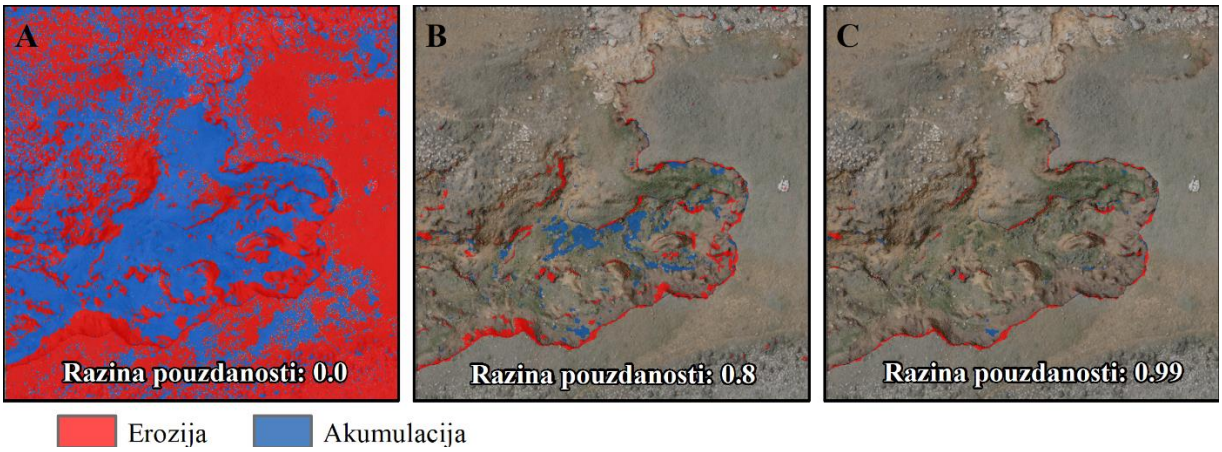

Slika 65. Prostorno-vremenske promjene određene prema različitom stupnju pouzdanosti

S druge strane, kod DMD-a s primijenjenom razinom pouzdanosti od 0.8 (80%), odnosno 0.99 (99 %), detekcija stvarne promjene je znatno olakšana, te se rezultati ovakvog DMD-a mogu smatrati znatno pouzdanijim.

Prilikom iterativnog testiranja različitih **stupnjeva razine pouzdanosti detektiranih promjena** uočeno je da optimalne rezultate daje vrijednost 0.95 (95% pouzdanosti). Naime, iako veće vrijednosti razine pouzdanosti poboljšavaju točnost rezultata detekcije PVP, prevelike vrijednosti mogu dovesti do uklanjanja dijela stvarnih geomorfoloških promjena (Wheaton i dr., 2010). Upravo to primijećeno je pri primjeni vrijednosti 0.99, gdje su znatni dijelovi stvarnih promjena s prostora glavnog čela jaruge uklonjeni iz analize, umanjujući pritom ukupne vrijednosti površine i volumena zahvaćenih s PVP.

Rezultati višegodišnje (2014.-2018.) detekcije i kvantifikacije PVP unutar šireg područja mezo razine istraživanja dovedeni su u odnos sa *značajkama drenažnih bazena pojedinih jaruga* (**1**) i *obrađenim višegodišnjim meteorološkim podacima* (**2**). Istovjetno tome, rezultati jednogodišnje (2019.-2020.) detaljnije detekcije i kvantifikacije PVP, unutar užeg područja mezo razine istraživanja dovedeni su u odnos s *in-situ prikupljenim i obrađenim meteorološkim podacima* (**1**) te s *izrađenom detaljnom geološkom kartom jaruge Santiš* (**2**) i s odabranim *morfometrijskim značajkama tereta* (**3**).

3.2.4. Prikupljanje i obrada meteoroloških podataka

3.2.4.1. Prikupljanje podataka Državnog hidrometeorološkog zavoda

S obzirom da je odlučeno da će se prostorno-vremenske promjene uzrokovane erozijom tla pratiti na mezo razini uz pomoć modela izrađenih iz aerofotogrametrijskih snimaka Državne geodetske uprave dostupnih za razdoblje od 2014. do 2018. godine, bilo je potrebno prikupiti odgovarajuće meteorološke podatke za isto, ili duže vremensko razdoblje. Zbog toga su od Državnog hidrometeorološkog zavoda naručeni dostupni meteorološki podaci za vremenski period od 1970. do 2020. godine te su korišteni sljedeći meteorološki podaci: *prosječna mjesečna temperatura zraka* (°C); *ukupna mjesečna količina oborina* (mm); *ukupna dnevna količina oborina* (mm).

Od Državnog hidrometeorološkog zavoda su dobiveni podaci za jedinu obližnju klimatološku postaju, koja se nalazi u gradu Pagu, oko 13.5 km zračne linije od jaruge Santiš. S obzirom da je ova klimatološka postaja započela s radom tek 1978., zatraženi su podaci i za glavnu meteorološku postaju u gradu Rabu (oko 55 km od jaruge Santiš) i glavnu meteorološku postaju u gradu Zadru (oko 25 km od jaruge Santiš).

3.2.4.2. In-situ prikupljanje meteoroloških podataka

Unutar užeg područja mezo razine (prostor jaruge Santiš) u sklopu ove doktorske disertacije provedeno je *in-situ* prikupljanje meteoroloških podataka, u prvom redu količine i intenziteta oborina te temperature zraka.

Prikupljanje podataka o količini i intenzitetu oborina

Prikupljanje podataka o količini i intenzitetu oborina izvršeno je uz pomoć Hobo Onset RG3-M uređaja za prikupljanje podataka (engl. *data logger*) (Sl. 66.), koji je postavljen prije inicijalnog aerofotogrametrijskog snimanja jaruge. Hobo Onset RG3-M omogućava kontinuirano prikupljanje podataka o intenzitetu i ukupnoj količini oborina, pri čemu je minimalna količina kiše koju uređaj može zabilježiti 0.2 mm (Onset, 2020). Uređaj se sastoji od metalnog poklopca u obliku lijevka (Sl. 66.A), koji na vrhu ima mrežu za zaštitu od upadanja nečistoća, a u dnu ljevak kroz koji kapljice kiše otječu prema unutrašnjosti uređajaa. Ispod metalnog lijevka se nalazi ljuljačka s dvije posude zapremnine 0.2 mm (Sl. 66.B), koja je spojena na senzor uređaja (Sl. 66.C). Kada se posuda na ljuljački postupno napuni kišnicom,

koja se procjeđuje s metalnog lijevka, dolazi do njihaja, uslijed čega se posuda prazni, a uređaj bilježi količinu od 0.2 mm oborina. Ispod ljuljačke i senzora, u dnu posude, nalazi se otvor kroz koji kišnica može nesmetano isteći iz uređaja, osiguravajući pritom da se uređaj ne prepuni kišnicom.

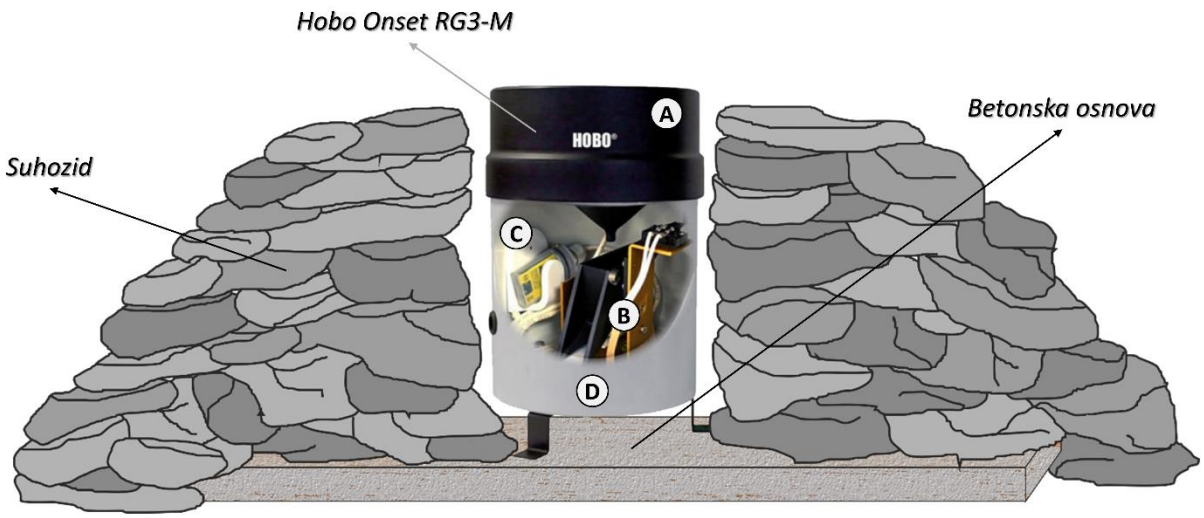

Slika 66. Princip postavljanja i zaštite Hobo Onset RG3-M uređaj

Da bi uređaj mogao neometano precizno vršiti bilježenje količine i intenziteta oborina, mora biti postavljen horizontalno na ravnoj podlozi, te mora biti zaštićen od bilo kakvih vibracija uzrokovanih vjetrom ili nekim drugim utjecajima (Onset, 2020). Prilikom ranijih istraživanja (Domazetović, 2018) uređaj je postavljen na ravnu drvenu dasku, što se nije pokazalo dobrim rješenjem, jer se drvena daska uslijed istjecanja vode iz uređaja s vremenom počela deformirati. Također, s obzirom da je ovaj dio otoka Paga pod izravnim utjecajem snažnog sjeveroistočnog vjetra bure, bilo je potrebno zaštititi uređaj od izravnih udara vjetra. Zbog toga je uređaj postavljen na ravnu betonsku ploču, oko koje je složen suhozidni obrambeni zid (Sl. 67.). In-situ praćenje količine i intenziteta oborina u sklopu ove doktorske disertacije započelo je 06. lipnja 2019. godine u 12:00 h, a završilo[27] 17. prosinca 2020. godine u 12:00 h. Za analizu unutar ove disertacije su uzeti samo podaci prikupljeni u razdoblju od 17. prosinca 2019. godine u 12:00 h do 17. prosinca 2020. godine u 12:00 h.

[27] In-situ prikupljanje meteoroloških podataka nastavljeno je za potrebe daljnih istraživanja na ovoj lokaciji, ali unutar doktorske disertacije u obzir su uzeti isključivo podaci prikupljeni do navedenog datuma.

Slika 67. Jedan od dva Hobo Onset RG3-M uređaja postavljena nedaleko od jaruge Santiš

Prikupljanje podataka o temperaturi zraka

Paralelno s uređajem za praćenje količine i intenziteta oborina na istoj lokaciji postavljen je i **Hobo U23 Pro V2** uređaj za praćenje temperature i vlažnosti zraka (Sl. 68.). Navedeni uređaj postavljen je u vodoravnom položaju u duboku, zasjenjenu pukotinu u donjoj strani većeg vapnenačke stijene. Postavljanjem u zasjenjenu pukotinu uređaj se osigurao od utjecaja izravnih udara bure te se omogućilo da uređaj uvijek bude u sjeni. Prije postavljanja uređaj je isprogramiran tako da prikuplja podatke o temperaturi zraka svakih sat vremena, čime je omogućeno kasnije izdvajanje prosječnih dnevnih, tjednih i mjesečnih vrijednosti temperature zraka. *In-situ* praćenje temperature zraka u sklopu ove doktorske disertacije započelo je 06. lipnja 2019. godine u 12:00 h, a završilo 17. prosinca 2020. godine u 12:00 h. Isto kao i kod prikupljenih podataka o količini i intenzitetu oborina, analizirani su isključivo podaci prikupljeni u razdoblju od 17. prosinca 2019. godine u 12:00 h do 17. prosinca 2020. godine u 12:00 h.

Slika 68. Lokacija postavljanja **Hobo U23 Pro V2** uređaj-a nedaleko od jaruge Santiš i proces očitavanja prikupljenih podataka uz pomoć **Hobo Waterproof Shuttle**-a

3.2.4.3. Obrada prikupljenih meteoroloških podataka

Meteorološki podaci prikupljeni postavljenim uređajima obrađeni su u **Hoboware 3.7.16** softveru, unutar kojega je izvršena osnovna obrada prikupljenih podataka, koja je uključivala izdvajanje ukupne dnevne, mjesečne i godišnje količine oborina te izdvajanje intenziteta oborina (mm/h). Također, u istom softveru izdvojen je i broj kišnih dana za svaki mjesec, te prosječna dnevna, mjesečna i godišnja količina oborina, ali i prosječna dnevna, mjesečna i godišnja temperatura zraka. Osim obrade prikupljenih podataka o količini i intenzitetu oborina isti softver korišten je za izdvajanje i obradu in-situ prikupljenih podataka o temperaturi zraka, gdje su prvenstveno izdvojene prosječne dnevne i mjesečne vrijednosti. Finalna obrada meteoroloških podataka prikupljenih napravljena je u **Microsoft Excel 2016** softveru, koji je poslužio za izradu meteoroloških grafikona te analizu ovisnosti utvrđenih meteoroloških uvjeta s detektiranim prostorno-vremenskim promjenama uzrokovanim erozijom tla.

Meteorološki podaci ustupljeni od strane DHMZ-a (vidi **3.2.4.1.)** su također obrađivani uz pomoć **Microsoft Excel 2016** softvera. Pri tome su na temelju ustupljenih podataka o dnevnoj količini oborina izračunati isti indikatori, kao i za in-situ prikupljene podatke.

U konačnici su na temelju prikupljenih podataka o količini oborina (DHMZ i Hobo Onset) izračunati sljedeći meteorološki indikatori: ukupna godišnja količina oborina (engl. *total annual percipitation* –TAP; mm/y^{-1}); broj kišnih dana (engl. *number of rainy days* - #RDs); maksimalna dnevna količina oborina (engl. *maximal daily rainfall* – MDR (mm/d^{-1})); normala kišnog dana[28] (engl. *rainy day normal* - RDN); broj kišnih dana s više od 13 mm oborina (engl. *number of rainy days* - #RD13) te broj kišnih dana s više od 20 mm oborina (engl. *number of rainy days* - #RD20).

Normala kišnog dana (RDN) izračunata je prema sljedećoj formuli (Vanmaercke i dr., 2016):

$$\mathrm{RDN} = \frac{TAP}{\#\mathrm{RDs}} \tag{6}$$

Vrijednosti izračunatih indikatora za pojedine godine iz višegodišnjeg razdoblja (2014. – 2018.) poslužile su za izračun prosječnih vrijednosti za to razdoblje. Izračunate prosječne vrijednosti indikatora uspoređene su s izračunatim jednogodišnjim vrijednostima (2019. – 2020.).

[28] RDN je izračunat kao kvocijent ukupne godišnje količine oborina (TAP) i broja kišnih dana (#RDs)

3.2.5. Izrada litološke karte užeg dijela mezo razine

Za potrebe utvrđivanja ovisnosti intenziteta erozije tla o litološkim značajkama podloge, provedeno je detaljno terensko kartiranje litoloških jedinica, koje je obuhvatilo cijeli prostor jaruge Santiš. Osnovni cilj provedenog terenskog kartiranja bio je utvrditi diverzitet i prostorni obuhvat različitih litoloških jedinica prisutnih unutar kartiranog prostora, na temelju kojega će zatim biti moguće utvrditi utjecaj litoloških značajki na varijabilnost erozije tla. Pri tome je osnovna pretpostavka bila da će intenzitet erozije tla biti najveći unutar naslaga smeđeg tla, uz vrlo visoku varijabilnost među pojedinim različitim litološkim jedinicama.

Terensko kartiranje provedeno je 16. rujna, 2020. godine na temelju pripremljenog predloška, odnosno karte krupnog mjerila (1:110) u analognom formatu, pripremljene na temelju DOF-a i DMP-a izrađenog iz aerofotogrametrijskih podataka inicijalnog aerofotogrametrijskog snimanja (Model UAV-A). Pripremljena karta je za potrebe terenskog kartiranja isprintana uz pomoć plotera u formatu A1. Tijekom terenskog istraživanja na kartu su ucrtani prostorni obuhvati svih detektiranih litoloških jedinica, dok su u zaseban dnevnik istraživanja zapisane bilješke o primijećenim značajkama kartiranih jedinica (Sl. 69). Također, tijekom terenskog istraživanja prikupljeni su različiti nalazi značajni za interpretaciju litoloških značajki prostora i rekonstrukciju postanka današnje jaruge Santiš (Sl. 125.A.). Nakon provedenog terenskog kartiranja na temelju analogne karte izvršena je ručna vektorizacija litoloških jedinica, koja je napravljena u mjerilu 1:50, gdje je svaka pojedina litološka jedinica kartirana kao zasebna poligonska klasa.

Slika 69. Karta korištena za terensko kartiranje litološke podloge krupnog mjerila (1:110)

Osim kartiranja litoloških jedinica tijekom provedenog terenskog istraživanja prikupljeni su uzorci tla, potrebni za analizu granulometrijskih značajki naslaga tla. Ukupno su uzorci tla prikupljeni na 20 različitih lokacija, distribuiranih unutar cijele mezo razine istraživanja (Sl. 126.). Prilikom odabira lokacija uzorkovanja primijenjena metoda promjenjive gustoće točaka (engl. *progressive sampling*) (Šiljeg, 2013). Najveći dio uzoraka (njih 13) prikupljen je unutar naslaga *smeđeg tla*, kao najzastupljenijeg tipa tla, dok su tri uzorka prikupljena unutar klase *karbonatnih pješčenjaka i pijesaka*, tri uzorka unutar prostora *žala*, te jedan uzorak unutar *prijelaznog prostora između pješčenjaka i smeđeg tla*.

Plan prikupljanja uzoraka tla pripremljen je ranije prema napravljenoj karti u ArcGIS 10.1 softveru (Sl. 69.), da bi kasnije tijekom terenskih istraživanja sve lokacije bile iskolčene na terenu uz pomoć Stonex S10 RTK GNSS-a. Na svakoj odabranoj lokaciji prikupljeno je ukupno oko 1 kg sedimenta, pri čemu je radi dodatne provjere homogenosti sediment unutar svake odabrane lokacije prikupljen iz pet različitih pozicija (Sl. 70.A). Prikupljeni sediment pospremljen je u plastične vrećice označene identifikacijskim nazivom svake lokacije (Sl. 70.B). U konačnici je prikupljeno oko 20 kg sedimenta (Sl. 70.C).

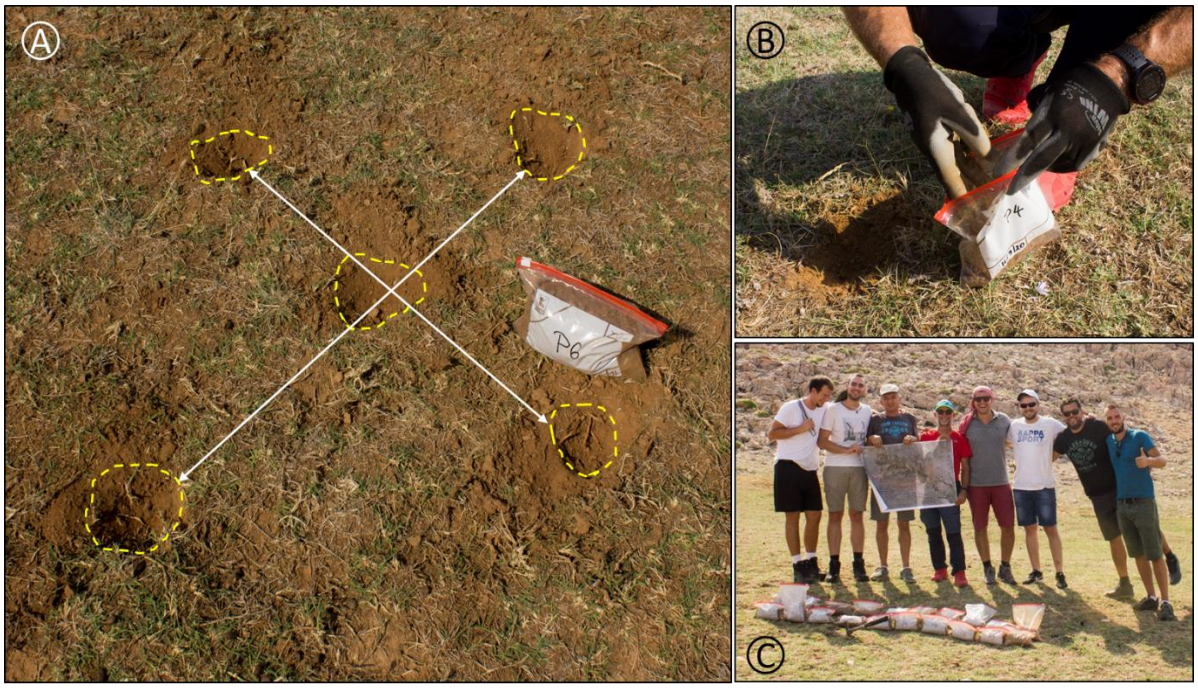

Slika 70. Princip uzorkovanja tla (A); pohranjivanje prikupljenih uzoraka (B); prikupljeni uzorci sedimenta (C)

Prikupljeni uzorci prvo su osušeni uz pomoć **Labconco FreeZone 8L** zamrzavajuće sušilice (Sl. 71.A), koja na temelju procesa liofilizacije hladi materijal na određenu temperaturu

(–40 °C), da bi zatim u visokom vakuumu sublimacijom uklonila vodu (Labconco, 2020). Zatim je granulometrijski sastav prikupljenih uzoraka tla analiziran uz pomoć **Retsch AS 200** automatskog vibracionog sita za prosijavanje (Retsch, 2020), koje je omogućilo raščlambu prikupljenog sedimenta prema granulometrijskom sastavu, odnosno različitim frakcijama (od 4 mm sve do <0.25 mm). Prosijavanje uzoraka napravljeno je primjenom 60% vibracije, unutar 15 minutnog intervala. Prikupljeni uzorci biti će klasificirani prema udjelu različitih frakcija na: *vrlo krupne (4 mm), krupne (2 mm), srednje (1 mm), sitne (0.25 mm)* te *vrlo sitne (<0.25 mm)* sedimente. Da bi se mogao izračunati udio pojedinih frakcija unutar svakog prikupljenog uzorka sve izdvojene frakcije su izvagane nakon razdvajanja u vibracionom situ.

Slika 71. Sušenje prikupljenih uzoraka (B) u **Labconco FreeZone 8L** zamrzavajućoj sušilici (A); Prosijavanje prikupljenog sedimenta uz pomoć **Retsch AS 200** sita

3.3. Pregled metodologije mikro razine istraživanja

Metodologija mikro razine istraživanja uključuje *primjenu terestričkog laserskog skenera za intervalno skeniranje prostora čela jaruge Santiš* (**A**) te *razvoj kvantitativnih alata za automatizirano praćenje prostorno-vremenskih promjena* (**B**).

3.3.1. LiDAR lasersko skeniranje prostora čela jaruge Santiš

Za prikupljanje podataka uz pomoć LiDAR tehnologije korišten je terestrički laserski skener (*u nastavku* TLS) Faro M70, kojim je intervalno skeniran prostor čela jaruge Santiš. Korišteni Faro M70 je jedan od trenutačno najmodernijih terestričkih laserskih skenera, koji omogućava prikupljanje i do 488 000 točaka/sekundi u dometu do 70 m od lokacije stajališta skenera (Faro, 2019a). Ostale tehničke specifikacije dane su u tablici 26.

Tablica 26. Tehničke specifikacije Faro Focus M70 TLS-a (Faro, 2020a)

ID	Parametar	Vrijednost parametra
1	Brzina prikupljanja podataka (točaka/s)	Do 488 000
2	Preciznost prikupljanja točaka	± 3 mm
3	Maksimalan domet (m)	70
4	Minimalan domet (m)	0.6
5	Vertikalni kut snimanja (º)	300
6	Horizontalni kut snimanja (º)	360
7	Integrirana RGB kamera (MP)	Do 165 MP[29]
8	Težina uređaja (kg)	4.2
9	Trajanje baterije (h)	4.5 h

Izražena vertikalna raščlanjenost i kompleksnost površinskog reljefa jaruga mogu znatno otežati proces terestričkog laserskog skeniranja, ali i uzrokovati pojavu znatnih nedostataka i artefakata u izrađenim modelima (Domazetović i dr., 2020). Primjerice, kompleksni morfološki oblici, poput strmih dijelova čela jaruge, mogu zakloniti laserske zrake, uzrokujući pojavu "sjene", odnosno praznina u prikupljenom gustom oblaku točaka (Marzolff i Poesen, 2009; Stöcker i dr., 2015; Perroy i dr., 2010) (Sl. 72.B). Takvi zaklonjeni prostori mogu dovesti do devalvacije kvalitete izrađenih modela i smanjene točnosti detekcije i kvantifikacije PVP (npr. pojava preuveličavanja ili podcjenjivanja vrijednosti volumetrijskih promjena)

[29] 360º snimak nastao spajanjem velikog broja fotografija snimljenih s integriranom RGB kamerom

(Bremer i Sass, 2012). Većina navedenih problema povezana je s primjenom nesistematičnog terestričkog laserskog skeniranja, kojemu nije prethodilo temeljito planiranje provođenja laserske izmjere. Naime, zbog vremenskih i financijskih ograničenja, faza planiranja i pripreme zanemarena je u mnogim istraživanjima, gdje su broj i optimalne lokacije *stajališta terestričkog laserskog skenera* (STLS) određeni na licu mjesta, najčešće prema prosudbi i iskustvu istraživača (npr. Perroy i dr., 2010; Bremer i Sass, 2012; Rengers i Tucker, 2015; Goodwin i dr., 2016; 2017).

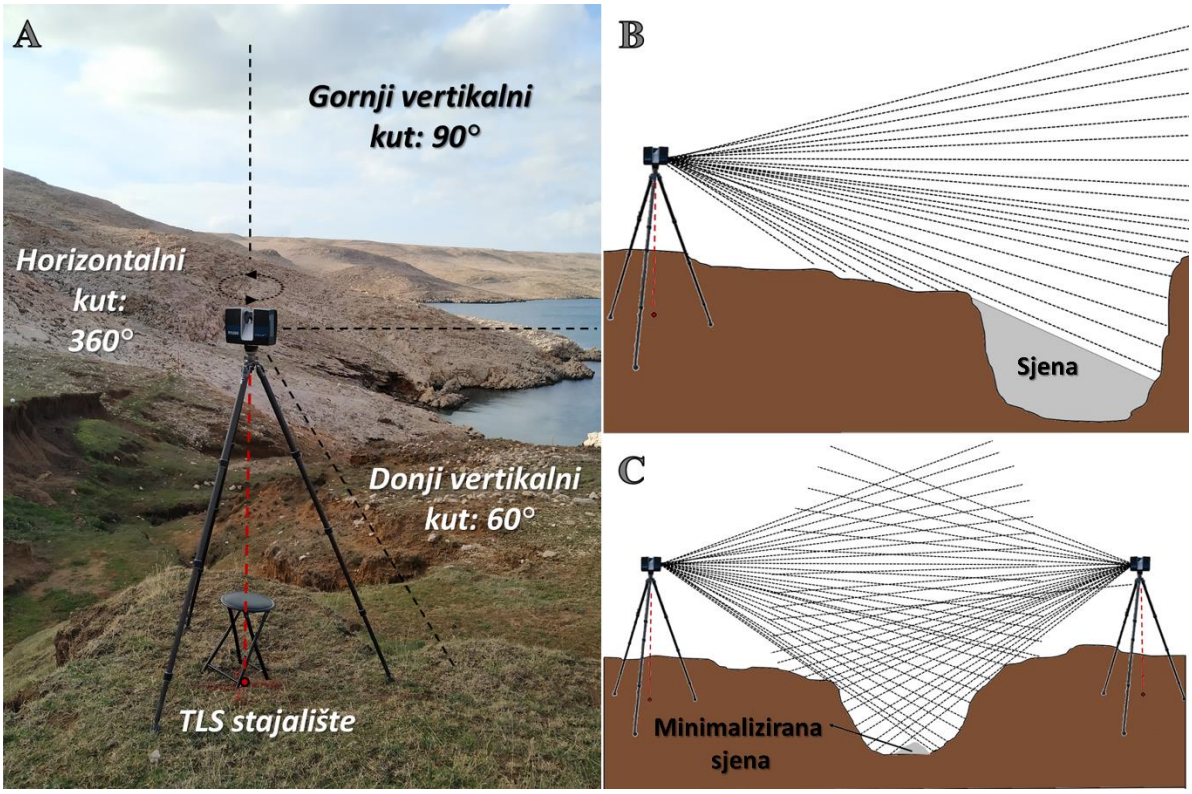

Slika 72. Snimanje prostora jaruge Santiš sa uređajem Faro M70 (A); pojava sjene uslijed snimanja vertikalno raščlanjenog terena sa TLS-om (B); princip snimanja istog prostora sa više STLS radi postizanja bolje pokrivenosti laserskim zrakama (C)

Kako bi se uklonile sve pogreške koje proizlaze iz takvog nesistematičnog pristupa, u sklopu ove doktorske disertacije osmišljen je, razvijen i primijenjen novi metodološki pristup za optimizaciju intervalnog praćenja erozije tla, koji može biti podijeljen u četiri osnovna koraka: *izrada plana intervalnih TLS izmjera* (A), *terenska izrada lokalnog koordinatnog sustava* (B), *intervalna terenska laserska izmjera* (C) te *izrada i validacija intervalnih modela* (D).

I. Izrada plana intervalnih TLS izmjera

Izrada plana intervalnih TLS izmjera predstavlja inicijalni i najvažniji korak razvijenog metodološkog pristupa, o kojemu izravno ovisi uspješnost svih kasnijih koraka. Unutar ovog koraka se na temelju ranije dostupnih podataka (npr. DMP i DOF) izrađuje preliminarni plan izvođenja terenskih intervalnih TLS izmjera. U slučaju ove doktorske disertacije izrada plana napravljena je unutar ArcGIS 10.1 softvera, na temelju dostupnog preliminarnog DMP-a i DOF-a užeg prostora jaruge Santiš, prostorne rezolucije 1.8 cm[30]. Izrada plana intervalnih TLS izmjera može se raščlaniti na sljedeća četiri potkoraka: *definiranje prostornog obuhvata izmjere* (A1), *određivanje ukupnog broja skenova* (A2), *determinacija optimalnih stajališta za TLS* (A3) te *određivanje optimalnih lokacija za referentne mete* (A4).

Prvi potkorak izrade plana intervalnih TLS izmjera uključuje određivanje prostornog obuhvata željene izmjere (A1), koji je u slučaju jaruge Santiš određen na temelju obuhvata jaruge u preliminarnom modelu. Ukupna površina prostornog obuhvata željene izmjere iznosi 1163 m².

Nakon definiranja prostornog obuhvata izmjere, slijedi potkorak određivanja ukupnog broja skenova izmjere (A2). Ukupan broj skenova TLS izmjere treba biti određen na temelju raspoloživog vremena za provođenje izmjere, te odabranih korisničko-definiranih parametara skeniranja. Dva ključna korisničko-definirana parametra pri skeniranju s terestričkim laserskim skenerom su rezolucija (engl. *resolution*) i kvaliteta (engl. *quality*) laserskog skeniranja (Faro, 2019b), koji ujedno uvjetuju i ukupno trajanje prikupljanja svakog skena. Dok rezolucija laserskog skeniranja određuje broj točaka koji se prikuplja pri svakom skenu (npr. $^1/_1$ – maksimalan broj točaka; $^1/_2$ – 50% maksimalnog broja točaka; $^1/_{32}$ – 3.12% maksimalnog broja točaka)), parametar kvalitete se odnosi na provjeru izmjerenih vrijednosti prikupljenog oblaka točaka (npr. 2x – svaka točka provjerava se dva puta; 8x – svaka točka provjerava se 8 puta) (Faro, 2019b). S obzirom da je planirano da TLS izmjera traje između 3 i 5 sati[31], određeno je da će intervalne izmjere imati optimalno osam skenova (oko 30 minuta po skenu). Da bi trajanje skeniranja ostalo unutar zadanog okvira od 30 minuta, korisničko-definirani

[30] Preliminarni DMP napravljen je iz aerofotogrametrijskih podataka prikupljenih prilikom inicijalnog snimanja testne plohe u ožujku 2019. godine (Model UAV-TEST).

[31] Trajanje TLS izmjere bilo je ograničeno kratkim trajanjem dana u 12. mjesecu, kada su izmjere izvršene.

parametri skeniranja morali su biti podešeni na $^1/_2$ za rezoluciju, te 3x za kvalitetu, što je rezultiralo ukupnim trajanjem pojedinog skeniranja od oko 20 minuta.

Nakon određivanja korisničko-definiranih parametara TLS izmjere i određivanja optimalnog broja skenova, uslijedio je potkorak definiranja optimalnih lokacija za postavljanje TLS-a (A3). Za određivanje optimalnih lokacija napravljena je analiza vidljivosti uz pomoć alata *Interactive viewshed*, pri čemu parametri provedene analize vidljivosti trebaju biti prilagođeni značajkama korištenog TLS-a, prvenstveno specifičnom kutu i dometu snimanja uređaja. U slučaju izmjera provedenih u sklopu ove disertacije parametri analize vidljivosti prilagođeni su specifikacijama Faro Focus M70 TLS-a (Sl. 72; Tabl. 27.). Raspon donjeg vertikalnog kuta snimanja korištenog TLS-a je 60º (Sl. 72.A), zbog čega skener ne može prikupljati uzorke koji se nalaze neposredno ispod stajališta. Nadalje, raspon skeniranja Faro M70 uređaja se kreće od 0,6 m pa do 70 m od stajališta uređaja, zbog čega je onemogućeno prikupljanje uzoraka unutar prvih 0,6 m od stajališta skenera. Dok ova činjenica nije bila problem kod stajališta koje se nalaze van definiranog područja izmjere, kod stajališta koje se nalaze unutar istraživanog područja bilo je potrebno pobrinuti se da taj prostor bude pokriven susjednim skenom. Iako je maksimalan domet korištenog TLS-a 70 m, s povećanjem udaljenosti od stajališta dolazi do postupnog povećanja razmaka među prikupljenim točkama (Faro, 2019a). Primjerice, pri odabranim parametrima rezolucije i kvalitete razmak između dvije prikupljene točke na 10 m udaljenosti od stajališta TLS-a iznosi 3.1 mm (FARO, 2019a). Zbog toga je pri odabiru optimalnih lokacija bilo potrebno voditi računa o međusobnom razmaku između susjednih stajališta, ali i stajališta i lokacija referentnih meta.

Tablica 27. Tehničke specifikacije Faro Focus M70 TLS-a (Faro, 2020a)

Minimalan domet	Maksimalan domet	Horizontalni kut skeniranja	Gornji vertikalni kut skeniranja	Doljnji vertikalni kut skeniranja	Visina TLS uređaja
0.60 m	70 m	360º	90º	60º	1.9 m

Uz pomoć *Interactive viewshed* alata analizirano je preko 100 različitih potencijalnih lokacija za postavljanje TLS-a (Sl. 73.), pri čemu su prostorni obuhvat i preklapanje između susjednih skenova izračunati za svaku testiranu lokaciju. U konačnici je na temelju provedene analize vidljivosti odabrano 8 lokacija s najvećim udjelom pokrivenosti željenog područja izmjere.

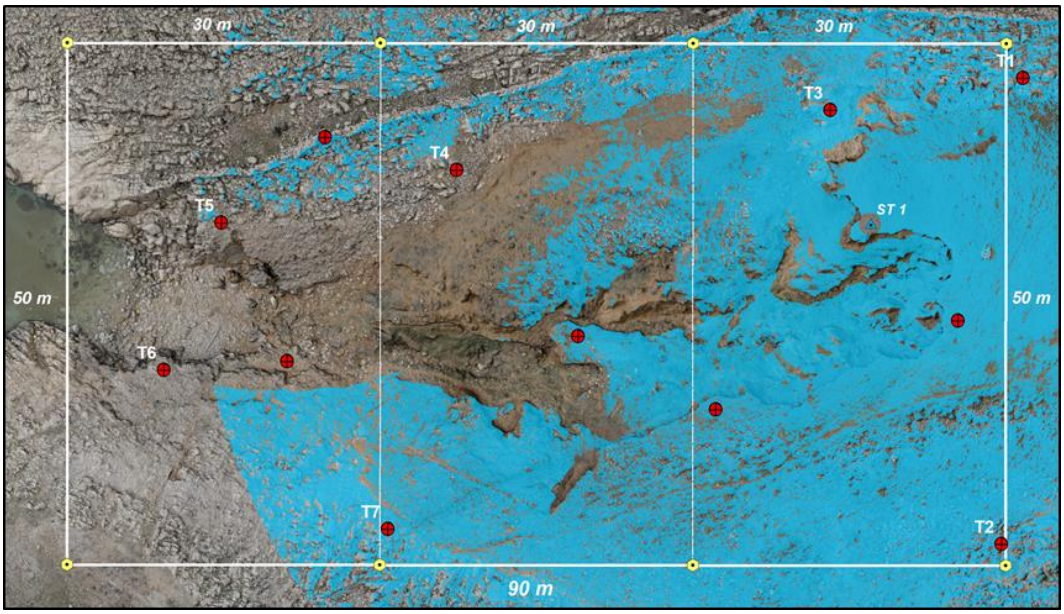

Slika 73. Primjer provedene analize vidljivosti za testirano stajalište TLS-a

Konačni potkorak unutar izrade plana intervalnih TLS izmjera obuhvaća određivanje optimalnih pozicija za referentne mete (A4). Referentne mete (npr. sfere, šahovsko polje, itd.) predstavljaju oznake koje se u TLS izmjeri koriste za registraciju više susjednih prikupljenih skenova ((Faro, 2019a). S obzirom na to, referentne mete moraju se postaviti na identičnu xyz lokaciju, prilikom svake ponovljene intervalne TLS izmjere. Pri tome odabrane lokacije ne smiju biti zahvaćene nastalim PVP, odnosno moraju biti izvan zone aktivnog djelovanja erozije tla. Zbog toga su optimalne lokacije referentnih meta postavljane na karbonatnim stijenama, van eroziji podložnijih naslaga tla. Vidljivost svake odabrane lokacije referentne mete sa susjednih stajališta TLS-a provjerena je uz pomoć *Line of sight* alata, pri čemu je visina svake mete postavljena na 2.1 m. Sa svakog stajališta morale su biti vidljive barem tri referentne mete, dok maksimalna udaljenost između stajališta i mete zbog raspršivanja laserskih zraka nije smjela prelaziti 35 m. U konačnici je odabrano sedam različitih optimalnih lokacija za referentne mete.

Izrađeni plan intervalnih TLS izmjera i udio pokrivene površine u ukupnoj površini definiranog područja izmjere dani su u rezultatima mikro razine istraživanja (4.3.).

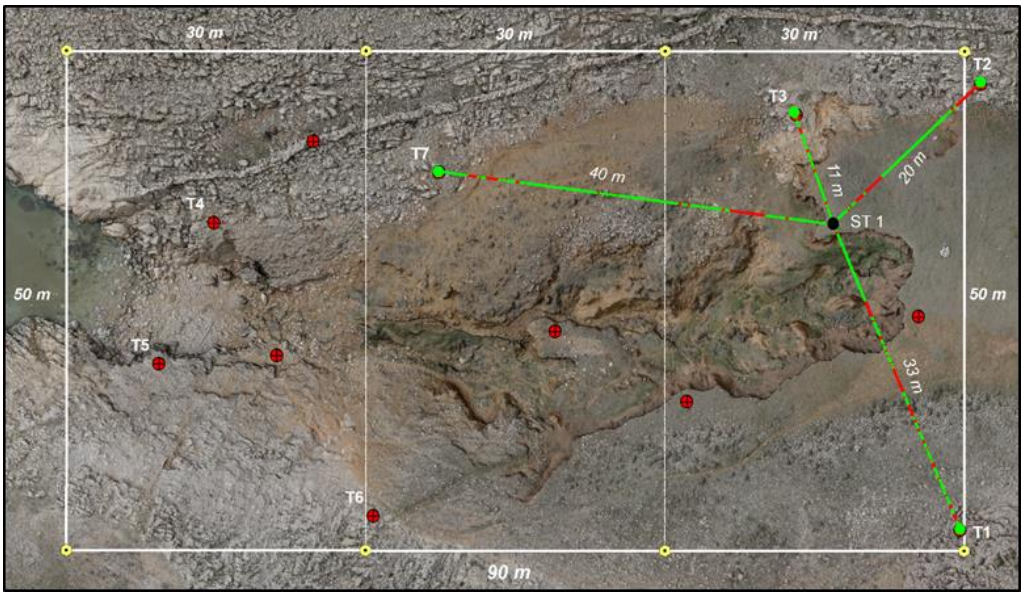

Slika 74. Primjer analize vidljivosti referentnih meta s određenog stajališta TLS-a

II. Izrada terenskog lokalnog koordinatnog sustava

Drugi korak novog metodološkog pristupa za optimizaciju intervalnog praćenja erozije tla obuhvaća izradu terenskog lokalnog koordinatnog sustava (B), prema ranije izrađenom planu intervalnih TLS izmjera. Ovaj korak moguće je raščlaniti na sljedeće potkorake: *iskolčenje određenih lokacija za postavljanje referentnih meta* (B1), *izradu stalnih fiksiranih postolja za referentne mete* (B2), *prikupljanje preciznih koordinata referentnih meta uz pomoć RTK-GNSS-a* (B3) te *iskolčenje stajališta TLS-a* (B4).

Unutar prvog potkoraka na terenu je uz pomoć Stonex S10 RTK-GNSS-a iskolčeno sedam optimalnih lokacija (B1) za postavljanje referentnih meta, definiranih ranije u izrađenom planu TLS izmjere. Nakon iskolčenja odabranih lokacija započela je izrada *stalnih geodetskih postolja* (SGP) (B2), na kojima će prije intervalnih izmjera biti postavljeni metalni nosači (trasirke) i referentne mete. Na svakoj označenoj lokaciji prvo je u karbonatnu podlogu uklesano postolje uz pomoć Bosch udarne bušilice (Sl. 75.A). Zatim su uklesana postolja izravnata uz pomoć samonivelirajućeg betona (Sl. 75.B), koji je nakon stvrdnjavanja poslužio kao poravnata osnova za postavljanje sidrišnih vijaka. Četiri sidrišna vijka ubušena u izrađeno stalno postolje (Sl. 75.C), poslužili su kao osnova za fiksiranje metalnih nosača, na koje se postavljaju referentne mete. U konačnici je izrađeno ukupno sedam identičnih SGP, dimenzija 10x10 cm (Sl. 76.). U središtu izrađenog postolja ubušena je rupica, koja označava središte nosača referentne mete.

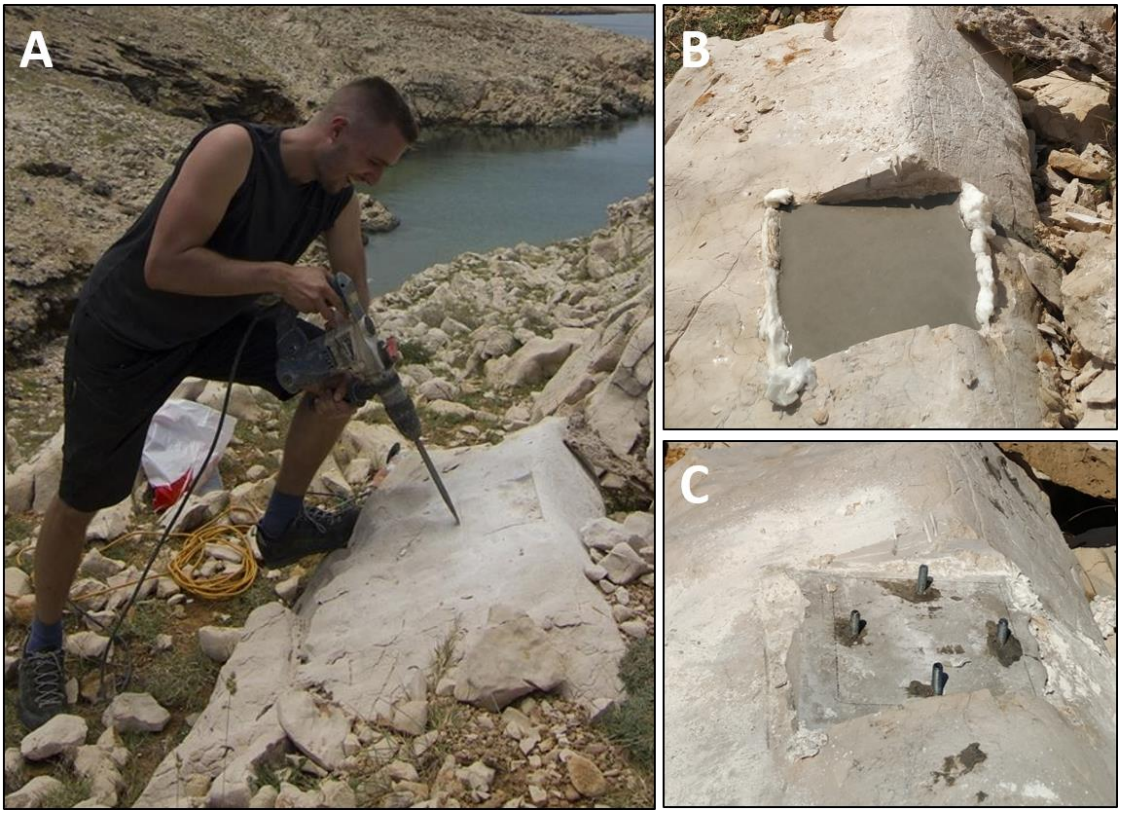

Slika 75. Izrada SGP za metu (sferu) sa udarnom bušilicom (A);
niveliranje izrađenog stajališta uz pomoć samonivelirajućeg betona (B);
sidrišni vijci za fiksiranje metalnih nosača (C)

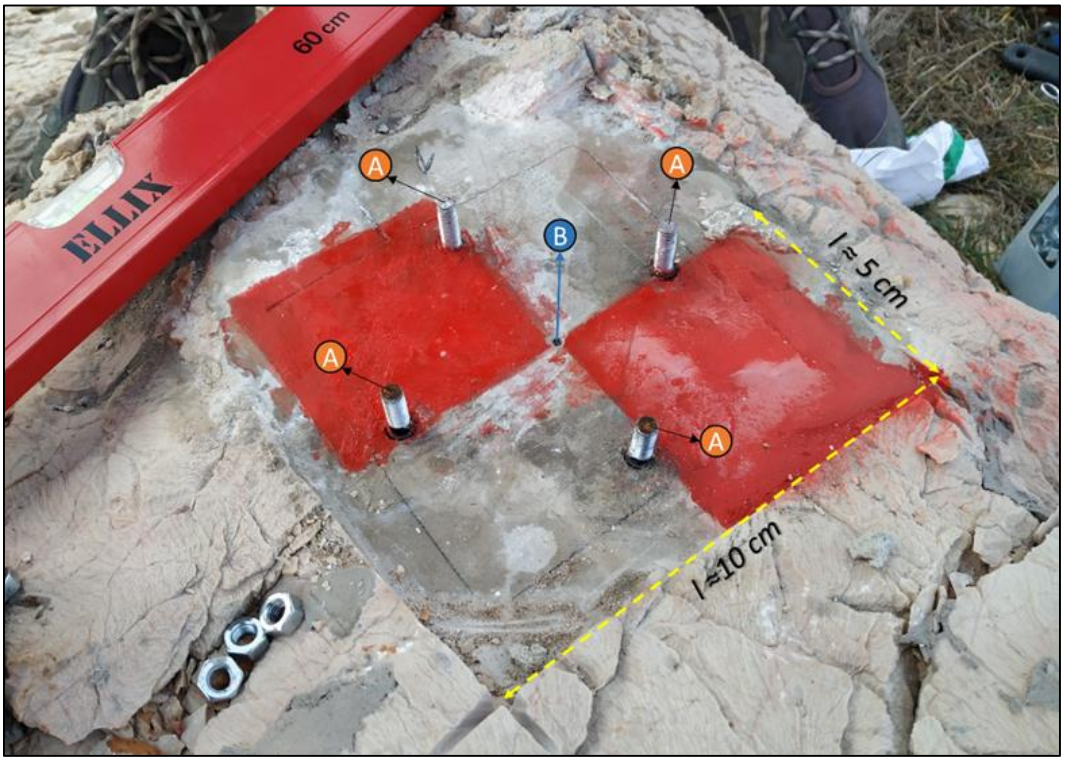

Slika 76. Izrađeno stajalište za metalni nosač referentne mete
(A – sidrišni vijak za fiksiranje nosača; B – središte nosača za metu (sferu))

Ista rupica je ujedno i orijentacijska točka za aerofotogrametrijsko snimanje.

Stalna geodetska postolja (SGP) moraju biti identična kod svih intervalnih TLS izmjera. Zbog toga je bilo potrebno zaštititi sidrišne vijke od propadanja i potencijalnih oštećenja, u prvom redu uzrokovanih korozijom povezanom s prodiranjem vode i učestalom posolicom. Svaki sidrišni vijak je prvo premazan tovatnom masti, nakon čega je presvučen plastičnim crijevom i zaštitnom kapicom (Sl. 77.). Time je onemogućeno prodiranje vode i posolice do sidrišnog vijka.

Slika 77. Zaštita sidrišnih vijaka od korozije
(A – nezaštićeni vijak; B – plastična zaštitna kapica;
C – plastično crijevo; D – samonivelirajući beton)

Svako izrađeno postolje dodatno je zaštićeno od izloženosti meteorološkim utjecajima i posolici zaštitnom kapom, izrađenom od najlona i gipsa (Sl. 78.C). Zahvaljujući kombinaciji najlona i gipsa zaštitne kape sprječavaju prodor vode i posolice do sidrišnih vijaka, ali i smanjuju uočljivost pripremljenih postolja. Da bi se zaštitne kape dodatno prikrile komadići razlomljenog stijenskog materijala pomiješani su s svježim gipsom (Sl. 78.C). Time je postignuta struktura zaštitne kape slična okolnom materijalu.

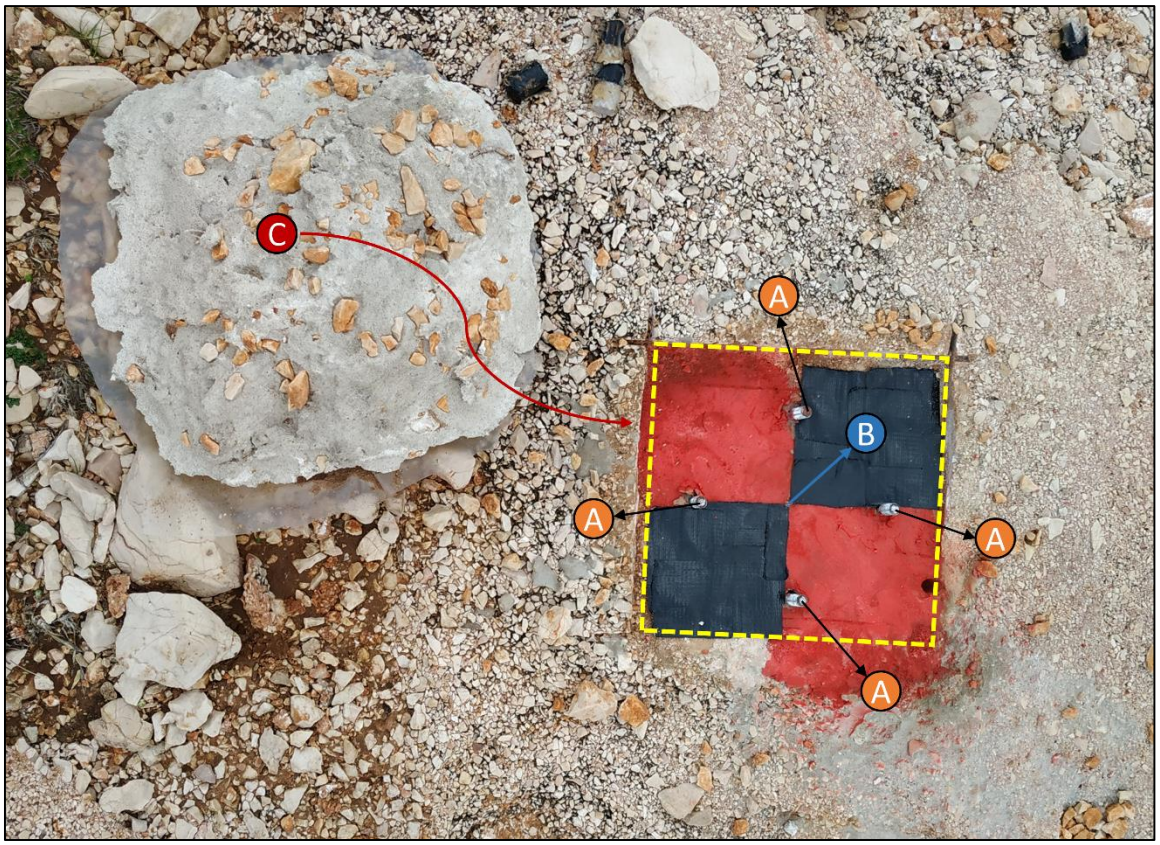

Slika 78. Gipsana kapa za prikrivanje i zaštitu izrađenog stalnog postolja
(A – sidrišni vijak; B – središte nosača za metu; C – gipsani zaštitni poklopac)

Za razmještanje meta na pripremljena postolja i željenu visinu izrađeno je ukupno sedam masivnih metalnih nosača (trasirki), ukupne duljine 210 cm, koji su omogućili identično pozicioniranje i fiksiranje sfera prilikom svih intervalnih TLS izmjera (Sl. 79.). Da bi ih bilo moguće lakše raspremiti i skladištiti između dvije TLS izmjere, svaki izrađeni nosač sastoji se od dva rasklopna dijela (Sl. 79.). Donji dio nosača sastoji se od postolja s izbušenim otvorima, koji odgovaraju zabušenim sidrišnim vijcima (Sl. 79.A). Gornji dio nosača (Sl. 79.B) montira se na završetak donjeg dijela nosača, pri čemu je moguće podesiti željenu ukupnu visinu cijelog nosača. Na drugom kraju gornji dio nosača završava otvorom na koji se može montirati nosač mete (sfera) (Sl. 79.C) ili nosač za antenu RTK-GNSS-a (Sl. 79.D). Širina nosača mete odgovara širini podnožja standardne geodetske sfere (Ø = 40 mm). U sklopu ove disertacije korištena je standardna geodetska sfera (Ø = 139 mm), čije središte se nalazi na 13.45 cm od postolja sfere (Sl. 9.E). Izrađeni nosač za antenu RTK-GNSS uređaja omogućava pozicioniranje antene RTK-GNSS-a na visini koja je identična visini središta sfere postavljene na metalnom nosaču (Sl. 79.F). Na taj način je postignuto da RTK-GNSS uspije prikupiti koordinatu središta svake postavljene mete (sfere) (Sl. 79.G). U konačnici su prije provođenja svake intervalne TLS izmjere mete postavljene na pripremljene metalne nosače fiksirane na SGP. Da bi se lakše

moglo TLS pozicionirati na planom određene lokacije sva stajališta TLS-a su prije izmjere iskolčena i označena crvenim sprejom.

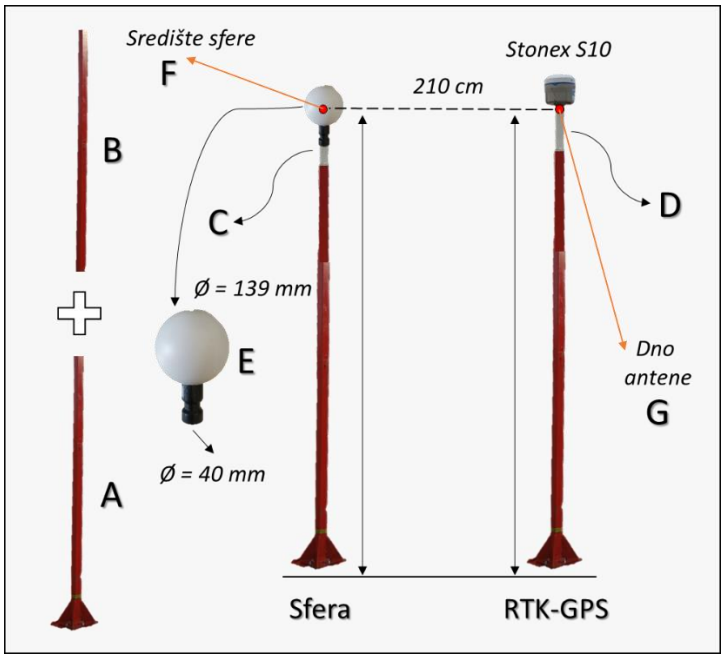

Slika 79. Izrađeni metalni nosači za mete: A – donji dio nosača; B – gornji dio nosača; C – adapter za metu; D – adapter za GNSS antenu; E – sfera; F – središte sfere; G – dno antene

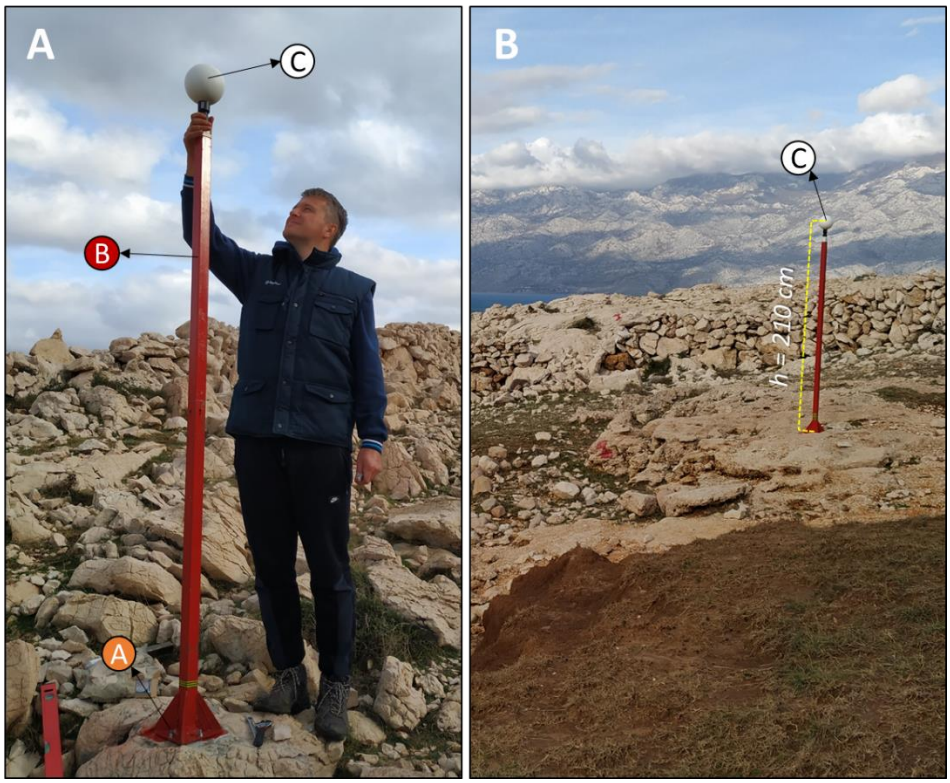

Slika 80. Referentne mete (C) postavljene na metalni nosač (B) fiksiran na izrađenom postolju (A) (*lijevo)*; meta (T3) fiksirana na karbonatnoj podlozi izvan aktivne erozije (*desno*)

III. Intervalna terenska laserska izmjera

Inicijalno terestričko lasersko skeniranje (TLS-A) unutar prostora jaruge Santiš izvršeno je 17. prosinca 2019. godine, u razdoblju od 14:23 h do 17:34 h. Prostor cijele jaruge Santiš snimljen je sa Faro Focus M70 terestričkim laserskim skenerom sa predviđenih sedam SGT, pri čemu je ukupno prikupljeno sedam pojedinih skenova.

Drugo, završno skeniranje sa TLS-om (TLS-B) izvršeno je 04. prosinca 2020. godine, prema ranije izrađenom planu intervalnih TLS izmjera. S obzirom da mikro razina istraživanja obuhvaća prostor glavnog čela jaruge Santiš (Sl. 81.), odlučeno je da će se u sklopu ove izmjere izvršiti skeniranje sa samo pet stajališta TLS-a vezanih direktno za prostor čela. Time je znatno skraćeno ukupno trajanje TLS izmjere, dok su istovremeno prikupljeni svi potrebni podaci za prostor čela jaruge. Druga izmjera započela je u 15:15 h, a trajala je do 18:11 h, pri čemu je ukupno prikupljeno pet skenova.

Slika 81. Skeniranje testne plohe s prvog stajališta (ST1) prilikom inicijalne TLS izmjere

IV. Izrada oblaka točaka iz podataka prikupljenih intervalnim TLS izmjerama

Podaci prikupljeni u sklopu dvije provedene intervalne TLS izmjere obrađeni su u Faro SCENE softveru, specijaliziranom za obradu laserskih skenova prikupljenih Faro terestričkim laserskim skenerima (Faro, 2019a). Radi usporedivosti modela izrađenih iz podataka prikupljenih u sklopu intervalnih TLS izmjera, primijenjena je identična metodologija za obradu prikupljenih intervalnih laserskih skenova. U konačnici proces obrade laserskih skenova može biti podijeljen na 6 osnovnih koraka, koji uključuju: *izradu projekta* (1), *obradu pojedinačnih laserskih skenova* (2), *registraciju laserskih skenova* (3), *dodavanje koordinata referentnim metama* (4), *izradu konačnog oblaka točaka* (5) te *eksportiranje oblaka točaka* (6). Pojedini koraci i korisničko definirani parametri metodologije primijenjene za obradu prikupljenih podataka dani su na slici 82.

U sklopu prvog koraka obrade izrađen je novi Faro SCENE projekt, u kojega su dodani svi prikupljeni laserski skenovi. U projekt vezan za prvu intervalnu TLS izmjeru dodano je 7 prikupljenih laserskih skenova, dok su u projekt vezan za drugu TLS izmjeru dodana 4 pripadajuća laserska skena. Sljedeći korak obuhvaća obradu pojedinačnih laserskih skenova (engl. *Process scans*), u sklopu koje se vrši osnovna obrada sirovih prikupljenih skenova, prema odabranim postavkama (engl. *Configure processing*). Prilikom obrade podešene su postavke obrade koje su uključivale izradu oblaka točaka i teksture iz svakog pojedinačnog skena, uz korištenje filtera za automatsko uklanjanje tamnih točaka (engl. *Dark Scan Point filter*) i točaka koje značajno odstupaju od okolnih točaka (engl. *Stray Point filter*) (Faro, 2019b). Također, korišten je i filter za automatsko prepoznavanje rubova i uklanjanje pogrešaka koje se nalaze uz njih (engl. *Edge Artifact Filter*) (Faro, 2019b). Jedini filter koji nije korišten je filter udaljenosti (engl. *Distance filter*), koji omogućava automatsko uklanjanje točaka prema njihovoj udaljenosti od stajališta TLS-a (npr. Distance filter = 50 uklanja sve točke koje su udaljene više od 50 m od stajališta) (Faro, 2019b). Ovaj filter nije primijenjen jer su nekada i udaljenija stajališta (npr. 60-70 m) prikupljala bitne točke vezane za primjerice prostor čela jaruge. Također, osim filtera u sklopu ovog koraka podešeno je automatsko prepoznavanje meta, pri čemu su za tip meta odabrane standardne sfere (engl. Find spheres), radijusa 0.0695 m.

Nakon obrade pojedinačnih laserskih skenova, slijedi korak registracije (3), unutar kojega se zasebni laserski skenovi koji imaju proizvoljan početni položaj i orijentaciju međusobno poravnavaju (engl. *Scan alignment*), čime se generira jedinstveni oblak točaka

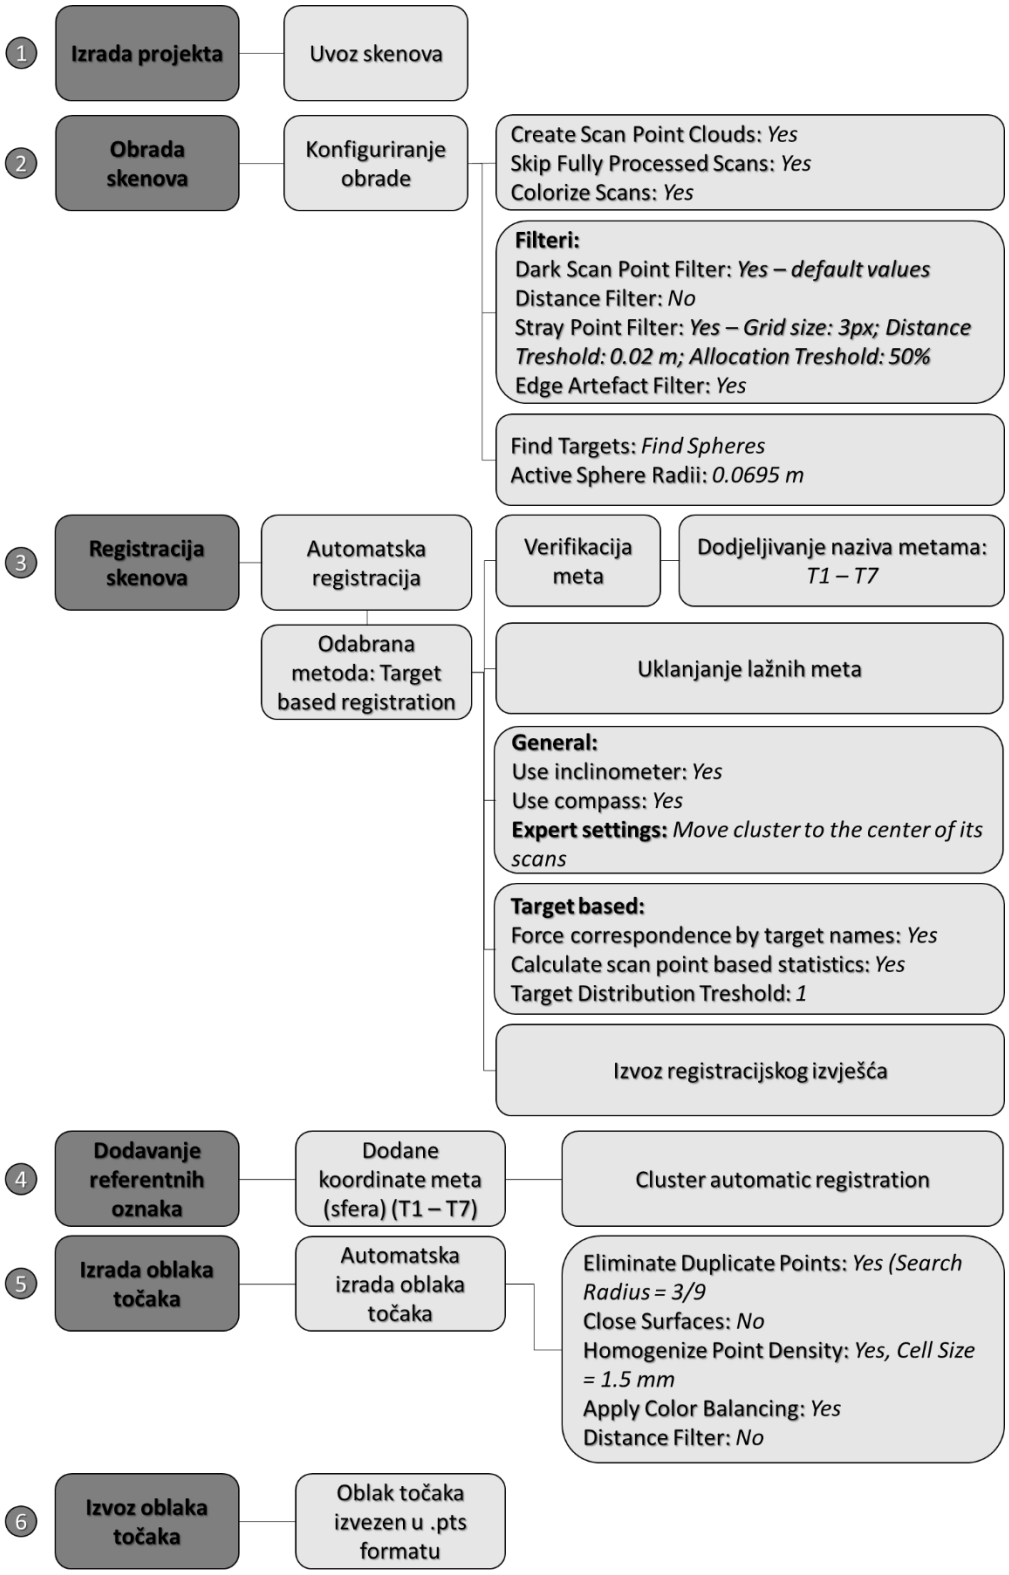

Slika 82. Koraci i parametri izrade modela iz podataka prikupljenih intervalnim laserskim skeniranjem u Faro Scene softveru

proučavanog područja (Faro, 2019b; Cheng i dr., 2018; Dong i dr., 2020b). Korak registracije skenova ujedno je i najvažniji korak obrade TLS podataka, jer o točnosti ovog koraka izravno ovisi točnost konačnih izrađenih modela, što je posebice bitno za intervalne izmjere i usporedbu

modela (Fan i dr., 2015; Dong i dr., 2020b). U sklopu primijenjene metodologije korištena je automatska registracija (engl. *automatic registration*), zasnovana na upotrebi meta (engl. *target based registration*). Prvo su verificirane sve stalne i pomoćne geodetske sfere, koje je softver automatski pronašao prema zadanim postavkama, pri čemu su sferama pridruženi odgovarajući nazivi (T1 – T7), sukladno izrađenom planu provedbe intervalnih TLS izmjera (Sl. 73; 74). Također, prilikom verifikacije su ručno uklonjene sve "lažne" sfere, odnosno svi objekti koji su krivo automatski klasificirani kao sfere (npr. okruglo kamenje). Nakon verifikacije sfera uslijedila je automatska registracija skenova, pri čemu je odabrana opcija prvenstvenog povezivanja sfera po nazivu (engl. *force correspondence by target names*). S obzirom da su ranije automatski prepoznatim sferama postavljeni odgovarajući nazivi (T1-T7), ova opcija omogućila je povezivanje istih sfera na svim laserskim skenovima. U konačnici je nakon završetka automatske registracije izrađen jedinstveni oblak točaka (Sl. 83.A), s jasno označenim pozicijama sfera i stajališta TLS-a), dok su pogreške generirane u procesu registracije izražene u pratećem izvješću.

Četvrti korak obuhvaća dodavanje geodetskih koordinata registriranom oblaku točaka, što je napravljeno na način da su koordinate pojedinih referentnih meta, izmjerene na terenu prilikom prve TLS izmjere uz pomoć Stonex S10 RTK GNSS-a, pridodane odgovarajućim sferama (T1-T7) unutar Faro SCENE softvera (Sl. 83.B). Na taj način registrirani oblak točaka iz lokalnog koordinatnog sustava transformiran je u službeni geodetski koordinatni sustav[32]. Koordinate referentnih meta (sfera) dane su u tablici 28.

[32] HTRS96 / Croatia TM (EPSG:3765)

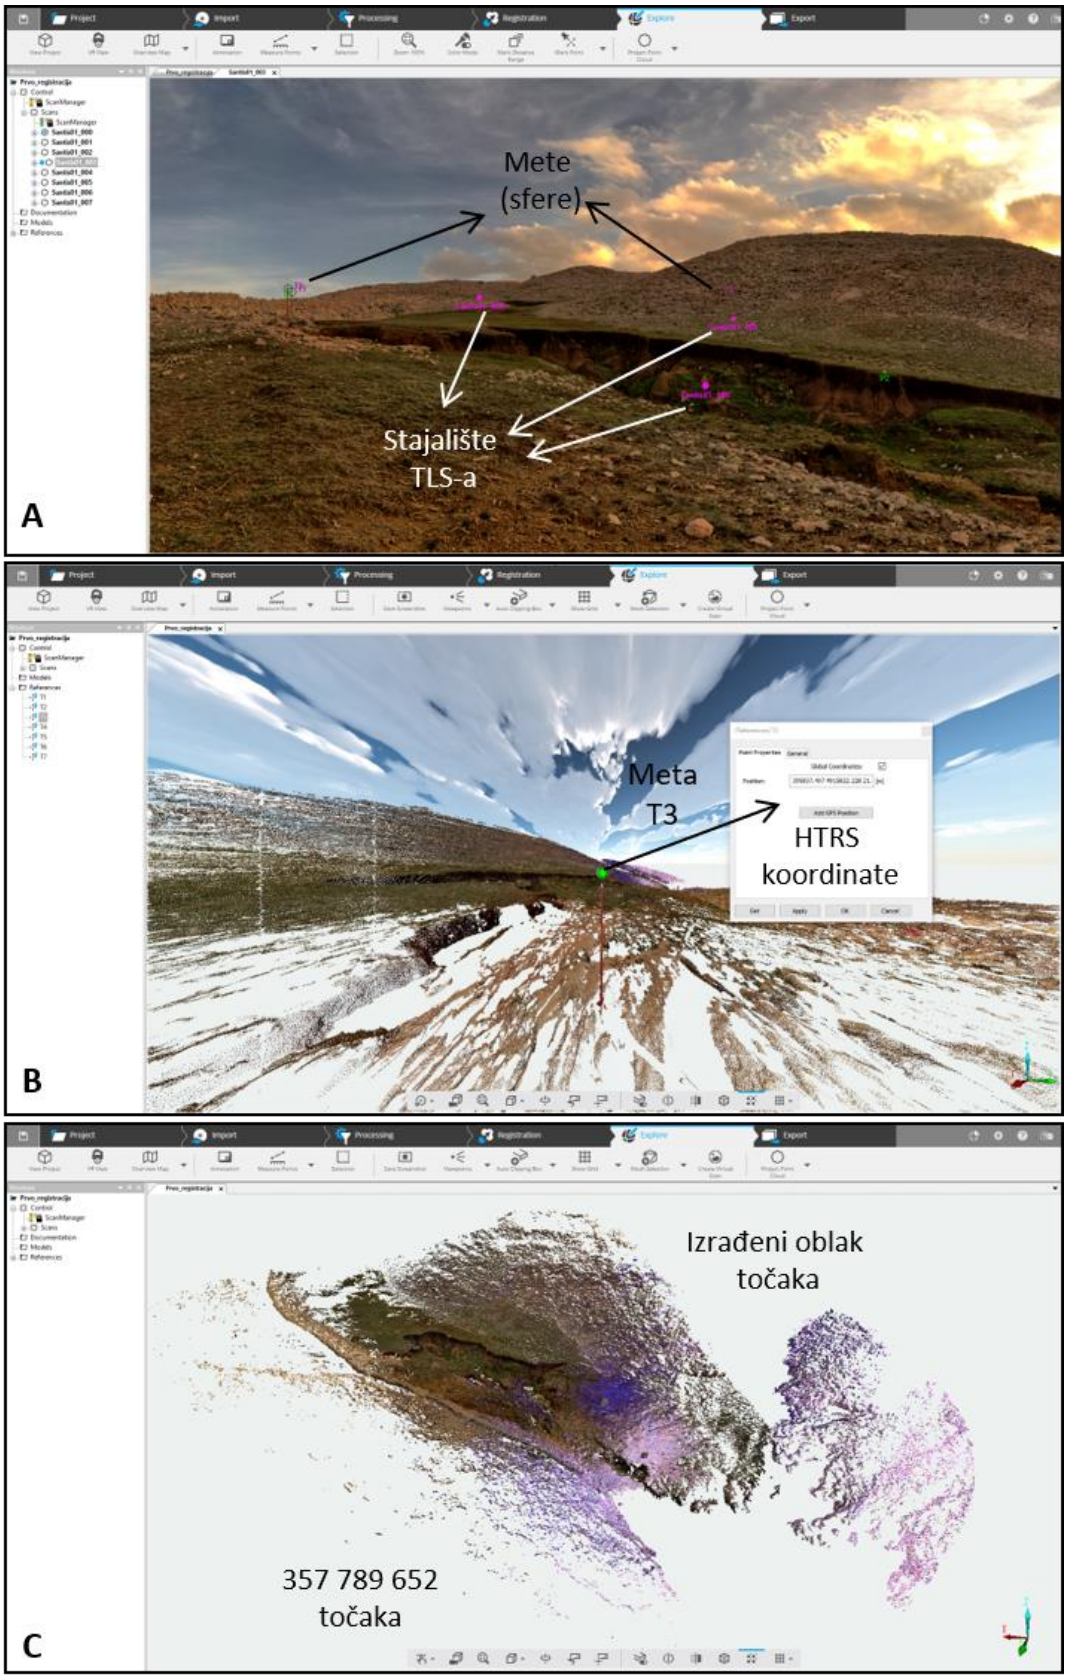

Slika 83. Izdvojeni koraci obrade podataka u Faro SCENE softveru
(A - dodavanje XYZ koordinata (HTRS96) postavljenim metama (T1-T7); B – registrirani i orijentirani skenovi; C – izrađeni finalni oblak točaka)

Tablica 28. Koordinate referentnih meta korištene pri obradi intervalnih TLS izmjera

ID	Naziv	X (E)	Y (N)	Z (H)
1	T1	395854.37	4915814.36	24.71
2	T2	395827.31	4915778.60	26.76
3	T3	395837.50	4915822.23	21.70
4	T4	395804.71	4915838.27	14.02
5	T5	395781.46	4915847.58	7.39
6	T6	395771.30	4915836.88	6.18
7	T7	395779.42	4915812.93	15.62

Nakon transformacije registriranog oblaka točaka uslijedio je korak izrade finalnog oblaka točaka, prema odabranim postavkama (Sl. 82.). Prilikom izrade konačnog oblaka točaka izvršeno je automatsko balansiranje boje teksture prikupljenih točaka (engl. *apply color balancing*), uklanjanje dupliciranih točaka (engl. *eliminate duplicate points*) i homogenizacija završnog oblaka točaka (engl. *homogenize points density*). Homogenizacija završnog oblaka točaka vrlo je bitna, jer je omogućila standardizaciju gustoće točaka u oba izrađena oblaka točaka (PC_{TLS-A} i PC_{TLS-B}) (Faro, 2019a). Naime, unatoč različitom broju prikupljenih sirovih laserskih skenova (TLS-A: 7 skenova; TLS-B: 4 skena), na temelju homogenizacije postigla se gotovo identična gustoća točaka u oba izrađena oblaka točaka. Homogenizacija je prilikom izrade intervalnih oblaka točaka podešena na standardnu vrijednost od 1.5 mm (Faro, 2019a).

Posljednji korak obrade obuhvaća eksportiranje izrađenih intervalnih oblaka točaka (PC_{TLS-A} i PC_{TLS-B}), čime je omogućena njihova daljnja obrada u sklopu drugih softvera (npr. CloudCompare, ArcGIS, itd.). Oba izrađena oblaka točaka eksportirana su u .PTS formatu, koji sadrži informacije o lokaciji (XYZ) svake točke, ali i RGB (tekstura) podatke te informacije o intenzitetu (engl. intensity), potrebne za daljnju klasifikaciju oblaka točaka.

V. Provjera ostvarene pokrivenosti područja istraživanja

Da bi se moglo provjeriti u kolikoj se mjeri ostvarene TLS izmjere podudaraju s rezultatima izrađenog plana intervalnih TLS izmjera, bilo je potrebno usporediti postotak pokrivenosti područja istraživanja u izrađenom planu i u ostvarenom, odnosno izrađenom modeli. S obzirom da je, zbog ranije navedenih razloga, jedino prva TLS izmjera (TLS-A) pokrila cijeli širi prostor mikro razine istraživanja, usporedbu ostvarenog i planiranog bilo je moguće napraviti isključivo na temelju ove izmjere.

Prilikom izrade plana intervalnih TLS izmjera izračunata je ukupna površina pokrivena optimalnom TLS izmjerom, te postotak pokrivene površine šireg prostora mikro razine istraživanja (vidi 4.2.1). Da bi isto bilo moguće izračunati iz prvog izrađenog oblaka točaka (PC_{TLS-A}), bilo je potrebno oblak točaka pretvoriti u rasterski prikaz. Konverzija izrađenog oblaka točaka u rasterski model, odnosno u digitalni model površina, napravljena je uz pomoć LiDAR360 komercijalnog softvera. LiDAR360 je komercijalni softver za naprednu obradu prikupljenih laserskih podataka (GreenValley International, 2020). Izrada rasterskog modela iz izrađenog oblaka točaka napravljena je na temelju *Kriging* metode interpolacije, integrirane u sklopu *DSM* alata u LiDAR360 softveru. Pri tome je isključena opcija interpolacije praznina u oblaku točaka (engl. *Fill in holes*). Na taj način izrađen je rasterski model bez vrijednosti (*No data*) na prostorima na kojima su bile prisutne rupe u izrađenom oblaku točaka. Prostorna rezolucija izrađenog rasterskog modela određena je prema metodi inspekcija gustoće (engl. *Inspection density*) (Hengl, 2006), koja u obzir uzima površinu područja istraživanja i broj prikupljenih točaka unutar njega. Unutar šireg prostora mikro razine istraživanja, površine 1163.09 m^2, ukupno se nalazi 128 164 408 točaka. Iako prema metodi inspekcije gustoće optimalna prostorna rezolucija u slučaju TLS-A izmjere iznosi 0.02 cm, zbog ograničenja korištenog LiDAR360 softvera[33], ali i zbog lakšeg i bržeg procesiranja prostorna rezolucija je morala biti podešena na 1 cm.

Na temelju izrađenog rasterskog modela u ArcGIS 10.1 softveru izračunati su ukupna pokrivena površina (m^2) i postotak (%) pokrivenosti šireg prostora mikro razine istraživanja, te je izvršena usporedba s vrijednostima dobivenim prilikom planiranja TLS izmjera.

[33] LiDAR360 softver ne dopušta izradu rasterskih modela prostorne rezolucije ispod 1 cm.

3.3.2. Procjena točnosti izrađenog inicijalnog aerofotogrametrijskog modela

Procjena točnosti izrađenog aerofotogrametrijskog intervalnog modela (*Model UAV-A*) napravljena je na temelju usporedbe izrađenog oblaka točaka (PC_{UAV-A}) s referentnim oblakom točaka (PC_{TLS-A}). Prema proučenim ranije objavljenim istraživanjima modeli izrađeni iz podataka prikupljenih u sklopu TLS izmjere mogu se koristiti kao referentni podaci, jer u odnosu na modele izrađene intervalnom UAV fotogrametrijom, imaju veću detaljnost i točnost (Glendell i dr., 2017). Zbog toga je oblak točaka izrađen iz podataka inicijalne TLS izmjere (PC_{TLS-A}) korišten kao referentni podatak, na temelju kojega je izvršena procjena točnosti intervalnog aerofotogrametrijskog modela (Sl. 84.).

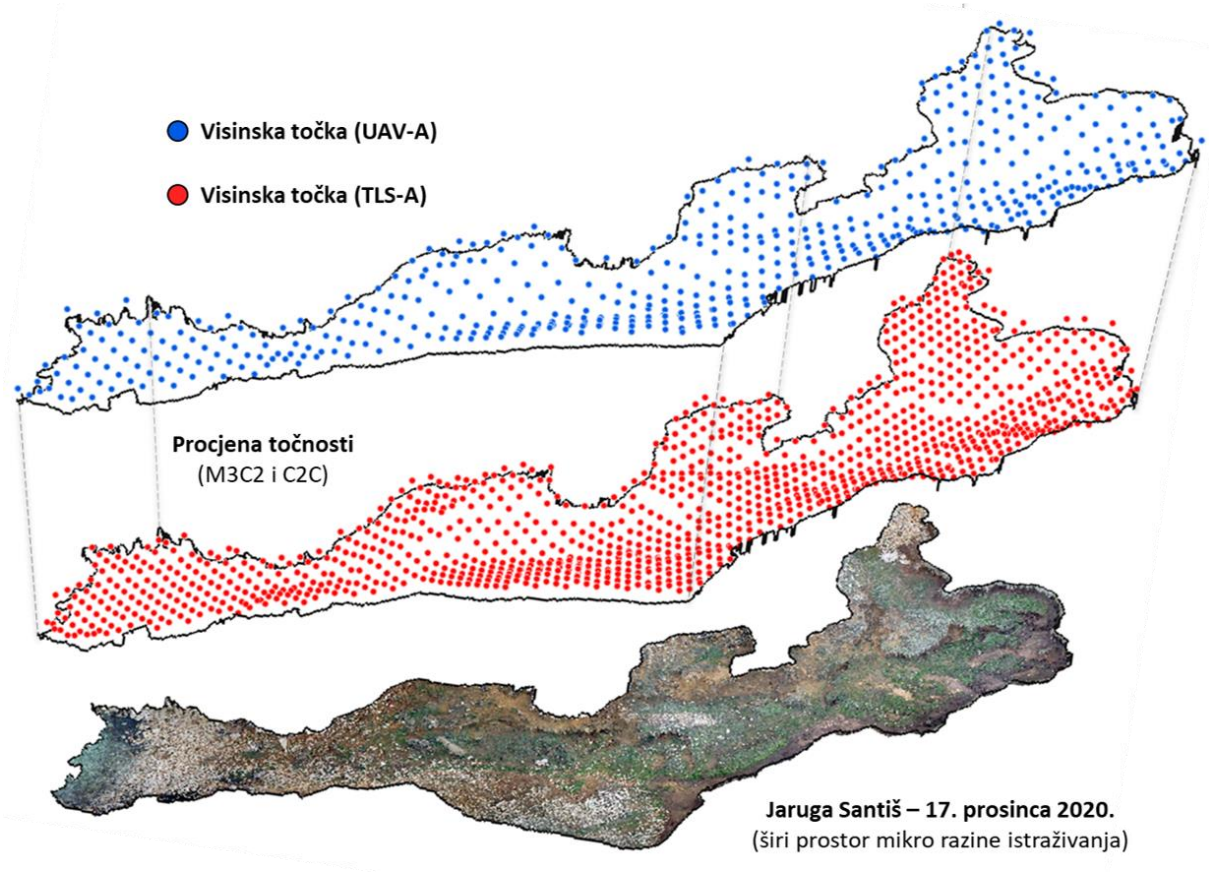

Slika 84. Procjena točnosti oblaka točaka prvog intervalnog aerofotogrametrijskog snimanja (*UAV-A*) na temelju referentnog oblaka točaka prikupljenog u sklopu inicijalne TLS izmjere

Usporedba oblaka točaka izvršena je korištenjem M3C2 (engl. *Multiscale Model to Model Cloud Comparison* - M3C2) algoritma unutar CloudCompare softvera. M3C2 omogućava izravnu usporedbu i izračun udaljenosti između dva oblaka točaka, uz procjenu pouzdanosti izračunate udaljenosti, temeljene na kompleksnosti terena i registracijskoj pogrešci (Lague i dr., 2013). Primjenom M3C2 metode za detekciju i kvantifikaciju kompleksnih 3D

PVP uzrokovanih djelovanjem erozije tla nadoknađuju se nedostaci digitalnih modela diferencije vezani za kompleksnu morfologiju erozijskih formi (DMD) (Lague i dr., 2013; James i dr., 2017b; Cândido i dr., 2020). S obzirom da DMD predstavlja 2.5D model, prilikom detekcije PVP može doći do značajnih pogrešaka, posebice u kompleksnim strmim i prevjesnim dijelovima reljefa, gdje 2.5D modeli ne mogu vjerno reprezentirati morfologiju terena (Gómez-Gutiérrez i Gonçalves, 2020).

M3C2 metoda za svaku točku inicijalnog oblaka točaka (PC_{TLS-A}) izračunava lokalnu prosječnu udaljenost između dva oblaka točaka (James i dr., 2017b). U prvom koraku M3C2 određuje lokalnu normalu (N) svake pojedine točke (*i*) iz inicijalnog oblaka točaka (*i*), kroz namještanje ravnine kroz sve susjedne točke iz drugog oblaka točaka, unutar zadanog radijusa normale od točke *i* (D/2) (Sl. 85.A) (Lague i dr., 2013; James i dr., 2017b). Pri tome je najvažniji korisničko-definirani parametar radijus od točke *i* (D/2), gdje odabrana vrijednost definira promjer sfernog susjedstva unutar kojega će M3C2 izvršiti određivanje lokalne normale (N) (Gómez-Gutiérrez i Gonçalves, 2020). Što je radijus sfernog susjedstva veći, to je utjecaj lokalne raščlanjenosti i kompleksnosti reljefa, ali i pogreški u oblaku točaka, manji, što se odražava kroz veću generalizaciju rezultata M3C2 udaljenosti (James i dr., 2017b; Gómez-Gutiérrez i Gonçalves, 2020).

Zatim u drugom koraku M3C2 algoritam određuje prosječnu poziciju točaka jednog i drugog oblaka točaka, unutar cilindra zadanog polumjera (*d/2*), orijentiranog duž određene normale (N) (Sl. 85.B). Time M3C2 algoritam određuje srednji položaj točke u inicijalnom oblaku točaka (i_1) i u drugom oblaku točaka (i_1), te udaljenost (L_{M3C2}) između te dvije pozicije (James i dr., 2017b; DiFrancesco i dr., 2020).

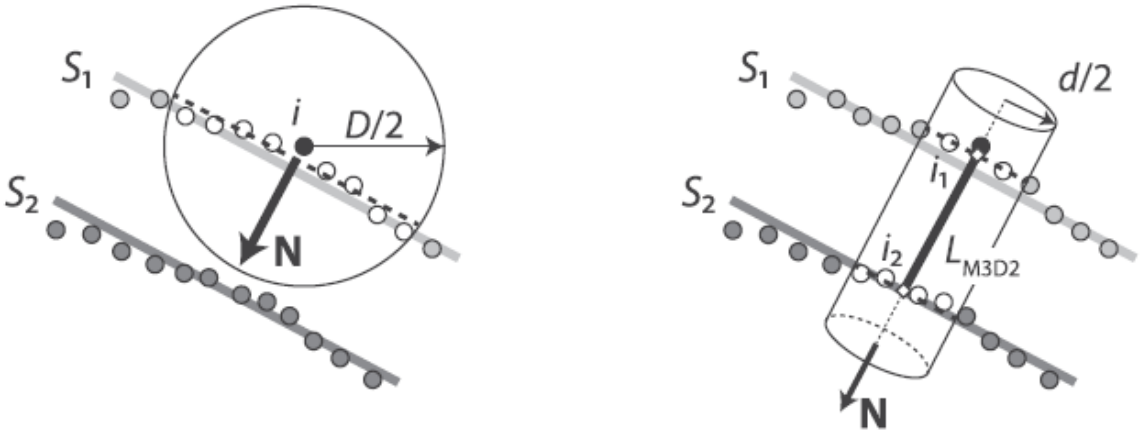

Slika 85. Koraci određivanja udaljenosti između dva oblaka točaka uz pomoć M3C2 algoritma (preuzeto iz James i dr., 2017b)

Prilikom primjene M3C2 algoritma treba voditi računa o korisničko-definiranim parametrima, koji uvelike mogu utjecati na izlazne rezultate (James i dr., 2017b; DiFrancesco i dr., 2020; Gómez-Gutiérrez i Gonçalves, 2020). Korisničko-definirani parametar promjer normale (engl. *normals diameter* (D/2)) podešen je na 3.66 cm, a promjer cilindra (engl. *projection diameter* (d/2)) postavljen je na 1.83 cm, dok je maksimalna dubina (engl. *max depth*) postavljena na 1.5 m. Orijentacija cilindra (engl. *prefered orientation*) postavljena je na +Z. Vrijednosti navedenih korisničko-definiranih parametara određene su empirijskom metodom, kroz iterativnu primjenu M3C2 algoritma s različitim vrijednostima ovih parametara. Pri tome su ranije navedene vrijednosti rezultirale najmanjom generalizacijom rezultata.

3.3.3. Izdvajanje užeg prostornog obuhvata mikro razine istraživanja

Iako je primijenjenim intervalnim terestričkim laserskim skeniranjem obuhvaćen cijeli donji dio jaruge Santiš (Sl. 9.A), uže područje istraživanja mikro razine obuhvatilo je samo manji dio tog prostora. Razlog tomu je prvenstveno zahtjevna i dugotrajna obrada prikupljenih oblaka točaka, koja bi za čitav prostor jaruge bila vrlo kompleksna. Također, unutar većeg prostora bilo bi znatno teže detektirati i interpretirati pojedine promjene uzrokovane erozijom tla. Stoga uži prostor mikro razine istraživanja obuhvaća isključivo manji pravokutni dio glavnog čela jaruge Santiš, ukupne površine 200 m^2, unutar kojega su prilikom ranijih terenskih istraživanja (Šiljeg i dr., 2021) zabilježeni najintenzivniji tragovi erozije tla (Sl. 9.B).

Generirani poligonski pravokutni prostorni obuhvat iskorišten je za izdvajanje intervalnih oblaka točaka užeg prostora mikro razine, na temelju kojih je kasnije napravljena detekcija i kvantifikacija 3D PVP (*vidi* 3.3.5.). Zatim su izrezani intervalni oblaci točaka (PC_{TLS-A} i PC_{TLS-B}) iskorišteni za izradu rasterskih modela ($DSM_{TLS2019}$ i $DSM_{TLS2020}$), prema ranije pojašnjenoj metodologiji zasnovanoj na primjeni komercijalnog LiDAR360 softvera. Kao i ranije, rasterski modeli napravljeni su na temelju *Kriging* metode interpolacije, pri čemu je ovaj put uključena opcija popunjavanja praznina prilikom interpolacije oblaka točaka (engl. *Fill in holes*). Rasterski modeli užeg prostora mikro razine istraživanja iskorišteni su za automatsko izdvajanje linija čela jaruge, prema metodologiji razvijenoj u sklopu ranijih istraživanja (Domazetović, 2018), zasnovanoj na automatskom izdvajanju *infleksijskih linija*. Primijenjeni koncept sastoji se od nekoliko koraka (Sl. 86.). Automatsko izdvajanje infleksijskih linija napravljeno je unutar ArcGIS 10.1 softvera, korištenjem *Focal Statistics* alata, uz pomoć kojega je bilo moguće napraviti analizu varijabilnosti visina unutar zadanog lokalnog područja. Slijedeći praksu ustaljenu u sklopu ranijih istraživanja parametar tipa susjedstva (engl. *neighboorhood*) alata Focal Statistics podešen je na pravokutno (engl. *rectangle*) susjedstvo, dok je veličina zadanog susjedstva (engl. *height* i *width*) podešena na 3 x 3 piksela. Za parametar izračuna statistike odabran je izračun raspona (engl. *range*) vrijednosti, na temelju čega je alat unutar zadanog susjedstva izračunao raspon visinskih vrijednosti (Sl. 86. A).

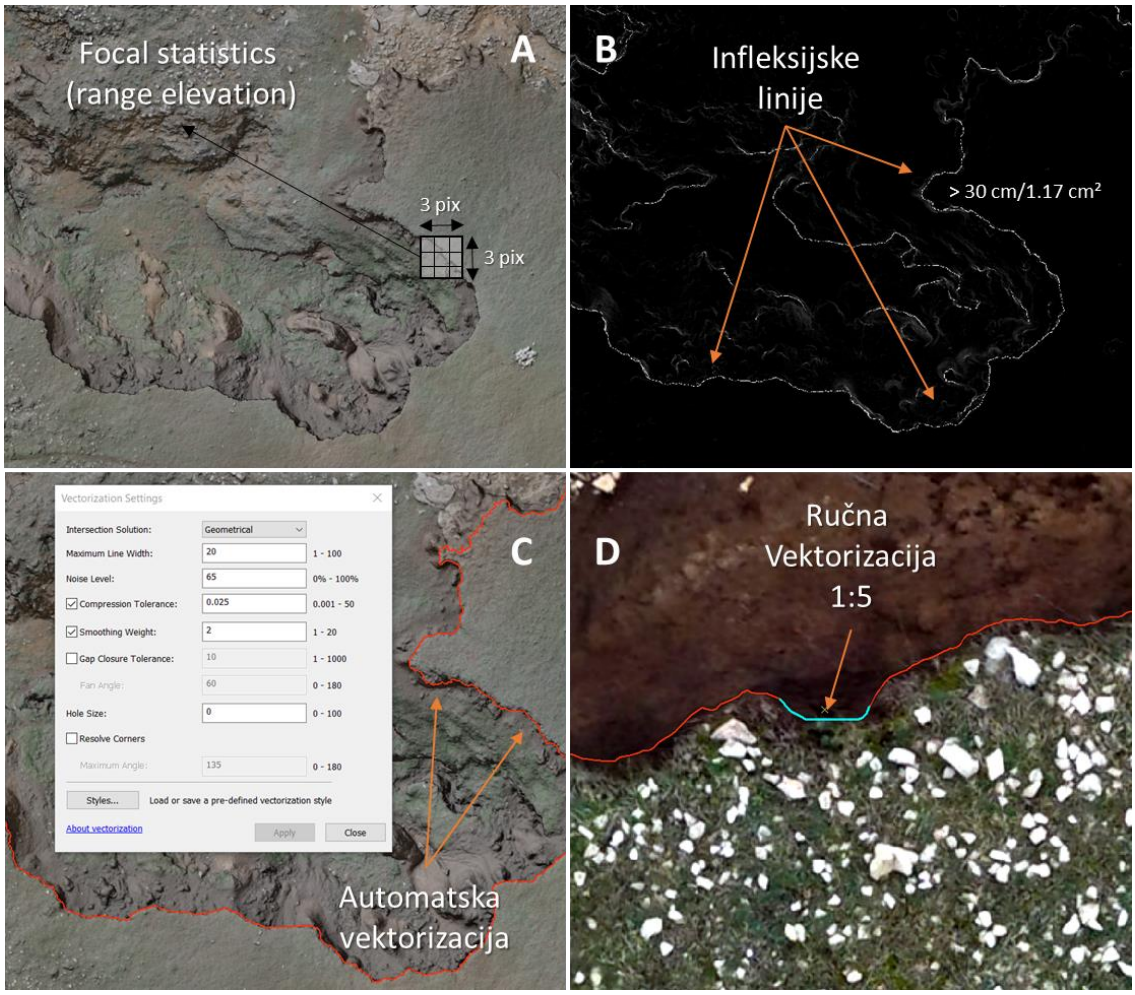

Slika 86. Koraci primijenjenog automatskog izdvajanja linije glavnog čela jaruge Santiš

Generirani rasterski podatak zatim je klasificiran u dvije klase s pragom podešenim na 30 cm, čime je omogućena detekcija i izdvajanje svih infleksijskih linija koje predstavljaju promjenu visine od minimalno 30 cm/1.17 cm^2 (30 cm unutar 3 x 3 piksela) (Sl. 86. B). Detektirane infleksijske linije automatski su vektorizirane korištenjem ArcScan ekstenzije, pri čemu su korišteni sljedeći parametri automatske vektorizacije: *Smoothing weight = 2; Compression Tolerance = 0.025; Maximum line width = 20; Noise level = 65; Intersection solution = Geometrical* (Sl. 86. C).

S obzirom da su linije generirane automatskom vektorizacijom bile mjestimice prekinute, bilo je potrebno ručno nadopuniti i ispraviti sve prekide. Zbog toga je napravljena ručna vektorizacija uz pomoć DOF-a (Model UAV-A) u mjerilu 1:5, kojom su svi prekidi ispravljeni (Sl. 86. D). U konačnici su izdvojene jedinstvene linije, koje predstavljaju glavno čelo jaruge Santiš izdvojeno iz intervalnih TLS rasterskih modela (modeli TLS-A i TLS-B).

3.3.4. Razvoj kvantitativnog alata za praćenje pomaka čela jaruge

Trenutačno postoje brojni različiti napredni alati i softveri za automatsku detekciju i kvantifikaciju 2D, 2.5D ili pak 3D prostorno-vremenskih promjena, od kojih su neki primijenjeni i u ovoj disertaciji, npr. Gomorphic Change Detection 7 (Wheaton i dr., 2010; Neverman i dr., 2016); M3C2 algoritam (Lague i dr., 2013; James i dr., 2017b; Gómez-Gutiérrez i Gonçalves, 2020). S obzirom da većina postojećih alata i softvera omogućava detekciju svih PVP nastalih unutar određenog područja, izdvajanje i interpretacija intenziteta pojedinih procesa koji su doveli do tih promjena može predstavljati zahtjevan proces. Primjerice, iako primjena GCD7 softvera (vidi 3.2.3; 4.2.1; 4.2.2.) omogućava kvantifikaciju svih PVP promjena koje su nastale unutar određenog prostora, izdvajanje intenziteta erozije i akumulacije uzrokovane djelovanjem pojedinog procesa (npr. pomak čela jaruge) od preostalih PVP gotovo da nije moguće.

Zbog toga je osnovni cilj razvoja novog alata bio isključivo usmjeren na detekciju i kvantifikaciju promjena koje su uzrokovane pomakom čela jaruge unutar određenog prostora i vremena. Za potrebe ostvarivanja ovog cilja u ModelBuilder aplikaciji ArcGIS 10.1 softvera napravljen je alat za automatsko praćenje intenziteta pomaka čela jaruge (engl. *Headcut Change Detection* – HCD alat). HCD alat razvijen je unutar ModelBuilder aplikacije korištenjem i spajanje postojećih alata iz Spatial Analyst i 3D Analyst ekstenzija. Primjene HCD alata za detekciju i kvantifikaciju pomaka čela jaruge može se raščlaniti na sljedeća tri osnovna koraka: *detekcija i izračun linearnog pomaka čela jaruge (I), detekcija i izračun površinskog pomaka čela jaruge (II)* te na *detekciju i izračun volumetrijskog pomaka čela jaruge (III)* (Sl. 88.).

Prva dva koraka primjene HCD alata usmjerena su isključivo na 2D izračun pomaka čela jaruge, zbog čega su jedini potrebni ulazni podaci za izračun linearnog i površinskog intenziteta dva intervalna linijska sloja koji reprezentiraju čelo jaruge u različitim vremenskim periodima (Sl. 87.A). Pri tome vremenska rezolucija ovisno o dostupnim podacima i intenzitetu promjena može varirati od dnevne, tjedne, mjesečne, godišnje, sve do višegodišnje.

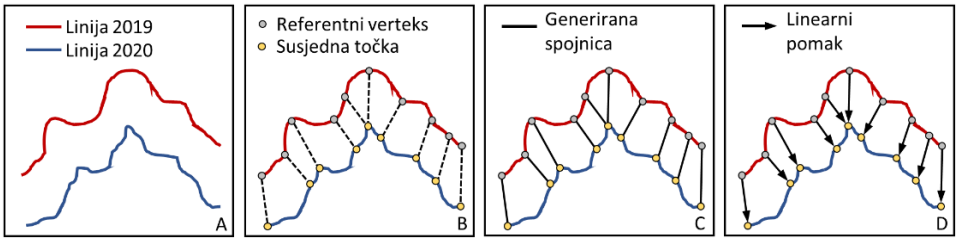

Slika 87. Princip izračuna linearnih 2D promjena uzrokovanih pomakom čela jaruge

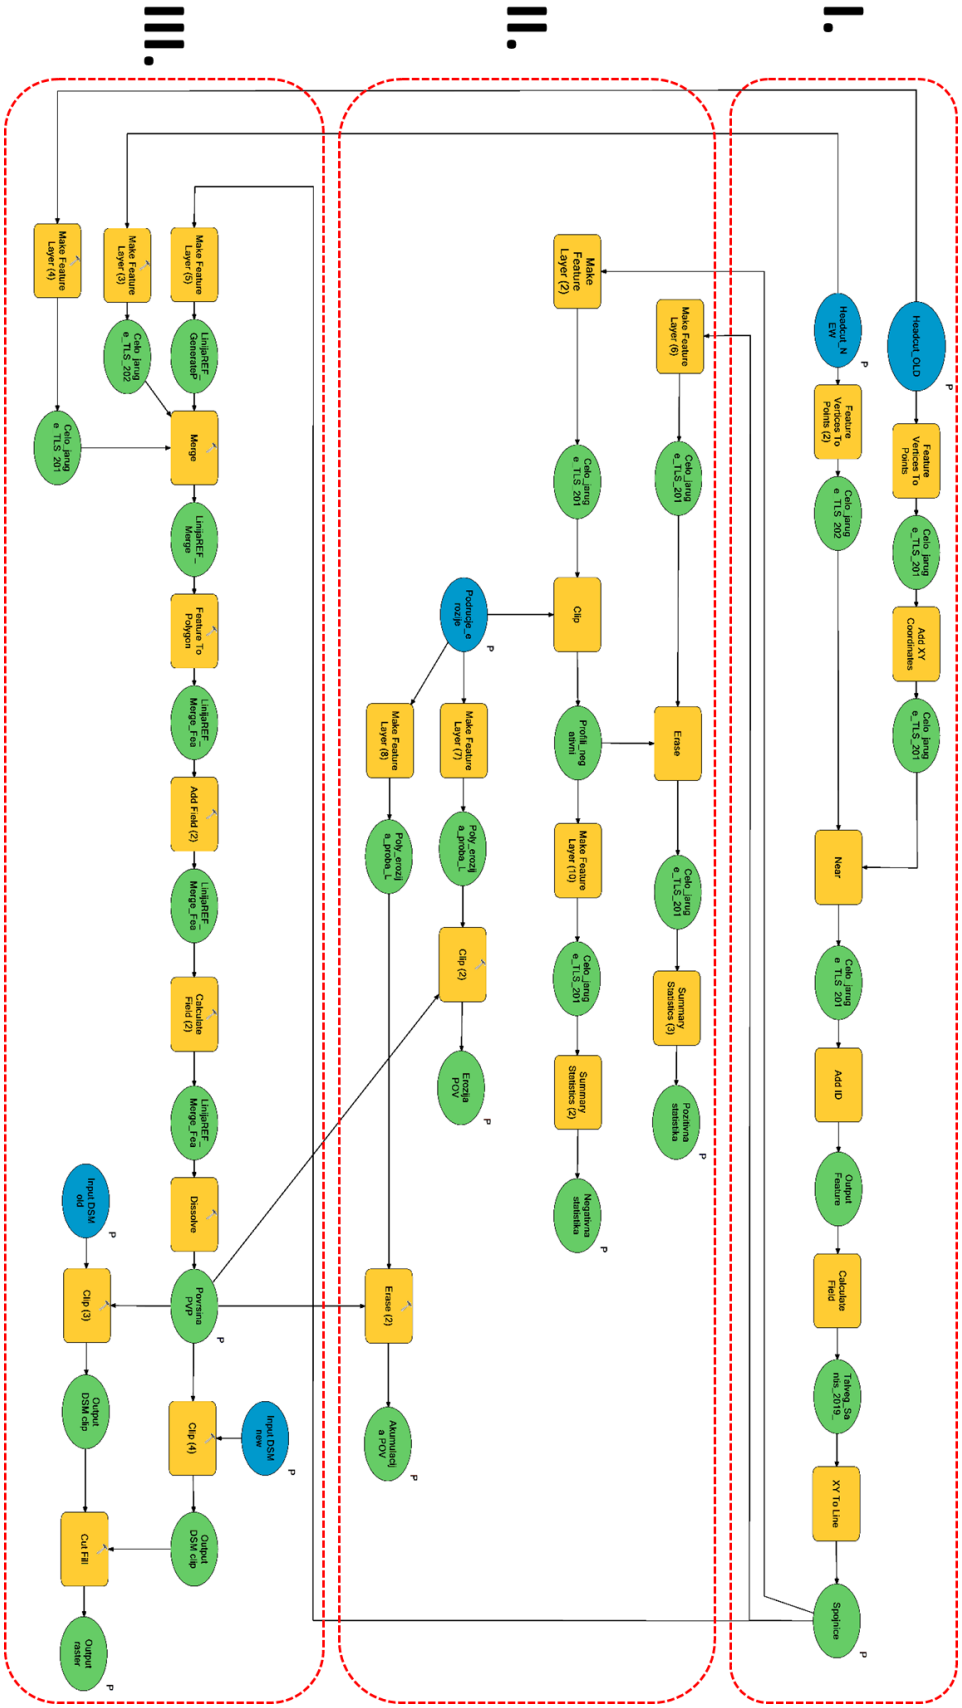

Slika 88. Shematski prikaz razvijenog HCD alata (I. – detekcija linearnog pomaka; II. – detekcija površinskog pomaka; III. – detekcija volumetrijskog pomaka)

Također, potrebne linije čela jaruge mogu biti ili automatski izdvojene na temelju dostupnih 2.5D rasterskih modela, kao što su izdvojena u sklopu ove disertacije (vidi 3.3.3.), ili u slučaju 2D modela mogu biti ručno vektorizirane prema dostupnom predlošku (npr. DOF).

U sklopu prvog koraka HCD alat na temelju lomnih točaka referentnog (starijeg) čela jaruge HCD alat uz pomoć alata *Near* određuje odgovarajuće najbliže susjedne točke na novijoj liniji čela jaruge (Sl. 87.B). Pri tome je broj uzoraka na temelju kojega će se napraviti izračun linearnog pomaka čela jaruge određen brojem lomnih točaka koji reprezentiraju referentnu liniju čela. Nakon određivanja odgovarajućih susjednih točaka na novijoj čeonoj liniji, HCD alat na temelju *XY to line* alata generira *spojnice*, odnosno linije koje spajaju lomne točke referentnog čela s određenim najbližim susjednim točkama na novijoj liniji čela jaruge (Sl. 87.C). Izrađene linije predstavljaju linearni pomak čela jaruge, pri čemu pozitivne vrijednosti predstavljaju progresivni pomak, a negativne vrijednosti retrogradni pomak čela jaruge. U konačnici alat HCD iz generiranih *spojnica* uz pomoć *Summary statistics* alata izdvaja kumulativnu statistiku linearnog pomaka (MIN, MAX, RANGE, SUM, COUNT, STDEV), zasebno za eroziju (negativne vrijednosti) i akumulaciju (pozitivne vrijednosti).

Drugi korak primjene HCD alata obuhvaća detekciju i kvantifikaciju površinskog pomaka (Sl. 88. II.), koji se temelji na pretvaranju prostornog obuhvata linija čela jaruge i generiranih spojnica u poligonsku reprezentaciju PVP (Sl. 89.). Alat HCD prvo spaja dvije zadane linije čela jaruge s kreiranim linijama spojnicama, da bi zatim uz pomoć *Line to polygon* alata izvršio konverziju povezanih linija u poligone. Nakon kreiranja poligona, uz pomoć *Dissolve* opcije HCD alat razvrstava poligone u jedan poligonski sloj koji reprezentira pozitivni površinski pomak, odnosno akumulaciju i u jedan poligonski sloj koji reprezentira negativni površinski pomak, odnosno eroziju tla.

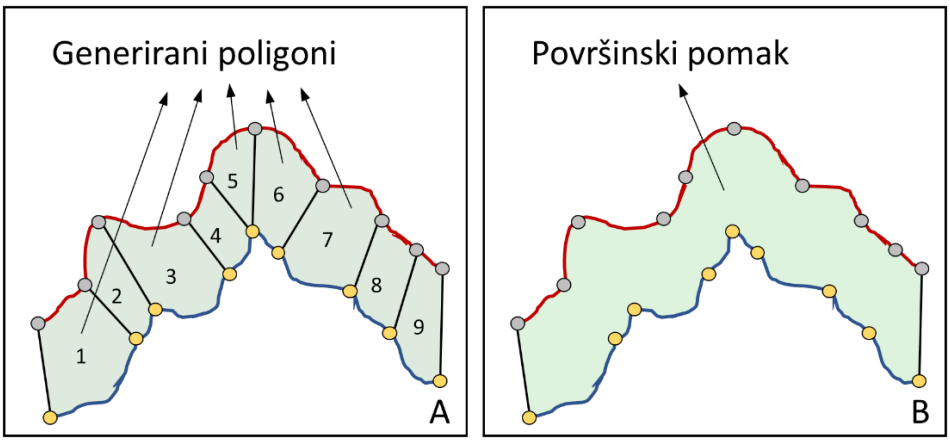

Slika 89. Princip izračuna površinskih 2D promjena uzrokovanih pomakom čela jaruge

Zadnji korak primjenjiv je isključivo na rasterskim 2.5D modelima, jer HCD alat na temelju ranije generiranih poligona erozije i akumulacije i informacija o visini pojedinih piksela vrši izračun erodiranog i akumuliranog volumena. Za izračun volumena uz pomoć HCD alata korisnik uz ranije definirane dvije linije čela jaruge mora u sučelju alata odabrati i odgovarajuće rasterske modele, na temelju kojih će alat napraviti izračun volumetrijskih promjena. Oduzimanjem novijeg rasterskog modela od inicijalnog referentnog modela HCD generira model visinske razlike između dva modela, na temelju kojega zatim računa volumen detektiranih promjena.

3.3.5. Detekcija i kvantifikacija PVP uzrokovanih erozijom tla unutar užeg prostornog obuhvata mikro razine istraživanja

U sklopu ove disertacije detekcija i kvantifikacija PVP uzrokovanih erozijom tla je unutar užeg prostornog obuhvata mikro razine istraživanja napravljena na temelju sljedećih modela izrađenih iz podataka prikupljenih u sklopu intervalnih TLS izmjera: *intervalni oblaci točaka* (**I.**) te *intervalni rasterski modeli* (**II.**)

I. Detekcija i kvantifikacija PVP na temelju izrađenih intervalnih oblaka točaka dijela čela jaruge

Detekcija jednogodišnjih PVP uzrokovanih erozijom tla unutar mikro razine istraživanja napravljena je unutar besplatnog CloudCompare softvera (v2.6.1.). CloudeCompare (CC) softver omogućava naprednu obradu 3D oblaka točaka (CloudCompare, 2020), te se kao takav koristi u brojnim geomorfološkim istraživanjima. Prednosti korištenja oblaka točaka za detekciju i kvantifikaciju PVP u odnosu na 2.5D modele (npr. DMP) istražene su u brojnim prethodnim istraživanjima, te su i unutar ove disertacije detaljno pojašnjena u ranijim poglavljima (vidi 2.3.). Detekcija i kvantifikacija jednogodišnjih PVP napravljena je na temelju dva intervalna oblaka točaka (PC_{TLS-A} i PC_{TLS-B}) izrađenim iz podataka prikupljenim u sklopu provedenih intervalnih TLS izmjera.

Kao i ranije kod procjene točnosti inicijalnog aerofotogrametrijskog modela (*vidi 3.3.2.*), za detekciju promjena nastalih unutar proučavanog prostora u promatranom jednogodišnjem razdoblju korištena je napredna M3C2 metoda.

Korisničko-definirani parametri primjene M3C2 algoritma podešeni su prema značajkama oblaka točaka, te prema proučenim ranije objavljenim istraživanjima u kojima je M3C2 algoritam korišten za usporedbu intervalnih oblaka točaka sličnih karakteristika (npr. Cândido i dr., 2020). Pri tome je korisničko-definirani parametar promjer normale (engl. *normals diameter* (D/2)) podešen na 10 cm, promjer cilindra (engl. *projection diameter* (d/2)) na 20 cm, dok je maksimalna dubina (engl. max depth) postavljena na 1.40 m. Orijentacija cilindra (engl. *prefered orientation*) postavljena je na +Z, a pogreška u registraciji podešena je na 2.2 cm, sukladno rezultatima provedene registracije izrađenih oblaka točaka (*vidi 4.3.1.*).

II. Detekcija i kvantifikacija PVP uzrokovanih erozijom tla na temelju izdvojenih intervalnih linija čela jaruge

Osim detekcije PVP na temelju intervalnih oblaka točaka u sklopu ove disertacije napravljena je i detekcija promjena uzrokovanih pomakom čela jaruge. Za potrebe ove analize razvijeni HCD alat primijenjen je za usporedbu dviju intervalnih linija čela jaruge generiranih iz podataka prikupljenih intervalnim TLS izmjerama (*vidi 3.3.3.*). U konačnici je usporedbom izdvojenih intervalnih linija čela jaruge Santiš omogućena je detekcija i kvantifikacija jednogodišnje linearne, površinske i volumetrijske stope uzmaka čela jaruge.

4. REZULTATI I RASPRAVA

4.1. Rezultati makro razine istraživanja

Rezultati makro razine istraživanja obuhvaćaju rezultate vezane za izradu višekriterijskog GIS modela podložnosti eroziji tla. Pri tome je u prvom dijelu dan pregled odabranih kriterija i njihove zastupljenosti unutar prostora Paga, zatim pregled i validacija različitih izrađenih GIS-MCDA modela te u konačnici pregled konačnog GIS-MCDA modela.

4.1.1. Odabrani kriteriji podložnosti eroziji tla

Odabrani kriteriji GIS-MCDA grupirani su u sljedeće tri grupe kriterija: *morfometrijski kriteriji*; *hidrološki kriteriji* i *ostali kriteriji*.

Grupa morfometrijskih kriterija

Unutar grupe morfometrijskih kriterija svrstani su sljedećih sedam kriterija koji kvantificiraju određeni segment morfologije terena: nagib padine (engl. *slope* - SLO), orijentacija padine (engl. *aspect* - ASP), profilna zakrivljenost padine (engl. *profile curvature* - PROF), planarna zakrivljenost padine (engl. *planar curvature* - PLAN), indeks ravnoteže mase (engl. *mass balance index* - MBI), topografski indeks pozicije (engl. *topographic position index* - TPI) te indeks vertikalne raščlanjenosti (engl. *terrain ruggedness index* - TRI). Prikaz prostorne distribucije klasa odabranih morfometrijskih kriterija dan je na slici 90.

Prvi kriterij unutar ove grupe kriterija je nagib padine (SLO). SLO predstavlja možda i najvažniji predisponirajući kriteriji erozije tla, koji je kao takav neizostavan za modeliranje podložnosti (Conforti i dr., 2011; Conoscenti i dr., 2013; Arabameri i dr., 2020b). Nagibi padina otoka Paga su vrlo heterogeni (Tabl. 29.) jer morfologija otoka varira od zaravnjenih prostora blagih nagiba, pa sve do gotovo vertikalnih strmaca. Zaravnjeni tereni (do 2°) obuhvaćaju 55.46 km^2, odnosno oko 19.47 % ukupne površine otoka. Pretežito su vezani za unutrašnje sinklinalne dijelove otoka ispunjene flišnim naslagama. Blago nagnuti (2° – 5°) i nagnuti tereni (5° – 12°) obuhvaćaju 31.89 % (90.81 km^2), odnosno 29.61 % (84.33 km^2) ukupne površine otoka i predstavljaju prijelazno područje iz zaravnjenih sinklinalnih flišnih udolina, prema antiklinalnim uzdignutim karbonatnim dijelovima otoka. Slijede značajno nagnuti tereni (12° – 32°) s 17.58 % udjela (50.05 km^2) u ukupnoj površini otoka, vezani za strmije padine vapnenačkih uzvisina i padine većih jaruga. Posljednje dvije klase su vrlo strmi tereni (32° –

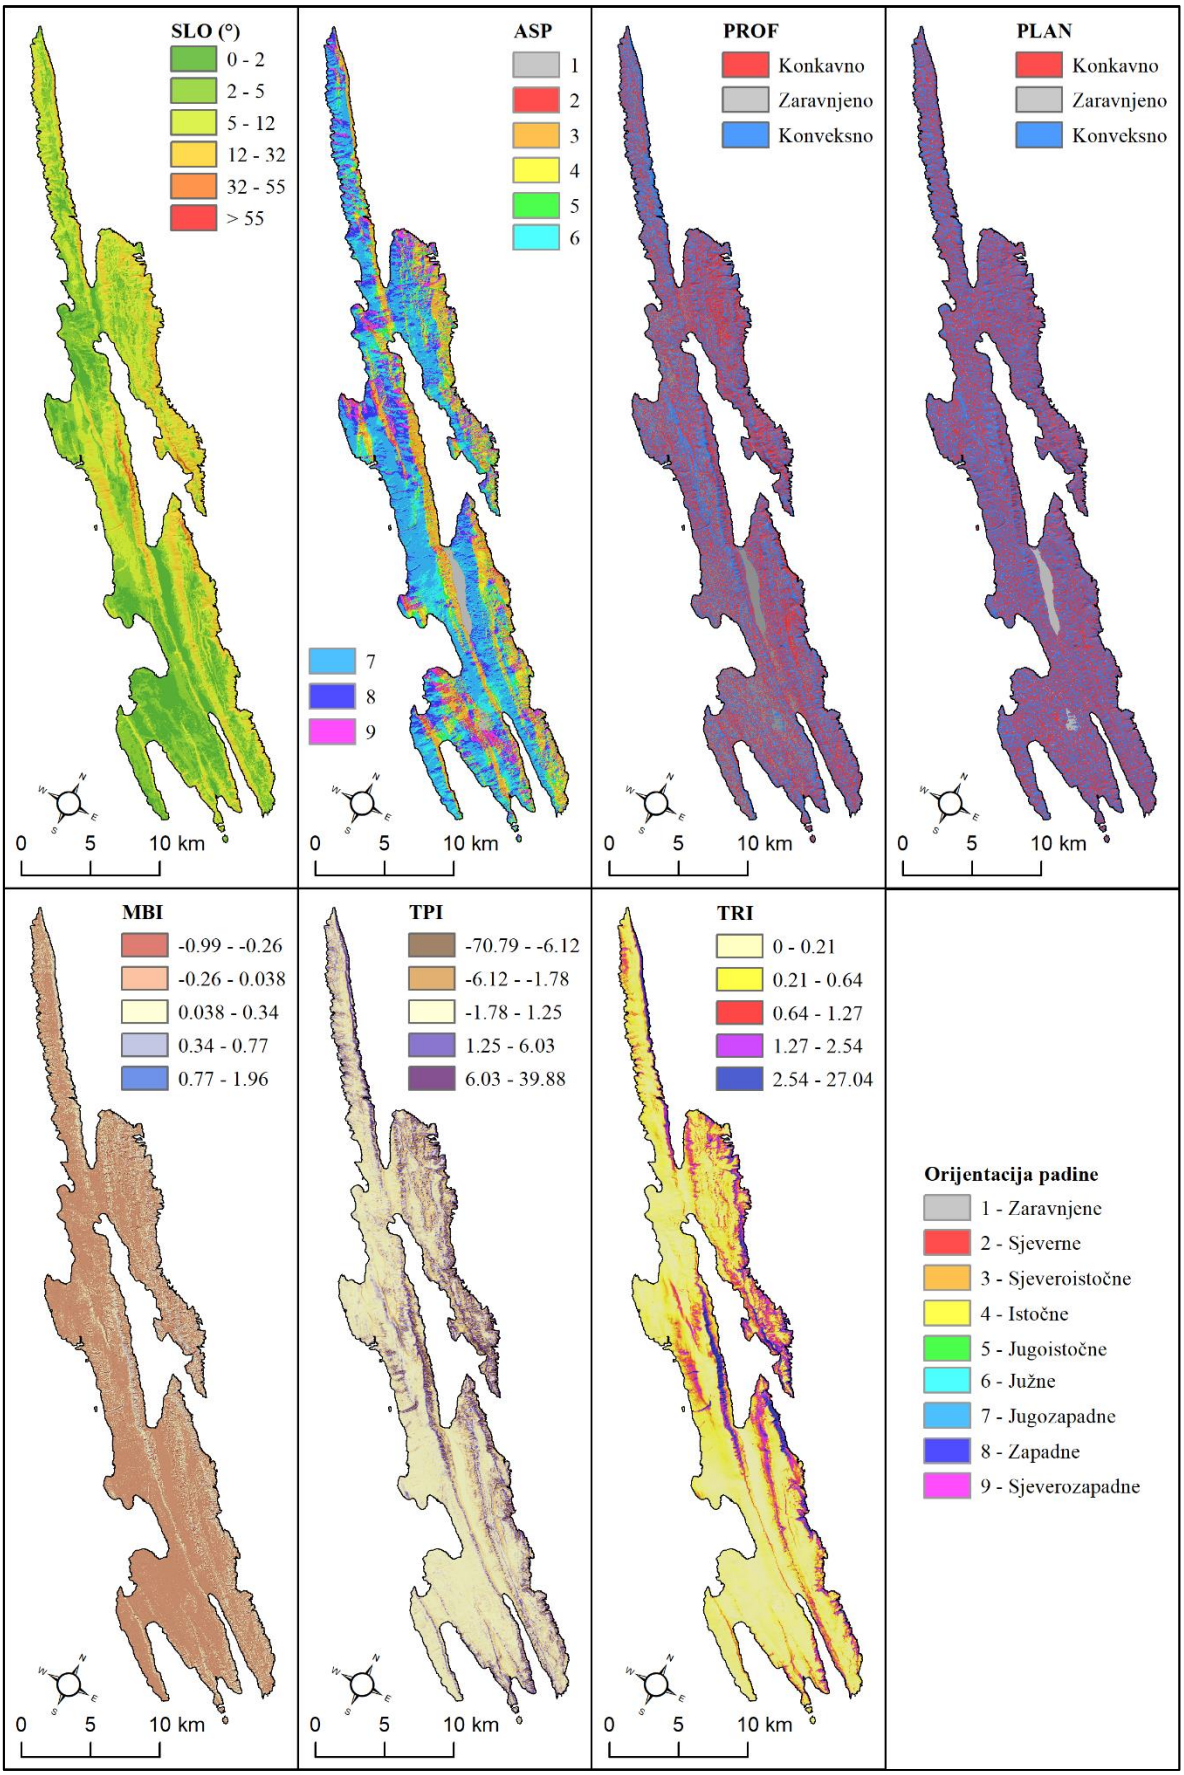

Slika 90. Grupa morfometrijskih kriterija GIS-MCDA podložnosti eroziji tla

55°) i strmci (> 55°) koji su zastupljeni na svega 1.46 % površine otoka, odnosno na najraščlanjenijim i najvišim dijelovima otoka te na strmim priobalnim padinama istočnog dijela otoka.

Tablica 29. Zastupljenost klasa SLO s pripadajućim standardiziranim vrijednostima

SLO	0° – 2°	2° – 5°	5° – 12°	12° – 32°	32° – 55°	> 55°
Površina (km²)	55.46	90.81	84.33	50.05	3.97	0.17
Udio	19.47	31.89	29.61	17.58	1.40	0.06
Referentni uzorci	0	6	13	15	3	1
Referentni uzorci (%)	0	18.42	39.47	39.47	7.89	2.63
Težinski koeficijent	1.00	3.00	4.00	5.00	4.00	3.00

Orijentacija padine (ASP) je sljedeći morfometrijski kriterij, koji određuje izloženost određene površine različitim klimatskim utjecajima (npr. insolacija, vjetar, itd.) te utječe na razvijenost vegetacijskog pokrova i erozivnost različitih agensa (Domazetović i dr., 2019a.). Iako nije često korišten u drugim istraživanjima (Tabl. 11.), ASP je zbog specifičnih mikrolokacijskih reljefnih značajki otoka Paga vrlo bitan za modeliranje podložnosti eroziji tla. U prvom redu te specifične mikrolokacijske značajke su vezane za izraženi utjecaj sjeveroistočnog vjetra bure na onemogućavanje razvoja značajnijeg vegetacijskog pokrova i oblikovanje ogoljenog krškog krajolika (Domazetović i dr., 2019a). Zbog erozivnog utjecaja bure i posljedično slabo razvijenog vegetacijskog pokrova najveća podložnost eroziji tla na prostoru otoka Paga je na sjevernim i sjeveroistočnim te na istočnim padinama koje obuhvaćaju ukupno oko 25 % površine otoka (72.66 km^2) (Tabl. 30.). Znatno manji utjecaj bure je na padinama od jugozapadne do zapadne orijentacije, koje su dijelom zaklonjene od erozivnog djelovanja vjetra. Padine ove orijentacije obuhvaćaju oko 55% površine otoka, unutar kojega su i jedini pošumljeni dijelovi otoka.

Tablica 30. Zastupljenost klasa ASP s pripadajućim standardiziranim vrijednostima

ASP	S	SI	I	JI
Površina (km²)	4.63	27.36	40.67	23.91
Udio	1.63	9.61	14.28	8.40
Referentni uzorci	7	6	6	4
Referentni uzorci (%)	18.42	15.79	15.79	10.53
Težinski koeficijent	5	5	4	3
ASP	J	JZ	Z	SZ
Površina (km²)	17.81	38.62	76.84	34.20

Udio	6.25	13.56	26.98	12.01
Referentni uzorci	3	4	3	5
Referentni uzorci (%)	7.89	10.53	7.89	13.16
Težinski koeficijent	3	3	3	4

Profilna (PROF) i planarna (PLAN) zakrivljenost padine utječu na brzinu, te na konvergenciju i divergenciju površinskog otjecanja (Domazetović i dr., 2019a), zbog čega se ova dva kriterija često koriste pri modeliranju podložnosti eroziji tla (Agnesi i dr., 2011; Conoscenti i dr., 2014; Dewitte i dr., 2015). Općenito, neovisno o tipu zakrivljenosti padine (PROF, PLAN) konkavne padine su podložnije eroziji tla, jer unutar njih dolazi do ubrzanja i konvergencije površinskog otjecanja, zbog čega su prilikom standardizacije najveće ocjene i dodijeljene ovakvim padinama. Zastupljenost konkavnih i konveksnih padina unutar otoka Paga je za PROF i PLAN poprilično ujednačena (Tabl. 31. i 31.).

Tablica 31. Zastupljenost klasa PROF s pripadajućim standardiziranim vrijednostima

PROF	Konkavne	Zaravnjene	Konveksne
Površina (km²)	127.50	31.47	125.80
Udio	44.77	11.05	44.18
Referentni uzorci	28	2	8
Referentni uzorci (%)	73.68	5.26	21.05
Težinski koeficijent	5.00	1.00	3.00

Tablica 32. Zastupljenost klasa PLAN s pripadajućim standardiziranim vrijednostima

PLAN	Konkavne	Zaravnjene	Konveksne
Površina (km²)	131.60	6.70	146.48
Udio	46.21	2.35	51.44
Referentni uzorci	32	0	6
Referentni uzorci (%)	84.21	0	15.79
Težinski koeficijent	5.00	1.00	3.00

Kriterij Indeks ravnoteže mase (MBI) predstavlja funkciju nagiba padine i vertikalne udaljenosti od drenažne mreže, a koristi se za utvrđivanje područja prevladavajućeg procesa trošenja ili akumuliranja materijala (Möller i dr., 2008). Pri tome su niže vrijednosti ovog kriterija vezane za udubljenja u terenu, poput jaruga, zbog čega su prilikom standardizacije kriterija (Tabl. 33.) njima dodijeljene veće ocjene.

Tablica 33. Zastupljenost klasa MBI s pripadajućim standardiziranim vrijednostima

MBI	1	2	3	4	5
Površina (km²)	34.71	122.09	76.41	36.74	14.82
Udio	12.19	42.87	26.83	12.90	5.20
Referentni uzorci	32	4	1	1	0
Referentni uzorci (%)	84.21	10.53	2.63	2.63	0.00
Težinski koeficijent	5.00	4.00	3.00	2.00	1.00

Topografski indeks pozicije (TPI) je pokazatelj relativnog položaja padine u odnosu na zadano okružujuće susjedstvo, koji predstvlja predisponiranost određenog prostora za iniciranje erozije i akumulacije (Weiss, 2001; Wilson i Gallant, 2000; De Reu i dr., 2013; Conoscenti i dr., 2014). Niže vrijednosti ovog kriterija smatraju se pogodnijim za pojavu erozije, jer predstavljaju različita udubljenja u reljefu (npr. jaruge), dok veće vrijednosti predstavljaju različita uzvišenja. Zbog toga su prilikom standardizacije najveće ocjene dodijeljene najnižim vrijednostima TPI kriterija (Tabl. 34).

Tablica 34. Zastupljenost klasa TPI s pripadajućim standardiziranim vrijednostima

TPI	1	2	3	4	5
Površina (km²)	6.38	26.26	196.97	46.76	8.40
Udio	2.24	9.22	69.17	16.42	2.95
Referentni uzorci	28	6	4	0	0
Referentni uzorci (%)	73.68	15.79	10.53	0.00	0.00
Težinski koeficijent	5.00	4.00	3.00	2.00	1.00

Vertikalna raščlanjenost terena, odnosno TRI predstavlja posljednji kriterij iz grupe morfometrijskih kriterija, koji predstavlja mjeru nepravilnosti i varijabilnosti terena unutar određene površine (Amatulli i dr., 2018.). Dok niže vrijednosti TRI predstavljaju zaravnjenije prostore, manje vertikalne raščlanjenosti, više vrijednosti ovog kriterija karakteriziraju pretežito strme grebene i vršna područja velike vertikalne raščlanjenosti (Amatulli i dr., 2018). Na otoku Pagu prevladavaju područja vrlo niske i niske vertikalne raščlanjenosti, koji pokrivaju gotovo 90% površine otoka (Tabl. 35.). Značajnije vrijednosti vertikalne raščlanjenosti prisutne su unutar manjeg dijela otoka, prvenstveno na strmim padinama najvećih uzvišenja na otoku.

Tablica 35. Zastupljenost klasa TRI s pripadajućim standardiziranim vrijednostima

TRI	1	2	3	4	5
Površina (km²)	167.47	88.62	24.89	3.55	0.24
Udio	58.81	31.12	8.74	1.25	0.08
Referentni uzorci	5	24	9	0	0
Referentni uzorci (%)	13.16	63.16	23.68	0.00	0.00
Težinski koeficijent	3.00	5.00	4.00	2.00	1.00

Grupa hidroloških kriterija

Unutar grupe hidroloških kriterija svrstano je sljedećih sedam kriterija koji reprezentiraju hidrološke značajke prostora: topografski indeks vlažnosti (engl. *topographic wetness index* - TWI), indeks snage toka (engl. *stream power index* - SPI), LS faktor (engl. *lenght-slope* factor - LSF), vertikalna udaljenost od tokova (engl. *vertical distance to channel network* - VDC), veličina slivnog područja (engl. watershed - WAT), gustoća drenažne mreže (engl. *drainage* density - DD) te indeks konvergencije (engl. *convergence index* - CI). Prikaz prostorne distribucije klasa odabranih morfometrijskih kriterija dan je na slici 91.

Prvi kriterij unutar grupe hidroloških kriterija je topografski indeks vlažnosti (TWI), čije vrijednosti ukazuju na distribuciju zona povećane saturacije vodom (Beven i Kirkby, 1979, u Gómez-Gutiérrez i dr., 2015), gdje više vrijednosti TWI kriterija prevladavaju unutar različitih reljefnih depresija, odnosno prostora zasićenih vodom, poput jaruga i udolina, dok niže vrijednosti ovog kriterija pretežito prevladavaju na prostoru uzvišenja i grebena. Zastupljenost klasa TWI unutar otoka Paga dana je u tablici 36.

Tablica 36. Zastupljenost klasa TWI s pripadajućim standardiziranim vrijednostima

TWI	1	2	3	4	5
Površina (km²)	41.58	90.41	91.19	52.03	9.56
Udio	14.60	31.75	32.03	18.27	3.36
Referentni uzorci	1	4	7	11	15
Referentni uzorci (%)	2.63	10.53	18.42	28.95	39.47
Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

Sljedeći kriterij je indeks snage toga (SPI), koji predstavlja mjeru potencijalne erozivnosti površinskog otjecanja (Moore i dr., 1993, u Gómez-Gutiérrez i dr., 2015), gdje veće vrijednosti ovog indeksa odgovaraju prostorima veće potencijalne erozivnosti površinskog otjecanja. Zastupljenost klasa SPII unutar otoka Paga dana je u tablici 37.

Tablica 37. Zastupljenost klasa SPI s pripadajućim standardiziranim vrijednostima

SPI	1	2	3	4	5
Površina (km²)	40.10	67.01	96.51	64.22	16.93
Udio	14.08	23.53	33.89	22.55	5.95
Referentni uzorci	2	4	5	7	20
Referentni uzorci (%)	5.26	10.53	13.16	18.42	52.63
Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

LS faktor (LSF) predstavlja mjeru transportnog kapaciteta površinskog otjecanja određenog na temelju nagiba i duljine padine (Lal, 1988), koji je jedan od osnovnih parametara RUSLE pristupa određivanja intenziteta erozije (Panagos i dr., 2015c; 2015d). Veće vrijednosti LSF kriterija javljaju se na vertikalno raščlanjenijim i kompleksnijim dijelovima reljefa, dok niže se vrijednosti vežu za zaravnjene prostore niske energije reljefa. Zastupljenost klasa LSF unutar otoka Paga dana je u tablici 38.

Tablica 38. Zastupljenost klasa LSF s pripadajućim standardiziranim vrijednostima

LSF	1	2	3	4	5
Površina (km²)	180.90	61.95	20.98	14.92	6.02
Udio	63.52	21.75	7.37	5.24	2.11
Referentni uzorci	3	1	5	17	12
Referentni uzorci (%)	7.89	2.63	13.16	44.74	31.58
Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

Vrijednosti vertikalne udaljenosti od tokova (VDC) kriterija ukazuju na vertikalnu udaljenost pojedinog piksela od zadane drenažne mreže, pri čemu se najveći dio otoka Paga (oko 65 %) nalazi unutar prve klase ovog kriterija, koja predstavlja prostore neposredno uz samu drenažnu mrežu, dok udio ostalih klasa postepeno opada (Tabl. 39.). Najmanja zastupljenost klasa s visokim vrijednostima VDC kriterija (4 i 5) ukazuje da značajno vertikalno udaljena od drenažne mreže uzvišenja obuhvaćaju vrlo mali dio otoka. S obzirom da je erozija tla vezana za drenažnu mrežu, klasama s nižim vrijednostima VDC dodijeljeni su veći težinski koeficijenti.

Tablica 39. Zastupljenost klasa VDC s pripadajućim standardiziranim vrijednostima

VDC	1	2	3	4	5
Površina (km²)	185.67	63.04	23.69	9.65	2.72
Udio	65.20	22.14	8.32	3.39	0.96
Referentni uzorci	36	2	0	0	0
Referentni uzorci (%)	94.74	5.26	0.00	0.00	0.00
Težinski koeficijent	5.00	4.00	3.00	2.00	1.00

Kriterij veličine slivnog područja (WAT) odnosi se na veličinu slivnog područja, pri čemu su brojna ranija istraživanja potvrdila da je upravo veličina slivnog područja uz nagib padina najvažniji predisponirajući kriterij za pojavu erozije tla (Vandekerckhove i dr., 2000; Valentin i dr., 2005). Veća slivna područja generalno imaju i veći potencijal za generiranje izraženijeg površinskog otjecanja, zbog čega je i vjerojatnost za pojavu erozije tla veća nego u slučaju manjih slivova. Zastupljenost klasa WAT unutar otoka Paga dana je u tablici 40.

Tablica 40. Zastupljenost klasa WAT s pripadajućim standardiziranim vrijednostima

WAT	1	2	3	4	5
Površina (km²)	171.08	50.53	26.04	20.32	16.81
Udio	60.07	17.74	9.14	7.13	5.90
Referentni uzorci	0.00	4.00	4.00	5.00	25.00
Referentni uzorci (%)	0.00	10.53	10.53	13.16	65.79
Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

Kriterij gustoće drenažne mreže (DD) odnosi se na gustoću drenažne mreže, pri čemu veće vrijednosti ovog indeksa reprezentiraju prostore s većom gustoćom drenažne mreže, pretežito vezane za veća slivna područja i udubljenja u reljefu. Veća gustoća drenažne mreže također se može povezati s većim potencijalom za generiranje površinskog otjecanja s dovoljnom energijom za iniciranje erozije tla. Zastupljenost klasa DD unutar otoka Paga dana je u tablici 41.

Tablica 41. Zastupljenost klasa DD s pripadajućim standardiziranim vrijednostima

DD	1	2	3	4	5
Površina (km²)	185.67	63.04	23.69	9.65	2.72
Udio	65.20	22.14	8.32	3.39	0.96
Referentni uzorci	0	8	7	14	9
Referentni uzorci (%)	0.00	21.05	18.42	36.84	23.68

Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

CI, odnosno indeks konvergencije je zadnji kriterij iz grupe hidroloških kriterija, koji ukazuje na reljefom uzrokovanu konvergenciju površinskog otjecanja (Thommeret i dr., 2009). Više vrijednosti ovog indeksa vezane su za prostore divergencije površinskog otjecanja, odnosno grebene i uzvišenja, dok niže vrijednosti predstavljaju udubljenja, poput jaruga, unutar kojih dolazi do konvergencije otjecanja. Zastupljenost klasa CI unutar otoka Paga dana je u tablici 42.

Tablica 42. Zastupljenost klasa CI s pripadajućim standardiziranim vrijednostima

CI	1	2	3	4	5
Površina (km²)	0.58	10.55	247.55	25.57	0.52
Udio	0.20	3.71	86.93	8.98	0.18
Referentni uzorci	7	16	14	1	0
Referentni uzorci (%)	18.42	42.11	36.84	2.63	0.00
Težinski koeficijent	3.00	5.00	4.00	2.00	1.00

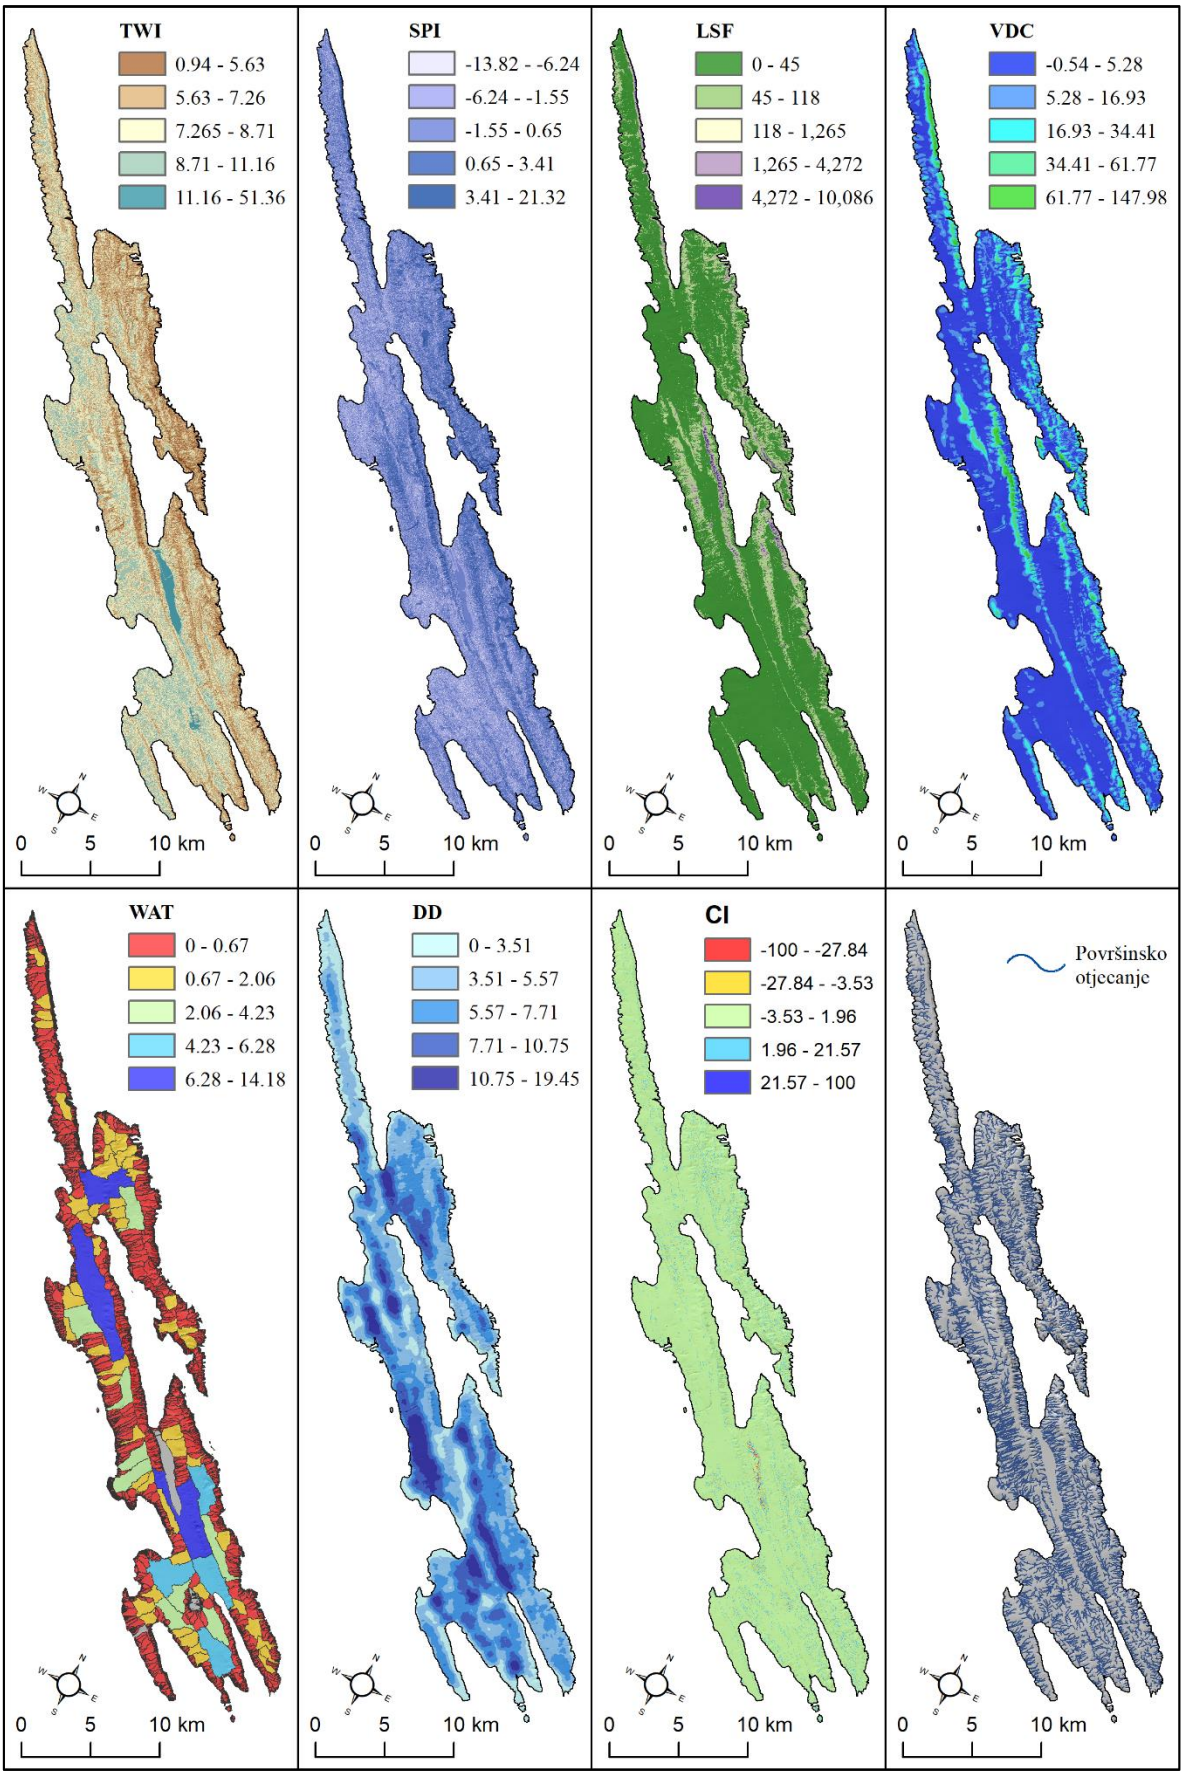

Slika 91. Grupa hidroloških kriterija GIS-MCDA podložnosti eroziji tla

Grupa ostalih kriterija

Unutar grupe ostalih kriterija svrstana su sljedeća tri kriterija generirana na temelju izrađenog WV-2 multispektralnog snimka otoka Paga: zemljišni pokrov (engl. *land cover* - LC), normalizirani indeks različitosti vegetacije (engl. *normalized difference vegetation index* - NDVI) te normalizirani indeks različitosti tla (engl. *normalized difference soil index* - NDSI). Prikaz prostorne distribucije klasa odabranih morfometrijskih kriterija dan je na slici 92.Prvi i najvažniji kriterij iz grupe ostalih kriterija je zemljišni pokrov (LC), koji je izdvojen nadziranom klasifikacijom na temelju pripremljenog multispektralnog WV-2 satelitskog snimka otoka Paga. Iz zastupljenosti pojedinih klasa zemljišnog pokrova vidljivo je da unutar Paga postoji značajna heterogenost različitih tipova zemljišnog pokrova, ali i da na značajnom dijelu otoka prevladavaju tipovi zemljišnog pokrova s oskudnim ili nikakvim vegetacijskim pokrovom (Tabl. 43). Naime, najzastupljenije takve klase na otoku su kamenjar (48.29 %), niski travnjak (17.95 %) te tlo (5.06 %). Među tipovima pokrova koji predstavljaju prostore s značajnije razvijenim vegetacijskim pokrovom treba istaknuti makiju i šume, koji zajedno prekrivaju oko 19 % površine otoka. Visoki travnjaci obuhvaćaju oko 5.79 % površine otoka. Preostala površina otoka prekrivena je zamočvarenim, urbanim i vodenim površinama, koje karakterizira vrlo slaba podložnost eroziji tla.

Tablica 43. Zastupljenost klasa LC s pripadajućim standardiziranim vrijednostima

LC	Kamenjar	Niski travnjak	Makija	Šuma	Tlo
Površina (km²)	137.52	51.13	20.51	33.71	14.41
Udio	48.29	17.95	7.20	11.84	5.06
Referentni uzorci	18	4	0	0	13
Referentni uzorci (%)	47.37	10.53	0.00	0.00	34.21
Težinski koeficijent	5	4	3	3	5
LC	Urbano	Visoki travnjak	Močvarno	Voda	
Površina (km²)	1.92	16.48	6.51	2.58	
Udio	0.67	5.79	2.29	0.91	
Referentni uzorci	0	3	0	0	
Referentni uzorci (%)	0.00	7.89	0.00	0.00	
Težinski koeficijent	1	4	2	1	

Sljedeći kriterij u grupi ostalih kriterija je normalizirani indeks različitosti vegetacije (NDVI), koji omogućava razdiobu prostora prekrivenih gustom i razvijenom vegetacijom od ogoljenih i eroziji tla izloženih prostora (Phinzi i Ngetar, 2017). Kao takav, NDVI se često koristi u modeliranju podložnosti eroziji tla (Tabl. 11.). Niže vrijednosti ovog indeksa predstavljaju ogoljene dijelove Zemljine površine, s nikakvim ili slabo razvijenim vegetacijskim pokrovom (npr. kamenjar, livade), dok više vrijednosti predstavljaju prostore s dobro razvijenim vegetacijskim pokrovom (npr. šume, grmlje, itd.). Zastupljenost klasa NDVI unutar otoka Paga dana je u tablici 44.

Tablica 44. Zastupljenost klasa NDVI s pripadajućim standardiziranim vrijednostima

NDVI	1	2	3	4	5
Površina (km²)	21.11	79.25	75.60	69.35	39.46
Udio	7.41	27.83	26.55	24.35	13.86
Referentni uzorci	11	15	7	4	1
Referentni uzorci (%)	28.95	39.47	18.42	10.53	2.63
Težinski koeficijent	5.00	4.00	3.00	2.00	1.00

Zadnji kriterij u ovoj grupi je normalizirani indeks različitosti tla (NDSI), indeks namijenjen lakšem izdvajanju ogoljenih površina i naslaga tla. Vrijednosti ovog indeksa suprotne su od vrijednosti NDVI indeksa, pri čemu više vrijednosti predstavljaju ogoljene površine, bez vegetacijskog pokrova. Zastupljenost klasa NDSI unutar otoka Paga dana je u tablici 45.

Tablica 45. Zastupljenost klasa NDSI s pripadajućim standardiziranim vrijednostima

NDSI	1	2	3	4	5
Površina (km²)	23.81	50.77	61.18	76.21	72.81
Udio	8.36	17.83	21.48	26.76	25.57
Referentni uzorci	0	2	8	11	17
Referentni uzorci (%)	0.00	5.26	21.05	28.95	44.74
Težinski koeficijent	1.00	2.00	3.00	4.00	5.00

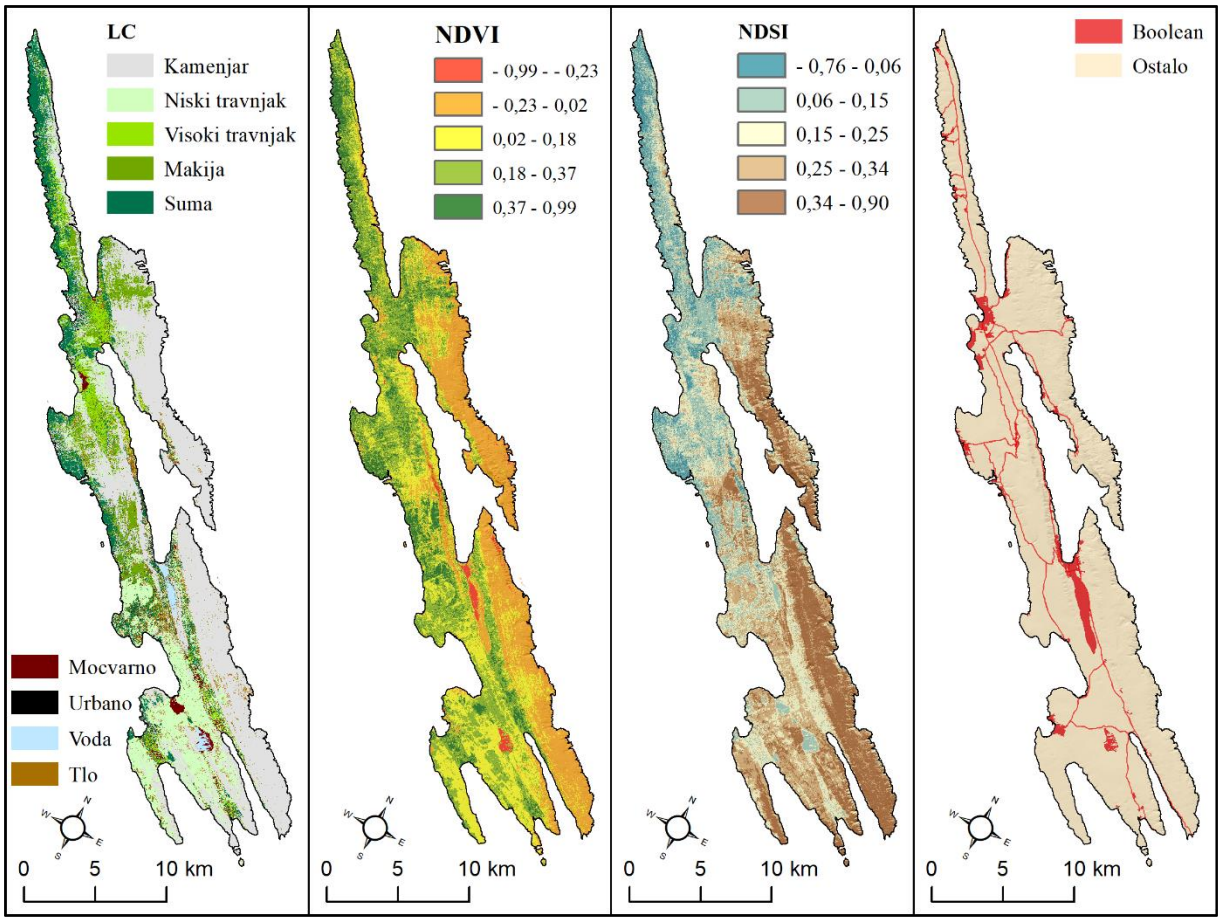

Slika 92. Grupa ostalih kriterija GIS-MCDA podložnosti eroziji tla i ograničavajući Boolean kriterij

Ograničavajući kriteriji

Ograničavajući Boolean kriterij obuhvaća sve urbane i vodene površine izdvojene metodom nadzirane klasifikacije iz WV-2 multispektralnog snimka (Sl. 92.). Pri tome u urbane površine spadaju svi stambeni i industrijski objekti, te sve asfaltirane prometnice. Ukupno Boolean kriterij obuhvaća površinu od oko 14.93 km^2, odnosno oko 5.25 % ukupne površine otoka.

Standardizirani kriteriji

Svi predisponirajući kriteriji standardizirani su na skalu 1 – 5, pri čemu su ocjene u procesu standardizacije usklađene s važnosti pojedinih klasa određenog kriterija. Ograničavajući Boolean kriterij standardiziran je na skalu 0 – 1. Prostorna distribucija standardiziranih kriterija vidljiva je na slikama 93., 94. i 95.

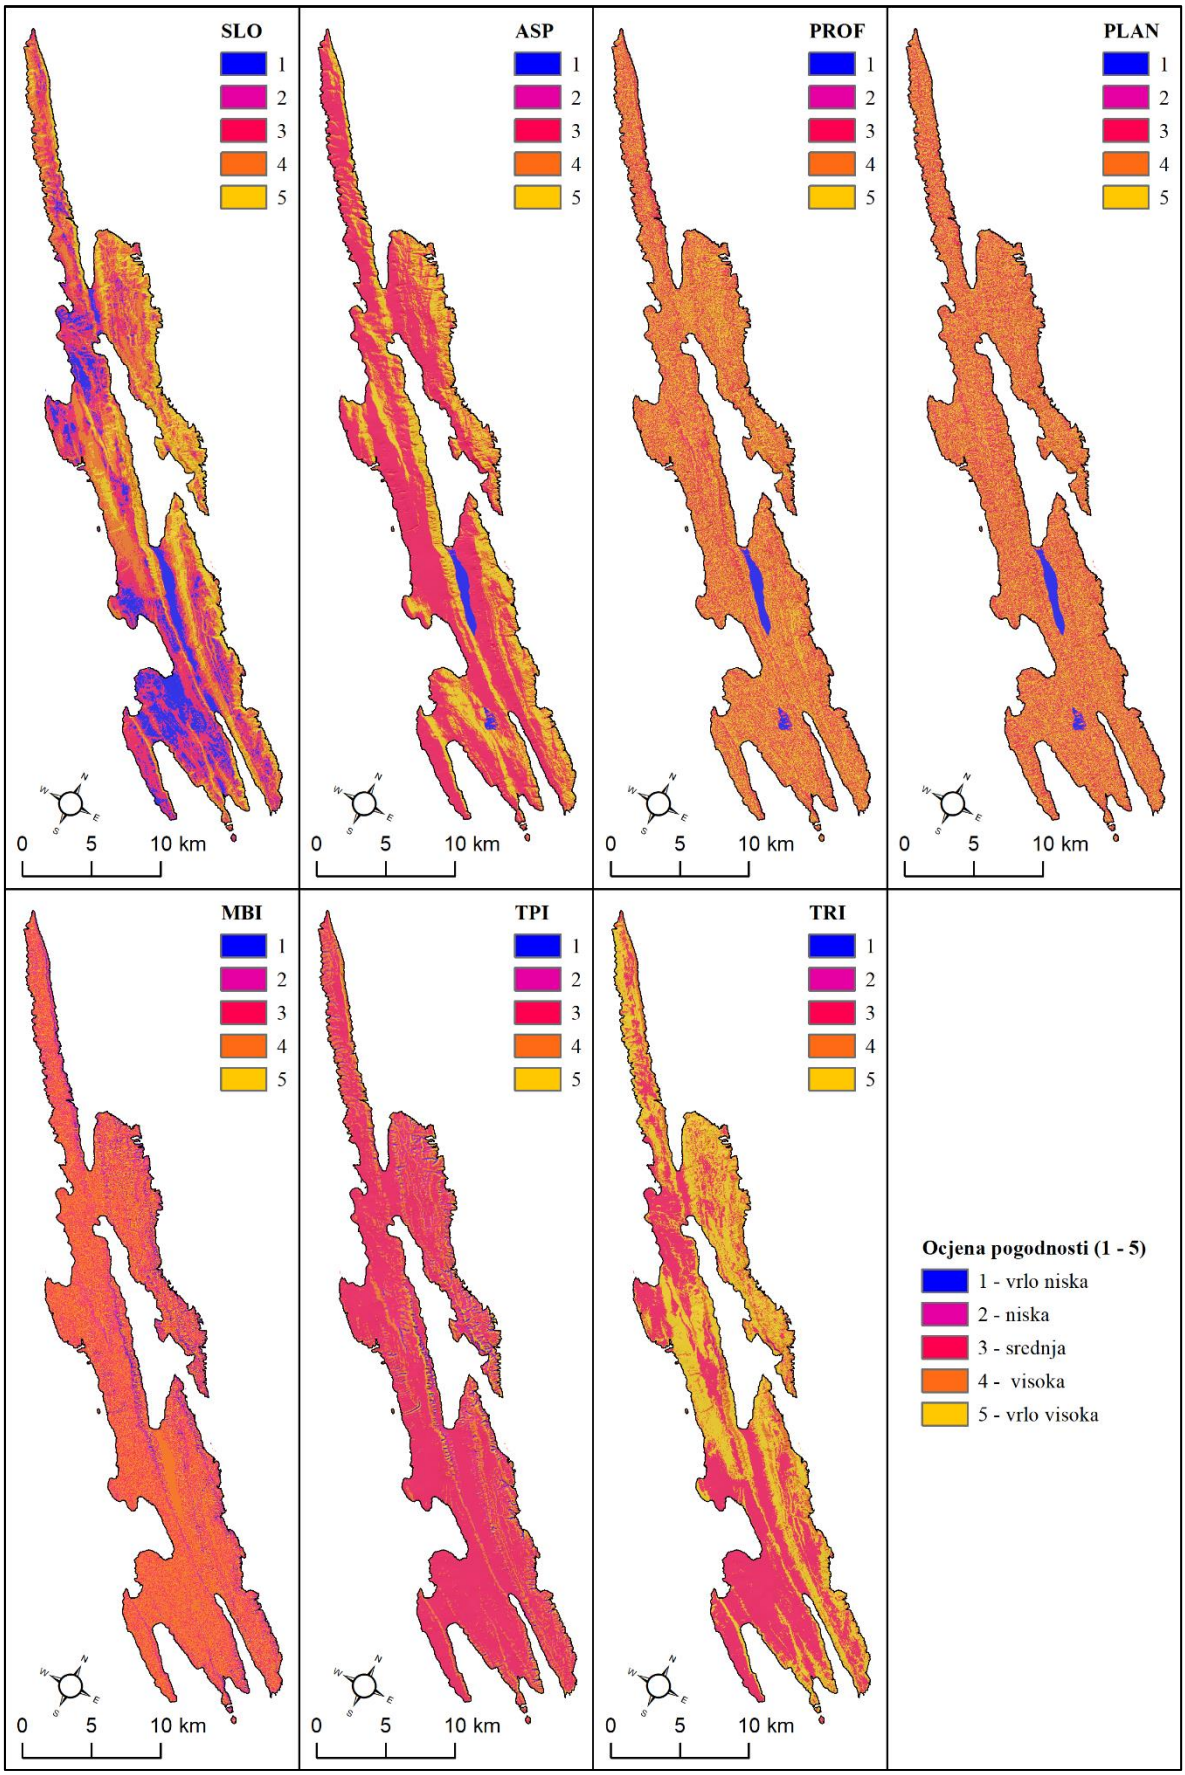

Slika 93. Standardizirani morfometrijski kriteriji GIS-MCDA podložnosti eroziji tla

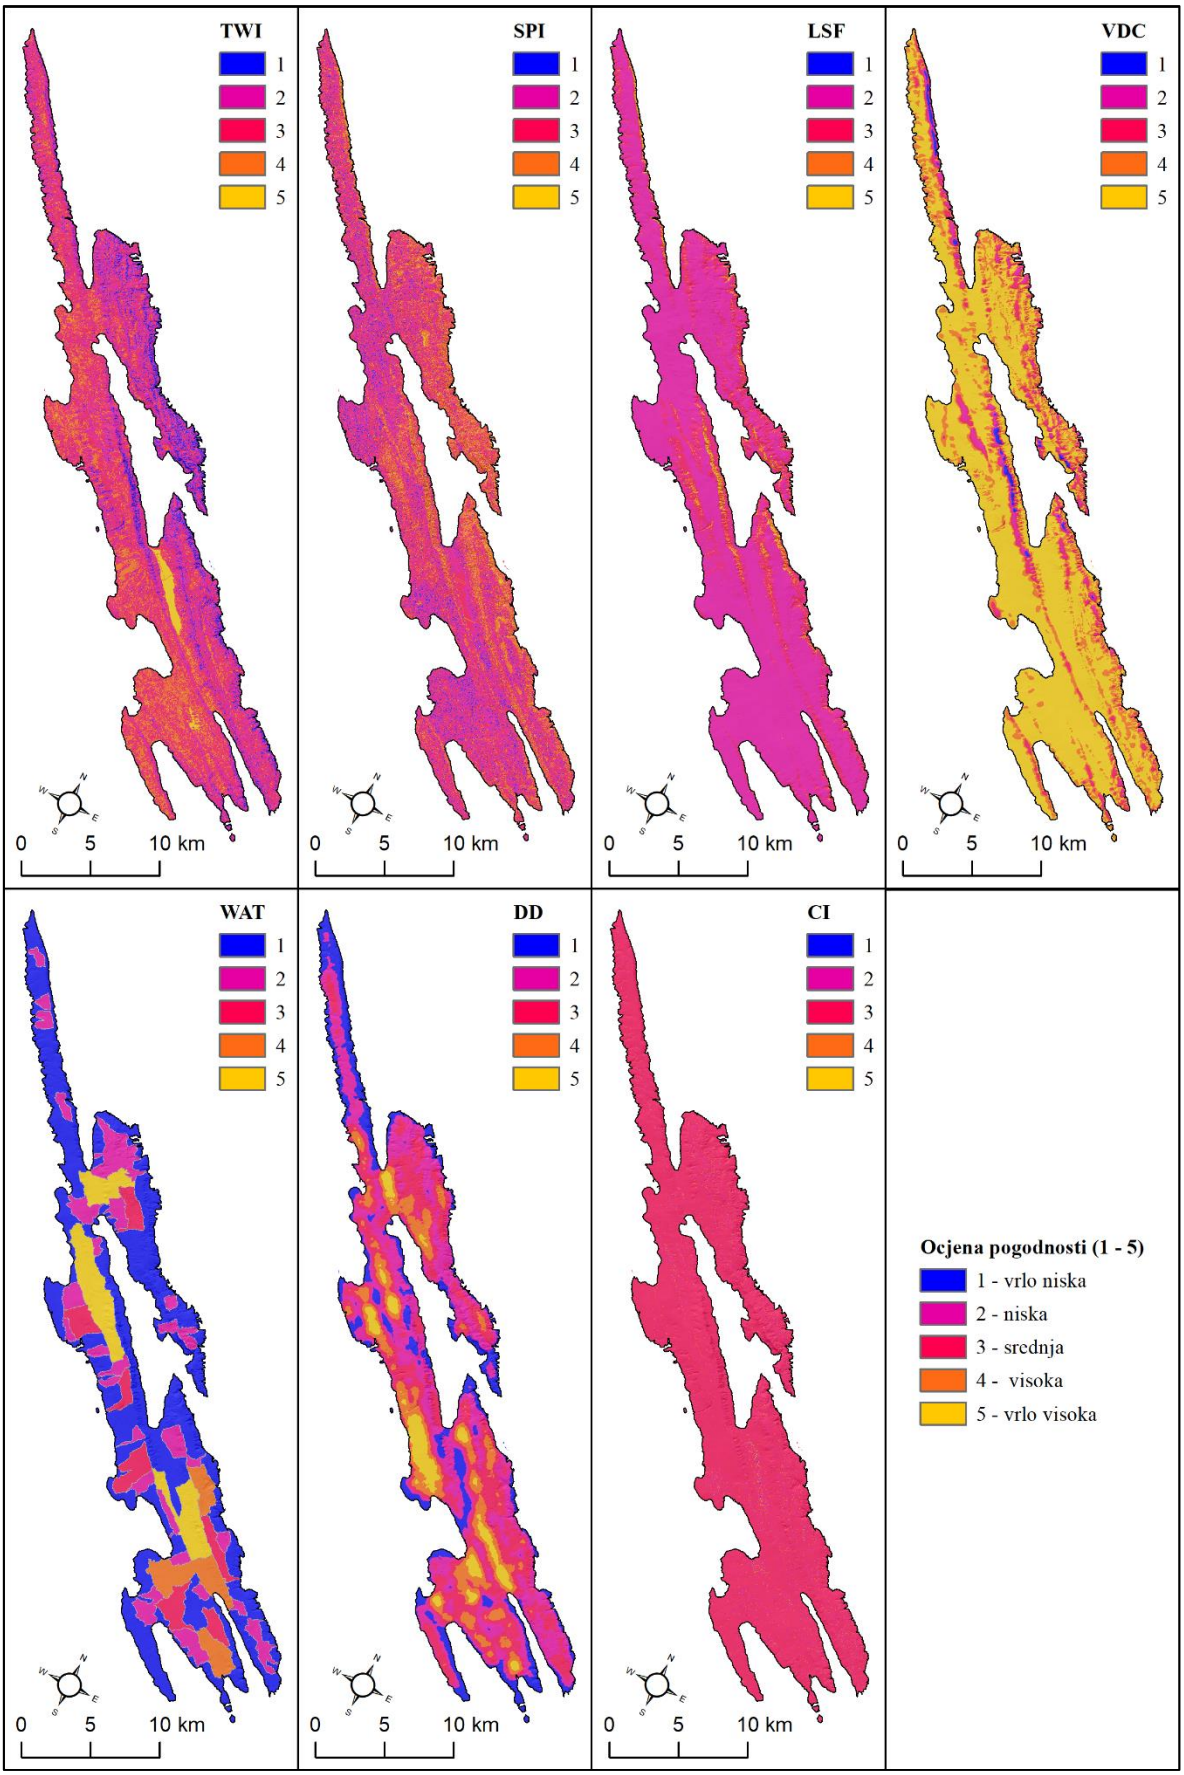

Slika 94. Standardizirani hidrološki kriteriji GIS-MCDA podložnosti eroziji tla

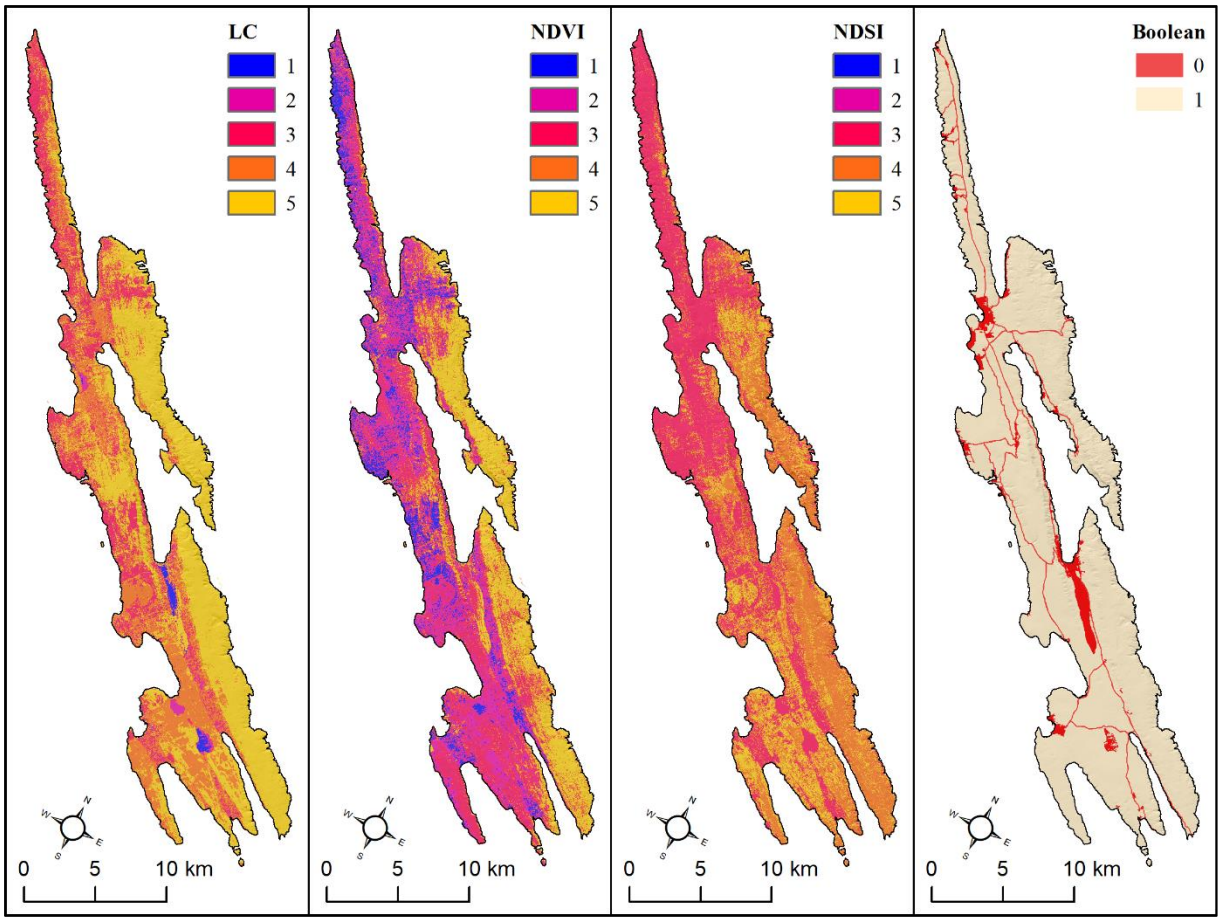

Slika 95. Standardizirani ostali kriteriji GIS-MCDA podložnosti eroziji tla

4.1.2. Rezultat validacije izrađenih GIC-MCDA modela

Na temelju odabranih i grupiranih kriterija te težinskih koeficijenata dodijeljenih kroz AHP izrađena su ukupno četiri različita modela podložnosti eroziji tla otoka Paga (Sl. 97.). Prva razina rangiranja obuhvatila je međusobno hijerarhijsko rangiranje kriterija unutar tri odabrane grupe kriterija, na temelju čega su napravljeni rasterski modeli koji reprezentiraju grupe morfometrijskih (Sl. 96.A), hidroloških (Sl. 96.B) i ostalih kriterija (Sl. 96.C).

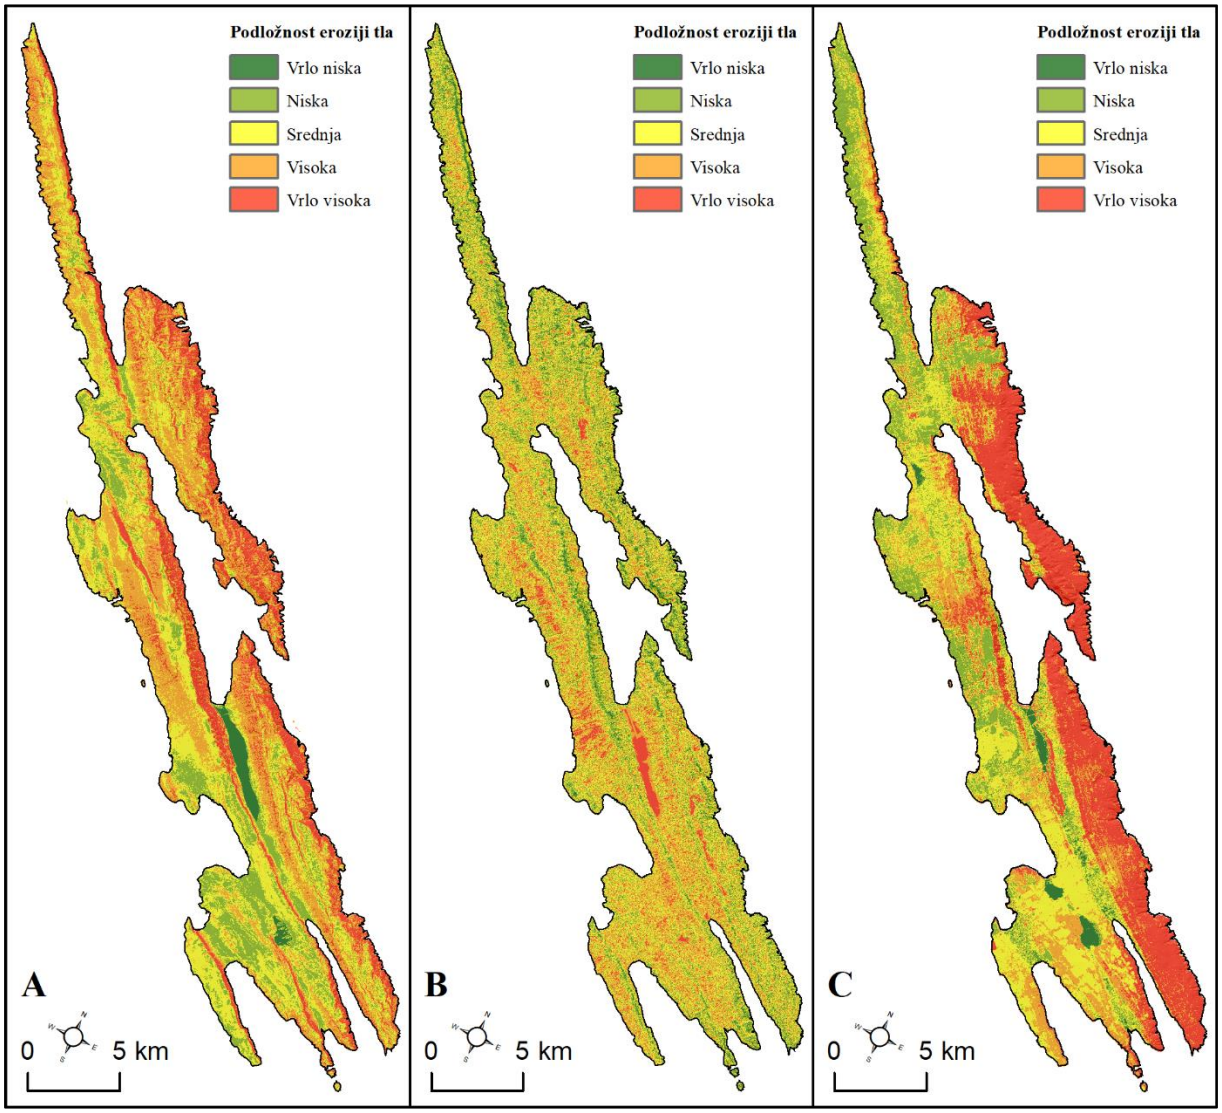

Slika 96. Rasterski modeli grupe morfometrijskih (A), hidroloških (B) i ostalih (C) kriterija[34]

Osim što su kriteriji uz pomoć AHP-a rangirani unutar tri odabrane grupe kriterija, primijenjeno je i dodatno rangiranje prilikom agregiranja izrađenih rasterskih modela morfometrijske, hidrološke i ostale grupe kriterija (Tabl. 18). Provedeno rangiranje grupa

[34] Rasterskim modelima nije pridružen ograničavajući Boolean kriterij, zbog čega su određene vrijednosti podložnosti prisutne i unutar ogrničavajućih prostora, poput urbanih i vodenih površina.

kriterija dovelo je do značajne heterogenosti izrađenih modela podložnosti, pri čemu je razlika u prostornoj distribuciji i zastupljenosti pojedinih klasa podložnosti kod izrađenih modela vidljiva i iz vizualne usporedbe modela (Sl. 97).

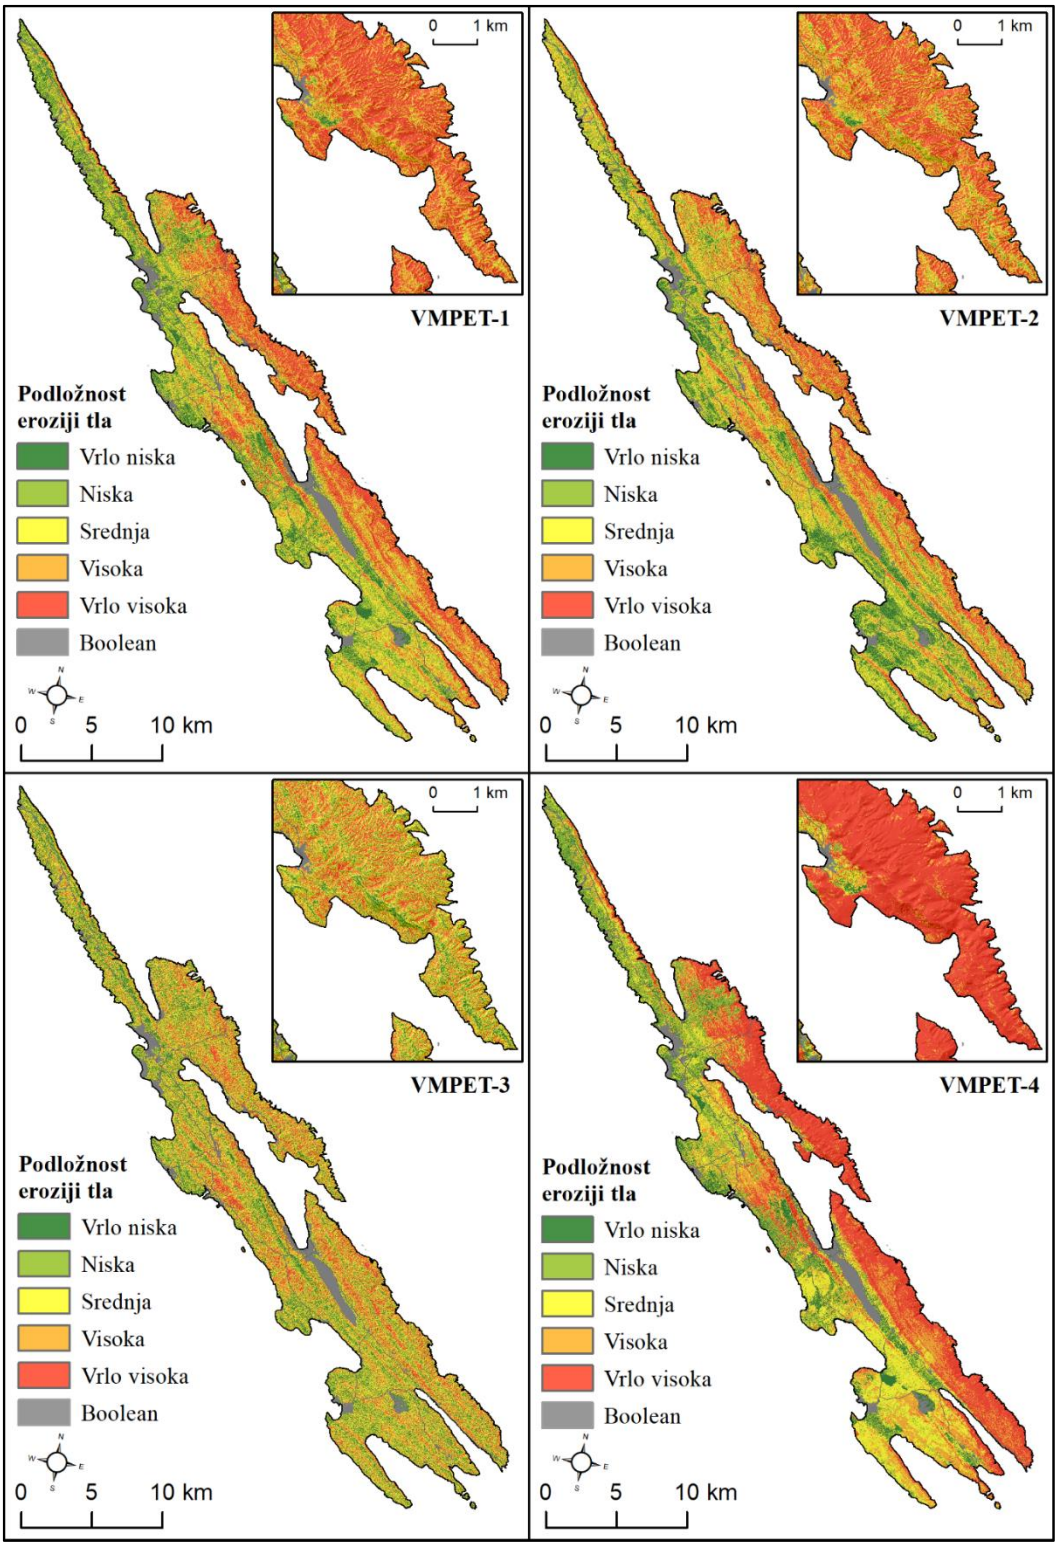

Slika 97. Izrađeni GIS-MCDA modeli podložnosti eroziji tla

Prvi izrađeni model je VMPET-1, kod kojega je jednaka važnost, odnosno težinski koeficijent (0.33) dodijeljen svim grupama kriterija (Tabl. 18.). Ovakav princip ujednačenog rangiranja različitih grupa kriterija primijenjen je u sklopu ranijih istraživanja vezanih za modeliranje podložnosti jaruženju, pri čemu je najbolji izrađeni model podložnosti postigao zadovoljavajuću razinu točnosti (AUC = 0.89) (Domazetović i dr., 2019a). Za razliku od navedenog ranijeg istraživanja, u sklopu ovog istraživanja ukupan broj kriterija korištenih prilikom izrade modela podložnosti povećan je za gotovo 40 %[35]. Unatoč tome prostorna distribucija i zastupljenost klasa visoke i vrlo visoke podložnosti kod VMPET-1 modela ne odstupaju značajnije od ranije izrađenog modela. Vidljivo je da su zone visoke i vrlo visoke podložnosti eroziji tla uglavnom zastupljene unutar udubljenih i ogoljenih padina istočnih i sjeveroistočnih dijelova otoka Paga (Sl. 97.). Takva distribucija zona izražene podložnosti eroziji tla odraz je prvenstveno nagiba i orijentacije padina reprezentiranih u sklopu SLO i ASP kriterija iz grupe morfometrijskih kriterija, izraženog površinskog otjecanja reprezentiranog TWI i SPI kriterijima iz grupe hidroloških kriterija, ali i ogoljenim kamenjarom i naslagama tla reprezentiranim u sklopu LC kriterija iz grupe ostalih kriterija. Na temelju vizualne interpretacije VMPET-1 modela može se zaključiti da je prilikom njegove izrade prevelik značaj dodijeljen ostalim kriterijima, zbog čega su zone visoke i vrlo visoke podložnosti usko vezane za odgovarajuće klase zemljišnog pokrova (npr. *kamenjar, tlo, niski travnjak*).

Sljedeći izrađeni model je VMPET-2, kod kojega su za razliku od VMPET-1 modela prilikom agregiranja grupa kriterija primijenjeni različiti težinski koeficijenti (Tabl. 18.). Pri tome je kod VMPET-2 modela najveći težinski koeficijent (0.59) dodijeljen morfometrijskoj grupi kriterija, dok je smanjena važnost grupa hidroloških i ostalih kriterija. S obzirom da su upravo morfometrijski kriteriji prema mnogim istraživanjima najvažniji za modeliranje podložnosti eroziji tla (Conforti i dr., 2011; Arabameri i dr., 2019), pretpostavljeno je da će povećanjem važnosti ove grupe kriterija doći i do poboljšanja točnosti izrađenog GIS-MCDA modela u odnosu na VMPET-1 model.

Kod VMPET-3 modela najveća važnost (0.63) dodijeljena je hidrološkoj grupi kriterija, odnosno kriterijima povezanim s značajkama slivnih područja (WAT, LSF) i drenažne mreže (TWI, SPI, VDC, DD, CI) otoka Paga. Nakon hidrološke grupe kriterija sljedeća po važnosti je grupa morfometrijskih kriterija, dok je najmanja važnost dodijeljena grupi ostalih kriterija. Već

[35] U sklopu ranijih istraživanja korišteno je 10 predisponirajućih i 1 ograničavajući kriterij (Domazetović i dr., 2019a).

iz vizualne interpretacije VMPET-3 modela može se zaključiti da ovaj model u odnosu na prethodne modele poprilično podcjenjuje zastupljenost zona visoke i vrlo visoke podložnosti. Posebice je podcjenjivanje ovih zona u VMPET-3 modelu prisutno unutar brojnih dijelova otoka (npr. poluotok Metajna, poluotok Santiš, istočne padine Sv. Vida, itd.), gdje su u sklopu ranijih istraživanja zabilježeni učestali tragovi erozije tla (Domazetović, 2018; Domazetović i dr., 2019a).

U slučaju posljednjeg izrađenog VMPET-4 modela najveći težinski koeficijent dodijeljen je grupi ostalih kriterija (0.65), za kojom slijede morfometrijska, pa hidrološka grupa kriterija (Tabl. 18.). Zone visoke i vrlo visoke podložnosti su zbog težinskih koeficijenata dodijeljenih grupama kriterija u VMPET-4 modelu znatno preuveličane u odnosu na ranije pojašnjene modele. Sva tri kriterija iz grupe ostalih kriterija (LC, NDVI, NDSI) ističu ogoljene i izložene dijelove otoka (npr. kamenjar, tlo, niska vegetacija) u odnosu na dijelove otoka s razvijenijim vegetacijskim pokrovom. Zbog toga su klase visoke i vrlo visoke podložnosti eroziji tla preuveličane u VMPET-4 modelu unutar ogoljenih dijelova otoka, pri čemu je unutar ovih prostora gotovo u potpunosti poništen utjecaj morfometrijskih i hidroloških značajki.

Naglašene razlike u točnosti izrađenih modela podložnosti utvrđene vizualnom interpretacijom dodatno su potvrđene kroz izradu ROC krivulja i izračun AUC vrijednosti (Sl. 98.).

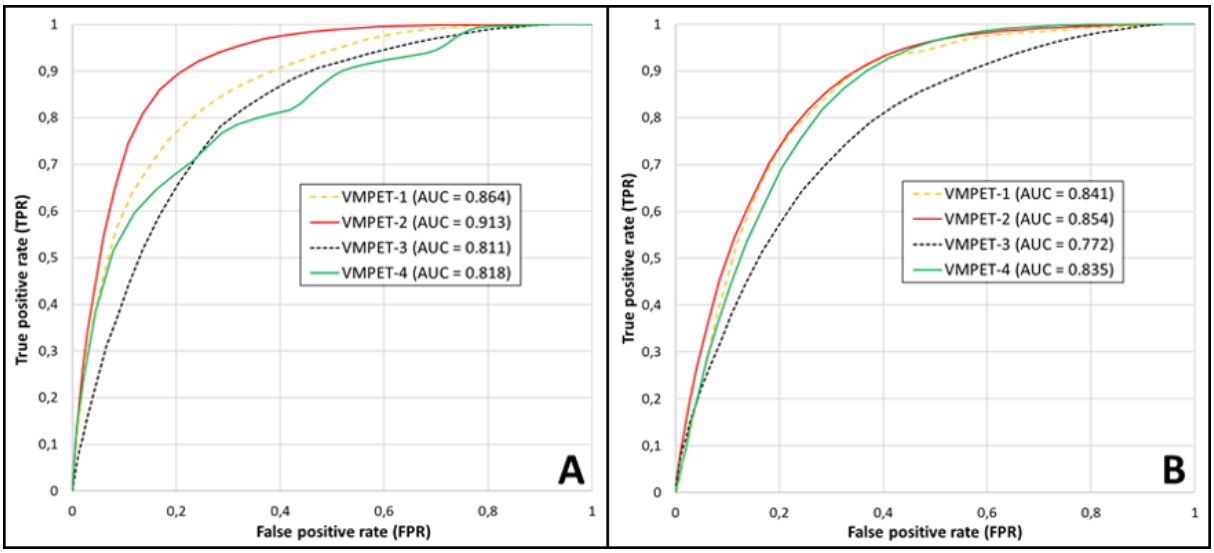

Slika 98. ROC krivulje izrađenih GIS-MCDA modela podložnosti eroziji tla napravljene na temelju referentnih erozijskih lokacija (A) i referentnih jaruga (B)

Prema ROC krivuljama i AUC vrijednostima izračunatim na temelju validacijskog seta podataka, kojega predstavlja 30% referentnih erozijskih lokacija tri modela podložnosti (VMPET-1, VMPET-3 i VMPET-4) mogu se svrstati u modele vrlo dobre kvalitete (0.8 – 0.9), dok najbolji model (VMPET-2) ima nešto više vrijednosti i zbog toga spada u modele odlične (> 0.9) kvalitete (Sl. 98). VMPET-2 model tako bilježi AUC vrijednost od 0.913, čime je potvrđeno da morfometrijska grupa kriterija ima najveću važnost za modeliranje podložnosti eroziji tla. Zbog toga je VMPET-2 model rezultirao boljom točnosti od modela ujednačenog značaja grupa kriterija (VMPET-1), ili naglašenijeg značaja grupe hidroloških (VMPET-3) ili ostalih (VMPET-4) kriterija.

Nakon VMPET-2 modela sljedeći model po vrijednostima AUC je VMPET-1 model (AUC = 0.864), kod kojega je jednaka važnost dodijeljena svim grupama kriterija (Sl. 98.). Niže vrijednosti AUC u odnosu na VMPET-2 model potvrđuju da prilikom izrade ovog modela nije dovoljna važnost pridodana morfometrijskim kriterijima, odnosno da grupa morfometrijskih kriterija treba imati veću važnost od preostale dvije grupe kriterija. Unatoč tome prema vrijednosti AUC VMPET-1 model spada među modele vrlo dobre kvalitete, što potvrđuje da se i jednakim vrednovanjem grupa kriterija može postići zadovoljavajuća točnost modela podložnosti. Iz ovakvih vrijednosti AUC proizlazi da je točnost modela veća, ukoliko se svim grupama pridoda jednaka važnost, u odnosu na modele kod kojih je veća važnost stavljena na grupu hidroloških (VMPET-3) ili ostalih kriterija (VMPET-4).

Nešto lošije vrijednosti AUC bilježi VMPET-4 model (AUC = 0.818), kod kojega je prevelika ovisnost zona podložnosti eroziji tla o prostornoj distribuciji pojedinih klasa LC kriterija dovela do smanjenja točnosti modela. Iako ovaj model po AUC vrijednosti spada među modele vrlo dobre kvalitete, prostorna distribucija i zastupljenost zona vrlo visoke podložnosti eroziji tla je zbog navedene prevelike ovisnosti o klasama LC kriterija znatno preuveličana. Posebice je to primjetno unutar klase kamenjara, koja obuhvaća oko 48 % otoka. Dok unutar ovog prostora u VMPET-4 modelu gotovo da nema drugih klasa osim klase vrlo visoke podložnosti, kod drugih modela (VMPET-1; 2; 3) vidljive su brojne manje zone klasa niže podložnosti. Ove zone slabije podložnosti vezane su za hidrološki i morfometrijski manje podložne prostore (npr. zaravnjeniji i ispupčeniji dijelovi sa slabim površinskim otjecanjem), koji su uslijed preuveličavanja podložnosti kod VMPET-4 gotovo u potpunosti generalizirane.

Najlošija točnost prema izrađenim ROC krivuljama zabilježena je kod VMPET-3 modela (AUC = 0.811). Ovako niska vrijednost AUC potvrđuje da iako su hidrološke značajke

bitne za modeliranje podložnosti, njihov značaj ne smije biti stavljen iznad morfometrijske grupe kriterija, jer dolazi do znatnog podcjenjivanja prostornog obuhvata zona visoke i vrlo visoke podložnosti.

Uz ROC krivulje, dodatnu potvrdu točnosti VMPET-2 modela pružio je uvid u zastupljenost klasa vrlo visoke podložnosti eroziji tla (klasa 5) unutar ukupne površine tampon zone od 15 m oko referentnih točkastih uzoraka. Naime, VMPET-2 model bilježi najveću zastupljenost klase vrlo visoke podložnosti u preko 86 % svih analiziranih uzoraka. Primjer jednog takvog uzorka unutar kojeg je zastupljenost klase vrlo visoke podložnosti najveća kod VMPET-2 modela dan je na slici 99.

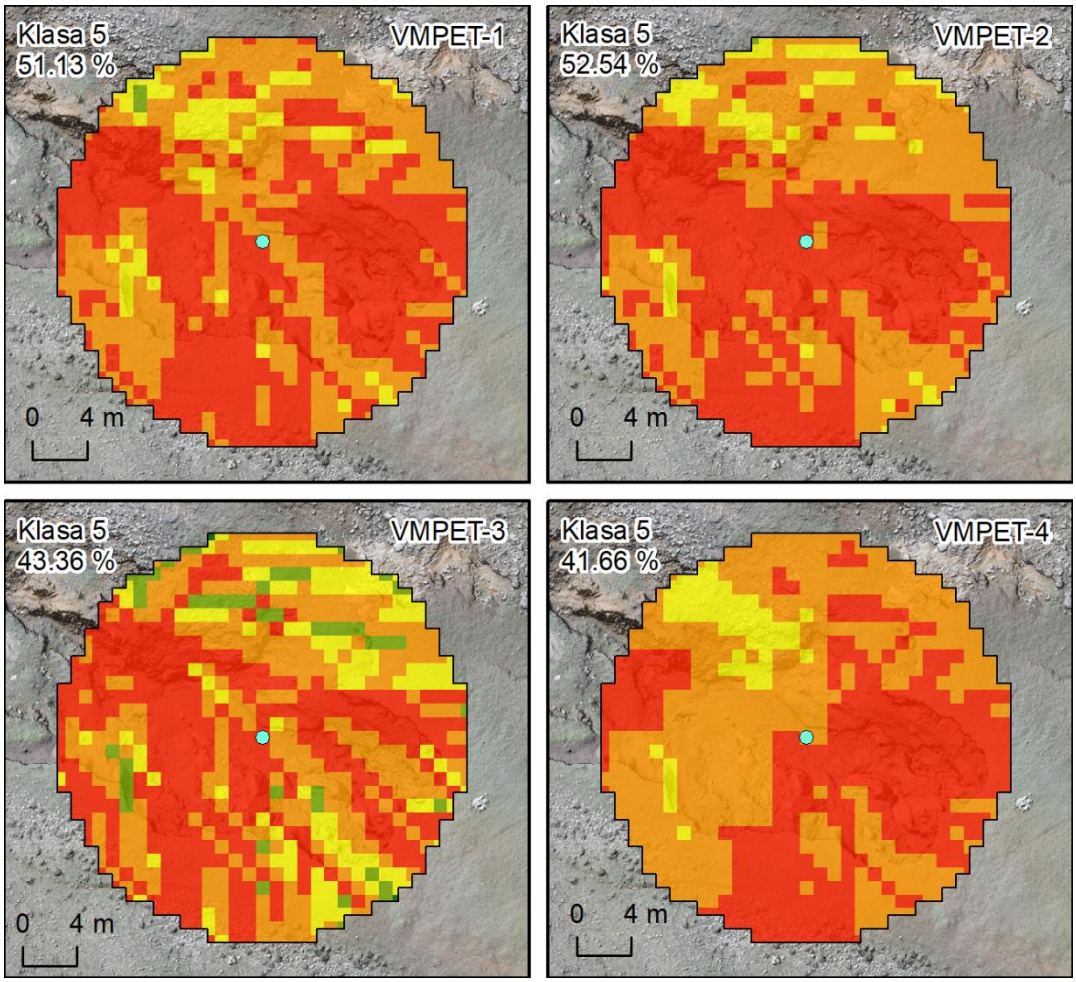

Slika 99. Udio klase vrlo visoke podložnosti eroziji tla unutar tampon zone uzorka br. 15 kod različitih izrađenih GIS-MCDA modela

Dodatna provjera točnosti izrađenih modela napravljena je na temelju 10 referentnih jaruga, koje su također korištene za validaciju modela u sklopu prethodnih istraživanja (Domazetović i dr., 2019a). Provjera točnosti na temelju referentnih 10 jaruga potvrdila je ranije

navedenu točnost modela, pri čemu ROC krivulje i izračunate AUC vrijednosti pojedinih modela podložnosti ipak u određenoj mjeri odudaraju od ranije iskazanih vrijednosti. Prema rezultatima ove validacije tri modela podložnosti spadaju u kategoriju modela vrlo dobre kvalitete (VMPET-1; VMPET-2 i VMPET-4), dok jedan model spada u modele dobre kvalitete (VMPET-3).

Ipak, AUC vrijednosti određene na temelju 10 referentnih jaruga su neznatno ispod AUC vrijednosti dobivenih u sklopu ranijih istraživanja (Domazetović i dr., 2019a). Uzrok tome je najvjerojatnije lošija prostorna rezolucija korištena za modeliranje u sklopu ranijeg istraživanja, zbog koje je došlo do generalizacije i preuveličavanja zona podložnosti. Naime, kao što su pokazala ranija istraživanja bolja prostorna rezolucije ne rezultira nužno boljim AUC vrijednostima (Gómez-Gutiérrez i dr., 2015). Izražena generalizacija zona podložnosti vidljiva je vizualnom usporedbom najboljeg modela podložnosti jaruženju (Sl. 100.) (Model 3 – Domazetović i dr., 2019) s najboljim modelom podložnosti eroziji tla (Sl. 101.). Iako se prostorna distribucija zone podložnosti generalno dobro poklapa, vidljivo je da je kod ranije izrađenog modela podložnosti jaruženju stupanja generalizacije daleko veći.

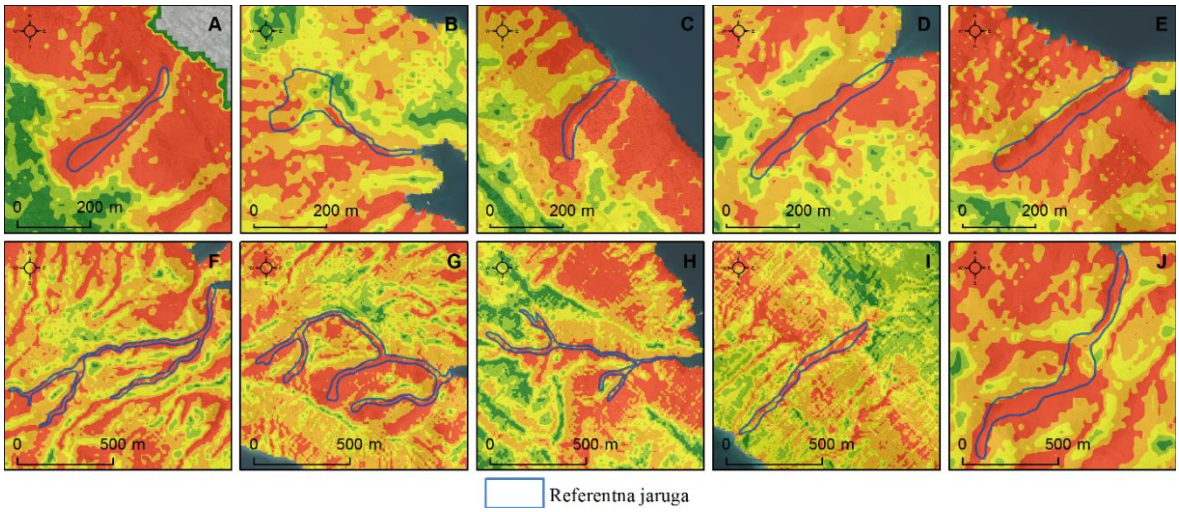

Slika 100. Vizualna usporedba različitih klasa podložnosti jaruženju (**Model 3**) s referentnim jarugama (preuzeto iz Domazetović i dr., 2019a)

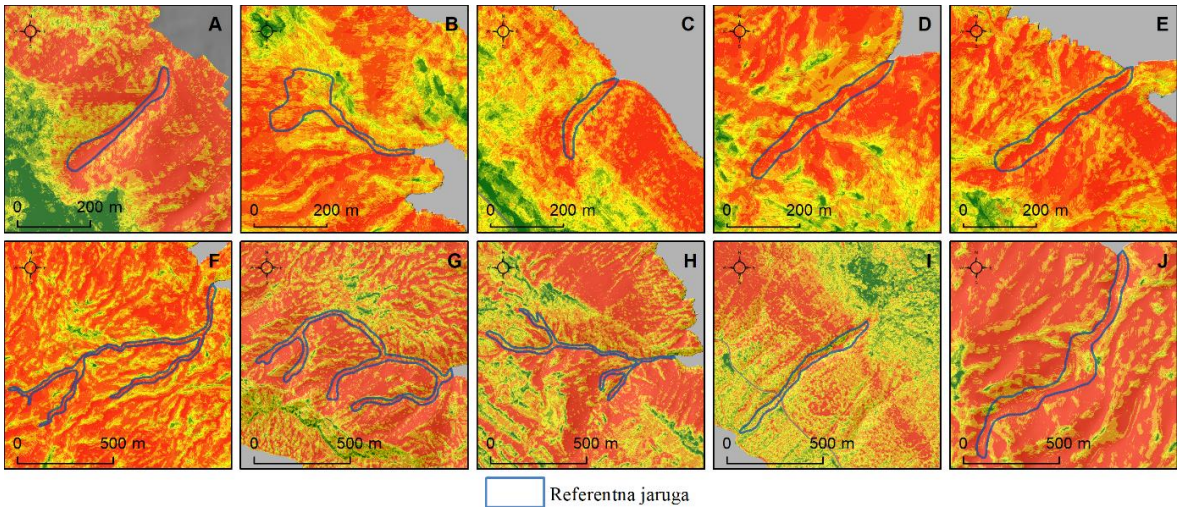

Slika 101. Vizualna usporedba različitih klasa podložnosti eroziji tla (**VMPET-2**) s referentnim jarugama

4.1.3. Utvrđena podložnost prostora otoka Paga eroziji tla

Prema konačnom izraženom modelu podložnosti (VMPET-2) oko 15 % ukupne površine otoka Paga (42 km^2) spada u klasu vrlo visoke podložnosti eroziji tla (Sl. 102; Tabl. 46.), dok klase visoke i vrlo visoke podložnosti zajedno obuhvaćaju gotovo 40 % površine otoka.

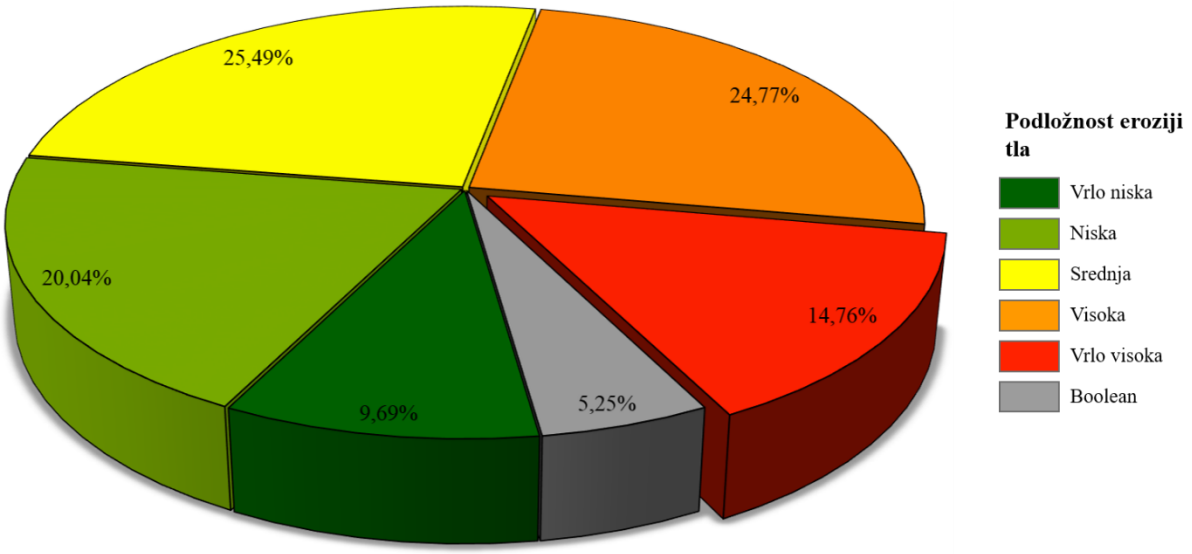

Slika 102. Udio klasa finalnog modela podložnosti eroziji tla u ukupnoj površini otoka Paga

Tablica 46. Zastupljenost pojedinih klasa izrađenog modela podložnosti eroziji tla

#	Klasa podložnosti	Površina klase (km^2)	Udio u ukupnoj površini otoka (%)
1	Boolean	14.93	5.25
2	Vrlo niska	27.57	9.69
3	Niska	57.02	20.04
4	Srednja	72.54	25.49
5	Visoka	70.47	24.77
6	Vrlo visoka	42.01	14.76

U odnosu na ranije izrađeni model podložnosti jaruženju (Domazetović i dr., 2019a), kod VMPET-2 modela podložnosti eroziji tla zone visoke i vrlo visoke podložnosti obuhvaćaju za oko 10 % veću površinu. Povećanje zastupljenosti klasa visoke i vrlo visoke podložnosti može biti i posljedica bolje prostorne rezolucije modela korištenih prilikom modeliranja podložnosti eroziji tla, ali i povećanja ukupnog broja kriterija i njihovog različitog rangiranja.

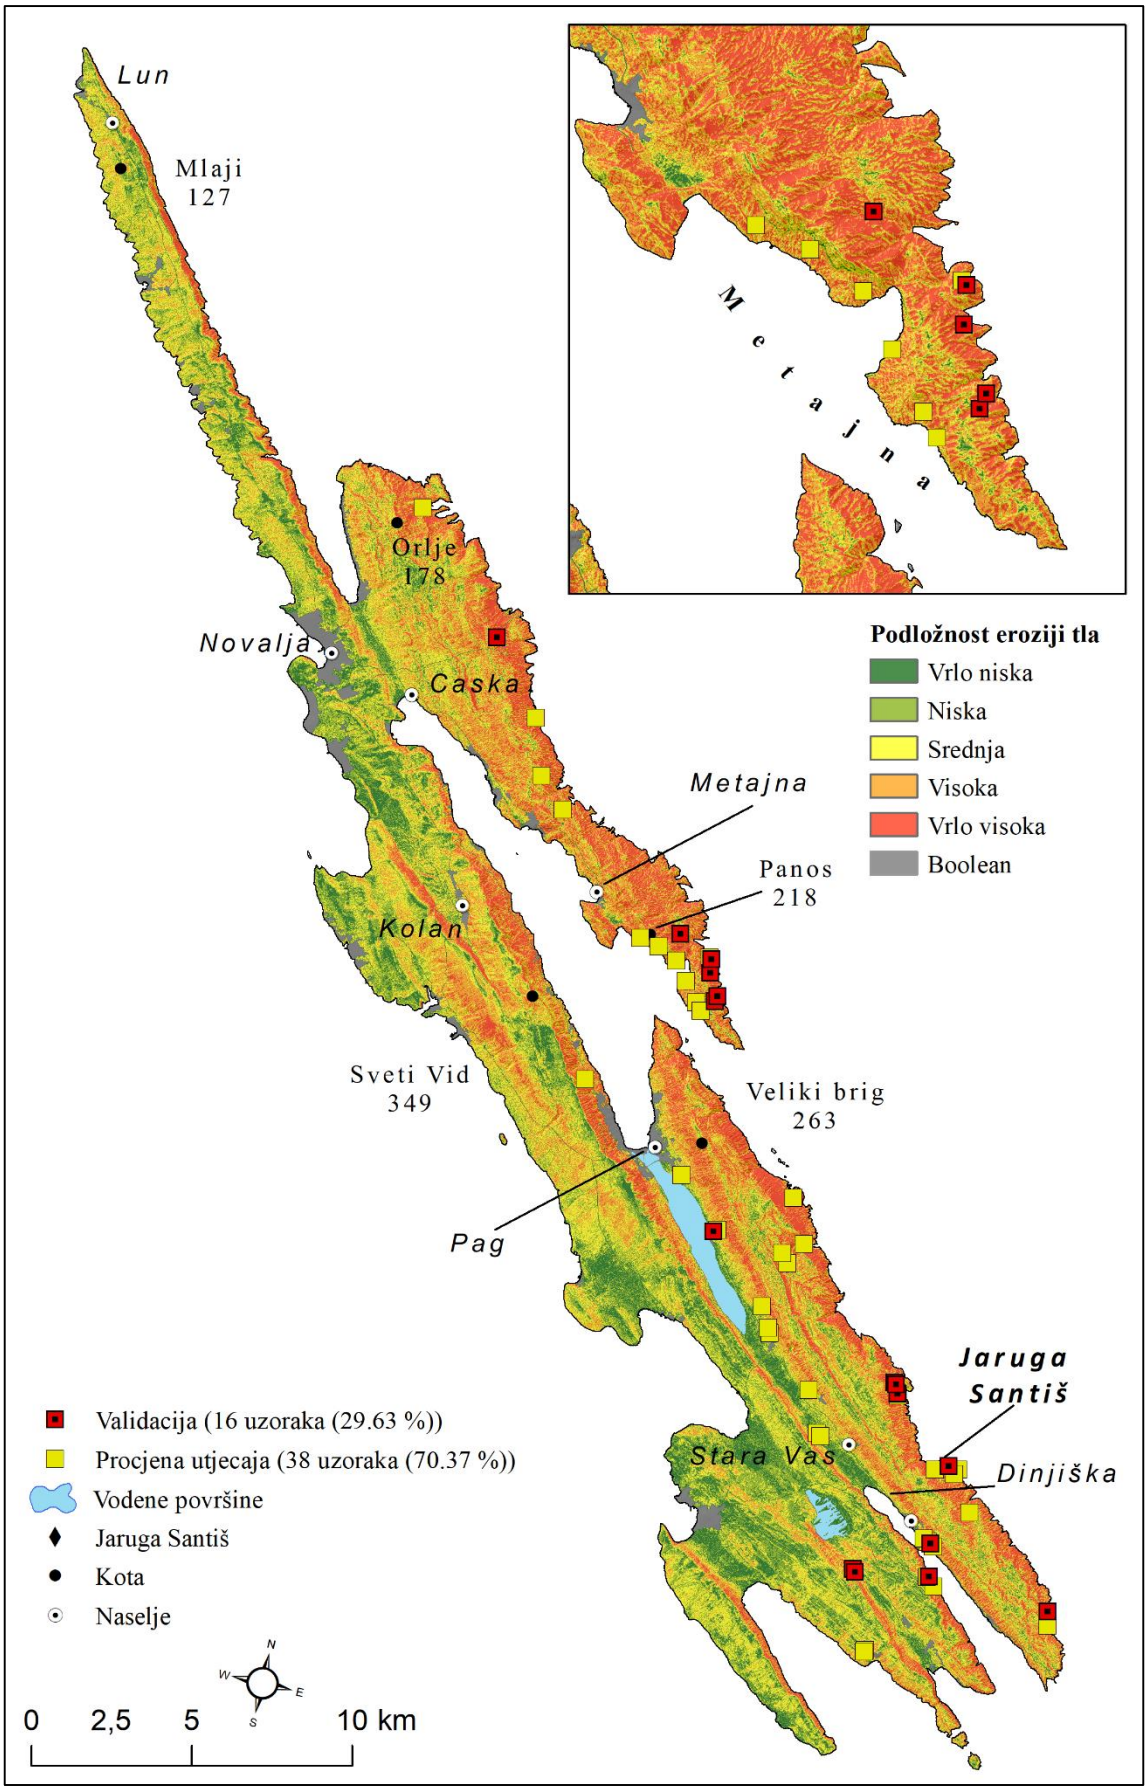

Slika 103. Finalni GIS-MCDA model podložnosti eroziji tla otoka Paga

Proces erozije tla osim jaruženja obuhvaća i brojne, obuhvatom i intenzitetom manje procese (vidi 2.1.2.), koji se mogu javiti i izvan jaruga (npr. EKK, spiranje, brazdanje), zbog čega je moguće da se različiti potprocesi erozije tla jave i izvan područja podložnih jaruženju.

Zone visoke i vrlo visoke podložnosti obuhvaćaju unutar otoka Paga pretežito strmije padine, sjeveroistočne i istočne orijentacije, gdje je zbog velikih strmina te utjecaja bure i oskudnije insolacije slabije razvijen vegetacijski pokrov. Zbog toga je zastupljenost klasa ovakve podložnosti osobito izražena u ogoljenim istočnim i sjeveroistočnim dijelovima otoka, uz Velebitski kanal, unutar kojih zbog djelovanja bure gotovo da i nema razvijenog vegetacijskog pokrova. Međutim, i unutar ovog prostora postoje značajne mikrolokacijski uvjetovane varijacije u podložnosti eroziji tla, ovisno o specifičnim morfološkim i drugim značajkama. Primjerice, dok zaravnjeni krški platoi i vršni dijelovi krških antiklinalnih uzvišenja bilježe slabiju podložnost eroziji tla, uzrokovanu slabijim površinskim otjecanjem, njihove strmije primorske padine bilježe znatno veću podložnost eroziji tla. Posebice je visoka podložnost na padinama jaruga i drugih reljefnih udubljenja povezanih s povremenim površinskim otjecanjem, što se najbolje očituje unutar poluotoka Metajna (Sl. 104.).

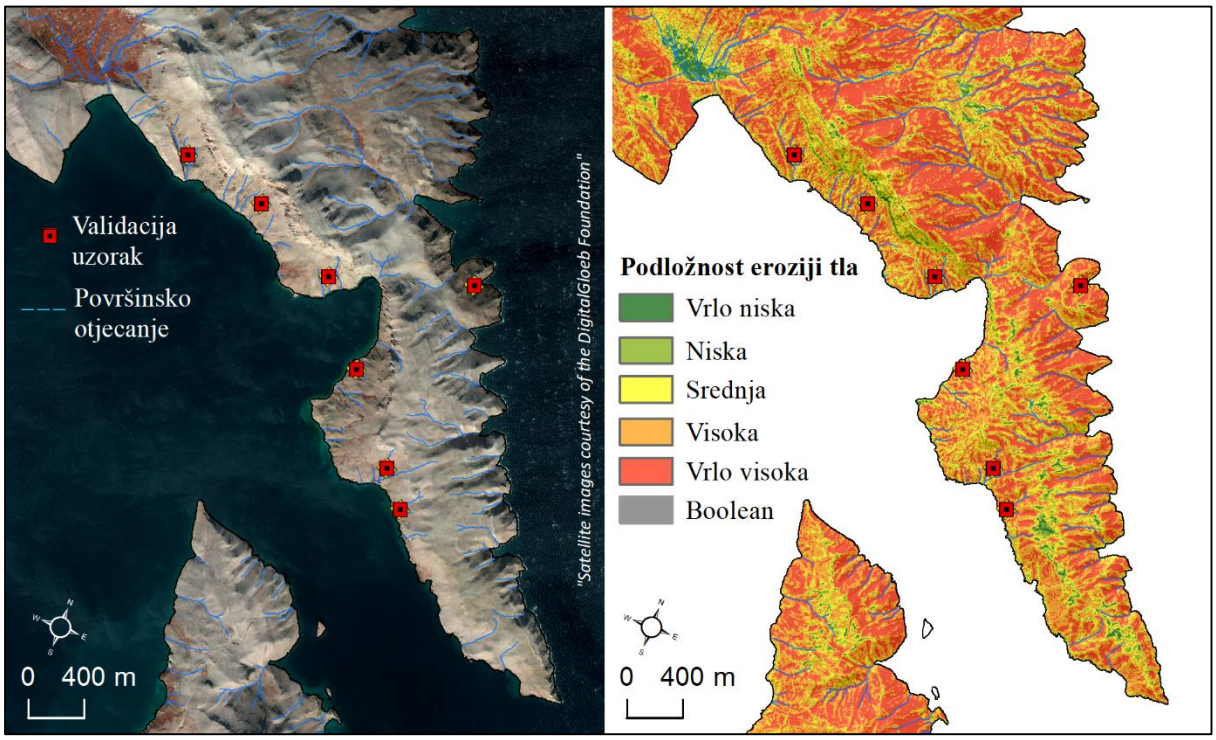

Slika 104. Prostorna distribucija zona vrlo visoke podložnosti eroziji tla unutar prostora poluotoka Metajna

Poluotok Metajna karakteriziraju brojne jaruge i drugi erozijski oblici, čija se prostorna distribucija (Sl. 104.) poklapa s generiranim zonama vrlo visoke podložnosti. Uz prostor vezan

za Velebitski kanal značajnija zastupljenost zona visoke i vrlo visoke podložnosti prisutna je i na istočnim padinama Svetog Vida, čije su strme padine ispresijecane brojnim jarugama.

Podudaranje zona visoke i vrlo visoke podložnosti s referentnim lokacijama na kojima su primijećeni tragovi erozije tla najbolje je vidljiva unutar prostora poluotoka Santiš, kao jednog od eroziji tla najpodložnijih dijelova otoka (Sl. 105.).

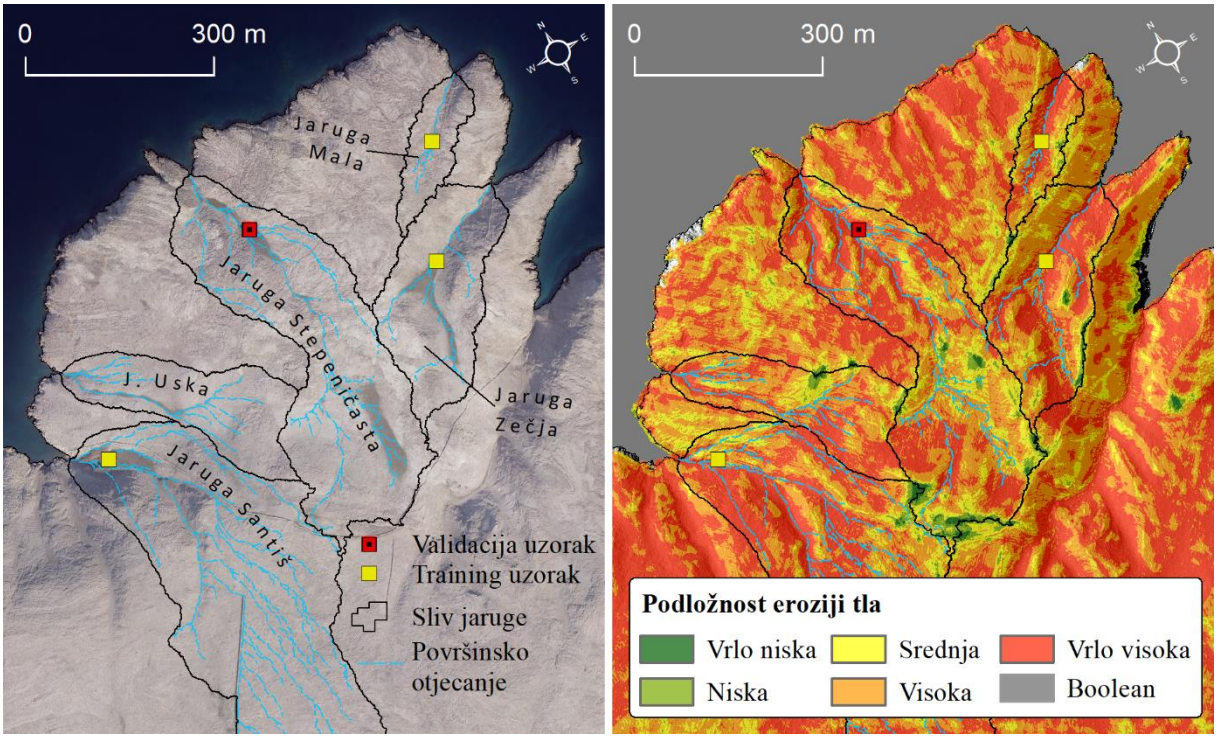

Slika 105. Prostorna distribucija zona vrlo visoke podložnosti u finalnom GIS-MCDA modelu podložnosti eroziji tla unutar prostora poluotoka Santiš

Zone vrlo visoke podložnosti eroziji tla prevladavaju unutar svih pet većih jaruga poluotoka Santiš, uključujući i prikupljene lokacije referentnih erozijskih uzoraka. Osim što se sva četiri referentna uzorka nalaze unutar zone vrlo visoke podložnosti, vidljivo je i generalno dobro podudaranje prostorne distribucije ove zone s reljefnim značajkama poluotoka. Naime, dok su klase visoke i vrlo visoke podložnosti pretežito prisutne unutar udubljenih jaruga i manjih usjeka, klase niže podložnosti su prisutne u središnjem dijelu poluotoka, te na rubnim dijelovima slivnih područja. Dok je prisutnost zona niže podložnosti u središnjem dijelu poluotoka odraz zaravnjenog krškog platoa, niže vrijednosti podložnosti na rubnim dijelovima slivnih područja vezane su za razvodnice tih slivova, odnosno manje grebene i uzvišenja koji ih dijele.

Područja srednje podložnosti eroziji tla predstavljaju prijelazne prostore iz zona visoke i vrlo visoke podložnosti, prema zonama niže podložnosti, koji pretežito obuhvaćaju padine

manjeg nagiba te područja s razvijenijim vegetacijskim pokrovom. S druge strane, zone niske i vrlo niske podložnosti pokrivaju oko 30 % površine otoka, te su pretežito vezane za zaravnjene dijelove otoka, poput Novaljsko-Paške flišne udoline, ili pak šireg prostora naselja Povljana, te prostora oko Malog i Velog blata (Sl. 106.). Unutar ovog prostora morfometrijske i hidrološke značajke, ali i razvijenost vegetacijskog pokrova onemogućavaju značajniju pojavu erozije tla.

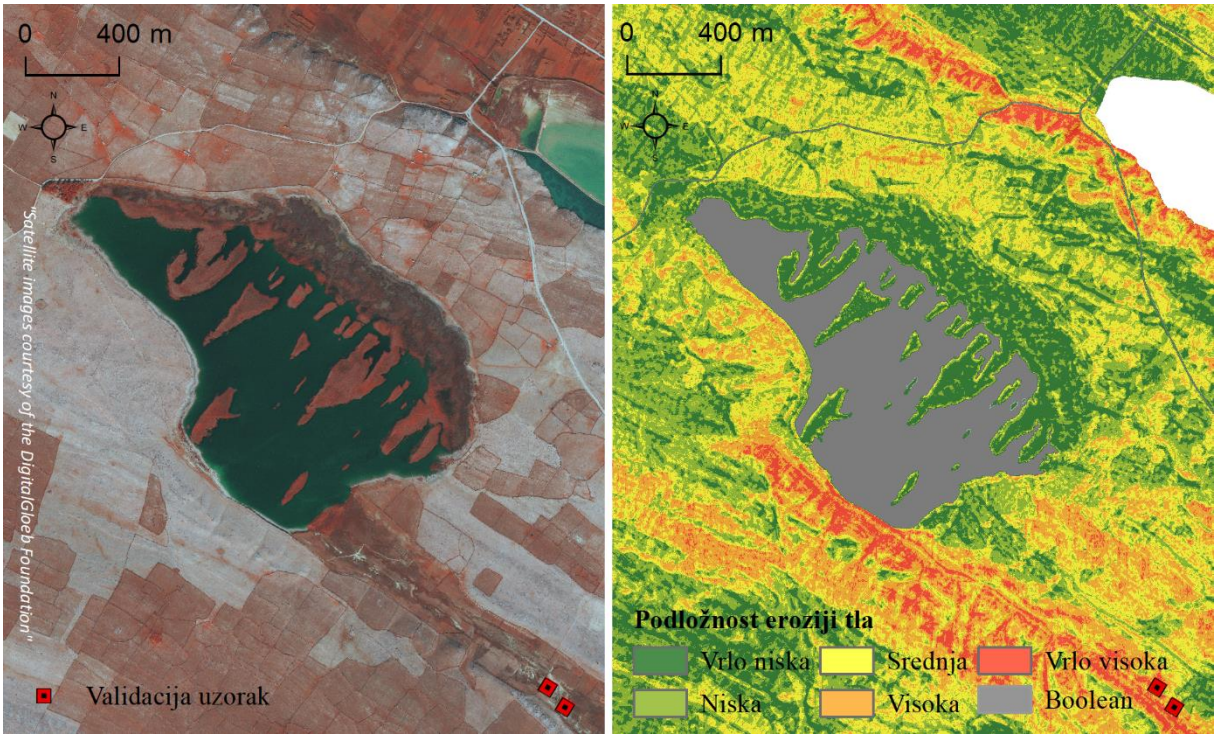

Slika 106. Prostorna distribucija zona vrlo visoke podložnosti u finalnom GIS-MCDA modelu podložnosti eroziji tla unutar prostora Velog blata

4.2. Rezultati mezo razine istraživanja

Rezultate mezo razine moguće je raščlaniti na rezultate usporedbe intervalnih modela izrađenih iz aerofotogrametrijskih snimaka Državne geodetske uprave (4.2.1.) te na rezultate usporedbe intervalnih modela testnog područja (jaruga Santiš) izrađenih iz aerofotogrametrijskih snimaka prikupljenih RAPS-om (4.2.2.). Dok rezultati usporedbe intervalnih DGU modela predstavljaju višegodišnje prostorno-vremenske promjene (DGU-1 - DGU-2 (2014.-2018.)) nastale na prostoru cijelog poluotoka Santiš, rezultati usporedbe intervalnih UAV modela predstavljaju jednogodišnje promjene nastale na odabranoj jaruzi (Jaruga Santiš).

4.2.1. Višegodišnje prostorno-vremenske promjene uzrokovane erozijom tla na prostoru poluotoka Santiš

I. Značajke izrađenih intervalnih (DGU) aerofotogrametrijskih modela

Višegodišnje prostorno-vremenske promjene na prostoru poluotoka Santiš detektirane su na temelju intervalnih modela izrađenih iz DGU aerofotogrametrijskih snimaka (vidi 3.2.1.). Ukupno su na temelju DGU aerofotogrametrijskih snimaka izrađena dva intervalna modela (Sl. 107.), koji su obuhvatili svih pet jaruga (i šest čela jaruga) poluotoka Santiš. Detaljne značajke izrađenih intervalnih modela su dane u tablicama 47, 48 i 49.

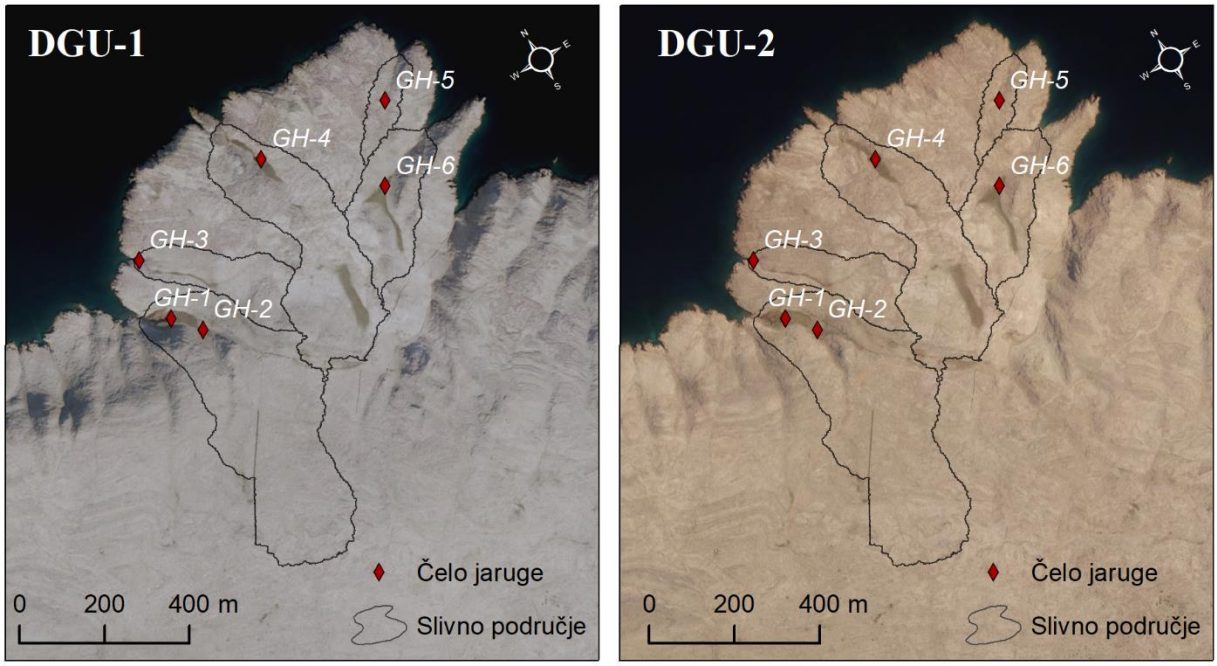

Slika 107. Intervalni modeli poluotoka Santiš izrađeni iz aerofotogrametrijskih DGU snimaka

S obzirom da među podacima ustupljenim za određene godine postoje znatne razlike u dostupnom broju snimaka, ali i u značajkama i kvaliteti tih snimaka[36], vidljiva je i razlika u izvedenim podacima (npr. gustoća oblaka točaka) (Tabl. 47.).

Tablica 47. Pregled značajki podataka izvedenih iz aerofotogrametrijskih snimaka

ID	Godina prikupljanja	Model kamere	Broj snimaka	Površina modela (km²)	Rijetki oblak točaka	Gusti oblak točaka
1	2014	UltraCam Condor M1 f80	6	36.3	1 809 712	319 730 698
2	2018	UltraCam Eagle M3 f100	4	14.9	632 438	132 910 929

Unatoč tome na temelju dostupnih snimaka i primijenjene metodologije u konačnici je bilo moguće izraditi dva intervalna modela identične vrijednosti prostorne rezolucije (30 cm), te približno iste točnosti (Tabl. 48.). Svi izračunati metrički pokazatelji točnosti modela (MAE, RMSE, SD, MAD) pokazuju ujednačene vrijednosti za oba izrađena modela. Pri tome je ipak nepobitna bolja točnost recentnijeg modela (DGU-2), izrađenog iz aerofotogrametrijskih snimaka prikupljenih najnovijim modelom UltraCam fotogrametrijske kamere.

Tablica 48. Rezultati provjere točnosti izrađenih intervalnih modela

ID	Naziv modela	Broj točaka (RTK-GNSS)	Srednja apsolutna pogreška (MAE)	Korijen srednje kvadratne pogreške (RMSE)	Standardna devijacija (SD)	Srednje apsolutno odstupanje (MAD)
1	DGU-1 (2014.)	22	0.30	0.36	0.36	0.27
2	DGU-2 (2018.)	22	0.27	0.31	0.31	0.21

Provjera točnosti izrađenih intervalnih modela poslužila je za određivanje nesigurnosti modela, kroz izračun praga minimalne detekcije, utvrđenog na temelju vrijednosti srednje kvadratne pogreške modela (Tabl. 49.). Prag minimalne detekcije za inicijalni model (DGU-1) iznosi 0.36 m, dok je za završni model prag nešto niži i iznosi 0.31 m. Ove vrijednosti praga

[36] Ovisno o korištenom modelu aerofotogrametrijske kamere

minimalne detekcije su proporcionalne ili čak niže (bolje) od vrijednosti praga u sličnim istraživanjima (Fernández i dr., 2020; Stark i dr., 2020). Postizanjem sličnih vrijednosti praga minimalne detekcije osigurana je usporedivost izrađenih intervalnih modela, odnosno valjanost detektiranih i kvantificiranih PVP.

Tablica 49. Nesigurnost pojedinih modela

ID	Naziv modela	Godina aerofotogrametrijskog snimanja	Prostorna rezolucija (m)	Pogreška u CP (m)[37]	Nesigurnost (m)[38]	Razina pouzdanosti
1	DGU-1	2014.	0.3	0.43	0.36	95%
2	DGU-2	2018.	0.3	0.49	0.31	95%

II. Utvrđene prostorno-vremenske promjene uzrokovane erozijom tla

U nastavku su dani višegodišnji rezultati detekcije i kvantifikacije PVP za prostor poluotoka Santiš, unutar kojega se nalazi pet izdvojenih jaruga. Ukoliko se sagledaju ukupne prostorno-vremenske promjene uzrokovane erozijom tla, detektirane unutar mezo razine u promatranom petogodišnjem razdoblju (2014.-2018.), vidljivo je da unutar promatranog područja značajno prevladava erozija tla (> 97% svih promjena). Erozija tla unutar promatranog razdoblja se javila na ukupno 164.34 m², gdje je ukupno erodirano 201.28 m³ naslaga tla (Sl. 108; Tabl. 50). Akumulacija tla javila se na tek 4.59 m² površine, unutar koje je akumulirano samo 5.01 m³ tla (Sl. 108; Tabl. 50.). S obzirom da količina erodiranog materijala višestruko nadilazi količinu akumuliranog materijala, preostali erodirani materijal je vjerojatno površinski otjecanjem transportiran do mora.

Tablica 50. Ukupne PVP uzrokovane erozijom tla na poluotoka Santiš (2014.-2018.)

Proces	Površinske promjene		Volumetrijske promjene		Prosječna vertikalna promjena
	m²	%	m³	%	m
Erozija	164.34	97.28	201.28	97.57	1.22
Akumulacija	4.59	2.72	5.01	2.43	1.08
Ukupno	168.93	100	206.29	100	-

[37] RMSE određena na temelju kontrolnih točaka dodanih pri izradi modela u Agisoft Metashape softveru
[38] SD određena na temelju kontrolnih točaka prikupljenih uz pomoć RTK-GNSS-a na terenu

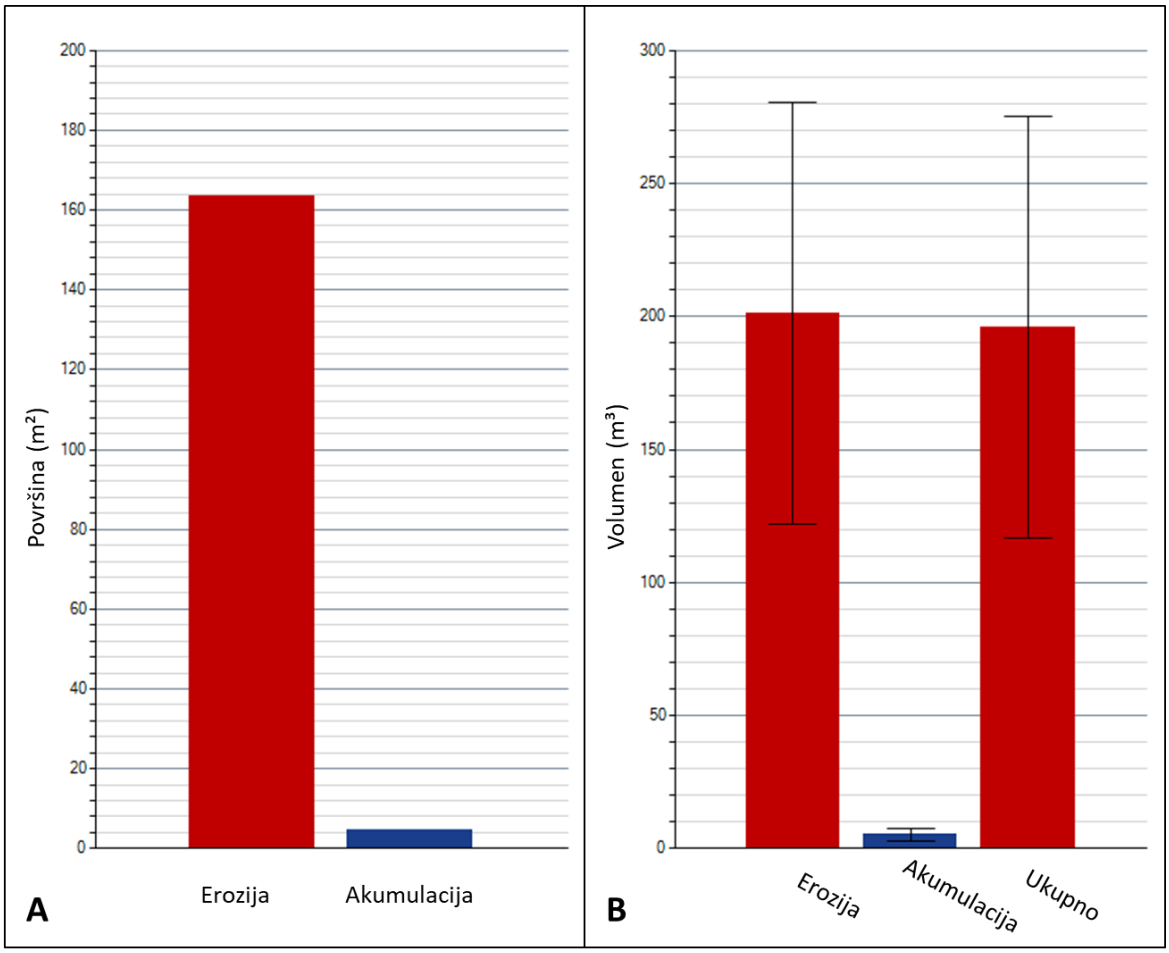

Slika 108. Površinski (A) i volumetrijski (B) pokazatelji ukupnih PVP na prostoru poluotoka Santiš uzrokovanih erozijom tla za razdoblje 2014.-2018.

Ukoliko se utvrđene petogodišnje vrijednosti volumetrijskih PVP preračunaju u prosječnu jednogodišnju vrijednost, proizlazi da je u prosjeku unutar prostora poluotoka Santiš erodirano 40.26 m^3 materijala, dok je akumulirano samo 1.02 m^3 materijala.

Prostorno-vremenske promjene pojedinih čela jaruge na prostoru poluotoka Santiš

Nakon što su utvrđene ukupne PVP uzrokovane u petogodišnjem razdoblju djelovanjem erozije tla, analizirana je varijabilnost promjena unutar pet jaruga poluotoka Santiš. Pri tome su detektirane PVP raspodijeljene po pojedinim jarugama, ali i po šest detektiranih čela jaruga (GH-1 – GH-6) (Tabl. 51.). Iz detektiranih PVP vidljivo je da je varijabilnost erozije i akumulacije tla unutar različitih jaruga vrlo velika. Akumulacija materijala zabilježena je

isključivo kod jaruge Santiš, na prostoru ispod glavnog (većeg) čela jaruge (GH-1) (Sl. 110.), dok na dvije lokacije (Uska i Mala) nisu zabilježene nikakve PVP[39].

Tablica 51. PVP (2014. – 2018.) na prostoru pet odabranih jaruga poluotoka Santiš

##	Jaruga (Čelo jaruge)	Prostorno-vremenske promjene					
		Površina		Volumen		Vertikalne promjene	
		Erozija (m² (%)	Akumulacija (m² (%))	Erozija (m³ (%))	Akumulacija (m³ (%))	Prosječno povećanje dubine (m)	Prosječno smanjenje dubine (m)
1	Jaruga Santiš (ukupno)	138.51 (96.85)	4.59 (3.14)	172.87 (97.18)	5.01 (2.81)	1.18	1.11
1.1	Jaruga Santiš (GH-1)	120.24 (96.39)	4.59 (3.61)	153.03 (96.83)	5.01 (3.17)	1.27	1.11
1.2	Jaruga Santiš (GH-2)	18.27 (100)	0 (0)	19.84 (100)	0 (0)	1.09	0
2	Jaruga Uska (GH-3)	0 (0)	0 (0)	0 (0)	0 (0)	0	0
3	Stepeničasta jaruga (GH-4)	11.97 (100)	0 (0)	13.29 (100)	0 (0)	1.11	0
4	Jaruga Mala (GH-5)	0 (0)	0 (0)	0 (0)	0 (0)	0	0
5	Zečja jaruga (GH-6)	13.86 (100)	0 (0)	15.11 (100)	0 (0)	1.09	0
UKUPNO (SVIH 5)		164.34 (97.28)	4.59 (2.72)	201.28 (97.57)	5.01 (2.43)	1.22	1.08

Varijabilnost prostornog obuhvata erozije tla i količine erodiranog materijala među pojedinim jarugama (i čelima jaruge) je također vrlo velika (Tabl. 50; Sl. 108). Prostorni raspored pojedinih erozijskih zona (čela jaruga) unutar kojih je zabilježena erozija tla vidljiv je na slici 109., dok je grafički pregled površinskih i volumetrijskih PVP po pojedinim čelima jaruga dan na slikama 111. i 112.

[39] PVP za jarugu Uska (GH-3) i jarugu Mala (GH-5) u promatranom razdoblju (2014.-2018.) bile su manje od procijenjene nesigurnosti modela (DGU-1 = 0.36 m; DGU-2 = 0.31 m) i zadane razine pouzdanosti (95 %) te zbog toga nisu detektirane kroz usporedbu intervalnih modela. Unatoč tome, PVP su gotovo sigurno prisutne i unutar ove dvije jaruge, samo sa intenzitetom manjim od praga detekcije.

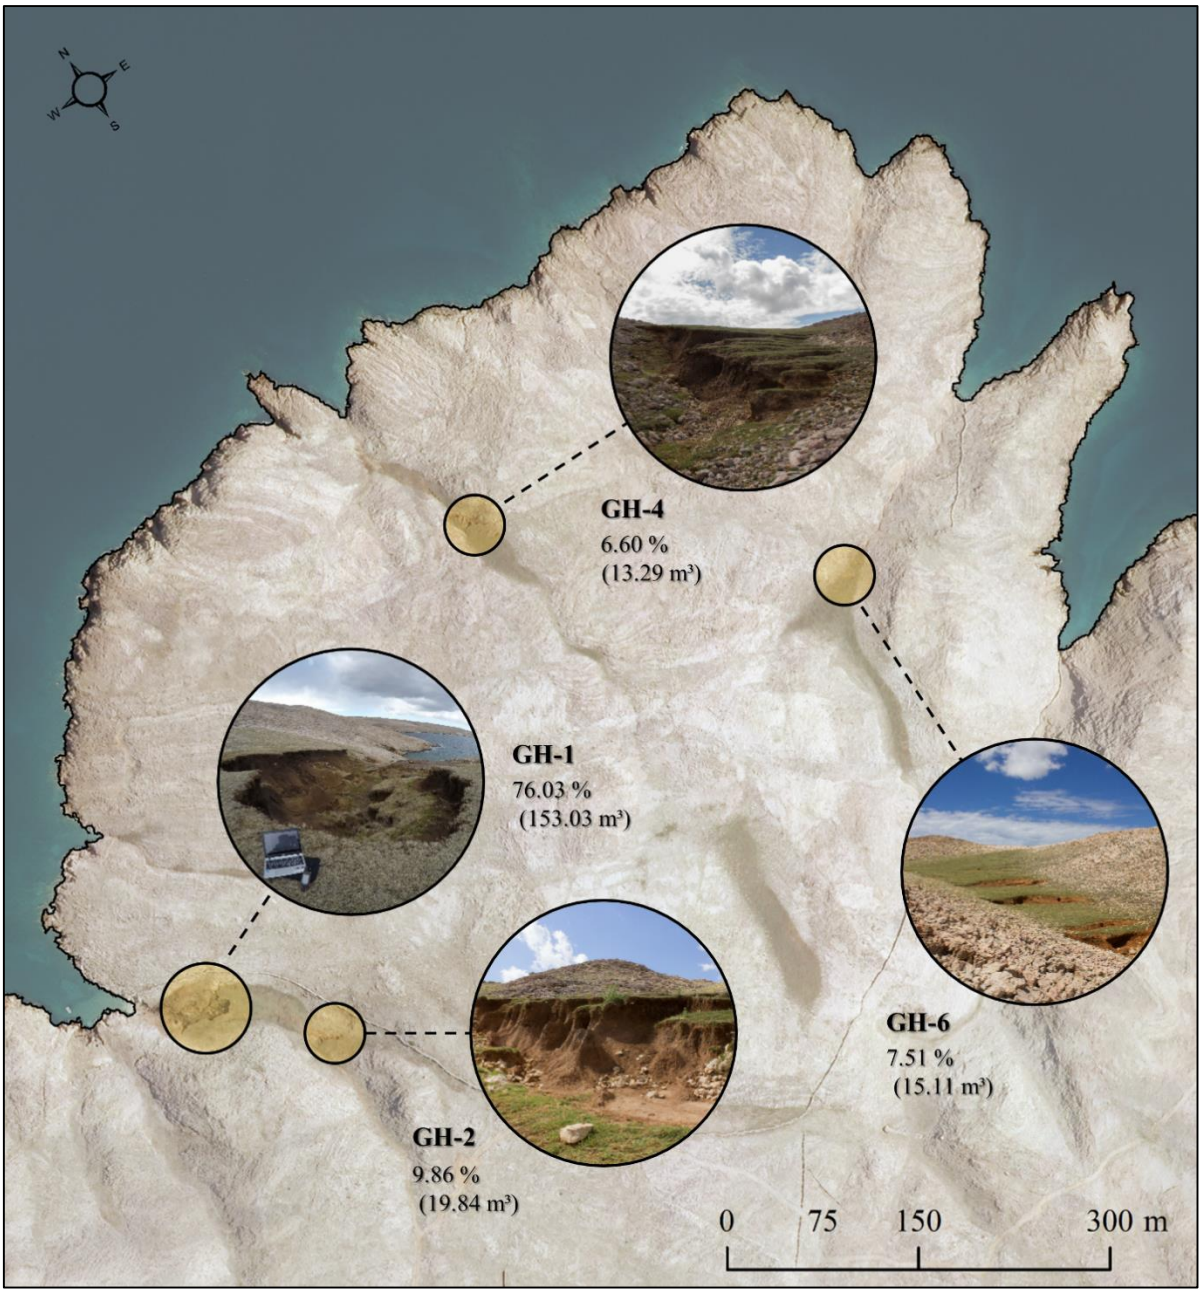

Slika 109. Prostorna raspodjela ukupne količine erodiranog materijala unutar četiri čela jaruge za koje su detektirane PVP u razdoblju 2014.-2018.

Unutar promatranog razdoblja daleko najveći intenzitet erozije tla zabilježen je unutar *jaruge Santiš*, gdje je na 138.51 m^2 erozijom zahvaćene površine ukupno erodirano 172.87 m^3 materijala (Tabl. 51; Sl. 109; 110.). Međutim i unutar jaruge Santiš zabilježena je izražena varijabilnost u intenzitetu erozije tla, pri čemu je moguće izdvojiti dvije izražene erozijske zone, unutar kojih prostorni obuhvat i intenzitet erozije tla nisu ni približno jednaki. Navedene erozijske zone vezane su za dva čela jaruge Santiš. Veće, odnosno glavno (GH-1) čelo jaruge Santiš bilježi najintenzivnije stope erozije tla od svih šest analiziranih čela jaruga, pri čemu na

njega otpada većina (76.03%) ukupnog materijala erodiranog u petogodišnjem razdoblju (Sl. 110.). U sklopu GH-1 erozijom tla zahvaćeno je 120.24 m^2 površine, unutar koje je erodirano 153.03 m^3 materijala (Tabl. 50.). Prostorna distribucija utvrđenih PVP unutar GH-1 potvrđuje da je u promatranom petogodišnjem razdoblju došlo do intenzivnog uzmaka čela jaruge, pri čemu se uslijed kontinuiranog erodiranja materijala čelo znatno retrogradno pomaklo (Sl. 110.). PVP detektirane na manjem čelu jaruge Santiš (GH-2) znatno su manjeg prostornog obuhvata (18.27 m2) i intenziteta (19.84 m^3) (Tabl. 51; Sl. 109; 110; 111.). U promatranom petogodišnjem razdoblju na ovo čelo jaruge Santiš ukupno otpada 9.86% svog materijala erodiranog unutar šireg područja mezo razine istraživanja, zbog čega je ovo čelo drugo po ukupnom intenzitetu erozije od šest analiziranih čela.

Ukoliko se petogodišnje PVP detektirane unutar jaruge Santiš preračunaju u prosječnu jednogodišnju vrijednost, proizlazi da je unutar prostora jaruge u prosjeku erodirano 34.57 m^3 materijala, dok je akumulirano samo 1.02 m^3 materijala. Zabilježena vrijednost volumena erodiranog materijala odgovara eroziji tla od 32.71 t/ha y^{-1}, što je u skladu s vrijednostima određenim za prostor poluotoka Santiš prema RUSLE metodi (Tabl. 52; Panagos i dr., 2015).

Tablica 52. Prosječne jednogodišnje volumetrijske PVP unutar jaruge Santiš

Proces	Volumetrijske promjene		t/ha y^{-1}	RUSLE[40]
	m^3	%		t/ha y^{-1}
Erozija	34.57	97.55	32.71	20 - 50
Akumulacija	1.02	2.45	0.96	-
Ukupno	41.28	100	-	20 - 50

[40] Podaci za prostor otoka Paga i ostatka RH preuzeti sa https://esdac.jrc.ec.europa.eu/content/soil-erosion-water-rusle2015 (Panagos i dr., 2015).

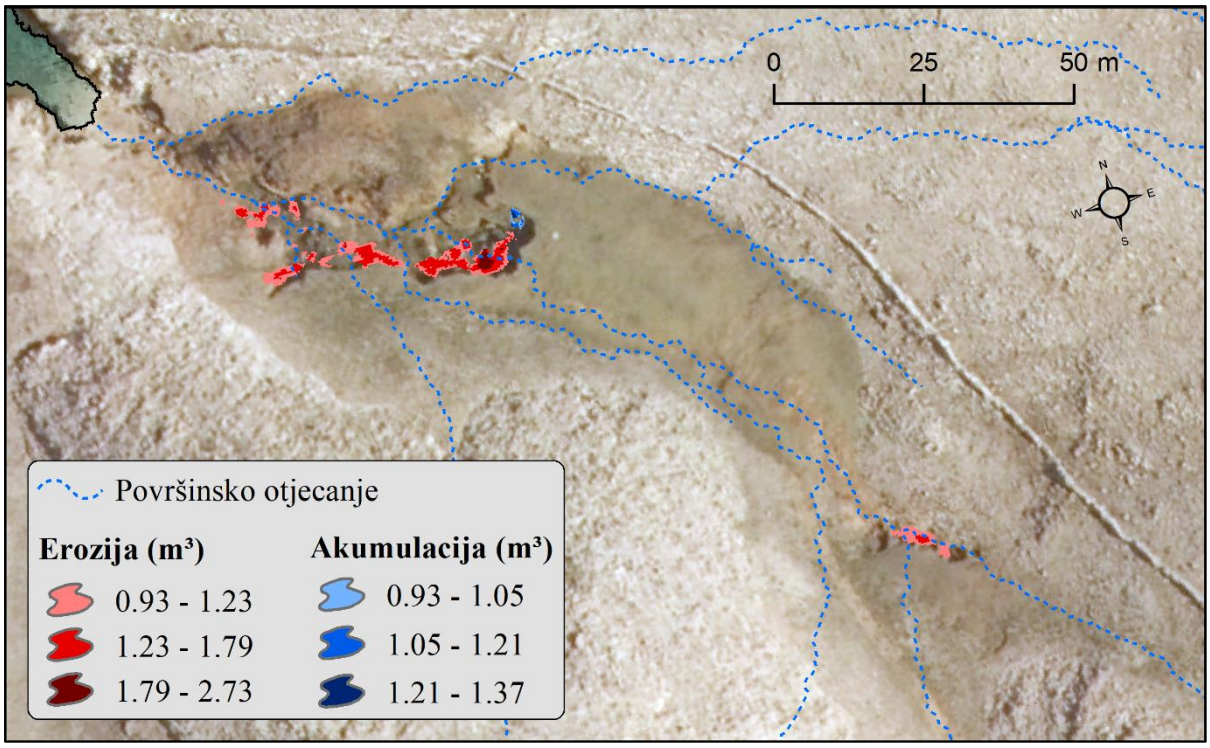

Slika 110. Volumetrijske PVP unutar jaruge Santiš (GH-1 i GH-2) za razdoblje 2014.-2018.

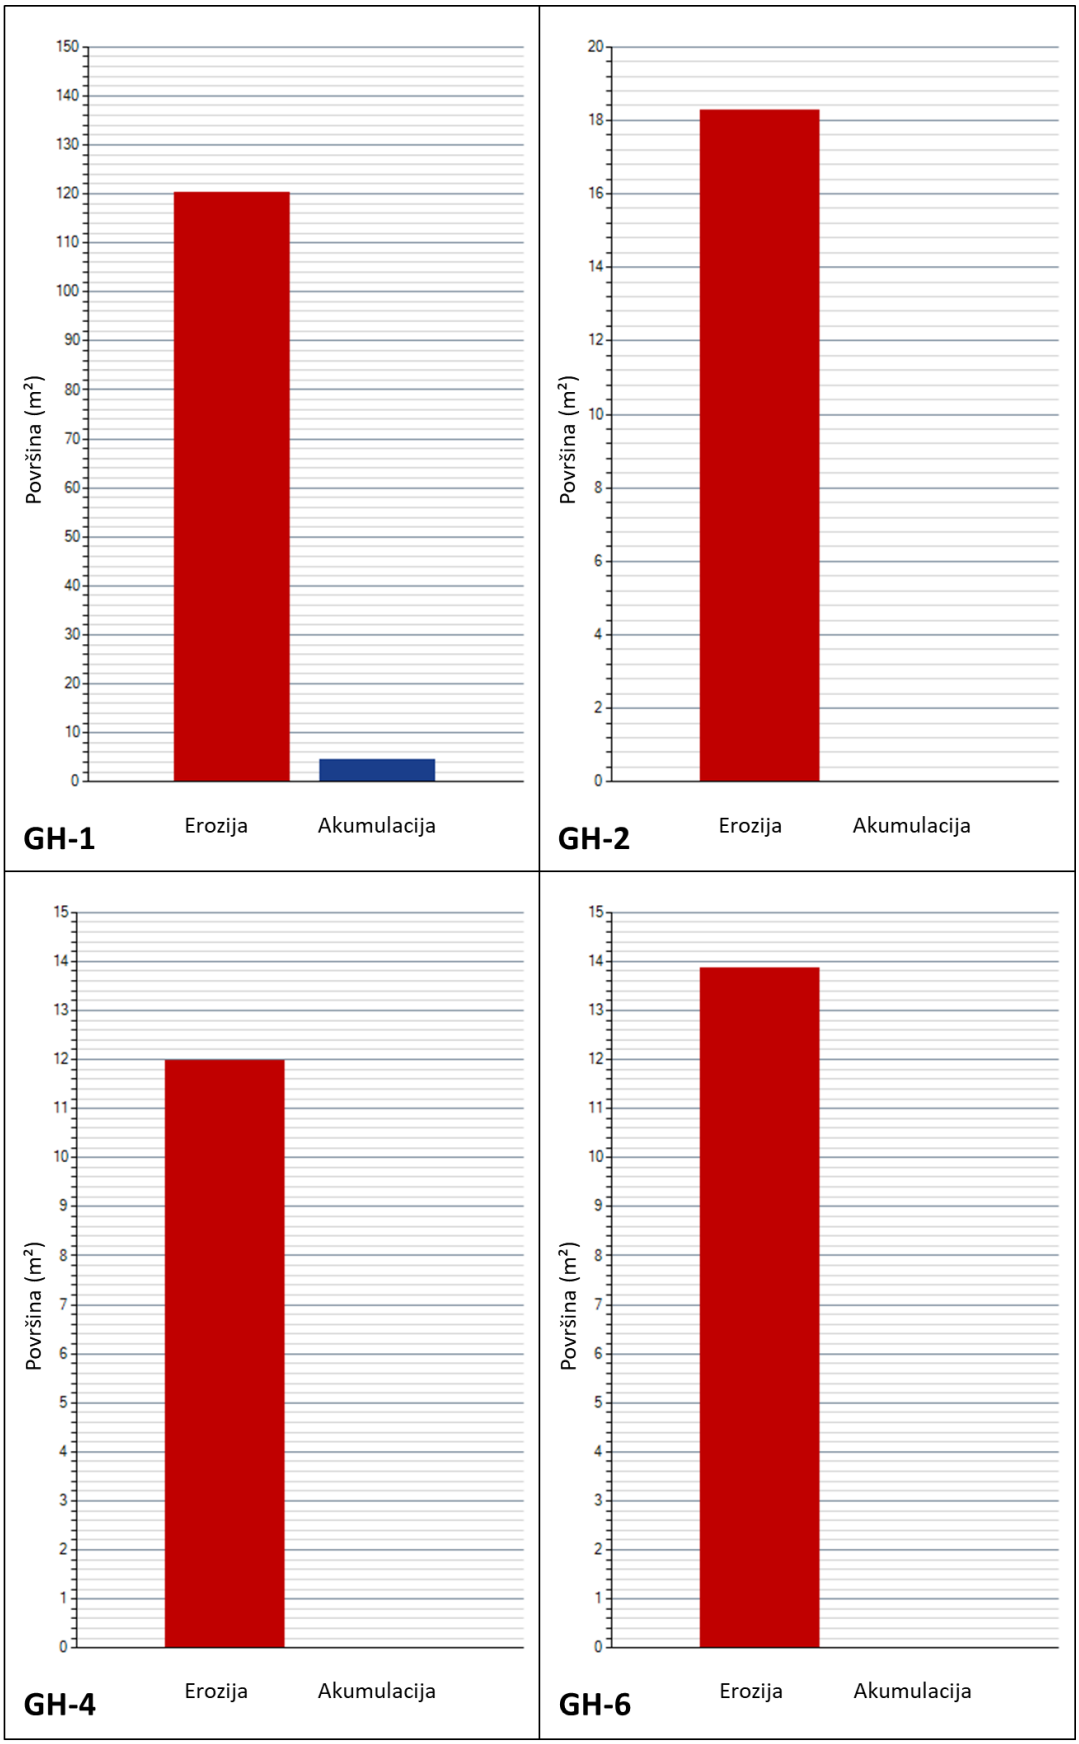

Slika 111. Površinske PVP unutar četiri čela jaruge za razdoblje 2014.-2018.

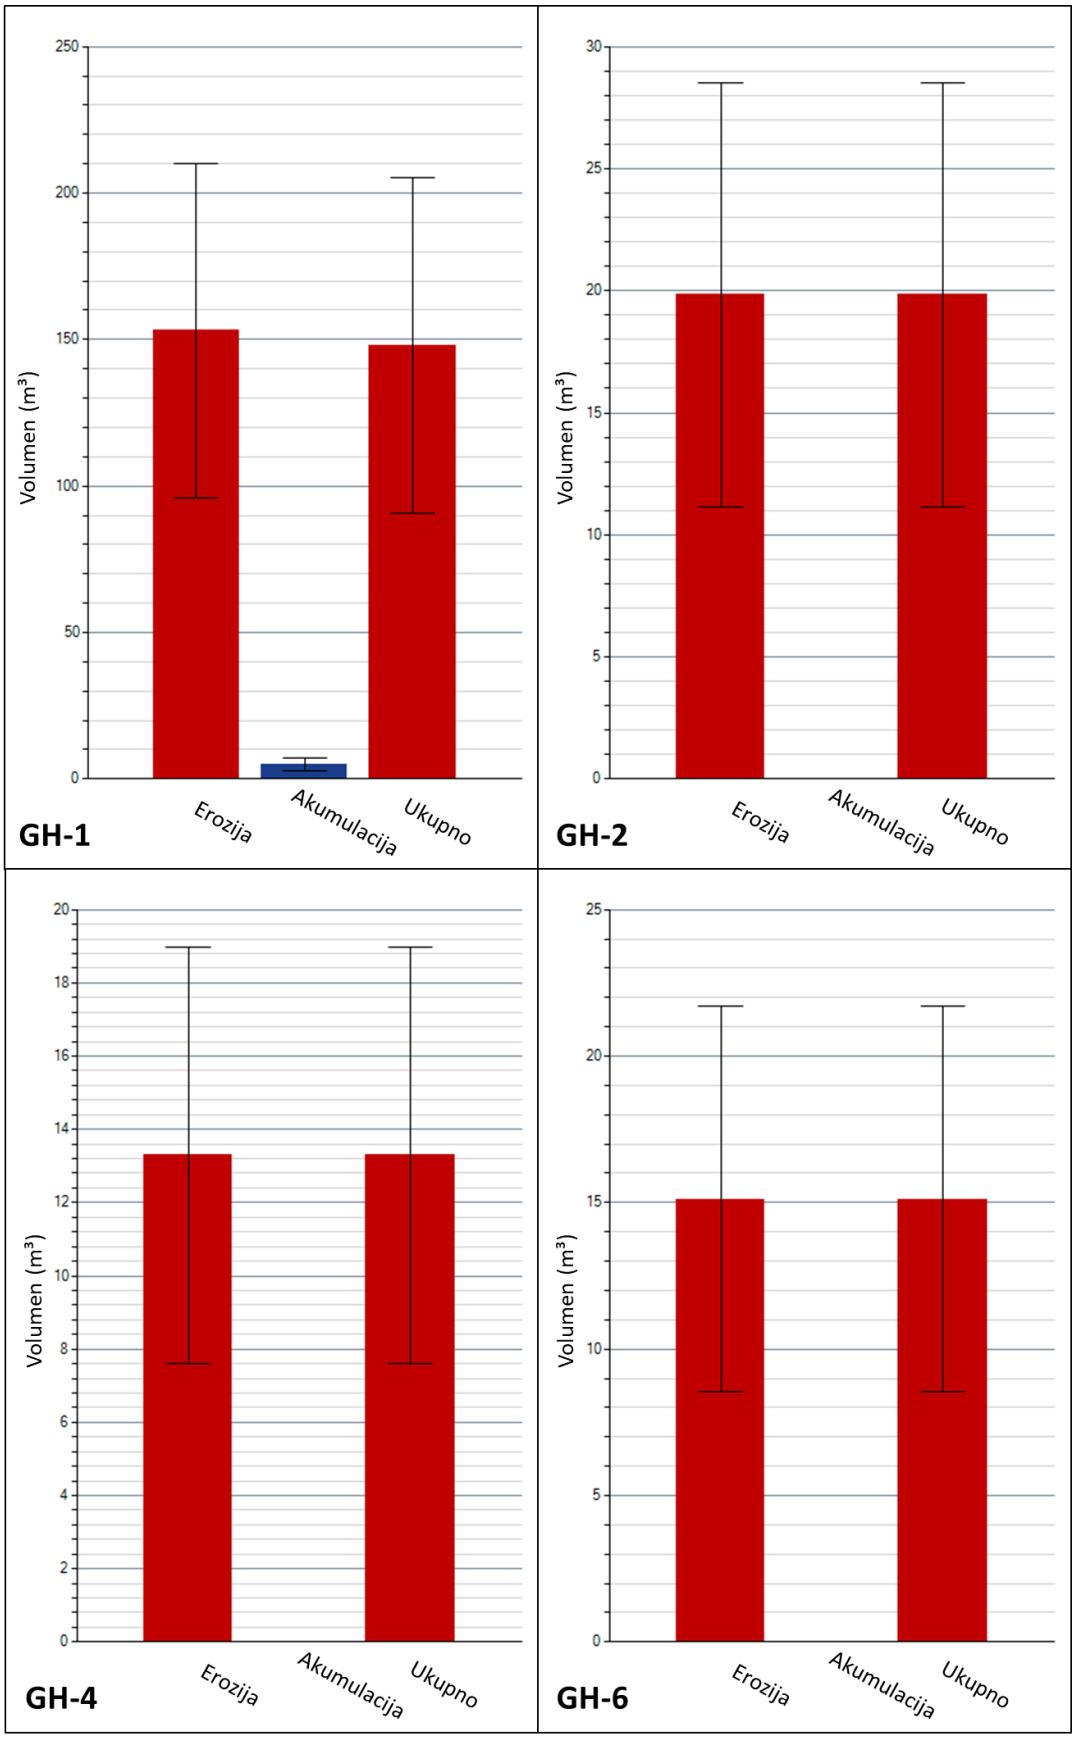

Slika 112. Volumetrijske PVP unutar četiri čela jaruge za razdoblje 2014.-2018.

Osim unutar *jaruge Santiš* erozija tla je u promatranom petogodišnjem razdoblju detektirana i unutar *Zečje jaruge* (Sl. 113.) i *Stepeničaste jaruge* (Sl. 114.), pri čemu obje jaruge bilježe znatno manje erozijom zahvaćene površine i manju količinu ukupnog erodiranog materijala, u odnosu na jarugu Santiš.

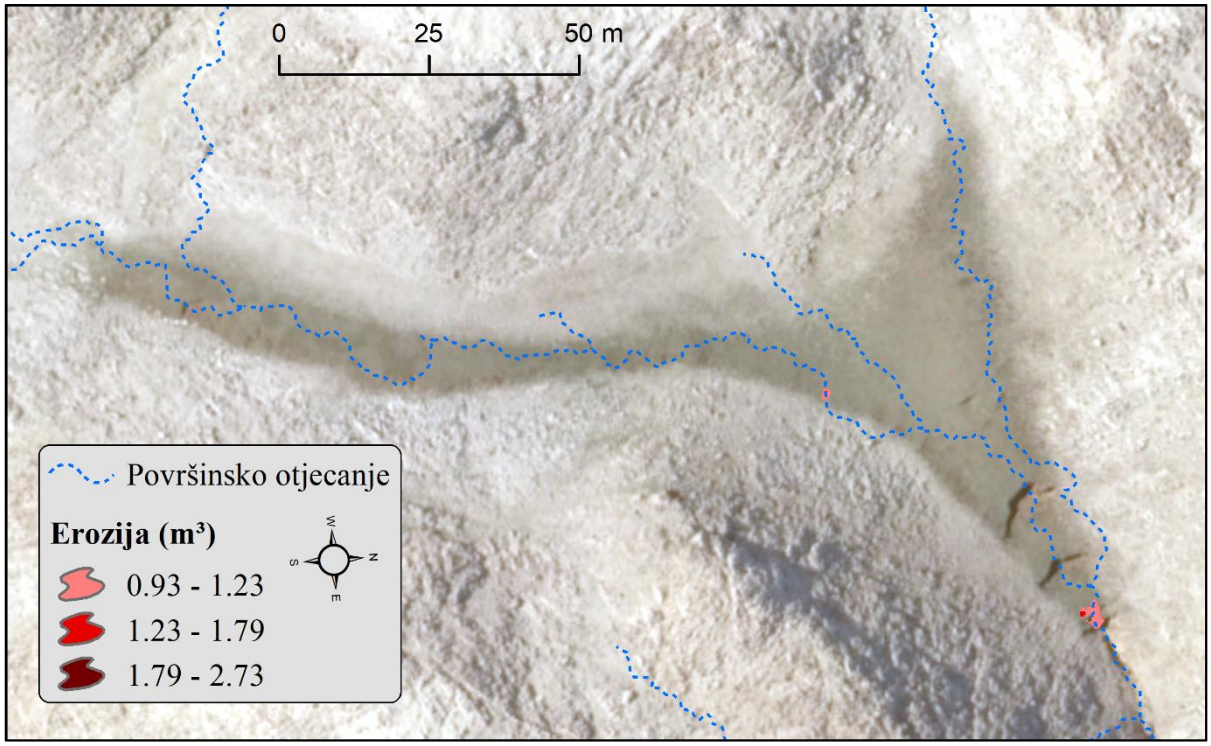

Slika 113. Volumetrijske PVP unutar Zečje jaruge (GH-6) za razdoblje 2014.-2018.

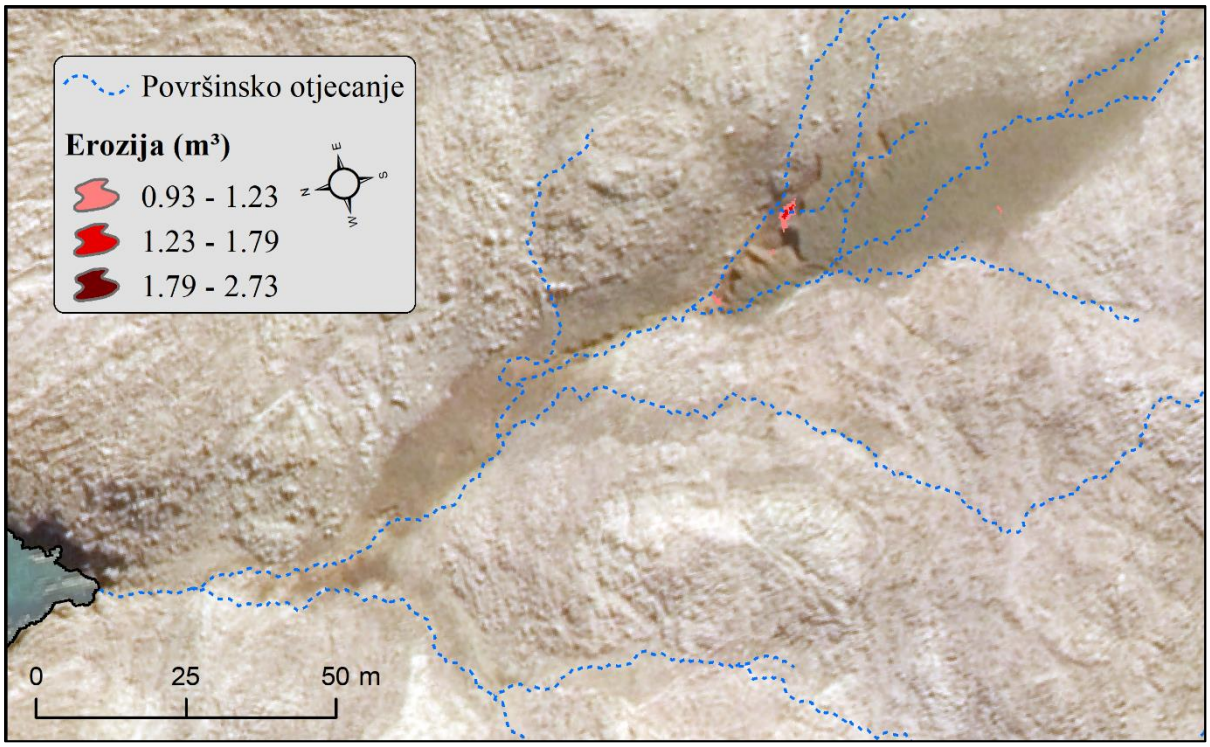

Slika 114. Volumetrijske PVP unutar Stepeničaste jaruge (GH-4) za razdoblje 2014.-2018.

manjim slivnim područjima, ali i s različitim drugim značajkama ovih jaruga. Unutar *Zečje jaruge* erozija tla se u promatranom razdoblju javila na 13.86 m^2 površine, gdje je ukupno erodirano 15.11 m^3 materijala. *Stepeničasta jaruga* bilježi najniži prostorni obuhvat (11.97 m^2) i intenzitet (13.29 m^3) procesa erozije tla, gdje su također sve detektirane PVP vezane za prostor čela jaruge (GH-4).

III. Utjecaj značajki slivnog područja na eroziju tla

Utvrđene petogodišnje PVP uzrokovane djelovanjem erozije tla moguće je djelomično objasniti i dovesti u vezu sa značajkama slivnih područja pojedinih jaruga (Sl. 115; Tabl. 53.).

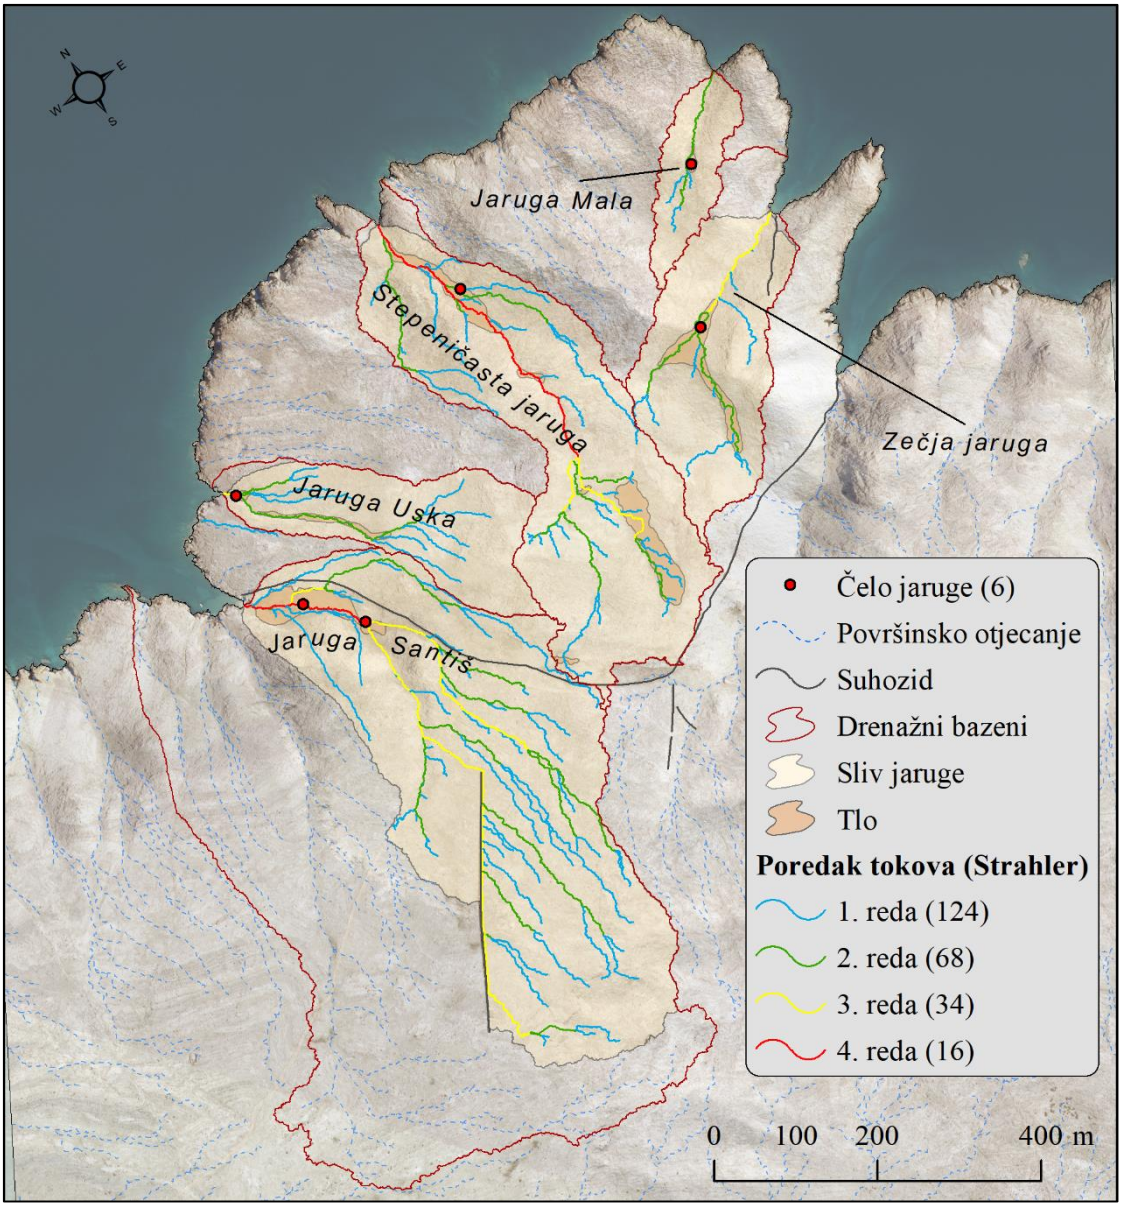

Slika 115. Usporedba drenažnih bazena i slivnih područja pojedinih jaruga poluotoka Santiš

Tablica 53. Usporedba intenziteta erozije tla (m³) s hidrološkim značajkama

#	Jaruga	Čela jaruge	Erozija (m³)	Naslage tla (m²)	Drenažni bazen (ha)	Slivno područje (ha)	Duljina tokova (km)
1	Santiš	GH-1; GH-2	172.87	4203.16	34.41	16.08	6.66
2	Uska	GH-3	0	1249.23	4.04	3.91	1.29
3	Stepeničasta[41]	GH-4	13.29	7539.30	10.77	10.52	3.47
4	Mala	GH-5	0	249.71	1.55	1.55	0.33
5	Zečja	GH-6	15.11	3659.94	5.12	4.91	1.04

Utjecaj hidroloških značajki slivnog područja na intenzitet erozije tla najbolje je vidljiv na primjeru jaruge Santiš, unutar koje je utvrđen najveći prostorni obuhvat i intenzitet erozije tla (Tabl. 53.). Jaruzi Santiš pripadaju najveći drenažni bazen (34.41 ha) i najveće slivno područje (16.08 ha) unutar poluotoka Santiš, uz razgranatu mrežu površinskih tokova ukupne duljine od 6.66 km, koja upravo na prostoru sporednog čela jaruge (GH-2)[42] formira tok 4. reda po Strahleru (Sl. 115.). Brojna istraživanja dokazala su da veličina slivnog područja jaruge izravno utječe na sposobnost generiranja površinskog otjecanja potrebnog za inicijaciju erozije tla (Le Roux i Sumner, 2012). Sukladno tome može se pretpostaviti da su zabilježeni najveći prostorni obuhvat i intenzitet erozije tla kod jaruge Santiš odraz velikog slivnog područja i razgranate drenažne mreže, koji imaju sposobnost učestalog generiranja površinskog otjecanja dovoljne snage za erodiranje značajnijih količina naslaga tla. S druge strane, drenažni bazeni i slivna područja preostalih jaruga poluotoka Santiš su znatno manji, zbog čega je unutar njih zabilježen i manji intenzitet erozije tla (Tabl. 53; Sl. 116.).

Osim hidroloških značajki slivnog područja, na intenzitet erozije tla velik utjecaj imaju i značajke te prostorni obuhvat naslaga tla u kojima su formirane analizirane jaruge. Jaruga Santiš oblikovana je u po površini (4203.16 m^2) i volumenu najvećim naslagama tla unutar poluotoka Santiš, čija debljina mjestimice prelazi i nekoliko metara. Unutar ovih naslaga su oblikovana čak dva velika čela jaruge (GH-1 i GH-2), unutar kojih su jasno vidljivi recentni tragovi erozije tla. Prema površini naslaga tla zatim slijedi Zečja jaruge, oblikovana u naslagama ukupne površine od 3659.94 m^2 (Sl. 17.A.), unutar kojih je oblikovana serija manje

[41] Ne radi se o jedinstvenoj homogenoj površini naslaga tla, već o četiri odvojene površine, različitog obuhvata i debljine. Unutar tri od četiri navedene površine nisu zabilježeni tragovi recentnih PVP.

[42] Oblikovanje sporednog čela jaruge Santiš (GH-2) uzrokovano je spajanjem navedenih tokova, odnosno postupnim potkopavanjem baze čela (Sl. 15.).

izraženih čela jaruge (GH-6). Zatim po površini naslaga slijedi Stepeničasta jaruga, čije stepeničasto čelo (GH-4; Sl. 19.) je oblikovano u naslagama tla ukupne površine od 2835.56 m^2. S druge strane, Uska i Mala jaruga oblikovane su u znatno plićim i obihvatom manjim naslagama tla, koje su onemogućile razvoj većih erozijskih oblika i nastanak intenzivnije erozije tla.

Osim ukupne površine naslaga tla, velik utjecaj na intenzitet erozije tla ima i smještaj naslaga unutar slivnog područja, na što najbolje ukazuje primjer usporedbe između Stepeničaste i Zečje jaruge. Naime, iako Stepeničasta jaruga ima bolje hidrološke predispozicije za pojavu intenzivne erozije tla[43] i veću ukupnu površinu pokrivenu naslagama tla (7539.30 m^2), unutar nje je utvrđen manji intenzitet erozije tla u odnosu na Zečju jaruga. Uzrok tome može biti u smještaju naslaga tla unutar sliva Stepeničaste jaruge. Uz ranije navedene naslage tla u kojima je oblikovana Stepeničasta jaruga, unutar istog slivnog područja se nalaze i dvije manje, disperzne površine naslaga tla (ukupno 359.88 m^2) te jedna veća površina naslaga tla (4174.48 m^2). Ove naslage tla smještene su u početnom dijelu sliva Stepeničaste jaruge, koji obuhvaća zaravnjeni krški plato, gdje zbog vrlo malih nagiba i slabo izraženog površinskog otjecanja[44] (Sl. 115; 116.) nema recentnih tragova erozije tla. S druge strane, naslage tla u Zečjoj jarugi smještene su u središnjem dijelu slivnog područja, gdje je površinsko otjecanje znatno izraženije, što potvrđuje i formiranje toka 3. reda po Strahleru na prostoru čela jaruge (GH-6).

Na temelju navedenog moguće je zaključiti da su intenzitet i prostorni obuhvat erozije tla unutar analiziranih pet jaruga poluotoka Santiš uvjetovani prije svega različitim hidrološkim značajkama slivnog područja (npr. površina slivnog područja i drenažnog bazena; razgranatost drenažne mreže; itd.), ali i prostornim obuhvatom, debljinom i smještajem naslaga tla unutar slivnog područja pojedine jaruge. Tome treba pridodati i utjecaj ovaca, odnosno zoogenu eroziju tla, koja zasigurno značajno pridonosi ukupnim stopama erozije tla. Naime, prilikom terenskih sitraživanja prisutnost i tragovi ovaca primjećeni su isključivo unutar jaruge Santiš[45], zbog čega je moguće zaključiti da je upravo zoogena erozija pridonjela povećanom intenzitetu erozije unutar ove jaruge.

[43] Stepeničasta jaruga ima znatno veće slivno područje (10.77 ha) i razgranatiju drenažnu mrežu (3.47 km; tok 4. red po Strahleru) u odnosu na Zečju jarugu, čije slivno područje obuhvaća tek 5.12 ha, a drenažna mreža ima duljinu od samo 1.04 km (tok 3. reda po Strahleru).

[44] Na prostoru naslaga tla smještenih u početnom dijelu sliva Stepeničaste jaruge prevladavaju tokovi 1. reda po Strahleru, čija erozivnost je zasigurno manja od tokova u nizvodnim dijelovima sliva.

[45] Zabilježena prisutnost ovaca unutar jaruge Santiš može se potencijalno objasniti postojanjem povremenog izvora slatke vode u dnu jaruge.

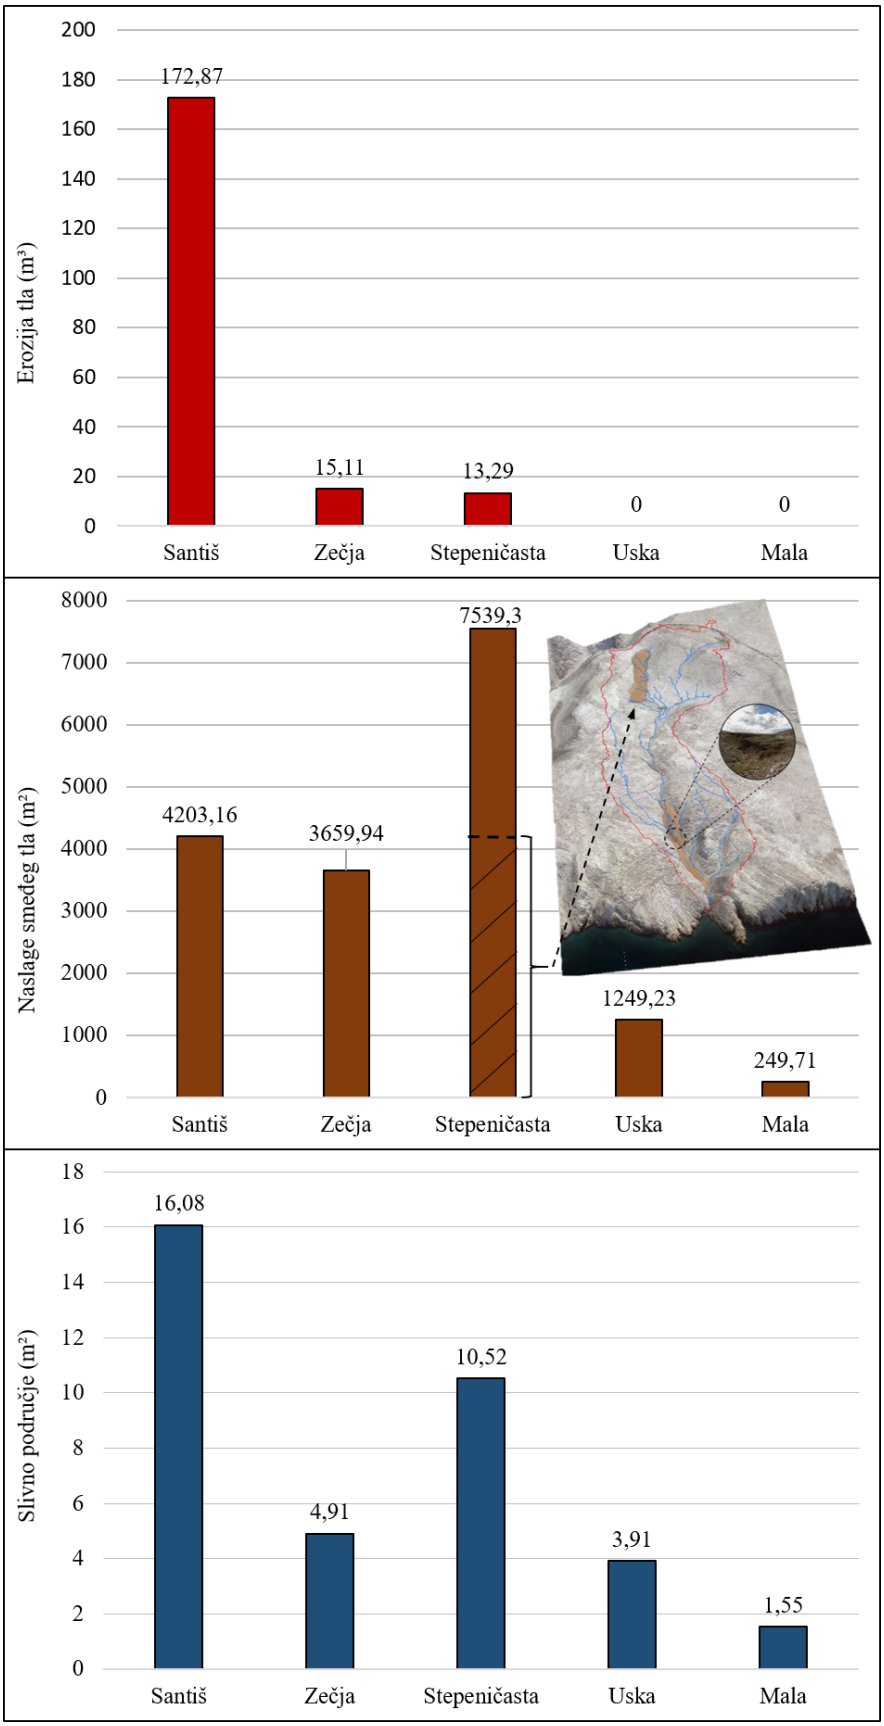

Slika 116. Usporedba detektiranog intenziteta erozije tla pojedinih jaruga s površinom pripadajućih slivnih područja i naslaga tla

4.2.2. Jednogodišnje prostorno-vremenske promjene uzrokovane erozijom tla detektirane na prostoru jaruge Santiš

I. Značajke izrađenih intervalnih (UAV) aerofotogrametrijskih modela

Detekcija jednogodišnjih PVP unutar jaruge Santiš napravljena je na temelju intervalnih aerofotogrametrijskih modela izrađenih na temelju podataka prikupljenim unutar užeg prostora mezo razine istraživanja intervalnom UAV fotogrametrijom (vidi 3.2.2.). Na temelju provedenih aerofotogrametrijskih snimanja izrađena su dva intervalna modela, prvi iz podataka prikupljenih u prosincu 2019. godine (UAV-A) i drugi iz podataka prikupljenih u prosincu 2020. (UAV-B). Detaljne značajke izrađenih intervalnih modela su dane na slici 117., te u tablicama 54, 55 i 56.

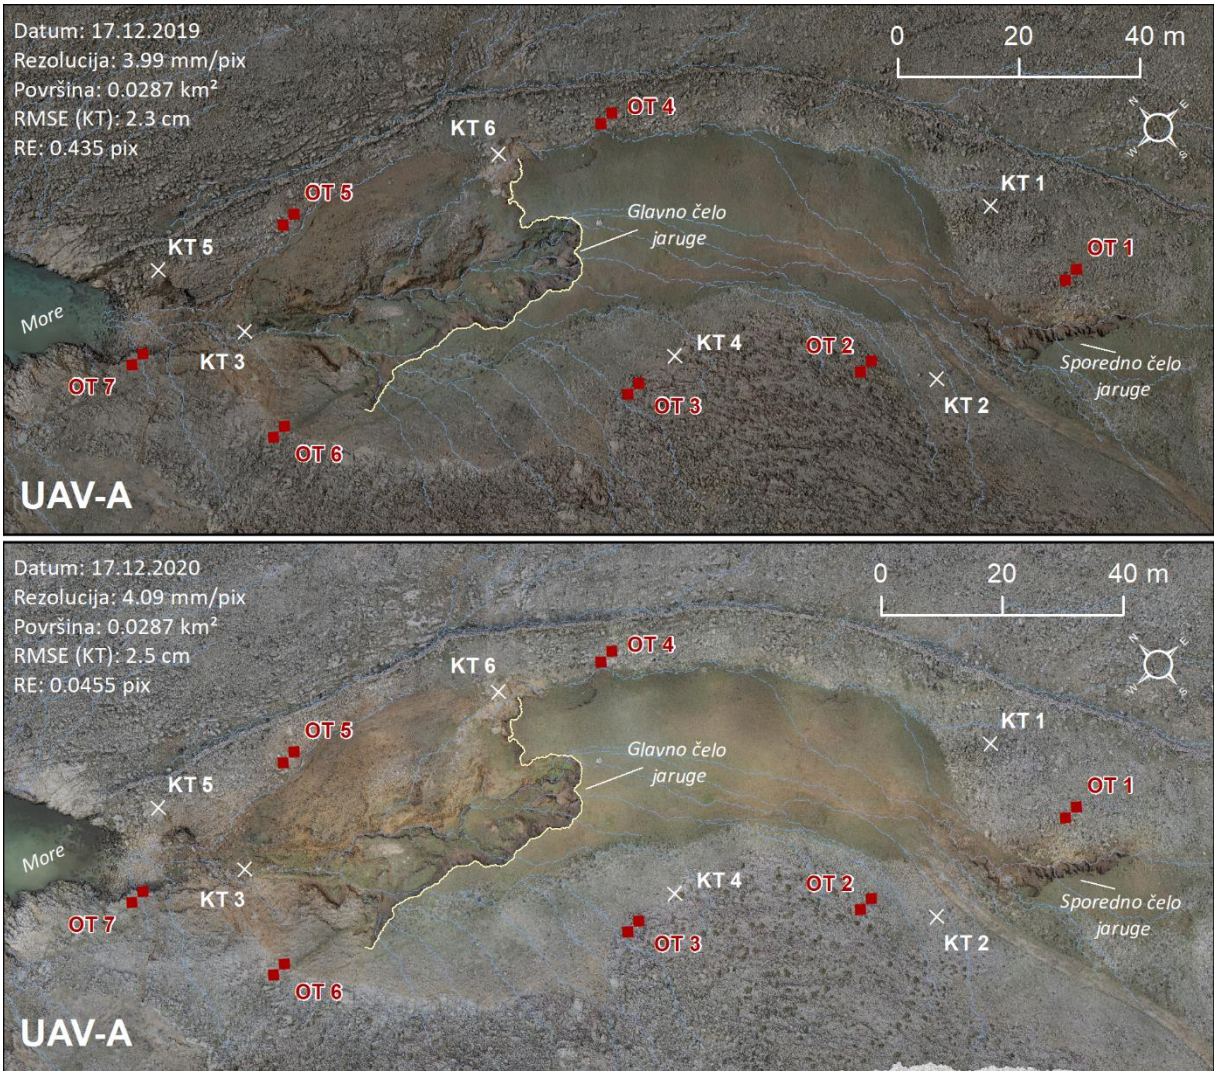

Slika 117. Generirani VHR modeli (DOF i DMP) užeg prostora jaruge Santiš

Na temelju primijenjene metodologije (vidi 3.2.2.) generirani su intervalni (DOF i DMP) prostorne rezolucije 4.09 mm/pix, koja je radi lakše obrade generalizirana (engl. *resampling*) na 1 cm/pix. Svi intervalni aerofotogrametrijski modeli izrađena su iz snimaka prikupljenih RAPS sustavom (Tabl. 54), zbog čega su i karakteristike podataka izvedenih iz tih snimaka vrlo slične. Posebice se to vidi u pogrešci modela, te vrlo sličnom ukupnom broju točaka unutar izrađenih rijetkih i gustih oblaka točaka. Pogreška modela određena uz pomoć KT kod modela UAV-A iznosila je RMSE = 2.3 cm, dok je kod modela UAV-B bila neznatno veća, RMSE = 2.5 cm.

Tablica 54. Pregled značajki podataka izvedenih iz snimaka prikupljenih aerofotogrametrijskim snimanjem užeg prostora jaruge Santiš

ID	Model (Datum prikupljanja)	Sustav (kamera)	Broj snimaka	Površina modela (km²)	Rijetki oblak točaka	Gusti oblak točaka
1	Model UAV-A (17.12.2019)	RAPS (Sony Alpha A7RII DSLR)	1534	0.0249	6 553 782	2 643 894 432
2	Model UAV-B (17.12.2020)	RAPS (Sony Alpha A7RII DSLR)	1534	0.0249	6 695 692	2 677 054 568

Provjera točnosti izrađenih modela napravljena je na temelju usporedbe izrađenog inicijalnog gustog oblaka točaka s referentnim podacima prikupljenim s TLS-om (vidi 4.3.2.). Pri tome treba napomenuti da je ovakva provjera točnosti provedena samo za inicijalni aerofotogrametrijski model (UAV-A), jer kod drugog snimanja u prosincu 2020. godine aerofotogrametrijski i TLS podaci nisu prikupljeni na isti dan. Zbog toga su u nastavku dani kraći rezultati provjere točnosti inicijalnog aerofotogrametrijskog modela, dok su detaljniji rezultati dani u poglavlju 4.3.2.

Tablica 55. Rezultati provjere točnosti izrađenih modela na temelju referentnih TLS-A podataka

ID	Naziv modela	Površina testnog područja (m^2)	Broj točaka (TLS-A)	Broj točaka (UAV-A)	Standardna devijacija - M3C2 (TLS-A – UAV-A)	RMSE - M3C2 (TLS-A – UAV-A)
1	Model UAV-A (2019.)	1163.09	8 022 041	33 025 559	0.0199	0.0196

Rezultati procjene točnosti aerofotogrametrijskog inicijalnog modela (vidi 4.3.2.) su u skladu s točnosti izrađenih intervalnih modela (UAV-A i UAV-B) izračunatom na temelju CP prilikom izrade modela unutar Agisoft Metashape softvera (Tabl. 56). Provedena procjena točnosti inicijalnog aerofotogrametrijskog modela (UAV-A) (*vidi 4.3.2.*) pokazala je da vrijednost srednje kvadratne pogreške modela izračunate uz pomoć M3C2 alata iznosi oko 2 cm (Tabl. 55). Takva vrijednost RMSE u skladu je s vrijednostima pogreške u CP, izračunate prilikom izrade aerofotogrametrijskih modela u Agisoft Metashape softveru (Tabl. 56.). Zbog toga je točnost intervalnih aerofotogrametrijskih modela procijenjena na temelju CP uzeta kao referentna za određivanje nesigurnosti intervalnih modela. Konačne vrijednosti nesigurnosti za modele UAV-A i UAV-B dane su u tablici 56.

Tablica 56. Nesigurnost pojedinih modela primijenjena prilikom detekcije PVP

ID	Naziv modela	Datum aerofotogrametrijskog snimanja	Prostorna rezolucija (cm)	Pogreška u CP (m)[46]	Nesigurnost (m)[47]	Razina pouzdanosti
1	Model UAV-A	17. prosinca 2019.	1	0.023	0.023	95%
2	Model UAV-B	17. prosinca 2020.	1	0.025	0.025	95%

[46] RMSE određena na temelju kontrolnih točaka dodanih pri izradi modela u Agisoft Metashape softveru

[47] SD određena na temelju usporedbe izrađenog inicijalnog aerofotogrametrijskog modela (UAV-A) s odgovarajućim referentnim podacima prikupljenim terestričkim laserskim skenerom (TLS-A).

II. Utvrđeni intenzitet prostorno-vremenskih promjena uzrokovanih erozijom tla

Unutar promatranog jednogodišnjeg perioda (17. prosinca 2019. – 17. prosinca 2020.) utvrđene su intenzivne PVP, koje uključuju intenzivnu pojavu erozije, ali i akumulacije materijala (Tabl. 57). Na temelju izrađenih intervalnih modela i procijenjene nesigurnosti tih modela, te primijenjene razine pouzdanosti (95%) ukupno su unutar prostora jaruge Santiš PVP detektirane na površini od 255.99 m^2, pri čemu volumen ukupnih detektiranih promjena iznosi 25.01 m^3. Ukoliko se pogleda neto volumen PVP, koji iznosi -1.91 m^3, tada je vidljivo da unutar jednogodišnjeg razdoblja blago dominira erozija tla, ali i da je većina erodiranog materijala akumulirana unutar prostora jaruge, dok je samo manji dio (1.91 m^3) transportiran u more. Iz navedenog proizlazi da transportna energija površinskog otjecanja nije dovoljno snažna za transport svog erodiranog materijala u more.

Tablica 57. Ukupne PVP uzrokovane erozijom tla unutar jaruge Santiš (2019.-2020.)

Proces	Površinske promjene		Volumetrijske promjene		t/ha y^{-1}	RUSLE[48]
	m²	%	m³	%		
Erozija	158.51	61.92	13.46	53.82	12.74	20 - 50
Akumulacija	97.48	38.08	11.55	46.18	10.93	-
Ukupno	255.99	100	25.01	100	-	20 - 50

Erozija tla zabilježena je unutar jaruge Santiš na površini od ukupno 158.51 m², (61.92 % ukupne površine zahvaćene PVP) (Sl. 118.A). Unutar cijelog prostora jaruge Santiš zabilježeno je ukupno smanjenje volumena erodiranog materijala od 13.46 m³ (Sl. 118.B), koje obuhvaća oko 53.82 % svih zabilježenih volumetrijskih PVP. Zabilježena vrijednost volumena erodiranog materijala odgovara eroziji tla od 12.74 t/ha y^{-1}, što je manje od vrijednosti određenih za prostor poluotoka Santiš prema RUSLE metodi (Tabl 57; Panagos i dr., 2015).

Najintenzivnija erozija tla zabilježena je u središnjem dijelu jaruge, gdje je uslijed trošenja mekših naslaga došlo do urušavanja većeg komada bočne padine jaruge (Sl. 121; 123A). Osim ovog izdvojenog erozijskog događaja, većina zabilježene erozije vezana je uglavnom za prostor glavnog (Sl. 121, 123.B) i sporednog čela jaruge (Sl. 121; 122.B).

[48] Podaci za prostor otoka Paga i ostatka RH preuzeti sa https://esdac.jrc.ec.europa.eu/content/soil-erosion-water-rusle2015 (Panagos i dr., 2015).

Zabilježena intenzivna erozija tla unutar prostora dva postojeća čela jaruge Santiš može se izravno povezati s izraženim odronjavanjem naslaga tla, uzrokovanim postupnim retrogradnim pomakom linije čela jaruge. Prisutnost intenzivne erozije tla unutar dva čela jaruge Santiš u skladu je s rezultatima višegodišnjeg praćenja PVP (vidi 4.2.1.), ali i sa ranijim istraživanjima (Domazetović, 2018; Šiljeg i dr., 2021.) Također, osim na dva veća postojeća čela jaruge, erozija tla zabilježena je tijekom promatranog jednogodišnjeg razdoblja i na nekoliko novih, manjih čela jaruge (Sl. 121; 122.A), čije je formiranje započelo na blago nagnutoj travnatoj padini između sporednog i glavnog čela jaruge Santiš (Sl. 122.C). Utvrđene PVP ukazuju da je unutar jednogodišnjeg promatranog razdoblja postupno započeo proces erozije tla, a samim time i nastanak manjih čela jaruge, što dodatno potvrđuje da je proces erozije tla prisutan i aktivan unutar gotovo čitavog proučavanog prostora.

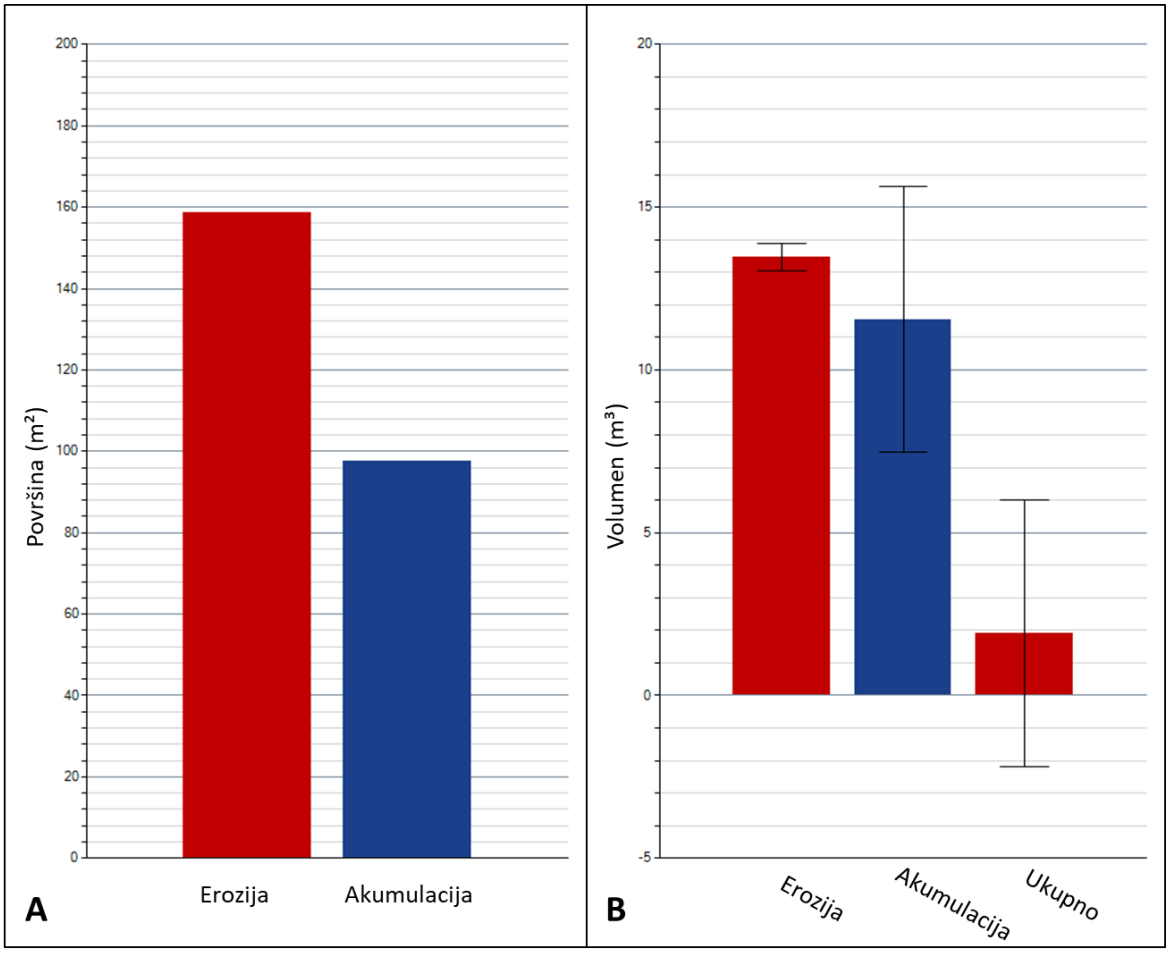

Slika 118. Površinski (A) i volumetrijski (B) pokazatelji ukupnih PVP unutar jaruge Santiš uzrokovanih erozijom tla u razdoblju od 17. prosinca 2019. do 17. prosinca 2020.

Iako detektirana nova čela dimenzijama i intenzitetom erozije tla znatno zaostaju za postojećim glavnim i sporednim čelom jaruge Santiš, njihova značaj za proučavanje i bolje

razumijevanje inicijacijske faze razvoja čela jaruge je vrlo velik. Iz prostorne distribucije novih čela vidljivo je da su se ona pretežito aktivirala na rubnim i plićim dijelovima naslaga tla, dok unutar središnjeg, debljeg dijela naslaga smeđeg tla nije zabilježena značajnija aktivacija. Takva distribucija novih čela može biti rezultat interakcije između površinskog i podzemnog otjecanja, koje u rubnim, plićim naslagama dovodi do saturacije tla i pojave intenzivnije erozije.

Prema klasifikaciji faza razvoja čela jaruge (Morgan, 2009) (Sl. 16.), vidljivo je da detektirana nova čela jaruge obuhvaćaju prve tri faze razvoja čela jaruge. Naime, stupanj razvijenosti novih čela jaruge varira od tek erozijom uklonjene vegetacije i formiranog inicijalnog udubljenja (I. i II. faza), sve do dijelova na kojima je došlo do začetka formiranja čela jaruge (III. faza), odnosno do formiranja "stepenice". Izostanak intenzivnije erozije tla potvrđuje da vjerojatno još uvijek nije započelo odronjavanje (IV. faza) i retrogradni pomak (V. faza) čela jaruge, što je i potvrđeno tragovima erozije tla zabilježenim prilikom provedenih terenskih istraživanja (Sl. 119.).

Slika 119. Začetak formiranja inicijalne "stepenice" unutar prostora novog čela jaruge zabilježeno prilikom terenskih istraživanja (16. lipnja 2020.)

Daljnjim djelovanjem procesa erozije tla vjerojatno će doći do daljnje evolucije novonastalih čela jaruge, pri čemu postepeno može doći do njihovog spajanja i formiranja jedinstvenog čela jaruge (Sl. 120). Takvo čelo jaruge presijecalo bi zaravnjeni dio jaruge Santiš,

te bi po morfometrijskim značajkama vrlo vjerojatno bilo slično današnjem glavnom čelu jaruge Santiš.

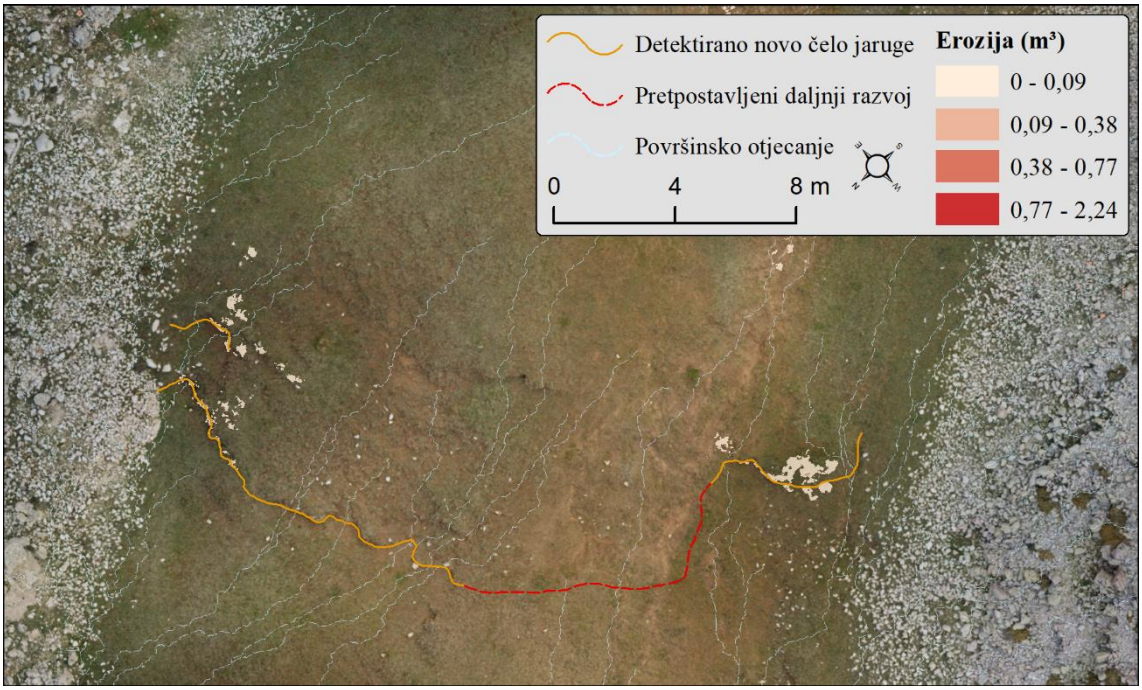

Slika 120. Lokacija formiranja novih čela jaruge (A) i pretpostavljeni budući razvoj (B)

Značajnija erozija, odnosno usijecanje površinskog otjecanja u podlogu zabilježeno je i na strmijim bočnim padinama donjeg dijela jaruge (Sl. 121; Sl. 123.C), ali i unutar glavnog kanala jaruge (Sl. 121; Sl. 123; D).

Za razliku od višegodišnjih detektiranih PVP (vidi 4.2.1.) unutar jednogodišnjeg razdoblja zabilježena je daleko veća prisutnost akumulacija tla, koja je prisutna na površini od 97.48 m^2 (odnosno 38.08 % ukupne površine zahvaćene PVP) (Sl. 118.A). Prostor akumulacije materijala može se raščlaniti na nekoliko značajnijih akumulacijskih zona (npr. prostor ispod glavnog čela jaruge (Sl.121; 123.E), prostor žala (Sl. 121; 123.F), prostor bočnih padina jaruge Santiš (Sl. 121; 123), itd.), te na brojne manje zone, unutar kojih je došlo do daleko slabije akumulacije materijala. Veće akumulacijske zone (osim prostora žala) pretežito su vezane za obližnje veće erozijske zone (npr. čelo jaruge), što svjedoči o tome da erodirani materijal najčešće nije transportiran daleko od mjesta s kojega je erodiran. Takva akumulacija materijala odgovara rezultatima ranije provedenih istraživanja (Domazetović, 2018; Šiljeg i dr., 2021). Unutar cijelog prostora zahvaćenog akumulacijom materijala zabilježeno je ukupno povećanje volumena od 11.55 m^3 (Sl. 118.B), koje obuhvaća oko 46.18 % svih zabilježenih volumetrijskih PVP.

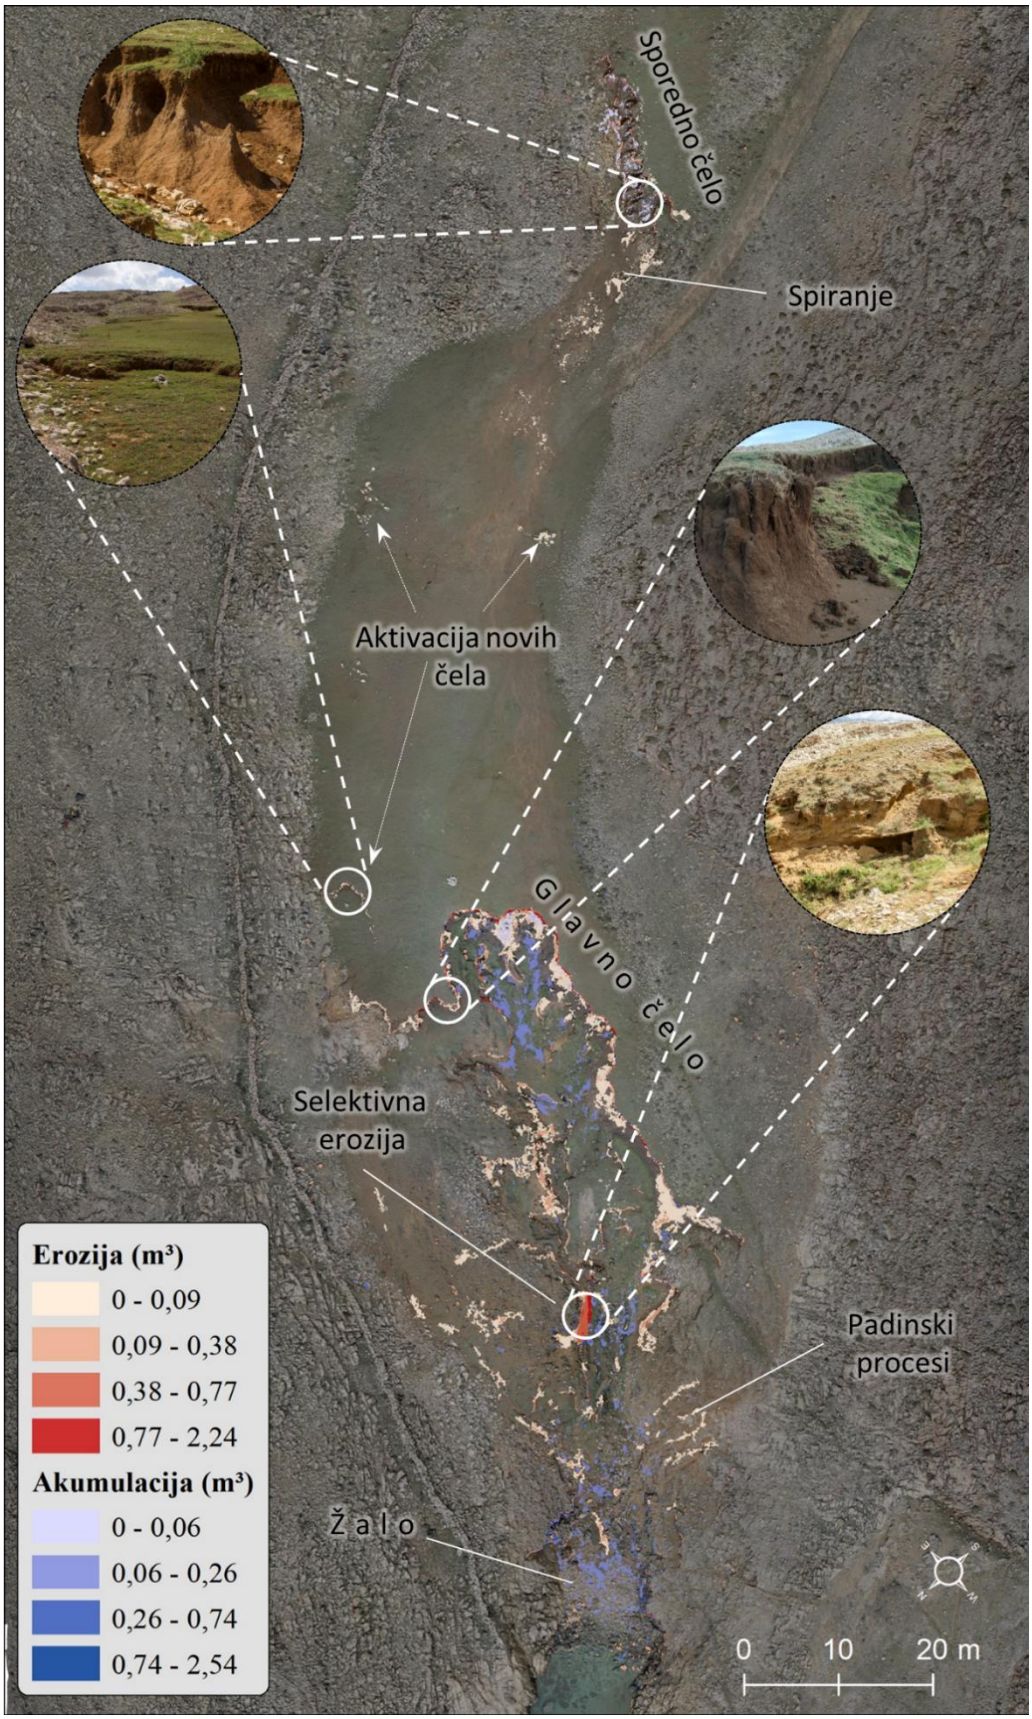

Slika 121. Prostorna distribucija PVP detektiranih unutar jednogodišnjeg razdoblja na prostoru jaruge Santiš

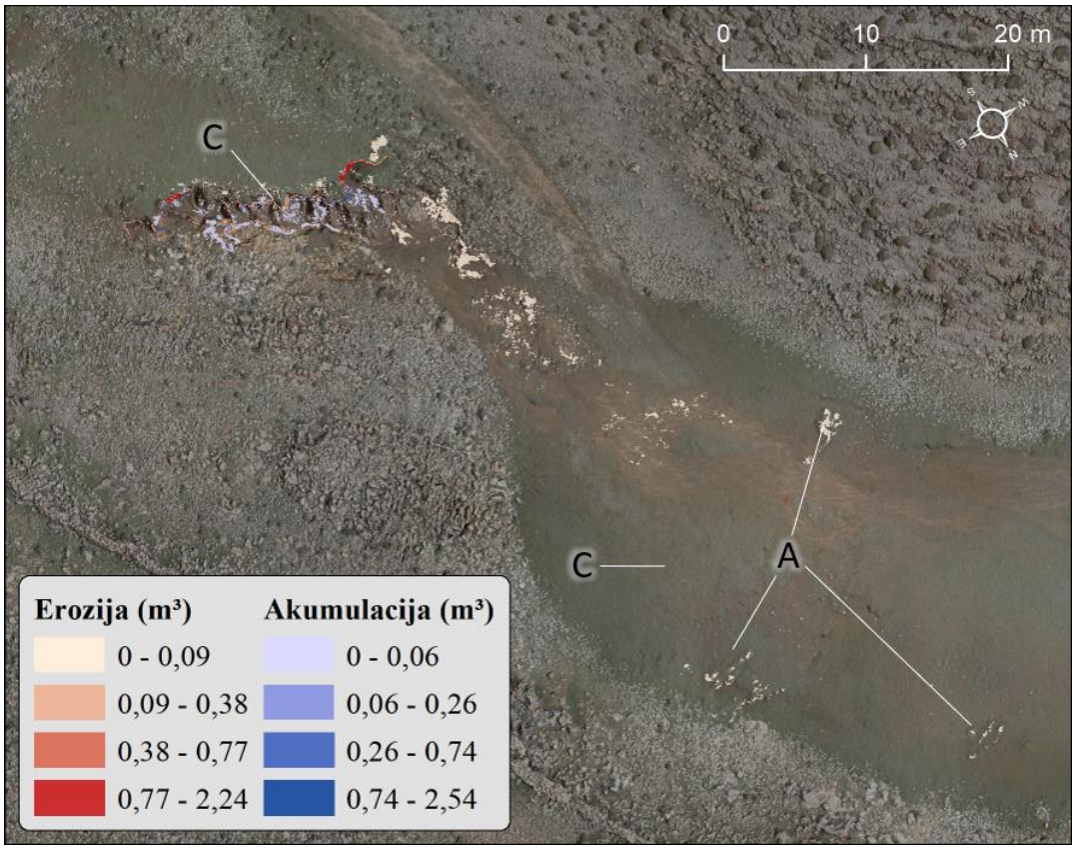

Slika 122. PVP detektirane unutar gornjeg dijela jaruge Santiš

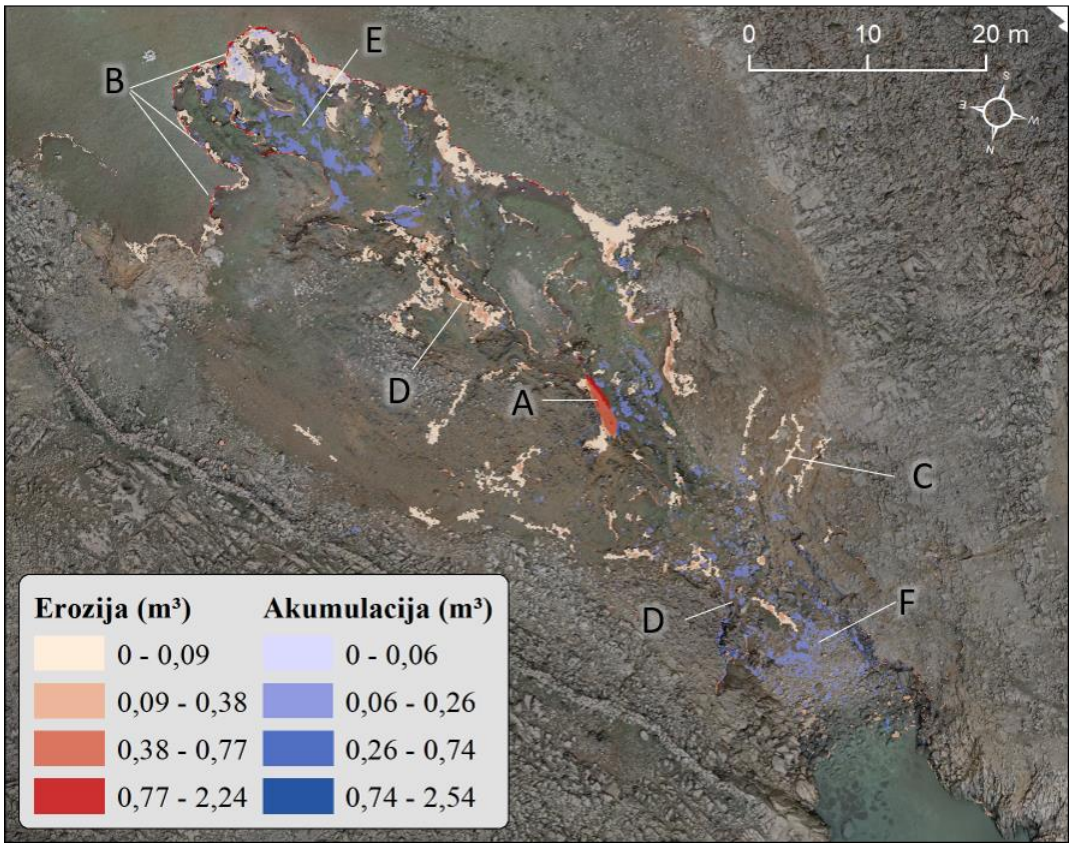

Slika 123. PVP detektirane u doljnjem dijelu jaruge Santiš

III. Odnos intenziteta erozije tla i litoloških značajki

Kartirane litološke jedinice na prostoru jaruge Santiš

Prilikom terenskog kartiranja ukupno je kartirano devet različitih litoloških jedinica, različitog prostornog obuhvata (Sl. 124.). Najrasprostranjenija litološka jedinica unutar kartiranog područja je vapnenac, odnosno *tektonski reklastizirani mudstone*, koji obuhvaća ukupno 7239.21 m^2 (52.15 % ukupne površine).

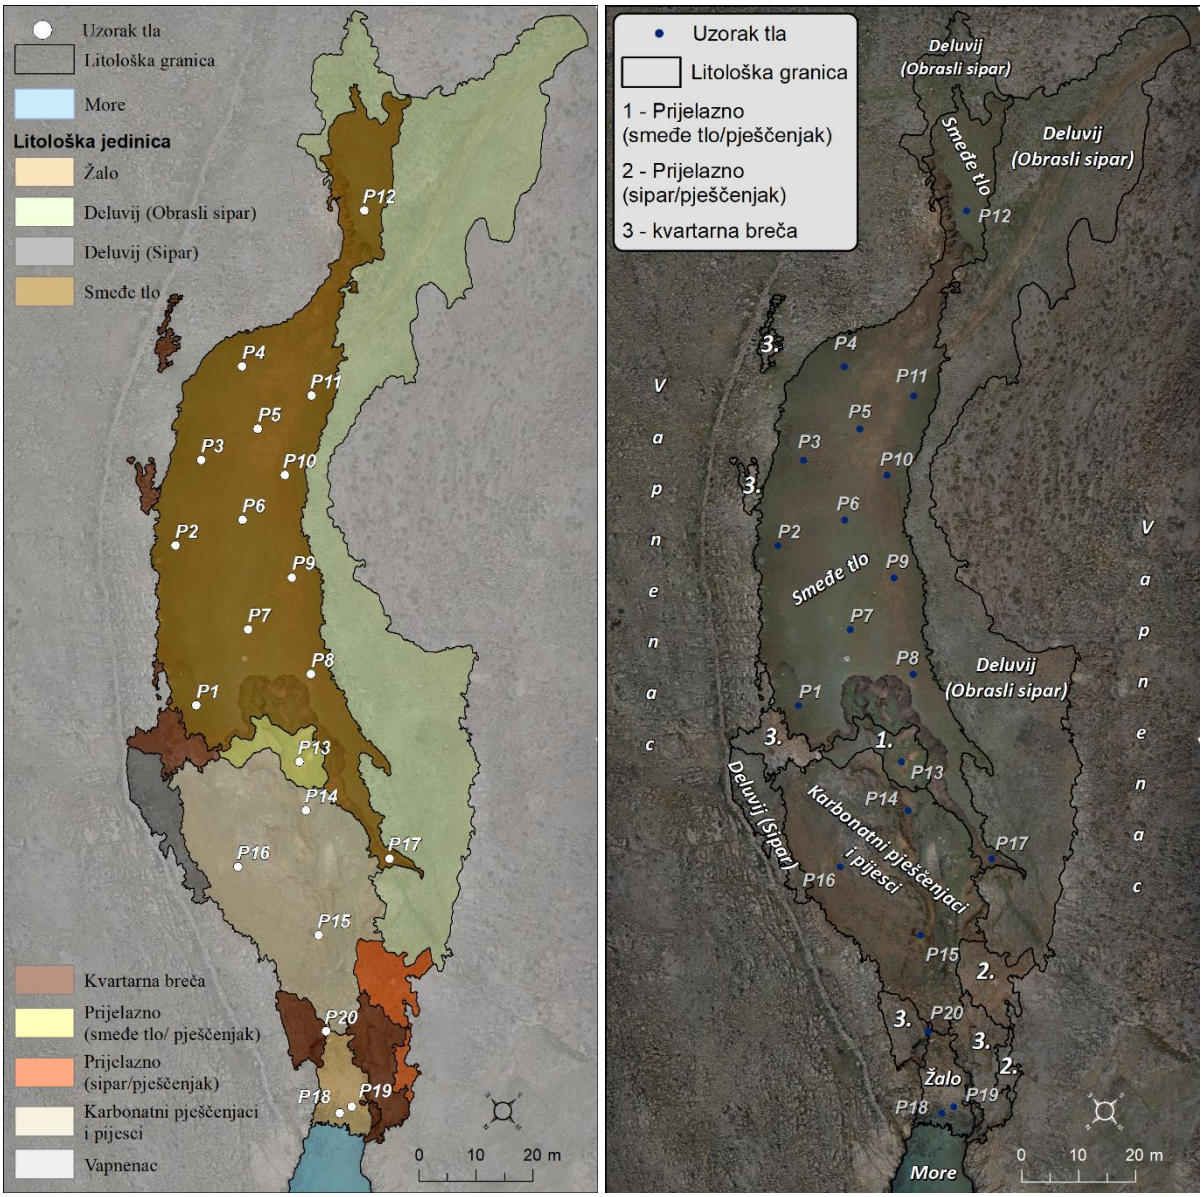

Slika 124. Izrađena detaljna (1:50) litološka karta jaruge Santiš

Karbonatni pješčenjaci i pijesci obuhvaćaju znatno manju površinu, u samom dnu jaruge Santiš (1065.34 m^2 (7.67 % ukupne površine)), unutar koje su pronađeni brojni nalazi fosiliziranih kopnenih gastropoda (lat. *Rumina decollata L.*) (Sl. 125.A). što svjedoči o

vjerojatnom limničkom postanku ovih naslaga (Bulić i Jurišić-Polšak, 2009.). S obzirom da pronađeni nalazi nisu bili naknadno ukopani u sediment, može se pretpostaviti da su ljušture istaložene istodobno sa sedimentacijom kvartarnog pješčenjaka, (Sl. 125.B), što bi dodatno potvrdilo činjenicu da su gastropodi živjeli u vrijeme nastanka ovih naslaga. Unutar ove jedinice primijećeni su tragovi selektivne erozije, ali i kalcificiranih ostaci nekadašnje grmolike vegetacije (Sl. 126.A), koji su svakako vrijedni daljnjeg istraživanja, posebice za rekonsturkciju paleogeneze prostora današnje jaruge Santiš.

Slika 125. Nalazi gastropoda *Rumina decollata L.* (A) pronađeni u naslagama karbonatnih pješčenjaka i pijesaka (B)

Uz karbonatne pješčenjake i pijeske vežu se još dvije manje jedinice, unutar kojih je litološki sastav vrlo heterogen. To su *prijelazno područje karbonatnih pješčenjaka i pijesaka prema smeđem tlu* (117.27 m^2 (0.84 % ukupne površine)), te *prijelazno područje karbonatnih pješčenjaka i pijesaka prema sipru* (146.42 m^2 (1.05 % ukupne površine)). Unutar ove dvije jedinice litološki sastav je previše heterogen da bi se ovaj prostor mogao sa sigurnošću svrstati pod jednu od većih jedinica, zbog čega je izdvojen kao zasebna jedinica.

Kvartarne breče (Sl. 126.B) obuhvaćaju površinu od ukupno 375.11 m^2 (2.70 % ukupne površine). Prostorna distribucija ove klase unutar kartiranog prostora je vrlo neujednačena, jer se izdanci ovih slojeva nalaze u povremenim disperziranim manjim površinama unutar cijelog područja istraživanja (Sl. 124). Postanak kvartarnih breča povezan je s intenzivnim *in-situ* rasjedanjem, praćenim dezintegracijom karbonatne podloge i formiranja klastita različitih dimenzija (Vlahović i dr., 2018). Nakon formiranja i sedimentiranja klastita, uslijed naknadne tektonizacije dolazi do izraženih dijagenetskih promjena, u prvom redu do kompakcije i

cementacije karbonatnih klastita (Benac, 2016; Vlahović i dr., 2018). Današnja disperzna prostorna distribucija karbonatnih breča odraz je relativno dugog razdoblja izloženosti ovih naslaga djelovanju različitih erozivnih agensa, pri čemu današnji izdanci predstavljaju ostatak većih cjelina (Vlahović i dr., 2018). Prisutnost naslaga karbonatnih breča unutar jaruge Santiš dokaz je intenzivnog rasjedanja, koje je vjerojatno i uzrokovalo nastanak inicijalnog udubljenja u reljefu, u kojemu je zatim došlo do formiranja breča, ali i sedimentacije mlađih naslaga smeđeg tla. Također, iz današnje disperzne distribucije unutar jaruge Santiš može se zaključiti da su prvotne naslage breče većim dijelom potrošene uslijed dugotrajne izloženosti erozivnom djelovanju, kako vode, tako i deflacije i abrazije, ili su prekrivene mlađim slojevima smeđeg tla.

Slika 126. Kalcificiranih ostaci grmolike vegetacije (A); kvartarne breče (B)

Naslage smeđeg tla na vapnencu, odnosno *kalkokambisoli* kartirane unutar prostora jaruge Santiš predstavljaju jednu od najvećih preostalih homogenih naslaga ovog tipa tla na otoku. Ukupna površina ovog tipa tla unutar kartiranog područja iznosi 2403.17 m^2 (17.31 % ukupne površine), pri čemu dubina naslaga varira od svega nekoliko cm, pa mjestimice i do nekoliko metara (npr. unutar prostora glavnog čela jaruge Santiš). Unutar ove jedinice je prilikom svih provedenih terenskih istraživanja primijećeno najviše recentnih tragova različitih izraženih potprocesa erozije tla (npr. EKK, brazdanje, uzmak čela jaruge, itd.). Upravo unutar ove litološke jedinice su formirana oba čela jaruge Santiš, ali i ranije opisana detektirana nova čela jaruge, zbog čega je jedna od hipoteza istraživanja bila da će najveći intenzitet PVP biti upravo unutar ovog tipa naslaga tla.

Prostor jaruge Santiš gotovo je sa svih strana okružen *deluvijem*, odnosno *siparom* (137.09 m^2 (0.99 % ukupne površine)), te posebice *obraslim siparom* (2143.51 m^2 (15.44 % ukupne površine)), koji predstavljaju prijelaz prema okolnom vapnenačkom prostoru. Može se pretpostaviti da su sipari i obrasli sipari nastali na bočnim padinama jaruge Santiš pod utjecajem padinskih procesa i postupnog trošenja okolnih viših vapnenačkih padina. Mjestimice je pod utjecajem padinskih procesa materijal iz sipara transportiran u unutrašnjost jaruge Santiš, čime dolazi do miješanja s naslagama karbonatnih pješčenjaka i smeđeg tla, povećavajući pritom heterogenost litološke podloge na zahvaćenim područjima, što je i potvrđeno provedenom granulometrijskom analizom (Sl. 127).

Posljednja kartirana jedinica obuhvaća prostor *žala* (128.77 m^2 (0.93 % ukupne površine)). Iako se radi o površinom relativno malom prostoru, unutar njega dolazi do interakcije različitih kompleksnih procesa. S jedne strane ovaj prostor karakterizira povremena sedimentacija materijala erodiranog i transportiranog iz jaruge i okolnih sipara, dok ga s druge strane karakterizira stalno preoblikovanje uzrokovano djelovanjem valova i morskih mijena.

Rezultati provedene granulometrijske analize (Sl. 127.) pokazuju da unutar prostora jaruge Santiš prevladavaju sedimenti homogenog sastava, odnosno vrlo sitne i sitne granulacije. U većini (85%) prikupljenih uzoraka prevladava najsitnija zabilježena frakcija (<0.25 mm), koja nije dominantna u samo tri uzorka (P18, P19, P20) prikupljenih na prostoru žala. U ta tri uzorka veća je zastupljenost materijala krupne i vrlo krupne frakcije, što je vjerojatno rezultat povećanog udjela šljunka i krupnijeg pijeska, nastalog djelovanjem mora, odnosno valova na postupno usitnjavanje akumuliranog većeg materijala. Zanimljivo je da veće razlike u granulaciji uzoraka prikupljenih na prostoru *smeđeg tla* i *karbonatnih pješčenjaka i pijesaka* nema, jer su unutar oba tipa podloge najzastupljenije sitna i vrlo sitna frakcija. Vidljiv je i povećan udio krupnijih frakcija u uzorcima prikupljenim u blizini aktivnog sipra (npr. P7; P8; P9; P17), ali i u uzorcima prikupljenim nizvodno od postojeće pristupne makadamske ceste (npr. P11; P12). Rastresiti krupniji materijal (sipar) transportiran je padinskim procesima i površinskim otjecanjem (poglavito s prostora makadamske ceste) prema središnjem dijelu naslaga smeđeg tla, mijenjajući pritom granulometrijski sastav.

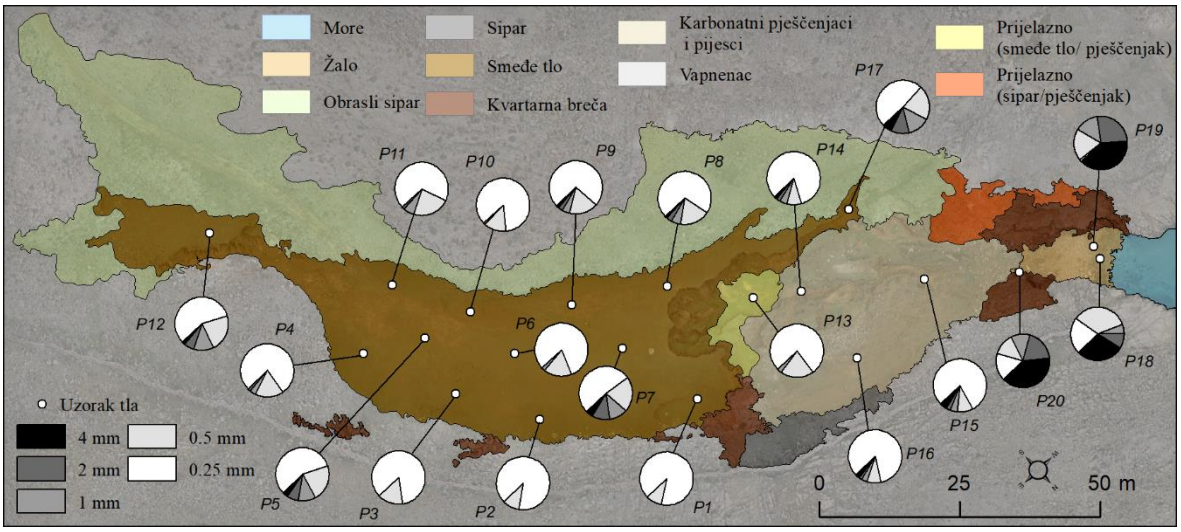

Slika 127. Granulometrijske značajke prikupljenih uzoraka

Unatoč velikom broju različitih litoloških jedinica, provedenom granulometrijskom analizom utvrđena je prevladavajuća homogenost naslaga tla unutar pojedine jedinice. Iz usporedbe zastupljenosti pojedinih granulometrijskih klasa (4 mm, 2 mm, 1 mm, 0.5 mm, 0.25 mm) u uzorcima tla prikupljenim unutar naslaga smeđeg tla (Sl. 128) vidljivo je da prevladavaju najsitnije (0.5 mm i 0.25 mm) frakcije. Zbog navedene homogenosti postojećih naslaga može se pretpostaviti da je i erodibilnost, odnosno podložnost različitim procesima erozije tla, unutar istih jedinica približno jednaka.

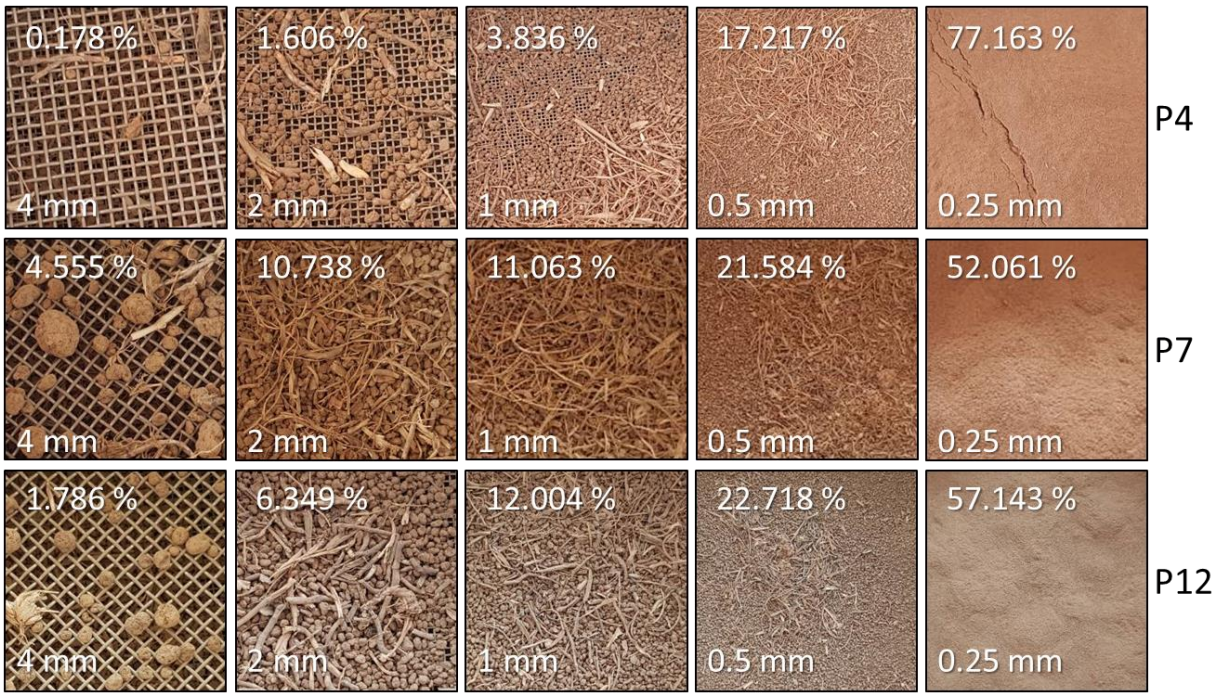

Slika 128. Zastupljenost pojedinih granulometrijskih klasa za tri odabrana uzorka tla

Ovisnost utvrđenih jednogodišnjih PVP o litološkoj osnovi

Ukoliko se pogleda raspodjela detektiranih jednogodišnjih PVP unutar kartiranih litoloških jedinica (Tabl. 58.; Sl. 129.), jasno je vidljiva izražena heterogenost distribucije zabilježenih promjena. Naime, dok unutar određenih područja nisu zabilježene značajnije PVP (npr. more, vapnenac, sipar, itd.), unutar drugih su zabilježene vrlo intenzivne promjene (npr. smeđe tlo ili karbonatni pješčenjaci i pijesci). Intenzitet erozije i akumulacije unutar pojedinih kartiranih litoloških jedinica je heterogen (Sl. 129.), pri čemu izražena erozija tla dominira isključivo unutar naslaga *karbonatnih pješčenjaka i pijesaka* te naslaga *smeđeg tla*, dok unutar svih ostalih litoloških jedinica prevladava akumulacija materijala.

Tablica 58. Odnos između kartiranih litoloških jedinica i utvrđenih jednogodišnjih PVP

#	Litološka jedinica	m²	% površine	Erozija		Akumulacija	
				Površina (m²)	Volumen (m³)	Povšina (m²)	Volumen (m³)
1	More	125.73	0.91	0.09	0.02	0.13	0.03
2	Deluvij (Sipar)	137.09	0.99	0.66	0.10	0.27	0.05
3	Prijelazno (sipar/pješčenjak)	146.42	1.05	6.10	0.15	1.83	0.21
4	Deluvij (Obrasli sipar)	2143.51	15.44	3.79	0.21	3.06	0.34
5	Vapnenac	7239.21	52.15	1.68	0.31	3.31	0.39
6	Kvartarna breča	375.11	2.70	2.51	0.33	6.91	1.23
7	Prijelazno (smeđe tlo/pješčenjak)	117.27	0.84	3.14	0.40	11.49	1.32
8	Žalo	128.77	0.93	3.07	0.30	17.27	2.24
9	Smeđe tlo	2403.17	17.31	70.15	4.84	27.40	2.33
10	Karbonatni pješčenjaci i pijesci	1065.34	7.67	67.32	6.80	25.81	3.41
Ukupno		13881.63	100.00	158.51	13.46	97.48	11.55

Izraženi nesrazmjer između intenziteta erozije i akumulacije unutar pojedinih litoloških jedinica ukazuje da se samo dio erodiranog materijala akumulira unutar istih jedinica, dok se preostali dio utjecajem površinskog otjecanja transportira prema nižim dijelovima jaruge. Primjerice, dok se oko 48% materijala erodiranog s prostora naslaga *smeđeg tla* akumulira unutar iste litološke jedinice, preostali dio se transportira dalje prema jedinicama koje bilježe izraženiju akumulaciju materijala (npr. *prijelazno (smeđe tlo – pješčenjak)*. Isti je

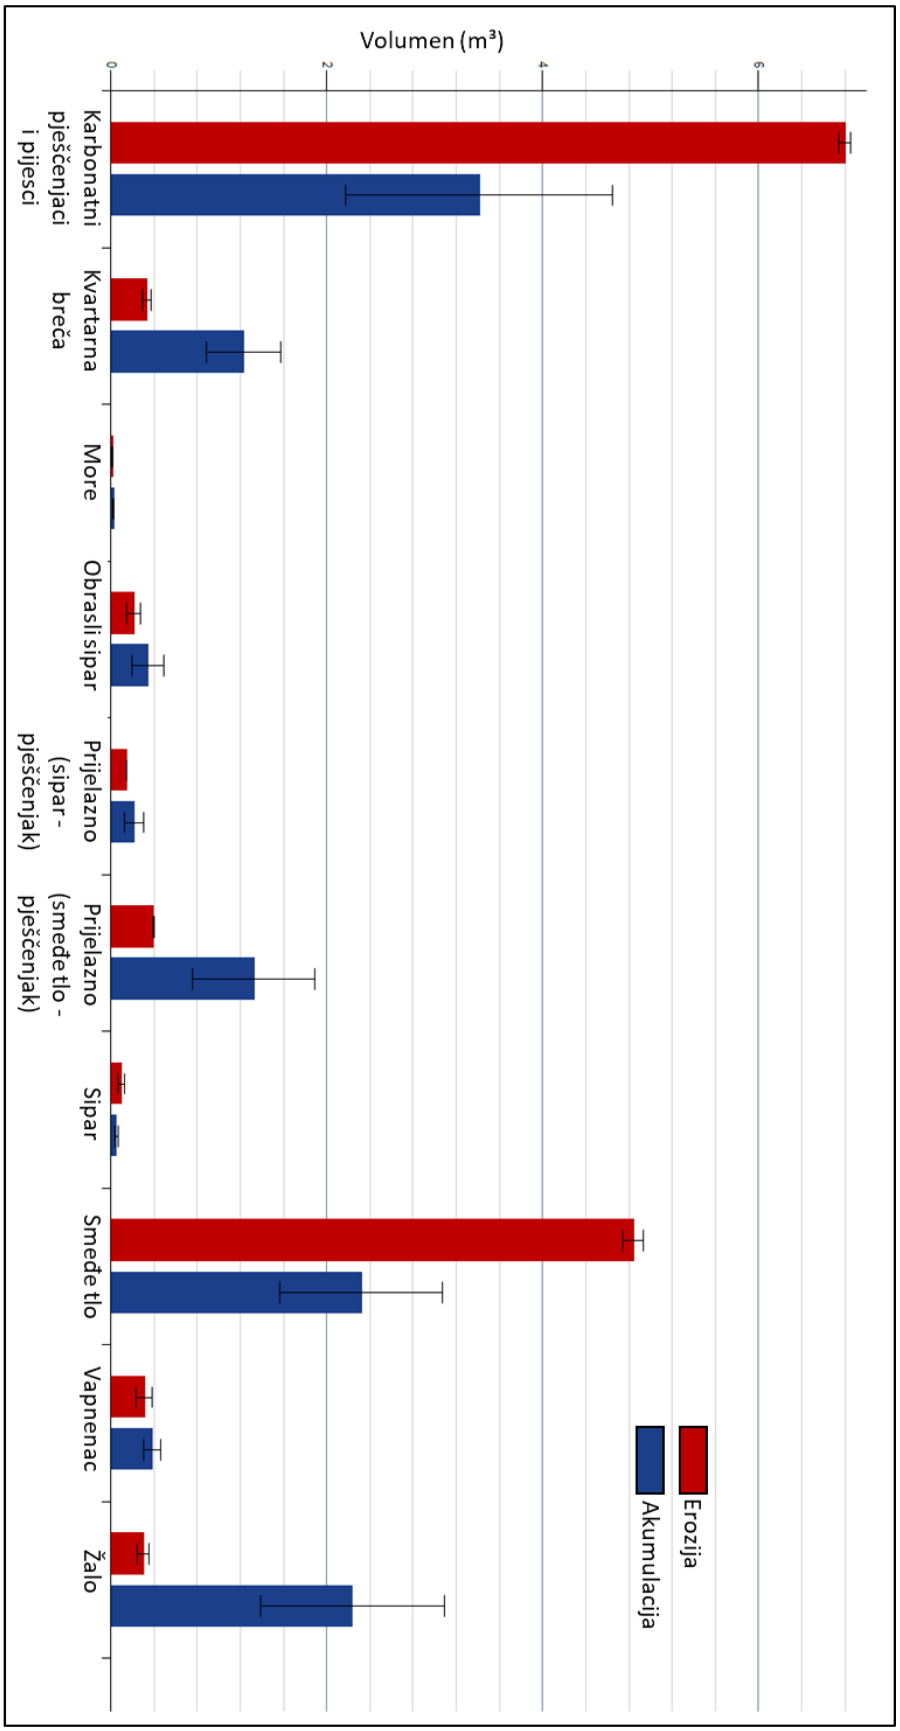

Slika 129. Raščlamba volumetrijskih promjena uzrokovane erozijom tla prema kartiranim litološkim jedinicama (17. prosinca 2019. - 17. prosinca 2020.)

slučaj i s naslagama *karbonatnih pješčenjaka i pijesaka*, s kojih površinsko otjecanje odnosi oko 50% svog erodiranog materijala. Izraženu akumulacijsku zonu predstavlja prostor *žala*, unutar kojega se akumulira većina materijala koji površinskim otjecanjem i padinskim procesima bude transportiran s preostalih litoloških jedinica.

Nerazmjerna distribucija i intenzitet detektiranih PVP unutar istraživanog područja mogu se uočiti usporedbom površine pojedinih litoloških jedinica s udjelom detektirane erozije i akumulacije (Sl. 130.). Iako naslage *karbonatnih pješčenjaka i pijesaka* te *smeđeg tla* obuhvaćaju tek oko 25% ukupne površine istraživanog područja, unutar njih je detektirano 86.48% sve ukupne detektirane erozije tla, te 49.70 % ukupne detektirane akumulacije materijala.

S druge strane, unutar pojedinih litoloških jedinica koje prekrivaju znatno veće površine gotovo da nije došlo do nikakvih prostorno-vremenskih promjena. Primjerice, iako *vapnenac* i *obrasli sipar* prekrivaju gotovo 70 % ukupne površine područja istraživanja, unutar njih je zabilježen zanemariv intenzitet erozije i akumulacije materijala. Uzrok tome je daleko manja erodibilnost ovih litoloških jedinica, u odnosu na eroziji podložnije jedinice, poput smeđeg tla ili karbonatnog pješčenjaka.

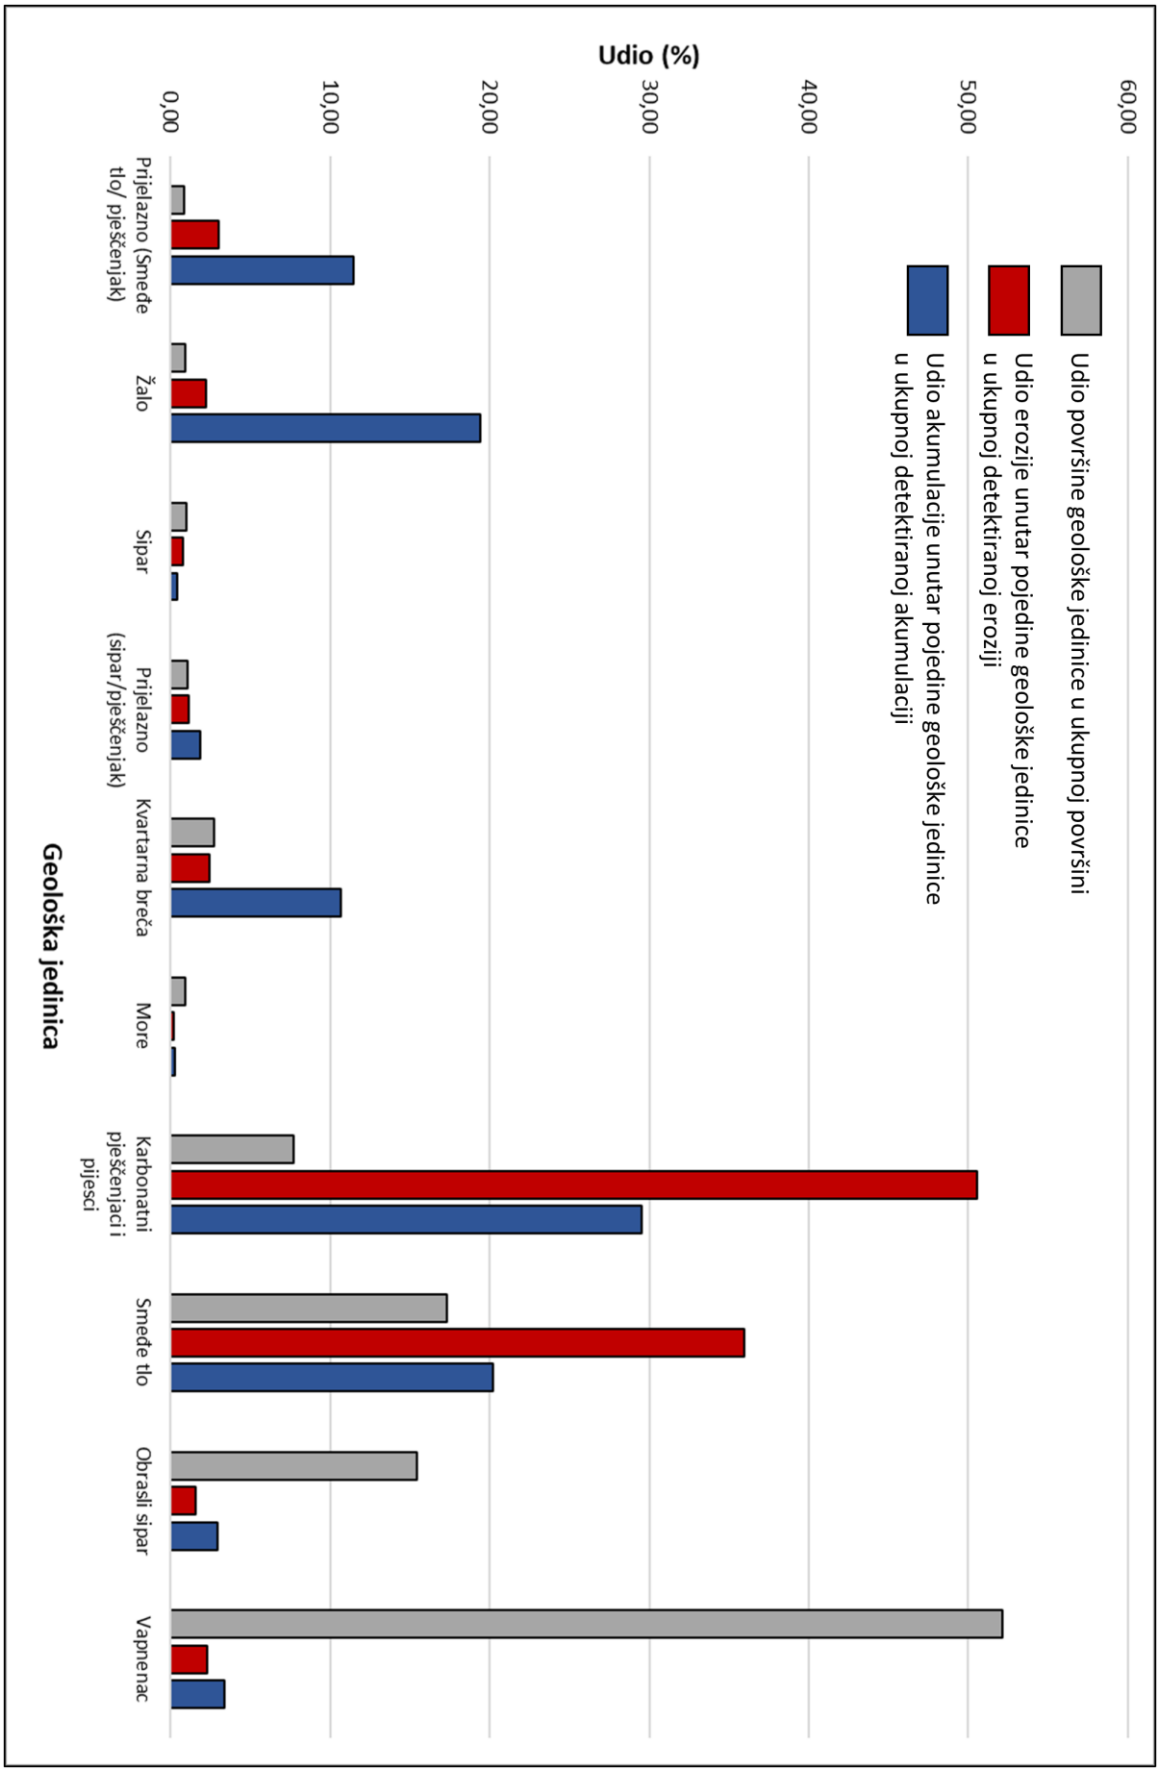

Slika 130. Usporedba površine pojedine litološke jedinice i detektiranih PVP

Najrasprostranjenija i najintenzivnija erozija materijala zabilježena je unutar litoloških jedinica *karbonatnih pješčenjaka i pijesaka* (zahvaćeno 67.32 m² površine, unutar koje je erodirano 6.80 m^3 materijala), te *smeđeg tla* (zahvaćeno 70.15 m² površine, unutar koje je erodirano 4.84 m^3 materijala). Navedene PVP promjenama odgovaraju brojnim recentnim tragovima erozije tla, koji su unutar ovih litoloških jedinica zabilježeni tijekom provedenih terenskih istraživanja (npr. Sl. 131; 132.), što potvrđuje točnost izrađenog DMD-a. Iako je pretpostavka bila da će intenzitet erozije tla biti najveći unutar naslaga smeđeg tla, najintenzivnija erozija tla zabilježena je unutar naslaga karbonatnih pješčenjaka i pijesaka (Sl. 129.). Uzrok tome je intenzivno trošenje mekših dijelova karbonatnih pješčenjaka, uslijed kojih je unutar središnjeg kanala jaruge došlo do pojave selektivne erozije (Toševski i dr., 2012.), odnosno odronjavanja komada čvršćeg dijela karbonatnih pješčenjaka (Sl. 131. i 132.A). Navedeno odronjavanje uzrokovano je povremenim koncentriranim površinskim otjecanjem, što je i dokazano izrađenim modelom površinskog otjecanja.

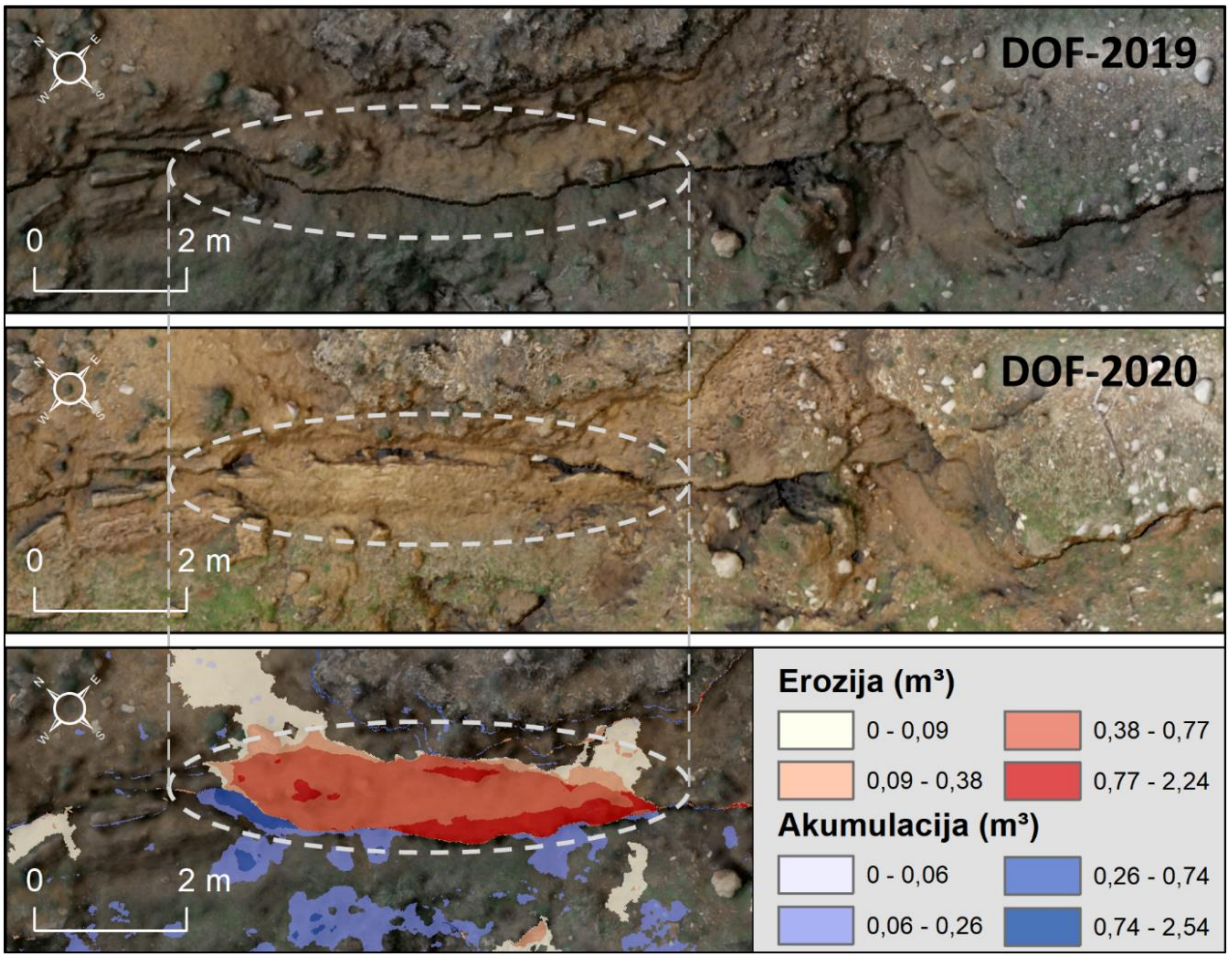

Slika 131. Volumetrijske PVP uzrokovane utjecajem selektivne erozije na odronjavanje dijela horizontalnog sloja karbonatnih pješčenjaka

Iako ovakvi erozijski događaji rezultiraju intenzivnim PVP, odnosno erodiranjem znatnih količina materijala, njihova učestalost ovisi o izdržljivosti karbonatnih pješčenjaka, zbog čega se ovako nagle promjene vjerojatno događaju jednom u nekoliko godina. Tome svjedoči i činjenica da iste promjene nisu zabilježene tijekom ranijih istraživanja (Domazetović, 2018; Šiljeg i dr., 2021.).

Osim navedenog istaknutog erozijskog događaja, unutar naslaga karbonatnih pješčenjaka i pijesaka su uočeni i drugi tragovi selektivne erozije slabijeg intenziteta. Trošenjem mekših dijelova pjeskovitih naslaga postepeno je došlo do izbijanja kalcificiranih ostataka nekadašnje grmolike vegetacije (Sl. 132.B).

Slika 132. Odronjeni komad kompaktnijeg dijela naslaga karbonatnog pješčenjaka (A) i izdanci grmolike kalsificirane vegetacije (B)

Unutar naslaga smeđeg tla zabilježena je najveća raznolikost erozijskih formi, pri čemu je intenzivna erozija tla prvenstveno detektirana unutar postojećeg glavnog čela jaruge Santiš, gdje je došlo do intenzivnog odronjavanja naslaga tla (engl. *mass failure*) uslijed retrogradnog pomicanja čela jaruge (Sl. 133.D). Uz intenzivno odronjavanje materijala s glavnog čela jaruge, na izloženim padinama glavnog i sporednog čela jaruge zabilježena je i erozija kišnih kapljica

(Sl. 133.A) te raširenospiranje tla (engl. *sheet erosion*), koje je utjecalo na formiranje različitih erozijskih formi (Sl. 133.B). Unutar naslaga smeđeg tla mjestimice su zabilježeni i recentni tragovi brazdanja (engl. *rill erosion*), koje je prisutno pretežito na ogoljenim i izloženim, te blago nagnutim dijelovima naslaga tla (Sl. 133. C).

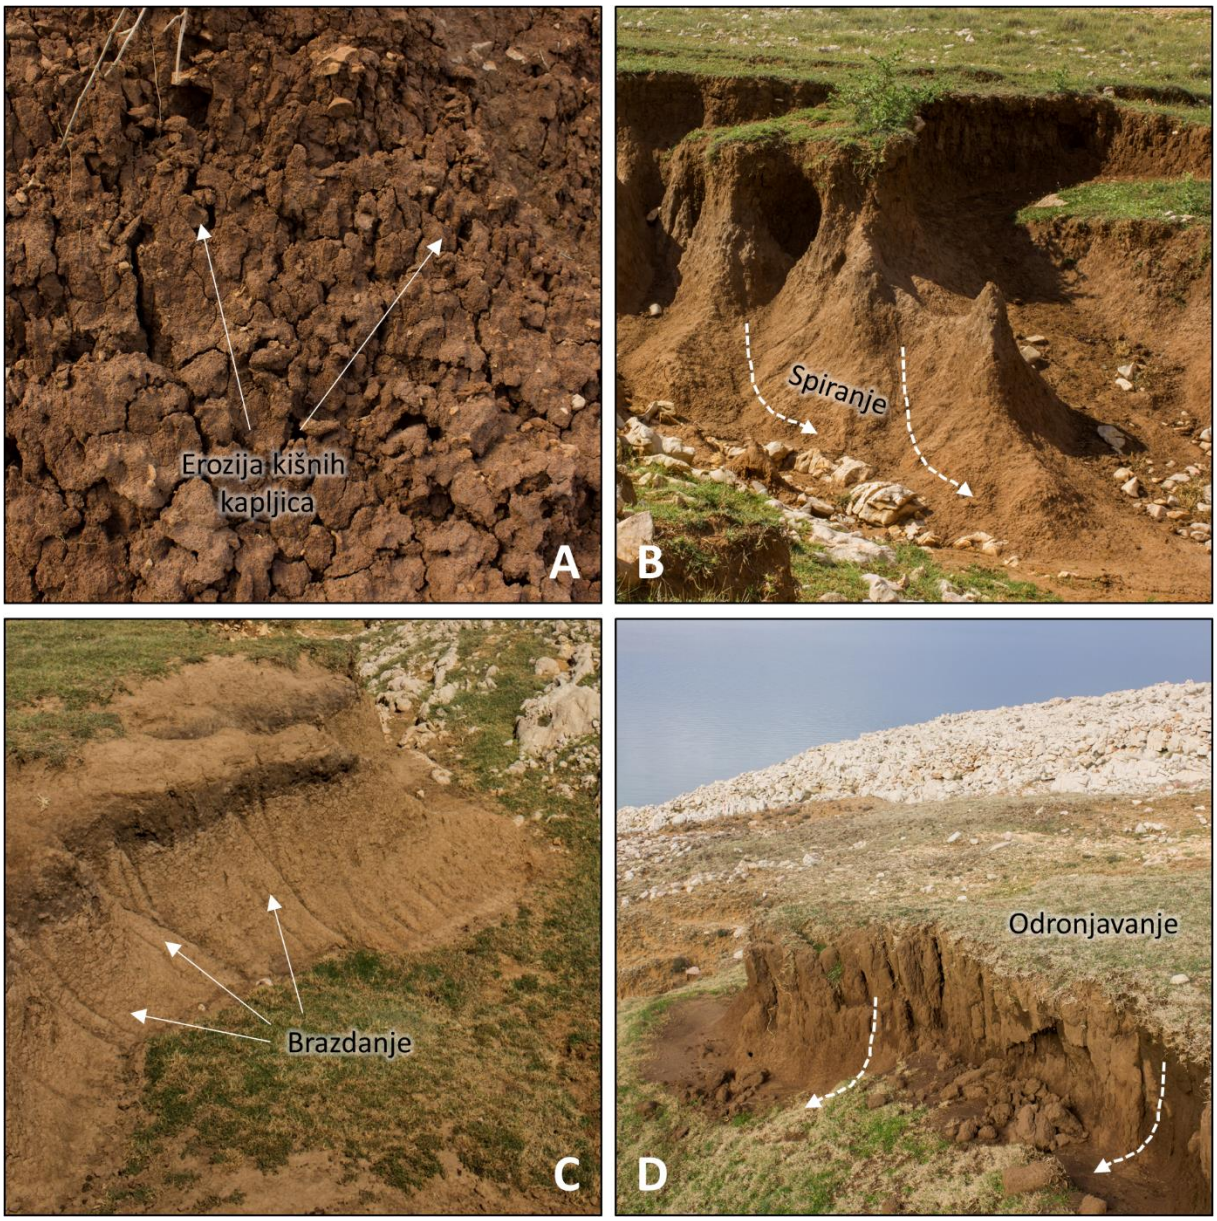

Slika 133. Tragovi recentne erozije tla unutar naslaga smeđeg tla: A - erozija kišnih kapljica ; B - spiranjem naslaga tla; C - brazdanje na nagnutim naslagama tla; D - odronjavanje naslaga tla s prostora glavnog čela jaruge Santiš

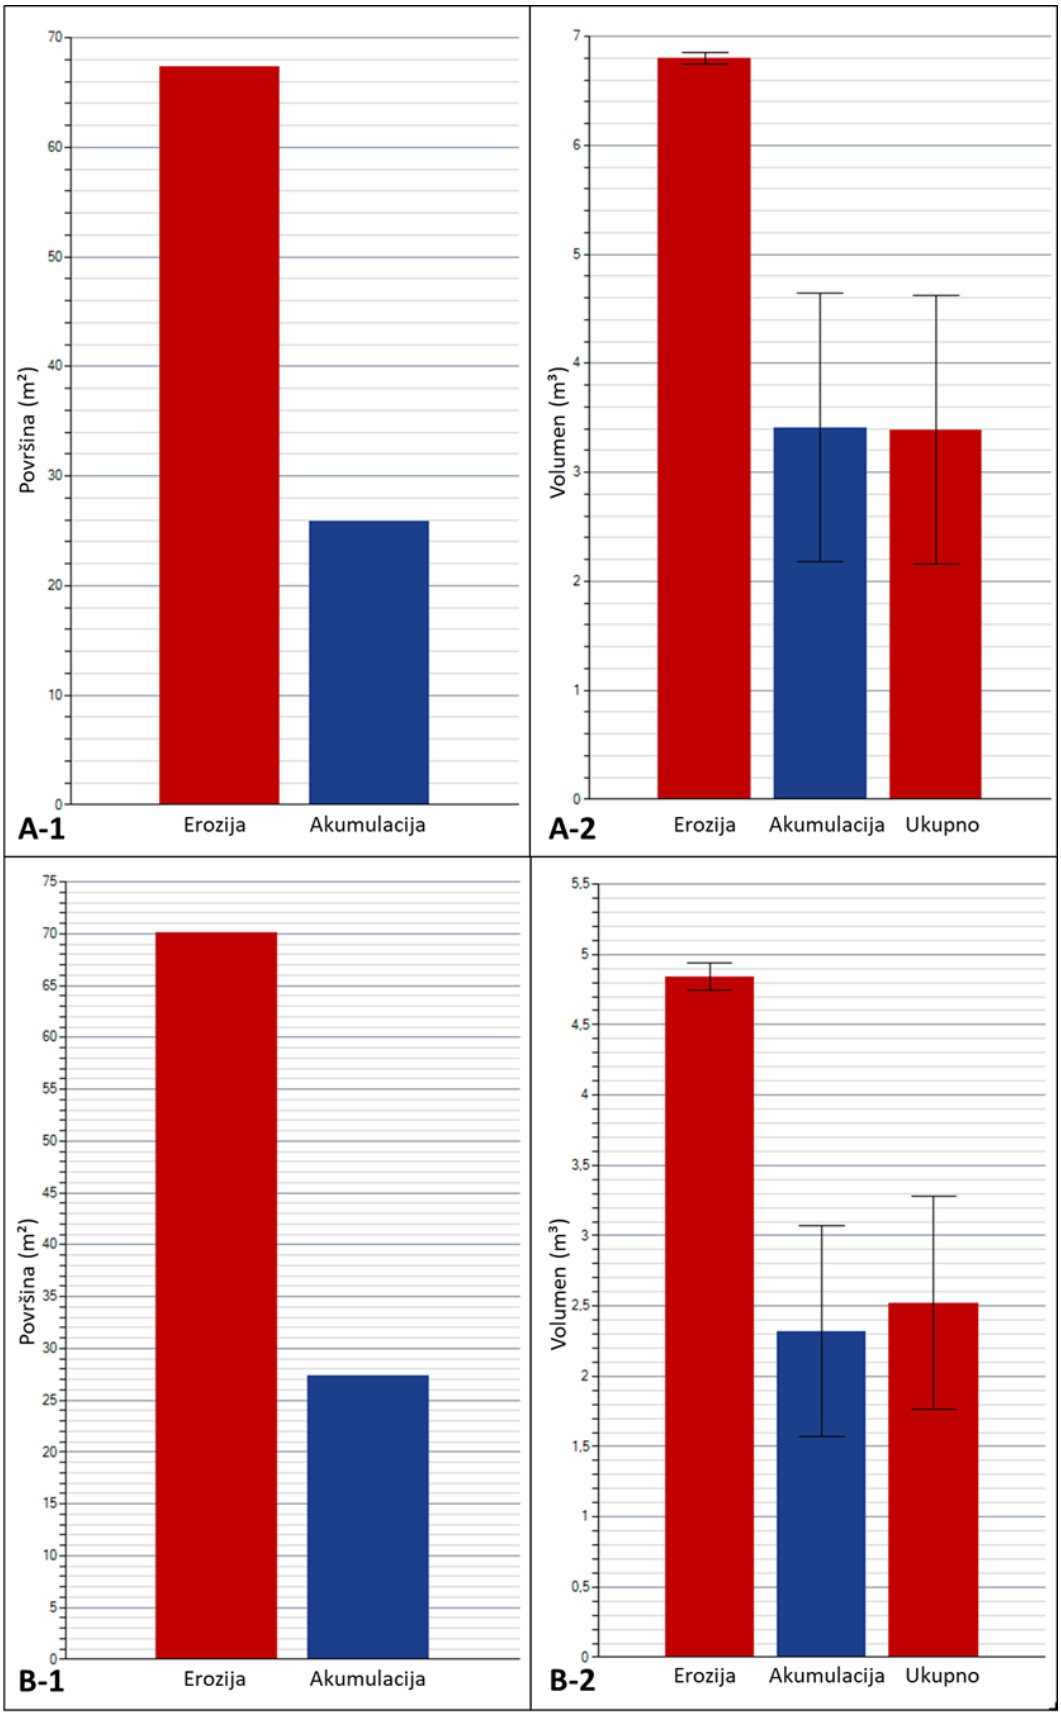

Slika 134. Površinske (1) i volumetrijske (2) PVP detektirane unutar litoloških jedinica karbonatni pješčenjaci i pijesci (A) i smeđe tlo (B)

Litološke jedinice *žala* i *prijelaznog prostora između smeđeg tla i pješčenjaka* predstavljaju prostor dominantne akumulacije materijala, unutar kojega je akumulirano ukupno 3.56 m^3 materijala. *Prijelazni prostor između smeđeg tla i pješčenjaka* obuhvaća prostor izravno ispod glavnog čela jaruge Santiš, unutar kojega je zabilježena ranije opisana intenzivna erozija tla. Iako se dio erodiranog materijala površinskim otjecanjem transportira dalje od čela jaruge, većina se taloži u prvih nekoliko metara ispod čela (Domazetović, 2018; Šiljeg i dr., 2021.). Upravo taj materijal zabilježen je na izrađenom DMD-u kao akumulacija materijala (Sl. 123; 136.B.). Prostor *žala* predstavlja završni dio jaruge Santiš, u kojemu završava većina tokova iz slivnog područja jaruge Santiš (Sl. 123). Samim time prostor *žala* predstavlja završnu akumulacijsku zonu, unutar koje se taloži sav materijal transportiran s prostora jaruge površinskim i podzemnim otjecanjem. Međutim, kao što su pokazala ranija istraživanja (Domazetović i dr., 2018; Šiljeg i dr., 2021.) gotovo čitav prostor *žala* zahvaćen je djelovanjem morskih mijena i valova, što utječe na remećenje i daljnje transportiranje inicijalno akumuliranog sedimenta. Utjecaj morskih mijena i valova utječe i na pomicanje većih oblutaka, koje je također zabilježeno u izrađenom DMD-u. Jedina iznimka unutar početnog prostora *žala* je pojava izraženog linearnog usijecanja kanala jaruge, uzrokovanog koncentriranim površinskim otjecanjem, do kojega je došlo uslijed intenzivnijih oborina (Sl. 135.B), što potvrđuje i generirani model otjecanja (*flow accumulation*).

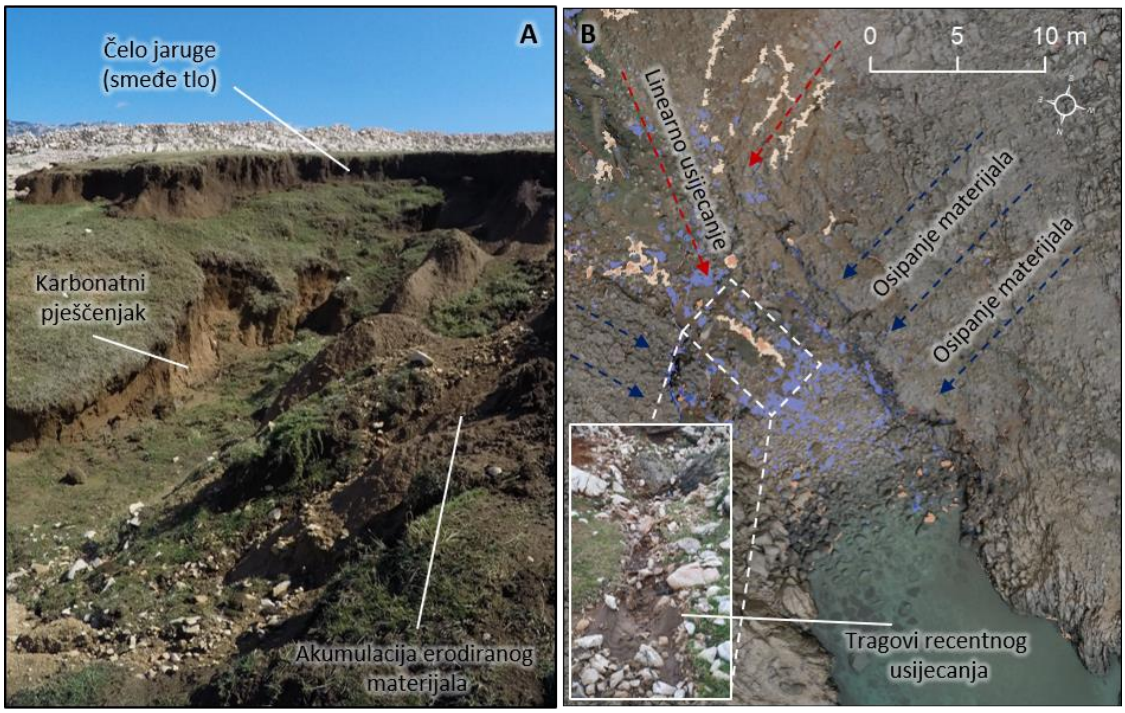

Slika 135. Tragovi recentnih PVP - *prijelazni prostor (smeđe tlo/pješčenjak)* (A) i *žalo* (B)

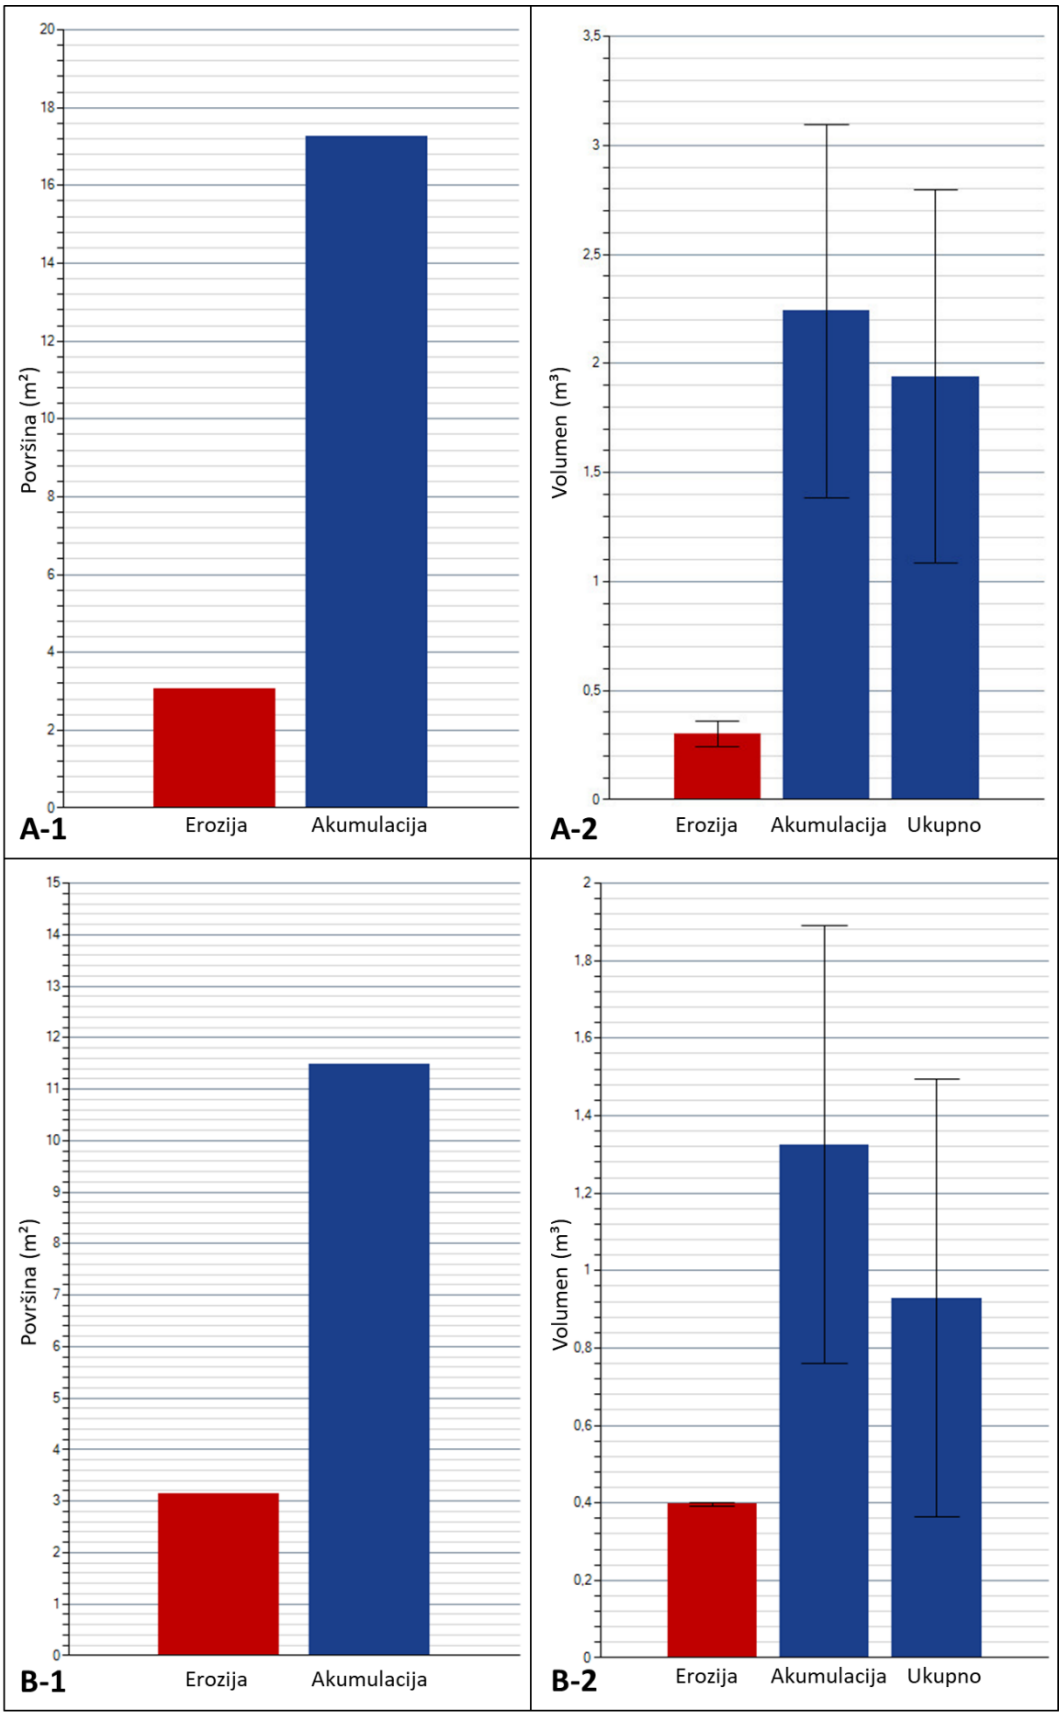

Slika 136. Površinske (1) i volumetrijske (2) PVP detektirane unutar litoloških jedinica žalo (A) i prijelazno (smeđe tlo/pješčenjak) (B)

Karbonatne breče obuhvaćaju tek oko 2.70 % ukupne površine istraživanog područja, unutar kojega je zabilježeno 0.33 m^3 erozije materijala i 1.23 m^3 akumulacije materijala (Sl. 139.A1 i A2). S obzirom da karbonatne breče uz vapnenac predstavljaju najtvrđu i na eroziju najotporniju litološku jedinicu nije vjerojatno da su detektirane PVP rezultat trošenja same breče, već erodiranja i akumuliranja materijala iznad njih. Većina naslaga karbonatnih breča unutar područja istraživanja nalazi se u dnu jaruge Santiš, s obje strane *žala* (Sl. 124.). Navedene naslage okružene su strmim padinama s kojih se pod utjecajem padinskih procesa rastresiti materijal (deluvij) postepeno transportira prema prostoru žala, preko karbonatnih breča. Premještanje materijala preko karbonatnih breča pod utjecajem padinskih procesa predstavlja PVP, koja je kao takva detektirana na izrađenim intervalnim modelima, potvrđujući pritom točnost provedenih analiza. Tragovi transporta rastresitog materijala zabilježeni su prilikom terenskih istraživanja na prostoru orijentacijske točke OT 7 (Sl. 137.). Unutar prostora OT7 je u jednogodišnjem razdoblju između prvog i drugog aerofotogrametrijskog snimanja došlo do intenzivne akumulacije rastresitog materijala različite granulacije, koji je gotovo u potpunosti zatrpao orijentacijsku točku. Debljina akumuliranog materijala mjestimice je prelazila 10 cm, zbog čega je prije drugog aerofotogrametrijskog snimanja bilo potrebno otkopati i očistiti orijentacijsku točku (Sl. 137.). Takva akumulacija materijala odgovara detektiranom intenzitetu PVP, prema kojima prosječna akumulacija materijala na prostoru karbonatnih breča iznosi oko 18 cm.

Slika 137. Akumulacija na litološkoj jedinici karbonatna breča (OT 7) uslijed transportiranja rastresitog materijala djelovanjem padinskih procesa

Iako *vapnenac* obuhvaća najveći dio područja istraživanja (7239.21 m^2, odnosno 52.15 % ukupne površine), unutar njega su zabilježene gotovo zanemarive PVP (Sl. 139.B1 i B2),

koje uključuju 0.31 m^3 erodiranog i 0.39 m^3 akumuliranog materijala. Relativno proporcionalan odnos između erodiranog i akumuliranog materijala ukazuje na to da su utvrđene PVP uglavnom posljedica pomicanja i premještana odronjenih vapnenačkih komada stijena, uslijed djelovanja padinskih procesa na strmim bočnim padinama oko jaruge Santiš. Također, pomicanje odronjenih komada stijena često je uzrokovano i kretanjem ovaca po strmoj vapnenačkoj podlozi, o čemu svjedoči i uginula ovca koja je na temelju izrađenih intervalnih modela zabilježena kao akumulacija (Sl. 138).

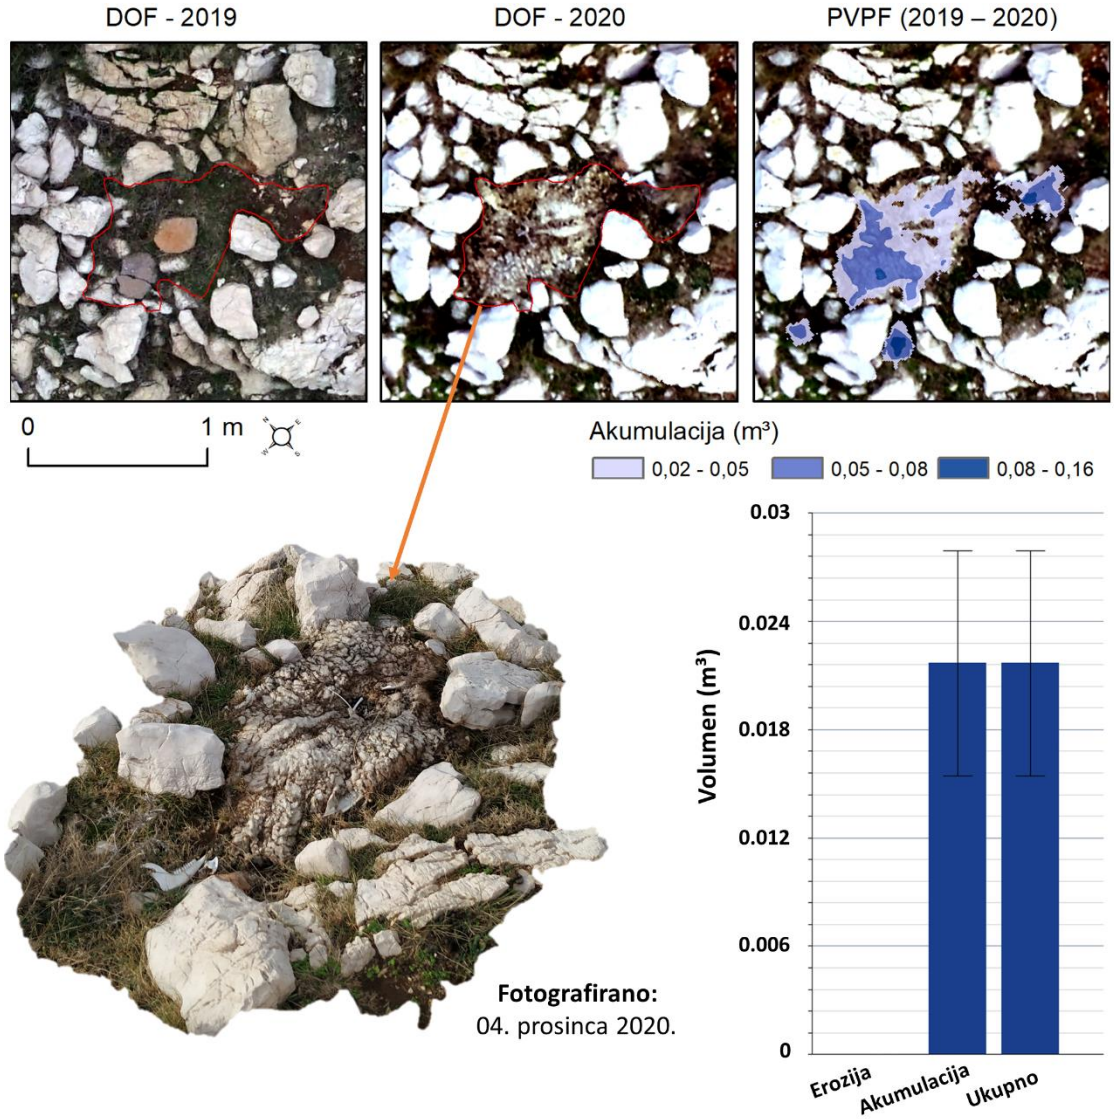

Slika 138. Uginula ovca zabilježena kao akumulacija unutar litološke jedinice vapnenac

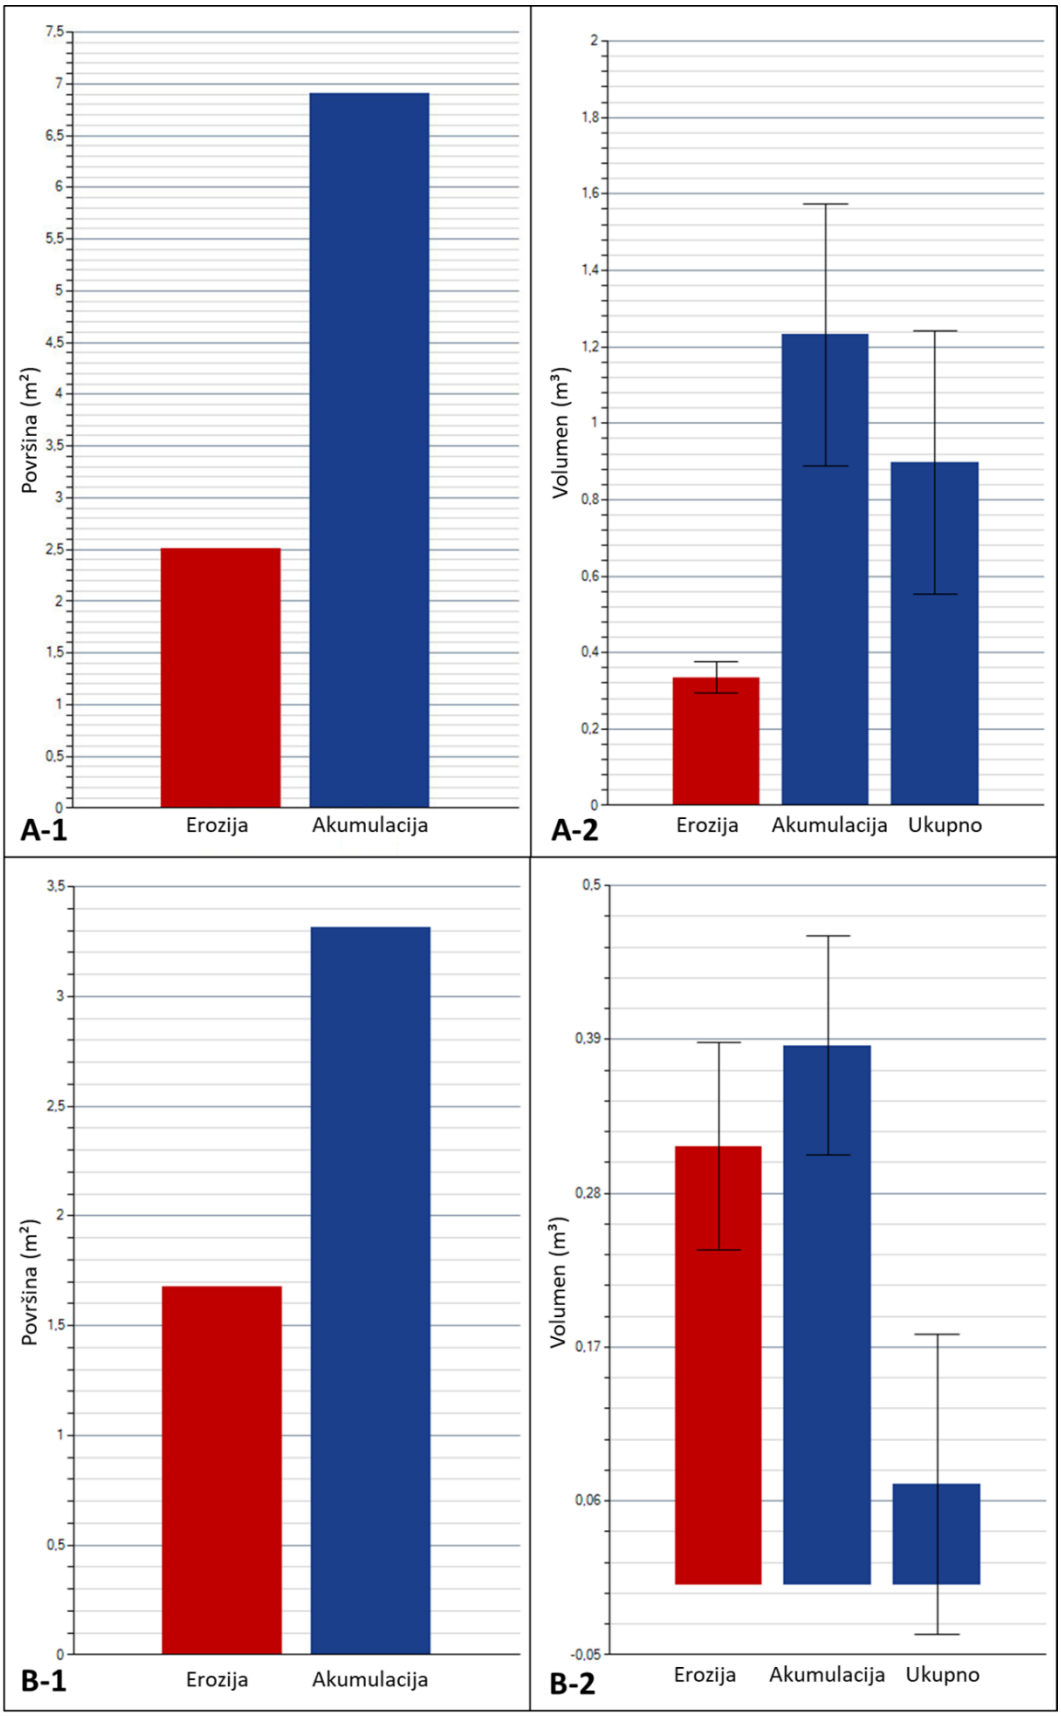

Slika 139. Površinske (1) i volumetrijske (2) PVP detektirane unutar litoloških jedinica kvartarna breča (A) i vapnenac (B)

IV. Ovisnost između utvrđenih PVP i morfometrijskih značajki

Analiza ovisnosti PVP o morfometrijskim značajkama napravljena je na temelju nagiba padina, kojega se u mnogobrojnim istraživanjima smatra glavnim predisponirajućim kriterijem za inicijaciju erozije tla (Valentin i dr., 2005; Chaplot i dr., 2013). Pri tome je osnovna pretpostavka provedene usporedbe bila da će unutar odabranog područja istraživanja najveći volumetrijski (m^3) intenzitet erozije tla biti zabilježen unutar najstrmije klase nagiba padine (> 55°). Prvenstveno je takva pretpostavka postavljena zbog strmih postojećih čela jaruge, unutar kojih su tijekom terenskih istraživanja zabilježeni intenzivni tragovi recentne erozije tla. Pokazatelji detektiranih površinskih i volumetrijskih PVP dani su u tablici 59.

Tablica 59. Odnos nagiba padine i utvrđenih jednogodišnjih PVP

#	Nagib padine (°)	m²	% površine	Erozija		Akumulacija	
				Povšina (m²)	Volumen (m³)	Povšina (m²)	Volumen (m³)
1.1	Ravnice (0 – 2)	222.90	1.61	0.27	0.02	1.15	0.12
1.2	Blago nagnuti tereni (2 – 5)	670.68	4.83	1.63	0.08	5.36	0.60
1.3	Nagnuti tereni (5 – 12)	3775.70	27.20	10.81	0.72	19.10	2.21
1.4	Značajno nagnuti tereni (12 – 32)	6751.48	48.64	55.63	3.10	43.84	4.83
1.5	Vrlo strmi tereni (32 – 55)	1982.45	14.28	52.63	3.09	16.76	1.67
1.6	Strmci (> 55)	478.42	3.45	37.54	6.45	11.27	2.12
Ukupno		13881.63	100	158.51	13.46	97.48	11.55

Iz rezultata provedene analize vidljivo je da je preko 70% sve erozije tla zabilježeno unutar strmaca (6.45 m³, odnosno 47.92 % ukupne erozije) te unutar značajno nagnutih terena (3.10 m³, odnosno 23.03 % ukupne erozije). Slijede vrlo strmi tereni s 3.10 m³ (22.96 % ukupne erozije). Najmanje erozije zabilježeno je unutar klase *ravnica, blago nagnutih* te *nagnutih terena* na koje otpada samo oko 6 % ukupne zabilježene erozije. Ovakva distribucija erozije tla unutar pojedinih klasa nagiba padina potvrdila je pretpostavku da će se najveći intenzitet erozije tla javiti unutar strmaca, povezanih s prostorom glavnog i sporednog čela jaruge (Sl. 140.). Naime, intenzitet odronjavanja strmih, gotovo okomitih padina glavnog i sporednog čela jaruge znatno nadilazi intenzitet svih drugih oblika erozije tla (npr. brazdanje i spiranje), koji se javljaju na padinama blažih nagiba. Tome pridonosi i ranije pojašnjeno odronjavanje komada karbonatnog pješčenjaka, unutar strmih bočnih padina jaruge Santiš (Sl. 132.).

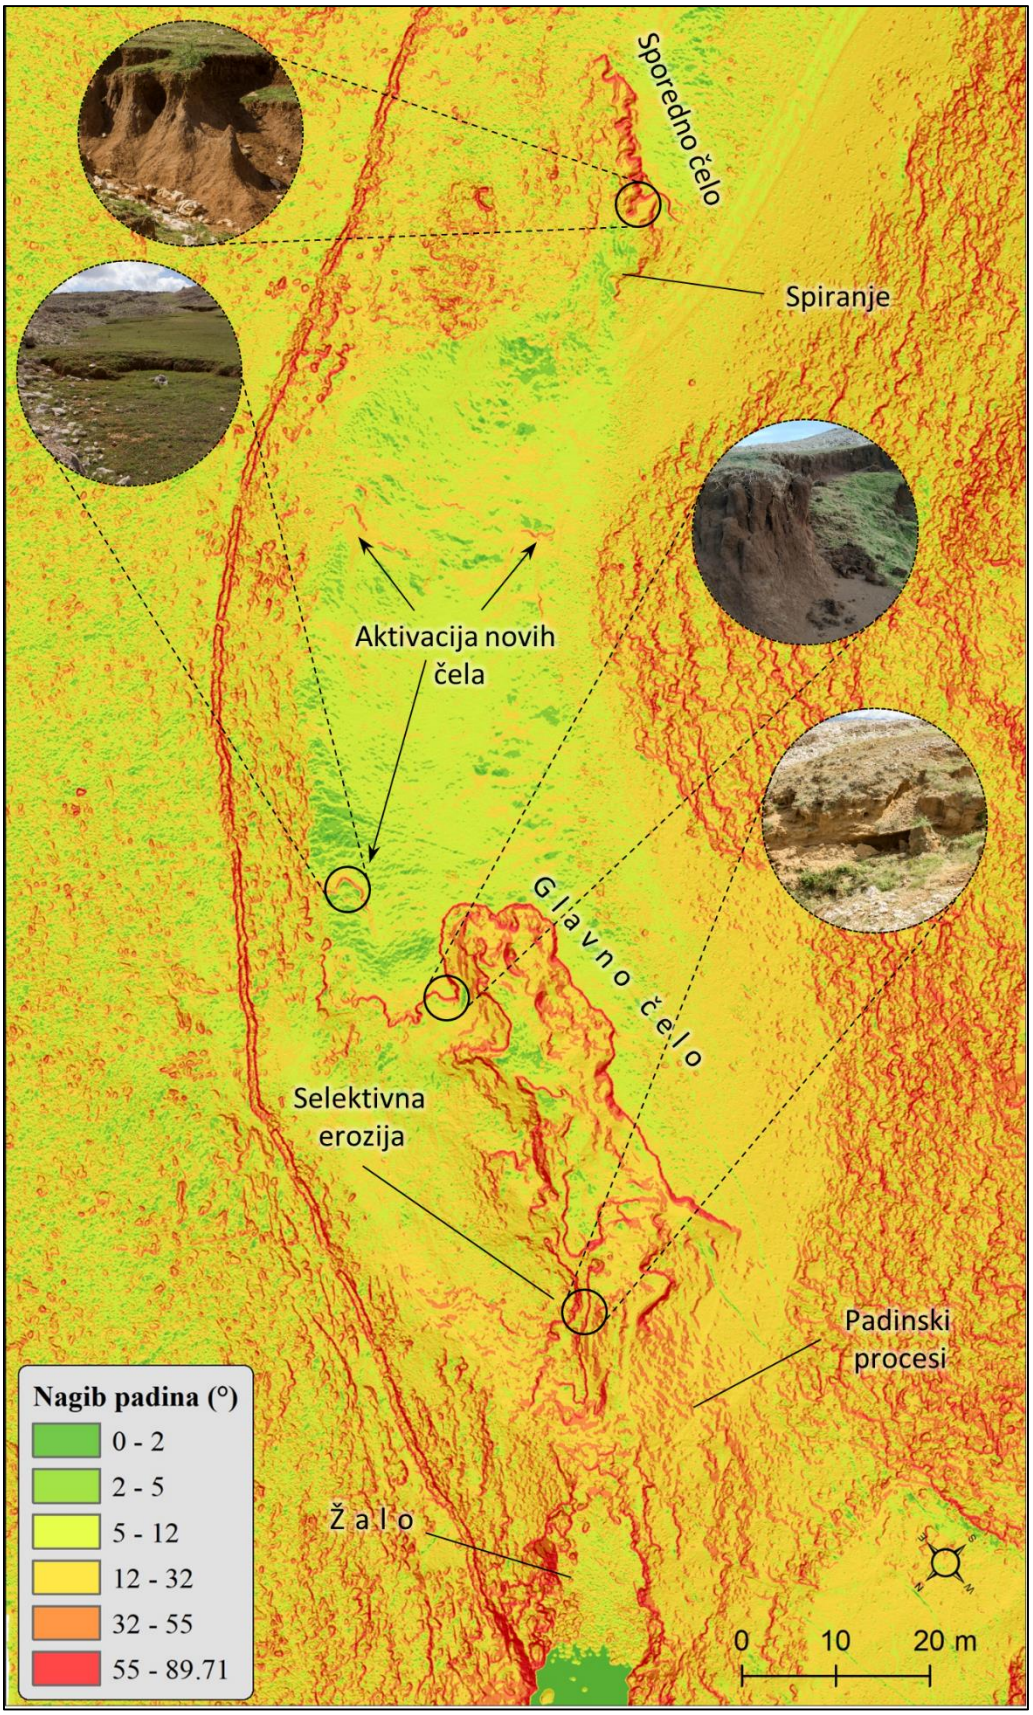

Slika 140. Prostorna distribucija klasa nagiba padina unutar prostora jaruge Santiš

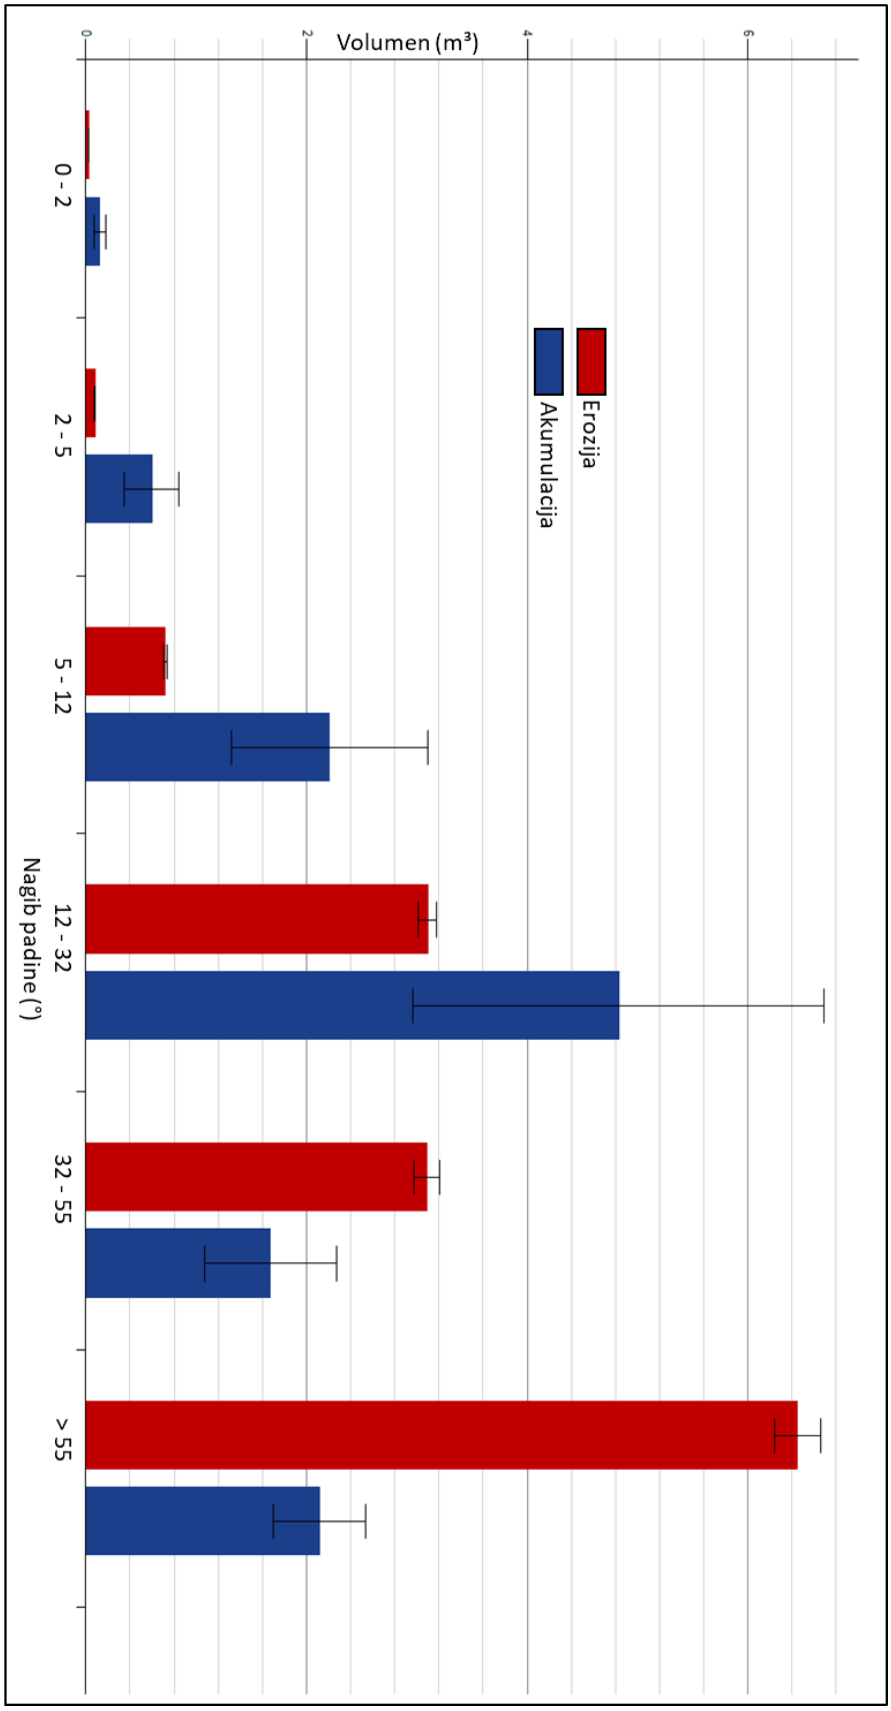

Slika 141. Raščlamba volumetrijskih promjena uzrokovane erozijom tla prema klasama nagiba padina (17. prosinca 2019. - 17. prosinca 2020.)

Strmci (> 55º) obuhvaćaju tek 3.45 % ukupne površine jaruge, unutar koje se javlja čak 47.92 % ukupne zabilježene erozije (Sl. 143.). Iako strmi i vrlo strmi tereni doprinose s najvećom količinom erodiranog materijala (9.54 m^3), zbog velikih nagiba i značajnog utjecaja gravitacije, tek oko trećine erodiranog materijala (3.37 m^3) se akumulira unutar ovih strmih padina. Daljnjim djelovanjem padinskih procesa te posebice površinskog otjecanja, o kojemu svjedoče recentni tragovi spiranja i brazdanja, većina preostalog erodiranog materijala transportira se dalje od podnožja čela jaruge, prema slabije nagnutim terenima (6.17 m^3), koji prekrivaju zaravnjenije prostore ispod glavnog i sporednog čela (Sl. 140.). Međutim, zbog postupnog opadanja nagiba s udaljavanjem od čela jaruge, ali i nedovoljne transportne snage površinskog otjecanja preostali erodirani materijal se ponovno akumulira nakon sljedećih nekoliko metara. Naime, udaljenost na kojoj će erodirani materijal biti akumuliran izravno ovisi o sposobnosti površinskog otjecanja da transportira materijal dalje od čela jaruge (Kirkby i Bracken, 2009; Chaplot, 2013), pri čemu se ukoliko snaga otjecanja nije dostatna materijal akumulira vrlo blizu čelu jaruge. Iz provedenih analiza može se zaključiti da je većina materijala erodiranog s prostora čela jaruge Santiš akumulirano neposredno u prvih nekoliko metara od čela, što ukazuje na izostanak izraženijeg površinskog otjecanja, sposobnog za transportiranje materijala na veće udaljenosti. Daljnjim akumuliranjem materijala može doći do postupnog zatrpavanja čela, te formiranja naslaga tla po formi sličnih sipru (engl. *talus slope*) u podnožju čela jaruge, koje prema Chaplotu (2013) mogu onemogućiti daljnji razvoj jaruge. Formiranje takvih naslaga materijala detektirano je neposredno ispod glavnog čela jaruge (Sl. 142), pri čemu za sada ipak akumulacija nije dovoljno intenzivna da bi došlo do "zatrpavanja" čela jaruge i onemogućavanja njezinog daljnjeg razvoja.

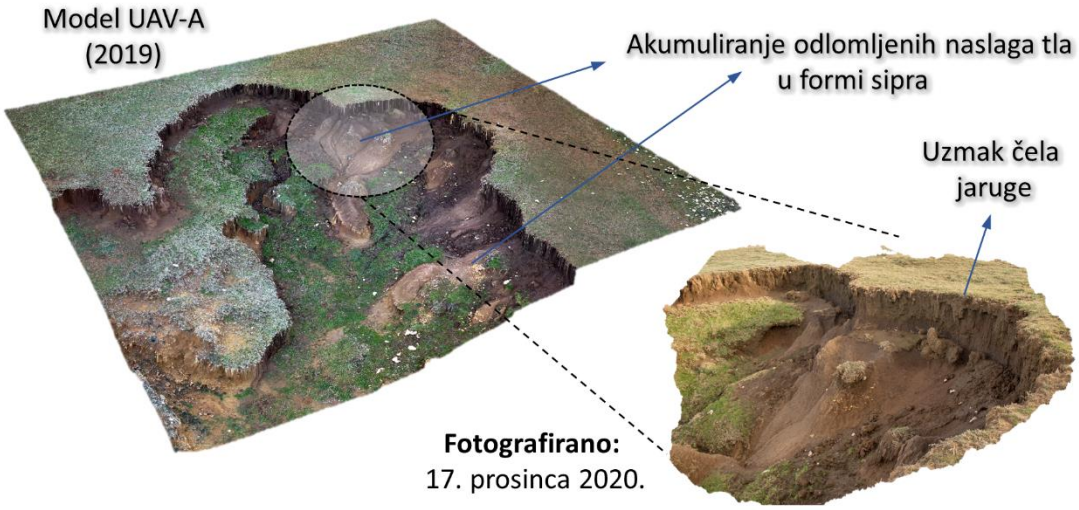

Slika 142. Primjer akumulacije naslaga tla u podnožju glavnog čela jaruge

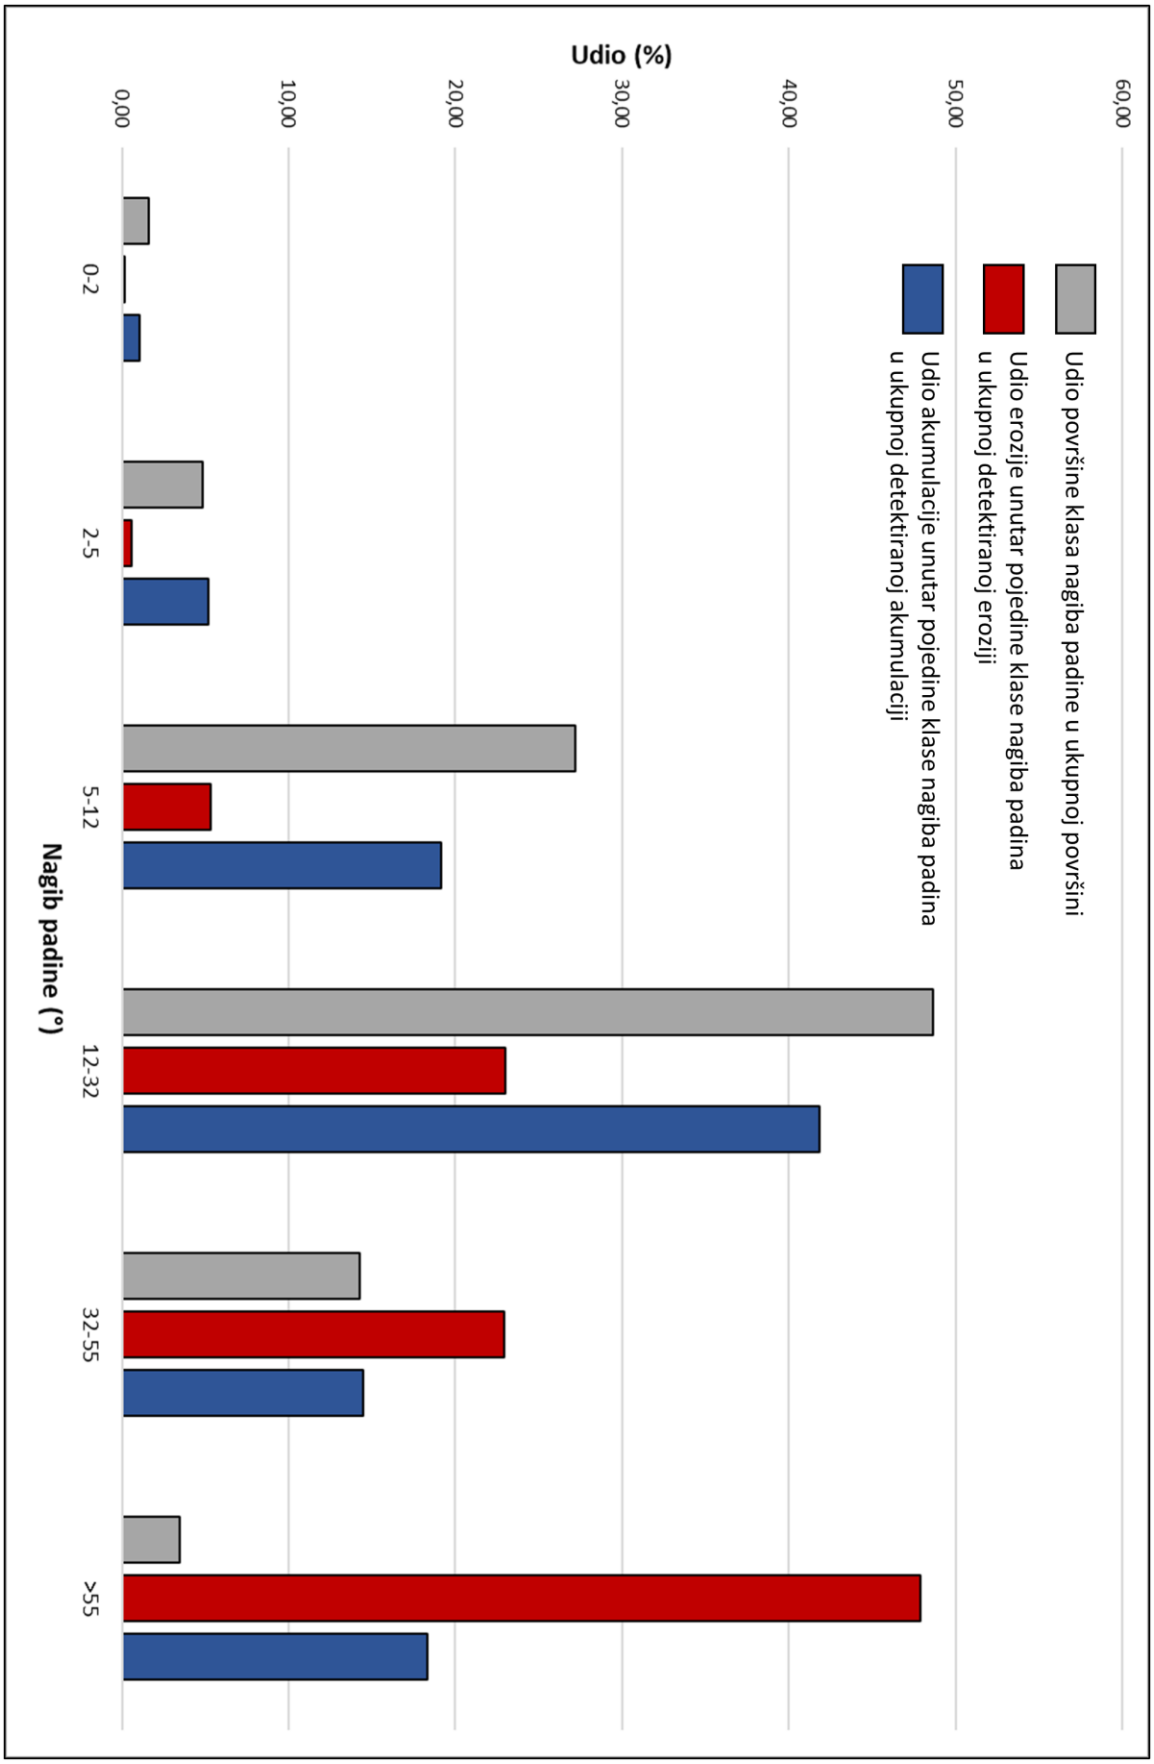

Slika 143. Usporedba površine pojedine klase nagiba padina i detektiranih PVP

4.2.3. Odnos između intenziteta erozije tla i prikupljenih meteoroloških indikatora

Značajke oborina u dva promatrana razdoblja, višegodišnjem (2014.-2018.) i jednogodišnjem (2019.-2020.) uspoređene su na temelju šest različitih oborinskih indikatora. Od jednostavnijih standardnih oborinskih indikatora, koji ukazuju na osnovne značajke oborinskih godišnjih kretanja, izdvojeni su ukupna godišnja količina oborina (TAP), broj kišnih dana (#RDs), te normala kišnog dana (RDN). Osim toga, izdvojena su i tri oborinska indikatora izravnije povezana s procesom erozije tla. Indikatori *broja dana s količinom oborina iznad 13 mm* (#RD13) i *broja dana s količinom oborina iznad 20 mm* (#RD20) ukazuju na učestalost intenzivnih oborinskih događaja, a indikator *maksimalne dnevne količine oborina* (MDR) na maksimalnu količinu oborina u jednom danu. Indikator #RD13 izdvojen je jer se vrijednost od 13 mm smatra minimalnom količinom oborina potrebnom za inicijaciju erozivnog djelovanja (Wischmeier i Smith, 1978., u Hayas i dr., 2017.). Također, indikator broja dana s količinom oborina iznad 20 mm izdvojen je jer se količina oborina od 20 mm pokazala kao kritična količina oborina potrebna za inicijaciju erozije tla u čelu jaruge (Poesen i dr., 2003., u Hayas i dr., 2017.). Rezultati analize odnosa između izračunatih oborinskih indikatora i detektiranog površinskog i volumetrijskog intenziteta erozije tla za dva proučavana perioda prikazani su u tablici 60. Vidljivo je da jednogodišnje razdoblje bilježi znatno manju količinu oborina, ali i manji intenzitet erozije tla u odnosu na vrijednosti izračunate za višegodišnje razdoblje.

Tablica 60. Odnos između izračunatih oborinskih pokazatelja i detektiranih PVP

#	Godina	Godišnji statistički pokazatelji						Erozija tla	
		TAP (mm/ y^{-1})	(#RDs)	RDN (*mm* d^{-1})	MDR (*mm* d^{-1})	#DR13	#DR20	POV	VOL
1.1	2014	1680.20	128	13.13	120.00	41	24	164.34	201.28
1.2	2015	972.60	70	13.89	62.00	22	20		
1.3	2016	1148.60	109	10.54	50.00	32	21		
1.4	2017	1210.70	96	12.61	153.50	27	15		
1.5	2018	1131.20	104	10.88	78.00	34	12		
Prosjek 2014 - 2018		1228.66	92.70	12.21	92.70	31.20	18.40	164.34	201.28
2.	17.12.2019-17.12.2020	998.80	87	11.48	63.22	28	17	158.51	13.46

Prema izračunatim indikatorima vidljivo je da jednogodišnjeg razdoblje (2019. – 2020.) bilježi znatno manje vrijednosti svih šest odabranih statističkih oborinskih pokazatelja (Tabl. 58). Prema tome moguće je zaključiti da je promatrano jednogodišnje razdoblje u odnosu na

višegodišnje (2014. – 2018.) bilo znatno sušnije, s obzirom na ukupu godišnju količinu oborina (TAP) i broj kišnih dana, ali i dana s količinom oborina većom od 13 i 20 mm, te po maksimalnoj dnevnoj količini oborina.

Ukupna godišnja količina oborina jednogodišnjeg razdoblja manja je za gotovo 229.86 mm (odnosno 18.71 %) u odnosu na prosječnu vrijednost višegodišnjeg razdoblja (2014. – 2018.). Sušnost jednogodišnjeg promatranog razdoblja očituje se i kroz opadanje oborinskih indikatora povezanih s intenzitetom erozije (Tabl. 60.). Primjerice, MDR je u jednogodišnjem razdoblju opao za gotovo 31.80 %, što ukazuje da su intenzitet i izdašnost oborina bili ispod višegodišnjeg prosjeka. Također, ako se pogledaju višegodišnje vrijednosti ukupne mjesečne količine oborina (Sl. 145.A) vidljivo je da je godišnji režim vrlo heterogen, ali da se najviše oborina javlja u razdoblju od rujna do veljače, s nekoliko istaknutih maksimuma (npr. rujan; studeni; veljača). S druge strane, jednogodišnje mjesečne vrijednosti ukupne količine oborina (Sl. 145.B) ukazuju da su svi zimski i proljetni, te pojedini ljetni (*srpanj*) i jesenski (*studeni*) mjeseci bili znatno suši od prosječnih vrijednosti.

Manja količina i intenzitet oborina u jednogodišnjem razdoblju zasigurno je utjecala na pojavu manjeg intenziteta erozije tla, što je i utvrđeno i u pojedinim ranijim istraživanjima s prostora Mediterana (Campo-Bescós i dr., 2013). Međutim, nerazmjer između utvrđenog intenziteta erozije tla unutar višegodišnjeg promatranog razdoblja (34.57 m^3) i jednogodišnjeg promatranog razdoblja (13.46 m^3) znatno nadilazi razliku u količini oborina, koja bi mogla dovesti do takvog nerazmjera u intenzitetu erozije. Unutar jednogodišnjeg razdoblja (2019. – 2020.) zabilježeno je 81.29 % prosječne višegodišnje vrijednosti TAP-a, dok je u istom razdoblju erodirano samo 34.93 % ukupne količine materijala koji je erodiran u višegodišnjem razdoblju (2014. – 2018.). Ovako velika razlika u zabilježenim vrijednostima erozije tla između višegodišnjeg i jednogodišnjeg promatranog razdoblja zasigurno nije isključivo rezultat promjene u količini i godišnjem režimu oborina. Vrlo vjerojatno su na nesrazmjeran intenzitet erozije utjecali i drugi čimbenici, poput razlike u prostornoj rezoluciji modela korištenih za detekciju PVP[49], ili pak različitim pogreškama u modelima sitnije rezolucije (npr. uvjetovanim pojavom sjene).

Značajniji utjecaj indikatora povezanih s prikupljenim podacima o temperaturi zraka na intenzitet erozije tla nije uočen prilikom istraživanja provedenih u sklopu ove disertacije, osim

[49] Višegodišnje PVP detektirane su na temelju intervalnih modela prostorne rezolucije 30 cm, a jednogodišnje PVP na temelju intervalnih modela prostorne rezolucije 1 cm.

u pogledu pojave krustacije (Sl. 144.) na površini naslaga *smeđeg tla* prilikom sušnih i vrućih ljetnih mjeseci. Primjerice, krustaciji zabilježenoj prilikom provedenih terenskih istraživanja (Sl. 15; 144.) prethodilo je sedam dana bez gotovo ikakvih oborina, uz prosječnu dnevnu temperaturu od 23.26 ºC[50]. Intenzitet krustacije zasigurno zna biti i znatno veći, od onoga zabilježenog tijekom navedenog terenskog istraživanja, Naime, prema prikupljenim meteorološkim podacima prosječna dnevna temperatura tijekom ljetnih mjeseci na prostoru jaruge Santiš može iznositi i do 31.96 ºC, uz dugotrajna razdoblja bez oborina, koja mogu trajati i nekoliko desetaka dana. U takvim uvijetima može se pretpostaviti da je i krustacija površinskih slojeva tla na prostoru jaruge Santiš daleko veća. Utjecaj krustacije na intenzitet erozije tla također bi trebao biti detaljnije istražen u sklopu daljnjih istraživanja i planirane nano razine istraživanja erozije tla (*vidi* 2.2.).

Slika 144. Pojava krustacije u površinskim slojevima naslaga smeđeg tla unutar jaruge Santiš (19. lipnja 2020.)

[50] Od 12. do 19. lipnja 2020 godine zabilježeno je tek 3 mm oborina, raspoređenih u tri vrlo slaba oborinska događaja, uz prosječnu dnevnu temperaturu od 23.26 ºC, odnosno prosječnu maksimalnu dnevnu temperaturu od 27.69 ºC.

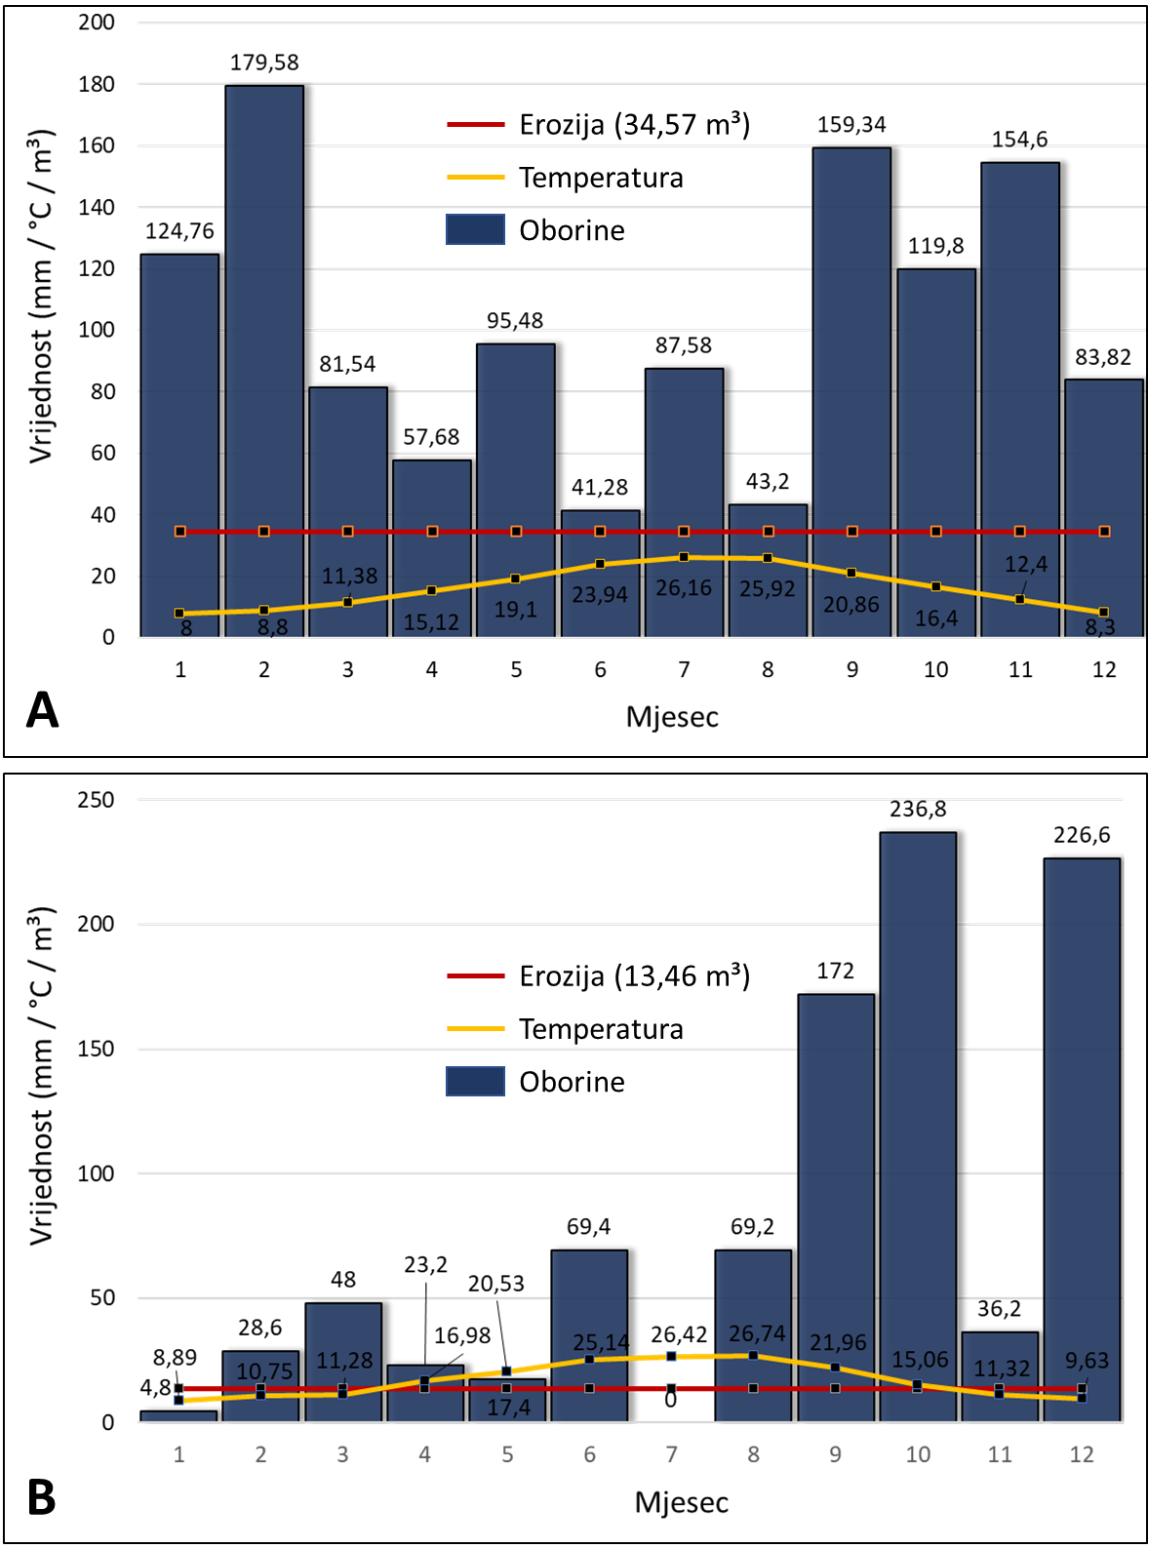

Slika 145. Analiza odnosa između intenziteta erozije tla i prikupljenih meteo podataka (A – prosječna ukupna mjesečna količina oborina i prosječna mjesečna temperatura zraka za razdoblje od 2014. do 2018. godine (izvor: DHMZ); B – ukupna mjesečna količina oborina i prosječna mjesečna temperatura zraka za razdoblje od 17. prosinca 2019. do 17. prosinca 2020. godine (izvor: in-situ mjerenja))

4.3. Rezultati mikro razine istraživanja

4.3.1. Uspješnost razvijene metodologije za optimizaciju intervalnih TLS izmjera

I. Izrađeni plan intervalnih TLS izmjera

U konačnici je na temelju provedene analize vidljivost odabrano osam optimalnih lokacija za postavljanje terestričkog laserskog skenera i intervalno skeniranje željenog prostora jaruge. Uz navedena stajališta TLS-a u sklopu izrađenog plana TLS izmjera određene su lokacije postavljanja sedam stalnih geodetskih meta (sfera), te dodatnih pet pomoćnih sfera. Analiza vidljivosti je pokazala da je širi prostor mikro razine, ukupne površine 1163.09 m² moguće snimiti sa osam stajališta TLS-a i to sa postotkom pokrivenosti od 96,93 % (pokriveno 1127.43 m² površine jaruge) (Sl. 146.).

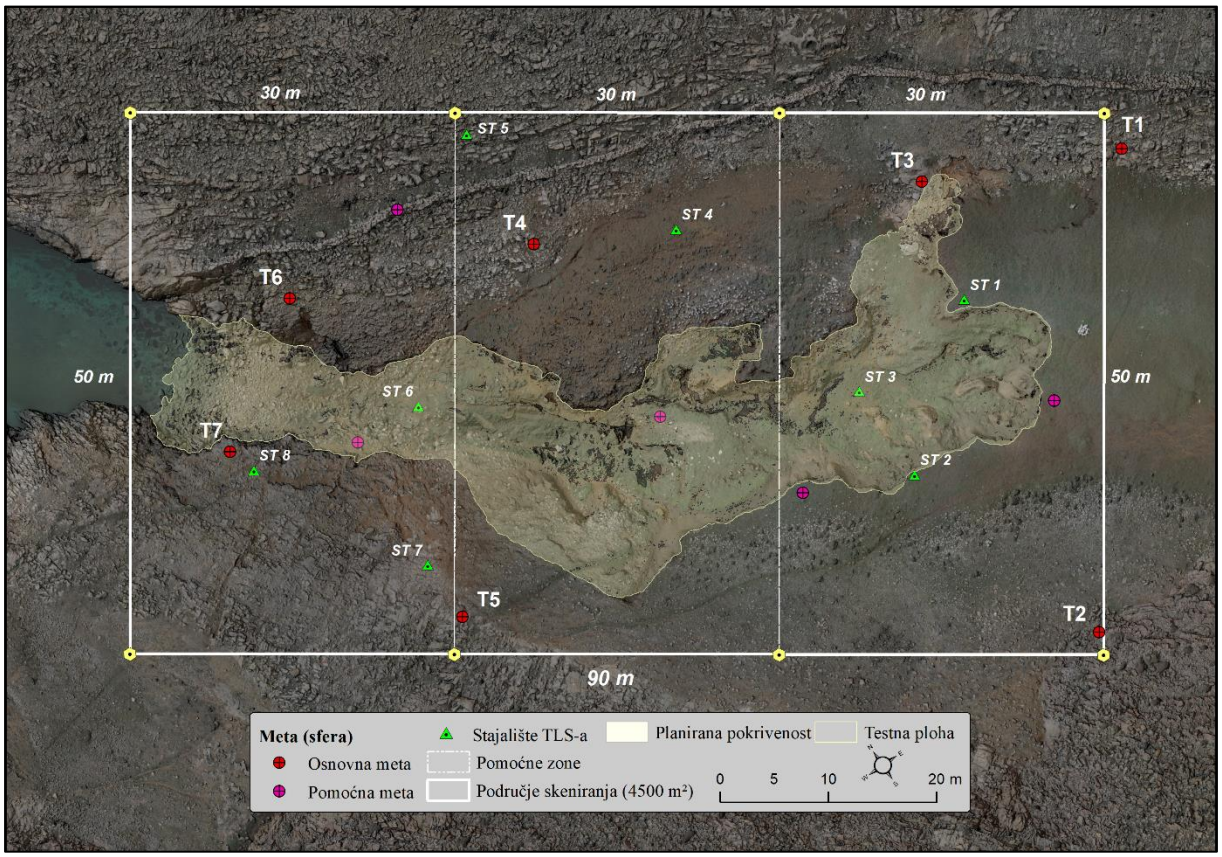

Slika 146. Planirana pokrivenost šireg prostora mikro razine sa osam odabranih stajališta

Pri tome valja napomenuti kako je uz pokrivenost vrlo visok i postotak preklapanja snimaka sa više susjednih STLS-a (Sl. 147; Tabl. 61). Primjerice samo oko 10 % prostora jaruge snimljeno je sa samo jednog stajališta, dok je oko 86 % prostora pokriveno sa minimalno dva

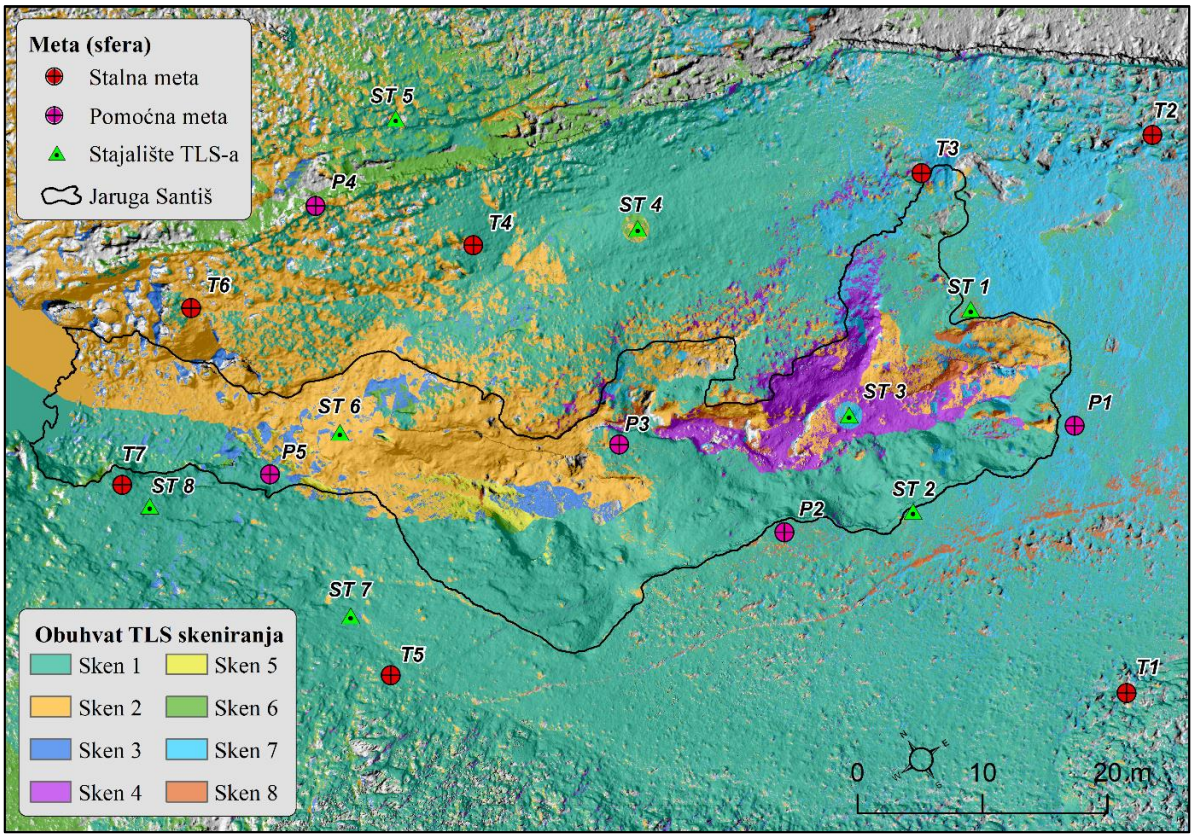

Slika 147. Prikaz preklapanja laserskih zraka susjednih stajališta

Tablica 61. Broj stajališta TLS-a s kojih je pokriveno testno područje

ID	Broj stajališta s kojih je površina vidljiva	Površina (m^2)	Udio u ukupnoj površini (%)
1	Nije pokriveno	35.65	3.07
2	Jedno stajalište	119.19	10.25
3	Dva stajališta	226.28	19.46
4	Tri stajališta	320.63	27.57
5	Četiri stajališta	221.56	19.05
6	Pet stajališta	161.68	13.90
7	Šest stajališta	54.58	4.69
8	Sedam stajališta	17.55	1.51
9	Osam stajališta	5.97	0.51
Ukupno		1163.09	100.00

ili više stajališta. Najviše površine pokriveno je s dva (19.45 %), tri (27.57 %) ili četiri (19.05 %) stajališta. Preostalih 3.07 % prostora čela jaruge koji nije pokriven sa laserskim zrakama

niti jedne od odabranih osam stajališta TLS-a nalazi se unutar površine od tek 35.65 m². Ovaj nepokriveni prostor vezan je pretežito za zaklonjene dublje dijelove manjih kanala, unutar jaruge Santiš, u kojima je došlo do pojave sjene. Unatoč opsežnom planiranju izmjere i analizi više od 100 potencijalnih lokacija stajališta TLS-a kompleksna morfologija jaruge ipak je dovela do nemogućnosti pokrivanja laserskim zrakama određenih manjih dijelova testne plohe.

Međutim, na primjeru morfološki vrlo kompleksnog prostora glavnog čela jaruge Santiš (Sl. 148), vidljivo je da je izrađenim planom TLS intervalnih izmjera ipak osigurana vrlo dobra pokrivenost raščlanjenijih i kompleksnijih dijelova jaruge.

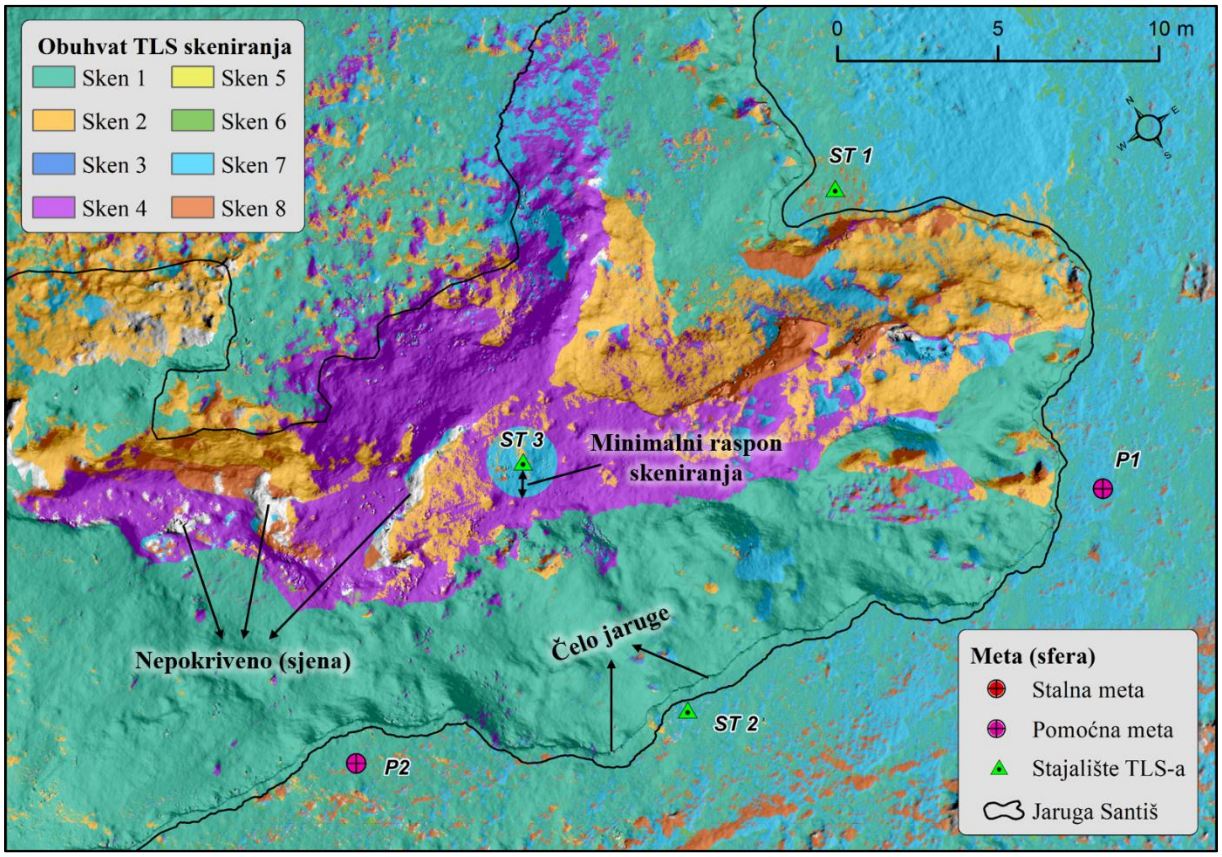

Slika 148. Planirana pokrivenost kompleksne morfologije početnog čeonog dijela jaruge Santiš

II. Izrađeni modeli šireg prostora mikro razine istraživanja

Na temelju izrađenog plana i provedenih intervalnih TLS izmjera napravljeni su intervalni oblaci točaka (PC_{TLS-A} i PC_{TLS-B}) jaruge Santiš (Sl. 149). ,

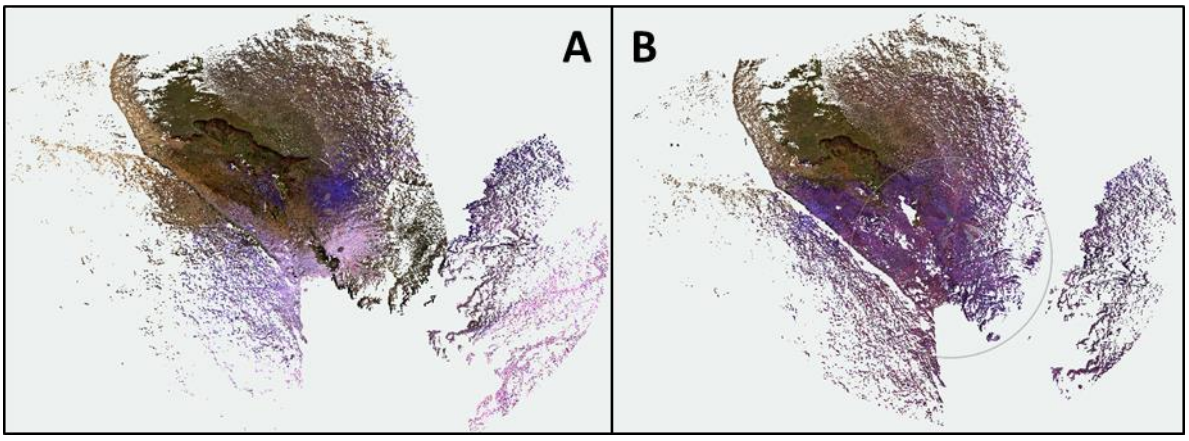

Slika 149. Početni (PC_{TLS-A}) i završni (PC_{TLS-B}) intervalni oblak točaka jaruge Santiš

Osnovne značajke izrađenih modela dane su u tablici 62. Iz sedam skenova prikupljenih prilikom inicijalne TLS izmjere (17. prosinca 2019. godine) izrađen je oblak točaka (PC_{TLS-A}) s ukupno 357 789 652 točaka, pri čemu prosječna gustoća točaka iznosi 22 383.94 točaka/m^2. S obzirom da je kod završne TLS izmjere (04. prosinca 2020. godine) prikupljeno samo 5 skenova, izrađen je oblak točaka (PC_{TLS-B}) s ukupno 228 402 735 točaka, gdje prosječna gustoća točaka iznosi 16 229.82 točaka/m^2.

Tablica 62. Pregled značajki izrađenih modela užeg prostora mikro razine istraživanja napravljenih iz podataka prikupljenih intervalnim TLS izmjerama

ID	Model (Datum prikupljanja)	Uređaj	Broj skenova	Prosječna gustoća točaka	Oblak točaka
1	Model TLS-A (17.12.2019)	Faro Focus M70	7	22 383.94 točaka/m^2	357 789 652
2	Model TLS-B (04.12.2020)	Faro Focus M70	5	16 229.82 točaka/m^2	228 402 735

Uspješnost procesa registracije unutar Faro Scene softvera za izrađene TLS modele iskazana je kroz vrijednosti prosječne i maksimalne pogreške u registraciji meta (sfera) (Tabl. 63). Na pogrešku u registraciji skenova utječu brojni čimbenici, među kojima se najčešće ističu: *prisutnost pokretnih artefakata* (npr. vozila ili ljudi u pokretu; njihanje vegetacije uzrokovano vjetrom), *prisutnost zaklonjenih dijelova* (npr. kompleksna morfologija terena) te *promjene u*

poziciji stajališta TLS-a ili promjene u poziciji referentnih meta (Fan i dr., 2015; Dong i dr., 2020b). S obzirom da su obje TLS izmjere napravljene s istim stajalištima i referentnim metama, te da prilikom intervalnih izmjera nije bilo prisutnih pokretnih artefakata, detektirana pogreška u registraciji odraz je isključivo kompleksne morfologije skenirane jaruge.

Tablica 63. Pregled prosječnih i maksimalnih pogreški u registraciji meta (sfera)

ID	Model	Srednja horizontalna pogreška	Maks. horizontalna pogreška	Srednja vertikalna pogreška	Maks. vertikalna pogreška	Srednja pogreška udaljenosti	Maks. pogreška udaljenosti
1	TLS-A	19.2 mm	30.2 mm	12.2 mm	36.3 mm	24.9 mm	46.7 mm
2	TLS-B	12.8 m	19.2 mm	13.0 mm	32.3 mm	19.6 mm	36.4 mm

S obzirom da je u sklopu završne intervalne TLS izmjere (TLS-B) prikupljeno samo 5 skenova, odnosno da nije snimljen cijeli planirani širi prostor, procjena ostvarene pokrivenosti napravljena je isključivo na temelju oblaka točaka inicijalne TLS izmjere. U konačnici je na temelju podataka prikupljenih u sklopu inicijalne TLS izmjere napravljen oblak točaka ($PC_{TLS-2019-šire}$) šireg prostora mikro razine istraživanja. Izrađeni oblak točaka reprezentiran je unutar prostora od 1163.09 m^2 s ukupno 134 149 819 točaka (Sl. 150), na temelju kojih je napravljena procjena ostvarene pokrivenosti (u nastavku) te procjena točnosti aerofotogrametrijskog inicijalnog modela (UAV-A) (vidi 4.3.2.).

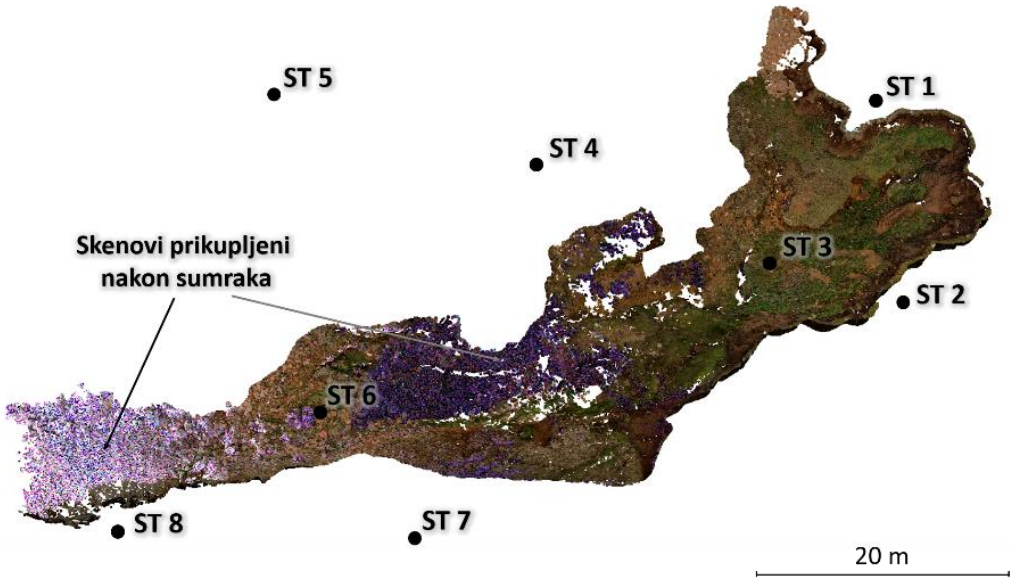

Slika 150. Finalni oblak točaka šireg prostora mikro razine istraživanja (TLS-A)

III. Pokrivenost ostvarena kroz provedenu inicijalnu TLS izmjeru

Unatoč izradi detaljnog plana intervalnih TLS izmjera i odabiru prema analizi vidljivosti optimalnih lokacija stajališta TLS-a, ostvarena pokrivenost testnog prostora je bila neznatno lošija od predviđene. Inicijalnom TLS izmjerom ostvarena je pokrivenost testnog područja od 91.66 % (1066.05 m^2), što predstavlja 94.56 % područja koje je trebalo biti pokriveno prema izrađenom planu intervalnih izmjera. Ukoliko se pogleda odnos između postotka planirane i ostvarene pokrivenosti testne plohe (Sl. 151.), jasno je vidljivo da je kod ostvarene pokrivenosti (B) udio nepokrivenog prostora porastao za preko tri puta u odnosu na planiranu pokrivenost (A).

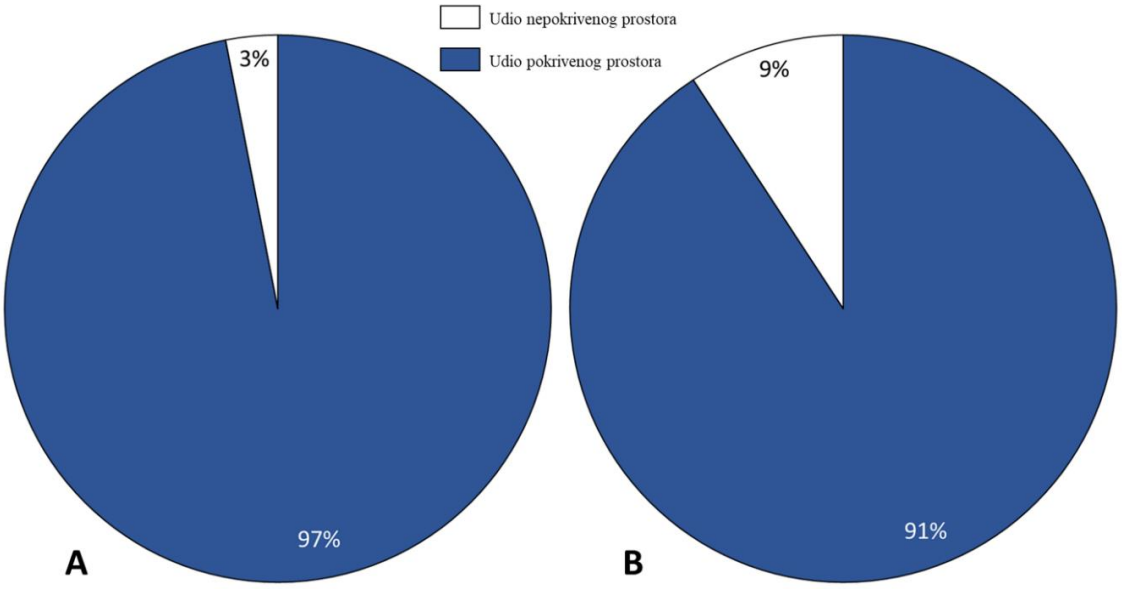

Slika 151. Razlika između postotka planirane (A) i ostvarene (B) pokrivenosti testne plohe

Manji postotak ostvarene pokrivenosti od planirane odraz je prvenstveno kompleksne morfologije jaruge Santiš, koja je uvjetovala pojavu nepokrivenih dijelova terena (Sl. 152). Naime, većina nepokrivenih prostora odnosi se na duboko usječene dijelove kanala jaruge u središnjem dijelu testne plohe, ili pak na raščlanjene bočne padine jaruge. Nepokriveni dijelovi u središnjem dijelu jaruge javili su se pretežito u zaklonjenim udubljenima, koja se nalaze relativno daleko od okolnih stajališta TLS-a. Također, kod nekoliko stajališta (npr. ST2) kompleksna morfologija jaruge utjecala je na onemogućavanje postavljanja TLS-a izravno na analizom vidljivosti odabranu lokaciju. Zbog rahlog materijala i opasnosti za sam uređaj pojedina stajališta su morala biti minimalno dislocirana, ovisno o značajkama terena. Iako taj odmak od određene optimalne pozicije kod niti jednog stajališta nije iznosio više od nekoliko desetaka cm, ipak je zasigurno u određenoj mjeri utjecao na smanjenje ostvarene pokrivenosti.

Osim utjecajem kompleksne morfologije reljefa nepokrivenost određenih dijelova može biti prouzrokovana i mogućim prostorno-vremenskih promjena koje su nastale u razdoblju između izrade preliminarnog modela (Model UAV-TEST) i provođenja inicijalne TLS izmjere. Naime, preliminarni model na temelju kojega je izrađen plan TLS izmjera napravljen je iz podataka prikupljenih 11. ožujka 2019. godine, dok je inicijalna intervalna izmjera provedena više od osam mjeseci nakon toga (17. prosinca 2019.). S obzirom na takav vremenski odmak neupitno je da su unutar testne plohe nastale određene prostorno-vremenske promjene, koje su utjecale na promjenu morfologije reljefa, a samim time i na ostvarenu pokrivenost. Izravan utjecaj PVP na smanjenje ostvarene pokrivenosti najbolje je vidljiv na primjeru prostora žala, koje se i u sklopu ranijih istraživanja pokazalo vrlo podložnim promjenama uzrokovanim djelovanjem valova i morskih mijena (Domazetović, 2018; Šiljeg i dr., 2021.). Djelovanjem valova unutar prostora žala dolazi do znatnog pomicanja i preslagivanja oblutaka i većeg kamenja, koji potencijalno mogu zakloniti prostor koji je trebao biti pokriven s određenog stajališta.

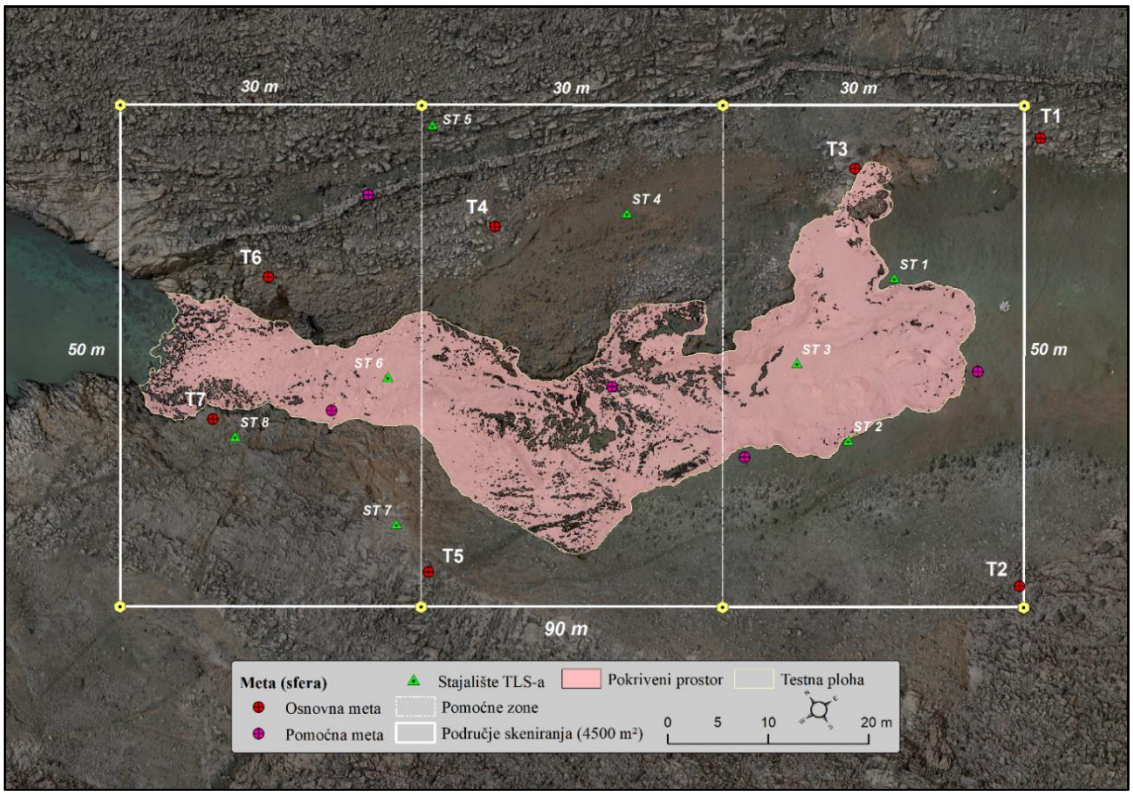

Slika 152. Ostvarena pokrivenost šireg prostora mikro razine sa osam odabranih stajališta

Unatoč navedenim nedostacima, izrada detaljnog plana omogućila je odličnu pokrivenost (> 90%) testne plohe, potvrđujući pritom postavljenu hipotezu o pozitivnom

utjecaju optimizacije intervalnih TLS izmjera na pokrivenost kompleksne morfologije jaruge. Podudarnost kompleksnosti terena i nepokrivenih dijelova jaruge najbolje je vidljiva iz 3D prikaza, uz pomoć kojega se jasno vidi da su nepokriveni dijelovi jaruge isključivo vezani za vertikalno najraščlanjenije dijelove jaruge (Sl. 153).

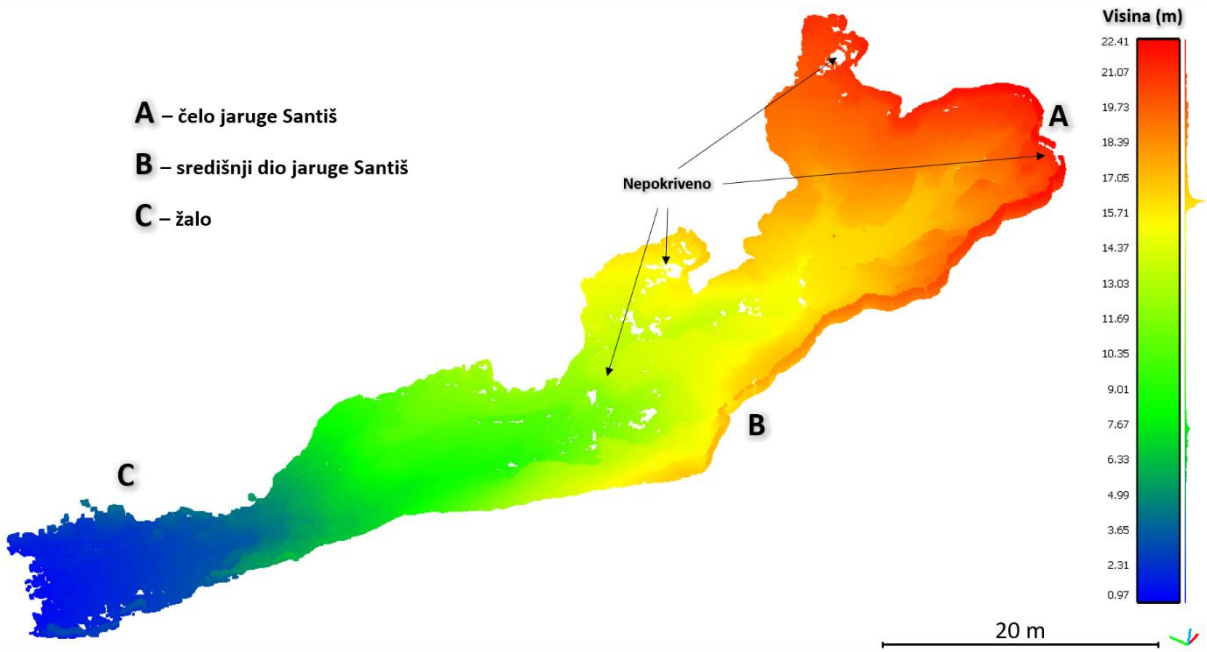

Slika 153. 3D prikaz nepokrivenih dijelova šireg prostora mikro razine istraživanja

4.3.2. Procijenjena točnost izrađenog aerofotogrametrijskog (UAV) modela

Za prikupljanje podataka potrebnih za izradu intervalnih modela unutar mezo i mikro razine ove disertacije primijenjeni su intervalna UAV fotogrametrija (*vidi 3.2.2.*) te intervalna TLS izmjera (*vidi 3.3.1.*).

I. Izrađeni modeli šireg prostora mikro razine istraživanja

Procjena točnosti napravljena je na temelju usporedbe referentnog oblaka točaka šireg prostora ($PC_{TLS-2019-\check{s}ire}$) i oblaka točaka generiranog iz podataka prikupljenih u sklopu intervalnog aerofotogrametrijskog snimanja (PC_{UAV-A}) (Sl. 154.). Iako su podaci prikupljani potpuno različitim geoprostornim tehnologijama, izrađeni oblaci točaka su prema osnovnim značajkama vrlo slični (Tabl. 64.). Ukupan broj točaka u referentnom oblaku točaka izrađenom iz podataka prikupljenih TLS-om iznosi 134 149 819 točaka, uz prosječnu gustoću točaka od 88 024.82 točaka po m^2. Uspoređeni oblak točaka napravljen je iz aerofotogrametrijskih snimaka te unutar istog proučavanog prostora ima ukupno 125 588 086 točaka, prosječnu gustoću točaka od 81 976.56 točaka po m^2. Već iz ovih osnovnih značajki izrađenih oblaka točaka vidljivo je da aerofotogrametrijski model ne zaostaje značajnije po karakteristikama i detaljnosti za modelom izrađenim iz podataka prikupljenih TLS-om. Naime, ukupan broj točaka UAV-A oblaka točaka odstupa samo za 6.38% od TLS-A oblaka točaka, unatoč tome što TLS predstavlja daleko složeniju i skuplju geoprostornu tehnologiju (Glendell i dr., 2017).

Tablica 64. Pregled značajki izrađenih modela šireg prostora mikro razine istraživanja

ID	Model (Datum prikupljanja)	Uređaj	Oblak točaka	Površina oblaka točaka (m^2)	Gustoća točaka (n/m^2)
1	Model TLS-A (17.12.2019)	Faro Focus M70	134 149 819	1163.09	88 024.82
2	Model UAV-A (17.12.2019)	RAPS	125 588 086	1163.09	81 976.56

Unatoč pomnom planiranju provedenog aerofotogrametrijskog snimanja i TLS izmjere, vidljivo je da oba oblaka točaka imaju određene nedostatke, koji su posljedica isključivo kompleksne morfologije jaruge Santiš. Pri tome se prema lokaciji nepokrivenih dijelova u pojedinom oblaku točaka mogu razlikovati određene prednosti i nedostaci primijenjenih

geoprostornih metoda prikupljanja podataka. Primjerice, dok je prisutnost nepokrivenih dijelova u strmom, mjestimice i prevjesnom prostoru glavnog čela jaruge Santiš kod TLS-A oblaka točaka neznatna, isti prostor je mjestimice vrlo loše reprezentiran u UAV-A oblaku točaka (Sl. 154.A).

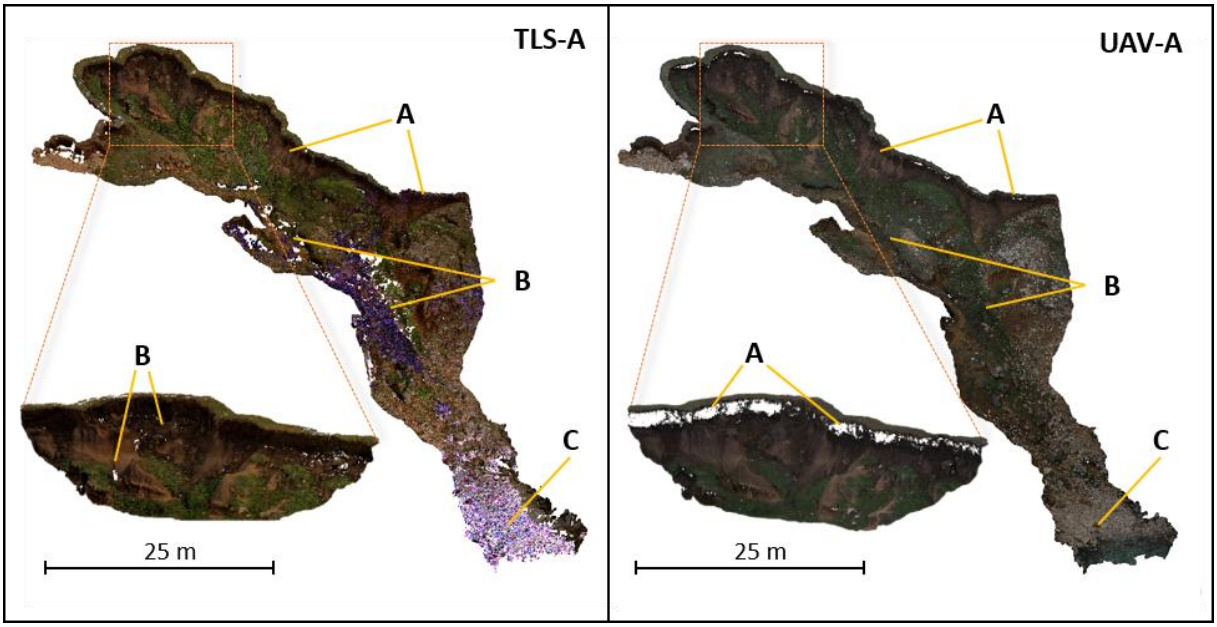

Slika 154. Nedostaci izrađenih oblaka točaka mikro razine vezani za kompleksnu morfologiju jaruge (A – čelo jaruge; B – duboko usječeni kanali unutar jaruge; C – žalo)

Nepokrivenost takvih prevjesnih prostora u UAV-A oblaku točaka posljedica je okomitog gledišta RAPS-a prilikom provođenja aerofotogrametrijskog snimanja, određenog zadanim kutom kamere (90º). Iz izrađenog UAV-A oblaka točaka vidljivo je da je takav problem prisutan kod gotovo svih vertikalnih i/ili prevjesnih padina unutar jaruge Santiš (npr. čelo jaruge, strme padine dubljih kanala, prostor potkapina vezanih za selektivnu eroziju, itd.). Slični nedostaci aerofotogrametrije uočeni su i u brojnim ranijim istraživanjima, u kojima je nepokrivenost kompleksnih prevjesnih padina prepoznat kao jedan od glavnih nedostataka primjene aerofotogrametrije za snimanje složenih reljefnih formi oblikovanih erozijom tla (Liu i dr., 2016; Cook, 2017; Hout i dr., 2020). Da bi se ovakvi prevjesni prostori ipak mogli snimiti bilo bi potrebno ili podesiti drugačiji kut kamere unutar RAPS-a (npr. 75º), ili bi se kao što je također sugerirano u ranijim istraživanjima (npr. Stöcker i dr., 2015) aerofotogrametrijske podatka trebalo nadopuniti odgovarajućim terestričkim podacima (npr. terestrička fotogrametrija ili TLS).

No, TLS-A oblak točaka bilježi nedostatke u drugim područjima, koja su odlično pokrivena u UAV-A oblaku točaka, poput dna duboko usječenih dijelova kanala jaruge Santiš

(Sl. 154.B) te prostora žala (Sl. 154.C), pokrivenog oblutcima različitih veličina. Iako je TLS izmjera provedena prema detaljno razrađenom planu, zasnovanom na primijeni više različitih stajališta oko jaruge Santiš, laserske zrake ipak nisu bile u mogućnosti doprijeti do svih najdubljih dijelova uskih dubokih kanala unutar jaruge. Pojava nepokrivenih dijelova u dubokim zaklonjenim dijelovima jaruge zabilježena je u brojnim ranijim istraživanjima (Perroy i dr., 2010; Bremer i Sass, 2012; Goodwin i dr., 2017). Primjerice, Perroy i dr. (2010) ističu da TLS ima vrlo velikih problema prilikom prikupljanja podataka u uskim i relativno dubokim (> 0.5 m) kanalima jaruge, gdje dolazi do pojave sjene, odnosno nepokrivenog prostora. Sličan uzrok nepokrivenim područjima je i na prostoru žala, gdje je raščlanjena površina sačinjena od oblutaka različitih veličina bila prekompleksna za potpunu pokrivenost laserskim zrakama. Zbog čega je došlo do pojave nepokrivenih dijelova između većih oblutaka (Sl. 154.C). S druge strane, kod UAV-A oblaka točaka ovi prostori su relativno dobro pokriveni, jer je RAPS prilikom prikupljanja snimaka bio direktno iznad njih, čime je fotografirano i samo dno najdubljih dijelova kanala. Međutim, navedeni nedostaci UAV-A i TLS-A oblaka točaka obuhvaćaju vrlo male površine, vezane za najkompleksnije dijelove jaruge. U nastavku je dan pregled udaljenosti između dva oblaka točaka, koja je određena primjenom M3C2 algoritma. Prikaz gustoće točaka korištenih za izračun M3C2 udaljenosti dan je na slici 155.

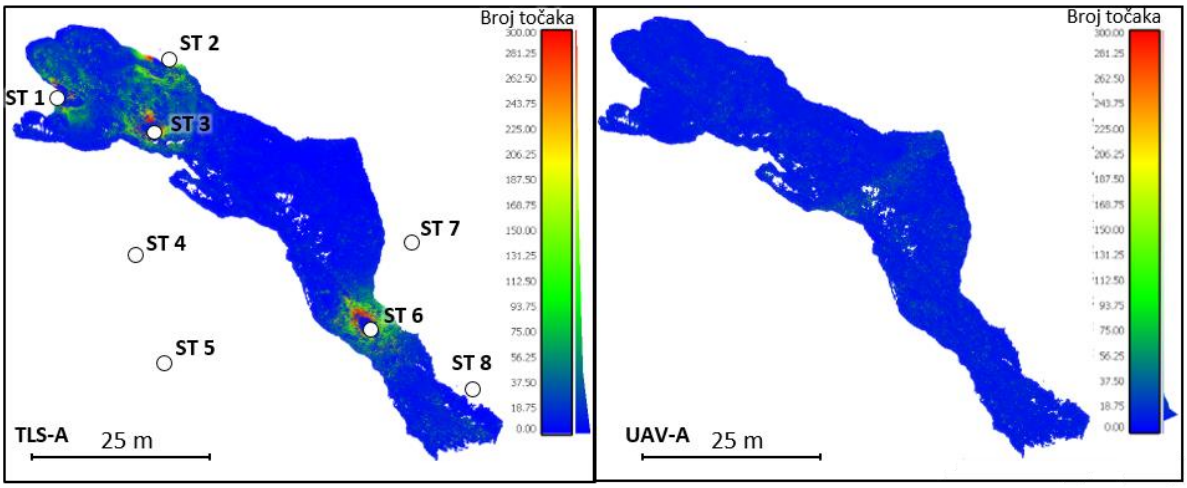

Slika 155. Usporedba između gustoće točaka korištenih za izračun M3C2 udaljenosti između TLS-A i UAV-A oblaka točaka

II. Utvrđena točnost inicijalnog aerofotogrametrijskog modela

Analiza provedena uz pomoć M3C2 algoritma potvrdila je značajnu podudarnost izrađenog UAV-A oblaka točaka, u odnosu na referentni TLS-A oblak točaka (Sl. 156.). Vrijednost M3C2 udaljenosti između dva uspoređena oblaka točaka manja je od ±2.5 cm u čak 83.48 % analiziranih točaka, što potvrđuje da UAV-A oblak točaka unutar većine proučavanog prostora ne odstupa značajnije od referentnog TLS-A oblaka točaka. Udaljenost od ±2.5 cm odgovara vrijednostima prosječne pogreške udaljenosti (engl. *mean distance error*) utvrđene prilikom izrade TLS-A oblaka točaka (Tabl. 63.), iz čega proizlazi da je u većini (> 80 %) točaka točnost UAV-A oblaka točaka unutar točnosti TLS-A oblaka točaka.

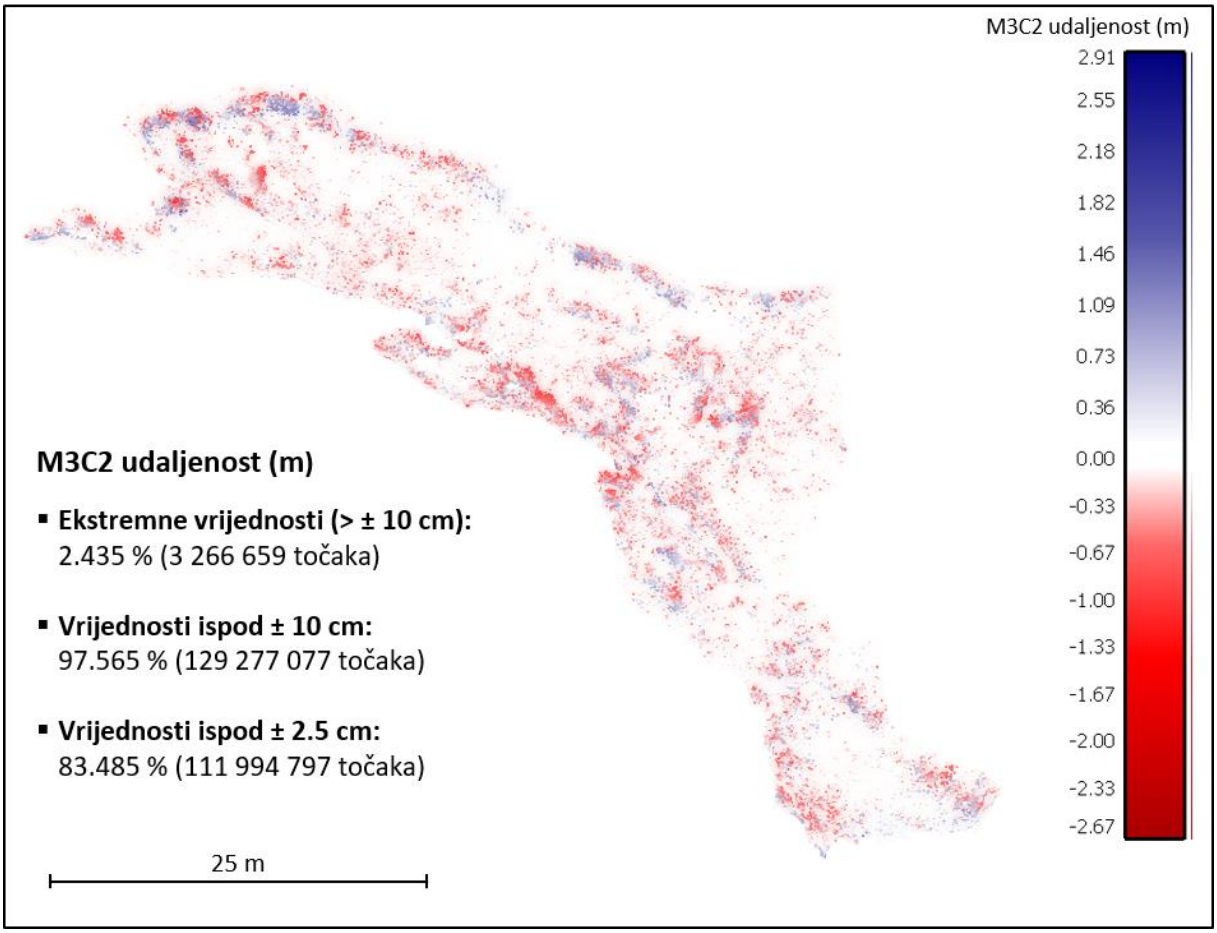

Slika 156. Udaljenost između referentnog (TLS-A) i evaluiranog oblaka točaka (UAV-A) određena uz pomoć M3C2 algoritma

Zabilježene niske vrijednosti odstupanja UAV-A oblaka točaka odgovaraju rezultatima ranijih istraživanja u kojima je i s jednostavnim i jeftinim aerofotogrametrijskim UAV sustavima (npr. DJI Phantom II (Cook, 2017)) postignuta točnost od ispod ± 10 cm. Ukoliko se pogledaju isključivo vrijednosti M3C2 udaljenosti manje od ± 10 cm, vidljivo je da model izrađen iz aerofotogrametrijskih podataka prikupljenih uz pomoć RAPS-a postiže ovakvu

točnost u preko 97 % svih točaka (Sl. 156.). Ekstremna odstupanja (> ±10 cm) javila unutar vrlo malog udjela točaka (2.435 % ukupnog broja točaka), pretežito koncentriranog unutar prostora najkompleksnije morfologije, poput strmijih padina čela jaruge ili unutrašnjih kanala (Sl. 156.), gdje se javljaju i najveće vrijednosti standardne devijacije (Sl. 157.A) i nesigurnosti udaljenosti (Sl. 157.B).

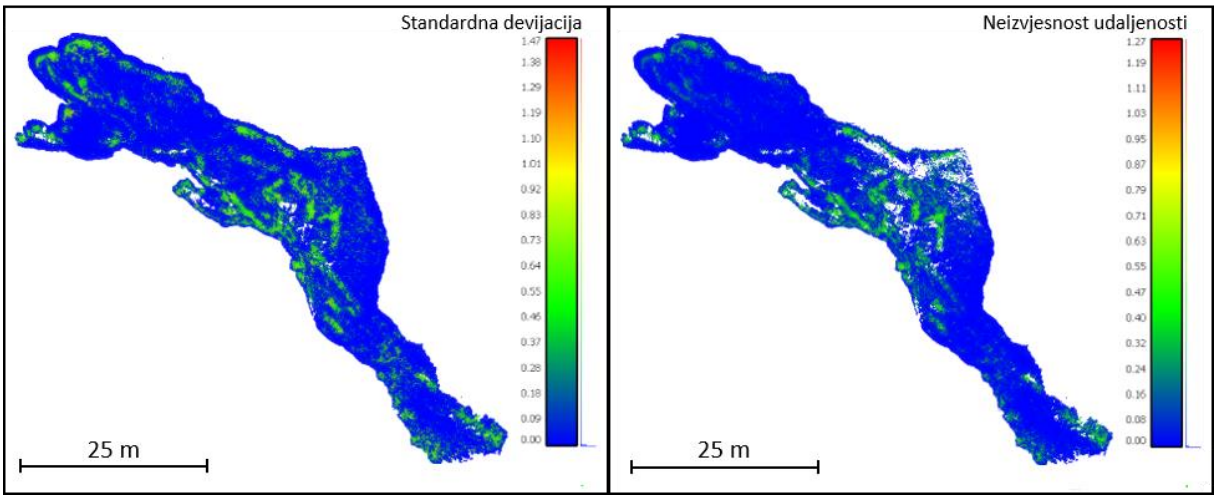

Slika 157. Prostorna distribucija standardne devijacije (A) i nesigurnost udaljenosti (B) između referentnog (TLS-A) i evaluiranog oblaka točaka (UAV-A) određena uz pomoć M3C2 algoritma

Ukoliko se u obzir uzme čitav UAV-A oblak točaka, uključujući 2.435 % ekstremnih vrijednosti, tada vrijednost prosječne M3C2 udaljenosti iznosi 0.01 m, uz standardnu devijaciju od 8 cm (Sl. 158). Pri tome treba napomenuti da mali udio ekstremnih vrijednosti koje se javljaju unutar prostora kompleksne morfologije, izrazito odstupa od preostalih vrijednosti M3C2 udaljenosti, zbog čega dolazi do znatnog podizanja vrijednosti ukupne standardne devijacije UAV-A oblaka točaka. Iz prostorne distribucije takvih ekstremnih vrijednosti vidljivo je da se one javljaju pretežito unutar i oko nepokrivenih dijelova strmih i prevjesnih padina (Sl. 159.). Nepokriveni prevjesni prostori rezultirali su pojavom praznina u UAV-A oblaku točaka, zbog kojih M3C2 algoritam unutar tih praznina nije mogao izračunati točne vrijednosti udaljenosti od referentnog TLS-A oblaka točaka.

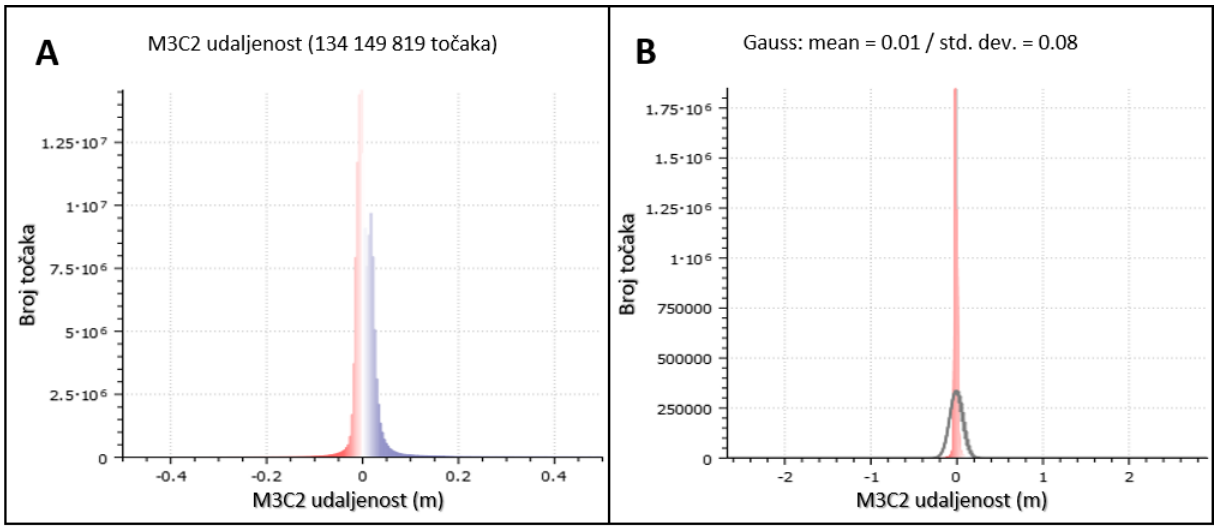

Slika 158. Histogram svih M3C2 udaljenosti između referentnog (TLS-A) i evaluiranog (UAV-A) oblaka točaka (A); Gaussova raspodjela vrijednosti M3C2 udaljenosti (B)

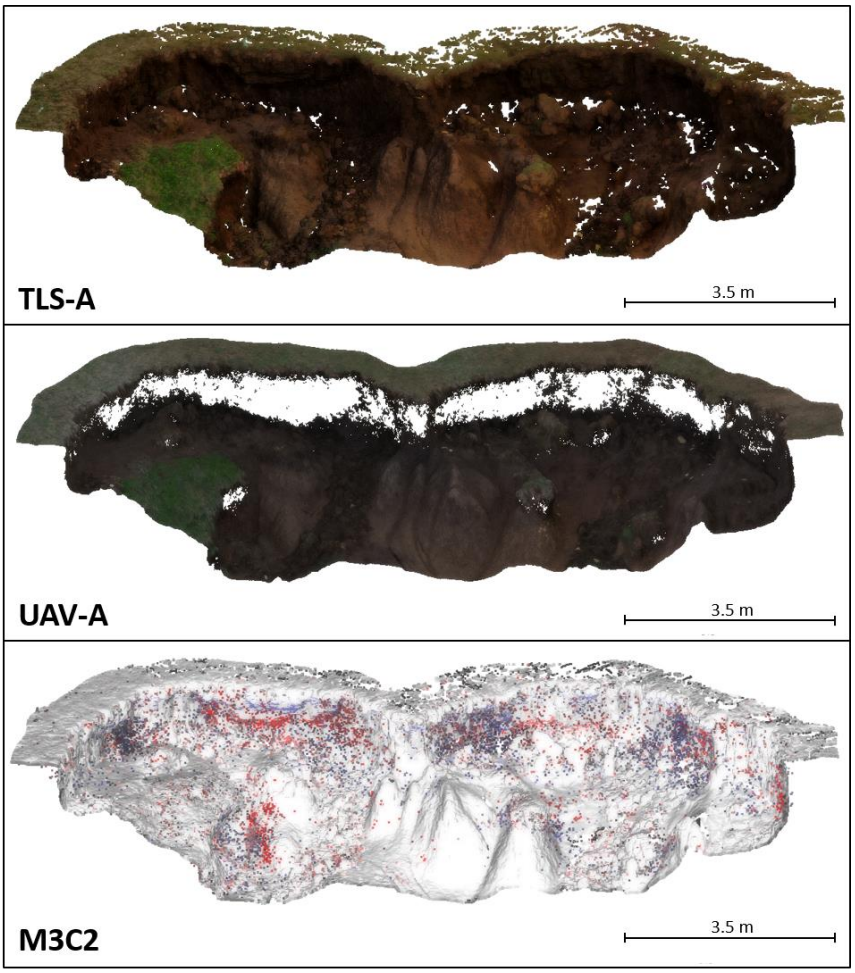

Slika 159. Utjecaj praznina u čeonom dijelu UAV-A oblaka točaka na pojavu ekstremnih vrijednosti M3C2 udaljenosti

Međutim, valja napomenuti da su na pojavnost utjecale i praznine u TLS-A oblaku točaka, koje iako ih ima znatno manje, ipak imaju određeni utjecaj na pojavu ekstremnih vrijednosti. Takav primjer vidljiv je na prostoru praznina u TLS-A oblaku točaka, vezanih za dno dubljeg kanala unutar jaruge Santiš (Sl. 160.).

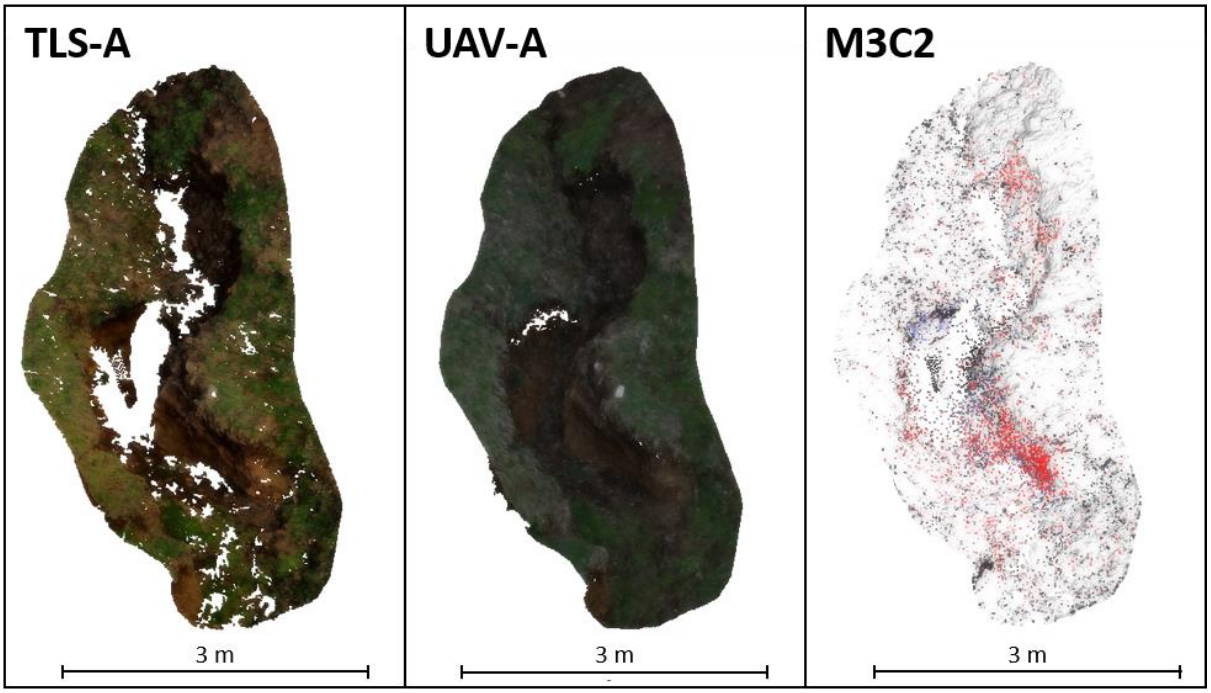

Slika 160. Utjecaj praznina u dnu dubokog kanala u TLS-A oblaku točaka na pojavu ekstremnih vrijednosti M3C2 udaljenosti

S obzirom da su se ovakve ekstremne vrijednosti javile unutar vrlo malog dijela područja istraživanja, može se zaključiti da one ne reprezentiraju sveukupnu točnost izrađenog UAV-A oblaka točaka. Primjerice, ukoliko se pogledaju samo vrijednosti M3C2 udaljenosti ispod ± 10 cm, koje obuhvaćaju čak preko 97 % svih točaka, tada prosječna vrijednost M3C2 udaljenost pada na 0.00 m, uz standardnu devijaciju od 0.02 m[51] (Sl. 161.). Ukoliko se pogledaju samo vrijednosti ispod ±2.5 cm (> 80 % točaka) tada vrijednost standardne devijacije i srednje kvadratne pogreške dodatno padaju.

Provedena analiza potvrdila je postignutu visoku točnost izrađenog UAV-A oblaka točaka, uz naglašenu potrebu za filtriranjem mjestimičnih ekstremnih vrijednosti uzrokovanih kompleksnom morfologijom jaruge. Pri tome se smanjenje pojavnosti tih ekstremnih

[51] RMSE izračunata na temelju 97.565 % točaka UAV-A oblaka točaka iznosi 0.0194 m (SD = 0.0188 m).

vrijednosti može ostvariti i kombiniranjem UAV-A oblaka točaka s podacima prikupljenim drugim terestričkim metodama (npr. TLS-A).

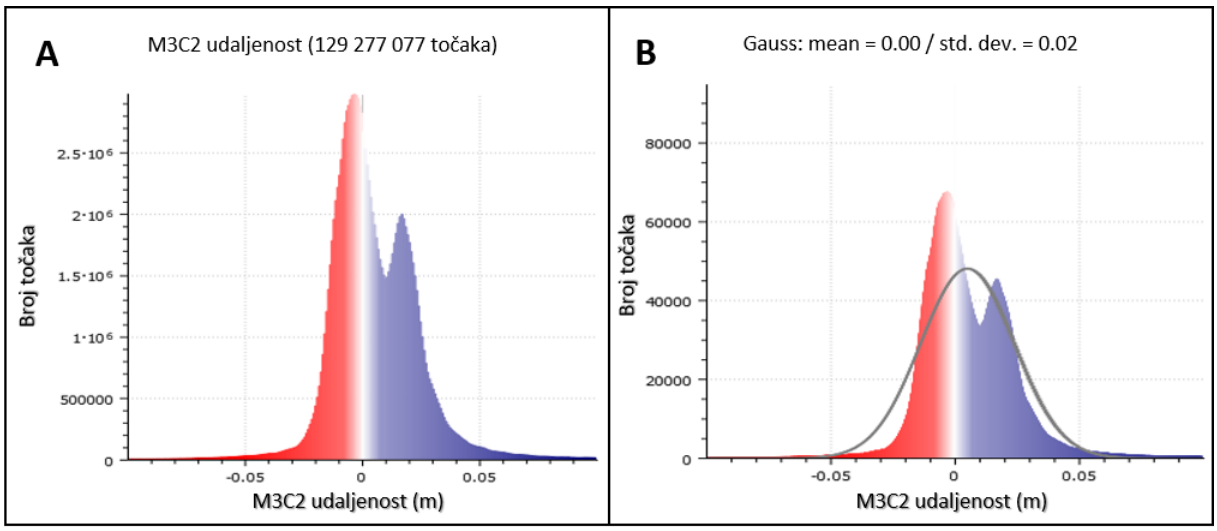

Slika 161. Histogram M3C2 udaljenosti manjih od ±10 cm (A); Gaussova raspodjela vrijednosti M3C2 udaljenosti manjih od ±10 cm (B)

4.3.3. Detektirane jednogodišnje PVP unutar užeg prostora mikro razine

I. Izrađeni modeli užeg prostora mikro razine istraživanja

Iz izrađenih intervalnih oblaka točaka (PC_{TLS-A} i PC_{TLS-B}) jaruge Santiš izdvojeni su odgovarajući oblaci točaka užeg prostora mikro razine istraživanja (Sl. 162.).

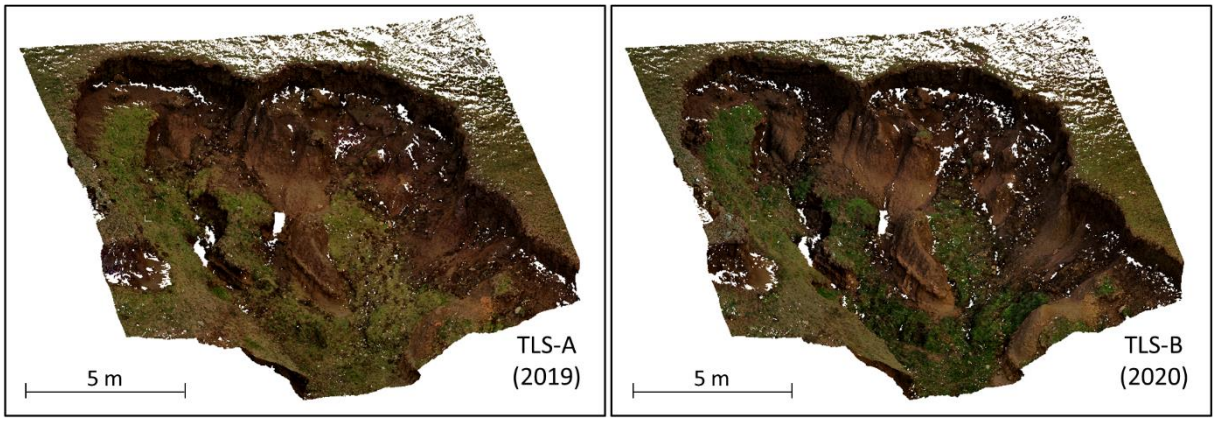

Slika 162. Izrađeni početni (A) i završni (B) intervalni oblak točaka užeg prostora mikro razine istraživanja izrađen iz podataka prikupljenih u sklopu intervalnih TLS izmjera jaruge Santiš

Dok je unutar užeg prostora mikro razine iz inicijalnog oblaka točaka (PC_{TLS-A}) izdvojeno je ukupno 26 650 295 točaka (prosječna gustoća točaka iznosi 95 179.63 točke/m^2), iz završnog oblaka točaka (PC_{TLS-B}) izdvojeno je 25 875 206 točaka, odnosno u prosjeku 92 411.45 točke/m^2 (Tabl. 65.).

Tablica 65. Pregled značajki izrađenih modela užeg prostora mikro razine istraživanja napravljenih iz podataka prikupljenih intervalnim TLS izmjerama

ID	Model (Datum prikupljanja)	Uređaj	Broj skenova	Oblak točaka	Gustoća točaka (n/m^2)	SD (RMSE)[52]
1	Model TLS-A (17.12.2019)	Faro Focus M70	7	26 650 295	95 179.63	0.004 (0.007)
2	Model TLS-B (04.12.2020)	Faro Focus M70	5	25 875 206	92 411.45	0.015 (0.018)

[52] Znatna razlika u vrijednostima SD (0.004 naspram 0.015 m) uzrokovana je prvenstveno PVP uzrokovanim erozijom tla, koje su se dogodile unutar promatranog jednogodišnjeg razdoblja.

Broj i gustoća točaka prikupljenih u sklopu dvije intervalne TLS izmjere približno jednak (broj točaka u PC_{TLS-B} odstupa za 2.91 % od broja točaka u PC_{TLS-A}), unatoč razlici u inicijalnom broju prikupljenih skenova. Podudarnost broja i gustoće točaka između dvije intervalne TLS izmjere rezultat je provedene homogenizacije gustoće oblaka točaka, provedene prilikom inicijalne obrade prikupljenih skenova. Iz prikaza prostorne varijacije u gustoći prikupljenih točaka vidljivo je da unutar testne plohe prevladava homogena gustoća točaka, uz iznimku prostora bližih stajalištima TLS-a (Sl. 163. ST 1 i 2). Također, vidljiva je i prisutnost nepokrivenih područja, koja su se u oba oblaka točaka javila na morfološki kompleksnim dijelovima plohe. Ostvarena podudarnost broja i gustoće točaka u izrađenim intervalnim oblacima točaka užeg prostora mikro razine istraživanja preduvjet je za daljnju usporedbu izrađenih oblaka točaka te detekciju i kvantifikaciju PVP.

Uz prikaz gustoće točaka korištenih za izračun udaljenosti, M3C2 algoritam izračunava i standardnu devijaciju zadanih intervalnih oblaka točaka (Sl. 164.). Zanemariva standardna devijacija inicijalnog intervalnog oblaka točaka (SD = 0.4 cm) neznatno je povećana kod drugog intervalnog oblaka točaka (SD = 1.5 cm). Iz prostorne distribucije povećanih vrijednosti standardne devijacije vidljivo je da takav porast standardne devijacije nije povezan s pogreškama u prikupljenom oblaku točaka, već s prostorima zahvaćenim PVP. S obzirom da su obje TLS izmjere napravljene s istim laserskim skenerom i identičnim postavkama skeniranja, RMSE izrađenih oblaka točaka trebala bi biti gotovo identična. Zbog toga je moguće zaključiti da je prostorni obuhvat povećane standardne devijacije vezan pretežito za dijelove područja istraživanja unutar kojih je u jednogodišnjem razdoblju došlo do značajnijih prostorno-vremenskih promjena. Na taj način razlika u standardnoj devijaciji između inicijalnog i završnog oblaka također može poslužiti za detekciju prostora unutar kojih je došlo do značajnijih PVP.

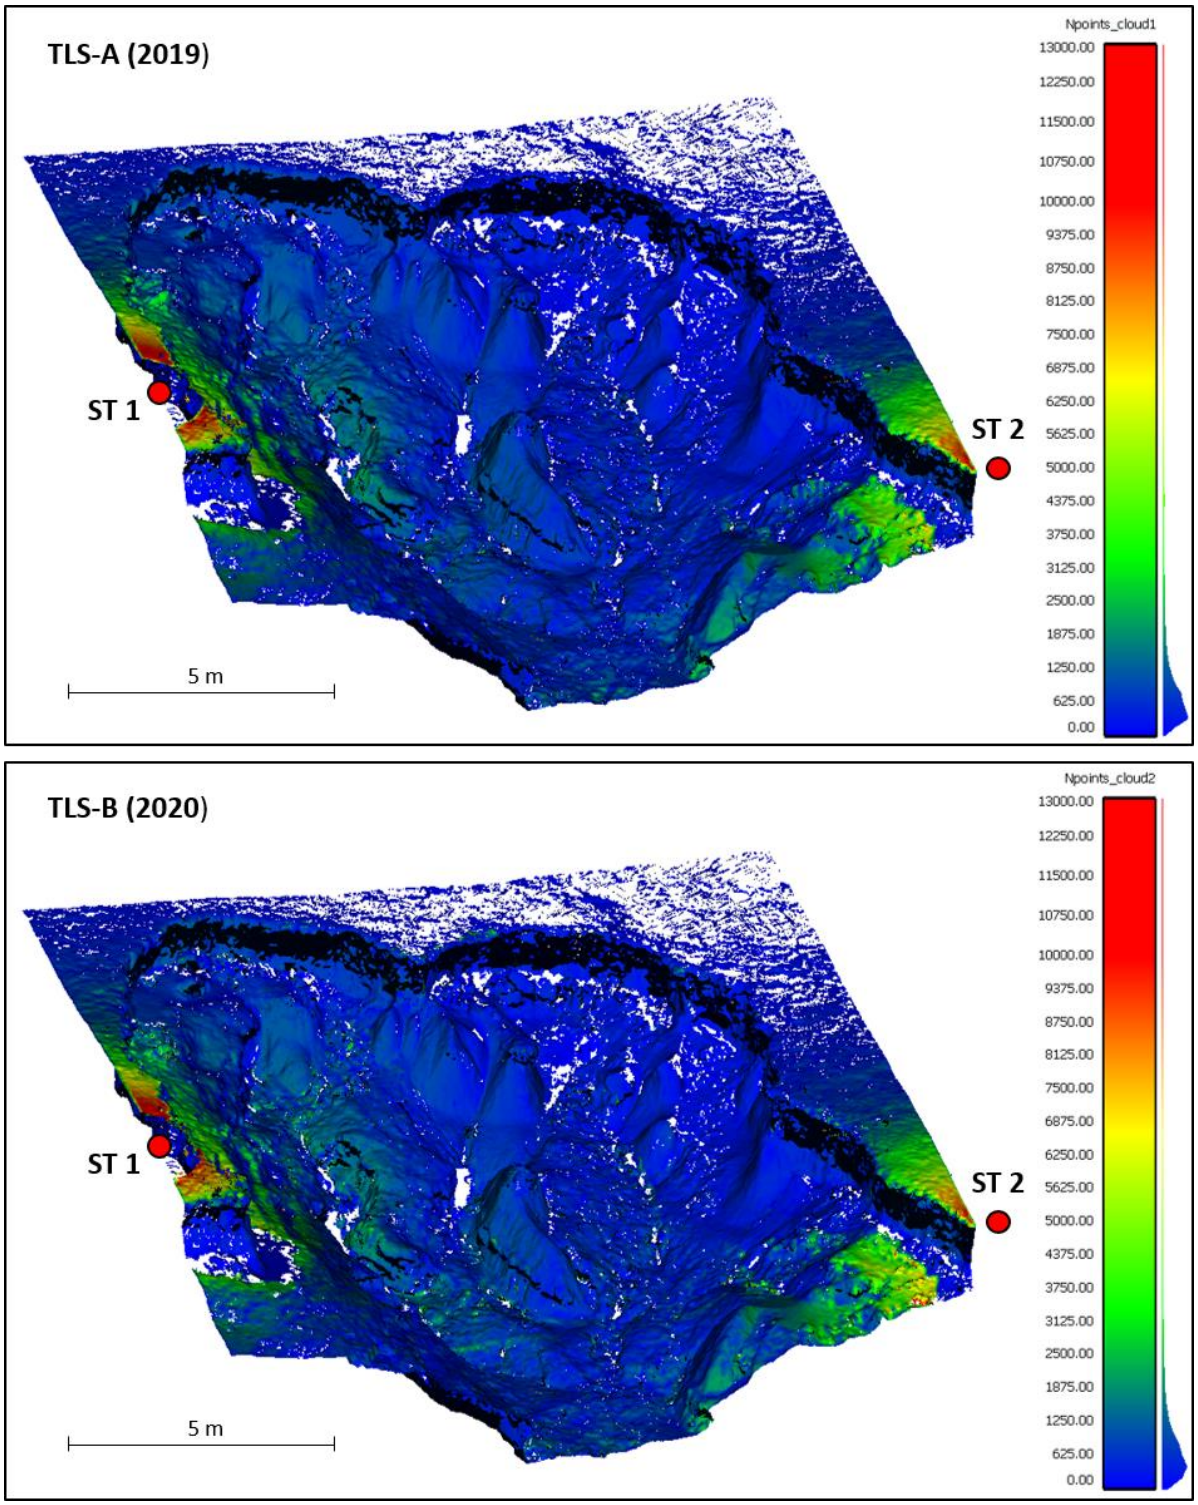

Slika 163. Usporedba između gustoće točaka korištenih za izračun M3C2 udaljenosti između TLS-A i TLS-B oblaka točaka

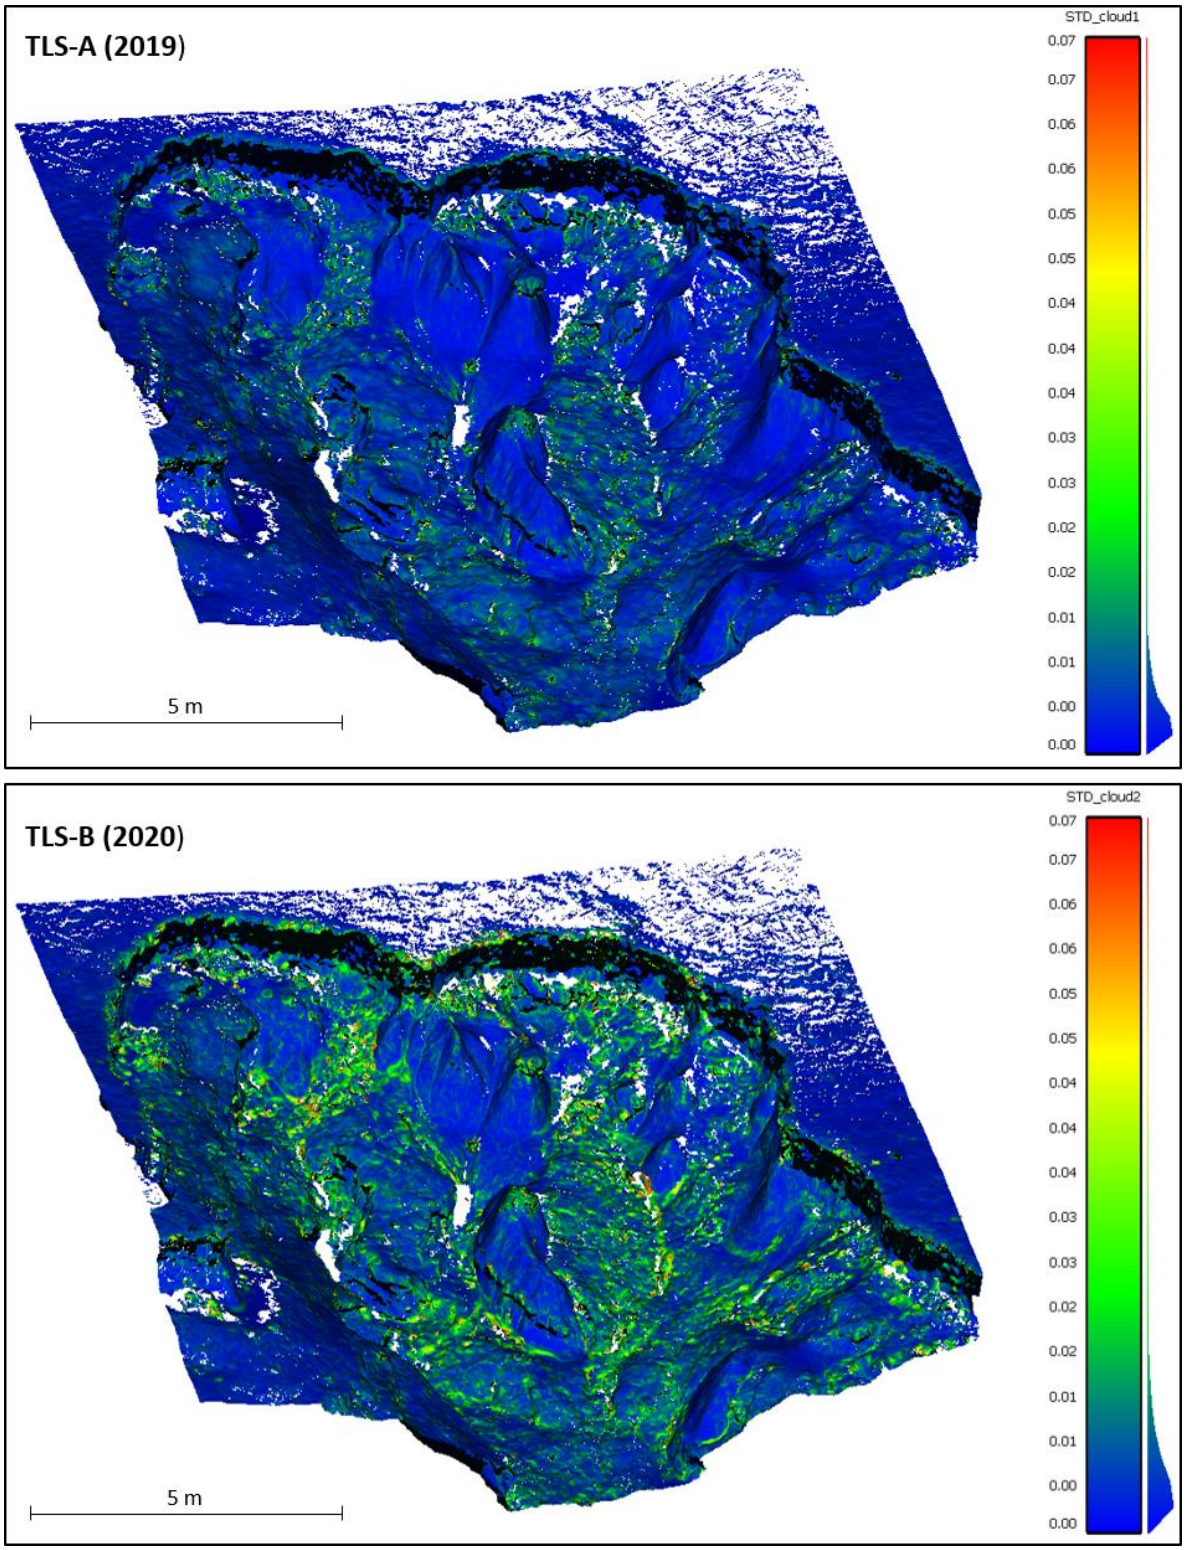

Slika 164. Usporedba između standardne devijacije izrađenog početnog (A) i završnog (B) oblaka točaka užeg prostora mikro razine istraživanja

Za razliku od detekcije PVP uz pomoć M3C2 algoritma, koja se zasnivala na usporedbi izrađenih intervalnih oblaka točaka užeg prostora mikro razine istraživanja, detekcija i kvantifikacija pomaka glavnog čela jaruge Santiš napravljena je uz pomoć razvijenog HCD alata, koji se temelji na upotrebi rasterskih modela. Zbog toga su na temelju izdvojenih intervalnih oblaka točaka napravljeni rasterski modeli užeg prostora mikro razine. Zbog ranije navedenih ograničenja korištenog LiDAR360 softvera prostorna rezolucija izrađenih rasterskih modela morala je biti podešena na 1 cm. Dok ukupna duljina dijela inicijalnog glavnog čela jaruge (TLS-A) iznosi 38.87 m, duljina izdvojenog dijela završnog čela jaruge (TLS-B) iznosi 39.27 m. Izrađeni rasterski modeli užeg prostora mikro razine istraživanja vidljivi su na slici 165.

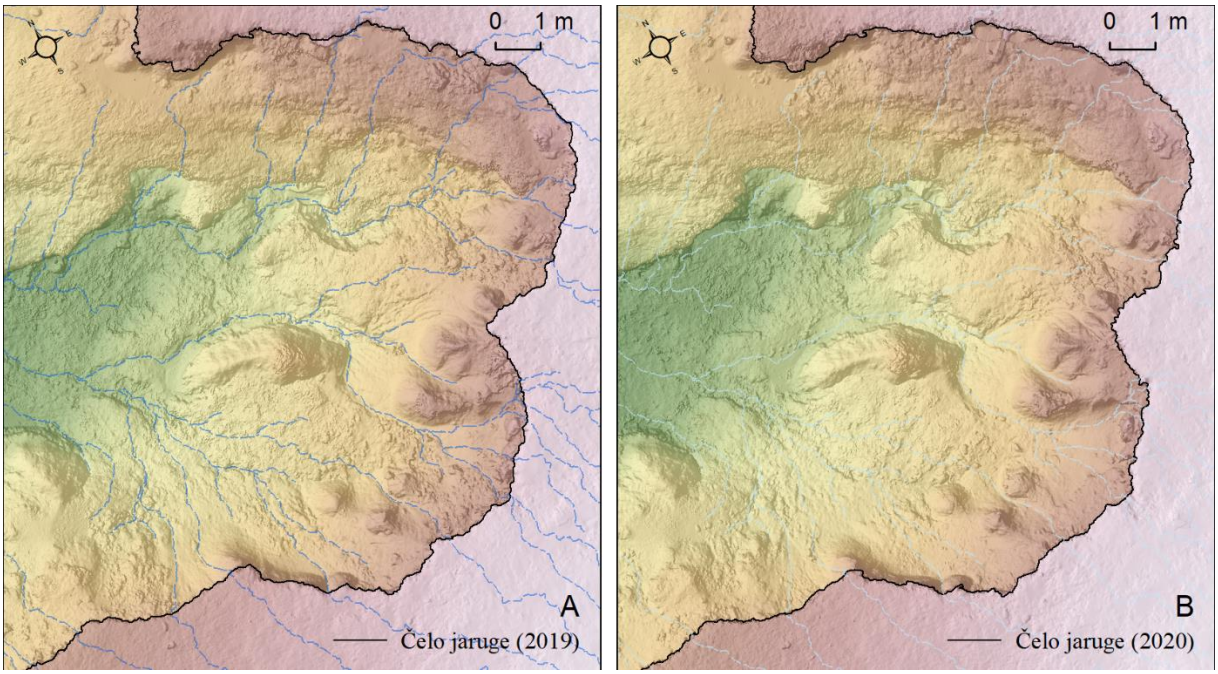

Slika 165. Izrađeni početni (A) i završni (B) rasterski model užeg prostora mikro razine istraživanja izrađen iz podataka prikupljenih u sklopu intervalnih TLS izmjera jaruge Santiš

II. Prostorno-vremenske promjene detektirane na temelju intervalnih oblaka točaka uz pomoć M3C2 alata

Na temelju primjene M3C2 algoritma uspješno su detektirane kompleksne linearne prostorno-vremenske promjene koje su pod utjecajem erozije tla nastale u jednogodišnjem promatranom razdoblju (prosinac 2019. – prosinac 2020) unutar užeg prostora mikro razine istraživanja. Dok su određene promjene zabilježene na gotovo cijelom području istraživanja, najznačajnije promjene zabilježene su pretežito unutar strmih padina promatranog dijela čela jaruge (Sl. 166.). Uz ove erozijske zone značajnije promjene zabilježene su u manjoj mjeri i u dnu čela jaruge, gdje je došlo do akumuliranja materijala. Pri tome se značajnim PVP smatraju sve promjene koje po intenzitetu nadilaze zadanu pogrešku u registraciji (engl. *registration error*), koja je podešena na 2.2 cm.

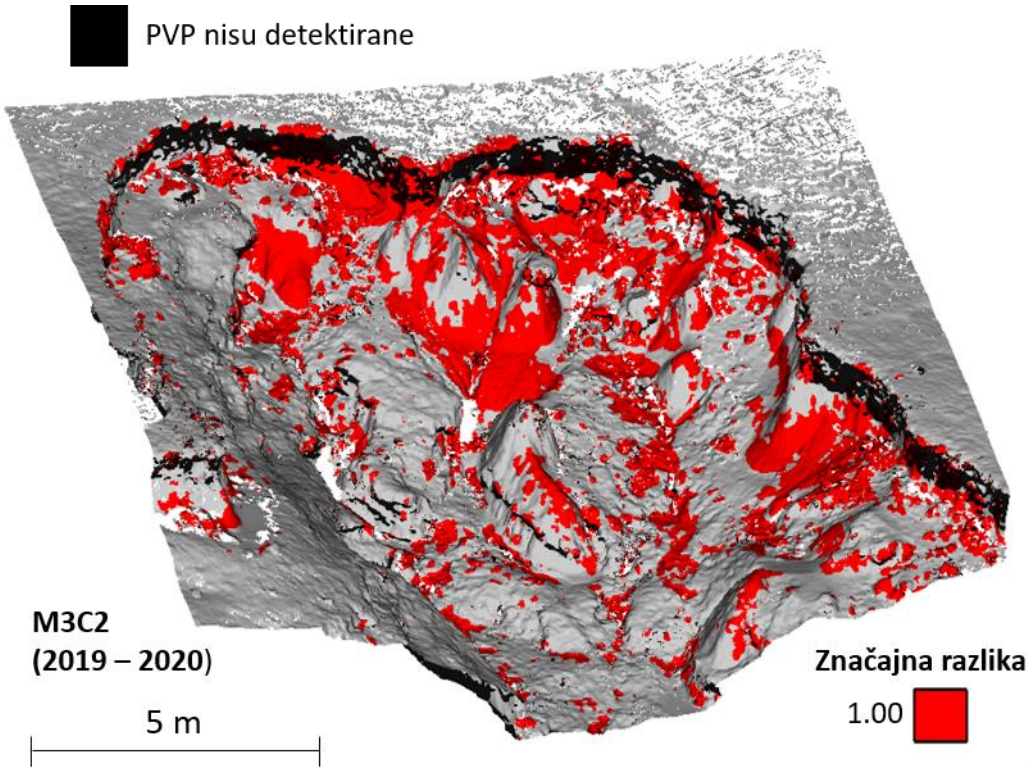

Slika 166. Značajne promjene detektirane unutar užeg prostora mikro razine uz pomoć M3C2 algoritma

Trenutačno M3C2 algoritam omogućava detekciju PVP duž samo jedne zadane osi (npr. Z os), zbog čega prilikom praćenja kompleksnih geomorfoloških procesa, kod kojih se PVP javljaju duž različitih osi, može doći do pojave prostora unutar kojih nije moguće detektirati promjene (Williams i dr., 2021). Pomak čela jaruge uzrokovan postupnim odronjavanjem

naslaga tla predstavlja takav kompleksan geomorfološki proces, kojega M3C2 može vrlo teško detektirati. Naime, dok odronjavanje naslaga tla dijelom uzrokuje prominentne vertikalne promjene (duž Z osi), usporedno zbog odronjavanja dolazi i do znatnog horizontalnog pomaka (duž X i/ili Y osi). Takvo višesmjerno pomicanje čela jaruge je prekompleksno za detekciju promjena uz pomoć M3C2 algoritma, što rezultira područjima unutar kojih nisu kvantificirane udaljenosti između intervalnih oblaka točaka (Sl. 166.). Navedeni nedostatak M3C2 algoritma razriješen je uz sklopu zadnje nadogradnje (Williams i dr., 2021), koja omogućava višesmjernu detekciju kompleksnih PVP. U sklopu budućih istraživanja bilo bi poželjno primijeniti navedenu unaprijeđenu verziju M3C2 algoritma, čim ona bude dostupna.

Unatoč navedenom nedostatku M3C2 algoritam uspješno je detektirao većinu intenzivnih PVP koje su unutar prostora istraživanja nastale u promatranom jednogodišnjem razdoblju. Unutar odabranog područja istraživanja prevladava erozija tla, koja je zabilježena u 72.37 % točaka (Sl. 167.A), pri čemu prosječna vrijednost M3C2 udaljenosti iznosi -1 cm, uz standardnu devijaciju od 5 cm (Sl. 167.B).

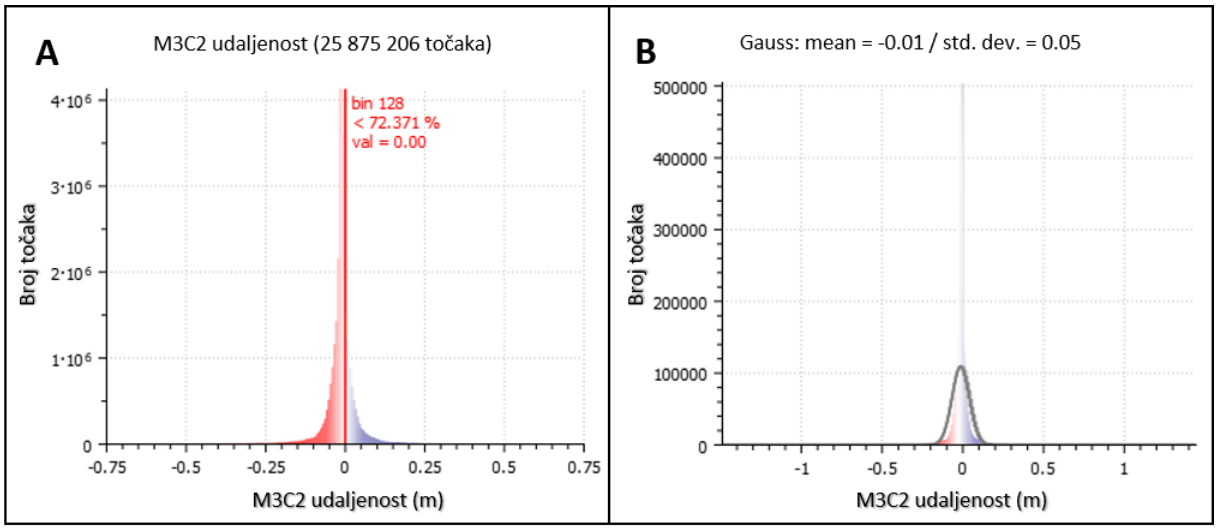

Slika 167. Histogram PVP detektiranih uz pomoć M3C2 algoritma (A); Gaussova raspodjela vrijednosti izračunatih uz pomoć M3C2 algoritma (B)

Iako je prosječni linearni intenzitet detektirane erozije tla relativno nizak (-1 cm/godišnje), unutar pojedinih dijelova područja istraživanja zabilježene su daleko intenzivnije vrijednosti erozije. Prvenstveno je vrlo intenzivna erozija tla prisutna unutar čela jaruge, gdje je unutar promatranog razdoblja došlo do odronjavanja oslabljenih prevjesnih naslaga tla. Takvo odronjavanje naslaga tla zabilježeno je duž analiziranog dijela čela jaruge unutar promatranog razdoblja na najmanje pet lokacija (Sl. 168.A). Pri tome intenzitet odronjavanja

naslaga tla mjestimice doseže i 75 cm. Osim intenzivnog odronjavanja naslaga tla, erozija tla zabilježena je i na strmim padinama ispod čela jaruge, gdje je došlo do daljnjeg spiranja materijala (Sl. 168.B). Prosječni linearni intenzitet ovakvog spiranja materijala znatno je manji od intenziteta odronjavanja u čelu jaruge, te većinom ne prelazi 30 cm.

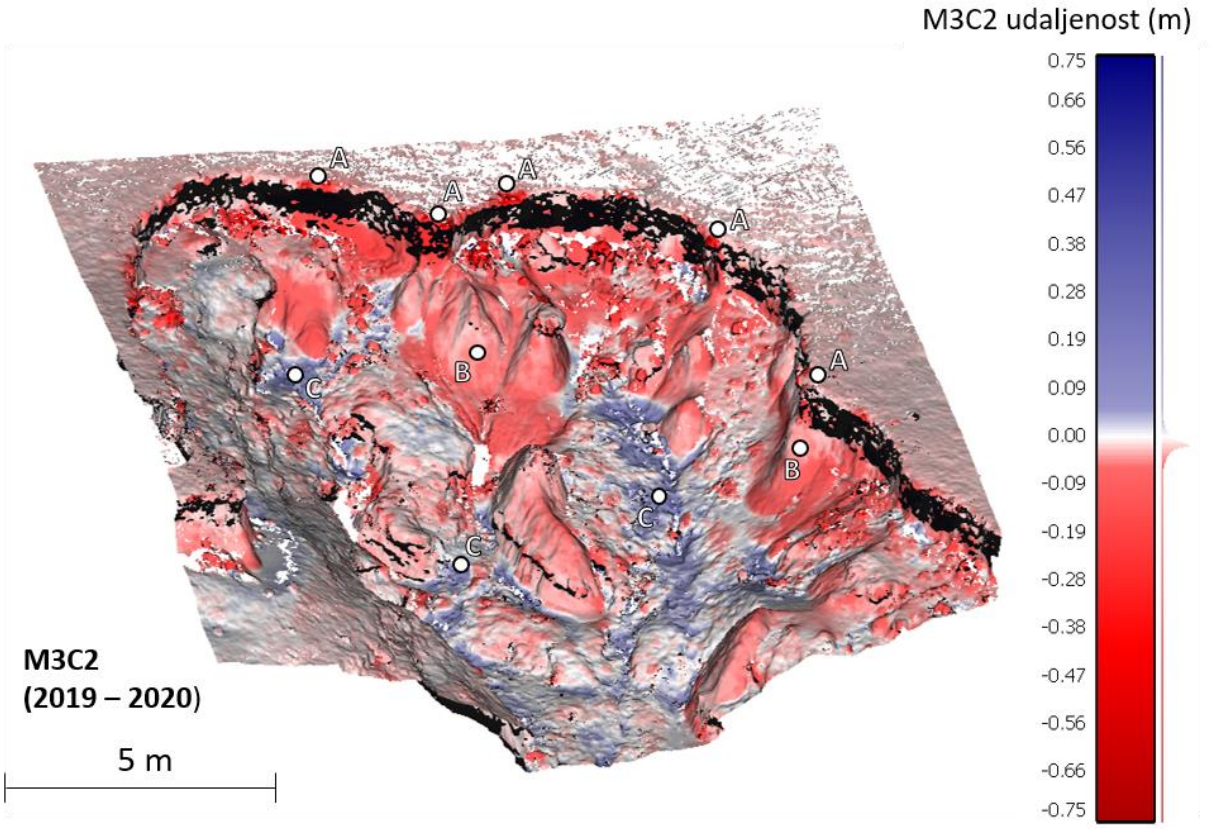

Slika 168. PVP detektirane unutar užeg prostora mikro razine uz pomoć M3C2 algoritma (A – odronjavanje naslaga tla i pomak čela jaruge; B – spiranje materijala na nagnutim padinama; C – akumulacija materijala u podnožju čela jaruge)

Također, osim erozije tla unutar područja istraživanja zabilježena je i akumulacija erodiranog materijala, koja je ipak slabijeg intenziteta i prostornog obuhvata od detektirane erozije tla. Većina akumulacije materijala lokalizirana je nedaleko od podnožja strmih padina čela jaruge (Sl. 168.C), gdje dolazi do slabljenja transportne moći padinskih procesa i povremenog površinskog otjecanja. Zabilježene lokacije i vrijednosti akumulacije materijala potkrjepljuju rezultate mezo razine istraživanja, prema kojima se dio erodiranog materijala taloži nedaleko od čela jaruge. Međutim, manji intenzitet zabilježene akumulacije od erozije tla svjedoči o tome da površinsko otjecanje ipak uspijeva transportirati manju količinu erodiranog materijala izvan mikro razine područja istraživanja.

Navedene PVP posebice se jasno razaznaju iz još detaljnijeg isječka izrađenog modela (Sl. 169.), koji jasno reprezentira sve etape opisanog procesa, od postupnog erodiranja (A i B) i transportiranja (C), do konačne akumulacije materijala (D).

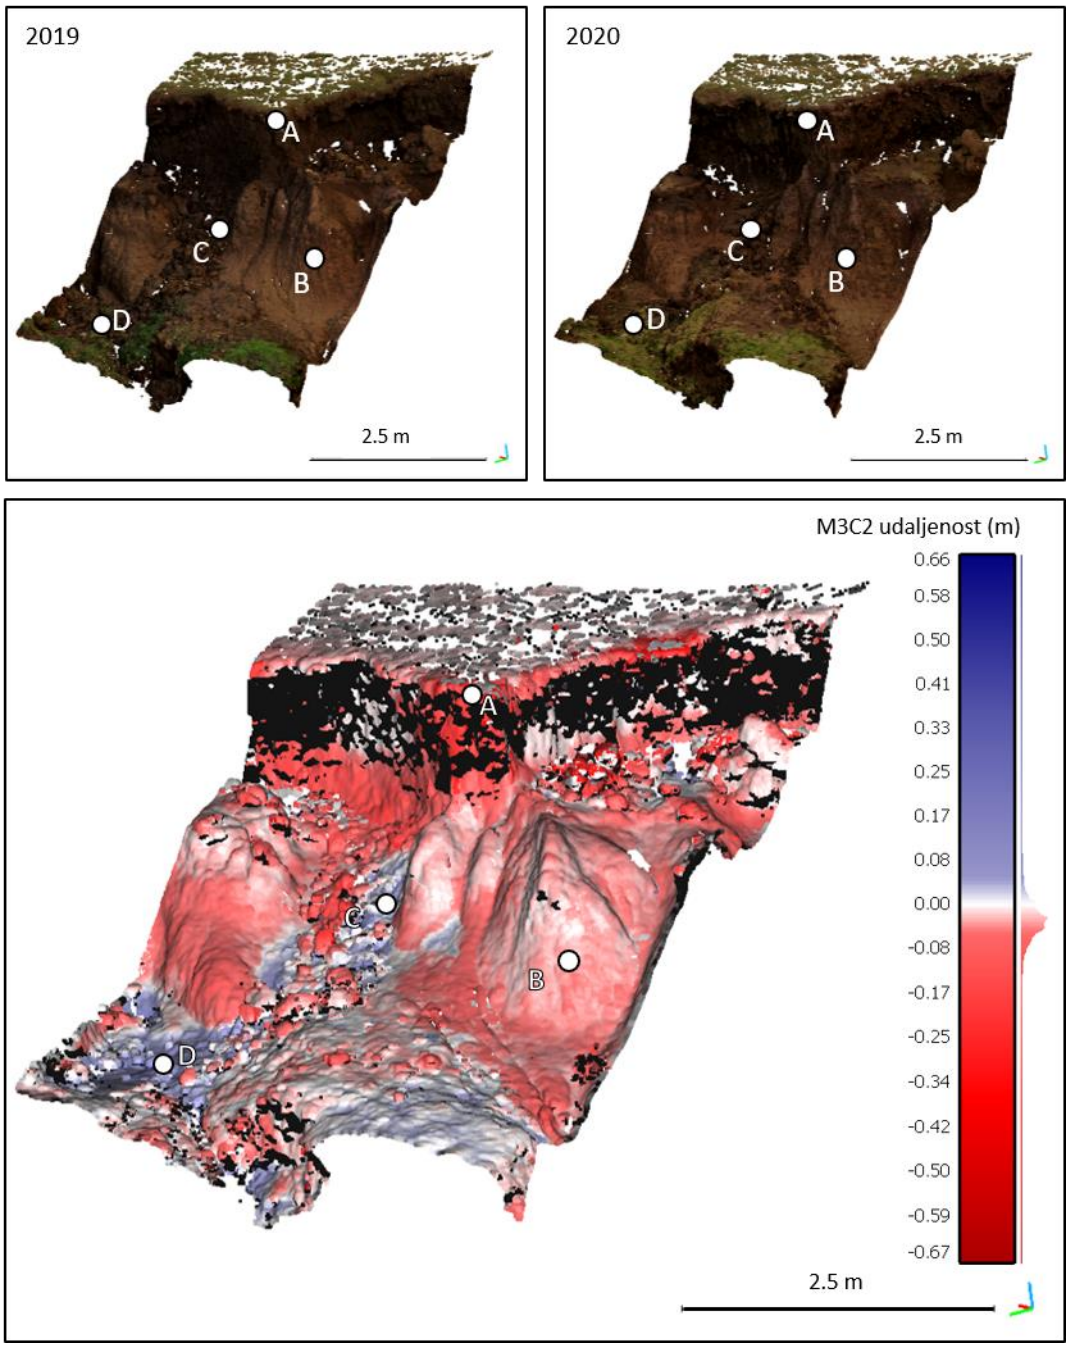

Slika 169. Isječak dijela čela jaruge unutar kojega se jasno vidljive detektirane PVP (A – odronjavanje naslaga čela jaruge; B – spiranje na ogoljenim padinama čela jaruge; C – transportiranje materijala padinskim procesima i površinskim otjecanjem; D – akumulacija materijala u podnožju čela jaruge)

III. Prostorno-vremenski pomak čela jaruge utvrđen na temelju razvijenog HCD alata

Postupni retrogradni pomak čela jaruge jedna je od osnovnih obilježja aktivnih jaruge (Vanmaercke i dr., 2016), zbog čega je kvantifikacija pomaka jedan od osnovnih načina za kontinuirano praćenje progresivnog razvoja jaruga. Razvijeni HCD alat omogućio je automatsku detekciju i kvantifikaciju linearnog, površinskog i volumetrijskog pomaka čela jaruge, pri čemu je alat primijenjen na modelima užeg prostora mikro razine istraživanja. Prema ranije objašnjenoj metodologiji (vidi 3.3.3.) iz izrađenih rasterskih modela ($DSM_{TLS2019}\ i\ DSM_{TLS2020}$) automatski su izdvojene linije koje predstavljaju čelo jaruge Santiš (Sl. 169.A). Izdvojene linije čela jaruge poslužile su kao osnova za detekciju prostorno-vremenskih promjena nastalih u jednogodišnjem razdoblju od 17. prosinca 2019. do 04. prosinca 2020. godine. Pri tome je već običnom vizualnom usporedbom izvedenih linija razvidno da je unutar promatranog jednogodišnjeg razdoblja došlo do značajnih promjena uzrokovanih djelovanjem erozije tla. Detaljni prikaz utvrđenih vrijednosti linearnog pomaka čela jaruge dan je u tablici 65.

Tablica 65. Linearne prostorno-vremenske promjene uzrokovane pomakom čela jaruge

ID	Prostorno-vremenska promjena	Broj izmjerenih linija	Ukupne promjene (m)	Prosječna promjena (cm)	Minimalna promjena (cm)	Maksimalna Promjena (cm)	STDEV (cm)
1	Erozija	1964.00	96.89	4.93	0.00	23.58	4.84
2	Akumulacija	380.00	7.12	1.87	0.00	10.36	1.58

Provedenom analizom utvrđen je retrogradni linearni pomak čela jaruge, uzrokovan intenzivnom erozijom tla. Nazadovanje čela jaruge zabilježeno je u ukupno 1964 izmjerene linije, odnosno 83.79 % svih izmjerenih linija. Dok prosječni retrogradni pomak čela jaruge iznosi 4.93 cm, maksimalne vrijednosti pomaka dosežu i preko 23 cm. Ovakvo intenzivno linearno nazadovanje čela jaruge Santiš uzrokovano je postupnim odronjavanjem većih komada naslaga tla (Sl. 121; 123.B.), koje je zabilježeno i tijekom ranije provedenih istraživanja. Naime, na istom lokalitetu u razdoblju od svibnja 2017. do ožujka 2019. godine zabilježen je prosječni jednogodišnji linearni pomak čela jaruge od 5.43 cm, dok je maksimalni jednogodišnji pomak iznosio 24.85 cm (Domazetović, 2018; Šiljeg i dr., 2021).

Za razliku od erozije tla, akumulacija tla je zabilježena u znatno manje izmjerenih linearnih uzoraka, njih 380 (16.21 % svih izmjerenih linija). Prosječno pozitivni pomak čela

jaruge iznosi 1.87 cm, dok maksimalne vrijednosti pomaka dosežu do 10.36 cm. S obzirom da proces erozije tla općenito uzrokuje postupno odronjavanje i nazadovanje čela jaruge, odnosno retrogradno pomicanje, prisutnost ovakvog pozitivnog pomaka na prvi pogled nije očekivana. Međutim, kada se detaljnije analizira prostorna distribucija dijelova čela jaruge unutar kojih su zabilježeni progresivni pomaci vidljivo je da su oni također povezani s odronjavanjem materijala (Sl. 171.B). Naime, prije odronjavanja većih komada naslaga tla dolazi do njihovog postupnog odvajanja od preostalog kompaktnog dijela naslaga smeđeg tla i nastanka tenzijskih pukotina (Sl. 170.). Postupnim širenjem tenzijskih pukotina komadi naslaga tla se postupno odvajaju od kompaktnog dijela naslaga tla, te se prije samog odronjavanja zbog tog širenja cijeli zahvaćeni komadi tla pomiču prema naprijed u odnosu na liniju čela jaruge (Sl. 170.).

Slika 170. Nastanak tenzijskih pukotina prije odronjavanja naslaga tla

Utvrđeni površinski pomak čela jaruge potvrđuje ranije navedeno linearno pomicanje čela jaruge (Tabl. 67.). U promatranom jednogodišnjem razdoblju PVP su zabilježene na površini od ukupno 1.59 m^2, unutar koje se čak 99.37 % te površine odnosi na eroziju tla, odnosno zabilježeno odronjavanje naslaga tla. Iz prikaza prostorne distribucije površinskih retrogradnih pomaka čela jaruge vidljivo je da pomak nije jednoličan duž cijelog čela jaruge,

već da se ističu određene zone unutar kojih je zabilježeno intenzivnije odronjavanje naslaga tla. Većina izdvojenih zona intenzivnijeg odronjavanja naslaga tla iz čela jaruge povezana je s tokovima povremenog površinskog otjecanja (Sl. 171.B). Naime, može se pretpostaviti da koncentriranije površinsko otjecanje prilikom ekstremnijih oborinskih događaja utječe na slabljenje kohezije u rubnim naslagama tla čela jaruge, čijom ispiranjem dolazi do inicijacije odronjavanje.

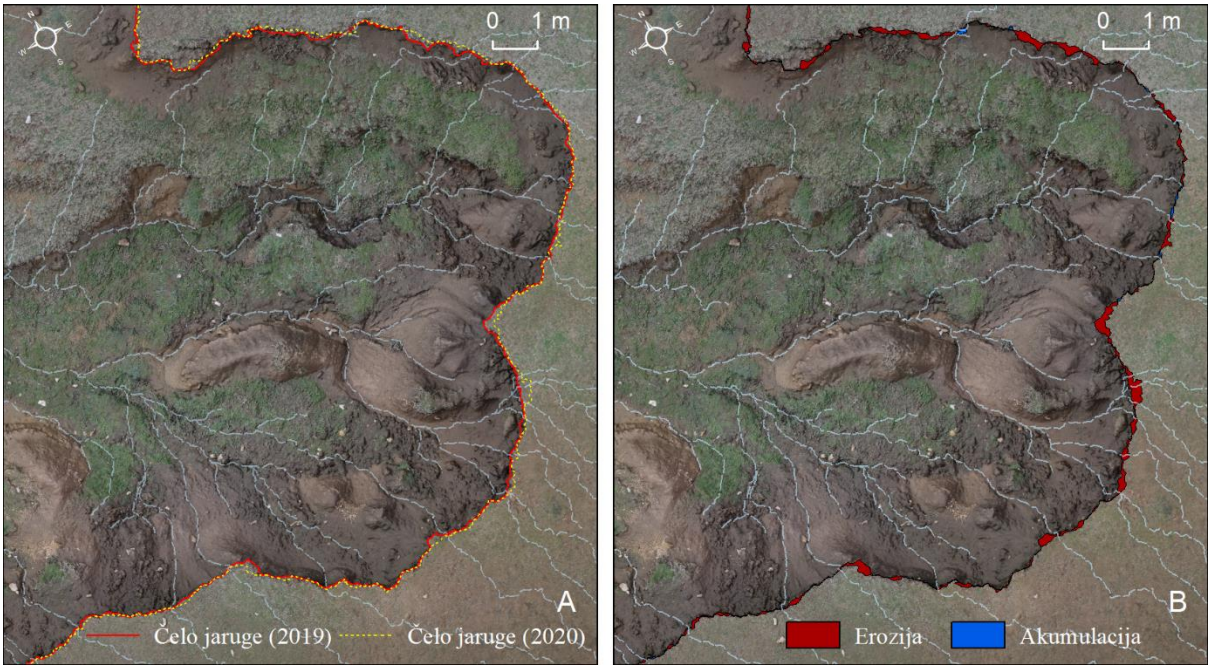

Slika 171. Prostorna distribucija površinskog pomaka čela jaruge detektiranog HCD alatom

Volumetrijske promjene utvrđene uz pomoć HCD alata pokazale su da je unutar promatranog jednogodišnjeg razdoblja retrogradni pomak čela jaruge rezultirao sa ukupno 1.14 m³ erodiranog materija (Tabl. 66).

Tablica 67. Površinske i volumetrijske PVP uzrokovane pomakom čela jaruge

Proces	Površinske promjene		Volumetrijske promjene	
	m²	%	m³	%
Erozija	1.58	99.37	1.14	95.80
Akumulacija	0.1	0.63	0.05	4.20
Ukupno	1.59	100	1.19	100

IV. Prednosti i nedostaci razvijenog HCD alata

Razvijeni HCD alat omogućio je u potpunosti automatiziranu detekciju i kvantifikaciju linearnih, površinskih i volumetrijskih promjena uzrokovanih pomakom čela jaruge. Primjena razvijenog HCD alata na primjeru intervalnih linija čela jaruge izdvojenih unutar uže razine mikro razine istraživanja ukazala je na nekoliko bitnih prednosti i nedostataka razvijenog alata. U nastavku su ukratko pojašnjene prednosti i nedostaci HCD alata:

(1) Automatizirana detekcija i kvantifikacija pomaka – proces detekcije i kvantifikacije pomaka u sklopu razvijenog alata je u potpunosti automatiziran, čime se znatno smanjuje utjecaj korisnika na pojavu pogrešaka. Zahvaljujući automatizaciji cijeli proces mjerenja je znatno pojednostavljen i ubrzan, pri čemu HCD alat izračunava sve tri komponente pomaka unutar nekoliko minuta. Također, u slučaju linearnog pomaka automatizacija mjerenja pomaka omogućila je izvođenje statističkih pokazatelja na temelju daleko većeg broj linija (npr. u slučaju jaruge Santiš – 2344 linije). Ručno mjerenje tolikog broja linija bilo bi vrlo sporo i mukotrpno.

(2) Prilagodljivost alata – s obzirom da razvijeni alat omogućava detekciju i kvantifikaciju linearnog, površinskog i volumetrijskog pomaka čela jaruge, primjenjiv je u različitim situacijama. Primjerice, kada su dostupni samo 2D modeli (DOF; satelitski snimci; itd.) čela jaruge HCD alat omogućava izračun linearnog i površinskog pomaka. S druge strane uz linearni i površinski pomak HCD alat u slučajevima kada su dostupni 2.5D modeli (DMR ili DSM) omogućava i izračun volumetrijskog pomaka. Zbog navedene prilagodljivosti dostupnim modelima korisnici mogu koristiti pojedine (npr. samo izračun linearnog pomaka), ili sve tri komponente alata, ovisno o podacima koji su im dostupni.

(3) Prostorna komponenta detektiranih promjena – izračunati linearni, površinski i volumetrijski intenzitet pomaka čela jaruge moguće je prostorno prikazati, što omogućava analizu prostorne distribucije detektiranih pomaka. Zahvaljujući ovoj mogućnosti detektirane promjene moguće je dovesti u vezu s različitim drugim prostornim informacijama (npr. lokacija tokova površinskog otjecanja; geološki i pedološki sastav podloge; prisutnost vegetacije; itd.), čime se olakšava daljnja interpretacija detektiranih progresivnih i retrogradnih pomaka.

(4) Primjenjivost alata – osim za detekciju i kvantifikaciju pomaka čela jaruga razvijeni HCD alat može se koristiti i za praćenje pomaka drugih linearnih geomorfoloških formi.

Primjerice, HCD alat potencijalnu primjenjivost mogao bi imati kod longitudinalnog praćenja kretanja obalne linije (a), ili za praćenje napredovanja ili regresije ledenjaka (b).

Osim navedenih prednosti, prilikom primjene HCD alata unutar užeg prostora mikro razine istraživanja uočeni su određeni nedostaci razvijeno alata. Navedene nedostatke potrebno je u sklopu daljnjih istraživanja riješiti kroz daljnji razvoj i nadogradnju razvijenog alata. Primijećeni nedostaci HCD alata su:

(1) Nekompatibilnost s 3D modelima – trenutačno primjena HCD alata ograničena je na 2D i 2.5D modele, prvenstveno zbog ograničenja alata integriranih u sklopu ArcGIS 10.1 softvera. Radi sve veće dostupnosti različitih 3D modela i zbog činjenice da 3D modeli često točnije reprezentiraju kompleksne morfološke oblike (Gómez-Gutiérrez i Gonçalves, 2020) bilo bi poželjno da HCD alat bude kompatibilan s takvim modelima.

(2) Ovisnost mjerenja o točnosti reprezentacije linije čela jaruge – automatizacija mjerenja utjecala na maksimalno smanjenje utjecaja korisnika na pojavu pogrešaka. Međutim, točnost mjerenja u znatnoj mjeri i dalje ovisi o točnosti reprezentacije čela jaruge u zadanim intervalnim linijama. Dok je točnost automatski generirane linije čela jaruge podložna točnosti modela korištenih za automatsko izdvajanje, ali i pogreškama koje proizlaze iz automatskog izdvajanja, točnost ručno izdvojene linije ovisna je o točnosti vektorizacije korisnika.

5. POTVRDA TEMELJNIH HIPOTEZA ISTRAŽIVANJA

- **H.1. Točnost modela podložnosti eroziji tla izvedenog isključivo na temelju WV podataka visoke rezolucije (DMR i MS) bit će AUC > 0.8.**

Navedena hipoteza je **potvrđena**. Izrada modela podložnosti eroziji tla obavljena je kroz primjenu višerezolucijskog GIS modeliranja, zasnovanog na korištenju 17 različitih predisponirajućih kriterija i jednom ograničavajućeg Boolean kriterija. Svi korišteni kriteriji generirani su izravno iz digitalnog modela reljefa i multispektralnog snimka otoka Paga, prostorne rezolucije 1 m. DMR i multipektralni snimak su pripremljeni na temelju dostupnih Worldview satelitskih snimaka. Izračunate AUC vrijednosti pokazale su da gotovo svi izrađeni modeli podložnosti prostora otoka Paga eroziji tla bilježe vrijednosti iznad 0.8, dok najbolji izrađeni model (**VMPET-2**) bilježi AUC vrijednost i iznad 0.9[53].

Zbog vrlo loše detaljnosti i kvalitete dostupnih podataka u procesu višekriterijskog modeliranja nisu korišteni određeni za eroziju tla značajni kriteriji, poput pedološke i litološke podloge. Dok su za prostor otoka Paga najdetaljniji podaci o litološkoj podlozi dostupni s postojećih geoloških karata u mjerilu 1:100 000 (Mamužić i Sokač, 1973; Sokač i dr., 1976; Majcen i dr., 1976), podaci o pedološkoj podlozi su dostupni s postojećih pedoloških karata u mjerilu 1:50 000 (Bogunović i Rapaić, 1993; Bogunović i dr., 1997). Prema Tobleru mjerilo navedenih geoloških i pedoloških karata bi odgovaralo rasterskim modelima prostorne rezolucije od 50, odnosno 25 m (Tobler, 1987; 1988). Takva rezolucija ovih podataka bila je već prepoznata kao nedostatna i u sklopu ranijeg istraživanja (Domazetović i dr., 2019a), gdje je prostorna rezolucija izrađenog modela podložnosti bila 15 m. S obzirom da modeli otoka Paga generirani na temelju WV satelitskih snimaka imaju prostornu rezoluciju od 1 m, zaključeno je da bi korištenje podataka o pedološkoj i geološkoj podlozi, tako niske razine detaljnosti potencijalno znatno devalviralo generirane modele podložnosti. Primjerice, iz istog razloga podaci o pedološkoj i litološkoj podlozi isključeni su iz modeliranja podložnosti i u istraživanjima provedenim ranije od strane Dewitte i dr., (2015), te Gómez-Gutiérrez i dr. (2015). Radi toga u sklopu ove disertacije u konačnici podaci o pedološkoj i geološkoj podlozi nisu korišteni u procesu višekriterijskog modeliranja. Iako se podaci o litološkoj i pedološkoj podlozi gotovo standardno koriste prilikom modeliranja podložnosti eroziji tla (Gómez-Gutiérrez i dr., 2009a; 2009b; Akgün i Türk, 2011;Conforti i dr., 2011; Conoscenti i dr., 2013; 2014; Arabameri i dr., 2019; Arabameri i dr., 2020b), pri čemu se često smatraju i jednim od

[53] Gledano na temelju 30% referentnih točkastih uzoraka s izdvojenom tampon zonom od 15 m,

važnijih predisponirajućih kriterija (npr. litološka podloga (Arabameri i dr., 2019; Arabameri i dr., 2020b), rezultati ove disertacije dokazali su da se visoka točnost modela podložnosti može postići i bez njihovog korištenja. Ovakvi rezultati posebice su važni za modeliranje podložnosti erozije tla u područjima gdje podaci o geološkoj i pedološkoj podlozi nisu dostupni, jer ili ne postoje, ili jer njihova kvaliteta nije dostatna za modeliranje. Nadalje, Worldview satelitski snimci omogućavaju relativno jednostavnu izradu modela visoke (DMP i DMR) i vrlo visoke rezolucije (MS snimak) za vrlo velika područja (nekoliko stotina km^2), pri čemu se minimalizira potrebni terenski rad (Goldbergs i dr., 2019). Upravo zbog toga su postignute AUC vrijednosti (> 0.8) značajne, jer dokazuju da WV modeli mogu biti korišteni kao osnova za modeliranje podložnosti s visokom točnosti, unutar regionalnog obuhvata makro razine istraživanja erozije tla.

- **H.2. Najveću vrijednost AUC imati će model kod kojega je najveći težinski koeficijent dodijeljen grupi morfometrijskih predisponirajućih kriterija.**

Navedena hipoteza je **potvrđena**. Izrađene ROC krivulje i izračunate AUC vrijednosti potvrdile su da najveću točnost ima model podložnosti eroziji tla (VMPET-2) kod kojega je najveći težinski koeficijent dodijeljen grupi morfometrijskih predisponirajućih kriterija. Grupa morfometrijskih predisponirajućih kriterija obuhvaća kriterije koji su neizostavni kod modeliranja podložnosti eroziji tla, poput nagiba padina (Magliulo i dr., 2010; Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; 2014; Rahmati i dr., 2016; 2017a; Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b) ili pak zakrivljenosti padina (Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; Rahmati i dr., 2016; Nhu i dr., 2020; Arabameri i dr., 2019; 2020a; 2020b). Zbog toga je osnovna pretpostavka bila da će upravo model podložnosti kod kojega je najveći težinski koeficijent biti pridodan ovoj grupi kriterija biti najtočniji prema izračunatim AUC vrijednostima.

Prema izrađenim ROC krivuljama i AUC vrijednostima izračunatim na temelju validacijskog seta podataka, kojega predstavlja 30% referentnih erozijskih lokacija, VMPET-2 model podložnosti bilježi AUC vrijednost od 0.913. Također, VMPET-2 model podložnosti bilježi najveću AUC vrijednost (0.854) i kod validacije napravljene na temelju 10 referentnih jaruga. Navedene AUC vrijednosti potvrdile su da je VMPET-2 model rezultirao boljom točnosti od modela ujednačenog značaja grupa kriterija (VMPET-1), ili naglašenijeg značaja grupe hidroloških (VMPET-3) ili ostalih (VMPET-4) kriterija. Ovi rezultati značajni su za buduća istraživanja koja će se baviti modeliranjem podložnosti eroziji tla, a koja će također

koristiti različite hijerarhijski vrednovane morfometrijske, hidrološke i ostale predisponirajući kriterije.

- **H.3. Višegodišnji volumetrijski (m^3) intenzitet erozije tla unutar istraživanog područja mezo razine biti će najveći unutar jaruge Santiš.**

Navedena hipoteza je **potvrđena.** Prostor poluotoka Santiš karakterizira vrlo visoka prostorna zastupljenost različitih potprocesa erozije tla (EKK, spiranje, brazdanje, jaruženje), koja je potvrđena i izrađenim modelom podložnosti (VMPET-2). Takav utjecaj procesa erozije tla odrazio se i na visoku pojavnost različitih erozijskih formi unutar poluotoka, među kojima se po dimenzijama i recentnim tragovima erozije tla ističu sljedeće jaruge: *jaruga Santiš, jaruga Uska, jaruga Stepeničasta, jaruga Mala* i *Zečja jaruga*. Tijekom inicijalnih terenskih istraživanja tragovi recentne erozije tla zabilježeni su unutar svih pet navedenih jaruga, pri čemu su tragovi erozije bili najintenzivniji unutar prostora postojećih šest čela jaruga (GH-1 – GH-6). Jaruga Santiš je jedina jaruga unutar koje su u naslagama smeđeg tla debljine nekoliko metara oblikovana dva odvojena čela jaruge (GH-1 i GH-2). Veće, glavno čelo jaruge Santiš (GH-1) s ukupnom širinom od 92.5 m predstavlja najveće čelo unutar poluotoka Santiš, ali ujedno i jedno od najvećih čela na cijelom otoku. Osim po prisutnosti ovih erozijskih oblika, jaruga Santiš se ističe i po najvećem slivnom području (16.08 ha) unutar poluotoka Santiš, ali i značajnim naslagama tla. Unutar slivnog područja razvijena je razgranata mreža povremenih površinskih tokova, ukupne duljine 6.66 km, koji upravo na prostoru naslaga tla formiraju tok 4. reda po Strahleru. Ranija istraživanja dokazala su da veličina slivnog područja jaruge izravno utječe na sposobnost generiranja površinskog otjecanja potrebnog za inicijaciju erozije tla (Le Roux i Sumner, 2012). Pri tome veća slivna područja imaju veći potencijal za formiranje površinskog otjecanja dovoljnog volumena za inicijaciju erozije tla (Vanmaercke i dr., 2016). Upravo zbog toga je pretpostavljeno da će od svih jaruga na poluotoku Santiš višegodišnji intenzitet erozije tla biti najveći unutar jaruge Santiš.

Navedena pretpostavka potvrđena je na temelju prostorno-vremenskih promjena uzrokovanih erozijom tla, koje su detektirane unutar promatranog višegodišnjeg razdoblja (2014. – 2018.). PVP detektirane na temelju intervalnih modela poluotoka Santiš dokazale su da je najveći intenzitet erozije tla zabilježen upravo unutar jaruge Santiš, gdje je na 138.51 m^2 erozijom zahvaćene površine ukupno erodirano 172.87 m^3 tla. U istom višegodišnjem razdoblju erozija tla je unutar cijelog poluotoka Santiš zabilježena na površini od 164.34 m^2, uz ukupno 201.28 m^3 erodiranog materijala. Iz toga proizlazi da je čak oko 82 % ukupne površine

zahvaćene erozijom tla, te 85.89 % ukupne količine erodiranog tla detektirano unutar jaruge Santiš, dok je preostalih 18 % zahvaćene površine, te oko 14 % erodiranog materijala vezano za preostale četiri jaruge. Iz navedenih vrijednosti vidljivo je da je najveći višegodišnji intenzitet erozije tla definitivno zabilježen unutar jaruge s najvećim slivnim područjem i najvećom razvijenosti erozijskih formi (GH-1 i GH-2).

- **H.4. Utvrđene jednogodišnje stope PVP uzrokovane erozijom tla će značajno (> 10%) odstupati od utvrđenih višegodišnjih vrijednosti.**

Navedena hipoteza je **potvrđena.** Pojavnost i intenzitet procesa erozija tla ovise o brojnim prirodnim i antropogenim predisponirajućim čimbenicima (Valentin i dr., 2005; Poesen i dr., 2006; Poesen, 2011; Castillo i Gómez, 2016; Vanmaercke i dr., 2016; Borrelli i dr., 2020), čija međusobna interakcija i utjecaj uvjetuju postupni nastanak i intenzitet različitih erozijom tla uzrokovanih prostorno-vremenskih promjena. Castillo i Gómez (2016) i Vanmaercke i dr. (2016) u sklopu detaljne analize rezultata većine do tada dostupnih istraživanja vezanih za intenzitet erozije tla zaključuju da je vremenska varijabilnost intenziteta erozije tla u pravilu izrazito velika. Pri tome jednogodišnje vrijednosti intenziteta erozije tla unutar određenog prostora mogu varirati od potpunog izostanka erozije tla (0 m^3), pa sve do vrijednosti 2-3 puta većih od uobičajenog višegodišnjeg prosjeka (Vanmaercke i dr., 2016). Značajno izražena varijabilnost intenziteta erozije tla zabilježena je i u brojnim pojedinačnim istraživanjima, koja su se bavila proučavanjem erozijskih formi različitih dimenzija i prostornog obuhvata, poput *ogolina* (Aucelli i dr., 2016; Neugirg i dr., 2016; Fernández i dr., 2020), *jaruga* (Morgan i Mngomezulu, 2003; Campo-Bescósi dr., 2013; Gómez-Gutiérrez i dr., 2014) i *brazdi* (Eltner i dr., 2014). Upravo zbog toliko izražene varijabilnosti intenziteta erozije tla Vanmaercke i dr. (2016) ističu da se vrijednosti intenziteta erozije tla zasnovane na kratkoj vremenskoj rezoluciji mjerenja (< 5 godina) ne mogu uzimati kao relevantan pokazatelj pravog intenziteta erozije na nekom području. Sukladno tome osnovna pretpostavka bila je da će jednogodišnji intenzitet erozije tla zabilježen unutar jaruge Santiš znatno (> 10 %) odstupati od prosječnih višegodišnjih vrijednosti.

U sklopu ove disertacije praćenje višegodišnjeg intenziteta erozije tla provedeno je za prostor poluotoka Santiš unutar petogodišnjeg razdoblja (2014. – 2018.), pri čemu je zabilježeno ukupno 201.28 m^3 erodiranog materijala, od čega je čak 172.87 m^3 (85.89 %) erodirano unutar jaruge Santiš. Prosječna godišnja vrijednost intenziteta erozije u jaruzi Santiš u promatranom razdoblju je 34.57 m^3 tla. Jednogodišnji intenzitet erozije tla praćen je unutar

jaruge Santiš u razdoblju između 17. prosinca 2019. i 17. prosinca 2020. godine te je uz pomoć visokorezolucijskog DMD-a utvrđen intenzitet erozije tla od ukupno 13.46 m^3 erodiranog materijala. Iz toga proizlazi da je u jednogodišnjem promatranom razdoblju zabilježen intenzitet erozije tla za 61.06 % manji od ranije navedene prosječne višegodišnje vrijednosti. Ovakvo odstupanje od višegodišnje prosječne vrijednosti potvrđuje postavljenu hipotezu, ali i povlači brojna pitanja o potencijalnim uzrocima smanjenog intenziteta erozije tla, što je svakako vrijedno daljnjeg proučavanja, koje će biti usmjereno na utvrđivanje uzroka navedenih oscilacija u intenzitetu erozije tla.

Jedan od potencijalnih uzroka nižeg jednogodišnjeg zabilježenog intenziteta u odnosu na prosječnu višegodišnju vrijednost vjerojatno je povećana sušnost promatranog jednogodišnjeg razdoblja (2019.-2020.). Naime, pojedina ranija istraživanja dokazala su da je smanjenje ukupne količine i intenziteta oborina izravno utjecalo na smanjenje intenziteta erozije tla (Campo-Bescós i dr., 2013). *In-situ* prikupljeni podaci o količini i intenzitetu oborina, te iz njih izračunati oborinski indikatori potvrđuju da je unutar prostora jaruge Santiš u jednogodišnjem razdoblju došlo do znatnog opadanja svih šest odabranih statističkih oborinskih pokazatelja u odnosu na prosječnu vrijednost višegodišnjeg razdoblja (2014. – 2018.). Primjerice, ukupna godišnja količina oborina jednogodišnjeg razdoblja manja je za gotovo 229.86 mm (odnosno 18.71 %). Također, MDR je u jednogodišnjem razdoblju niži za gotovo 29.40 mm d^{-1} (31.80 %), što neupitno ukazuje da je intenzitet oborina bio ispod višegodišnjeg prosjeka.

Međutim, u obzir treba uzeti i činjenicu da utvrđeno odstupanje jednogodišnjeg zabilježenog intenziteta erozije tla, u odnosu na prosječnu višegodišnju vrijednost može biti uzrokovan i drugim čimbenicima, poput razlike u prostornoj rezoluciji[54] modela korištenih za detekciju PVP. Neizvjesnost DMD-a na temelju kojega je utvrđena prosječna višegodišnja vrijednost intenziteta je daleko veća, od neizvjesnosti modela korištenih za izračun jednogodišnjih vrijednosti intenziteta tla. Zbog toga je moguće da su određeni artefakti prisutni u modelima sitnije rezolucije (npr. uvjetovanim pojavom sjena) mogli u određenoj mjeri utjecati na izračun PVP, odnosno na pojavu „lažne“ erozije ili akumulacije materijala. S druge strane kod jednogodišnjih modela (UAV-A i UAV-B) neizvjesnost je znatno manja, čime je i manja mogućnost da su utvrđene vrijednosti intenziteta erozije tla podložne ujtecaju artefakata.

[54] DMD izrađen za cijeli poluotok Santiš ima prostornu rezoluciju od 30 cm (LOD3), dok prostorna rezolucija DMD-a za jarugu Santiš iznosi 1 cm (LOD4).

Da bi se osigurala bolja usporedivost jednogodišnjih vrijednosti erozije tla s višegodišnjim vrijednostima, u sklopu daljnjih istraživanja bilo bi poželjno analizirati sve dostupne aerofotogrametrijske snimke Državne geodetske uprave. Time bi se utvrdile vrijednosti višegodišnjeg intenziteta erozije tla unutar prostora poluotoka Santiš za znatno duže vremensko razdoblje (1959. – 2018.), što bi omogućilo detaljniju usporedbu s prikupljenim meteorološkim podacima. Tek tada bi bilo moguće sa sigurnošću utvrditi da li detektirane jednogodišnje vrijednosti erozije tla (2019. – 2020.) doista u tolikoj mjeri odudaraju od prosječnih višegodišnjih vrijednosti, ili se radi o izoliranom slučaju. Također, tek tada bi bilo moguće utvrditi utjecaj sušnijih razdoblja na intezitet erozije te postoji li pozitivna podudarnost između tih varijabli (manje oborina, manji intenzitet erozije tla) te postojanje variracije intenziteta erozije tla na godišnjoj razini, kako je zabilježeno u sličnim provedenim istraživanjima (Morgan i Mngomezulu, 2003; Castillo i Gómez, 2016; Vanmaercke i dr., 2016).

- **H.5. Višegodišnji intenzitet erozije tla zabilježen unutar jaruge Santiš biti će u skladu s vrijednostima RUSLE2015 modela.**

Navedena hipoteza je **potvrđena.** RUSLE2015[55] model predstavlja do sada najdetaljniji pan-europski model procijenjenog gubitka tla izazvanog erozijom tla uzrokovanom djelovanjem vode (Panagos i dr., 2015c). Osnovna prednost RUSLE15 modela nad ranijim modelima procjene gubitka tla, je ostvarena relativno visoka prostorna rezolucija modela (100 m)[56], te činjenica da je izrađen na temelju sljedećih predisponirajućih čimbenika provjerene kvalitete: *erozivnost oborina* (Panagos i dr., 2015a), *erodibilnost tla* (Panagos i dr., 2015e), *upravljanje pokrovom* (Panagos i dr., 2015e), *topografija* (Panagos i dr., 2015d) te *praksa podrške* (Panagos i dr., 2015d). Prema RUSLE2015 modelu Hrvatska je prema prosječnoj stopi gubitka tla (3.1 t/ha y^{-1}) među srednje ugroženim zemljama Europske Unije (Panagos i dr., 2015a). Unatoč tome pojedini priobalni dijelovi Hrvatske se ističu po vrlo visokim vrijednostima prosječne stope gubitka tla, koja mjestimice iznosi i iznad 50 t/ha y^{-1} (Panagos i dr., 2015a). Prema RUSLE2015 modelu znatan dio otoka Paga bilježi vrijednosti procijenjenog gubitka tla iznad 10 t/ha y^{-1}, pri čemu se generalno zone viših vrijednosti poklapaju s zonama visoke i vrlo visoke podložnosti eroziji tla unutar izrađenog VMPET-2 modela. Prema visokim vrijednostima na RUSLE2015 modelu se ističe prostor poluotoka Santiš, unutar kojeg prevladavaju vrijednosti procijenjenog gubitka tla između 20 i 50 t/ha y^{-1}. Pojedina ranija

[55] Revised Universal Soil Loss Equation (RUSLE)

[56] Visoka prostorna rezolucija s obzirom na razinu detaljnosti (LOD1), odnosno na prostorni obuhvat izrađenog modela (cijela EU).

istraživanja su dokazala da vrijednosti gubitka tla procijenjene RUSLE metodom odgovaraju vrijednostima zabilježenim na terenu direktnim (npr. *erozijski klinovi* (Hancock i dr., 2008)), ili indirektnim (npr. *intervalna UAV fotogrametrija* (Bazzoffi, 2015) metodama prikupljanja podataka. Soga je pretpostavljeno da će višegodišnji intenzitet erozije tla izračunat za područje poluotoka Santiš na temelju intervalnih aerofotogrametrijskih snimaka biti u skladu s vrijednostima u RUSLE2015 modelu.

Višegodišnja (2014. – 2018.) detekcija i kvantifikacija PVP provedena unutar šireg prostora mezo razine istraživanja pokazala je da prosječni jednogodišnji intenzitet erozije tla unutar jaruge Santiš iznosi 34.57 m^3. Navedeni erodirani volumen odgovara stopi masene promjene od 32.71 t/ha y^{-1}, što se podudara s vrijednostima iz RUSLE2015 modela za prostor jaruge Santiš (20 – 50 t/ha y^{-1} (Panagos i dr., 2015c)). Podudaranje vrijednosti intenziteta erozije tla potvrdilo je točnost RUSLE2015 modela. Potvrda točnosti RUSLE2015 modela posebno je značajna ako se u obzir uzme da je ovaj model izrađen za prostor cijele EU, s razinom detaljnosti znatno nižom (LOD1) od razine detaljnosti istraživanja provedenih unutar šireg prostora mezo razine istraživanja (LOD3). S obzirom da RUSLE2015 model predstavlja trenutačno najdetaljniji dostupni model procjene gubitka tla za prostor EU (Panagos i dr., 2015c), podudarnost vrijednosti potvrđuje i točnost vrijednosti izračunatih u sklopu ove disertacije. Za dodatnu provjeru trebalo bi u sklopu daljnjih istraživanja obraditi sve dostupne aerofotogrametrijske snimke. Time bi se na temelju izrađenih intervalnih modela omogućio izračun višegodišnjeg intenziteta erozije tla unutar znatno dužeg vremenskog razdoblja (npr. 1997.-2018.), te bi se tad mogla provjeriti podudarnost utvrđenih višegodišnjih PVP, izračunatih za duže vremensko razdoblje, s vrijednostima definiranim RUSLE2015 modelom.

H.6. Najveći volumetrijski (m^3) intenzitet erozije tla unutar jaruge Santiš biti će zabilježen unutar naslaga smeđeg tla i unutar najstrmijih padina.

Navedena hipoteza je **odbačena.** Recentni tragovi erozije tla zabilježeni su tijekom inicijalnih terenskih istraživanja početkom 2019. godine unutar gotovo čitave jaruge Santiš. Međutim, najintenzivniji tragovi erozije tla bili su prisutni unutar dva čela jaruge (GH-1 i GH-2), koja su formirana unutar naslaga *smeđeg tla*. Upravo unutar ovih dijelova jaruge zabilježeni su tragovi recentnog intenzivnog odronjavanja čeonih naslaga smeđeg tla uzrokovanog postupnim retrogradnim pomakom čela jaruge (Sl. 133; 142). Postupni retrogradni pomak čela jaruge jedna je od osnovnih obilježja aktivnih jaruga (Gómez-Gutiérrez i dr., 2009c; Rieke-Zapp i Nichols, 2011; Campo-Bescósi dr., 2013; Vanmaercke i dr., 2016). Zbog toga je na

temelju uočenih tragova recentne erozije i rezultata ranijih istraživanja (Domazetović, 2018; Šiljeg i dr., 2021) postavljena hipoteza da će najveći volumetrijski intenzitet erozije tla biti zabilježen upravo unutar prostora dvaju postojećih čela jaruga, odnosno unutar naslaga smeđeg tla.

Provedena analiza temeljena na usporedbi intervalnih modela jaruge Santiš omogućila je detekciju i kvantifikaciju jednogodišnjih (17. prosinca 2019. – 17. prosinca 2020.) prostorno-vremenskih promjena uzrokovanih erozijom tla. Utvrđene PVP su pri tome dovedene u odnos s izrađenom litološkom kartom krupnog mjerila. Suprotno očekivanom najrasprostranjenija i najintenzivnija erozija tla zabilježena je unutar litoloških jedinica *karbonatnih pješčenjaka i pijesaka*, unutar koje je zahvaćeno 67.32 m² površine, uz 6.80 m^3 erodiranog materijala. S druge strane unutar naslaga *smeđeg tla* zahvaćeno je 70.15 m² površine, uz 4.84 m^3 erodiranog materijala.

Prema navedenim vrijednostima postavljena hipoteza prema kojoj je intenzitet erozije tla najveći unutar naslaga smeđeg tla **nije potvrđena**. Uzrok većih PVP unutar karbonatnih pješčenjaka je intenzivna selektivna erozija tla, koja je unutar središnjeg kanala jaruge Santiš uzrokovala odronjavanje većeg komada kompaktnijeg dijela pješčenjaka. Iako selektivna erozija rezultira intenzivnim PVP, učestalost ovakvih odronjavanja je relativno mala, što je i potvrđeno time da ovakve promjene na prostoru jaruge Santiš nisu zabilježene od početka istraživanja 2017. godine (Domazetović, 2018; Šiljeg i dr., 2021.). Istovremeno, unutar jednogodišnjeg promatranog razdoblja (2019.-2020.) intenzivni tragovi erozije tla zabilježeni su na naslagama smeđeg tla. Erozija se u većoj mjeri odnosi na odronjavanje čeonih naslaga tla u glavnom i sporednom čelu jaruge Santiš, ali i na tragove brazdanja i spiranja. Međutim, intenzitet ovih PVP ipak je slabiji od intenziteta promjena uzrokovanih selektivnom erozijom unutar karbonatnog pješčenjaka.

H.7. *Optimizacija intervalnog laserskog skeniranja omogućiti će pokrivenost > 90% kompleksne morfologije testnog područja.*

Navedena hipoteza je **potvrđena.** Pojedine erozijske forme oblikovane djelovanjem procesa erozije tla (npr. jaruge) karakterizira izražena vertikalna raščlanjenost, koja potencijalno može dovesti do pojave različitih praznina i artefakata u prikupljenom oblaku točaka (Marzolff i Poesen, 2009; Stöcker i dr., 2015; Perroy i dr., 2010; Domazetović i dr., 2020). Posebice se nedostaci neplanski provedenog terestričkog laserskog skeniranja ističu

unutar prostora dubljih dijelova kompleksnijih jaruga (Perroy i dr., 2010). Većina navedenih problema povezana je s primjenom nesistematičnog terestričkog laserskog skeniranja, kojemu nije prethodilo temeljito planiranje provođenja laserske izmjere. Naime, zbog vremenskih i financijskih ograničenja, faza planiranja i pripreme zanemarena je u mnogim istraživanjima, gdje su broj i optimalne lokacije *stajališta terestričkog laserskog skenera* (STLS) određeni na izravno na terenu, najčešće prema prosudbi i iskustvu istraživača (npr. Perroy i dr., 2010; Bremer i Sass, 2012; Rengers i Tucker, 2015; Goodwin i dr., 2016; 2017). Goodwin i dr. (2017) primjerice ističu da određivanje optimalnog broja i rasporeda lokacija postavljanja TLS-a na terenu nije jednostavno, jer se često artefakti i praznine u prikupljenim podacima mogu spoznati tek nakon završetka provedenog skeniranja. Navedeni nedostaci nastojali su se u sklopu ove disertacije riješiti kroz razvoj metodologije za optimizaciju intervalnog laserskog skeniranja (*vidi 3.3.1. i 4.3.1.*). Pri tome je osnovna pretpostavka bila da će optimizirano skeniranje omogućiti pokrivenost veću od 90 % ukupne površine odabranog područja istraživanja.

Prema izrađenom planu intervalnih TLS izmjera, koji definira osam optimalnih lokacija za postavljanje TLS-a i intervalno skeniranje, planirana pokrivenost odabranog područja istraživanja (1163.09 m²) iznosi 96,93 %. Pri tome je prema planu pokriveno 1127.43 m² površine jaruge. Preostalih 3.07 % prostora koji nije pokriven odnosi se na površinu od tek 35.65 m², vezanu pretežito za zaklonjene dublje dijelove manjih kanala, unutar jaruge Santiš.

Inicijalnom TLS izmjerom provedenom 17. prosinca 2019. godine ostvarena je pokrivenost testnog područja od 91.66 %, odnosno skenirano je ukupno 1066.05 m^2 površine odabranog područja istraživanja. Ostvarena pokrivenost manja je za 5.27 % od planirane, što je prvenstveno uzrokovano prazninama, koje su se unatoč izrađenom i provedenom planu TLS izmjere, javile u zaklonjenim i dubljim dijelovima jaruge (Sl. 152; 153; 160). Međutim, preostali dijelovi kompleksne morfologije jaruge Santiš, poput čeonog dijela, su vrlo dobro pokriveni ostvarenim skeniranjem, pri čemu unutar prostora čela jaruge nema većih praznina u prikupljenom oblaku točaka (Sl. 154; 159). Manja ostvarena pokrivenost od planirane najvjerojatnije je posljedica prostorno-vremenskih promjena koje su se unutar proučavanog područja dogodile u razdoblju između inicijalnog snimanja jaruge i izrade preliminarnog modela (ožujak 2019. - UAV-TEST) i provedene inicijalne TLS izmjere (17. prosinca 2019. godine). Unatoč manjoj pokrivenosti od planirane, ostvarena je pokrivenost od preko 90 % kompleksne morfologije jaruge, čime je izravno potvrđena postavljena hipoteza.

H.8. *Točnost aerofotogrametrijskog modela iskazana srednjom kvadratnom pogreškom odstupati će manje od ±4 cm u odnosu na referentni model.*

Navedena hipoteza je **potvrđena.** Unazad nekoliko godina primjena intervalne UAV aerofotogrametrije u modeliranju kompleksne morfologije erozijskih oblika postaje sve popularnija (Hugenholtz i dr., 2013;), pri čemu točnost izrađenih modela varira od submetarske do subcentimetarske (Eltner i dr., 2013; Hugenholtz i dr., 2013; Ouédraogo i dr., 2014; Eltner i dr., 2015; Clapuyt i dr., 2016; Glendell i dr., 2017; Koci i dr., 2017). U sklopu ranijih istraživanja provedenih na prostoru jaruge Santiš u kojima je također korišten RAPS sustav postignuta je točnost aerofotogrametrijskog modela od ±4.913 cm (Šiljeg, 2021). U odnosu na to istraživanje u sklopu ove disertacije je proširen prostorni obuhvat aerofotogrametrijskih snimanja, uz provođenje pomnog planiranja i pripreme prikupljanja podataka uz pomoć RAPS-a (*vidi 3.2.2*). Navedeno pomno planiranje uključivalo je izradu većeg broja i bolje distribucije stalnih orijentacijskih točaka (Sl. 60). Također, pojedine postavke intervalnih aerofotogrametrijskih snimanja su promijenjene (npr. visina leta), zbog čega su u konačnici izrađeni modeli prostorne rezolucije od 1 cm[57]. Zbog svega navedenog je pretpostavljeno da će točnost aerofotogrametrijskih modela izrađenih u sklopu ove disertacije biti i ispod ±4 cm.

Procjena točnosti aerofotogrametrijskog modela obavljena je na temelju usporedbe referentnog oblaka točaka prikupljenog TLS-om ($PC_{TLS-2019-šire}$) i oblaka točaka generiranog iz podataka prikupljenih RAPS-om u sklopu inicijalnog aerofotogrametrijskog snimanja (PC_{UAV-A}). Već i osnovne značajke izrađenih oblaka točaka potvrdile su da aerofotogrametrijski model ne zaostaje značajno za referentnim TLS modelom (npr. broj točaka UAV modela je za samo 6.38% manji od ukupnog broja točaka TLS modela). Usporedba zasnovana na primjeni M3C2 algoritma je potvrdila značajnu podudarnost izrađenog UAV-A oblaka točaka, u odnosu na referentni TLS-A oblak točaka. Vrijednost M3C2 udaljenosti između dva uspoređena oblaka točaka manja je od ±2.5 cm u čak 83.485 % analiziranih točaka (111 994 797 točaka). Udaljenost od ±2.5 cm odgovara vrijednostima prosječne pogreške udaljenosti (engl. *mean distance error*) utvrđene prilikom izrade TLS-A oblaka točaka (Tabl. 62.), iz čega proizlazi da je u većini (> 80 %) točaka točnost UAV-A oblaka točaka unutar točnosti TLS-a. Ekstremne vrijednosti M3C2 udaljenosti su se javile u samo 2.435 % analiziranih točaka (3 266 659 visinske točke), koncentriranih uglavnom unutar prostora najkompleksnije morfologije (npr. čelo jaruge (Sl. 159.) ili dno zaklonjenih kanala (Sl. 160.)).

[57] U sklopu ranijih istraživanja prostorna rezolucija aerofotogrametrijskih modela bila je 1.9 cm.

Iako je znatan dio tih ekstremnih vrijednosti uzrokovan prazninama u UAV-A oblaku točaka (npr. čelo jaruge (Sl. 154; 159)), dio ih je uzrokovan i prazninama u referentnom oblaku točaka (Sl. 154; 160). Ukoliko se u obzir uzme cijeli UAV-A oblak točaka (uključujući ekstremne vrijednosti) RMSE UAV-A oblaka točaka u odnosu na referentni TLS-A oblak iznosi 8 cm. Međutim, ukoliko se ove ekstremne vrijednosti uklone, tada vrijednost srednje kvadratne pogreške (izračunata na temelju preostalih 97.565 % točaka) iznosi tek 2 cm. Ovako niske vrijednosti srednje kvadratne pogreške potvrđuju postignutu vrlo visoku točnost aerofotogrametrijskog modela, čija točnost u za aerofotogrametriju optimalnim uvjetima (npr. izostanak razvijenije vegetacije i sjena unutar jaruge Santiš) ne zaostaje značajnije za točnosti referentnog TLS modela.

H.9. *Izrađeni alat omogućiti će automatiziranu kvantifikaciju linearnih, površinskih i volumetrijskih prostorno-vremenskih promjena u čelu jaruge.*

Navedena hipoteza je **potvrđena.** Osnovni cilj razvoja novog alata za praćenje prostorno-vremenskih promjena u čelu jaruge bio je isključivo usmjeren na automatizaciju detekcije i kvantifikacije promjena koje su uzrokovane pomakom čela jaruge unutar određenog prostora i vremena. Pri tome je osnovna pretpostavka bila da će razvijeni alata omogućiti automatsku kvantifikaciju linearnog, površinskog i volumetrijskog pomaka čela jaruge.

Razvijeni HCD alat omogućio je automatsku detekciju i kvantifikaciju linearnog, površinskog i volumetrijskog pomaka čela jaruge, pri čemu je alat primijenjen na modelima užeg prostora mikro razine istraživanja. Osim što automatizira cijeli proces kvantifikacije pomaka čela jaruge, prednost razvijenog HCD alata je i njegova prilagodljivost različitim tipovima dostupnih podataka. Tako se HCD alat može koristiti za kvantifikaciju linearnog i površinskog pomaka čela jaruge na temelju 2D modela (npr. linije čela jaruge izdvojene iz DOF-a ili satelitskog snimka). Osim toga, u slučaju kada su dostupni 2.5D modeli (DMR ili DMP) razvijeni HCD alat uz izračun linearnog i volumetrijskog pomaka omogućava automatizirani izračun volumetrijskog pomaka čela jaruge. S obzirom da trenutačno HCD alat nije moguće primijeniti na 3D modelima (npr. gusti oblak točaka), u sklopu daljnjih istraživanja poželjno bi bilo da se alat u ovom segmentu dodatno unaprijedi.

6. ZAKLJUČAK

U sklopu disertacije je razvijen novi metodološki pristup za višerezolucijsko modeliranje erozije tla korištenjem različitih naprednih geoprostornih tehnologija. Osnova razvijenog metodološkog pristupa su različite geoprostorne tehnologije koje omogućavaju izradu modela kompleksnih erozijskih oblika i proučavanje različitih aspekata procesa erozije tla. Višerezolucijsko modeliranje erozije tla uključivalo je primjenu cijelog niza različitih tehnologija, unutar tri osnovne razine istraživanja, koje se razlikuju po postavljenim ciljevima, primjenjenoj metodologiji te detaljnosti istraživanja, što se odražava i na različitu prostornu, vremensku i spektralnu rezoluciju izrađenih modela.

Unutar makro razine istraživanja izrađen je višekriterijski GIS model podložnosti eroziji tla, za čiju izradu su osnova bili modeli visoke prostorne i spektralne rezolucije. Modeli visoke rezolucije kreirani su na temelju komercijalnih Worldview satelitskih snimaka ustupljenih od strane DigitalGlobe fondacije. Primjenom različitih metoda i tehnika na temelju ustupljenih Worldview snimaka izrađeni su DMR i multispektralni snimak (8 kanala) otoka Paga, prostorne rezolucije od 1 m, koji predstavljaju do sada najdetaljnije modele čitavog prostora otoka. Navedeni modeli poslužili su za izradu modela podložnosti eroziji tla unutar makro razine istraživanja. Model podložnosti eroziji tla napravljen je na temelju 18 različitih kriterija, pri čemu je postignuta izvrsna točnost (AUC = 0.91). Visoka točnost izrađenog modela podložnosti dokazala je da Worldview snimci mogu biti uspješno primijenjeni za modeliranje podložnosti unutar velikih područja istraživanja za koje nisu dostupni detaljniji podaci o litološkoj i pedološkoj podlozi. Takav zaključak relevantan je za sva buduća istraživanja, koja će se baviti modeliranjem podložnosti eroziji tla, jer dokazuje da se Worldview snimci mogu koristiti za modeliranje velikih i zabačenih područja, s oskudnim postojećim izvorima podataka, uz postizanje izvrsne točnosti modela. Prema izrađenom modelu oko 40 % površine otoka Paga prekriveno je zonama visoke i vrlo visoke podložnosti eroziji tla, pri čemu se zone visoke i vrlo visoke podložnosti podudaraju s rezultatima ranijih istraživanja.

U sklopu mezo razine istraživanja provedena je detekcija i kvantifikacije prostorno-vremenskih promjena uzrokovanih djelovanjem procesa erozije tla. Širi prostor mezo razine obuhvaćao je prostor poluotoka Santiš unutar kojega je provedena detekcija višegodišnjeg intenziteta erozije tla. Detekcija višegodišnjeg intenziteta erozije tla napravljena je za razdoblje od 2014. do 2018 godine na temelju DMD-a vrlo visoke rezolucije (30 cm), izrađenog iz intervalnih aerofotogrametrijskih snimaka Državne geodetske uprave. Aktivan proces erozije

tla utvrđen je u tri odvojene jaruge (Santiš, Zečja i Stepeničasta), unutar kojih je ukupno erodirano 201.28 m^3, uz vrlo veliku varijabilnost u izabilježenom intenzitetu erozije tla među analiziranim jarugama. Navedena varijabilnost intenziteta tla dovedena je u odnos sa veličinom i značajkama slivnog područja, te obuhvatom i smještajem naslaga tla unutar slivnog područja. Pri tome se pokazalo da veličina slivnog područja i naslaga tla izravno utječu na intenzitet erozije tla. Najveći višegodišnji intenzitet erozije tla zabilježen je unutar jaruge Santiš, unutar koje je utvrđeno gotovo 85 % svih prostorno-vremenskih promjena. Upravo zbog toga jaruga Santiš je odabrana za praćenje jednogodišnjeg intenziteta erozije tla, koje je provedeno u sklopu užeg prostora mezo razine istraživanja. Praćenje jednogodišnjeg (2019. – 2020.) intenziteta erozije tla provedeno je na temelju primjene intervalne UAV fotogrametrije, pri čemu je izrađen DMD-a prostorne rezolucije od 1 cm. Unutar promatranog jednogodišnjeg razdoblja erodirano je ukupno 13.46 m^3 tla, a akumulirano 11.55 m^3 materijala, dok je preostalih 1.91 m^3 istaloženo u more. Kroz provedenu usporedu zabilježenog intenziteta erozije tla s različitim litološkim jedinicama unutar jaruge Santiš utvrđeno je da se najviše prostorno-vremenskih promjena javilo na naslagama karbonatnih pješčenjaka i pijesaka. Unutar ove litološke jedinice zabilježeno je intenzivno odronjavanje uzrokovano djelovanjem selektivne erozije, čiji je intenzitet nadmašio promjene zabilježene unutar prostora čela jaruge, odnosno unutar naslaga smeđeg tla. Također, zabilježeno je i značajno odstupanje utvrđenog jednogodišnjeg volumena erodiranog materijala, od prosječnih višegodišnjih vrijednosti ukazuje. Takvo odstupanje ukazuje na izraženu varijabilnost intenziteta erozije tla unutar jaruge Santiš, koja može biti posljedica velikog broja različitih čimbenika. Analiza prikupljenih meteoroloških podataka pokazala je da navedena varijabilnost može biti uzrokovana zabilježenim smanjenjem ukupne količine i intenziteta oborina u promatranom jednogodišnjem razdoblju, u odnosu na prosječne višegodišnje vrijednosti. Istraživanja provedena u sklopu mezo razine predstavljaju prvo longitudinalno istraživanje intenziteta erozije tla u Hrvatskoj, čiji rezultati pružaju jedinstveni uvid u višegodišnju dinamiku procesa erozije tla unutar prostora otoka Paga. S obzirom na uočenu varijabilnost intenziteta erozije tla poželjno je započeta istraživanja vezana za praćenje intenziteta erozije tla nastaviti i van okvira ove disertacije. Time bi se omogućilo utvrđivanje intenziteta erozije tla na temelju desetogodišnjeg, ili čak dužeg vremenskog razdoblja, na temelju čega bi zatim bilo moguće detaljnije utvrditi utjecaj pojedinih čimbenika (npr. meteorološki uvjeti; pedološke značajke; morfologija jaruge; itd.) na varijabilnost intenziteta erozije tla.

Mikro razina istraživanja obuhvaća izdvojene dijelove jaruge Santiš, unutar kojih je izvršena optimizacija intervalnog praćenja erozije tla korištenjem terestričkog laserskog skeniranja. Na temelju razvijene metodologije za optimizaciju intervalnog laserskog skeniranja ostvarena je pokrivenost odabranog dijela kompleksne morfologije jaruge Santiš od 91.66%. Pomno planiranje provođenja intervalnih TLS izmjera i izrada lokalnog koordinatnog sustava pokazali su se ključnim za postizanje zadovoljavajuće pokrivenosti kompleksne morfologije jaruge Santiš. Zahvaljujući provedenoj optimizaciji postignuta je zadovoljavajuća pokrivenost morfološki najkompleksnijih dijelova jaruge, poput prevjesnih dijelova čela jaruge, ili uskih dijelova središnjeg kanala jaruge. U sklopu mikro razine provedena je i procjena točnosti aerofotogrametrijskog modela. Procjena točnosti temeljila se na usporedbi inicijalnog aerofotogrametrijskog oblaka točaka (UAV-A) s referentnim oblakom točaka prikupljenim TLS-om (TLS-A). Pri tome je usporedba dva oblaka točaka obavljena uz pomoć naprednog M3C2 algoritma. Provedena procjena točnosti pokazala je da odstupanje aerofotogrametrijski model iznosi manje od ±2.5 cm u odnosu na referentni model, uz srednju kvadratnu pogrešku od 1.94 cm. Tako niske vrijednosti RMSE ukazuju da aerofotogrametrijski model unatoč izraženoj kompleksnoj morfologiji jaruge ne odstupa značajnije od referentnog TLS modela. Time je izravno potvrđena vrlo visoka točnost aerofotogrametrijskih modela izrađenih unutar užeg prostora mezo razine (UAV-A i UAV-B), ali i točnost rezultata provedene detekcije prostorno-vremenskih promjena, utvrđenih na temelju izrađenog DMD-a. Nadalje, rezultati procjene točnosti opravdavaju upotrebu intervalne UAV fotogrametrije, odnosno razvijenog RAPS-a za daljnje provođenje intervalnih aerofototogrametrijskih snimanja na prostoru jaruge Santiš, kao u odnosu na TLS praktičnije i jeftinije metode, koja rezultira gotovo jednago točnim modelima. U konačnici je u sklopu mikro razine razvijen HCD alat za automatizirano praćenje linearnog, površinskog i volumetrijskog pomaka čela jaruge, koji je primijenjen na primjeru većeg čela jaruge Santiš. Osim što u potpunosti omogućava automatizaciju mjerenja pomaka čela jaruge, osnovna prednost razvijenog HCD alata je njegova prilagodljivost dostupnim podacima, odnosno primjenjivost na 2D i 2.5D modele. U slučaju kada su za određeno čelo jaruge dostupni isključivo 2D modeli (npr. digitalni ortofoto snimak ili satelitski snimak) HCD alat omogućava automatizirani izračun linearnog i površinskog 2D pomaka čela jaruge. S druge strane ukoliko su za određenu jarugu dostupni 2.5D modeli (npr. DMP ili DMR) HCD alat omogućava izračun 3D volumetrijskog pomaka čela jaruge. Primjena HCD alata na primjeru odabranog dijela glavnog čela jaruge Santiš pokazala je da prosječni jednogodišnji retrogradni pomak čela jaruge iznosi 4.93 cm, uz površinski pomak od 1.58 m^2, te uz ukupno 1.14 m^3

erodiranog materijala. Utvrđene vrijednosti retrogradnog pomaka čela jaruge vrlo su bitne za razumijevanje evolucije jaruge unutar promatranog razdoblja, ali i pretstavljaju osnovu za rekonstrukciju pomaka čela jaruge u prošlosti, te modeliranje daljnjeg razvoja jaruge u budućnosti.

Rezultati ove disertacije vezani za longitudinalno praćenje prostorno-vremenskih promjena uzrokovanih erozijom tla znatno će doprinjeti razumijevanju stopa erozije i akumulacije materijala na prostoru otoka paga i Hrvatske, pri čemu započeta istraživanja treba nastaviti i tijekom sljedećih godina. Nadalje, razvijeni višerezolucijski metodološki pristup omogućiti će drugim znanstvenicima koji se bave proučavanjem procesa erozije tla lakše provođenje vlastitih istraživanja. Posebice tu treba istaknuti značaj teorijske osnove ove disertacije, u sklopu koje su predložene smjernice za modeliranje različitih podprocesa erozije tla (*EKK, spiranje, brazdanje, jaruženje, ogoline*), unutar predloženih šest različitih razina detaljnosti (LOD1 – LOD6), uz opširni pregled i pojašnjenje prednosti i nedostataka primjene različitih geoprostornih tehnologija za proučavanje erozije tl. Navedeno predstavljaja osnovu na temelju koje će drugi znanstvenici lakše moći odrediti potrebnu razinu detaljnosti modeliranja, koju će primijeniti u svojim istraživanjima sukladno određenim ciljevima te svrsi istraživanja.

Iako je razvijeni višerezolucijski pristup proučavanju erozije tla u sklopu ove disertacije primijenjen za proučavanje erozije tla unutar specifičnog krškog područja, primjenjiv je i u drugim područjima Mediterana i svijeta, zahvaćenim intenzivnim utjecajem procesa erozije tla.

SAŽETAK

Erozija tla predstavlja primarni uzrok degradacije tla na globalnoj razini, koji je izravno odgovaran za dugoročno smanjivanje poljoprivredne produktivnosti i značajne financijske gubitke. Velika prostorna rasprostranjenost i raznolikost erozijskih oblika, prisutnost surovih klimatskih predisponirajućih čimbenika te specifični ogoljeni krški krajolik čine otok Pag idealnim prostorom za sustavno proučavanje pojavnosti i intenziteta procesa erozije tla. Osnovni cilj ove doktorske disertacije je razvoj višerezolucijskog metodološkog pristupa za sustavno proučavanje procesa erozije tla, zasnovanog na upotrebi više istraživačkih razina, različitog prostornog obuhvata i ciljeva istraživanja.

Metodološki okvir razvijenog višerezolucijskog pristupa proučavanju erozije tla omogućio je proučavanje različitih aspekata procesa erozije tla, kroz tri različite razine istraživanja. Makro razina istraživanja obuhvaća proces izrade višekriterijskog GIS modela podložnosti eroziji tla visoke rezolucije, za čitav prostor otoka Paga. Unutar mezo razine istraživanja je na temelju visokorezolucijskih modela provedeno praćenje višegodišnjeg (2014. – 2018.) i jednogodišnjeg (2019. – 2020.) intenziteta erozije tla. Mikro razina istraživanja obuhvaća aktivnosti vezane za optimizaciju intervalnih TLS izmjera i detekciju subcentimetarskih prostorno-vremenskih promjena uzrokovanih retrogradnim pomicanjem čela jaruge.

Primjenom razvijenog višerezolucijskog pristupa proučavanju erozije tla ostvareni su svi postavljeni ciljevi doktorske disertacije. Izrađen je prvi visokorezolucijski (1 m) model podložnosti eroziji tla, na temelju kojega su izdvojeni najugroženiji dijelovi otoka. U konačnici je utvrđeno da oko 40 % površine otoka Paga spada u zone visoko ili vrlo visoko podložnosti eroziji tla. Praćenjem višegodišnjeg intenziteta erozije tla utvrđeni su aktivni tragovi erozije tla unutar tri od ukupno pet jaruga analiziranih unutar poluotoka Santiš. Utvrđena je velika varijabilnost u prostornom obuhvatu i ukupnoj količini erodiranog materijala. Najviše PVP (oko 85 %) detektirano je unutar dva čela jaruge Santiš. Utvrđeni jednogodišnji volumetrijski intenzitet erozije tla unutar jaruge Santiš iznosi 13.46 m^3. Analiza odnosa između utvrđenog jednogodišnjeg intenziteta i kartiranih litoloških jedinica pokazala je da se najviše PVP javilo unutar naslaga *karbonatnih pješčenjaka i pijesaka* te naslaga *smeđeg tla*. Zabilježena je izražena godišnja varijabilnost intenziteta erozije tla, koja je dovedena u kodnos s osciliranjem količine i rasporeda oborina. Unutar mikro razine istraživanja provedena je optimizacija intervalnih TLS izmjera i aerofotogrametrijskih snimanja. Dok je optimizacijom TLS izmjera

omogućena vrlo visoka (> 90 %) pokrivenost kompleksne morfologije odabranog dijela jaruge Santiš, optimizacijom aerofotogrametrijskih snimanja postignuta je vrlo visoka točnost izrađenih aerofotogrametrijskih modela (RMSE < ±2 cm).

Razvijeni višerezolucijski pristup proučavanju erozije tla primijenjen je u sklopu ove disertacije na kompleksnom krškom području, pri čemu su uspješno ostvareni svi postavljeni ciljevi istraživanja. Osim na sličnim krškim prostorima, razvijeni višerezolucijski pristup je primjenjiv i na svim drugim dijelovima Mediterana i svijeta, zahvaćenim intenzivnim utjecajem procesa erozije tla.

Ključne riječi: erozija tla, geoprostorne tehnologije, višerezolucijsko modeliranje, prostorno-vremenske promjene, otok Pag, Hrvatska

SUMMARY

Soil erosion is globally primary cause of soil degradation, which is directly responsible for long-term reductions in agricultural productivity and significant financial losses. Due to the significant spatial distribution and diversity of erosion forms, the presence of harsh climatic predisposing factors and the specific bare karst landscape, Pag Island is ideal for a systematic study of the occurrence and intensity of soil erosion. The main goal of this doctoral dissertation is development of a multi-resolution methodological approach for the systematic study of soil erosion processes, based on the use of multiple research levels, with different spatial coverage and research objectives.

The methodological framework of the developed multi-resolution approach for the study of soil erosion enabled the study of different aspects of the soil erosion process, through three different research levels. The macro level of research includes the process of creating a high-resolution multi-criteria GIS soil erosion susceptibility model, for the entire area of the Pag Island. Monitoring of multi-year (2014. – 2018.) and one-year (2019. – 2020.) soil erosion intensity based on VHR models was conducted within the meso level of research. The micro level of research includes activities related to the optimization of interval TLS measurements and detection of subcentimeter spatio-temporal changes caused by uphill headcut retreat.

Implementation of the developed multiresolution approach for the study of soil erosion resulted with the achievment of all scientific goals set within this doctoral dissertation. The first high-resolution (1 m) GIS-MCDA model of soil erosion susceptibility was created, on the basis of which the most endangered parts of the island were isolated. Ultimately, it was found that about 40% of the surface of the Pag islands belongs to the high or very high susceptibility areas. Active traces of soil erosion were determined by monitoring the long-term intensity of soil erosion in three of the five gullies analyzed within the Santiš peninsula. Great variability in spatial coverage and total amount of eroded material was found. Most spatio-temporal changes (about 85%) were detected within the two headcuts of the gully Santiš. The determined one-year volumetric intensity of soil erosion within the Santiš ravine was 13.46 m3. The correlation between the determined one-year intensity and the mapped lithological units showed that the highest spatio-temporal changes have occurred within the *carbonate sandstones and sands* and *brown soil* deposits. There was a pronounced annual variability in the intensity of soil erosion, which was correlated with the oscillations in the amount and distribution of precipitation. Within the micro level of the research, optimization of interval TLS measurements and UAV

photogrametric surveys was performed. While the optimization of TLS measurements enabled a very high (> 90%) coverage of the complex gully morphology, optimization of UAV photogrammetric survey achieved a very high accuracy of created models (RMSE < ± 2 cm).

The developed multi-resolution approach for the study of soil erosion was applied as part of this dissertation in a complex karst area, where all scientific research goals were successfully achieved. Apart from similar karst areas, the developed multi-resolution approach is applicable to all other parts of the Mediterranean and the World, affected by the intense soil erosion.

Keywords: soil erosion, geospatial technologies, multiresolution modelling, spatio-temporal changes, Pag Island, Croatia

Literatura i izvori

1. Agisoft (2020). Agisoft Metashape User Manual Professional Edition, Version 1.6. Preuzeto sa https://www.agisoft.com/pdf/metashape-pro_1_6_en.pdf (18.09.2020.).
2. Agnesi, V., Angileri, S., Cappadonia, C., Conoscenti, C., i Rotigliano, E. (2011). Multi parametric gis analysis to assess gully erosion susceptibility: A test in southern sicily, italy. Landform Analysis, 17, 15-20.
3. Aguilar, M. A., Bianconi, F., Aguilar, F. J., i Fernández, I. (2014). Object-based greenhouse classification from GeoEye-1 and WorldView-2 stereo imagery. Remote sensing, 6(5), 3554-3582.
4. Aguilar, M. Á., del Mar Saldaña, M., i Aguilar, F. J. (2013a). Generation and quality assessment of stereo-extracted DSM from GeoEye-1 and WorldView-2 imagery. IEEE Transactions on Geoscience and Remote Sensing, 52(2), 1259-1271.
5. Aguilar, M. A., del Mar Saldaña, M., i Aguilar, F. J. (2013b). Assessing geometric accuracy of the orthorectification process from GeoEye-1 and WorldView-2 panchromatic images. International Journal of Applied Earth Observation and Geoinformation, 21, 427-435.
6. Aguilar, M. A., Nemmaoui, A., Aguilar, F. J., i Qin, R. (2019). Quality assessment of digital surface models extracted from WorldView-2 and WorldView-3 stereo pairs over different land covers. GIScience i remote sensing, 56(1), 109-129.
7. Aiello, A., Adamo, M., i Canora, F. (2015). Remote sensing and GIS to assess soil erosion with RUSLE3D and USPED at river basin scale in southern Italy. Catena, 131, 174-185.
8. Akgün, A., i Türk, N. (2011). Mapping erosion susceptibility by a multivariate statistical method: a case study from the Ayvalık region, NW Turkey. Computers i geosciences, 37(9), 1515-1524.
9. Alexakis, D. D., Daliakopoulos, I. N., Panagea, I. S., i Tsanis, I. K. (2018). Assessing soil salinity using WorldView-2 multispectral images in Timpaki, Crete, Greece. Geocarto International, 33(4), 321-338.
10. Alexakis, D. D., Hadjimitsis, D. G., i Agapiou, A. (2013). Integrated use of remote sensing, GIS and precipitation data for the assessment of soil erosion rate in the catchment area of “Yialias” in Cyprus. Atmospheric Research, 131, 108-124.

11. Altuntas, C., Karabork, H., i Tusat, E. (2014). Georeferencing of ground-based LIDAR data using continuously operating reference stations. Optical Engineering, 53(11), 114110.
12. Amatulli, G., Domisch, S., Tuanmu, M. N., Parmentier, B., Ranipeta, A., Malczyk, J., i Jetz, W. (2018). A suite of global, cross-scale topographic variables for environmental and biodiversity modeling. Scientific data, 5(1), 1-15.
13. Arabameri, A., Blaschke, T., Pradhan, B., Pourghasemi, H. R., Tiefenbacher, J. P., i Bui, D. T. (2020a). Evaluation of recent advanced soft computing techniques for gully erosion susceptibility mapping: A comparative study. Sensors, 20(2), 335.
14. Arabameri, A., Cerda, A., Rodrigo-Comino, J., Pradhan, B., Sohrabi, M., Blaschke, T., i Tien Bui, D. (2019). Proposing a novel predictive technique for gully erosion susceptibility mapping in arid and semi-arid regions (Iran). Remote Sensing, 11(21), 2577.
15. Arabameri, A., Chen, W., Blaschke, T., Tiefenbacher, J. P., Pradhan, B., i Tien Bui, D. (2020b). Gully Head-Cut Distribution Modeling Using Machine Learning Methods—A Case Study of NW Iran. Water, 12(1), 16.
16. Arabameri, A., Chen, W., Lombardo, L., Blaschke, T., i Tien Bui, D. (2020d). Hybrid computational intelligence models for improvement gully erosion assessment. Remote Sensing, 12(1), 140.
17. Arabameri, A., Rezaei, K., Pourghasemi, H. R., Lee, S., i Yamani, M. (2018). GIS-based gully erosion susceptibility mapping: a comparison among three data-driven models and AHP knowledge-based technique. Environmental earth sciences, 77(17), 628.
18. Arabameri, A., Tiefenbacher, J. P., Blaschke, T., Pradhan, B., i Tien Bui, D. (2020c). Morphometric analysis for soil erosion susceptibility mapping using novel gis-based ensemble model. Remote Sensing, 12(5), 874.
19. Atoma, H., Suryabhagavan, K. V., i Balakrishnan, M. (2020). Soil erosion assessment using RUSLE model and GIS in Huluka watershed, Central Ethiopia. Sustainable Water Resources Management, 6(1), 12.
20. Aucelli, P. P., Conforti, M., Della Seta, M., Del Monte, M., D'uva, L., Rosskopf, C. M., i Vergari, F. (2016). Multi-temporal digital photogrammetric analysis for quantitative assessment of soil erosion rates in the Landola catchment of the Upper Orcia Valley (Tuscany, Italy). Land Degradation i Development, 27(4), 1075-1092.

21. Babić, N., Večenaj, Ž., Kozmar, H., Horvath, K., De Wekker, S. F., i Grisogono, B. (2016). On turbulent fluxes during strong winter bora wind events. Boundary-layer meteorology, 158(2), 331-350.
22. Ballabio, C., Borrelli, P., Spinoni, J., Meusburger, K., Michaelides, S., Beguería, S., ... i Panagos, P. (2017). Mapping monthly rainfall erosivity in Europe. Science of the Total Environment, 579, 1298-1315.).
23. Barać, Z., Mioč, B., Pavić, V., i Sušić, V. (2007). Uzgoj izvornih pasmina ovaca i koza u Republici Hrvatskoj. In Konferencija o izvornim pasminama i sortama kao dijelu prirodne i kulturne baštine (p. 12).
24. Barazzetti, L., Roncoroni, F., Brumana, R., i Previtali, M. (2016). Georeferencing accuracy analysis of a single worldview-3 image collected over Milan. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B1.
25. Barbarella, M., Fiani, M., i Zollo, C. (2017). Assessment of DEM derived from very high-resolution stereo satellite imagery for geomorphometric analysis. European Journal of Remote Sensing, 50(1), 534-549.
26. Bates, C. B. (2019). Multi-temporal DEM and land use analysis for determining gully formation (Master thesis, San Francisco State University).
27. Bazzoffi, P. (2015). Measurement of rill erosion through a new UAV-GIS methodology. Italian Journal of Agronomy.
28. Belfiore, O. R., Meneghini, C., Parente, C., i Santamaria, R. (2016). Application of different Pan-sharpening methods on WorldView-3 images. ARPN-JEAS, 11, 490-496.
29. Berhane, T. M., Lane, C. R., Wu, Q., Autrey, B. C., Anenkhonov, O. A., Chepinoga, V. V., i Liu, H. (2018). Decision-tree, rule-based, and random forest classification of high-resolution multispectral imagery for wetland mapping and inventory. Remote sensing, 10(4), 580.
30. Beven, K. J., i Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. Hydrological Sciences Journal, 24(1), 43-69.
31. Biljecki, F., Heuvelink, G. B., Ledoux, H., i Stoter, J. (2018). The effect of acquisition error and level of detail on the accuracy of spatial analyses. Cartography and Geographic Information Science, 45(2), 156-176.

32. Biočić, M. (2014). Prikupljanje podataka novim i pristupačnim metodama izmjere korištenjem letjelica. Diplomski rad, Geodetski fakultet Sveučilišta u Zagrebu.
33. Boardman, J., i Poesen, J. (Eds.). (2007). Soil erosion in Europe. John Wiley i Sons.
34. Bogunović, M., i Rapaić, M. (1993). Digitalizacija osnovne pedološke karte Republike Hrvatske. Bilten Savjeta za daljinska istraživanja i fotointerpretaciju, 12, 67-76.
35. Bogunović, M., Vidaček, Ž., Racz, Z., Husnjak, S., i Sraka, M. (1997). Namjenska pedološka karta Republike Hrvatske i njena uporaba. Agronomski glasnik: Glasilo Hrvatskog agronomskog društva, 59(5-6), 363-399.
36. Borrelli, P., Robinson, D. A., Fleischer, L. R., Lugato, E., Ballabio, C., Alewell, C., ... i Bagarello, V. (2017). An assessment of the global impact of 21st century land use change on soil erosion. Nature communications, 8(1), 1-13.
37. Borrelli, P., Robinson, D. A., Panagos, P., Lugato, E., Yang, J. E., Alewell, C., ... i Ballabio, C. (2020). Land use and climate change impacts on global soil erosion by water (2015-2070). Proceedings of the National Academy of Sciences, 117(36), 21994-22001.
38. Bou-imajjane, L., Belfoul, M. A., Elkadiri, R., i Stokes, M. (2020). Soil erosion assessment in a semi-arid environment: a case study from the Argana Corridor, Morocco. Environmental Earth Sciences, 79(18), 1-14.
39. Boulton, S. J., i Stokes, M. (2018). Which DEM is best for analyzing fluvial landscape development in mountainous terrains?. Geomorphology, 310, 168-187.
40. Brasington, J., Rumsby, B. T., i McVey, R. A. (2000). Monitoring and modelling morphological change in a braided gravel-bed river using high resolution GPS-based survey. Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group, 25(9), 973-990.
41. Brasington, J., Vericat, D., i Rychkov, I. (2012). Modeling river bed morphology, roughness, and surface sedimentology using high resolution terrestrial laser scanning. Water Resources Research, 48(11).
42. Bremer, M., i Sass, O. (2012). Combining airborne and terrestrial laser scanning for quantifying erosion and deposition by a debris flow event. Geomorphology, 138(1), 49-60.
43. Brown, L. C., i Foster, G. R. (1987). Storm erosivity using idealized intensity distributions. Transactions of the ASAE, 30(2), 379-0386.

44. Brus, J., Vondrakova, A., i Vozenilek, V. (Eds.). (2014): *Modern Trends in Cartography: Selected Papers of CARTOCON 2014*. Springer
45. Bulić, J., & Jurišić-Polšak, Z. (2009). Macropalaeontology and stratigraphy of lacustrine Miocene deposits at Crnika beach on the Island of Pag (Croatia). Geologia Croatica, 62(3), 0-0.
46. Campbell, J. B., i Wynne, R. H. (2011). Introduction to remote sensing. Guilford Press.
47. Campo-Bescós, M. A., Flores-Cervantes, J. H., Bras, R. L., Casalí, J., i Giráldez, J. V. (2013). Evaluation of a gully headcut retreat model using multitemporal aerial photographs and digital elevation models. Journal of Geophysical Research: Earth Surface, 118(4), 2159-2173.
48. Cândido, B. M., James, M., Quinton, J., Lima, W. D., i Silva, M. L. N. (2020). Sediment source and volume of soil erosion in a gully system using UAV photogrammetry. Revista Brasileira de Ciência do Solo, 44.
49. Capolongo, D., Pennetta, L., Piccarreta, M., Fallacara, G., i Boenzi, F. (2008). Spatial and temporal variations in soil erosion and deposition due to land-levelling in a semi-arid area of Basilicata (Southern Italy). Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group, 33(3), 364-379.
50. Castillo, C., i Gómez, J. A. (2016). A century of gully erosion research: Urgency, complexity and study approaches. Earth-Science Reviews, 160, 300-319.
51. Castillo, C., Pérez, R., James, M. R., Quinton, J. N., Taguas, E. V., i Gómez, J. A. (2012). Comparing the accuracy of several field methods for measuring gully erosion. Soil Science Society of America Journal, 76(4), 1319-1332.
52. Cegan, J. C., Filion, A. M., Keisler, J. M., i Linkov, I. (2017). Trends and applications of multi-criteria decision analysis in environmental sciences: literature review. Environment Systems and Decisions, 37(2), 123-133.
53. Chaplot, V. (2013). Impact of terrain attributes, parent material and soil types on gully erosion. Geomorphology, 186, 1-11.
54. Cheng, L., Chen, S., Liu, X., Xu, H., Wu, Y., Li, M., i Chen, Y. (2018). Registration of laser scanning point clouds: A review. Sensors, 18(5), 1641.
55. Cheng, P., i Chaapel, C. (2010). Pan-sharpening and geometric correction: worldview-2 satellite. GeoInformatics, 13(4), 30.
56. Cheng, Y. C., Yang, C. J., i Lin, J. C. (2019). Application for Terrestrial LiDAR on Mudstone Erosion Caused by Typhoons. Remote Sensing, 11(20), 2425.

57. Clapuyt, F., Vanacker, V., i Van Oost, K. (2016). Reproducibility of UAV-based earth topography reconstructions based on Structure-from-Motion algorithms. Geomorphology, 260, 4-15.
58. CloudCompare (2020). 3D point cloud and mesh processing software Open Source Project. Preuzeto sa: https://www.danielgm.net/cc/ (02.03.2020).
59. Coffer, M. M., Schaeffer, B. A., Zimmerman, R. C., Hill, V., Li, J., Islam, K. A., i Whitman, P. J. (2020). Performance across WorldView-2 and RapidEye for reproducible seagrass mapping. Remote Sensing of Environment, 250, 112036.
60. Conforti, M., i Buttafuoco, G. (2017). Assessing space–time variations of denudation processes and related soil loss from 1955 to 2016 in southern Italy (Calabria region). Environmental Earth Sciences, 76(13), 1-18.
61. Conforti, M., Aucelli, P. P., Robustelli, G., i Scarciglia, F. (2011). Geomorphology and GIS analysis for mapping gully erosion susceptibility in the Turbolo stream catchment (Northern Calabria, Italy). Natural hazards, 56(3), 881-898.
62. Conoscenti, C., Agnesi, V., Angileri, S., Cappadonia, C., Rotigliano, E., i Märker, M. (2013). A GIS-based approach for gully erosion susceptibility modelling: a test in Sicily, Italy. Environmental earth sciences, 70(3), 1179-1195.
63. Conoscenti, C., Angileri, S., Cappadonia, C., Rotigliano, E., Agnesi, V., i Märker, M. (2014). Gully erosion susceptibility assessment by means of GIS-based logistic regression: A case of Sicily (Italy). Geomorphology, 204, 399-411.
64. Cook, K. L. (2017): An evaluation of the effectiveness of low-cost UAVs and structure from motion for geomorphic change detection. Geomorphology, 278, 195-208
65. Dai, Q., Peng, X., Wang, P., Li, C., i Shao, H. (2018). Surface erosion and underground leakage of yellow soil on slopes in karst regions of southwest China. Land Degradation i Development, 29(8), 2438-2448.
66. Dai, Q., Peng, X., Yang, Z., i Zhao, L. (2017). Runoff and erosion processes on bare slopes in the karst rocky desertification area. Catena, 152, 218-226.
67. Dai, W., Yang, X., Na, J., Li, J., Brus, D., Xiong, L., ... i Huang, X. (2019). Effects of DEM resolution on the accuracy of gully maps in loess hilly areas. Catena, 177, 114-125.
68. de Almeida, A. T., Alencar, M. H., Garcez, T. V., i Ferreira, R. J. P. (2017). A systematic literature review of multicriteria and multi-objective models applied in risk management. IMA Journal of Management Mathematics, 28(2), 153-184.

69. De Reu, J., Bourgeois, J., Bats, M., Zwertvaegher, A., Gelorini, V., De Smedt, P., ... i Van Meirvenne, M. (2013). Application of the topographic position index to heterogeneous landscapes. Geomorphology, 186, 39-49.
70. de Vente, J., Poesen, J., Verstraeten, G., Van Rompaey, A., i Govers, G. (2008). Spatially distributed modelling of soil erosion and sediment yield at regional scales in Spain. Global and planetary change, 60(3-4), 393-415.
71. de Zeeuw-van Dalfsen, E., Richter, N., González, G., i Walter, T. R. (2017). Geomorphology and structural development of the nested summit crater of Láscar Volcano studied with Terrestrial Laser Scanner data and analogue modelling. Journal of Volcanology and Geothermal Research, 329, 1-12.
72. Desta, L., i Adugna, B. (2012). A field guide on gully prevention and control. Nile Basin Initiative Eastern Nile Subsidiary Action Program (ENSAP), Addis Ababa, Ethiopia, 67.
73. Dewez, T., Leroux, J., i Morelli, S. (2016). Cliff collapse hazard from repeated multicopter UAV acquisitions: return on experience.
74. DiFrancesco, P. M., Bonneau, D., i Hutchinson, D. J. (2020). The implications of M3C2 projection diameter on 3D semi-automated rockfall extraction from sequential terrestrial laser scanning point clouds. Remote Sensing, 12(11), 1885.
75. DigitalGlobe, Inc. (2010a) - WorldView-2 Imagery Basics and Erdas Imagine, https://docplayer.net/44891764-Worldview-2-imagery-basics-and-erdas-imagine.html (Zadnji pristup: 09. siječnja, 2019.).
76. DigitalGlobe, Inc. (2010b): DigitalGlobe Core Imagery Products Guide, http://www.digitalglobe.com/downloads/DigitalGlobe Core Imagery Products Guide.pdf (Zadnji pristup: 25. ožujka, 2019).
77. DigitalGlobe, Inc. (2018): The DigitalGlobe Constellation, https://dgv4-cms-production.s3.amazonaws.com/uploads/document/file/126/Constellation_Brochure_2018.pdf (Zadnji pristup: 10. siječnja, 2019.).
78. DigitalGlobe, Inc. (2010c): The Benefits of the 8 Spectral Bands of WorldView-2, http://www.digitalglobe.com/sites/default/files/DG-8SPECTRAL-WP.pdf (Zadnji pristup: 23. ožujka, 2019.).
79. Dikau, R. (1989). The application of a digital relief model to landform analysis in geomorphology. Three dimensional applications in geographical information systems, 51-77.

80. Ding, H., Liu, K., Chen, X., Xiong, L., Tang, G., Qiu, F., i Strobl, J. (2020). Optimized Segmentation Based on the Weighted Aggregation Method for Loess Bank Gully Mapping. Remote Sensing, 12(5), 793.
81. Dobos, E., i Daroussin, J. (2005). Potential drainage density Index (PDD). An SRTM-based procedure to delineate SOTER Terrain Units on, 1(1), 40-51.
82. d'Oleire-Oltmanns, S., Marzolff, I., Tiede, D., i Blaschke, T. (2014). Detection of gully-affected areas by applying object-based image analysis (OBIA) in the region of Taroudannt, Morocco. Remote Sensing, 6(9), 8287-8309.
83. Domazetović, F. (2018). Kvantitativna analiza jaruga na prostoru otoka Paga korištenjem modela visoke rezolucije (Diplomski rad, Sveučilište u Zadru. Odjel za geografiju).
84. Domazetović, F., Šiljeg, A., Lončar, N., i Marić, I. (2019a). Development of automated multicriteria GIS analysis of gully erosion susceptibility. Applied Geography, 112, 102083.
85. Domazetović, F., Šiljeg, A., Lončar, N., i Marić, I. (2019b). GIS automated multicriteria analysis (GAMA) method for susceptibility modelling. MethodsX, 6, 2553-2561.
86. Domazetović, F., Šiljeg, A., Marić, I. (2020). Guidelines for optimization of terrestrial laser scanning surveys over gully erosion affected areas. In Massimiliano Alvioli, Ivan Marchesini, Laura Melelli i Peter Guth, eds., Proceedings of the Geomorphometry 2020 Conference, doi:10.30437/GEOMORPHOMETRY2020_59
87. Đomlija, P., Bernat Gazibara, S., Arbanas, Ž., i Mihalić Arbanas, S. (2019). Identification and mapping of soil erosion processes using the visual interpretation of LiDAR imagery. ISPRS International Journal of Geo-Information, 8(10), 438.
88. Dong, S., Shang, Z., Gao, J., i Boone, R. B. (2020a). Enhancing sustainability of grassland ecosystems through ecological restoration and grazing management in an era of climate change on Qinghai-Tibetan Plateau. Agriculture, Ecosystems i Environment, 287, 106684.
89. Dong, Z., Liang, F., Yang, B., Xu, Y., Zang, Y., Li, J., ... i Stilla, U. (2020b). Registration of large-scale terrestrial laser scanner point clouds: A review and benchmark. ISPRS Journal of Photogrammetry and Remote Sensing, 163, 327-342.
90. Dragičević, N. (2016). Model for Erosion Intensity and Sediment Production Assessment Based on Erosion Potential Method Modification}} (Doctoral dissertation, University of Rijeka. Faculty of Civil Engineering.).

91. Državna geodetska uprava (2016). Pravilnik o topografskoj izmjeri i izradi državnih karata. Preuzeto sa https://narodne-novine.nn.hr/clanci/sluzbeni/2016_07_65_1618.html (22.10.2020.).
92. Državna geodetska uprava (2018). Katalog podataka (verzija 1.11). Preuzeto sa https://dgu.gov.hr/UserDocsImages/dokumenti/Pristup%20informacijama/Zakoni%20i%20ostali%20propisi/Ostalo/Katalog_podataka_DGU_2018_v11.pdf (21.04.2020.)
93. Duan, X., Bai, Z., Rong, L., Li, Y., Ding, J., Tao, Y., ... i Wang, W. (2020). Investigation method for regional soil erosion based on the Chinese Soil Loss Equation and high-resolution spatial data: Case study on the mountainous Yunnan Province, China. Catena, 184, 104237.
94. Dube, H. B., Mutema, M., Muchaonyerwa, P., Poesen, J., i Chaplot, V. (2020). A global analysis of the morphology of linear erosion features. Catena, 190, 104542.
95. Eltner, A., Baumgart, P., Maas, H. G., i Faust, D. (2015). Multi-temporal UAV data for automatic measurement of rill and interrill erosion on loess soil. Earth Surface Processes and Landforms, 40(6), 741-755.
96. Eltner, A., Kaiser, A., Castillo, C., Rock, G., Neugirg, F., i Abellán, A. (2016). Image-based surface reconstruction in geomorphometry-merits, limits and developments. Earth Surface Dynamics, 4(2).
97. Eltner, A., Mulsow, C., i Maas, H. G. (2013). Quantitative measurement of soil erosion from TLS and UAV data. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 1(2), 119-124.
98. Enters, T. (1998). Methods for the economic assessment of the on-and off-site impacts of soil erosion. Bangkok, Thailand: IBSRAM.
99. Erkossa, T., Wudneh, A., Desalegn, B., i Taye, G. (2015). Linking soil erosion to on-site financial cost: lessons from watersheds in the Blue Nile basin. Solid Earth, 6(2), 765.
100. European Soil Data Centre (ESDAC) (2020), esdac.jrc.ec.europa.eu, European Commission, Joint Research Centre
101. Faivre, S., Pahernik, M., i Maradin, M. (2011). The gully of Potovošća on the Island of Krk–The effects of a short-term rainfall event. Geologia Croatica, 64(1), 67-80.
102. Fan, L., Smethurst, J. A., Atkinson, P. M., i Powrie, W. (2015). Error in target-based georeferencing and registration in terrestrial laser scanning. Computers i geosciences, 83, 54-64.

103. FAO i ITPS (2015). Status of the World's Soil Resources (SWSR) – Main Report. Food and Agriculture Organization of the United Nations and Intergovernmental Technical Panel on Soils, Rome, Italy
104. Faro (2019a). FARO FocusM 70 Laser Scanner Short-range professional grade laser scanner, https://www.laserscanning-europe.com/sites/default/files/redakteur_images/FARO-Focus-M-70-tech-sheet.pdf (Zadnji pristup: 12. prosinca 2019.).
105. Faro (2019b). Faro Focus laser scanner user manual, https://faro.app.box.com/s/8xtj92jnpu011i8crn2qyh1bd6d3s0mo/file/571591226811
106. Fathizad, H., Karimi, H., i Alibakhshi, S. M. (2014). The estimation of erosion and sediment by using the RUSLE model and RS and GIS techniques (Case study: Arid and semi-arid regions of Doviraj, Ilam province, Iran). International Journal of Agriculture and Crop Sciences, 7(6), 303.
107. Fernández, T., Pérez, J. L., Colomo, C., Cardenal, J., Delgado, J., Palenzuela, J. A., ... i Chacón, J. (2017). Assessment of the evolution of a landslide using digital photogrammetry and LiDAR techniques in the Alpujarras region (Granada, southeastern Spain). Geosciences, 7(2), 32.
108. Fernández, T., Pérez-García, J. L., Gómez-López, J. M., Cardenal, J., Calero, J., Sánchez-Gómez, M., ... i Tovar-Pescador, J. (2020). Multitemporal Analysis of Gully Erosion in Olive Groves by Means of Digital Elevation Models Obtained with Aerial Photogrammetric and LiDAR Data. ISPRS International Journal of Geo-Information, 9(4), 260.
109. Ferrer, V., Gómez-Gutiérrez, A., Nadal-Romero, E., Errea, P., i Alonso, E. (2017). A multiscale approach to assess geomorphological processes in a semiarid badland area (Ebro Depression, Spain) (No. ART-2017-101130).
110. Fischer, M., Huss, M., Kummert, M., i Hoelzle, M. (2016). Application and validation of long-range terrestrial laser scanning to monitor the mass balance of very small glaciers in the Swiss Alps. The Cryosphere, 10(3), 1279-1295.
111. Florinsky, I. (2016). Digital terrain analysis in soil science and geology. Academic Press.
112. Ford, D., i Williams, P. D. (2013). Karst hydrogeology and geomorphology. John Wiley i Sons.
113. Fortis, A. (1774). Viaggio in Dalmazia, dell'abate Alberto Fortis... A. Milocco.

114. Franek, J., i Kresta, A. (2014). Judgment scales and consistency measure in AHP. Procedia Economics and Finance, 12, 164-173.
115. Gao, J., i Wang, H. (2019). Temporal analysis on quantitative attribution of karst soil erosion: A case study of a peak-cluster depression basin in Southwest China. Catena, 172, 369-377.
116. Gašparović, M., Dobrinić, D., i Medak, D. (2019). Geometric accuracy improvement of WorldView-2 imagery using freely available DEM data. The Photogrammetric Record, 34(167), 266-281.
117. Gatti, A., i Bertolini, A. (2013). Sentinel-2 products specification document. Available online (preuzeto 19.10.2020) https://earth. esa. int/documents/247904/685211/Sentinel-2+ Products+ Specification+ Document.
118. Ghahremani, M., i Ghassemian, H. (2016). Nonlinear IHS: A promising method for pan-sharpening. IEEE Geoscience and Remote Sensing Letters, 13(11), 1606-1610.
119. Giménez, R., Marzolff, I., Campo, M. A., Seeger, M., Ries, J. B., Casalí, J., i Alvarez-Mozos, J. (2009): Accuracy of high-resolution photogrammetric measurements of gullies with contrasting morphology. Earth Surface Processes and Landforms, 34(14), 1915-1926.
120. Girardeau-Montaut, D., Roux, M., Marc, R., i Thibault, G. (2005). Change detection on points cloud data acquired with a ground laser scanner. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 36(part 3), W19.
121. Glendell, M., McShane, G., Farrow, L., James, M. R., Quinton, J., Anderson, K., ... i Brazier, R. E. (2017). Testing the utility of structure-from-motion photogrammetry reconstructions using small unmanned aerial vehicles and ground photography to estimate the extent of upland soil erosion. Earth Surface Processes and Landforms, 42(12), 1860-1871.
122. Goldbergs, G., Maier, S. W., Levick, S. R., i Edwards, A. (2019). Limitations of high resolution satellite stereo imagery for estimating canopy height in Australian tropical savannas. International Journal of Applied Earth Observation and Geoinformation, 75, 83-95.
123. Gómez-Gutiérrez, Á., i Gonçalves, G. R. (2020). Surveying coastal cliffs using two UAV platforms (multirotor and fixed-wing) and three different approaches for the estimation of volumetric changes. International Journal of Remote Sensing, 41(21), 8143-8175.

124. Gómez-Gutiérrez, Á., Conoscenti, C., Angileri, S. E., Rotigliano, E., i Schnabel, S. (2015). Using topographical attributes to evaluate gully erosion proneness (susceptibility) in two mediterranean basins: advantages and limitations. Natural Hazards, 79(1), 291-314.
125. Gómez-Gutiérrez, Á., Schnabel, S., i Contador, F. L. (2009c). Gully erosion, land use and topographical thresholds during the last 60 years in a small rangeland catchment in SW Spain. Land Degradation i Development, 20(5), 535-550.
126. Gómez-Gutiérrez, Á., Schnabel, S., i Contador, J. F. L. (2009b). Using and comparing two nonparametric methods (CART and MARS) to model the potential distribution of gullies. Ecological Modelling, 220(24), 3630-3637.
127. Gómez-Gutiérrez, Á., Schnabel, S., i Felicísimo, Á. M. (2009a). Modelling the occurrence of gullies in rangelands of southwest Spain. Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group, 34(14), 1894-1902.
128. Gómez-Gutiérrez, Á., Schnabel, S., Berenguer-Sempere, F., Lavado-Contador, F., i Rubio-Delgado, J. (2014). Using 3D photo-reconstruction methods to estimate gully headcut erosion. Catena, 120, 91-101.
129. Gómez-Gutiérrez, A., Schnabel, S., Lavado Contador, J. F., Sanjosé Blasco, J. J. D., Atkinson Gordo, A. D. J., Pulido Fernández, M., i Sánchez Fernández, M. (2018). Studying the influence of livestock pressure on gully erosion in rangelands of SW Spain by means of the UAV SfM workflow.
130. Goodwin, N. R., Armston, J. D., Muir, J., i Stiller, I. (2017). Monitoring gully change: A comparison of airborne and terrestrial laser scanning using a case study from Aratula, Queensland. Geomorphology, 282, 195-208.
131. Goodwin, N. R., Armston, J., Stiller, I., i Muir, J. (2016). Assessing the repeatability of terrestrial laser scanning for monitoring gully topography: A case study from Aratula, Queensland, Australia. Geomorphology, 262, 24-36.
132. Gourfi, A., i Daoudi, L. (2019). Effects of land use changes on soil erosion and sedimentation of dams in semi-arid regions: example of N'fis watershed in western high atlas, Morocco. Journal of Earth Science and Climatic Change, 10(513), 2.
133. Greenbaum, N., Mushkin, A., Porat, N., i Amit, R. (2020). Runoff generation, rill erosion and time-scales for hyper-arid abandoned alluvial surfaces, the Negev desert, Israel. Geomorphology, 358, 107101.

134. GreenValley International (2020). LiDAR360 User Guide – LiDAR point cloud processing and analyzing software. Preuzeto sa https://greenvalleyintl.com/wp-content/lidar360_en/index.html (02.12.2020.)
135. Grisogono, B., i Belušić, D. (2009). A review of recent advances in understanding the mesoand microscale properties of the severe Bora wind. Tellus A: Dynamic Meteorology and Oceanography, 61(1), 1-16.
136. Gruber, M., Ponticellia, M., Bernögger, S., Leberl, L., Chen, J., Jiang, J., i Baudoin, A. (2008, July). UltraCamX, the large format digital aerial camera system by Vexcel Imaging/Microsoft. In Proceedings of ISPRS XXIst Congress "Silk Road for Information from Imagery (pp. 3-11).
137. Gugić, J., Mioč, B., Krvavica, M., Grgić, I., i Čemeljić, A. (2012). Proizvodno-ekonomska obilježja ovčarske proizvodnje na otoku Pagu. Mljekarstvo/Dairy, 62(1).
138. Hancock, G. R., Loughran, R. J., Evans, K. G., i Balog, R. M. (2008). Estimation of soil erosion using field and modelling approaches in an undisturbed Arnhem Land catchment, Northern Territory, Australia. Geographical Research, 46(3), 333-349.
139. Hartemink, A. E. (2016). The definition of soil since the early 1800s. In Advances in Agronomy (Vol. 137, pp. 73-126). Academic Press.
140. Hayas, A., Poesen, J., i Vanwalleghem, T. (2017). Rainfall and vegetation effects on temporal variation of topographic thresholds for gully initiation in Mediterranean cropland and olive groves. Land Degradation i Development, 28(8), 2540-2552.
141. He, G., Ji, J., Zhang, Q., i Xia, Z. (2019, November). A Hybrid Pan-Sharpening Approach Using Nonnegative Matrix Factorization for WorldView Imageries. In Chinese Conference on Pattern Recognition and Computer Vision (PRCV) (pp. 703-713). Springer, Cham.
142. Hengl, T. (2006). Finding the right pixel size. Computers i geosciences, 32(9), 1283-1298.
143. Hively, W. D., Lamb, B. T., Daughtry, C. S., Shermeyer, J., McCarty, G. W., i Quemada, M. (2018). Mapping crop residue and tillage intensity using WorldView-3 satellite shortwave infrared residue indices. Remote Sensing, 10(10), 1657.
144. Hobi, M. L., i Ginzler, C. (2012). Accuracy assessment of digital surface models based on WorldView-2 and ADS80 stereo remote sensing data. Sensors, 12(5), 6347-6368.

145. Hout, R., Maleval, V., Mahe, G., Rouvellac, E., Crouzevialle, R., i Cerbelaud, F. (2020). UAV and LiDAR Data in the Service of Bank Gully Erosion Measurement in Rambla de Algeciras Lakeshore. Water, 12(10), 2748. https://www.labconco.com/product/freezone-8-liter-50c-benchtop-freeze-dryer-8/6343 (13.09.2020).
146. Hugenholtz C. H., Whitehead, K., Brown, O. W., Barchyn, T. E., Moorman, B. J., LeClair, A., ... i Hamilton, T. (2013): Geomorphological mapping with a small unmanned aircraft system (sUAS): Feature detection and accuracy assessment of a photogrammetrically-derived digital terrain model. Geomorphology, *194*, 16-24
147. IGU, Commission on applied geomorphology, subcommission on geomorphological mapping (1968): The unified key to the detailed geomorphologial map of the world, 1:25000 – 1: 50000, Folia geografica, series geographica-physica 2, Krakow. Ionita, I., Fullen, M. A., Zgłobicki, W., i Poesen, J. (2015). Gully erosion as a natural and human-induced hazard.
148. Igwe, O., John, U. I., Solomon, O., i Obinna, O. (2020). GIS-based gully erosion susceptibility modeling, adapting bivariate statistical method and AHP approach in Gombe town and environs Northeast Nigeria. Geoenvironmental Disasters, 7(1), 1-16.
149. James, L. A., Hodgson, M. E., Ghoshal, S., i Latiolais, M. M. (2012). Geomorphic change detection using historic maps and DEM differencing: The temporal dimension of geospatial analysis. Geomorphology, 137(1), 181-198.
150. James, M. R., Chandler, J. H., Eltner, A., Fraser, C., Miller, P. E., Mills, J. P., ... i Lane, S. N. (2019). Guidelines on the use of structure-from-motion photogrammetry in geomorphic research. Earth Surface Processes and Landforms, 44(10), 2081-2084.
151. James, M. R., Robson, S., i Smith, M. W. (2017b). 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. Earth Surface Processes and Landforms, 42(12), 1769-1788.
152. James, M. R., Robson, S., d'Oleire-Oltmanns, S., i Niethammer, U. (2017a). Optimising UAV topographic surveys processed with structure-from-motion: Ground control quality, quantity and bundle adjustment. Geomorphology, 280, 51-66.
153. Kirkby, M. J., i Bracken, L. J. (2009). Gully processes and gully dynamics. Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group, 34(14), 1841-1851.

154. Kiss, R. (2004). Determination of drainage network in digital elevation models, utilities and limitations. Journal of Hungarian geomathematics, 2, 16-29.
155. Koci, J., Jarihani, B., Leon, J. X., Sidle, R. C., Wilkinson, S. N., i Bartley, R. (2017). Assessment of UAV and ground-based structure from motion with multi-view stereo photogrammetry in a gullied savanna catchment. ISPRS International Journal of Geo-Information, 6(11), 328.
156. Kouli, M., Soupios, P., i Vallianatos, F. (2009). Soil erosion prediction using the revised universal soil loss equation (RUSLE) in a GIS framework, Chania, Northwestern Crete, Greece. Environmental Geology, 57(3), 483-497.
157. Kromer, R. A., Abellán, A., Hutchinson, D. J., Lato, M., Chanut, M. A., Dubois, L., i Jaboyedoff, M. (2017). Automated terrestrial laser scanning with near-real-time change detection–monitoring of the Séchilienne landslide. Earth surface dynamics, 5(2), 293-310.
158. Labconco (2020). FreeZone 8 Liter -50C Benchtop Freeze Dryer Datasheet. Preuzeto sa
159. Lague, D., Brodu, N., i Leroux, J. (2013). Accurate 3D comparison of complex topography with terrestrial laser scanner: Application to the Rangitikei canyon (NZ). ISPRS journal of photogrammetry and remote sensing, 82, 10-26.
160. Lal, R. (1988): Effects of slope length, slope gradient, tillage methods and cropping systems on runoff and soil erosion on a tropical Alfisol: preliminary results, International Assoc. Hydrological Sciences Publ, (174), 79-88.
161. Lal, R. (2003). Soil erosion and the global carbon budget. Environment international, 29(4), 437-450.
162. Lal, R., i Elliot, W. (1994). Erodibility and erosivity. Soil erosion research methods, 1, 181-208.
163. Landeka, I., Vilus, I. (2012). Izrada DOF 5 za potrebe legalizacije nelegalno izrađenih objekata i izrada KB100; Hrvatska gospodarska komora - sektor za trgovinu, 17. forum poslovanja nekretninama, 4. – 5. svibnja 2012., Šibenik.
164. Landinfo (2020). Buying Satellite Imagery: Pricing Information for High Resolution Satellite Imagery. Preuzeto sa http://www.landinfo.com/satellite-imagery-pricing.html (22.10.2020.).

165. Le Roux, J. J., i Sumner, P. D. (2012). Factors controlling gully development: comparing continuous and discontinuous gullies. Land Degradation i Development, 23(5), 440-449.
166. Li, L., Nearing, M. A., Nichols, M. H., Polyakov, V. O., i Cavanaugh, M. L. (2020). Using terrestrial LiDAR to measure water erosion on stony plots under simulated rainfall. Earth Surface Processes and Landforms, 45(2), 484-495.
167. Liu, H., Qian, F., Ding, W., i Gómez, J. A. (2019). Using 3D scanner to study gully evolution and its hydrological analysis in the deep weathering of southern China. Catena, 183, 104218.
168. Liu, K., Ding, H., Tang, G., Na, J., Huang, X., Xue, Z., ... i Li, F. (2016). Detection of catchment-scale gully-affected areas using unmanned aerial vehicle (UAV) on the Chinese Loess Plateau. ISPRS International Journal of Geo-Information, 5(12), 238.
169. Liu, K., Ding, H., Tang, G., Zhu, A. X., Yang, X., Jiang, S., i Cao, J. (2017). An object-based approach for two-level gully feature mapping using high-resolution DEM and imagery: a case study on hilly loess plateau region, China. Chinese Geographical Science, 27(3), 415-430.
170. Llasat, M. C. (2001). An objective classification of rainfall events on the basis of their convective features: application to rainfall intensity in the northeast of Spain. International Journal of Climatology: A Journal of the Royal Meteorological Society, 21(11), 1385-1400.
171. Lončar, N. (2009). Geomorphologic regionalization of the central and southern parts of Pag Island. Geoadria, 14(1), 5-25.
172. Lu, X., Li, Y., Washington-Allen, R. A., Li, Y., Li, H., i Hu, Q. (2017). The effect of grid size on the quantification of erosion, deposition, and rill network. *International Soil and Water Conservation Research*, *5*(3), 241-251.
173. Lucà, F., Conforti, M., i Robustelli, G. (2011). Comparison of GIS-based gullying susceptibility mapping using bivariate and multivariate statistics: Northern Calabria, South Italy. Geomorphology, 134(3-4), 297-308.
174. Magaš, D. (2011). Zemljopisna obilježja otoka Paga u funkciji upoznavanja njegove toponimije. Toponimija otoka Paga, Biblioteka Onomastica Adriatica, knj, 5, 5-49.
175. Maglione, P., Parente, C., i Vallario, A. (2014). Coastline extraction using high resolution WorldView-2 satellite imagery. European Journal of Remote Sensing, 47(1), 685-699.

176. Magliulo, P. (2010). Soil erosion susceptibility maps of the Janare Torrent Basin (southern Italy). Journal of Maps, 6(1), 435-447.
177. Majcen, Ž., Korolija, B., Sokač, B., i Nikler, L. (1970). Osnovna geološka karta SFRJ 1: 100 000, List Zadar L33-139. Institut za geološka istraživanja Zagreb, Savezni geološki zavod, Beograd.
178. Malczewski, J. (2006). GIS-based multicriteria decision analysis: a survey of the literature. International journal of geographical information science, 20(7), 703-726.
179. Malczewski, J., i Rinner, C. (2015). Multicriteria decision analysis in geographic information science (p. 331). New York: Springer.
180. Mamužić, P. i Sokač, B. (1973). Osnovna geološka karta SFRJ 1 : 100 000. Tumač za listove Silba L 33-126 i Molat L 33-138. Institut za geološka istraživanja, Zagreb, Savezni geološki zavod, Beograd, 45 str.
mapping (1968). The unified key to the detailed geomorphological map of the world,
181. Marić, I., Šiljeg, A., Cukrov, N., Roland, V., i Domazetović, F. How fast does tufa grow? Very high-resolution measurement of the tufa growth rate on artificial substrates by the development of a contactless image-based modelling device. Earth Surface Processes and Landforms.
182. Marriner, N., Morhange, C., Faivre, S., Flaux, C., Vacchi, M., Miko, S., ... i Rossi, I. R. (2014). Post-Roman sea-level changes on Pag Island (Adriatic Sea): Dating Croatia's “enigmatic” coastal notch?. Geomorphology, 221, 83-94.
183. Marzolff, I., i Poesen, J. (2009). The potential of 3D gully monitoring with GIS using high-resolution aerial photography and a digital photogrammetry system. Geomorphology, 111(1), 48-60
184. Marzolff, I., Ries, J. B., i Poesen, J. (2011): Short-term versus medium-term monitoring for detecting gully-erosion variability in a Mediterranean environment. *Earth Surface Processes and Landforms, 36*(12), str. 1604-1623
185. Mas, J. F., Soares Filho, B., Pontius, R. G., Farfán Gutiérrez, M., i Rodrigues, H. (2013). A suite of tools for ROC analysis of spatial models. ISPRS International Journal of Geo-Information, 2(3), 869-887.
186. Maxar (2020a): Worldview-1. Datasheet. (Zadnji pristup: 24. ožujka, 2020.).
187. Maxar (2020b): Worldview-2. Datasheet. (Zadnji pristup: 24. ožujka, 2020.).
188. Maxar (2020c): Worldview-3. Datasheet. (Zadnji pristup: 24. ožujka, 2020.).

189. Meda, M., Martinelli, M., Bistacchi, A., Mittempergher, S., Berio, L., Balsamo, F., ... i Storti, F. (2019, November). 3D Multi-Scale Characterization and Modeling of Three Fractured Carbonatic Outcrop Analogues: Pag Croatia, Parmelan France, Gozo Maltese Islands. In Abu Dhabi International Petroleum Exhibition i Conference. Society of Petroleum Engineers.
190. Meusburger, K., Steel, A., Panagos, P., Montanarella, L., i Alewell, C. (2012). Spatial and temporal variability of rainfall erosivity factor for Switzerland. Hydrology and Earth System Sciences, 16, 167-177.
191. Mittempergher, S., Succo, A., Bistacchi, A., Storti, F., Bruna, P. B. R., i Meda, M. (2019). Geological and structural map of the southeastern Pag Island, Croatia: field constraints on the Cretaceous-Eocene evolution of the Dinarides foreland. Geological Field Trips and Maps, 11(2.4).
192. Möller, M., i Volk, M. (2015). Effective map scales for soil transport processes and related process domains—Statistical and spatial characterization of their scale-specific inaccuracies. Geoderma, 247, 151-160.
193. Möller, M., Koschitzki, T., Hartmann, K. J., i Jahn, R. (2012). Plausibility test of conceptual soil maps using relief parameters. Catena, 88(1), 57-67.
194. Möller, M., Volk, M., Friedrich, K., i Lymburner, L. (2008). Placing soil-genesis and transport processes into a landscape context: A multiscale terrain-analysis approach. Journal of Plant Nutrition and Soil Science, 171(3), 419-430.
195. Montanarella, L. (2015). Agricultural policy: Govern our soils. Nature, 528(7580), 32-33.
196. Moody, D. I., Brumby, S. P., Rowland, J. C., Altmann, G. L., i Larson, A. E. (2014). Change detection and classification of land cover in multispectral satellite imagery using clustering of sparse approximations (CoSA) over learned feature dictionaries. In 2014 IEEE Applied Imagery Pattern Recognition Workshop (AIPR) (pp. 1-10). IEEE.
197. Moore, I. D., Grayson, R. B., i Ladson, A. R. (1991). Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. Hydrological processes, 5(1), 3-30.
198. Moore, I. D., Turner AK, Wilson JP, Jenson SK, Band LE (1993) GIS and land-surface-subsurface process modelling. In: Goodchild MF, Parks BO, Steyaert LT (eds) Environmental modelling with GIS, pp 213–230.
199. Morgan, R. P. C. (2009). Soil erosion and conservation. John Wiley i Sons.

200. Morgan, R. P. C., i Mngomezulu, D. (2003). Threshold conditions for initiation of valley-side gullies in the Middle Veld of Swaziland. Catena, 50(2-4), 401-414.
201. Neef, E. (1963) Dimensionen geographischer Betrachtungen. Forsch u Fortschr 37:361-363.
202. Neugirg, F., Stark, M., Kaiser, A., Vlacilova, M., Della Seta, M., Vergari, F., ... i Haas, F. (2016). Erosion processes in calanchi in the Upper Orcia Valley, Southern Tuscany, Italy based on multitemporal high-resolution terrestrial LiDAR and UAV surveys. Geomorphology, 269, 8-22.
203. Neverman, A. J., Fuller, I. C., i Procter, J. N. (2016). Application of geomorphic change detection (GCD) to quantify morphological budgeting error in a New Zealand gravel-bed river: A case study from the Makaroro river, Hawke's bay. Journal of Hydrology (New Zealand), 45-63.
204. Newall, J. C., Dymova, T., Serra, E., Blomdin, R., Fredin, O., Glasser, N. F., ... i Stroeven, A. P. (2020). The glacial geomorphology of western Dronning Maud Land, Antarctica. Journal of Maps, 16(2), 468-478.
205. Nhu, V. H., Janizadeh, S., Avand, M., Chen, W., Farzin, M., Omidvar, E., ... i Mansoorypoor, F. (2020). Gis-based gully erosion susceptibility mapping: A comparison of computational ensemble data mining models. Applied Sciences, 10(6), 2039.
206. Onset (2020). HOBO® RG3-M Data Logger Rain Gauge (Metric) Data Logger. Datasheet. Preuzeto sa https://www.onsetcomp.com/datasheet/RG3-M (20.10.2020.).
207. Ouédraogo, M. M., Degré, A., Debouche, C., i Lisein, J. (2014): The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds. Geomorphology, 214, 339-355
208. Pan, J., i Wen, Y. (2014). Estimation of soil erosion using RUSLE in Caijiamiao watershed, China. Natural Hazards, 71(3), 2187-2205.
209. Panagos, P., Ballabio, C., Borrelli, P., Meusburger, K., Klik, A., Rousseva, S., ... i Aalto, J. (2015a). Rainfall erosivity in Europe. Science of the Total Environment, 511, 801-814.
210. Panagos, P., Borrelli, P., i Meusburger, K. (2015d). A new European slope length and steepness factor (LS-Factor) for modeling soil erosion by water. Geosciences, 5(2), 117-126.

211. Panagos, P., Borrelli, P., i Robinson, D. A. (2015b). Tackling soil loss across Europe. Nature, 526(7572), 195-195.
212. Panagos, P., i Borelli, P. (2017). Soil erosion in Europe: Current status, challenges and future developments. All that soil erosion: The global task to conserve our soil resources, 20-21.
213. Panagos, P., Borrelli, P., Meusburger, K., Alewell, C., Lugato, E., i Montanarella, L. (2015e). Estimating the soil erosion cover-management factor at the European scale. Land use policy, 48, 38-50.
214. Panagos, P., Borrelli, P., Meusburger, K., van der Zanden, E. H., Poesen, J., i Alewell, C. (2015f). Modelling the effect of support practices (P-factor) on the reduction of soil erosion by water at European scale. Environmental science i policy, 51, 23-34.
215. Panagos, P., Borrelli, P., Poesen, J., Ballabio, C., Lugato, E., Meusburger, K., ... i Alewell, C. (2015c). The new assessment of soil loss by water erosion in Europe. Environmental science i policy, 54, 438-447.
216. Panagos, P., Standardi, G., Borrelli, P., Lugato, E., Montanarella, L., i Bosello, F. (2018). Cost of agricultural productivity loss due to soil erosion in the European Union: From direct cost evaluation approaches to the use of macroeconomic models. Land Degradation i Development, 29(3), 471-484.
217. PCI Geomatics Enterprises (2018.). Geomatica Training Guide – Geomatica OrthoEngine Course exercises (version 2018), https://www.pcigeomatics.com/pdf/TrainingGuide-Geomatica-OrthoEngine.pdf (Zadnji pristup: 25. ožujka, 2020.).
218. Perroy, R. L., Bookhagen, B., Asner, G. P., i Chadwick, O. A. (2010). Comparison of gully erosion estimates using airborne and ground-based LiDAR on Santa Cruz Island, California. Geomorphology, 118(3-4), 288-300.
219. Peter, K. D., d'Oleire-Oltmanns, S., Ries, J. B., Marzolff, I., i Hssaine, A. A. (2014): Soil erosion in gully catchments affected by land-levelling measures in the Souss Basin, Morocco, analysed by rainfall simulation and UAV remote sensing data. Catena, 113, 24-40
220. Phinzi, K., i Ngetar, N. S. (2017). Mapping soil erosion in a quaternary catchment in Eastern Cape using geographic information system and remote sensing. South African Journal of Geomatics, 6(1), 11-29.

221. Pimentel, D., i Burgess, M. (2013). Soil erosion threatens food production. Agriculture, 3(3), 443-463.
222. Poesen, J. (1992). Mechanisms of overland flow generation and sediment production on loamy and sandy soils with and without rock fragments. In: Parsons, A.J., Abrahams, A.D. (Eds.), Overland Flow Hydraulics and Erosion Mechanics. UCL Press, London, pp. 275–305.
223. Poesen, J. (2011). Challenges in gully erosion research. Landform analysis, 17, 5-9.
224. Poesen, J., Nachtergaele, J., Verstraeten, G., i Valentin, C. (2003). Gully erosion and environmental change: importance and research needs. Catena, 50(2-4), 91-133.
225. Poesen, J., Vanwalleghem, T., de Vente, J., Knapen, A., Verstraeten, G., i Martínez-Casasnovas, J. A. (2006). Gully erosion in Europe. Soil erosion in Europe, 515-536.
226. Poli, D., i Caravaggi, I. (2012). Digital surface modelling and 3D information extraction from spaceborne very high resolution stereo pairs. JRC Scientific and Technical Reports, Ispra.
227. Raduła, M. W., Szymura, T. H., i Szymura, M. (2018). Topographic wetness index explains soil moisture better than bioindication with Ellenberg's indicator values. Ecological Indicators, 85, 172-179.
228. Rahmati, O., Haghizadeh, A., Pourghasemi, H. R., i Noormohamadi, F. (2016). Gully erosion susceptibility mapping: the role of GIS-based bivariate statistical models and their comparison. Natural Hazards, 82(2), 1231-1258.
229. Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R., i Feizizadeh, B. (2017b). Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion. Geomorphology, 298, 118-137.
230. Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R., i Feizizadeh, B. (2017). Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework. Science of the Total Environment, 579, 913-927.
231. Rajput, U. K., Ghosh, S. K., i Kumar, A. (2016). Multi-sensor satellite pan-sharpening based on IHS and window pseudo Wigner distribution integrated approach: application to WorldView-2 imagery. International Journal of Image and Data Fusion, 7(2), 119-147.

232. Rengers, F. K., i Tucker, G. E. (2015). The evolution of gully headcut morphology: a case study using terrestrial laser scanning and hydrological monitoring. Earth Surface Processes and Landforms, 40(10), 1304-1317.
233. Retsch (2020). Vibratory Sieve Shaker AS 200 basic Datasheet. Preuzeto sa https://www.retsch.com/products/sieving/sieve-shakers/as-200-basic/function-features/ (17.12.2020).
234. Rieke-Zapp, D. H., i Nichols, M. H. (2011). Headcut retreat in a semiarid watershed in the southwestern United States since 1935. Catena, 87(1), 1-10.
235. Riley, J. W., Calhoun, D. L., Barichivich, W. J., i Walls, S. C. (2017). Identifying small depressional wetlands and using a topographic position index to infer hydroperiod regimes for pond-breeding amphibians. Wetlands, 37(2), 325-338.
236. Riley, S. J., DeGloria, S. D., i Elliot, R. (1999). Index that quantifies topographic heterogeneity. intermountain Journal of sciences, 5(1-4), 23-27.
237. Riverscapes Consortium (2020). Geomorphic Change Detection Software. Preuzeto sa http://gcd.riverscapes.xyz/ (18.09.2020.).
238. Rodríguez-Caballero, E., Román, J. R., Chamizo, S., Roncero Ramos, B., i Cantón, Y. (2019). Biocrust landscape-scale spatial distribution is strongly controlled by terrain attributes: Topographic thresholds for colonization in a semiarid badland system. Earth Surface Processes and Landforms, 44(14), 2771-2779.
239. Roose, E. (1996). Land husbandry: components and strategy (Vol. 70). Rome: FAO.
240. Rossini, M., Di Mauro, B., Garzonio, R., Baccolo, G., Cavallini, G., Mattavelli, M., ... i Colombo, R. (2018). Rapid melting dynamics of an alpine glacier with repeated UAV photogrammetry. Geomorphology, 304, 159-172.
241. Różycka, M., Migoń, P., i Michniewicz, A. (2017). Topographic Wetness Index and Terrain Ruggedness Index in geomorphic characterisation of landslide terrains, on examples from the Sudetes, SW Poland. Zeitschrift für geomorphologie, Supplementary issues, 61(2), 61-80.
242. Ryan, J. C., Hubbard, A. L., Todd, J., Carr, J. R., Box, J. E., Christoffersen, P., ... i Snooke, N. (2014). Repeat UAV photogrammetry to assess calving front dynamics at a large outlet glacier draining the Greenland Ice Sheet. The Cryosphere Discuss, 8(2), 2243-2275.
243. Saaty, T. L. (2004). Decision making—the analytic hierarchy and network processes (AHP/ANP). Journal of systems science and systems engineering, 13(1), 1-35.

244. Saaty, T. L. (2008). Decision making with the analytic hierarchy process. International journal of services sciences, 1(1), 83-98.
245. Saha, S., Roy, J., Arabameri, A., Blaschke, T., i Tien Bui, D. (2020). Machine Learning-Based Gully Erosion Susceptibility Mapping: A Case Study of Eastern India. Sensors, 20(5), 1313.
246. Santarsiero, V., Nolè, G., Lanorte, A., Tucci, B., Saganeiti, L., Pilogallo, A., ... i Murgante, B. (2020, July). Assessment of Post Fire Soil Erosion with ESA Sentinel-2 Data and RUSLE Method in Apulia Region (Southern Italy). In International Conference on Computational Science and Its Applications (pp. 590-603). Springer, Cham.
247. Schmidt, J. (Ed.). (2013). Soil Erosion: Application of physically based models. Springer Science i Business Media.
248. Schmiedel, U., Kruspe, M., Kayser, L., i Oettlé, N. (2017). The ecological and financial impact of soil erosion and its control–a case study from the semiarid Northern Cape Province, South Africa. Land Degradation i Development, 28(1), 74-82.
249. Sena, N. C., Veloso, G. V., Fernandes Filho, E. I., Francelino, M. R., i Schaefer, C. E. G. (2020). Analysis of terrain attributes in different spatial resolutions for digital soil mapping application in southeastern Brazil. Geoderma Regional, e00268.
250. Sepuru, T. K., i Dube, T. (2018). An appraisal on the progress of remote sensing applications in soil erosion mapping and monitoring. Remote Sensing Applications: Society and Environment, 9, 1-9.
251. Seutloali, K. E., Dube, T., i Mutanga, O. (2017). Assessing and mapping the severity of soil erosion using the 30-m Landsat multispectral satellite data in the former South African homelands of Transkei. Physics and Chemistry of the Earth, Parts A/B/C, 100, 296-304.
252. Sharma, A. (2010). Integrating terrain and vegetation indices for identifying potential soil erosion risk area. Geo-Spatial Information Science, 13(3), 201-209.
253. Shean, D. E., Alexandrov, O., Moratto, Z. M., Smith, B. E., Joughin, I. R., Porter, C., i Morin, P. (2016). An automated, open-source pipeline for mass production of digital elevation models (DEMs) from very-high-resolution commercial stereo satellite imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 116, 101-117.

254. Shruthi, R. B., Kerle, N., Jetten, V., Abdellah, L., i Machmach, I. (2015). Quantifying temporal changes in gully erosion areas with object oriented analysis. Catena, 128, 262-277.

255. Šiljeg, A. (2013). Digitalni model reljefa u analizi geomorfometrijskih parametara– primjer PP Vransko jezero (Doctoral dissertation, Doktorski rad, PMF, Sveucilište u Zagrebu).

256. Šiljeg, A., Domazetović, F., Marić, I., Lončar, N., i Panđa, L. (2021). New Method for Automated Quantification of Vertical Spatio-Temporal Changes within Gully Cross-Sections Based on Very-High-Resolution Models. Remote Sensing, 13(2), 321.

257. Škoda, M. (2017). Utjecaj bure na kvalitetu tla u okružju grada Paga.

258. Soil Science Society of America (2008). Glossary of soil science terms 2008. Soil Science Glossary Terms Committee i Soil Science Society of America, ASA-CSSA-SSSA.

259. Sokač, B., Šćavničar, B., Velić, I. (1976). Osnovna geološka karta SFRJ 1 : 100 000. Tumač za list Gospić L 33-127. Institut za geološka istraživanja, Zagreb, Savezni geološki zavod, Beograd, 64 str.

260. Stark, M., Neugirg, F., Kaiser, A., Seta, M. D., Schmidt, J., Becht, M., i Haas, F. (2020). Calanchi badlands reconstructions and long-term change detection analysis from historical aerial and UAS image processing. Journal of Geomorphology.

261. Stöcker, C., Eltner, A., i Karrasch, P. (2015). Measuring gullies by synergetic application of UAV and close range photogrammetry—A case study from Andalusia, Spain. Catena, 132, 1-11.

262. Sun, W., Shao, Q., Liu, J., i Zhai, J. (2014). Assessing the effects of land use and topography on soil erosion on the Loess Plateau in China. Catena, 121, 151-163.

263. Šurda, P., Šimonides, I., i Antal, J. (2007). A determination of area of potential erosion by geographic information systems. Journal of environmental engineering and landscape management, 15(3), 144-152.

264. Taherdoost, H. (2017). Decision making using the analytic hierarchy process (AHP); A step by step approach. International Journal of Economics and Management Systems, 2.

265. Tamene, L., i Le, Q. B. (2015). Estimating soil erosion in sub-Saharan Africa based on landscape similarity mapping and using the revised universal soil loss equation (RUSLE). Nutrient cycling in agroecosystems, 102(1), 17-31.

266. Tang, Q., Xu, Y., Bennett, S. J., i Li, Y. (2015). Assessment of soil erosion using RUSLE and GIS: a case study of the Yangou watershed in the Loess Plateau, China. Environmental Earth Sciences, 73(4), 1715-1724.
267. Taylor, R. J., Massey, C., Fuller, I. C., Marden, M., Archibald, G., i Ries, W. (2018). Quantifying sediment connectivity in an actively eroding gully complex, Waipaoa catchment, New Zealand. Geomorphology, 307, 24-37.
268. Telles, T. S., Dechen, S. C. F., Souza, L. G. A. D., i Guimarães, M. D. F. (2013). Valuation and assessment of soil erosion costs. Scientia Agricola, 70(3), 209-216.
269. Telles, T. S., Guimarães, M. D. F., i Dechen, S. C. F. (2011). The costs of soil erosion. Revista Brasileira de Ciência do Solo, 35(2), 287-298.
270. Thomas, J., Joseph, S., i Thrivikramji, K. P. (2018). Estimation of soil erosion in a rain shadow river basin in the southern Western Ghats, India using RUSLE and transport limited sediment delivery function. International Soil and Water Conservation Research, 6(2), 111-122.
271. Thommeret, N., Bailly, J. S., i Puech, C. (2009). Robust extraction of Thalwegs networks from DTMs for topological characterisation: a case study on badlands. Proceedings of Geomorphometry, 31, 218-223.
272. Tobler, Waldo. 1987. “Measuring Spatial Resolution”, Proceedings, Land Resources Information Systems Conference, Beijing, pp. 12-16.
273. Tobler, Waldo. 1988. “Resolution, Resampling, and All That”, pp. 129-137 of H. Mounsey and R. Tomlinson, eds., Building Data Bases for Global Science, London, Taylor and Francis.
274. Tonković, T. (2006). Vexcel-UltraCam. Kartografija i geoinformacije, 5(5), 116-119.
275. Torresani, L., Wu, J., Masin, R., Penasa, M., i Tarolli, P. (2019). Estimating soil degradation in montane grasslands of North-eastern Italian Alps (Italy). Heliyon, 5(6), e01825.
276. Torri, D., i Poesen, J. (2014). A review of topographic threshold conditions for gully head development in different environments. Earth-Science Reviews, 130, 73-85.
277. Toševski, A., Grgec, D., & Padovan, B. (2012). Osnovno o genezi, sastavu i trošenju eocenskog fliša hrvatskog obalnog pojasa. Rudarsko-geološko-naftni zbornik, 25(1), 47-62.
278. USDA. (2017). Soil survey manual. Soil Science Division Staff. Agriculture Handbook No. 18.

279. van Veen, M., Hutchinson, D. J., Kromer, R., Lato, M., i Edwards, T. (2017). Effects of sampling interval on the frequency-magnitude relationship of rockfalls detected from terrestrial laser scanning using semi-automatedmethods. Landslides, 14(5), 1579-1592. Schlögel, R

280. Vandekerckhove, L., Poesen, J., Oostwoud-Wijdenes, D., Nachtergaele, J., Kosmas, D., Roxo, M. J., Figueiredo, T. D. (2000): Thresholds for gully initiation and sedimentation in Mediterranean Europe, Earth Surface Processes and Landforms, 1201-1220.

281. Vanmaercke, M., Poesen, J., Van Mele, B., Demuzere, M., Bruynseels, A., Golosov, V., ... i Fuseina, Y. (2016). How fast do gully headcuts retreat?. Earth-Science Reviews, 154, 336-355.

282. Vannoppen, W., Vanmaercke, M., De Baets, S., i Poesen, J. (2015). A review of the mechanical effects of plant roots on concentrated flow erosion rates. Earth-Science Reviews, 150, 666-678.

283. Velić, I., i Vlahović, I. (2009). Geološka karta Republike Hrvatske 1: 300 000. Hrvatski geološki institut, Zagreb.

284. Vexcel Imaging (2020a). UltraCam Condor Mark 1 – 38,000 pixels across the flight strip. Technical datasheet. Preuzeto sa https://www.vexcel-imaging.com/brochures/UC_Condor_M1_en.pdf (18.09.2020.).

285. Vexcel Imaging (2020b). UltraCam Eagle Mark 3 - One System for endless possibilities. Technical datasheet. Preuzeto sa https://www.vexcel-imaging.com/brochures/UC_Eagle_M3_en.pdf (18.09.2020.).

286. Vexcel Imaging (2020c). UltraMount – Because your jobs hang in the. Technical datasheet. Preuzeto sa https://www.vexcel-imaging.com/brochures/UltraMount_en.pdf (18.09.2020.).

287. Vlahović, I., Velić, I., Tomljenović, B., Matoš, B., i Enos, P. (2018). Massive Cenozoic carbonate breccia in the Karst Dinarides of Croatia. Advances of Geology in southeast European mountain belts, 201.

288. Wang, P., Jin, X., i Li, S. (2018). Application of Handheld 3D Scanner in Quantitative Study of Slope Soil Erosion. EiES, 170(2), 022178.

289. Wang, P., Jin, X., Li, S., Wang, C., i Zhao, H. (2019). Digital Modeling of Slope Micro-geomorphology Based on Artec Eva 3D Scanning Technology. In IOP

Conference Series: Earth and Environmental Science (Vol. 252, No. 5, p. 052116). IOP Publishing.

290. Wang, R., Zhang, S., Pu, L., Yang, J., Yang, C., Chen, J., ... i Sang, X. (2016). Gully erosion mapping and monitoring at multiple scales based on multi-source remote sensing data of the Sancha River Catchment, Northeast China. ISPRS International Journal of Geo-Information, 5(11), 200.
291. Wang, S., Ren, Z., Wu, C., Lei, Q., Gong, W., Ou, Q., ... i Li, C. (2019). DEM generation from Worldview-2 stereo imagery and vertical accuracy assessment for its application in active tectonics. Geomorphology, 336, 107-118.
292. Waser, L. T., Küchler, M., Jütte, K., i Stampfer, T. (2014). Evaluating the potential of WorldView-2 data to classify tree species and different levels of ash mortality. Remote Sensing, 6(5), 4515-4545.
293. Weiss, A. (2001). Topographic position and landforms analysis. In Poster presentation, ESRI user conference, San Diego, CA (Vol. 200).
294. Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., i Reynolds, J. M. (2012). 'Structure-from-Motion'photogrammetry: A low-cost, effective tool for geoscience applications. Geomorphology, 179, 300-314.
295. Wheaton, J. M., Brasington, J., Darby, S. E., i Sear, D. A. (2010). Accounting for uncertainty in DEMs from repeat topographic surveys: improved sediment budgets. Earth surface processes and landforms: the journal of the British Geomorphological Research Group, 35(2), 136-156.
296. Wilkinson, S. N., Kinsey-Henderson, A. E., Hawdon, A. A., Hairsine, P. B., Bartley, R., i Baker, B. (2018). Grazing impacts on gully dynamics indicate approaches for gully erosion control in northeast Australia. Earth Surface Processes and Landforms, 43(8), 1711-1725.
297. Williams, R. (2012). DEMs of difference. Geomorphological Techniques, 2(3.2).
298. Williams, J. G., Anders, K., Winiwarter, L., Zahs, V., i Höfle, B. (2021). Multi-directional change detection between point clouds. ISPRS Journal of Photogrammetry and Remote Sensing, 172, 95-113.
299. Wilson, J. P., Gallant, J. C. (ur.). (2000): Terrain analysis: principles and applications, John Wiley i Sons, New York, SAD

300. Wischmeier, W. H., i Smith, D. D. (1978). Predicting rainfall erosion losses: a guide to conservation planning (No. 537). Department of Agriculture, Science and Education Administration.

301. Wolf, A. F. (2012). Using WorldView-2 Vis-NIR multispectral imagery to support land mapping and feature extraction using normalized difference index ratios. In Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII (Vol. 8390, p. 83900N). International Society for Optics and Photonics.

302. Yokoi, H. (1968). Relationship between soil cohesion and shear strength. Soil Science and Plant Nutrition, 14(3), 89-93.

303. Zachar, D. (2011). Soil erosion. Elsevier.

304. Zakerinejad, R., i Maerker, M. (2015). An integrated assessment of soil erosion dynamics with special emphasis on gully erosion in the Mazayjan basin, southwestern Iran. Natural Hazards, 79(1), 25-50.

305. Zeng, C., Wang, S., Bai, X., Li, Y., Tian, Y., Li, Y., ... i Luo, G. (2017). Soil erosion evolution and spatial correlation analysis in a typical karst geomorphology using RUSLE with GIS. Solid Earth, 8(4), 721.

306. Zevenbergen, L. W., i Thorne, C. R. (1987). Quantitative analysis of land surface topography. Earth surface processes and landforms, 12(1), 47-56.

307. Zhang, H., Pu, R., i Liu, X. (2016). A new image processing procedure integrating PCI-RPC and ArcGIS-Spline tools to improve the orthorectification accuracy of high-resolution satellite imagery. Remote Sensing, 8(10), 827.

308. Zhang, H., Yang, Q., Li, R., Liu, Q., Moore, D., He, P., ... i Geissen, V. (2013). Extension of a GIS procedure for calculating the RUSLE equation LS factor. Computers i Geosciences, 52, 177-188.

309. Zhang, W., Chen, Y., Wang, H., Chen, M., Wang, X., i Yan, G. (2016). Efficient registration of terrestrial LiDAR scans using a coarse-to-fine strategy for forestry applications. Agricultural and Forest Meteorology, 225, 8-23.

310. Zhang, X. B., Bai, X. Y., i He, X. B. (2011). Soil creeping in the weathering crust of carbonate rocks and underground soil losses in the karst mountain areas of southwest China. Carbonates and evaporites, 26(2), 149-153.

311. Zhuang, Y., Du, C., Zhang, L., Du, Y., i Li, S. (2015). Research trends and hotspots in soil erosion from 1932 to 2013: a literature review. Scientometrics, 105(2), 743-758.

Pregled korištenih kratica

- **DMD** – digitalni model diferencije (engl. *DEM of Difference (DoD)*)
- **DMP** – digitalni model površina (engl. *digital surface model (DSM)*)
- **DMR** – digitalni model reljefa (engl. *digital elevation model (DEM)*)
- **MAE** – prosječna apsolutna pogreška (engl. *mean apsolute error*)
- **PVP** – prostorno-vremenske promjene (engl. *spatio-temporla changes*)
- **RMSE** – korijen srednje kvadratne pogreške – (engl. *root-mean square error*)
- **SD** – standardna devijacija (engl. *standard deviation*)
- **TLS** – terestrički laserski skener (engl. *terrestric laser scanner*)
- **UAV** – bespilotna letjelica (engl. *unmanned aerial vehiacle*)
- **WV** – Worldview
- **GSD** – prostorna veličina slikovnog elementa (pixela) na Zemlji (engl. *ground sampling distance*)
- **AHP** – analitički hijerarhijski proces (engl. *analytical hyerarchy process*)
- **GHR** – stopa pomaka čela jaruge (engl. *gully headcut retreat*)
- **LKS** – lokalni koordinatni sustav (engl. *local coordinate system*)

Životopis

Fran Domazetović rođen je 28. rujna 1992. godine u Osijeku, Hrvatska. Završio je Osnovnu školu Antuna Mihanovića u Osijeku te III. (matematičku) gimnaziju u Osijeku. Za vrijeme osnovnoškolskog i srednjoškolskog obrazovanja aktivno se bavi veslanjem u osječkom klubu VK Iktus s kojim je osvojio nekoliko državnih i međunarodnih odličja.

Na Sveučilištu u Zadru akademske godine 2011./2012. god. upisao je *Jednopredmetni studij primijenjene geografije*, kojeg je završio 2018. godine. Tijekom prediplomskog studija odlazi na Erasmus+ studentski boravak na Karl-Franzens-Universität u Grazu (Austrija). U sklopu diplomskog studija odlazi na Erasmus+ stručnu praksu u Berlin (Njemačka), gdje radi kao GIS analitičar na *Julius Kühn Institutu*. Od lipnja do studenog 2018. godine u sklopu stručnog osposobljavanja radi u *Centru za istraživanje krša i priobalja* pri Sveučilištu u Zadru. Od studenog 2018. godine radi na *Odjelu za geografiju, Sveučilišta u Zadru* u sklopu projekta Hrvatske zaklade za znanost (**Laboratorij za geoprostorne analize (UIP-2017-05-2694)**), gdje se pod mentorstvom doc. dr. sc. Ante Šiljega bavi primjenom naprednih geoprostornih tehnologija u različitim istraživanjima. Kao zaposlenik Laboratorija za geoprostorne analize završio je različita usavršavanja za rukovanje naprednim geoprostornim tehnologijama (UAV, TLS, 3D skener, itd.) te sudjeluje na brojnim znanstveno-stručnim projektima **(Interreg Italy-Croatia Protecting the Enclosed Parts of the Sea in Adriatic from Pollution (PEPSEA); Interreg Italy-Croatia Strategic development of flood management (STREAM); Competition in a Post-conflict Landscape (National Science Foundation (NSF)).**

U akademskoj godini 2018./2019. upisao je postiplomski studij *Jadran poveznica među kontinentima.* Dobitnik je stipendije DigitalGlobe Fondacije (Maxar Technologies), koja je za potrebe izrade disertacije o eroziji tla besplatno ustupila komercijalne satelitske Wolrdview snimke vrlo-visoke rezolucije. U sklopu postdiplomskog studija boravio je Erasmus+ mobilnosti za zaposlenike na Odjelu za geografiju, Harokopio Sveučilišta u Ateni.

Dobitnik je ***Nagrade Rektorice Sveučilišta u Zadru u znak priznanja za izvrsne rezultate postignute u akademskoj godini 2015./2016.*** te ***Nagrade Rektorice Sveučilišta u Zadru u znak priznanja za sudjelovanje na projektu Popularizacije znanosti i korištenja geografskih informacijskih sustava (GIS–a) u školama***. Dobitnik je nagrada *Federik Grisogono* za izvanredan uspjeh na 2. godini preddiplomskog te na 1. godini diplomskog studija geografije. Za vrijeme studija bio je demonstrator na četiri kolegija: *GIScience, Modeliranje prostornih podataka u GIS–u, Prostorne analize u GIS–u* i *Geografija prirodnih prijetnji*. Sudjelovao je s izlaganjem na **15 znanstvenih i 3 stručne konferencije**. Objavio je **8 izvornih znanstvenih radova i 6 poglavlja u knjigama i radova u zbornicima radova**.

Osim akademskih aktivnosti 2012. godine počeo se baviti speleologijom u Speleološkom odsjeku Liburnija (SOL) iz Zadra, nakon čega sudjeluje u istraživanju nekih od najvećih speleoloških objekata Hrvatske (ekspedicije: Velebita 2012; Lukina jama 2013; Slovačka jama 2016.) te inozemstva (ekspedicija Frauenmauerhöhle 2012., Hochschwab, Austrija). Od 2013. godine je član Hrvatske gorske službe spašavanja (HGSS).

Popis radova

1. **Šiljeg, A., Domazetović, F., Marić, I., Lončar, N., i Panđa, L. (2021).** New Method for Automated Quantification of Vertical Spatio-Temporal Changes within Gully Cross-Sections Based on Very-High-Resolution Models. Remote Sensing, 13(2), 321.

2. **Šiljeg, A., Marić, I., Cukrov, N., Domazetović, F., i Roland, V. (2020).** A Multiscale Framework for Sustainable Management of Tufa-Forming Watercourses: A Case Study of National Park "Krka", Croatia. Water, 12(11), 3096.

3. **Marić, I., Šiljeg, A., Cukrov, N., Roland, V., Domazetović, F. (2020).** How fast does tufa grow? Very high-resolution measurement of the tufa growth rate on artificial substrates by the development of a contactless image-based modelling device. Earth Surface Processes and Landforms.

4. **Domazetović, F., Šiljeg, A., Lončar, N., Marić, I. (2019).** GIS automated multicriteria analysis (GAMA) method for susceptibility modelling. MethodsX, 6, 2553-2561.

5. **Domazetović, F., Šiljeg, A., Lončar, N., Marić, I. (2019).** Development of automated multicriteria GIS analysis of gully erosion susceptibility. Applied Geography, 112, 102083.

6. **Marić, I., Šiljeg, A., Domazetović, F. (2019).** Geoprostorne tehnologije u 3D dokumentaciji i promociji kulturne baštine – primjer utvrde Fortica na otoku Pagu. Geodetski glasnik, 50, str. 19-44.

7. **Domazetović, F., Lončar, N., Šiljeg, A. (2017).** Kvantitativna analiza utjecaja porasta razine Jadranskog mora na hrvatsku obalu: GIS pristup, NAŠE MORE: znanstveno-stručni časopis za more i pomorstvo, 64 (2 Supplement), 33-43.

8. **Šiljeg, S., Domazetović, F., Pejdo, A. (2016).** Značajke tehničke opremljenosti grada Zadra. Geoadria, 21(2), 237-254.

Poglavlja u knjigama i radovi u zbornicima radova

1. **Domazetović, F., Šiljeg, A., Marić, I., Jurišić, M. (2020).** Assessing the Vertical Accuracy of Worldview-3 Stereo-extracted Digital Surface Model over Olive Groves. GISTAM 2020 Conference Proceedings.

2. **Marić, I., Šiljeg, A., Cukrov, N., i Domazetović, F. (2020).** Quantifying Tufa Growth Rates (TGRs) using Structure-from-Motion (SfM) Photogrammetry. GISTAM 2020 Conference Proceedings.

3. **Marić, I., Šiljeg, A., Domazetović, F., i Cukrov, N. (2020).** A framework for using handheld 3D surface scanners in quantifying the volumetric tufa growth. In Massimiliano Alvioli, Ivan Marchesini, Laura Melelli i Peter Guth, eds., Proceedings of the Geomorphometry 2020 Conference, str. 220. - 223.

4. **Domazetović, F., Šiljeg, A., Marić, I. (2020).** Guidelines for optimization of terrestrial laser scanning surveys over gully erosion affected areas. In Massimiliano Alvioli, Ivan Marchesini, Laura Melelli i Peter Guth, eds., Proceedings of the Geomorphometry 2020 Conference, str. 220. - 223.

5. **Lončar, N., Domazetović, F. (2018).** Paleogeografske značajke i suvremena geografska obilježja općine Pakoštane, u: Arheologija jadranske plovidbe i brodogradnje: Projekt Pakoštane, ur. I. Radić Rossi, G. Boetto, S. Marlier, AdriaS projekt.

6. **Čuka, A., Komšo, G., Perić, Z., Domazetović, F., Ivić, I. (2017).** Stav studentske populacije naspram emigraciji: primjer slučaja studenata sveučilišta u Zadru, u: Hrvatska izvan domovine - zbornik radova s II. Hrvatskog iseljeničkog kongresa, ur. M. Sopta, V. Lemić, M. Korade, I. Rogić, M. Perić Kaselj, Centar za istraživanje hrvatskog iseljeništva, Zagreb, 423-433.