

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni jednopredmetni studij primijenjene geografije

Fran Domazetović

**Kvantitativna analiza jaruga na prostoru otoka Paga
korištenjem modela visoke rezolucije**

Diplomski rad



Zadar, 2018.

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni studij primijenjene geografije

**Kvantitativna analiza jaruga na prostoru otoka Paga
korištenjem modela visoke rezolucije**

Diplomski rad

Student:

Fran Domazetović

Mentorica:

Doc. dr. sc. Nina Lončar

Komentor:

Doc. dr. sc. Ante Šiljeg

Zadar, 2018.



Izjava o akademskoj čestitosti

Ja, **Fran Domazetović**, ovime izjavljujem da je moj **diplomski** rad pod naslovom **Kvantitativna analiza jaruga na prostoru otoka Paga korištenjem modela visoke rezolucije** 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, 14.03.2018.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zadru

Odjel za geografiju

Diplomski rad

KVANTITATIVNA ANALIZA JARUGA NA PROSTORU OTOKA PAGA KORIŠTENJEM MODELA VISOKE REZOLUCIJE

Fran Domazetović

Sažetak

Jaruženje je jedan od najrasprostranjenijih denudacijskih procesa u priobalnim dijelovima Sredozemlja. Razumijevanje intenziteta jaruženja važno je za rekonstrukciju promjena krajolika u prošlosti, ali i za predviđanje njegovog budućeg razvoja. Jaruge su na razini Hrvatske vrlo slabo proučavane. U ovom diplomskom radu predložen je koncept praćenja intenziteta jaruženja zasnovanog na korištenju digitalnih modela površina (DMP), izvedenih iz snimaka prikupljenih UAV fotogrametrijom. Da bi se odredilo odgovarajuće područje za praćenje intenziteta jaruženja provedena je višekriterijska GIS analiza (GIS MCDA), utemeljena na različitim kriterijima (značajke terena, vegetacijski i pedološki pokrov, itd.). Na temelju GIS MCDA izvršena je raščlamba prostora otoka Paga s obzirom na podložnost terena jaruženju. Točnost izvedenih zona visoke podložnosti jaruženju potvrđena je na temelju postojećih jaruga, kartiranih kroz primjenu objektno-orijentirane analize (OBIA). Na temelju izdvojenih područja visoke podložnosti jaruženju i obavljenih terenskih izviđanja za detaljniju analizu odabrana je jaruga Santiš. Jaruga Santiš oblikovana je u naslagama smeđeg tla te su unutar nje zapaženi tragovi intenzivnog jaruženja. Praćenje intenziteta jaruženja i nastalih prostorno-vremenskih promjena unutar jaruge Santiš izvršeno je kroz usporedbu periodičkih DMP-ova visoke rezolucije. Da bi se promjene mogle kvantitativno opisati razvijen je egzaktni alat (GULIVER), namijenjen mjerenju vertikalnog pomaka unutar poprečnih presjeka jaruge. Predloženim konceptom uspješno je utvrđen i kvantificiran intenzitet jaruženja unutar šestomjesečnog razdoblja.

Ključne riječi: jaruženje; GIS MCDA; OBIA; modeli visoke rezolucije; UAV fotogrametrija; otok Pag

Voditelji: doc. dr. sc. Nina Lončar; doc. dr. sc. Ante Šiljeg (komentor)

Povjerenstvo: prof. dr. sc. Josip Faričić, doc. dr. sc. Nina Lončar; doc. dr. sc. Ante Blaće

BASIC DOCUMENTATION CARD

University of Zadar

Department of Geography

Graduation thesis

QUANTITATIVE ANALYSIS OF GULLIES OF PAG ISLAND THROUGH THE USE OF HIGH-RESOLUTION MODELS

Fran Domazetović

Abstract

Gully erosion is one of the most prominent denudation processes at coastal parts of the Mediterranean. Understanding of gully erosion rates is important for reconstruction of past landscape changes and prediction of its further development. Studies considering gully erosion in Croatia are scarce. In this graduation thesis concept of using repeat UAV photogrammetry derived high-resolution digital surface models (DSM) for monitoring of gully erosion rates is presented. In order to determine most suitable area for detailed high accuracy monitoring of gully erosion GIS-MCDA was performed, that was based on different criteria (terrain attributes, lithologic cover, vegetation cover, etc.). GIS MCDA divided Pag Island into different zones, in regard to the gully erosion susceptibility. Extracted high gully erosion susceptibility zones were verified by the reference gullies that were mapped through the object-based image analysis (OBIA) approach. Based on extracted high gully erosion susceptibility areas and conducted field research gully Santiš was found. Gully Santiš, formed in deep soil sediments and with recorded intensive erosion was selected for in detailed survey. The monitoring of the gully erosion intensity and the resulting spatial-temporal changes within gully Santiš was performed by comparing the high resolution periodic DMPs. In order to be able to quantitatively describe the changes, an exact tool (GULIVER) is developed, designed to measure the vertical shift within the cross section of the gully. The proposed concept has successfully determined the gully erosion intensity within the six months study period.

Keywords: gully erosion; GIS MCDA; OBIA; high-resolution models; UAV photogrammetry; Pag Island

Supervisors: Nina Lončar, PhD Assist. Prof; Ante Šiljeg, PhD Assist. Prof

Reviewers: Josip Faričić, PhD, Full. Prof; Nina Lončar, PhD, Assist. Prof; Ante Blaće, PhD, Assist. Prof

Sadržaj

Predgovor	9
1. Uvod	10
2. Objekt i ciljevi istraživanja	12
Hipoteze provedenog istraživanja	13
3. Pregled dosadašnjih istraživanja	14
4. Teorijska osnova diplomskog rada	17
4.1. Pregled korištene terminologije	18
4.2. Određivanje pojma jaruga	19
4.3. Terminologija morfoloških oblika povezanih s jarugama	21
4.4. Terminologija procesa povezanih s jarugama	22
5. Područje istraživanja	24
6. Metodologija istraživanja	29
6.1. Analiza postojeće literature	29
6.2. Terensko prikupljanje podataka	29
6.2.1. Izrada plana prikupljanja podataka za jarugu Santiš	29
6.2.3. Prikupljanje podataka uz pomoć bespilotne letjelice (UAV)	32
6.2.3.1. Aerofotogrametrijsko snimanje šireg prostora jaruge Santiš	32
6.2.3.2. Aerofotogrametrijsko snimanje užeg područja jaruge Santiš	33
6.2.4. Postavljanje meteoroloških mjernih uređaja	37
6.3. Modeliranje u GIS-u	40
6.3.1. Izrada DMR-a otoka Paga	40

6.3.2. Modeliranje aerofotogrametrijskih podataka.....	40
6.4. Analitičke operacije u GIS-u	44
6.4.1. Izdvajanje i inventarizacija jaruga otoka Paga	44
6.4.2. Višekriterijska analiza podložnosti terena jaruženju	53
6.4.3. Određivanje prostornog obuhvata jaruge Santiš i izdvajanje linije čela jaruge	64
6.4.4. Razvoj kvantitativnih pokazatelja za praćenje intenziteta jaruženja	66
6.5. Vizualizacija provedenih GIS analiza i obrađenih meteoroloških podataka ..	69
7. Kartiranje jaruga otoka Paga primjenom OBIA pristupa.....	70
7.1. Parametri korišteni za izdvajanje jaruga.....	71
7.2. Uklanjanje "lažnih" jaruga kandidata	73
7.3. Procjena kvalitete kartiranja jaruga OBIA pristupom	74
7.4. Značajke jaruga izdvojenih OBIA pristupom.....	79
8. Višekriterijska GIS analiza podložnosti terena jaruženju	82
8.1. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju	83
8.2. Procjena kvalitete izrađenih modela podložnosti terena jaruženju	96
8.3. Zonacija podložnosti terena jaruženju	103
9. Kvantitativna analiza intenziteta jaruženja – primjer jaruge Santiš.....	106
9.1. Detekcija prostorno-vremenskih promjena nastalih na prostoru jaruge Santiš	106
9.2. Praćenje vertikalnog pomaka unutar jaruge (<i>gully cross-sections</i>)	111
9.2.1. Princip praćenja stope vertikalnog pomaka unutar jaruge.....	112
9.2.2. Razvoj alata za automatizirano praćenje vertikalnog pomaka u GCs	113

9.2.3. Rezultati primjene GULIVER alata na primjeru jaruge Santiš	119
9.2.4. Procjena preciznosti i uspješnosti izrađenog alata	122
10. Utjecaj oborina na intenzitet jaruženja	124
11. Zaključak	129
Literatura	132
Izvori	141
Popis grafičkih priloga	142
Popis tabličnih prikaza	145
Prilog 1 - Python skripta napravljenog alata GULIVER	146

Predgovor

Geografija 21. stoljeća doživljava rapidne promjene, kakve nisu zabilježene još od vremena Velikih geografskih otkrića! Promjene se posebice pokazuju u znanstvenim disciplinama iz područja fizičke geografije, unutar kojih zahvaljujući tehnološkom razvoju naglasak prelazi s dosadašnjih konvencionalnih, deskriptivnih istraživačkih metoda na napredne kvantitativno utemeljene metode. Razvoj različitih modernih metoda prikupljanja podataka omogućava izradu modela kvalitete kakva je do samo prije par godina bila nezamisliva. Zahvaljujući primjeni suvremenih tehnologija, poput bespilotnih letjelica i laserskih skenera ostvarena je vizualna atraktivnost izrađenih modela, kojom se pomiču granice između modeliranja i stvarnosti. Međutim, kako to u znanosti često biva ostvareni napredak za sobom povlači mnogobrojna nova istraživačka pitanja, na koja tek treba odgovoriti. Odgovornost nas, geografa, jest da kroz svoja istraživanja nastavimo pratiti i primjenjivati tehnološke novitete, kako bi svojim zajedničkim trudom pridonijeli boljem razumijevanju kompleksnog svijeta koji nas okružuje.

Ovim putem zahvaljujem mentorici i dugogodišnjoj prijateljici doc. dr. sc. Nini Lončar, koja me svojim brojnim naputcima i požrtvovnim trudom usmjeravala za vrijeme definiranja i pisanja ovog diplomskog rada. Naročite zahvale komentoru doc. dr. sc. Anti Šiljegu na svom prenesenom znanju, bez kojega izrada ovog diplomskog rada ne bi bila moguća, ali i na svojoj pruženoj pomoći i savjetima. Veliko hvala na svojoj pomoći, te brojnim savjetima i zajedničkim raspravama prijatelju, asistentu Ivanu Mariću, mag. geogr. Hvala dr. sc. Juri Šućuru na pomoći oko prikupljanja podataka totalnom stanicom. Zahvale JU "Natura Jadera" na osiguranoj financijskoj pomoći potrebnoj za provođenje terenskih istraživanja.

Ein besonderer Dank geht an die Kollegen vom Julius Kühn Institut für Hilfe und Gastfreundschaft während meines viermonatigen Aufenthalts in Berlin. An erster Stelle, vielen Dank an den Co-Leiter des Instituts, dipl.ing M.Sc. Burkhard Golla und M.Sc. Ralf Neukampf, sowie an die anderen Kollegen und Freunden vom Institut. Besonderer Dank geht an Dr. Markus Möller, der mich in die objektorientierte Analyse eingeführt hat.

Hvala članovima povjerenstva za ocjenu i obranu ovog diplomskog rada: prof. dr. sc. Josipu Faričiću te doc. dr. sc. Anti Blaći na konstruktivnim kritikama i komentarima.

Posebne zahvale obitelji, bratu Dinku, sestri Ladi i djevojci Kristini, bez čije bih potpore, a naročito brojnih pošalica, teško završio ovaj diplomski rad. Također, hvala ostalim članovima obitelji, pogotovo teti Zrinki, Mirni i baki Mariji.

Naposljetku, najveće hvala mojim roditeljima Hrvoju i Barbari, njihova ljubav i potpora bili su mi nadahnuće za pisanje ovog diplomskog rada.

1. Uvod

Jaruženje je jedan od najrasprostranjenijih denudacijskih procesa na prostoru Sredozemlja, čiji je utjecaj na oblikovanje krajolika značajan (Poesen i dr., 2003; Poesen i dr., 2006; Valentin i dr., 2005; Bouchnak i dr., 2009; Marzolff i Poesen, 2009; Vanmaercke i dr., 2016.). Brojni primjeri s prostora Sredozemlja (Vandekerckhove i dr., 2000; Wijdenes i dr., 2000; Vandekerckhove i dr., 2001; Lesschen i dr., 2007; De Baets i dr., 2009; Marzolff i dr., 2011; Ben Slimane i dr., 2016; Erktan i dr., 2016.) i ostatka svijeta (Moges i Holden, 2008; Herzig i dr., 2011; Katz i dr., 2014; Vanmaercke i dr., 2016.) ukazuju kako jaruženje u znatnoj mjeri utječe na degradaciju tla i oslobađanje značajnih količina sedimenta. Prostorno-vremenska evolucija aktivnih jaruga ovisi o kompleksnom zajedničkom djelovanju raznovrsnih predisponirajućih čimbenika, kao što su litološki pokrov, zemljišni pokrov, razvijenost vegetacijskog pokrova, reljefne i klimatske značajke određenog prostora te raznovrsni oblici antropogenih utjecaja, koji uvjetuju intenzitet i prostorni obuhvat procesa jaruženja (Valentin i dr., 2005; Gómez Gutiérrez i dr., 2009; Kirkby i Bracken, 2009). Nepravilni godišnji režim oborina i surovi klimatski uvjeti onemogućavaju značajniji razvoj vegetacijskog pokrova, zbog čega intenzivne oborine uzrokuju pojavu snažnog površinskog otjecanja, dok antropogeni utjecaji poput prekomjerne ispaše dodatno potenciraju izloženost terena djelovanju jaruženja (Marzolff i Poesen, 2009.) Proučavanje intenziteta jaruženja ključno je za otkrivanje i razumijevanje prostorno-vremenskih promjena, prema kojima je moguće napraviti rekonstrukciju evolucije prostora jaruge u prošlosti, ali i napraviti procjene promjena u budućnosti (Whitford i dr., 2010.). Stoga ne čudi da su na globalnoj razini jaruge bile i ostale predmet brojnih znanstvenih istraživanja, koja su najčešće nastojala pronaći optimalne metode i pristupe namijenjene longitudinalnom praćenju intenziteta jaruženja, te predviđanju i ograničavanju njegovih negativnih posljedica (Castillo i Gómez, 2016; Vanmaercke i dr., 2016.).

Istraživanja provedena u sklopu ovog diplomskog rada provedena su na prostoru otoka Paga, koji se među jadranskim otocima ističe po svojoj ogoljenosti i rasprostranjenosti raznovrsnih denudacijskih procesa (Lončar, 2009; Magaš, 2013.). Slabo razvijeni vegetacijski pokrov i prisutnost nekoliko stotina aktivnih jaruga čine otok Pag pogodnim mjestom za sustavno proučavanje jaruga i procesa jaruženja. Unatoč njihovoj znatnoj rasprostranjenosti i nesumnjivom utjecaju na degradaciju tla, jaruge su na razini Hrvatske još uvijek vrlo slabo proučavane (Lončar, 2009; Faivre, 2011; Castillo i Gómez, 2016.), zbog čega postoji izražena potreba za njihovim sustavnijim i detaljnijim proučavanjem.

Osnova ovog diplomskog rada je procjena intenziteta jaruženja, koja je provedena kroz longitudinalno praćenje prostorno-vremenskih promjena na odabranoj jaruzi, unutar istraživanog perioda od šest mjeseci. Pri tome je procjena intenziteta jaruženja provedena na temelju usporedbe periodičnih digitalnih modela površina (DMP), izrađenih iz visinskih podataka prikupljenih na istraživanom području. Iako su se do nedavno u istraživanjima intenziteta jaruženja koristile različite konvencionalne terenske metode, prethodnih godina pojavljuje se niz raznovrsnih tehnologija i metoda prikupljanja podataka iz područja daljinskih istraživanja, koje se prema egzaktnosti mjerenja te vremenskoj i financijskoj učinkovitosti ističu pred klasičnim, konvencionalnim metodama za proučavanje intenziteta i značajki jaruženja (Evans i dr., 2012; Castillo i dr., 2012; Pike i dr., 2012; Gómez-Gutiérrez i dr., 2014; Stöcker i dr., 2015.). Porastom dostupnosti i kvalitete DMR-a visoke rezolucije stvoreni su preduvjeti za provedbu detaljnih morfometrijskih istraživanja, zasnovanih na detektiranju i kvantitativnom opisivanju prostorno-vremenskog razvoja određenog morfološkog oblika, na sub-decimetarskoj razini (d'Oleire-Oltmanns i dr., 2012; Stöcker i dr., 2015.).

2. Objekt i ciljevi istraživanja

Objekt istraživanja ovog diplomskog rada su jaruge na prostoru otoka Paga, pri čemu je poseban naglasak dan proučavanju i kvantitativnom opisivanju procesa jaruženja, kao jednog od ključnih čimbenika za oblikovanje površinskog krškog reljefa otoka. Proučavanje i kvantitativno opisivanje utjecaja jaruženja na evoluciju reljefa otoka Paga važno je za razumijevanje trenutnog stanja, ali isto tako je vrlo bitno za rekonstrukciju i razumijevanje izgleda nekadašnjeg reljefa i krajolika otoka, te predviđanje njegovih promjena i evolucije u budućnosti. Jaruge otoka Paga su zbog svoje raznovrsnosti i kompleksnosti u ovom radu proučavane na dvije razine (mezo i mikro razina), s različitim prostornim obuhvatom i detaljnosti istraživanja. Pri tome mezo razina istraživanja obuhvaća prostor cijelog otoka Paga (284 km²) u kojemu su proučavane značajke svih značajnijih, većih jaruga na otoku Pagu (120 jaruga), dok se mikro razina odnosi na znatno detaljnije proučavanje intenziteta jaruženja unutar jedne, odabrane jaruge.

Osnovni cilj mezo razine ovog istraživanja je sistematizacija i inventarizacija postojećih jaruga na otoku Pagu kroz koju se nastoji pružiti uvid u trenutnu prostornu rasprostranjenost postojećih jaruga na otoku. Kroz ostvarenje ovog cilja testirat će se mogućnosti kartiranja jaruga objektno-orijentiranim pristupom analiziranju snimaka (u nastavku OBIA), modernom metodom za brzo i učinkovito kartiranje jaruga te kompiliranje informacija o njihovom prostornom razmještaju. Poimanje prostornog razmještaja jaruga na otoku Pagu nužno je za razumijevanje djelovanja procesa jaruženja, ali i za predviđanje jaruženjem potencijalno ugroženih područja na otoku Pagu. Predviđanje i izdvajanje jaruženjem ugroženih područja jedan je od glavnih istraživačkih problema vezanih za proučavanja jaruga, jer je ono nužno za sprječavanje budućih negativnih učinaka jaruženja, u prvom redu smanjenje neželjenog odnošenja materijala na padinama i sprječavanje daljnje degradacije površinskog reljefa. Stoga je drugi cilj ovog diplomskog rada odrediti podložnost terena na otoku Pagu procesu jaruženja, pri čemu će prostor otoka biti podijeljen u različite zone podložnosti procesu jaruženja (vrlo niska podložnost, niska podložnost, srednja podložnost, visoka podložnost i vrlo visoka podložnost). Na ovaj način će se na temelju izdvojenih zona visoke podložnosti moći odrediti ukupna ugrožena površina na otoku, kao i ugroženost agrarno i stočarski vrednovanih površina, te će se na temelju izdvojenih zona moći sustavnije planirati mjere zaštite ugroženih dijelova otoka.

Na mikro razini istraživanja osnovni cilj rada je odrediti intenzitet jaruženja unutar odabrane jaruge u određenom vremenskom intervalu. Intenzitet jaruženja pratiti će se cikličkim

snimanjima, provedenim u vremenskom razdoblju od šest mjeseci, na temelju kojih će se opisati zabilježene morfometrijske promjene unutar jaruge (promjene volumena jaruge, trošenje materijala/akumulacija materijala, itd.). Pri tome će se kvantifikacija uočenih promjena izvesti kroz primjenu egzaktnih kvantitativnih pokazatelja, razvijenih u sklopu ovog diplomskog rada. Zabilježeni intenzitet jaruženja i morfometrijske promjene u jaruzi biti će dovedene u korelaciju s meteorološkim podacima o količini i intenzitetu oborina prikupljenim in situ. Korelacijom meteoroloških podataka nastojati će se utvrditi utjecaj ekstremnih meteoroloških događaja na pojavu i intenzitet jaruženja u odabranoj jaruzi.

Hipoteze provedenog istraživanja

Postavljene hipoteze ovog diplomskog rada su:

- Moguće je primijeniti OBIA pristup za kartiranje jaruga iz rasterskih podataka srednje kvalitete.
- Zone visoke podložnosti za jaruženje izdvojene kroz GIS-MCDA podudarati će se s postojećim jarugama.
- Unutar jaruge Santiš prevladava trošenje i odnošenje materijala, što će biti potvrđeno izrađenim kvantitativnim pokazateljima
- Predloženi kvantitativni pristup (*alat GULIVER*) omogućava detaljnije opisivanje značajki poprečnih presjeka od konvencionalnih terenskih metoda
- Intenzitet jaruženja u jaruzi Santiš izravno je povezan s količinom i intenzitetom oborina

3. Pregled dosadašnjih istraživanja

Proučavanje nastanka i intenziteta oblikovanja jaruga često je objekt temeljnih geomorfoloških istraživanja, kroz koja se nastoji utvrditi utjecaj jaruženja na preoblikovanje padinskog reljefa, ali i pojavu brojnih problema vezanih za negativni utjecaj denudacijskog djelovanja na postupnu degradaciju tla. Stoga ne čudi da je posebice proučavan negativni utjecaj jaruženja na agrarno i stočarski vrednovanim prostorima, na kojima su antropogeni interesi izravno ugroženi djelovanjem jaruženja. Najranija proučavanja jaruga bila su usmjerena na teorijsko tumačenje uzroka i posljedica ovog procesa, pri čemu se naglasak stavljao na deskriptivno opisivanje i matematičko kvantificiranje određenih segmenata procesa jaruženja (npr. izračun protoka u jaruzi, intenziteta odnošenja materijala, itd.). Početkom 21. stoljeća dolazi do razvoja i primjene različitih kvantitativnih GIS metoda u praćenju jaruženja, čime su mogućnosti egzaktnog proučavanja jaruga znatno unaprijeđene. Do danas je objavljen velik broj istraživanja koja se bave proučavanjem problematike jaruga iz različitih aspekata (Poesen i dr., 2003; Vanmaercke i dr., 2016.). Ipak, na nacionalnoj razini jaruge i jaruženje su vrlo slabo istraživani te se može utvrditi kako ne postoji dovoljna razina svijesti o važnosti procesa jaruženja za oblikovanje reljefa i degradaciju tla. S obzirom na sveobuhvatnost istraživanja koja se bave problematikom jaruga i jaruženja izdvajanje najvažnijih prethodnih istraživanja nije nimalo lak zadatak. Zbog toga je u nastavku dan pregled samo onih istraživanja koja su se pokazala ključnima za izradu ovog diplomskog rada, dok bi pregled svih radova koji su pridonijeli ovom istraživanju bio znatno duži.

Casalí i dr. (2015.) se bave problematikom nesigurnosti i nedefiniranosti točne determinacije prostornog obuhvata pojedinih jaruga. Znanstveno utemeljeno definiranje prostornog obuhvata morfoloških oblika, pa tako i jaruga ključno je za točno kvantitativno opisivanje značajki proučavanih oblika. S obzirom na to da pogrešno definiranje prostornog obuhvata može utjecati na pogrešan izračun kvantitativnih pokazatelja (npr. površine i volumena) proučavanih jaruga autori u ovom radu daju smjernice za metodološki ujednačeno definiranje prostornog obuhvata pojedine jaruge.

Castillo i dr. (2012.), u svom radu daju detaljan pregled i usporedbu točnosti nekoliko različitih metoda za mjerenje i praćenje intenziteta jaruženja. Provedena je usporedba točnosti najčešće primjenjivanih 2D konvencionalnih terenskih metoda s točnosti modernih digitalnih 3D metoda iz područja daljinskih istraživanja. Za referentni model uzeti su podaci prikupljeni terestričkim laserskim skenerom (TLS), u odnosu na koje je izračunato odstupanje u točnosti pojedinih analiziranih metoda. Rezultati provedenog istraživanja ukazali su na izraženu prevagu

modernih 3D tehnika, koje su u pravilu generirale znatno manje pogreške u određivanju površinskih i volumetrijskih značajki proučavanih jaruga, od primijenjenih konvencionalnih metoda.

Conoscenti i dr. (2013.) su kroz primjenu višekriterijske analize i statističkih metoda istražili utjecaj različitih čimbenika na podložnost određene površine jaruženju. Pri tome su proučili utjecaj 12 zasebnih varijabli na pojavnost jaruženja unutar sliva rijeke Magazzolo na Siciliji. U konačnici su na temelju analiziranih varijabli izradili model pogodnosti za pojavu jaruženju unutar odabranog sliva, prema kojemu je prostor bio klasificiran sukladno vjerojatnosti za pojavu jaruženja.

Cook (2017.) u svom radu ispituje primjenjivost aerofotogrametrije zasnovane na upotrebi jeftinih bespilotnih letjelica i *structure-from-motion* algoritama za rekonstrukciju složene topografije i detekciju preoblikovanja reljefa. Za potrebe ispitivanja rezultati navedenih metoda su uspoređeni s modelima napravljenim iz podataka prikupljenim upotrebom terestričkog laserskog skenera (TLS). Ispitivanje je pokazalo kako bespilotne letjelice pružaju jeftinu, dostupnu i visoko mobilnu alternativu znatno skupljim i kompleksnijim TLS uređajima, pri čemu je kriterij kvalitetne rekonstrukcije kompleksne topografije i dalje zadovoljen.

Deng i dr. (2015.) u svom radu daju smjernice za izračun različitih kvantitativnih parametara nužnih za mjerljivo opisivanje poprečnih presjeka (GCs) proučavane jaruge. Ukupno je analizirano preko 20 različitih kvantitativnih parametara koji mogu biti izvedeni iz izmjerenih podataka o poprečnim presjecima jaruge. Smjernice dane u ovom radu iskorištene su za razvoj alata za praćenje vertikalnog pomaka, razvijenog u sklopu ovog diplomskog rada.

Feivre i dr. (2011.) na primjeru jaruge Potovošća na otoku Krku koreliraju utjecaj specifičnog oborinskog događaja sa zabilježenim posljedičnim preoblikovanjem reljefa uzrokovanim izraženim jaruženjem. U radu su proučene značajke intenziteta oborina odabranog specifičnog oborinskog događaja, kao i morfološke i hidrološke značajke drenažnog bazena proučavane jaruge koje su utjecale na formiranje kritične količine otjecanja i pojavu jaruženja.

Lončar (2009.) proučava geološka, klimatska, geomorfološka i morfometrijska obilježja srednjeg i južnog dijela otoka Paga, na temelju kojih provodi geomorfološku regionalizaciju otoka. Unutar provedenog istraživanja izrađena je sistematizacija jaruga srednjeg i južnog dijela otoka, kojom je na istraživanom prostoru ukupno izdvojeno 337 jaruga. Izdvojenim jarugama su opisana osnovna morfometrijska obilježja (dužina, širina) te je napravljena kategorizacija pogodnosti zemljišta s aspekta gradnje.


Shruthi i dr. (2014.) ispituju mogućnosti primjene metoda iz djelokruga objektno-orijentiranih analiza (OBIA) za kartiranje jaruga iz rasterskih podataka srednje kvalitete. Testiranjem primjenjivosti segmentacijskih i klasifikacijskih algoritama za otkrivanje i izdvajanje jaruga autori su pokazali kako jaruge mogu biti uspješno kartirane iz rasterskih podataka srednje kvalitete, posebice ako se radi o kartiranju većih površina.

Valentin i dr. (2005.) pružaju opsežan pregled raznovrsnih čimbenika koji utječu na pojavnost i razvoj jaruga na određenom prostoru, kao i detaljno objašnjenje načina manifestiranja i funkcioniranja različitih sastavnica procesa jaruženja. U drugom dijelu rada autori objašnjavaju najčešće metode prevencije i stabilizacije procesa jaruženja.

Vanmaercke i dr. (2016.) prilažu vjerojatno najsustavniji pregled i usporedbu rezultata na globalnoj razini objavljenih radova vezanih za praćenje intenziteta jaruženja u različitim dijelovima svijeta. U ovom radu autori su okupili rezultate objavljene u preko 70 različitih radova, koji su se bavili praćenjem intenziteta uzmaca čela jaruge (GHR) na ukupno 933 proučavane jaruge. Unatoč znatnoj varijabilnosti prikupljenih podataka, autori su uspjeli sistematizirati linijske, površinske i volumetrijske stope GHR te ih dovesti u korelaciju s različitim čimbenicima koji utječu na intenzitet jaruženja. Zbog toga ovaj rad pruža odličnu osnovu za bolju interpretaciju i korelaciju intenziteta jaruženja zabilježenog na primjeru jaruge Santiš, s rezultatima drugih sličnih istraživanja.

4. Teorijska osnova diplomskog rada

Istraživanje provedeno u sklopu ovog diplomskog rada se može odrediti kao specifično geomorfometrijsko istraživanje usmjereno na proučavanje obilježja odabranih morfoloških oblika - jaruga. Geomorfometrija je interdisciplinarno znanstveno područje, koje okuplja metode i znanja iz geomorfologije, matematike i računalnih znanosti, koje primjenjuje kroz kvantitativnu analizu reljefnih oblika, temeljenu na izdvajanju raznovrsnih morfometrijskih parametara iz digitalnog modela reljefa (DMR-a) (Pike i dr., 2009.). Digitalni model reljefa (DMR) predstavlja prikaz reljefne površine Zemlje, unutar kojega svaki piksel sadrži pripadajuće x, y i z koordinate, zadane određenim koordinatnim sustavom (Miller i Laflamme, 1958; Šiljeg, 2013; Barada, 2017.). Osnovna klasifikacija raščlanjuje rasterske snimke prema njihovoj prostornoj rezoluciji na snimke: niske rezolucije (PR >30 m), srednje rezolucije (PR 2 - 30 m), te visoke rezolucije (PR < 2 m) (URL 1). Prema takvoj klasifikaciji DMR korišten za OBIA i GIS-MCDA spada među DMR-ove srednje rezolucije, dok se svi ostali korišteni modeli mogu smatrati modelima visoke rezolucije. Utjecaj prostorne rezolucije modela na detaljnost i kvalitetu prikaza određenih oblika te provođenje morfometrijskih istraživanja može se uočiti već i samom vizualnom usporedbom DOF-ova različite prostorne rezolucije (Sl. 1).



Slika 1. Detaljnosti prikaza prostora jaruge Santiš s ortofoto snimcima (DOF) različite prostorne rezolucije

Vrlo je važna razlika između DMR-a i digitalnog modela površina (DMP), pri čemu digitalni model površina uz prikaz površine reljefa sadrži i prikaz vršnih dijelova krajobraza, sa svim objektima koji se nalaze na površini reljefa (Barada, 2017.). S obzirom da svi modeli napravljeni iz aerofotogrametrijskih podataka u sklopu ovog diplomskog rada sadrže prikaz različitih objekata, koji se nalaze na reljefu (npr. suhozidi, vegetacijski pokrov, antropogeni materijal) ispravnije ih je smatrati digitalnim modelima površine. S druge strane napravljeni model otoka Paga sadrži isključivo prikaz površine reljefa (DGU, 2018.). Zbog toga će se u nastavku za model otoka Paga koristiti termin digitalni model reljefa (DMR), a za sve ostale modele izrađene u sklopu ovog diplomskog rada termin digitalni model površina (DMP).

Specifična geomorfometrijska istraživanja bave se proučavanjem određenih reljefnih oblika na temelju DMR-a, pri čemu se primjena geomorfometrijskog istraživanja temelji na sljedećih pet koraka: uzorkovanje površine reljefa (mjerjenje visina) (1), izrada digitalnog modela površina (DMP) iz prikupljenih visinskih uzoraka (2), ispravak artefakata i pogrešaka u izrađenom modelu (3), izdvajanje morfoloških parametara i oblika (4) te primjena i analiza izvedenih parametara i oblika (5) (Pike i dr., 2009.). Pri tome su u ovom diplomskom radu obuhvaćeni svi navedeni koraci, od konceptualizacije provedbe istraživanja, određivanja i razgraničenja jaruga, preko provođenja raznovrsnih mjerenja i razvoja kvantitativnih pokazatelja intenziteta jaruženja, pa do interpretacije prikupljenih podataka i izvođenja zaključaka.

4.1. Pregled korištene terminologije

Analiziranje kvantitativnih obilježja određenog morfološkog oblika, pa tako i jaruga, zahtjeva egzaktno definiranje terminologije, bez koje gotovo da nije moguće napraviti izdvajanje željenih morfoloških oblika i opisivanje njihovih točnih geomorfometrijskih obilježja (Goudie, 2004; Evans i dr., 2012.). Prilikom izrade ovoga diplomskog rada uočeno je kako u pogledu istraživanja jaruga postojeća znanstvena nomenklatura unutar hrvatskog jezika nije dostatno razrađena. Terminološke dvojbe počinju već s određivanjem pojma jaruga, gdje se isti pojam često definira na potpuno različite, a ponekad i oprečne načine. Problematika nerazrađenog nazivlja postaje još kompleksnija ako se u obzir žele uzeti jasne kvantitativne odrednice određenih pojmova, pri čemu je na temelju nacionalne literature i nazivlja gotovo nemoguće provesti klasifikaciju jaruga. Ipak, to možda i nije toliko iznenađujuće ako se u obzir uzme kako je na nacionalnoj razini do sada objavljeno vrlo malo istraživanja koja su se bavila isključivo problematikom jaruga (Lončar, 2009; Faivre, 2011; Castillo i Gómez, 2016.).

S druge strane, znanstvena terminologija o jarugama i procesu jaruženja je znatno sustavnije razrađena unutar znanstvene literature na engleskom jeziku, gdje se dakako i znatno veći broj autora bavi navedenom problematikom. Ipak i unutar engleskog jezika postoje određene terminološke nedoumice, pogotovo oko klasificiranja jaruga prema njihovim geometrijskim obilježjima (*npr. dužina, širina, dubina, razgranatost, itd.*) te pri opisivanju procesa koji utječu na pojavu i intenzitet jaruženja. Kako bi se otklonile navedene terminološke dvojbe te kako bi se poboljšalo i olakšalo razumijevanje u radu korištene terminologije, u nastavku je dan terminološki pregled nazivlja vezanog za jaruge i proces jaruženja, kao rezultat sinteze proučenih znanstvenih radova. Pri tome su određeni pojmovi trebali biti smisleno prevedeni s engleskog jezika, te su kao takvi isključivo rezultat autorovog subjektivnog prijevoda.

4.2. Određivanje pojma jaruga

Riječ *jaruga* potječe od turske riječi *jaryk*, označava vododerinu ili jarak oblikovan erozivnim djelovanjem vode (Klaić, 1984.) te se kao takav ovaj termin ustalio u službenoj znanstvenoj terminologiji hrvatskog jezika. Termin *jaruga* poznat je kao *gully* unutar anglosaksonskog govornog područja, *ravine* unutar frankofonskog govornog područja te *wadi* unutar arapskog govornog područja (Castillo i dr., 2016.), dok postoje još brojni drugi, manje rasprostranjeni i poznati nazivi. Postojanje različitih, pa i ponekad proturječnih tumačenja pojma jaruga prikazuje svu složenost jasnog definiranja značenja ovog termina. Složenost jasnog definiranja termina jaruga posljedica je njihove izrazite morfološke raznolikosti, ali i različitih pristupa u proučavanju i shvaćanju jaruga, zbog čega nije jednostavno odrediti jasnu i jedinstvenu sveobuhvatnu definiciju. Primjerice, Castillo i Gómez (2016.) određuju sljedeća četiri pristupa determinaciji termina jaruga: *morfološki pristup (1)*, *hidrološki pristup (2)*, *pedološki pristup (3)* te kriterij *postojanosti (4)* jaruga. Ovakvo određivanje pojma *jaruga* je u nastavku ovoga rada detaljnije razrađena te je potkrepljena primjerima iz proučene znanstvene literature.

Morfološko objašnjenje termina jaruga (1) polazi od opisivanja različitih morfoloških značajki terena jaruge (*npr. dubina, širina, dužina, itd.*) te površine njezinog slivnog područja. Pri tome se jaruga može definirati kao: *relativno duboki usjek, vrlo strmih bočnih strana i slabo razvijenog vegetacijskog pokrova, sa slivnim područjem manjim od 10 km²* (Houghes i dr, 2001; Eustace i dr., 2011.). Iz ove definicije je vidljivo kako postoji povezanost između slabo razvijenog vegetacijskog pokrova i aktivnog jaruženja.

Hidrološko objašnjenje termina jaruga značajke (2) polazi od opisivanja hidrološke funkcije i značajki jaruga. Primjerice, Morgan i Nearing (2016.) definiraju jaruge kao *povremene vodene tokove, koji su podložni sporadičnom bujičnom režimu, oblikovanim za vrijeme intenzivnijih oborina.*

Pedološko objašnjenje termina jaruga (3) definira termin jaruga sa stajališta proučavanja utjecaja razvoja i oblikovanja jaruga na matično tlo, te na ometanje i/ili onemogućavanje izvođenja poljoprivrednih radova. Sukladno tome, Soil Science Society of America (2008.) definira termin jaruga kao *kanal nastao koncentriranim erozivnim djelovanjem vode, uslijed intenzivnog i koncentriranog povremenog otjecanja, koji je dovoljno dubok (uglavnom > 0.5 m) da ometa izvođenje poljoprivrednih radova i da ne može biti jednostavno uklonjen primjenom uobičajenih poljoprivrednih zahvata.* Ovakva definicija se uglavnom primjenjuje u znanstvenoj literaturi za opisivanje jaruga nastalih na poljoprivrednim zemljištima (Casalí i dr., 2006.), iako ju pojedini autori koriste i za opisivanje jaruga formiranih van poljoprivredno vrednovanih prostora (Kirkby i Bracken, 2009; Perroy i dr., 2010; Campo-Bescós i dr., 2013.).

Definicija jaruga prema postojanosti (4) polazi od određivanja i klasifikacije jaruga s obzirom na njihove dimenzije te kontinuiranost postojanja, pri čemu se jaruge definiraju kao: *recentno oblikovana vododerina nastala na mjestu na kojemu jasno definirani kanal nije postojao* (Castillo i Gómez (2016.)). Prema kriterijima stalnosti i dimenzijama treba razlikovati: kišne brazde (*rill*), prolazne jaruge (*ephemeral gully*), te stalne jaruge (*permanent gully*).

- **Brazda (engl. rill)** – *povremeni vodeni tok, pretežito strmih bočnih strana te dubine od svega nekoliko cm, oblikovan uslijed koncentriranog erozivnog djelovanja vode, najčešće na eroziji podložnim materijalima (npr. nedavno kultivirane površine)* (Soil Science Society of America, 2008.). Najčešće se diferencira od ostalih prema kriteriju dubine kanala, pri čemu se vodeni tokovi dubine do 0.3 m mogu smatrati brazdama, dok se svi dublji oblici mogu smatrati jarugama (Castillo i Gómez, 2016.).
- **Prolazne jaruge (engl. ephemeral gully)** - *kanali malih dimenzija oblikovani koncentriranim erozivnim djelovanjem vode, koji su pretežito dubine ispod 0.5 m te koji mogu jednostavno biti uklonjeni klasičnim poljoprivrednim zahvatima* (Soil Science Society of America, 2008.). Za razliku od kišnih brazdi (*rills*) nastaju isključivo na mjestu prirodnih talvega određenih sjecištem dvije susjedne mikro-padine, zbog čega se i nakon adaptacije poljoprivrednim strojevima često ponovno pojavljuju na istim mjestima (Casalí i dr., 2015.).

- **Stalne jaruge (engl. *permanent gully/ gully*)** – za razliku od brazdi i prolaznih jaruga, stalne jaruge ne mogu biti lako uklonjene primjenom klasičnih poljoprivrednih zahvata, dok im dubina može varirati od 0,5 m pa do 25 ili 30 m, a dužina i širina od svega jednog metra, pa i do preko nekoliko stotina metara (Goudie, 2004; Soil Science Society of America, 2008.).

Definicija dana od strane Soil Science Society of America (2008.) je uzeta kao najvjerodostojnija za ovo istraživanje, jer ipak donekle utvrđuje kvantitativne odrednice (dubinu, širinu i dužinu) pojma jaruga i jer se odnosi na jaruge formirane u naslagama tla, što odgovara jarugama proučavanim u ovom radu. Istraživanjima provedenim u sklopu ovog diplomskog rada proučavane su stalne jaruge, ali ista istraživačka metodologija može se primijeniti i za proučavanje prolaznih jaruga na poljoprivrednim zemljištima.

4.3. Terminologija morfoloških oblika povezanih s jarugama

U nastavku su objašnjeni neki od najčešćih morfoloških oblika, koji su povezani s jarugama i procesom jaruženja.

- **Čelo jaruge (engl. *gully headcut*)** - prirodno formirani dijelovi kanala jaruge, na kojima dolazi do strmog, gotovo okomitog pada u nagibu kanala nazivaju se čelom jaruge (Poesen, 2002.). Nailaskom površinskog i/ili podzemnog otjecanja na nagli pad terena dolazi do snažnog erozivnog djelovanja, koje uzrokuje odnošenje materijala i postepeno uzmicanje čela jaruge uzvodno (Bull i Kirkby, 2002.). Uzmak čela jaruge (engl. *gully headcut retreat* (GHR)) smatra se primarnim procesom prostorno-vremenske evolucije jaruga, uslijed kojega dolazi do povećanja dužine jaruge (Poesen i dr., 2011; Vanmaercke i dr., 2016.).
- **Bočni zidovi jaruge (engl. *gully sidewall*)** - predstavljaju bočne strane jaruge, koje su kao i čela jaruge vrlo podložne trošenju materijala, o čijem intenzitetu ovise oblik i nagib bočnih zidova te količina oslobođenog sedimenta (Bull i Kirkby, 2002.). Specifični oblik bočnih zidova jaruge može poslužiti za određivanje prevladavajućih procesa, koji uvjetuju njihovo oblikovanje, pri čemu se mogu razlikovati sljedeća četiri osnovna tipa padina: *kose, vertikalne, stepenaste* te *kombinirane* (Crouch, 1987.). Nakon uzmarka čela jaruge, pomak bočnih zidova jaruge predstavlja drugi najvažniji proces prostorno-vremenske evolucije jaruga, koji utječe na postupno proširivanje jaruga (Bull i Kirkby, 2002; Poesen i dr., 2002.).

- **Završni dio jaruge (engl. *gully fan*)** - završni dio jaruge označava krajnji dio jaruge, u kojemu dolazi do slojevite sedimentacije aluvija transportiranog iz jaruge, do čijeg taloženja dolazi uslijed opadanja erozijske i transportne energije otjecanja vezanog za jarugu (Soil Science Society of America, 2008.). Završni dijelovi jaruge su pretežito vezani za erozijsku bazu, bilo da se radi o spoju jaruge s nekim vodenim tokom, jezerom ili morem, ili da se radi o mjestu gdje prestaju čimbenici odgovorni za pojavu jaruženja. Na prostoru otoka Paga završni dio većine razvijenijih priobalnih jaruga vezan je za kontaktnu zonu između jaruga i Jadranskog mora, dok tek manji dio jaruga u unutrašnjosti otoka završava na mjestu prestanka predisponirajućih čimbenika.

4.4. Terminologija procesa povezanih s jarugama


Denudacijski proces odgovoran za genezu i formiranje jaruga naziva se **jaruženje** (*gully erosion*), a odnosi se na usmjereno erozijsko trošenje uzrokovano kratkotrajnim i intenzivnim usmjerenim otjecanjem vode, koje uzrokuje odnošenje tla do znatnih dubina (Soil Science Society of America, 2008.). Nakon početnog oblikovanja, kanali jaruge se proširuju sve dok su zadovoljeni predisponirajući čimbenici koji utječu na aktivaciju i intenzitet jaruženja. Pri tome procesi koji u različitoj mjeri doprinose evoluciji prostora jaruge uključuju: razvoj tenzijskih pukotina (*tension crack development*), podzemno procjeđivanje (*piping*), eroziju poniranja vode (*plunge pool*), eroziju zapljuskivanja (*splash erosion*), stvaranje žljebova (*fluting*) te različite oblike odronjavanja (*mass failure*) (Poesen i dr., 2002, Poesen i dr., 2006; Vanmaercke i dr., 2016.).

- **Razvoj tenzijskih pukotina (engl. *tension crack development*)** – destabilizacija i potkopavanje strmih padina jaruge uslijed djelovanja erozije često je praćeno snažnim tenzijskim naprežanjima, koji mogu utjecati na pojavu i razvoj dubokih tenzijskih pukotina u tlu, paralelnih sa zidovima jaruge (Poesen i dr., 2002.), pri čemu nastale pukotine pospješuju prodiranje vode u unutrašnjost sedimenta tla i odnošenje materijala (Vanmaercke i dr., 2016.). Oblikovanje tenzijskih pukotina neposredno uz rub čela jaruge ili bočnih zidova jaruge znatno potiče učestalost odlamanja većih segmenata tla (Vandekerchove i dr., 2000.). Prisutnost tenzijskih pukotina uz rub čela ili bočnog zida jaruge može se smatrati indikatorom aktivnosti jaruga, pri čemu pukotine najčešće nastaju između 30 i 50 cm od ruba čela ili bočnih zidova jaruge (Martinez-Casasnovas i dr., 2004.).

- **Podzemno otjecanje (engl. *piping*)** – uzrokuje nastanak linearnih šupljina u naslagama tla ili nekonsolidiranom materijalu, koje mogu biti promjera od svega nekoliko mm, pa i do preko jednog metra (Goudie, 2004.). Do pojave podzemnog otjecanja dolazi uslijed poniranja vode kroz različite tenzijske pukotine na površini naslaga tla te nastanka podzemnog otjecanja, koje svojom erozivnom energijom dodatno proširuje početne pukotine te odnosi sediment, oblikujući pri tome cjevaste kanale unutar naslaga tla (Frankl i dr., 2016.). Za pojavu podzemnog otjecanja nužna je prisutnost brzog podzemnog otjecanja te slaba kohezivnost naslaga tla, ponajprije u obliku postojanja naslaga različite poroznosti, topljivosti i čvrstoće (Poesen i dr., 2002; Valentin i dr., 2005; Vanmaercke i dr., 2016.). Osim što utječe na odnošenje znatnih količina materijala, podzemno otjecanje potkopava naslage tla, utječući time na njihovu sveukupnu stabilnost.
- **Erozija poniranja vode (engl. *plunge pool erosion*)** – pojava ovog tipa erozije uvjetovana je nailaskom površinskog otjecanja na strmi pad terena (*npr. čelo jaruge ili bočni zid jaruge*), pri čemu voda ponire i u dnu padine uzrokuje odnošenje materijala, uzrokovano erozivnom snagom udara vode (Poesen i dr., 2002.). Pri tome površinsko otjecanje mora biti dostatno za formiranje koncentriranog površinskog toka, o čijoj energiji ovisi i intenzitet erozije pri poniranju.
- **Erozija zapljuskivanja (engl. *splash erosion*)** – predstavlja odvajanje i odnošenje malih čestica tla uslijed udaranja kišnih kapi o podlogu (Soil Science Society of America, 2008.), dok kod jaruga može biti povezana s erozijom poniranja vode.
- **Stvaranje žljebova (engl. *fluting*)** – žljebovi su vertikalno izdužene brazde, nastale djelovanjem površinskog otjecanja, koje su usječene u zid jaruge te se pretežito sužavaju prema vrhu (Poesen i dr., 2002.). Evolucija žljebova na strmim zidovima jaruga može se promatrati kroz tri razvojne faze. U početnoj fazi oblikuju se plitke brazde na strmim zidovima jaruge. Daljnjim površinskim otjecanjem dolazi do proširenja postojećih brazdi, pri čemu se oblikuju žljebovi, čije proširenje potkopava i destabilizira zid jaruge. U završnoj fazi žljebovi se nastavljaju proširivati sve dok ne potkopaju zid jaruge u dovoljnoj mjeri da dođe do odronjavanja tla (Vandekerchove i dr., 2000.).
- **Odronjavanje (engl. *mass failure / mass wasting*)** - odronjavanje materijala u čelu ili bočnim zidovima jaruge se često smatra uzročnikom najintenzivnijeg trošenja materijala (Bull i Kirby, 2002; Rengers i Tucker, 2014.).

5. Područje istraživanja

Područje istraživanja ovog diplomskog rad moguće je podijeliti na mezo (Sl. 2. - A) i mikro razinu (Sl. 2. - B).



Slika 2. Prostorni obuhvat i razdioba istraživanog područja na mezo (A) i mikro (B) razinu

Šire, mezo područje istraživanja ovog diplomskog rada obuhvaća prostor otoka Paga, na kojemu je provedena sistematizacija i inventarizacija svih većih jaruga te višekriterijska analiza podložnosti terena jaruženju.

Otok Pag je s površinom od 284 km² najveći otok u skupini sjevernodalmatinskih otoka te ukupno peti otok po veličini u Hrvatskoj. Obilježava ga vrlo izražena razvedenost obale, koja je ispresijecana brojnim uvalama, zaljevima i rtovima (Magaš, 2011.). Tumačenje smještaja otoka Paga vrlo je važno za razumijevanje raznovrsnih složenih procesa koji su utjecali na oblikovanje današnjeg specifičnog otočnog krajolika. Otok Pag smješten je u krajnjem sjeveroistočnom dijelu sjevernodalmatinske otočne skupine te se pruža u dužini od 59 km u smjeru JI – SZ, paralelno sa smjerom pružanja obalne linije kopna. Od kopna je otok Pag na istoku odijeljen s dubokim Velebitskim kanalom, koji s prosječnom širinom od oko 2 km dijeli otok Pag od planine Velebit na kopnu. Snažni sjeveroistočni vjetar bura spušta se iz smjera SI,

sa strmih velebitskih padina prema otoku Pagu, zbog čega udari ovog vjetera na istočnoj obali otoka Paga često poprimaju olujne razmjere. Sa sjeverne strane otok Pag je odvojen Paškim kanalom od otoka Raba, dok je na istoku odijeljen Maunskim kanalom od otoka Mauna te Poveljskim kanalom od otoka Vira. Južni dio otoka Paga odijeljen je Ninskim zaljevom i Ljubačkim zaljevom od prostora Ravnih kotara.


Gotovo cijelu površinu otoka Paga obilježava specifičan ogoljeni krški krajolik, koji se razvio kao rezultat stoljetnih kombiniranih prirodnih i antropogenih utjecaja i procesa (Magaš, 2013.). Otok je pretežito izgrađen od kredno-paleogenskih plitkomorskih karbonatnih naslaga vapnenca i dolomita, posebice izraženih na antiklinalnim dijelovima otoka, dok unutrašnje, sinklinalne dijelove otoka karakteriziraju povremene izmjene eocenskih laporastih i pjeskovitih klastita, sa značajkama fliša (Lončar, 2009; Magaš, 2011.). Klimatski gledano otok Pag se nalazi u prijelaznom prostoru između sredozemne klime s vrućim ljetom (*Csa*) prema umjereno toploj vlažnoj klimi s vrućim ljetom (*Cfa*), s prosječnom godišnjom količinom oborina između 1050 mm i 1106 mm (Magaš, 2011.). Pri tome treba naglasiti da je višegodišnje mjerenje količine i rasporeda oborina pokazalo kako režim oborina na prostoru otoka Paga ima izražene sezonalne značajke, s najvećim količinama oborina između rujna i prosinca (Magaš, 2011.). Izraženi denudacijski procesi i krška podloga otoka uvjetovali su slabu pedogenezu, unatoč kojoj je moguće razlikovati nekoliko različitih tipova tla, poput različitih glinovitih i pjeskovitih tala razvijenih na flišnoj podlozi te sporadički razvijenim naslagama plitkog smeđeg tla i crvenice (Magaš, 2011.). Dok su antropogeni utjecaji poput pretjerane sječe šuma, a kasnije i izrazite stočarske valorizacije otoka dovele do nestanka nekadašnjeg vegetacijskog pokrova, surovi klimatski uvjeti predvođeni snažnim utjecajem orkanskog vjetera bure i njome nošene posolice iz Velebitskog kanala te izraženi geomorfološki procesi trošenja površinskog supstrata doveli su do stvaranja gotovo nemogućih uvjeta za obnovu raslinja. Slabo razvijen vegetacijski pokrov utjecao je na izloženost površinskih slojeva otoka Paga djelovanju različitih egzogenih čimbenika, čijim je daljnjim djelovanjem oblikovan današnji specifični ogoljeni krški krajolik. Svakako jedan od bitnijih procesa za oblikovanje krajolika otoka Paga je jaruženje, koje nije prostorno ograničeno samo na ogoljene karbonatne dijelove otoka, već se javlja gotovo na svim dijelovima otoka, uključujući unutrašnje flišne zone i mjestimične naslage smeđeg tla (Lončar, 2009.). Zbog toga proučavanje jaruga na razini cijelog otok Paga omogućava bolje razumijevanje i uvid u opće značajke jaruga i procesa jaruženja na otoku. Važnost općih zaključaka o jarugama i jaruženju, koji su izvedeni iz ovog istraživanja je u njihovoj primjenjivosti u svim sličnim dijelovima Sredozemlja i svijeta, u kojima ono također predstavlja važan čimbenik oblikovanja reljefa.

Mikro razina istraživanja u sklopu ovog diplomskog rada proveden je na prostoru jaruge Santiš (Sl. 3.), koja je odabrana kao testna ploha (jaruga) za kontinuirano praćenje intenziteta i značajki jaruženja. Jaruga Santiš smještena je na krajnjem zapadnom dijelu rta Santiš, na istočnoj obali otoka Paga, oko 1,8 km zračne linije sjeveroistočno od sela Dinjiška. Ova jaruga je samo jedna od mnogih jaruga koje se na prostoru istočne obale otoka Paga spuštaju sa središnjeg zaravnjenog kamenjarskog dijela prema Velebitskom kanalu. Međutim, dok je većina ostalih jaruga na ovom prostoru oblikovana na karbonatnoj vapnenačkoj i/ili dolomitnoj podlozi, jaruga Santiš nastala je na relativno debelim naslagama akumuliranog smeđeg tla, čije debljina u pojedinim mjestima prelazi nekoliko metara (Sl. 4; Sl. 4. - B).



Slika 3. Jaruga Santiš i okružujući krški krajolik


Spomenute naslage tla su podložne odnošenju materijala uzrokovanom površinskim i podzemnim otjecanjem, zbog čega je u jaruzi Santiš zamijećeno znatno intenzivnije jaruženje nego u jarugama nastalim na karbonatima. Dok je funkcioniranje pojedinih jaruga na otoku Pagu poremećeno različitim oblicima antropogenih utjecaja (izgradnja prometnica, suhozida, itd.), na prostoru jaruge Santiš zamijećeni su minimalni antropogeni utjecaji za koje je zaključeno da ne remete hidrološke funkcije jaruge. Vrlo bitan čimbenik koji je utjecao na odabir ove jaruge za provođenje istraživanja je njezina dostupnost. Iako se jaruga Santiš nalazi na vrlo zabačenom dijelu otoka Paga, jaruga je razmjerna lako dostupna makadamskom cestom iz sela Dinjiška i Stara Vas.



Slika 4. Smještaj jaruge Santiš u ogoljenom priobalnom dijelu otoka Paga (A); naslage tla u čeonom dijelu jaruge Santiš (B)

Duljina jaruge Santiš iznosi oko 80 m, a prosječna širina oko 15 m. Površina jaruge Santiš iznosi 1155,105 m² te se može reći da ima klasični "kruškoliki" oblik (Morgan i Nearing, 2016.), dok je površina njezinog drenažnog bazena, odnosno slivnog područja znatno veća i iznosi 186 068 m² (0,186 km²) (Sl. 5.).

Prostor jaruge Santiš moguće je raščlaniti na početni (Sl. 5.A), središnji (Sl. 5.B) i završni dio (Sl. 5.C), pri čemu su u svakoj od izdvojenih zona zamijećeni različiti prevladavajući procesi oblikovanja morfologije jaruge. Početni dio (A) obuhvaća čelo jaruge Santiš, unutar kojega su terenskim opažanjem zamijećeni intenzivni procesi jaruženja. Ovaj dio jaruge je ujedno i najširi, nakon kojega se jaruga sužava prema središnjem i završnom dijelu. Prostor čela jaruge predstavlja osnovni prostor istraživanja ovog rada na temelju kojega će se periodički pratiti promjene volumena i morfologije. Zbog toga se prilikom snimanja unutar ovog prostora posebno pazilo na preklapanje snimaka prikupljenih s bespilotnom letjelicom, dok je u ostatku jaruge dostatna i manja pokrivenost.



Slika 5. Odnos između površine jaruge Santiš (desno) i površine njezinog slivnog područja (lijevo)

U središnjem dijelu (B) jaruga se sužava, što je vjerojatno povezano s promjenom prevladavajućeg procesa oblikovanja, gdje uslijed povećanja heterogenosti podloge i pojave čvršćih slojeva dolazi do oblikovanja koncentriranog toka i izraženijeg linearnog usijecanja jaruge. Završni dio jaruge (C) obuhvaća kontaktnu zonu jaruge s Jadranskim morem, u kojoj su aluvijalni sedimenti iz jaruge formirali nekoliko metara široko žalo. Pri tome je primijećeno kako isti sedimenti sežu duboko ispod morske površine, popunjavajući pri tome ranije nastale morfološke udubine u današnjem morskom dnu. Međutim, valja napomenuti kako je akumulirani materijal na prostoru žala te ispod morske razine u stalnoj interakciji s morskim mijenama i valovima, čijim se djelovanjem remeti prirodna stratifikacija nanesenih sedimenata.

6. Metodologija istraživanja

6.1. Analiza postojeće literature

Postojeća literature o jarugama i jaruženju neiscrpan je izvor važnih znanstvenih spoznaja o ovom kompleksnom procesu, čije proučavanje je bilo neophodno za konceptualno oblikovanje ovog diplomskog rada. Teorijski znanstveni radovi o jarugama pružili su odličnu osnovu za potpunije razumijevanje različitih, složenih komponenti procesa nastanka ovih morfoloških oblika, ali i za razumijevanje utjecaja raznovrsnih vanjskih čimbenika (npr. značajke reljefa, klimatski uvjeti, antropogeni utjecaji, itd.) na pojavnost jaruga na određenom prostoru. Znanstveni radovi u kojima su jaruge proučavane kombinacijom terenskog rada i raznovrsnih GIS metoda poslužili su za planiranje izvedbe terenskih istraživanja. Primjerice, proučavanjem znanstvene literature uočena su raznovrsna korisna iskustva znanstvenika, te problemi i/ili nedostaci u ranijim istraživanjima, koji su u znatnoj mjeri pomogli pri konceptualnom oblikovanju i provedbi ovog istraživanja. U konačnici analiza postojeće literature je poslužila za korelaciju znanstvenih spoznaja proizašlih iz ovog istraživanja s rezultatima ranijih sličnih istraživanja, čime je omogućena provjera dosljednosti istraživačke metodologije i usporedba rezultata ovog rada.

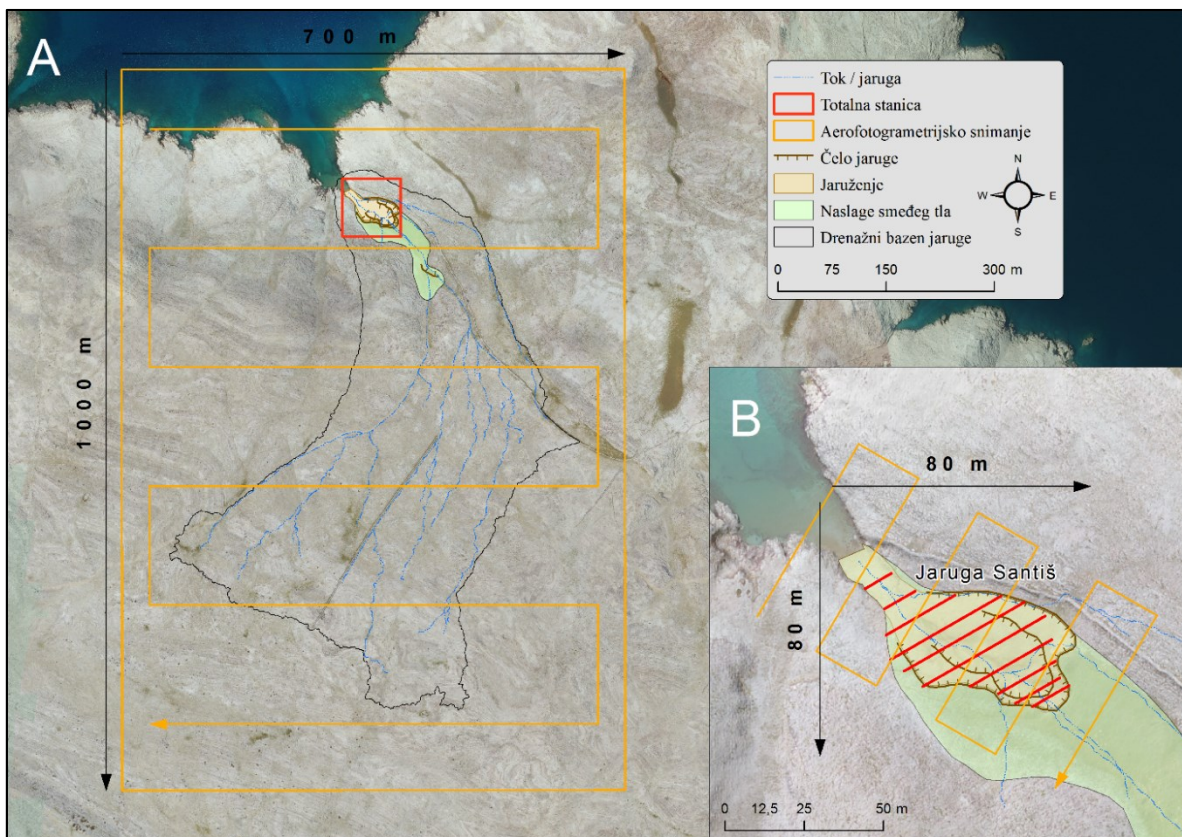
6.2. Terensko prikupljanje podataka

Terensko prikupljanje podataka je temeljna istraživačka metoda ovog diplomskog rada, na kojoj se bazira cijela mikro razina istraživanja. Kroz terenski rad prikupljeni su podaci neophodni za kasnije modeliranje i praćenje intenziteta jaruženja u GIS-u, kao i meteorološki podaci potrebni za analizu utjecaja meteoroloških čimbenika na intenzitet jaruženja. Terensko prikupljanje podataka provedeno je na prostoru otoka Paga, te posebice na prostoru jaruge Santiš, gdje su metodom cikličke aerofotogrametrije prikupljeni visinski podaci, kao i podaci o količini i intenzitetu oborina. Ukupno je provedeno 12 terenskih obilazaka, na kojima su sudjelovali doc. dr. sc. Nina Lončar, doc. dr. sc. Ante Šiljeg, Ivan Marić, mag. geogr. i Fran Domazetović, univ. bacc.. U ovom dijelu diplomskog rada dan je pregled metodologije terenskog prikupljanja visinskih i meteoroloških podataka.

6.2.1. Izrada plana prikupljanja podataka za jarugu Santiš

Brojni autori ističu kako izražena raščlanjenost i kompleksnost jaruge, u kombinaciji s predodređenim nedostacima primijenjenih metoda prikupljanja podataka, mogu uzrokovati pojavu značajnih grešaka i odstupanja u izrađenim modelima, zbog čega je temeljito planiranje

prikupljanja podataka nužno za umanjenje neželjenih negativnih utjecaja (Wells i dr., 2017.). Kako bi se optimiziralo vrijeme potrebno za prikupljanje podataka, smanjio utjecaj različitih korisničko definiranih parametara te osigurala što kvalitetnija pokrivenost istraživanog područja, izrađen je pregledni plan prikupljanja podataka s totalnom stanicom i bespilotnom letjelicom (engl. *unmanned aerial vehicle* - UAV). Ukupna površina istraživanog područja je manja od 1 km², zbog čega niti jedan od ranije dostupnih modela nije bio dovoljno kvalitetan za izradu detaljnog plana snimanja. Kako bi se iz prikupljenih snimaka mogao napraviti kvalitetniji DMP istraživanog područja, 30. ožujka 2017. je napravljeno aerofotogrametrijsko snimanje prostora jaruge Santiš. Pri tome je korištena bespilotna letjelica DJI Phantom 4, opremljena sa 12,4 MP kamerom, koja je pri letu na visini od 60 m prikupila 89 zračnih snimaka. Iz prikupljenih aero snimaka su izrađeni DMP prostorne rezolucije 20 cm i digitalni ortofoto (DOF) prikaz prostorne rezolucije 4 cm, čime je omogućeno planiranje daljnjih aerofotogrametrijskih snimanja prostora jaruge. Na temelju izrađenog DMP-a i DOF-a istraživanog područja, odabrane su i raspoređene orijentacijske točke (OT) za aerofotogrametrijsko snimanje. Pregled izrađenog plana prikupljanja visinskih podataka za prostor jaruge Santiš dan je na Slici 6.



Slika 6. Plan aerofotogrametrijskog snimanja šireg prostora sliva jaruge Santiš (A), plan aerofotogrametrijskog snimanja užeg prostora jaruge Santiš i snimanja poprečnih presjeka totalnom stanicom (B)

6.2.2. Prikupljanje podataka totalnom stanicom (teodolitom)

Izmjera odabranih poprečnih presjeka (u nastavku GCs) jaruge Santiš totalnom stanicom provedena je 7. prosinca 2017. godine. Prikupljanje je provedeno uz pomoć uređaja *LEICA TCR805 Power* (Sl. 7.), kojim je ukupno prikupljen 201 visinskih uzorak, podijeljen u devet poprečnih presjeka. Ukupno vremensko trajanje provedene izmjere iznosilo je 3 h i 30 min, iz čega proizlazi da je prosječna brzina prikupljanja uzoraka iznosila 0,9571 uzoraka/min. Prije izmjere, odabrani poprečni presjeci označeni su razvlačenjem mjernih traka (Sl. 7.B), prema linijama pripremljenim ranije u ArcMap softveru. Odabranih devet poprečnih presjeka su raspoređeni tako da predstavljaju cijeli prostor jaruge, dok im je pravac pružanja okomit na prosječnu orijentaciju talvega jaruge Santiš, određenu alatom *Linear Directional Mean (LDM)*. Ovakav pravac pružanja odabran je kako bi izmjereni poprečni presjeci pratili automatizmom izrađene poprečne presjeke, generirane alatom razvijenim u sklopu ovog diplomskog rada.

Prilikom izmjere odabranih GCs primijećeno je kako preciznost ovakvog mjerenja uvelike ovisi o značajkama terena, zbog kojega je u vertikalno raščlanjenijim dijelovima jaruge bilo gotovo nemoguće prikupiti visinske uzorke. Također, preciznost značajno ovisi i o antropogenom utjecaju, jer je prilikom postavljanja mjernih traka za profile napravljena pogreška u pozicioniranju traka za profile 5, 6 i 7. Uslijed te pogreške je prilikom izmjere tih presjeka napravljen vrlo veliki odmak, zbog čega je upitna njihova vjerodostojnost za potrebe izračuna površinskih i/ili volumetrijskih pokazatelja za jarugu Santiš. Međutim, s obzirom na to da je zbog raščlanjenog terena i sveukupne nesavršenosti ove konvencionalne metode uzorkovanja ovakva pogreška gotovo pa neizbježna, ovi profili nisu uklonjeni, već su iskorišteni za usporedbu s profilima generiranim GULIVER alatom.



Slika 7. Izmjera GCs uz pomoć uređaja *LEICA TCR805 Power* (A); označavanje poprečnog presjeka uz pomoć mjerne trake (B)

6.2.3. Prikupljanje podataka uz pomoć bespilotne letjelice (UAV)

Za daljnje aerofotogrametrijsko prikupljanje podataka uz pomoć bespilotne letjelice (u nastavku UAV) korišten je DJI Phantom 4 kvadrikopter, opremljen sa 12,4 MP digitalnom kamerom. Prikupljanje podataka izvršeno je dva puta u razdoblju od šest mjeseci. Detaljno planiranje aerofotogrametrijskog snimanja nužno je zbog postizanja optimalne pokrivenosti istraživanog područja te reduciranja pojavnosti pogreški, koje se javljaju u obliku pojave "sjene", odnosno područja unutar kojih nije moguće napraviti rekonstrukciju geometrije iz prikupljenih 2D snimaka (Stöcker i dr., 2015; Agisoft, 2016.). Zbog toga su misije leta (engl. *flight missions*) bespilotne letjelice definirane i automatizirane uz pomoć aplikacije Pix4D, koja omogućava korisniku da odredi raznovrsne parametre vezane za let letjelice i prikupljanje podataka (URL 2). Određeni su profili i visina leta, te je zadana učestalost prikupljanja snimaka i međusobno bočno i prednje preklapanje snimaka. Za pravilnu rekonstrukciju geometrije s prikupljenih snimaka, softver mora imati snimljeno isto područje na barem dvije prikupljene aero snimke, zbog čega je pri prikupljanju podataka potrebno 60 % bočnog preklapanja i 80 % prednjeg preklapanja snimaka (Stöcker i dr., 2015; Agisoft, 2016.). Aerofotogrametrijsko snimanje prostora jaruge Santiš provedeno je na dvije razine, prema detaljno izrađenim planovima snimanja. Na široj razini snimljen je cijeli sliv jaruge Santiš, s ciljem dobivanja informacija o općim značajkama sliva s kojega voda otječe u jarugu Santiš. Na užoj razini sniman je isključivo prostor jaruge Santiš, gdje je snimanje provedeno ciklički u razmaku od šest mjeseci, s ciljem dobivanja kvantitativnih informacija o intenzitetu jaruženja unutar jaruge. Za prikupljanje podatak uz pomoć bespilotne letjelice bilo je potrebno označiti i prikupiti orijentacijske točke (OT) na tlu, potrebne za kasniju orijentaciju prikupljenih aero snimaka. Na prostoru jaruge Santiš prevladavaju ogoljene, svijetle karbonatne stijene, zbog čega su orijentacijske i vezne točke označene upotrebom intezivne crvene boje (Sl. 8, A i B). Za svaku orijentacijsku točku su s preciznim geodetskim RTK GPS-om (Stonex 10) prikupljene njezine koordinate, s horizontalnom preciznosti od 0,8 cm i vertikalnom preciznosti od 1,5 cm (URL 3).

6.2.3.1. Aerofotogrametrijsko snimanje šireg prostora jaruge Santiš

Aerofotogrametrijsko snimanje sliva jaruge Santiš napravljeno je 26 svibnja 2017. godine. Šira razina snimanja obuhvaćala je prostor slivnog područja jaruge Santiš, površine 0,18 km². Zbog relativno velike površine slivno područje je snimljeno s bespilotnom letjelicom DJI Phantom 4 s visine od 200 m, čime je omogućena izrada DMP-a prostorne rezolucije 30 cm i izrada DOF-a prostorne rezolucije 15 cm. Snimanje slivnog područja jaruge Santiš

zahtijevalo je postavljanje 20-tak orijentacijskih točaka na prostoru sliva (Slika 8.). Budući da se u ovom slučaju radi o jednokratnom snimanju odlučeno je kako će se postavljati jednokratne orijentacijske točke. Područje sliva jaruge snimljeno je s ukupno tri misije (leta), pri čemu je prikupljeno 258 fotografija.




Slika 8. Plan snimanja prostora sliva jaruge Santiš (lijevo); primjer označavanja orijentacijskih točaka i prikupljanja njihovih preciznih koordinata (desno – A i B)

6.2.3.2. Aerofotogrametrijsko snimanje užeg područja jaruge Santiš

S obzirom na to da se željela postići što bolja prostorna rezolucija kranjeg DMP-a, potrebno je bilo odrediti optimalnu visinu leta aerofotogrametrijskih misija. Prostorna rezolucija modela ovisi primarno o visini leta bespilotne letjelice prilikom aerofotogrametrijskog snimanja.


Pri tome treba napomenuti da bespilotna letjelica određuje visinu leta u odnosu na nadmorsku visinu mjesta uzleta. S obzirom na to da je u ovom istraživanju prostorna rezolucija trebala biti što bolja (poželjno 1 - 2 cm), samim time je visina leta bespilotne letjelice bila ograničena na maksimalno 15 m iznad površine jaruge. Međutim, izrazita vertikalna raščlanjenost terena na prostoru jaruge Santiš odredila je nužnost detaljne izrade plana

snimanja s bespilotnom letjelicom, da bi se na cijelom istraživanom prostoru ostvarila jednaka kvaliteta generiranih modela. Naime, iako je bespilotnom letjelicom sniman razmjerno malen prostor, zbog izražene usječenosti jaruge u podlogu znatna je razlika u nadmorskoj visini između početnog, čeonog dijela jaruge i završnog dijela jaruge. Primjerice, kada bi se prostor cijele jaruge snimao s visine od 15 m u odnosu na vrh jaruge (23 m. n. m.) visina leta nad završnim dijelom jaruge (0 m. n. m.) bi bila oko 38 m (Sl. 9.). Sukladno tome, prostorna rezolucija modela varirala bi od oko 0,68 cm u početnom, čeonom dijelu jaruge, do oko 1,64 cm u najnižem dijelu. Tome valja pridodati izražene strmce u čeonom dijelu jaruge u kojima dolazi do pojave sjene čak i pri idealnim vremenskim uvjetima za aerofotogrametrijsko snimanje.



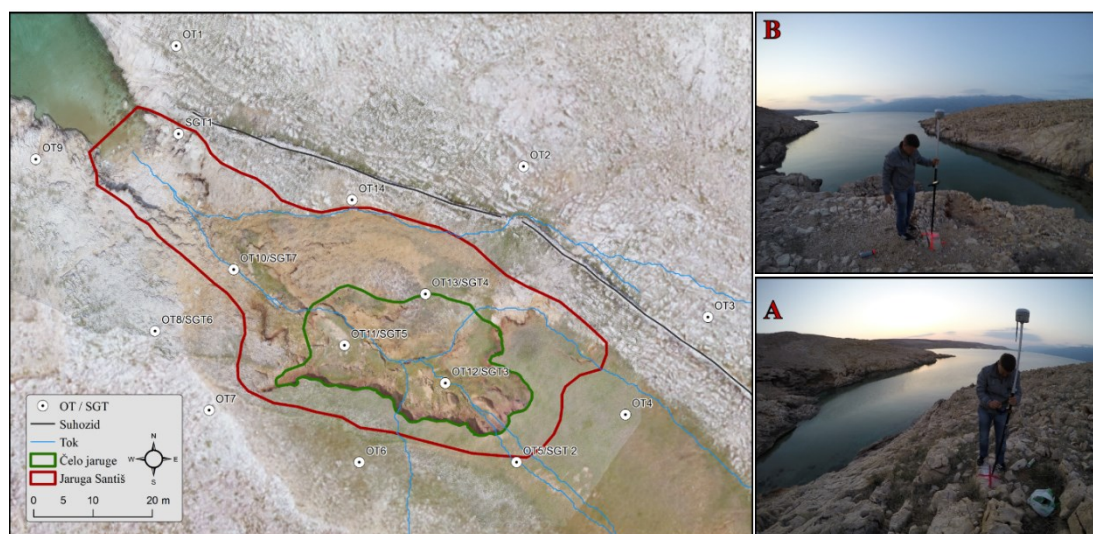
Slika 9. Prikaz utjecaja vertikalne raščlanjenosti terena i mjesta uzleta na prostornu rezoluciju modela (PR – prostorna rezolucija modela; h – visina leta; A – mjesto uzleta)

Da bi se riješili uočeni problemi prostor jaruge je sniman iz više misija te iz različitih kutova, čime se ostvarila maksimalna pokrivenost prostora jaruge s aerofotogrametrijskim snimcima, ali i konstantna visina leta od 15 m nad cijelim prostorom jaruge Santiš (Sl. 10.). Iako se pri snimanju terena iz više misija osigurava konstantna visina leta nad cijelim vertikalno raščlanjenim prostorom, treba voditi računa i o preklapanju misija snimanja. Ako se završni snimci prve misije i početni snimci sljedeće misije ne preklapaju može doći do pojave deformacija u modelu, u obliku pojave "lažnih" strmaca na mjestima odmaka (Sl. 10.).



Slika 10. Načelo postizanja konstantne visine aerofotogrametrijskog snimanja nad vertikalno raščlanjenim terenom kroz korištenje više misija snimanja


Ukupno je na užem prostoru jaruge Santiš postavljeno 14 orijentacijskih točaka (OT). Orijetacijske točke su markirane postavljanjem metalnih klinova i uporabom crvene boje (Sl. 11.). Kao i kod ostalih snimanja precizne koordinate orijentacijskih točaka prikupljene su s RTK GPS uređajem Stonex 10.



Slika 11. Plan snimanja prostora jaruge Santiš (lijevo); primjer označavanja orijentacijskih točaka i prikupljanja njihovih preciznih koordinata (desno – A i B)

Prvo aerofotogrametrijsko snimanje užeg područja jaruge Santiš napravljeno je 26. svibnja 2017. godine, dok je drugo izvršeno 20. studenog 2017. godine, pri čemu je svaki puta prikupljeno 389 snimaka. Prilikom provođenja aerofotogrametrijskih snimanja uočen je sezonalni rast mediteranskog čička (lat. *arctium lappa*), koji je uklonjen kako ne bi utjecao na konačni izlazni rezultat. Osnovni nedostatak UAV fotogrametrije za praćenje trošenja

materijala je utjecaj vegetacijskog pokrova, koji ometa izravno snimanje topografije terena (Marzolff i Poesen, 2009; Cook, 2017.). Zbog toga na područjima s razvijenim vegetacijskim pokrovom model ne predstavlja površinu terena, već površinu vrha vegetacijskog pokrova (Marzolff i Poesen, 2009.). S obzirom na to da je prostorna rezolucija izrađenog DMP-a 2 cm, čičak koji je unutar proučavanog razdoblja (šest mjeseci) narastao do visine od oko 10 cm bi na izrađenom modelu bio itekako vidljiv. Ako se ovakvi nedostaci UAV fotogrametrije ne uzmu u obzir na način da se vegetacija ukloni, može doći do pojave artefakata na modelu (Sl. 12.) i pogreški prilikom interpretacije temporalnih modela, gdje neupućena osoba može protumačiti ovakav ishod kao posljedicu akumulacije materijala unutar jaruge. Poradi toga je odlučeno kako izrasli čičak koji se nalazi unutar prostora jaruge treba ukloniti. Uklanjanje čička napravljeno je s maksimalnim oprezom. Nije se izvlačio korijen biljke, da se ne bi poremetilo tlo oko korijena, već je biljka odrezana pri dnu stabljike.



Slika 12. Utjecaj vegetacije na pojavu artefakata na izrađenom DMP-u; A - artefakti na prikazu reljefa sjenjčanjem; B - artefakti na modelu nagiba padina

U svrhu potpunog uklanjanja neželjenog utjecaja vegetacije poželjno je u daljnjim istraživanjima snimanje jaruge izvršiti LiDAR tehnologijom. Naime, laser uspješnije prodire kroz vegetacijski pokrov, zbog čega je prije izrade modela moguće u procesu filtracije ukloniti svu snimljenu vegetaciju (Marzolff i Poesen, 2009.).

6.2.4. Postavljanje meteoroloških mjernih uređaja

Od meteoroloških uvjeta koji utječu na intenzitet jaruženja unutar jaruge Santiš praćeni su količina i intenzitet oborina unutar istraživanog razdoblja. Za praćenje količine i intenziteta oborina korištena su dva mjerna uređaja *Hobo Onset RG3-M*.

Kalibriranje i postavljanje mjernog uređaja za intenzitet oborina


Mjerni uređaj *Hobo Onset RG3-M* namijenjen je prikupljanju i spremanju podataka o količini, intenzitetu i trajanju oborina (URL 4). Prije postavljanja uređaji su kalibrirani tako da bilježe sve oborine od trenutka postavljanja, čime je omogućeno prikupljanje podataka o ukupnoj količini oborinama na dnevnoj, tjednoj, mjesečnoj i godišnjoj bazi. Uređaj *RG3-M* sastoji se od protočne posude, unutar koje se nalaze dijelovi mjernog uređaja (Sl. 13.). Na vrhu posude se nalazi lijevak sa zaštitnim sitom, koji služi za prikupljanje oborina i oblikovanje kapi u dnu lijevka. Nastale kapi procjeđuju se s lijevka na njihalo, koja na oba kraja ima posudicu zapremnine 0,2 mm. Ispunjavanjem posude dolazi do njihaja, pri čemu uređaj bilježi 0,2 mm kiše, dok ujedno bilježi i vrijeme kada je došlo do njihaja.



Slika 13. Unutrašnjost mjernog uređaja *Hobo Onset RG3-M* postavljenog na ravnu drvenu dasku i obloženog kamenjem


Mjerni uređaji za praćenje intenziteta oborina su postavljeni na dvije odvojene lokacije (Sl. 15. - B). Primarni uređaj za intenzitet oborina postavljen je na lokaciji M1, odnosno na manjem uzvišenju oko 120 m zračne linije jugoistočno od jaruge Santiš (Sl. 15. - C). Iako se jaruga Santiš nalazi na relativno nepristupačnom terenu uređaj nije postavljen u samu jarugu, već je izdvojen na obližnje uzvišenje kako bi se smanjila mogućnost da ga netko od mogućih prolaznika pronade za vrijeme njegova rada. S obzirom na to da *Hobo Onset RG3-M* mjerni uređaji moraju prilikom postavljanja biti postavljeni u ravnini, problem prilikom montiranja je

predstavljao neravan krški teren, koji je onemogućavao pravilno postavljanje uređaja. Ovaj problem je riješen fiksiranjem uređaja na ravnu drvenu dasku, koju je nakon toga bilo znatno lakše iznivelirati na terenu (Sl. 13.). Nadalje, da bi se uređaj dodatno zaštitio od neželjenog utjecaja vjetra, u prvom redu bure koja na Pagu često poprima i olujne značajke, mjesto postavljanja je obloženo i zaštićeno kamenom (Sl. 13.; Sl. 14.A). Na taj način ne samo da su onemogućene vjetrom uzrokovane vibracije koje remete mjerenja uređaja, već je uređaj dodatno skriven u okolni krajolik, čime je smanjena mogućnost da ga netko pronade i utječe na njegov rad. Ovaj mjerni uređaj započeo je s mjerenjima 30. travnja 2017. godine u 16:00 h.



Slika 14. A - uređaj M1 postavljen na uzvišenje nedaleko od jaruge Santiš;
B - uređaj M2 postavljen na zid staje nedaleko od sela Dinjiška

Da bi se osigurali od iznenadnog prestanka rada primarnog mjernog uređaja, drugi, pričuvni mjerni uređaj postavljen je na sigurniju lokaciju (M2) unutar privatnog posjeda, nedaleko od sela Dinjiška (Sl. 15.B). Ova mjerni uređaj postavljen je na južno orijentirani zid staje, pri čemu stijenka zida štiti uređaj od utjecaja vjetra, ali istodobno ne remeti njegov rad (Sl. 14.B). Sekundarni mjerni uređaj udaljen je oko 1,5 km južno od jaruge Santiš te je s mjerenjima započeo 19. travnja 2017. u 12:00 h. Iako su mjerni uređaji postavljeni relativno blizu jedan drugome, ipak se nalaze na suprotnim stranama otoka (Sl. 15.B), zbog čega se očekuje da će ova dva mjerna uređaja zabilježiti razmjerno različite vrijednosti intenziteta oborina.



Slika 15. A – lokacija postavljenih uređaja u jugoistočnom dijelu otoka Paga; B – lokacija primarnog (M1) i sekundarnog (M2) postavljenog *Hobo Onset RG3-M* uređaja; C – udaljenost M1 uređaja od jaruge Santiš

6.3. Modeliranje u GIS-u

Modeliranje prikupljenih visinskih podataka izvršeno je pomoću *ArcGIS 10.1* i *Agisoft PhotoScan Professional*¹ računalnih programa. Terenski prikupljeni visinski podaci s prostora jaruge Santiš obrađivani su u različitim softverima, sukladno različitim korištenim metodama prikupljanja podataka, što je detaljno opisano u nastavku metodologije.

6.3.1. Izrada DMR-a otoka Paga


Visinski podaci potrebni za izradu digitalnog modela reljefa cijelog otoka Paga nastali su fotogrametrijskom restitucijom, a preuzeti su od Državne geodetske uprave (URL 5). Ovi podaci su interpolirani korištenjem ArcGIS ekstenzije *Geospatial Analysis*, unutar koje su okupljene najkorištenije determinističke i geostatističke metode prostorne interpolacije (Šiljeg, 2013; Barada, 2017.). Na temelju ukupno 148 518 visinskih točaka izrađen je DMR prostorne rezolucije 15 m, čija je kvaliteta znatno bolja od modela iz javno dostupnih izvora. Pri tome je korištena *ordinary kriging (OK)* metoda interpolacije, koja se nakon provjere i usporedbe točnosti interpolacijskih funkcija pokazala kao optimalna metoda za interpolaciju prikupljenih visinskih podataka. Procjena i usporedba točnosti različitih determinističkih i geostatističkih interpolacijskih funkcija napravljena je *metodom unakrsnog vrednovanja (cross-validation)*, nakon čega se OK metoda interpolacije pokazala kao najtočnija metoda, s najmanjom vrijednosti standardne devijacije (RMSE = 1,0279 m). Optimalna prostorna rezolucija izrađenog DMR-a otoka Paga od 15 m određena je metodom *kompleksnosti terena*, na temelju omjera između duljine linija presjeka i ukupnog broja infleksijskih točaka (Hengl, 2006; Šiljeg, 2013; Barada, 2017.).

6.3.2. Modeliranje aerofotogrametrijskih podataka

Obrada aero snimaka prikupljenih kroz UAV fotogrametriju napravljena je u *Agisoft PhotoScan Professional (APP)* programu, trenutačno jednom od najnaprednijih softvera za obradu aero snimaka (Gini i dr., 2013.). APP je softver namijenjen 3D modeliranju, koji na temelju implementiranih *structure-from-motion (SfM)* i *multi-view* algoritama omogućava rekonstrukciju 3D struktura iz preklapljenih 2D snimaka (Mancini i dr., 2013; Agisoft, 2016.). SfM algoritam automatski preklapa i uparuje prikupljene 2D snimke, na temelju kojih rekonstruira geometriju prikaza i izrađuje 3D oblak točaka (James i Robson, 2012; Westboy i

¹ Modeliranje u *Agisoft PhotoScan Professional* softveru obavljeno je za vrijeme sudjelovanja na Erasmus+ stručnoj praksi na **Julius Kühn Institutu**, Berlin, Njemačka

dr., 2012; Mancini i dr., 2013; Shervais, 2017.). Pri tome izrada oblaka točaka i DMP u APP-u predstavlja polu-automatizirani process, koji uključuje sljedećih pet faza: *orijentacija snimaka* (1), *dodavanje kontrolnih točaka* (2), *izrada gustog oblaka točaka* (3), *generiranje 3D mreže poligona* (4) te *izrada teksture modela* (5) (Agisoft, 2016.) (Sl. 16.):



Slika 16. Prikaz odabranih faza izrade DMP u APP softveru (A – orijentacija snimaka; B – dodavanje GCPs; C – izrada teksture modela)

Orijentacija snimaka (1) – prva faza procesa izrade modela iz prikupljenih aero snimaka podrazumijeva orijentaciju prikupljenih snimaka prema xyz lokacijama kamere zabilježenih prilikom prikupljanja snimaka. Program automatski za svaki prikupljeni snimak prepoznaje vezne piksele, uz pomoć kojih međusobno povezuje snimke i izrađuje rijetki oblak točaka (*sparse point cloud*) (Agisoft, 2016.). Pri tome korisnik definira varijablu *accuracy*, koja se odnosi na ukupan broj piksela slike koje će softver koristiti za orijentaciju iste. S obzirom da o ovoj fazi ovise sljedeći koraci procesa izrade modela, ali i vrijeme potrebno za obradu snimaka, poželjno je sukladno mogućnostima postaviti što višu razinu varijable *accuracy*. Radi postizanja što točnije orijentacije snimaka prilikom izrade svih modela u APP-u korištena je *highest* vrijednost varijable *accuracy*.

Dodavanje kontrolnih točaka (2) – iako su u prvoj fazi izrade modela snimci georeferencirani sukladno lokacijskim oznakama svakog prikupljenog snimka, točnost takvog georeferenciranja prije svega ovisi o preciznosti i točnosti IMU (engl. *inertial measurement unit*) sustava implementiranog unutar korištene bespilotne letjelice. S obzirom na to da se preciznost tih uređaja mjeri u metrima, takvo izravno georeferenciranje nije dovoljno za ostvarivanje željene centimetarske točnosti modela. Da bi se postigla apsolutna orijentacija rekonstruiranog modela potrebno je georeferencirati izrađeni rijetki oblak točaka prema koordinatama kontrolnih točaka postavljenih na tlu, čije precizne koordinate su prikupljene na terenu, korištenjem znatno preciznijih RTK-GPS uređaja (James, 2017.).

Tablica 1. Pregled korisničko definiranih parametara korištenih pri izradi DMP-a u Agisoft PhotoScan Professional programu

#	Korak	Korisničko-definirani parametar	Odabrana opcija
1	Odabir aero snimaka	Ispravljanje Z koordinata snimaka i provjera kvalitete snimaka (Image quality)	
2	Orijentacija snimaka	Accuracy Pair selection Key point limit Tie point limit	Highest Reference 40 000 10 000
3	Filtriranje rijetkog oblaka točaka	Projection accuracy	Removal of 10% points with biggest error
4	Optimizacija oblaka točaka	Optimization parameters	All parameters
5	Izrada gustog oblaka točaka	Quality Depth filtering	Low Mild
6	Generiranje 3D mreže poligona	Surface type Face count Interpolation	Height field High Enabled
7	Dodavanje kontrolnih točaka	Ground control points (GCPs) added	
8	Optimizacija oblaka točaka	Optimization parameters	All parameters
9	Filtriranje rijetkog oblaka točaka	Projection accuracy	Removal of 10% points with biggest error
10	Optimizacija oblaka točaka	Optimization parameters	All parameters
11	Izrada gustog oblaka točaka	Quality Depth filtering	Medium Mild
12	Generiranje 3D mreže poligona	Surface type Face count Interpolation	Height field 10000000 Enabled
13	Izrada teksture modela	Mapping mode Blending mode Texture size Color correction	Generic Mosaic 8096 Enabled
14	Izrada DMP-a	Coordinate system Source data Interpolation Point classes	WGS84 Dense cloud Enabled All
15	Izrada ortofoto snimka	Surface mode Blending mode	DEM Mosaic

Izrada gustog oblaka točkaka (3) – nakon dodavanja kontrolnih točkaka i optimizacije modela slijedi izrada gustog oblaka točkaka (*build dense cloud*). Unutar ove faze program automatski iz ranije izrađene geometrije i orijentiranih snimaka izračunava dubinske informacije te izrađuje oblak točkaka, čija gustoća ovisi o korisničko definiranoj varijabli *quality* i zadanom načinu dubinskog filtriranja (*depth filtering*) (Agisoft, 2016.). Varijabla *quality* određuje udio piksela orijentiranih snimaka koji će biti korišten za izradu gustog oblaka točkaka, pri čemu opcija *ultra high* za svaki piksel orijentiranih snimaka izrađuje jednu točku, dok kod ostalih opcija broj piksela za koje se izrađuju točke postupno opada. Odabir metode dubinskog filtriranja ovisi o značajkama terena za kojega se izrađuje model, pri čemu se za modeliranje vertikalno raščlanjenih terena, poput prostora jaruge, preporučava upotreba *mild* opcije dubinskog filtriranja (Agisoft, 2016.). Kao i kod *orijentacije snimaka*, radi izrade modela maksimalne točnosti poželjno je odabrati što veću razinu varijable *quality*, što opet ovisi o raspoloživom vremenu procesiranja te radnim značajkama računala. Prilikom izrade modela u APP-u korištena je *medium* opcija varijable *quality* te *mild* način dubinskog filtriranja. Iako bi korištenjem *high* ili *ultra high* opcije varijable *quality* bilo moguće izraditi detaljnije modele, testiranjem ovih opcija pokazalo se kako su one prema korištenju memorije i potrebnom vremenu procesiranja suviše zahtjevne za izradu modela za potrebe ovog diplomskog rada.

Generiranje 3D mreže poligona (4) – u ovoj fazi APP program iz izrađenog gustog oblaka točkaka rekonstruira 3D mrežu poligona, koja predstavlja površinu promatranog objekta (Agisoft, 2016.). Prilikom izrada 3D mreže poligona potrebno je definirati *surface type*, koji određuje tip površine koja se generira te varijablu *source data*, koja se odnosi na oblak točkaka na temelju kojega će poligoni biti izrađeni. Za parametar *surface type* odabrana je opcija *height value*. Također, potrebno je definirati i broj poligona (*polygon count*), pri čemu je zbog brzog procesiranja ove faze moguće postaviti broj poligona i iznad razine definirane opcijom *high*. Pri izradi svih modela u APP-u *polygon count* je postavljen na 10 000 000.

Izrada teksture modela (5) – posljednja faza procesa izrade DMP-a iz aerofotogrametrijskih snimaka u APP softveru obuhvaća izradu teksture modela (*build texture*), koja je vrlo bitna za poboljšavanje vizualnih značajki izrađenog modela (Agisoft, 2016.). Korisnik definira način kartiranja (*mapping mode*) teksture, gdje su različiti načini kartiranja teksture prilagođeni različitim tipovima modelirane površine. Pri izradi svih modela u APP-u korišten je *Mosaic* način kartiranja.

6.4. Analitičke operacije u GIS-u

Analitičke operacije u GIS-u obavljene su uz pomoć *ArcGIS 10.1*, *SAGA GIS 6.2.0.*, *Erdas Imagine 2014*, *eCognition Developer 8.7*² i *Agisoft PhotoScan Professional* računalnih programa, dok su prikupljeni meteorološki podaci obrađivani u *HOBOWare* i *Igor Pro* softverima.

6.4.1. Izdvajanje i inventarizacija jaruga otoka Paga

Pronalaženje i kartiranje postojećih jaruga otoka Paga napravljena je kroz primjenu objektno-orijentiranih rasterskih analiza (*eng. Object-based Image Analysis (OBIA)*), uz pomoć naprednog **eCognition Developer 8.7** softvera. Objektno-orijentirana rasterska analiza (OBIA) je pod disciplina GIS znanosti namijenjena obradi i analiziranju različitih rasterskih podataka, prikupljenih metodama iz područja daljinskih istraživanja, pri čemu se pikseli zadanih snimaka grupiraju u smislene homogene objekte, prema njihovim određenim značajkama (Hay i Castilla, 2006.). Za razliku od pikseli-orijentiranih analiza, OBIA u obzir uzima prostorne odnose među geografskim objektima, kao i njihove geometrijske i teksturalne značajke, zbog čega je prilikom izdvajanja objekata iz zadanih rasterskih snimaka moguće na temelju vlastitog znanja uspostaviti određena pravila i odnose među izdvojenim objektima, koji mogu znatno poboljšati rezultat izdvajanja i klasifikacije željenih objekata (Wang i dr., 2014.). Objektno-orijentirani pristup omogućava polu-automatsko izdvajanje različitih morfoloških oblika, pa tako i jaruga u procesu koji se može podijeliti na sljedeća tri temeljna koraka: *odabir i optimizacija segmentacijskog algoritma (a)*, *klasifikacija temeljena na znanju (b)* i *procjena kvalitete (c)* (d'Oleire-Oltmanns i dr., 2013.).

Primijenjeni OBIA pristup za izdvajanje jaruga je prilagođen sukladno kvaliteti i značajkama podataka dostupnih za prostor otoka Paga. Prema tome korišteni metodološki pristup kartiranju jaruga može se raščlaniti na sljedećih sedam koraka: *prikupljanje relevantnih rasterskih podataka (1)*, *standardizaciju prikupljenih rasterskih podataka (2)*, *odabir testnih podataka (3)*, *segmentacija rasterskih podataka (4)*, *klasifikacija izdvojenih objekata (5)*, *uklanjanje "lažnih" kandidata (6)* i *procjena rezultata OBIA (7)*. U nastavku je dano detaljno pojašnjenje svakog od navedenih koraka primijenjenog OBIA kartiranja jaruga.

² Analitičke operacije izvedene u *eCognition Developer 8.7* i *Agisoft PhotoScan Professional* softverima obavljene su za vrijeme sudjelovanja na Erasmus+ stručnoj praksi na **Julius Kühn Institutu**, Berlin, Njemačka

Prikupljanje relevantnih rasterskih podataka (1)

Za izdvajanje željenih morfoloških objekata OBIA pristupom odabir odgovarajućih rasterskih podataka je od iznimne važnosti. Radi kvalitete izdvajanja poželjno je da odabrani podaci imaju homogene vrijednosti unutar istraživanih objekata, koje odudaraju od okružujućih vrijednosti (Eisank i dr., 2014.). U procesu izdvajanja jaruga najčešće se kombiniraju multispektralni snimci s različitim morfometrijskim pokazateljima izdvojenim iz DMR-a (Shruthi i dr., 2011; 2014; 2015; Liu i dr., 2016.), pri čemu prostorna rezolucija korištenih rasterskih podataka ovisi o veličini istraživanog područja i dostupnosti podataka. U slučaju otoka Paga istraživano područje obuhvaća relativno velik prostor (284 km²), zbog čega se dostupni podaci mogu svrstati u kategoriju rasterskih podataka srednje rezolucije (URL 1). U tablici 2. je dano pojašnjenje parametara korištenih pri kartiranju jaruga na prostoru otoka Paga, dok se detaljnije pojašnjenje važnosti odabranih kriterija za kartiranje jaruga nalazi u poglavlju 7.

Tablica 2. Morfometrijski parametri korišteni za kartiranje postojećih jaruga OBIA pristupom

#	Parametar	Akronim	Definicija	Korištena metoda
1	Indeks ravnoteže materijala	MBI	Pokazatelj procesa trošenja i akumuliranja tla, funkcija nagiba i zakrivljenosti padine te vertikalne udaljenosti od drenažne mreže	Möller i dr., (2008.)
2	Nagib padine	SLO	Prvi derivat visine u bilo kojem smjeru	Zevenbergen i Thorne (1987.)
3	Topografski indeks pozicije	TPI	Razlika između visine središnjeg piksela i prosječne visine okružujućih piksela	Giusan i dr. (1999.)
4	Topografski indeks vlažnosti	TWI	Potencijal zasićenosti terena vodom izračunat prema lokalnim značajkama drenažnog bazena i nagiba terena	Moore i dr. (1991.)
5	Indeks snage otjecanja	SPI	Potencijalna snaga otjecanja izračunata prema lokalnim značajkama drenažnog bazena i nagiba terena	Moore i dr. (1991.)
6	Vertikalna udaljenost od drenažne mreže	VDC	Razlika između izvornog DMR-a i interpolirane razine kanala drenažne mreže	Conrad, O. (2002.)
7	Planarna zakrivljenost padine	PLAN	Zakrivljenost padine u pravcu najveće strmine	Moore i dr. (1991.)

Metodološki pregled procesa izrade PLAN, SPI, TWI i SLO parametara dan je u poglavlju 6.4.2., dok je u nastavku dano metodološko objašnjenje procesa pripreme MBI, TPI i VDC parametara, koji su pripremljeni unutar SAGA GIS softverskog paketa.

Indeks masne bilance (MBI)

Indeks masne bilance (engl. *Mass balance indeks (MBI)*) predstavlja funkciju lokalnih standardiziranih vrijednosti *nagiba padine (SLO)*, *ukupne zakrivljenosti padine (TC)* i *vertikalne udaljenosti od drenažne mreže (VDC)*. Izračun MBI automatiziran je unutar SAGA GIS softverskog paketa, gdje se izračunava prema sljedećoj formuli (Möller i dr., 2008; 2012.):

$$MBI = \begin{cases} f(TC) \times (1 - f(SLO)) \times (1 - f(VDC)) & \text{for } f(TC) < 0 \\ f(TC) \times (1 + f(SLO)) \times (1 - f(VDC)) & \text{for } f(TC) > 0 \end{cases} \quad (1)$$

Gdje je:

$f(TC)$ – standardizirana vrijednost ukupne zakrivljenosti padine

$f(SLO)$ – standardizirana vrijednost nagiba padine

$f(VDC)$ – standardizirana vrijednost VDC

Topografski indeks pozicije (TPI)

Izračun topografskog indeksa pozicije (engl. *Topographic position indeks (TPI)*) automatiziran je unutar SAGA GIS softverskog paketa. Algoritam za izračun TPI određuje vrijednost središnjeg piksela na temelju razlike između visine središnjeg piksela i prosječne visine unutar predodređenog susjedstva (Wilson i Gallant, 2000.). Izračun TPI se vrši prema sljedećoj formuli (Wilson i Gallant, 2000.):

$$TPI = Z_0 - \bar{Z} \quad (2)$$

gdje je:

Z_0 – središnji piksel

\bar{Z} – prosječna visina izračunata prema formuli:

$$\bar{Z} = \frac{1}{n_R} \sum_{i \in R} Z_i \quad (3)$$

gdje je:

R – predodređeno susjedstvo

Vertikalna udaljenost do drenažne mreže (VDC)

Izračun vertikalne udaljenosti do drenažne mreže (engl. *Vertical distance to channel network* (VDC)) također je automatiziran unutar SAGA GIS softvera, gdje se vrijednosti VDC izračunavaju oduzimanjem bazne razine drenažne mreže (DMR_{BASE}), dobivene interpolacijom svih tokova, od DMR-a istraživanog područja (Möller i dr., 2012.):

$$VDC = DMR - DMR_{BASE}$$

Gdje je:

DMR – zadani digitalni model reljefa istraživanog područja

DMR_{BASE} – bazna razine drenažne mreže izrađena interpolacijom zadanih tokova

Standardizacija prikupljenih rasterskih podataka (2)

Da bi se poboljšala usporedivost prikupljenih rasterskih podataka, njihove vrijednosti su standardizirane prema formuli (Friedrich, 1998; Möller i dr., 2008; 2012.):

$$f(x) = \frac{x}{|x|+F} \quad (4)$$

Gdje je:

x – odabrani rasterski parametar


F – korisničko-definirana transformacijska konstanta

Dok za parametre $x = SPI, MBI, TPI, PLAN$ vrijedi $f(SPI, MBI, TPI, PLAN) \in [-1,1]$; $F = 0.01$, za parametre $x = SLO, TWI, VDC$ vrijedi $f(SLO, TWI, VDC) \in [0,1]$; $F = 15$.

Odabir testnih podataka (3)

Da bi se optimizirala segmentacija prikupljenih rasterskih podataka te olakšala njihova kasnija klasifikacija, bilo je potrebno prikupiti referentne podatke, na temelju kojih je moguće izdvojiti objekte koji predstavljaju jaruge, od ostalih objekata. Za referentne podatke (R_j) je metodom slučajnog odabira izabrano 10 jaruga s prostora otoka Paga, čiji je prostorni obuhvat kartiran (Sl. 17.) metodom vizualne interpretacije i ručne digitalizacije u mjerilu 1:2500 prema DOF-u otoka Paga prostorne rezolucije 0,5 m (DGU, 2018.). Prikupljeni referentni podaci korišteni su kasnije za provjeru točnosti kartiranja jaruga OBIA pristupom. Kako bi se provjerila točnost kartiranja jaruga različitih dimenzija OBIA pristupom, bilo je potrebno prikupiti referentne podatke o jarugama različitih dimenzija. Stoga je za referentne jaruge odabrano 10 jaruga različitih dimenzija, koje je moguće podijeliti u sljedeće dvije klase: kraće

jaruge (< 500 m) i dulje jaruge (> 500 m) (Sl. 17.).




Slika 17. Referentne jaruge kartirane metodom ručne digitalizacije prema DOF-u visoke prostorne rezolucije (PR = 0.5 m)

Segmentacija rasterskih podataka (4)

Grupiranjem piksela zadanih rasterskih snimaka formiraju se segmenti, odnosno objekti, pri čemu se grupiranje provodi na temelju određenog algoritama te jednog ili više zadanih kriterija za identifikaciju objekata, sačinjenih od prostorno kontinuiranih piksela slične teksture, boje ili tona u procesu koji se naziva *segmentacija* (Blaschke, 2010.). Izdvajanje jaruga je napravljeno prema *multi-resolution segmentation (u nastavku MRS)* algoritmu, koji individualne piksele rasterskih snimaka spaja u smislene objekte, sve dok unutrašnja heterogenost stvorenih objekata ne dosegne određeni korisničko-definirani prag (Benz i dr., 2004; Shruthi, 2014.). Prije provođenja MRS potrebno je optimizirati **mjerilo** (eng. *scale*), **oblik** (eng. *shape*) i **kompaktnost** (eng. *compactness*) segmentacije, kako bi generirani objekti što vjerodostojnije predstavljali željene morfološke oblike. Najvažniji korisničko-definirani parametar je **mjerilo**, čija vrijednost izravno utječe na dozvoljenu heterogenost unutar generiranih objekata (Blaschke, 2010.). Veće vrijednosti ovog parametra dozvoljavaju veću heterogenost unutar generiranih objekata, čime se u pravilu omogućava stvaranje prostorno većih objekata (Drăgut i dr., 2014.). Radi vjerodostojnije i točnije klasifikacije željenih morfoloških oblika, vrijednost ovog parametra treba prilagoditi rasterskim podacima koji se koriste u segmentaciji te veličini oblika koje se želi izdvojiti (Drăgut i dr., 2010; Gao i dr., 2011.). Općenito govoreći postoje sljedeća dva različita statistička pristupa determiniranju optimalne vrijednosti **mjerila**: *nenadzirana metoda optimizacije uz pomoć ESP alata* razvijena u sklopu istraživanja Drăgut i dr. (2010.), te *nadzirana optimizacija prema referentnim*

poligonima predložena od strane Anders i dr. (2011.) (Eisank i dr., 2014.).

Segmentacijski parametri prilagođeni su odabranim rasterskim podacima uz pomoć ESP alata (*ESP tool*), koji omogućava automatsku optimizaciju *mjerila*, prema vrijednostima lokalne varijance (Drăgut i dr., 2010; Drăgut i dr., 2012; Shruthi i dr., 2011.). Nakon optimizacije *mjerila* bilo je potrebno definirati optimalne vrijednosti *oblika* i *kompaktnosti*. Korisničko-definirani parametar *oblik* određuje važnost vrijednosti piksela rasterskih snimaka u segmentacijskom postupku, gdje niže vrijednosti ovog parametra potenciraju važnost vrijednosti unutar piksela. Parametar *kompaktnost* definira kompaktnost i izgled resultantnih objekata, pri čemu niže vrijednosti ovog parametra ishode linearnije objekte (Drăgut i dr., 2014; Shruthi i dr., 2014.). S obzirom na to da je uočeno kako objekti generirani na temelju zadanih vrijednosti *oblika* (0,1) i *kompaktnosti* (0,5) parametara ne odgovaraju jarugama, zaključeno je da ove parametre također treba optimizirati. Optimalni vrijednosti parametara *oblik* i *kompaktnost* odabrani su na temelju vizualne interpretacije njihovih različitih vrijednosti (Sl. 18.). Sukladno tome, uočeno je kako su optimalne vrijednosti za izdvajanje jaruga iz odabranih rasterskih podataka 0,01 za parametar *oblik* i 0,05 za parametar *kompaktnost*.



Slika 18. Utjecaj definiranih parametara MRS na izgled resultantnih objekata

Klasifikacija izdvojenih objekata (5)

Sljedeći korak OBIA-e nakon izdvajanja homogenih objekata u procesu segmentacije, čini klasifikacija objekata prema njihovim određenim značajkama. Klasificiranje izdvojenih objekata provedena je unutar eCognition programa metodom manualne klasifikacije (eng. *assign class*), prema korisničko definiranim pragovima (eng. *threshold conditions*). Određivanje pragova napravljeno je na temelju prosječnih vrijednosti odabranih parametara za izdvojene

objekte (*meanMBI*, *meanSLO*, *meanVDC*, *meanTWI*, *meanSPI*, *meanTPI*, *meanPLAN*).

U tablici 3. je dan prikaz korisničko-definiranih pragova korištenih u manualnoj klasifikaciji jaruga, dok je pojašnjenje svakog od definiranih pragova dano u poglavlju 7.

Tablica 3. Pragovi definirani pri manualnoj klasifikaciji objekata izdvojenih OBIA pristupom

Morfometrijski parametar	Akronim	Definirani prag
Indeks masne balance	meanMBI	$\text{meanMBI} < 0$; $\text{meanMBI} \geq -2$
Nagib padine	meanSLO	$\text{meanSLO} \geq 0,2$
Topografski indeks pozicije	meanTPI	$\text{meanTPI} \leq -0,01$
Topografski indeks vlažnosti	meanTWI	$\text{meanTWI} > 0$
Indeks snage otjecanja	meanSPI	$\text{meanSPI} \geq 0$
Vertikalna udaljenost od drenažne mreže	meanVDC	$\text{meanVDC} \geq 0,1$
Planarna zakrivljenost padine	meanPLAN	$\text{meanPLAN} \leq 0$

Uklanjanje "lažnih" kandidata (6)


U ovom koraku su iz segmentacijom i klasifikacijom izdvojenih objekata mogućih jaruga (u nastavku se ovakve jaruge nazivaju kandidatima) uklonjeni svi oni objekti koji su pogrešno klasificirani kao jaruge. Pronalaženje takvih objekata izvršeno je vizualnom interpretacijom i provjerom svakog kartiranog objekta prema DOF-u visoke prostorne rezolucije (DGU, 2018.), pri čemu su objektima kandidatima dodijeljene binarne vrijednosti. Tako su "lažni" kandidati označeni s vrijednosti 0, dok su kandidati za koje je sa sigurnošću utvrđeno poklapanje sa stvarnim jarugama označeni s vrijednosti 1.

Procjena rezultata OBIA (7)

Procjena točnosti kartiranja jaruga OBIA pristupom napravljena je usporedbom podudarnosti 10 referentnih jaruga (R_j) s izdvojenim jarugama (C_i), kroz primjenu odabranih metričkih pokazatelja. Primjenom različitih metričkih pokazatelja moguće je kvantificirati podudarnost između referentnih podataka i generiranih objekata te procijeniti točnosti i uspješnost provedene segmentacije (Eisank i dr., 2014.). Za pokazatelje podudarnosti i točnosti kartiranja OBIA pristupom odabrana su sljedeća tri pokazatelja površinske točnosti (Cai i dr., 2018.): *Correctness* (COR), *Completeness* (COM) i *Overall quality* (OQ), te jedan pokazatelj lokacijske točnosti (Zheng i dr., 2005; Whiteside i dr., 2014.): *LOC measure* (LOC). Pri tome

se lokacijska točnost odnosi na ispravnost pozicioniranja izdvojenih objekata u odnosu na referentne objekte, a površinska točnost na sličnost oblika referentnih i generiranih objekata (Whiteside i dr., 2014.).

Preklapanje referentnih i izdvojenih jaruga izvedeno je unutar ArcGIS softvera. Na temelju provedenog preklapanja R_j sa C_i izračunata je površina *područja preklapanja* A_p (engl. *overlap area*) referentnih i kartiranih jaruge, te površina *precijenjenih područja* A_o (engl. *over-estimated area*) i površina *podcijenjenih područja* A_u (engl. *under-estimated area*) (Sl. 19.). Područje preklapanja A_p predstavlja ispravno kartirani prostor, unutar kojega se kartirani objekti podudaraju s referentnim objektima. Podcijenjeno područje A_u predstavlja dio referentnih objekata koji nije kartiran, a precijenjeno područje A_o prostor koji je kartiran kao jaruga, iako se nalazi izvan referentnog objekta.



Slika 19. Načelo određivanja točnosti izdvojenih objekata preklapanjem referentnih jaruga (A) s jarugama kartiranim OBIA pristupom (B)

Izračunate vrijednosti površine *područja preklapanja*, kao i podaci o lokaciji centroida kartiranih i referentnih jaruga iskorišteni su za izračun odabranih metričkih pokazatelja, koji su izračunati prema sljedećim formulama:

Formula za izračun *COR* (Cai i dr., 2018.):

$$COR = \frac{A_p}{A_{C_i}} \quad (5)$$

Gdje je:

A_p – područje preklapanja A_{C_i} – ukupna površina OBIA jaruge

Formula za izračun *COM* (Cai i dr., 2018.):

$$COM = \frac{A_p}{A_{R_j}} \quad (6)$$

Gdje je:

A_p – područje preklapanja A_{R_j} – ukupna površina referentne jaruge

Formula za izračun *OQ* (Cai i dr., 2018.):

$$OQ = \frac{A_p}{A_{R_j} + A_{C_i} - A_p} \quad (7)$$

Gdje je:

A_p – područje preklapanja A_{R_j} – ukupna površina referentne jaruge

A_{C_i} – ukupna površina OBIA jaruge

Formula za izračun *LOC* (Zhan i dr., 2005; Whiteside i dr., 2014.):

$$LOC_{R_j, C_i} = \sqrt{(X_{C_i} - X_{R_j})^2 + (Y_{C_i} - Y_{R_j})^2} \quad (8)$$

Gdje su:

X_{C_i} i Y_{C_i} – x i y koordinate centroida OBIA jaruge

X_{R_j} i Y_{R_j} – x i y koordinate centroida referentne jaruge

Vrijednosti *COR*, *COM* i *OQ* indeksa variraju u rasponu od 0 do 1, pri čemu veće vrijednosti označavaju veću podudarnost između referentnih i izdvojenih objekata, odnosno


veću točnost provedenog kartiranja (Whiteside i dr., 2014.). U slučaju *LOC mjere* vrijednosti bliže nuli predstavljaju idealno poklapanje centroida referentnih i testnih objekata, dok se za reprezentiranje sveukupne kvalitete izdvajanja objekata OBIA pristupom koriste prosječne vrijednosti *MeanLOC*, a za prikaz standardne devijacije vrijednosti *StDevLOC* (Whiteside i dr., 2014.).

6.4.2. Višekriterijska analiza podložnosti terena jaruženju

Raščlamba prostora otoka Paga prema podložnosti terena jaruženju provedena je kroz primjenu višekriterijske GIS analize (GIS-MCDA) namijenjene analiziranju pogodnosti prostora za pojavu jaruženja prema zadanim predisponirajućim kriterijima.

Višekriterijska analiza (MCDA) je napredna poddisciplina operacijskih istraživanja i upravljanja, posvećena razvoju metoda i alata za podršku u odlučivanju pri rješavanju složenih problema, koji uključuju više kriterija i ciljeva, često oprečnog karaktera (URL 6). Poseban tip višekriterijskih analiza predstavljaju višekriterijske GIS analize, koje kombiniraju funkcije GIS-a namijenjene prikupljanju, spremanju, obradi i analiziranju prostornih podataka s metodama i procedurama višekriterijskih analiza, koje služe definiranju odnosa između ulaznih podataka i rezultatnih podataka i karata (Malczewski, 2004; Greene i dr., 2011.).

Višekriterijska GIS analiza može se definirati kao proces transformiranja i kombiniranja geografskih prostornih podataka u svrhu dobivanja novih informacija o objektu proučavanja, nužnih za donošenje određenih odluka (Borouhaki i Malczewski, 2010; Malczewski, 2015.). Pri tome se odluka može odrediti kao izbor između alternativa, koji da bi bio racionalan mora biti donesen na temelju određenih kriterija, odnosno smjernica koje se koriste za donošenje te odluke (Eastman, 1999.). Alternativa se može definirati kao opcionalni smjer aktivnosti, kojeg donosioc odluke mora izabrati na temelju optimalnih kriterija (Malczewski, 2006.). Međusobna usporedba i vrednovanje utjecaja više različitih hijerarhijski posloženih kriterija određuje pogodnost ili podložnost određenog prostora nekoj pojavi ili procesu (Malczewski, 2015.). Primjena višekriterijske GIS analize sastoji se od ukupno šest koraka (Sl. 20.):



Slika 20. Tijek primijenjene višekriterijske GIS analize (prema Eastman, 1999.)

Postavljanje ciljeva/definiranje problema (1)

Osnova svake GIS-MCDA je postavljanja ciljeva, odnosno određivanje problema kojega se nastoji riješiti provedbom analize. Pri tome postavljeni cilj, da bi bio ostvariv, mora biti određen (*specific – S*), mjerljiv (*measurable – M*), ostvariv (*attainable – A*), relevantan (*relevent – R*) te vremenski ograničen (*time-bound – T*) (*eng. – SMART – pametan*) (URL 7). U okviru proučavanja podložnosti terena jaruženju osnovni cilj primjene GIS-MCDA je raščlamba prostora otoka Paga prema vjerojatnosti pojave jaruženja.

Određivanje kriterija i ograničenja (2)

Slijedi određivanje kriterija i ograničenja koji utječu na izlazni rezultat. Da bi se mogla provesti analiza podložnosti terena jaruženju, bilo je potrebno odabrati kriterije i ograničenja koji utječu na vjerojatnost pojave jaruženja na nekom prostoru.

Treba napomenuti kako postoje dva tipa kriterija unutar GIS-MCDA okruženja. Prvi tip kriterija naziva se Boolean kriterij, a može ga se smatrati kriterijem ograničavanja, koji se bazira na binarnom (*true/false*) iskazu pogodnosti nekog kriterija za odluku koja se razmatra (Jiang i

Eastman, 2000.). Tako primjerice svi kriteriji koji su relevantni za određenu odluku (npr. pojavnost jaruženja na nekom prostoru) imaju vrijednost 1 (*true*), dok kriteriji koji nisu pogodni imaju vrijednost 0 (*false*). U istraživanju podložnosti terena jaruženju ovaj tip kriterija je vrlo koristan, jer omogućava osnovnu raščlambu prostora na područja na kojima može doći do pojave jaruženja (*I – true*) te na područja na kojima ne može doći do pojave jaruženja (npr. vodene površine – *false*). Drugi tip kriterija čine čimbenici, odnosno kriteriji koji u određenoj mjeri, pozitivno ili negativno utječu na prikladnost određene alternative za donošenje odluke, što se može iskazati različitim stupnjevima prikladnosti. Pri tome kriteriji nisu ograničeni na binarni iskaz pogodnosti, već mogu biti iskazani kao kontinuirani brojčani prikaz pogodnosti, prema određenoj ljestvici (Eastman, 1999.).

Detaljnom analizom postojeće literature vezane za primjenu GIS-MCDA analize za proučavanje podložnosti terena jaruženju, odabrano je 10 čimbenika koji utječu na pojavnost jaruženja te dva ograničavajuća kriterija, okupljena u jedinstveni Boolean kriterij. U tablici 4. dan je pregled odabranih kriterija za GIS-MCDA, dok je detaljan prikaz procesa izrade svakog pojedinog odabranog kriterija dan nakon objašnjenja metodologije GIS-MCDA.

Standardizacija kriterija (3)

Da bi različiti kriteriji bili međusobno usporedivi, potrebno ih je ujednačiti na način da se svi podaci svedu na jednaku brojčanu skalu (npr. 0 – 1 ili 1 – 5), kroz proces koji je poznat kao standardizacija kriterija (Malczewski, 2015.). Osnovni pristup standardiziranju različitih kriterija su *Fuzzy Membership Functions* koje reklasificiraju ulazne podatke na skalu od 0 do 1, na temelju niza specifičnih funkcija (npr. linearna funkcija, Gaussova funkcija, itd.), pri čemu donosioci odluka trebaju prema svom iskustvu i stručnosti prosuditi koja funkcija bi najbolje odgovarala standardiziranju određenih podataka (Eastman, 2006.).

Odabranih 10 kriterija standardizirano je na brojčanu skalu 1 – 5 uz pomoć alata *Reclassify*, na način da su ocjenu 1 dobili najmanje pogodne klase određenog kriterija, a ocjenu 5 najpogodnije klase. Prikaz reklasificiranih kriterija i njihovih standardiziranih vrijednosti dan je u poglavlju 8.

Određivanje težinskih koeficijenata (4)

Nakon odabira kriterija i njihove standardizacije slijedi određivanje težinskih koeficijenata, koji služe diferencijaciji odabranih kriterija prema njihovoj važnosti, odnosno razini utjecaja na odluku ili model (Malczewski, 2004.). Postoji više metoda za određivanje težinskih koeficijenata odabranih kriterija, a kao najprikladnija metoda odabran je *Analitički*

Tablica 4. Prikaz odabranih kriterija za GIS-MCDA (A) i autora koji su u svojim radovima koristili pojedine kriterije (B)

	#	Odabrani kriteriji (A)	Autori (B)
Primarni morfometrijski parametri	1.	Nagib padine	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	2.	Orijentacija padine	Conforti i dr., 2011; Rahmati i dr., 2016.
	3.	Planarna zakrivljenost	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	4.	Profilna zakrivljenost	Conoscenti i dr., 2012.
	5.	LS Faktor	Conforti i dr., 2011; Lucà i dr., 2011.
Sekundarni morfometrijski parametri	6.	Topografski indeks vlažnosti (TWI)	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	7.	Indeks snage toka (SPI)	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	8.	Površina slijeva jaruge (km ²)	-
Ostali parametri	9.	Vegetacijski pokrov	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	10.	Pedološki pokrov	Agnesi i dr., 2011; Conforti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2012; Rahmati i dr., 2016.
	11.	Boolean	-

hijerarhijski proces (engl. *analytical hierarchy process (AHP)*), koji omogućava provjeru subjektivnosti i dosljednosti pridodavanja težinskih koeficijenata kroz omjer konzistentnosti (engl. *Consistency ratio (CR)*) (Saaty, 1990.). AHP se može okarakterizirati kao teorijski pristup mjerenju utjecaja pojedinih kriterija na određeni ishod, koji na temelju prosudbi stručnjaka međusobno uspoređuje parove kriterija i izvodi ljestvicu njihovog vrednovanja (Saaty, 1980; Saaty, 2008.). Pri tome se usporedba kriterija izvodi na temelju ljestvice apsolutnih prosudbi, koje predstavljaju mjeru u kojoj određeni kriterij dominira nad drugim kriterijem, u odnosu na određeni atribut (Saaty, 2001.). Prednost korištenja AHP za određivanje težinskih koeficijenata pojedinih kriterija GIS-MCDA svakako je mogućnost međusobne usporedbe svih korištenih kriterija, ali i mogućnost provjere objektivnosti dodijeljenih težinskih koeficijenata kroz dane vrijednosti CR (Saaty, 1980.). Pri tome je određivanje težinskih koeficijenata valjano ako je CR manji od 0,1. U slučaju većih vrijednosti dodijeljeni težinski koeficijenti trebaju biti ponovno određeni. Omjer konzistentnosti računa se prema sljedećoj formuli (Saaty, 1980.):

$$CR = CI / RI \quad (9)$$

gdje je:

CI = indeks konzistentnosti RI = indeks slučajne dosljednosti

Indeks konzistentnosti (CI) računa se prema formuli:

$$CI = (\lambda_{\max} - n) / (n - 1) \quad (10)$$

gdje je:

λ_{\max} = Principal Eigen Value n = broj kriterija

λ_{\max} se računa prema formuli:

$\lambda_{\max} = \Sigma$ proizvoda između prioritarnog vektora svakog elementa i umnoška stupca

Okupljanje (*agregiranje*) kriterija (5)

Okupljanje kriterija i njihovih težinskih koeficijenata obavljeno je prema sljedećoj formuli (Easman, 1999.):

$$P = \sum w_i X_i * \prod C_j \quad (11)$$

gdje je:

P = pogodnost

C_j = ograničenje j

w_i = težinski koeficijent dodijeljen kriteriju

Σ = suma ponderiranih kriterija;


Π = umnožak ograničenja (1 – pogodno, 0 – nepogodno)

X_i = vrijednost kriterija

Navedena formula implementirana je u GIS uz pomoć *Raster calculator* alata i *Spatial Analyst* ekstenzije.

Procjena rezultata (6)

Procjena pouzdanosti i točnosti GIC-MCDA modela predstavlja ključni korak u procesu modeliranja vjerojatnosti, bez kojega nije moguće utvrditi vjerodostojnosti i znanstvenu utemeljenost izrađenih modela (Chung i Fabbri, 2003; Feizizadeh i dr., 2014.). Procjena rezultata izrađenih modela podložnosti terena otoka Paga jaruženju testirana je preklapanjem podataka o postojećim jarugama s izrađenim GIS-MCDA modelima podložnosti terena jaruženju, pri čemu je optimalni model odabran prema značajkama *operativnih karakterističnih krivulja* (engl. *receiver operating characteristics curve – ROC*). ROC krivulja predstavlja dijagram kod kojega su vrijednosti *stvarnog pozitivnog postotka* (engl. *true positive rate – TPR*) prikazane na y osi stavljene u odnos s vrijednostima *lažnog pozitivnog postotka* (engl. *false positive rate – FPR*) prikazanog na osi x dijagrama (Brown i Davis, 2006.). Procjena točnosti modela ROC pristupom napravljena je na temelju dva testna skupa podataka o postojećim jarugama: *referentne jaruge generirane ručnom digitalizacijom prema DOF-u visoke prostorne rezolucije (1)* te *jaruge izdvojene OBIA pristupom (2)*. Pri tome je proces obrade podataka i izrade ROC krivulja automatiziran unutar besplatno dostupnog **Dinamica EGO 4 4.0.5.** modeling programa, na temelju odabranih ulaznih podataka (Sl. 21.) (Mas i dr., 2013.).



Slika 21. Ulazni podaci za izradu ROC krivulja (A – model podložnosti jaruženju; B – binarni prikaz referentnih jaruga)

Unutar **Dinamica Ego** programa je također za svaki izrađeni model automatski izračunata *površina ispod ROC krivulje* (engl. *area under curvature* – AUC) vrijednost. Vrijednosti AUC prikazuju uspješnost i točnost određenog modela u odnosu na referentne podatke, pri čemu se razlikuju *odlični* (AUC = 0,9 – 1), vrlo *dobri* (AUC = 0,8 – 0,9), *dobri* (AUC = 0,7 – 0,8), *loši* (AUC = 0,6 – 0,7), te *neuspješni modeli* (AUC = 0,5 – 0,6) (URL 8).

Odabrani kriteriji višekriterijske analize podložnosti terena jaruženju

U nastavku je dano kraće objašnjenje metodologije prikupljanja i obrade pojedinih odabranih kriterija višekriterijske analize podložnosti terena jaruženju. Osam morfometrijskih i hidroloških kriterija izdvojeno je iz 15 metarskog DMR-a otoka Paga u *ArcGIS* programu uz pomoć *Spatial Analysis* ekstenzije, koja sadrži niz korisnih alata za obradu rasterskih podataka i obavljanje raznovrsnih prostornih analiza (URL 9).

Kriteriji izdvojeni iz DMR-a otoka Paga se mogu podijeliti na primarne i sekundarne morfometrijske parametre. Primarni morfometrijski parametri su oni parametri koji se izravno izvode iz DMR-a, a koriste se za opisivanje morfologije reljefa (Wilson i Gallant, 2000; Šiljeg, 2013.). Sekundarni morfometrijski kriteriji nazivaju se još i složenim parametrima, jer nastaju kombinacijom dva, ili više primarna morfometrijska parametra (Wilson i Gallant, 2000.). Od primarnih morfometrijskih parametara izdvojeni su nagib padina (*slope*), ekspozicija padina (*aspect*), profilna zakrivljenost (*profile curvature*), i planarna zakrivljenost (*planar curvature*), dok su od sekundarnih morfometrijskih parametara izdvojeni topografski indeks vlažnosti (*topographic wetness indeks – TWI*), LS faktor (*LS factor*), indeks snage toka (*stream power indeks- SPI*) i veličina sliva većih jaruga (*watershed - WAT*).

Pripremljeni kriteriji višekriterijske analize reklasificirani su u *ArcGIS* softveru ako da imaju vrijednosti od 1 – 5, ovisno o njihovom utjecaju na proces jaruženja.

Detaljan opis obilježja odabranih kriterija, kao i njihovog utjecaja na pojavnost i intenzitet jaruženja dan je u poglavlju 8., dok je u nastavku dano metodološko objašnjenje procesa izrade 11 odabranih kriterija. Nerijetko postoje različite metode za izračun pojedinog morfometrijskog parametra, pri čemu se dobivene vrijednosti u pikselima mogu razlikovati zavisno o primijenjenoj metodi (Jennes, 2012.). Zbog toga je u nastavku dan kraći pregled algoritama korištenih za izradu pojedinih primarnih i sekundarnih morfometrijskih kriterija.

i. Izračun primarnih morfometrijskih parametara

Unutar rasterski orijentiranog GIS okruženja vrijednosti pojedinog piksela većine primarnih morfometrijskih parametara se određuju na temelju pokretne matrice od 3x3 piksela

(Šiljeg, 2013.). Pri tome se vrijednost središnjeg piksela izračunava na temelju vrijednosti osam okružujućih piksela i primjene formula za izračun određenog parametra. Detaljnije objašnjenje korištenih algoritama za izdvajanje primarnih morfometrijskih parametara može se naći u Šiljeg (2013.).

Nagib padine

Nagib (engl. *Slope (SLO)*) predstavlja mjeru strmine površine nekog terena u određenom smjeru (De Smith i dr., 2007.) Iako postoje različite metode za izračun nagiba unutar *Spatial Analyst* ekstenzije, u ovome radu je korištena Hornova metoda (Horn, 1981; Jennes, 2012; Šiljeg, 2013.), koja je korištena u ovom radu. Vrijednosti nagiba izvedene su uporabom alata *Slope*, koji unutar pomične rešetke od 3 * 3 rasterske ćelije izračunava nagib padine za središnju ćeliju, na temelju maksimalne stope promjene vrijednosti visina između središnje ćelije i okružujućih susjednih ćelija (Zeverbergen i Thorne, 1987; Šiljeg, 2013.). Vrijednosti nagiba padine mogu se iskazati u stupnjevima (0 – 90°) ili postocima (0 – 100 %), dok su u ovom radu odabrani stupnjevi, kako bi se mogla provesti standardna geomorfološka klasifikacija nagiba (IGU, 1968.).

Formula za izračun nagiba padine (Horn, 1981; Moore i dr., 1991.):

$$N (^{\circ}) = \sqrt{G^2 + H^2} \left(\frac{180}{\pi}\right) \quad (12)$$

gdje je:

G = stopa promjene u smjeru x (istok-zapad)

H = stopa promjene u smjeru y (sjever-jug)

Ekspozicija padine

Ekspozicija padine (engl. *Aspect*) predstavlja orijentaciju padine određenu u smjeru kazaljke na satu prema kutu kojeg zatvaraju referentni pravac i pravac padine, pri čemu se za referentni pravac najčešće uzima smjer sjevera (Šiljeg, 2013; Florinsky, 2016.). Unutar ekstenzije *Spatial Analyst* vrijednosti ekspozicije padina se računaju prema Hornovoj metodi (Jennes, 2012.). Vrijednosti ekspozicije padina iskazuju se u stupnjevima (0 – 360°), s iznimkom zaravnjenih područja kojima se pridodaje vrijednost -1.

Formula za izračun ekspozicije padine (Horn, 1981; Moore i dr., 1991.):

$$A = 180^\circ - \arctan\left(\frac{H}{G}\right) + 90^\circ\left(\frac{G}{|G|}\right) \quad (13)$$

gdje je:

G = stopa promjene u smjeru x (istok-zapad)

H = stopa promjene u smjeru y (sjever-jug)

Profilna zakrivljenost padine

Profilna zakrivljenost padine (engl. *Profile curvature*) određena je kao zakrivljenost padine u pravcu najveće strmine, gledano u odnosu na hipotetsku vertikalnu površinu koja siječe padinu u svakom njezinom segmentu (Šiljeg, 2013.). Iako postoji više metoda za određivanje profilne zakrivljenosti, unutar korištene *Spatial Analyst* ekstenzije je primijenjen Zevenbergen i Thorne pristup, koji je korišten za izradu profilne zakrivljenosti padina otoka Paga (Jennes, 2012; Šiljeg, 2013.). Negativne vrijednosti profilne zakrivljenosti predstavljaju konkavne padine, pozitivne vrijednosti konveksne padine, a nulom su označene zaravnjene padine.

Formula za izračun profilne zakrivljenosti (Zeverbergen i Thorne, 1987; Šiljeg, 2013.):

$$\emptyset = -2\left(\frac{DG^2 + EH^2 + FGH}{G^2 + H^2}\right) \quad (14)$$

Planarna zakrivljenost padine

Planarna zakrivljenost (engl. *Planar curvature (PLAN)*) može se odrediti kao zakrivljenost padine u sekanti ortogonalnoj na pravac najveće strmine (Šiljeg, 2013.). Negativne vrijednosti planarne zakrivljenosti karakterizira konkavni oblik padine, padine nulte vrijednosti predstavljaju pravocrtne padine, a pozitivne vrijednosti označavaju konveksne padine.

Formula za izračun planarne zakrivljenosti (Zeverbergen i Thorne, 1987; Šiljeg, 2013.):

$$\omega = 2\left(\frac{DH^2 + EG^2 + FGH}{G^2 + H^2}\right) \quad (15)$$

ii. Izračun sekundarnih morfometrijskih parametara

Za razliku od primarnih morfometrijskih parametara, koji su izravno izdvojeni iz DMR-a kroz primjenu različitih algoritama, sekundarni morfometrijski parametri su izračunati na temelju dva, ili više primarna parametra.

Topografski indeks vlažnosti

Topografski indeks vlažnosti, poznat i kao kombinirani topografski indeks (engl. *compound topographic index*) predstavlja mjeru potencijalne vlažnosti određenog terena, koja omogućava izdvajanje i razlikovanje prostora zasićenih vodom (npr. doline, uvale, ponikve, jaruge, itd.), od prostora manje zasićenosti (npr. grebeni, kukovi, vrhovi, strmije padine) (Wilson i Gallant, 2000; Florinsky, 2016.). Vlažnost terena određuje se na temelju modela otjecanja (*flow direction*) i iz njega izvedenog modela akumulacije (*flow accumulation*) te modela nagiba terena (*slope*), zbog čega ovaj pokazatelj spada u sekundarne, odnosno složene morfometrijske pokazatelje .

Formula za izračun TWI (Moore i dr., 1991.):

$$TWI = \ln\left(\frac{A_s}{\tan \beta}\right) \quad (16)$$

gdje je:

A_s = specifično slivno područje (flow accumulation)

$\beta(^{\circ})$ = nagib padine u istraživanoj točki, odnosno pikselu

Indeks snage toka (SPI)

Indeks jačine vodotoka (SPI) kvantificira potencijalnu erozivnu snagu površinskog otjecanja, a zasnovan je na pretpostavci da je protok proporcionalan veličini specifičnog slivnog područja vodotoka (Florinsky, 2016.). Indeks jačine vodotoka može se primijeniti za izdvajanje područja na kojima prevladavaju denudacijski procesi i na kojima treba primijeniti mjere zaštite od erozije (Moore i dr., 1991; Wilson i Gallant, 2000.). SPI se izračunava prema sljedećoj formuli (Moore, 1991.):

$$SPI = \ln(A_s \times \tan \beta) \quad (17)$$

gdje je:

A_s = specifično slivno područje

$\beta(^{\circ})$ = nagib padine u istraživanoj točki, odnosno pikselu rasterske rešetke

LS Faktor

Postoje različiti načini izračuna LS faktora (engl. *LS factor*), dok se unutar rasterski orijentiranog GIS-a najčešće primjenjuje sljedeća jednadžba (Zhang, 2013.):

$$LS = \left(\frac{A_s \times \text{prostorna rezolucija DMR} - a}{22.13} \right)^{0.4} \times \left(\frac{\sin \beta}{0.0896} \right)^{1.3} \quad (18)$$

gdje je:

A_s = specifično slivno područje

$\beta(^{\circ})$ = nagib padine u određenom pikselu rasterske rešetke

Specifično slivno područje (A_s) koristi se kao rasterska interpretacija L faktora, jer ono predstavlja površinu koja otječe u određenu rastersku ćeliju.

Specifično slivno područje (km²)

Specifično slivno područje (engl. *watershed*) izdvojeno je iz DMR-a otoka Paga uz pomoć *Hydrology* skupa alata okupljenih unutar *Spatial Analyst* ekstenzije. U prvom redu su za pripremu potrebnih modela otjecanja korišteni alati *Fill*, *Flow direction* te *Flow accumulation*, na temelju kojih je kasnije alatom *Watershed* napravljen model *specifičnih slivnih područja* otoka Paga. Izdvojenim slivovima otoka Paga je izračunata površina u km², nakon čega su slivovi klasificirani prema Jenksovoj metodi klasifikacije.

iii. Izvedba ostalih parametara

Pedološki pokrov

Podaci o pedološkom pokrovu za prostor otoka Paga preuzeti su s listova *Osnovne pedološke karte Republike Hrvatske* u mjerilu 1:50 000 (Bogunović i Šmanjak, 1983.). Da bi podaci bolje odgovarali ostalim krupnije kartiranim parametrima naknadno su obrađeni i nadopunjeni metodom fuziranja prema javno dostupnim digitalnim ortofoto snimcima (DOF – PR = 0,5 m). Metoda fuziranja (engl. *data fusion*) predstavlja proces integriranja podataka iz nekoliko izvora, u svrhu izrade kvalitetnijeg modela (Castanedo, 2013.). Na prostoru otoka Paga ukupno je s pedoloških karata u mjerilu 1:50 000 izdvojeno pet klasa pedološkog pokrova: antropogeno tlo na flišu (1), crvenica (2), litosol (3), močvarno-glejna tla (4), smeđe tlo na vapnencu (5), dok su vodene površine (6) usklađene s vodenim površinama klasificiranim sa Sentinel 2 snimaka.

Vegetacijski pokrov

Vegetacijski pokrov izdvojen je sa Sentinel 2 satelitskih snimaka (URL 10) metodom nadzirane klasifikacije u *Erdas Imagine* softveru. Prostorna rezolucija korištenih satelitskih snimaka je 10 m, što je omogućilo detaljno izdvajanje različitih tipova vegetacijskog pokrova. Ukupno je izdvojeno sljedećih šest različitih tipova vegetacijskog pokrova: zamočvarene površine (3), šumske površine (4), makija (5), sub-mediteranski travnjaci (6), kamenjarski travnjaci (7), poljoprivredne površine (8), te kamenjar (9).

Boolean kriterij

Metodom nadzirane klasifikacije izdvojena su urbano-industrijska područja (1) i vodene površine (2) otoka Paga, koja su iskorištena za pripremanje Boolean kriterija. Pri tome vodene površine i urbano-industrijske površine predstavljaju područja na kojima ne može doći do pojave jaruženja te im je zbog toga dodijeljena vrijednost 0.


6.4.3. Određivanje prostornog obuhvata jaruge Santiš i izdvajanje linije čela jaruge

Određivanje prostornog obuhvata jaruge Santiš provedeno je na temelju DMP-a prostorne rezolucije 2 cm, napravljenog na temelju aerofotogrametrijskih snimaka, koji se pokazao kao model maksimalne kvalitete. S obzirom na to da je prilikom proučavanja literature uočen učestali problem točnog definiranja prostornog obuhvata jaruga (Casalí i dr., 2015.), predložen je novi metodološki pristup, zasnovan na korištenju *infleksijskih linija* izdvojenih iz DMP-a za određivanje obuhvata jaruge.

Pri izdvajanju infleksijskih linija iz DMP-a izveden je rasterski prikaz lokalnog reljefa (engl. *local relief*), iz kojega je bilo moguće izdvojiti infleksijske linije. Lokalni reljef predstavlja varijaciju minimalnih i maksimalnih visina reljefa unutar određenog lokalnog područja (URL 11). Infleksijske linije su iz DMP-a izdvojene uz pomoć alata *Focal statistics* iz ArcGIS ekstenzije *Spatial Analysis*, koji omogućava analizu raspona visina unutar korisničko definiranog lokalnog područja. Unutar alata *Focal statistics* oblik i veličina lokalnog područja određeni su oblikom (*neighborhood*) i veličinom (*height* i *width*) pokretnog prozora, unutar kojega se za vrijednosti središnjeg piksela izvodi zadani statistički izračun (*statistics type*) (Sl. 22.).

Vizualnom usporedbom izlaznih rezultata različitih oblika i veličina pokretnog prozora

zaključeno je kako najprikladniji rezultat pruža pokretni prozor pravokutnog (*rectangle*) oblika te veličine 3×3 piksela. Tip izračuna statistike je postavljen na RANGE kako bi se za svaki središnji piksel izračunao raspon između minimalne i maksimalne visine. Vrijednosti izrađenog rasterskog prikaza lokalnog reljefa na istraživanom području variraju od 0 m do 2,34 m, gdje niske vrijednosti predstavljaju dijelove reljefa sa slabom varijacijom raspona visina




Slika 22. Primjer izračuna sumarne statistike za središnji piksel pravokutnog pokretnog prozora veličine 3×3 piksela (prema URL 12)

unutar zadane površine od 3×3 piksela, značajne za zaravnjenije dijelove istraživanog područja. S druge strane, više vrijednosti lokalnog reljefa označavaju one dijelove istraživanog područja na kojima unutar zadane površine od 3×3 piksela dolazi do nagle promjene nagiba terena. Vrijednosti rasterskog prikaza lokalnog reljefa su reklasificirane, pri čemu su svi pikseli s vrijednostima većim od 0,30 m klasificirani kao infleksijske linije. Vizualnom usporedbom određeno je kako vrijednost od 0,30 m predstavlja idealnu vrijednost praga za izdvajanje infleksijskih linija, jer je kod manjih ili većih vrijednosti primijećena pojava različitih artefakata.

Infleksijske linije su automatski vektorizirane iz izrađenog rasterskog prikaza uz pomoć alata za automatsku vektorizaciju rasterskih predložaka, okupljenih unutar ArcScan ekstenzije. Prilikom toga je bilo potrebno definirati optimalne parametre automatske vektorizacije (*Vectorisation settings*). Od parametara automatske vektorizacije opcije križanja (*intersection solution*) postavljena je na *Median* (medijan ili središnja vrijednost), koji se preporuča za vektorizaciju prirodnih objekata (URL 13). S obzirom na to da su infleksijske linije trebale biti što vjernije vektorizirane, parametar zaglađivanja linija (*smoothing weight*) je smanjen na minimalni mogući iznos. Preostale infleksijske linije predstavljaju rubne dijelove jaruge Santiš određene promjenom visine od minimalno $30 \text{ cm}/9 \text{ cm}^2$ ($30 \text{ cm}/3 \times 3$ piksela) (Sl. 23.). U konačnici su iz izdvojenih infleksijskih linija na temelju vizualne usporedbe s DOF-om otklonjene sve one linije koje ne predstavljaju rubne dijelove jaruge Santiš. S obzirom da na

temelju infleksijske linije nije moguće odrediti cijeli prostorni obuhvat jaruge Santiš, praznine su nadopunjene ručnom vektorizacijom (Sl. 23.) u mjerilu 1:100, prema DOF-u prostorne rezolucije i prikazu reljefa sjenjčanjem (*hillshade*) prostorne rezolucije 1 cm. Rub jaruge prema morskoj površini određen je izohipsom od 0 m. Ukupna kartirana površina jaruge Santiš iznosi 1155,105 m².



Slika 23. Načini izdvajanja linije prostornog obuhvata jaruge Santiš

Ipak treba istaknuti jedan nedostatak predložene metode, a to je korištenje ručne vektorizacije za kartiranje prostornog obuhvata jaruge. Ručna vektorizacija je podložna subjektivnosti osobe koja vrši kartiranje, zbog čega u daljnjim istraživanjima treba težiti pronalasku potpuno automatiziranog i metrički opravdanog pristupa izdvajanju prostornog obuhvata jaruge.

6.4.4. Razvoj kvantitativnih pokazatelja za praćenje intenziteta jaruženja

Pronalaženje prostorno-vremenskih promjena nastalih na unutar jaruge Santiš napravljena je na temelju usporedbe dva periodička DMP-a, izrađena iz aerofotogrametrijskih podataka, prikupljenih u razmaku od šest mjeseci. Pri tome je uz pomoć alata *Raster calculator* napravljen rasterski prikaz razlike između dva odabrana DMP-a (DMP_{RAZ}), koji je izračunat prema formuli:

$$DMP_{RAZ} = DMP_2 - DMP_1 \quad (19)$$

Gdje je:

DMP_1 = DMP inicijalnog stanja

DMP_2 = DMP završnog stanja

DMP_{RAZ} = model promjene

Pri tome pozitivne vrijednosti DMP_{RAZ} predstavljaju *akumulaciju materijala*, a negativne vrijednosti *trošenje materijala*.

Osnovni korak nakon izrade modela prostorno-vremenskih promjena predstavljala je *filtracija* mogućih grešaka u izrađenom modelu. Ove greške odraz su kvalitete korištenih digitalnih modela površina. Kvaliteta izvedenog rasterskog prikaza (modela) ustanovljenih promjena ovisi o kvalitete korištenih DMP-ova, koja je pak rezultat pogreški uzrokovanih *značajkama korištene opreme (1)*, te *pogreškama nastalih prilikom procesa modeliranja (2)*. S obzirom na to da su precizne xyz lokacije korištenih orijentacijskih točaka (potrebnih za izradu DMP-ova) prikupljane s RTG GPS-om Stonex 10, njihova preciznost ovisi o preciznosti korištenog uređaja. Horizontalna preciznost Stonex 10 uređaja iznosi 0,8 cm, a vertikalna 1,5 cm (URL 3), što određuje maksimalnu pogrešku uzrokovanu značajkama korištene opreme. Ako se tome pridoda prosječna pogreška dva korištena DMP-a (*nastala prilikom modeliranja*), koja iznosi 2,707 cm, tada maksimalna pogreška korištenih modela iznosi 3,507 cm horizontalno, odnosno 4,207 cm vertikalno. Da bi se otklonio utjecaj navedenih pogreški na konačni model prostorno-vremenskih promjena, filtracijom su uklonjene sve vrijednosti u rasponu od 0 – 5 cm, kao i maksimalne vrijednosti veće od $\pm 1,5$ m promjene. Maksimalne vrijednosti zabilježene su u samim krajnjim dijelovima izrađenog modela, gdje je zbog slabijeg preklapanja snimaka došlo do blage distorzije modela i pojave visinskih artefakata. Ovakvi artefakti uklonjeni su u procesu filtracije, jer su se javili na vrlo maloj površini izrađenog modela, te na prostoru od neznatnog značaja za ovo istraživanje. Nakon provedene filtracije konačne vrijednosti modela prostorno-vremenskih promjena su klasificirane manualnom metodom u sljedećih pet klasa intenziteta promjene: *vrlo slaba promjena* (0 – 5 cm), *slaba promjena* (5 – 10 cm), *srednja promjena* (10 – 25 cm), *intenzivna promjena* (25 – 50 cm) i *vrlo intenzivna promjena* (50 – 150 cm).

Na temelju navedenih DMP-ova je unutar *ArcGIS* i *Surfer 14* softvera izračunata promjena volumena unutar jaruge. Iz izračuna volumena su izbačeni svi dijelovi jaruge Santiš za koje je tijekom ranije objašnjenog procesa filtracije ustanovljeno da mogu predstavljati prostor pogreške (*klase 0 – 5 cm i >150 cm*), uzrokovanu smanjenom kvalitetom korištenih modela.

Ujedno je za potrebe rada unutar GIS-okruženja razvijen alat za automatizirano otkrivanje i kvantifikaciju nastalih prostorno-vremenskih promjena u poprečnim presjecima

jaruge (engl. *gully cross-sections (GCs)*). Napravljeni alat nazvan je GULIVER, sjedinjenjem engleskih riječi *gully* (jaruga) i *vertical* (vertikalno), čime se željelo asociirati na namijenu alata za praćenje vertikalnog pomaka unutar poprečnih presjeka jaruge. Za izradu GULIVER alata korištena je aplikacija *ModelBuilder*, unutar ArcGIS softvera. *ModelBuilder* je grafički programski jezik namijenjen izradi, editiranju i upravljanju modelima te automatizaciji i pojednostavljenju složenih struktura geoprocesiranja (URL 14). Velika prednost korištenja *ModelBuilder* aplikacije je mogućnost povezivanja i kombiniranja različitih, već postojećih alata iz *ArcToolbox-a*, u svrhu izrade u potpunosti novog alata. Uporabom *ModelBuilder* aplikacije izrađen je u potpunosti automatizirani alat, koji je primjenjiv za praćenje intenziteta jaruženja i u drugim istraživanjima.

Da bi se testirala uspješnost izrađenog alata, generirani podaci su uspoređeni s izmjerenim poprečnim presjecima jaruge Santiš, prikupljenim totalnom stanicom (*vidi* 6.2.2.). Pri tome je posebna pozornost dana usporedbi *vremenske učinkovitosti* te *metodološke susljednosti* ovih dviju metoda. Vremenska učinkovitost predstavlja brzinu uzorkovanja, koja je izračunata kao omjer između ukupnog vremena uzorkovanja i ukupnog broja prikupljenih uzoraka, prema formuli:

$$V_u = \frac{n_u}{t_u} \quad (20)$$

Gdje je:

V_u = brzina uzorkovanja n_u = broj uzoraka t_u = vrijeme uzorkovanja

Metodološka susljednost podrazumijeva identičnost izrađenih *GCs*, gdje je uspoređivano podudaranje idealnih *GCs* i izrađenih *GCs*. Susljednost provedene izmjere *GCs* jaruge Santiš određena je na temelju sinusoidnosti, koj predstavlja stupanj vijuganja određene linije u odnosu na referentnu, pravocrtnu liniju, a izračunava se prema formuli (Barada, 2017.):

$$S = \frac{l_{GCs}}{l_{REF}} \quad (21)$$

Gdje je:

S = sinusoidnost izrađenog *GCs* l_{GCs} = duljina izrađenog *GCs* l_{REF} = duljina idealnog, pravocrtnog *GCs*

6.5. Vizualizacija provedenih GIS analiza i obrađenih meteoroloških podataka

Ključan korak za interpretiranje obrađenih podataka i provedenih analiza, kao i diseminaciju ostvarenih rezultata ovog diplomskog rada predstavlja *vizualizacija*, koja je realizirana pomoću različitih softvera. Većina 2D kartografskih prikaza izrađena je uz pomoć *ArcMap 10.1* softvera, unutar kojega su okupljene raznovrsne korisne vizualizacijske tehnike. Pojedini kartografski prikazi nadopunjavani su unutar *Microsoft PowerPoint 2013*, koji je poslužio i za *skiciranje* određenih grafičkih prikaza. Vizualizacija napravljenih perspektivnih (3D) modela provedena je unutar *Surfer 14* te *ArcScene 10.1* softvera.

7. Kartiranje jaruga otoka Paga primjenom OBIA pristupa

Budući da je prilikom istraživanja uočena oskudnost osnovnih podataka o brojnosti i prostornom rasporedu jaruga na otoku Pagu, u ovom dijelu rada je na temelju objektno-orijentirane rasterske analize (*OBIA*) provedena sistematizacija i inventarizacija jaruga. Uz pomoć nje su, u skladu s kvalitetom trenutačno dostupnih podataka, kartirane veće jaruge na otoku.

Kartiranje postojećih jaruga važno je sa stajališta boljeg razumijevanja njihove prostorne rasprostranjenosti i osnovnih morfometrijskih značajki, kao i različitih čimbenika (npr. klimatski, topografski, pedološki, antropogeni, itd.) koji su povezani s njihovim oblikovanjem. Nadalje, kartiranje postojećih jaruga je od ključne važnosti za praćenje evolucije jaruga i intenziteta jaruženja, ali i bilježenje utjecaja jaruženja na degradaciju i odnošenje tla (Shruthi i dr., 2011.). S obzirom na izraženu varijabilnost prostorne rasprostranjenosti i morfometrijskih značajki jaruga, te njihovu nedostupnost, terensko kartiranje jaruga na većim površinama može biti vrlo izazovno, zbog čega se kartiranje ovih oblika uz pomoć podataka prikupljenih metodama iz područja daljinskih istraživanja pokazalo vrlo svrsishodnim (Shruthi i dr., 2014; Liu i dr., 2016.). Najjednostavniji oblik kartiranja jaruga na temelju rasterskih predložaka predstavlja kartiranje temeljeno na vizualnoj interpretaciji i ručnoj digitalizaciji digitalnih ortofoto snimaka visoke prostorne rezolucije (npr. Lončar, 2009.). Međutim, nedostatak ovakvog pristupa predstavljaju njegova dugotrajnost i subjektivnost, koju je moguće nadoknaditi većom automatizacijom procesa izdvajanja jaruga iz odgovarajućih rasterskih predložaka (Shruthi i dr., 2011.). Sukladno tome, nekoliko istraživanja je pokazalo kako jaruge mogu biti egzaktno identificirane i izdvojene s rasterskih snimaka visoke i srednje rezolucije kroz primjenu objektno-orijentirane rasterske analize (*OBIA*), zasnovane na korisničko-definiranim kombinacijama spektralnih, teksturalnih i geometrijskih značajki objekata koji predstavljaju jaruge (Shruthi i dr., 2011; Shruthi i dr., 2015; Wang i dr., 2014.). Za razliku od pikseli-orijentiranih analiza čiju osnovnu čini uniformna pravokutna pikselna struktura, *OBIA* u obzir uzima stvarne prostorne odnose među geografskim objektima. Zbog toga je na temelju vlastitih znanja moguće prilikom izdvajanja homogenih objekata iz zadanih rasterskih snimaka uspostaviti različita pravila, koja mogu znatno poboljšati rezultate izdvajanja i klasifikacije željenih morfoloških oblika (Blaschke, 2010; d'Oleire-Oltmanns i dr., 2014; Wang i dr., 2014.). Nadalje, za razliku od piksela objekti imaju odgovarajuće distinktivne oblike i veličine, koje je moguće kvantitativno opisati te dovesti u vezu s okolnim objektima (Blaschke, 2010.).

7.1. Parametri korišteni za izdvajanje jaruga

U nastavku je dan kraći pregled odabranih morfometrijskih parametara i njihove važnosti za pronalaženje i kartiranje jaruga.

Indeks masne bilance (MBI)

Indeks masne bilance (MBI) predstavlja mjeru za klasificiranje procesa koji utječu na erodiranje i akumuliranje materijala, gdje negativne vrijednosti MBI predstavljaju udubljenja u terenu u kojima prevladava taloženje materijala, a pozitivne vrijednosti uzvišenja na kojima prevladavaju denudacijski procesi (Möller i dr., 2012.). Budući da jaruge predstavljaju udubljenja u terenu primjena MBI parametra za potrebe izdvajanja jaruga OBIA pristupom zasniva se na pretpostavci da će objekti koji predstavljaju jaruge imati negativne vrijednosti MBI. Sukladno tome svi segmentacijom nastali objekti čije su *meanMBI* vrijednosti bile manje ili jednake nuli ($MBI \leq 0$) su klasificirani kao potencijalni "kandidati".

Nagib padine (SLO)

Iscrpnije pojašnjenje utjecaja nagiba padine na pojavnost jaruga i intenzitet jaruženja dan je u poglavlju 8. U OBIA pristupu nagib padine je korišten za uklanjanje svih segmentacijom nastalih objekata čije *meanSLO* vrijednosti se nalaze unutar klase *ravnica* ($0 - 2^\circ$) te strmci i litice ($> 55^\circ$), jer se u pravilu na ovakvim prostorima uobičajeno ne javljaju jaruge (Valentin i dr. 2005.).

Topografski indeks pozicije (TPI)

Topografski indeks pozicije (TPI) je pokazatelj relativnog topografskog položaja padine te se kao takav često koristi za klasifikaciju različitih morfoloških oblika (De Reu i dr., 2013.). Algoritam za izračun TPI određuje vrijednost središnjeg piksela na temelju razlike između visine središnjeg piksela i prosječne visine unutar predodređenog susjedstva (Wilson i Gallant, 2000.). TPI može imati pozitivne i negativne vrijednosti, pri čemu pozitivne vrijednosti indeksa ukazuju na niži položaj središnje rasterske ćelije u odnosu na okružujuće susjedstvo i obrnuto (De Reu i dr., 2013.). Izdvajanje jaruga na temelju TPI parametra se zasniva na pretpostavci da jaruge najčešće predstavljaju linearna udubljenja u terenu, čija je visina niža od okružujućeg terena. Sukladno tome za potrebe izdvajanja jaruga svi objekti s vrijednostima *meanTPI* < 0 su klasificirani kao potencijalne jaruge.

Topografski indeks vlažnosti (TWI)

Iscrpnije pojašnjenje utjecaja TWI na pojavnost jaruga i intenzitet jaruženja dan je u poglavlju 8. TWI indeks je korišten za izdvajanje i uklanjanje objekata nastalih segmentacijom koji su imali vrijednosti $meanTWI \leq 4$. Odabir ove vrijednosti temeljio se na pretpostavci da se jaruge javljaju na vodom zasićenijim dijelovima terena, zbog čega su svi objekti s manjim vrijednostima zasićenosti vodom uklonjeni.

Indeks snage otjecanja (SPI)

Iscrpnije pojašnjenje utjecaja SPI na pojavnost jaruga i intenzitet jaruženja dan je u poglavlju 8. Veće vrijednosti SPI ukazuju na izraženije i snažnije površinsko otjecanje, zbog čega su za izdvajanje jaruga kao potencijalni "kandidati" odabrani svi objekti sa $meanSPI \geq 0$. Odabir ovog praga temeljio se na pretpostavci da s jačim površinskim otjecanjem raste vjerojatnost za pokretanje jaruženja i nastanak jaruga.

Vertikalna udaljenost od drenažne mreže (VDC)

Vertikalna udaljenost od drenažne mreže predstavlja relativnu visinsku razliku između visine određenog piksela na zadanom DMR-u i visine odgovarajućeg piksela na rasterskom prikazu bazne razine drenažne mreže dobivene interpolacijom drenažnih tokova izdvojenih iz zadanog DMR-a (Möller i dr., 2012.). VDC je korišten za izdvajanje jaruga OBIA pristupom uz pretpostavku da se jaruge pretežito javljaju bliže baznoj razini drenažne mreže, gdje postoji veći potencijal za stvaranje kritične količine otjecanja potrebnog za pokretanje jaruženja, zbog čega su pri klasifikaciji korištene ograničavajuće vrijednosti $meanVDC \geq 0$ i $meanVDC \leq 50$.


Planarna zakrivljenost padine (PLAN)

Detaljnije pojašnjenje utjecaja planarne zakrivljenosti na pojavnost jaruga i intenzitet jaruženja dan je u poglavlju 8. S obzirom na to da jaruge predstavljaju linearna udubljenja u terenu, planarna zakrivljenost je u OBIA pristupu korištena za uklanjanje svih segmentacijom nastalih objekata čije su $meanPLAN$ vrijednosti veće od 0, jer takva područja predstavljaju uzvišenja na terenu te je pretpostavljeno da je vjerojatnost pojave jaruga na takvim terenima vrlo niska.

7.2. Uklanjanje "lažnih" jaruga kandidata

Od ukupno 2268 objekata, koliko ih je MRS algoritmom izdvojeno iz odabranih morfometrijskih parametara otoka Paga, nakon provedene klasifikacije preostalo je 384 *objekata kandidata*, koji prema odabranim klasifikacijskim parametrima predstavljaju potencijalne jaruge. Kako bi se iz 384 objekata kandidata izdvojili samo oni objekti koji uistinu predstavljaju postojeće jaruge provedena je filtracija potencijalnih objekata, pri kojoj su uklonjeni svi "lažni" kandidati jaruga. Međutim, zbog specifičnosti paške karbonatne podloge ponekad čak ni vizualnom interpretacijom objekata kandidata prema DOF-u visoke rezolucije ($PR = 0,5$ m) nije bilo moguće sa sigurnošću konstatirati predstavlja li određeni objekt uistinu jarugu, ili se radi o rezultatnoj pogrešci segmentacijskih i klasifikacijskih algoritama. Zbog toga su pri provođenju filtracije svi oni objekti kod kojih je prilikom vizualne interpretacije postojala barem i minimalna nesigurnost klasificirani kao "lažni" kandidati. Ovakav pristup rezultira sveukupno manjim brojem objekata koji su klasificirani kao stvarne jaruge, ali ujedno maksimalno smanjuje pogreške vezane za nesigurnost prosudbe, odnosno antropogeni čimbenik. Prilikom filtracije uočeno je kako se većina "lažnih" kandidata jaruga javlja na rubnim dijelovima modela, te strmijim padinama, što je zasigurno posljedica smanjenje kvalitete i točnosti korištenog DMR-a u ovakvim prostorima (Sl. 24. - A). Također ne iznenađuje činjenica da su površinom veći i dublji objekti kartirani znatno bolje od dimenzijama manjih jaruga (Sl. 24. - B), posebice ako se u obzir uzme da su za kartiranje korišteni morfometrijski parametri izvedeni iz DMR-a srednje kvalitete ($PR = 15$ m). U konačnici je nakon provedenog filtriranja 250 objekata kandidata klasificirano "lažnim" kandidatima jaruga, dok je za 135 objekata utvrđeno da uistinu predstavljaju postojeće jaruge, iz čega proizlazi kako 35,15% objekata kandidata uistinu predstavlja postojeće jaruge. Relativno nizak postotak uspješno klasificiranih objekata svjedoči o potrebi za detaljnijom razradom klasifikacijskih parametara u daljnjim istraživanjima, kojima bi se značajnije povećao postotak uspješnosti izdvajanja objekata koji uistinu predstavljaju jaruge.


Posebice bi u daljnjim istraživanjima trebalo u klasifikacijski korak uvrstiti druge, klasifikacijske parametre, poput onih korištenih u istraživanjima Shruthi i dr. (2011.). Također, u daljnjim istraživanjima poželjno bi bilo definirati u potpunosti automatiziran pristup filtraciji "lažnih" kandidata jaruga, kojim bi se dodatno smanjila subjektivnost cijelog procesa uklanjanja "lažnih" kandidata.



Slika 24. Filtracija objekata izdvojenih OBIA pristupom (A – pojava "lažnih" kandidata jaruga na prostoru obalnih strmaca; B1 – primjer izostanka kartiranja slabije izraženih jaruga; B2 – primjer lošijeg kartiranja dimenzijama manjih jaruga)

7.3. Procjena kvalitete kartiranja jaruga OBIA pristupom

Vizualnom interpretacijom izdvojenih objekata uočeno je kako je podudarnost kartiranih jaruga s referentnim jarugama zadovoljavajuća (Sl. 25.), ali i da generalno OBIA pristup predimensionira površinu kartiranih jaruga. Uočeno je i kako su kvaliteta i vjerodostojnost kartiranja jaruga bolja kod većih jaruga (Sl. 25. F, G, H, I, J), dok je podudarnost s referentnim podacima niža kod dimenzijama manjim jarugama (Sl. 25. B, C). Zanimljivo je kako jaruge duljine manje od 200 m uopće nisu kartirane, što se može pripisati ograničenosti korištenog DMR-a, čija prostorna rezolucija nije dostatna za kartiranje manjih morfoloških oblika.



Slika 25. Usporedba referentnih jaruga s jarugama kartiranim prema OBIA pristupu

Navedeni zaključci vizualne interpretacije podudarnost referentnih jaruga s jarugama izdvojenim OBIA pristupom potvrđeni su izradom površinskih metričkih pokazatelja (Tabl. 5.). Prosječne vrijednosti tri izračunata površinska pokazatelja dane su na Slici 26. Površinski pokazatelj *COR* predstavlja odnos između točno kartiranih površina (A_p) i ukupne kartirane površine (A_{C_i}), pri čemu je maksimalna vrijednost indeksa 1, koja označava 100 % točnost kartiranja površina (Cai i dr., 2018.). Iz dobivenih vrijednosti *COR* pokazatelja vidljivo je kako točnost kartiranja površina jaruga OBIA pristupom na temelju rasterskih podataka srednje kvalitete iznosi oko 46 % (MeanCOR = 46,51). Na temelju ovog pokazatelja moguće je zaključiti kako se znatan dio površine jaruga kartiranih OBIA pristupom nalazi izvan referentnih jaruga, odnosno kako je ranije spomenuta pretpostavka o prisutnosti predimenzioniranja potvrđena. Sljedeći izračunati površinski pokazatelj je *COM*, kojim se prikazuje zastupljenost točno kartiranih površina (A_p) u ukupnoj površini referentnih jaruga (A_{R_j}) (Cai i dr., 2018.). Prosječna zastupljenost iznosi oko 75 % (MeanCOM = 0,7521), iz čega se može zaključiti da je prostor unutar referentnih jaruga dosta dobro kartiran, odnosno da je sveukupno zastupljenost *podcijenjenih područja* A_U znatno manja u odnosu na zastupljenost *precijenjenih područja* A_O . Ovakav rezultat podupire raniji zaključak vizualne interpretacije o izraženijoj prisutnosti predimenzioniranja kod provedenog kartiranja jaruga OBIA pristupom. Pokazatelj *OQ* izjednačava vrijednosti *COR* i *COM* pokazatelja, čije vrijednosti mogu previše ovisiti o površini referentnih i kartiranih objekata (Cai i dr., 2018.), zbog čega ga se može smatrati najtočnijim od izrađenih površinskih pokazatelja točnosti OBIA kartiranja.


U konačnici je iz izrađenih površinskih pokazatelja kvalitete moguće zaključiti da kartiranje jaruga OBIA pristupom na temelju rasterskih podataka srednje rezolucije rezultira poprilično netočnim površinskim prikazom jaruga, zbog čega se ipak za potrebe detaljnijih studija preporuča korištenje kvalitetnijih rasterskih podataka.

Nakon procjene površinske točnosti jaruga kartiranih OBIA pristupom, napravljena je i procjena lokacijske točnosti, kojom se željelo utvrditi je li moguće točno utvrditi lokaciju jaruga na temelju OBIA pristupa i rasterskih podataka srednje rezolucije. Za potrebe procjene lokacijske točnosti kartiranja OBIA pristupom izračunate su vrijednosti LOC mjere, koje su dane u tablici 6. LOC mjera predstavlja euklidsku udaljenost između centroida referentnog objekta i klasifikacijom izdvojenog objekta, pri čemu manje vrijednosti ovog pokazatelja označavaju veću lokacijsku točnost kartiranja provedenog OBIA pristupom (Whiteside i dr., 2014.).

Tablica 5. Statistički površinski pokazatelji kvalitete kartiranja jaruga OBIA pristupom

REF jaruga (#)	Površina jaruge A_{R_j} (REF (km ²))	Površina jaruge A_{C_i} (OBIA (km ²))	Površina preklapanja A_p (km ²)	Precijenjena površina A_o (km ²)
1	0,1089	0,1429	0,0730	0,0698
2	0,0105	0,0241	0,0091	0,0149
3	0,0224	0,0437	0,0102	0,0334
4	0,0524	0,0839	0,0412	0,0427
5	0,0087	0,0128	0,0044	0,0084
6	0,0188	0,0324	0,0151	0,0173
7	0,0226	0,0376	0,0207	0,0169
8	0,0549	0,1109	0,0466	0,0643
9	0,0509	0,0945	0,0449	0,0496
10	0,0273	0,0277	0,0186	0,0091
Ukupno	0,3775	0,6104	0,2839	0,3265
REF jaruga (#)	Podcijenjena površina A_u (km ²)	Correctness (COR)	Completeness (COM)	Overall quality (OQ)
1	0,0359	0,5112	0,6704	0,4085
2	0,0014	0,3796	0,8679	0,3588
3	0,0122	0,2343	0,4567	0,1832
4	0,0112	0,4909	0,7856	0,4329
5	0,0042	0,3457	0,5119	0,2600
6	0,0037	0,4653	0,8032	0,4177
7	0,0019	0,5507	0,9148	0,5238
8	0,0082	0,4204	0,8502	0,3914
9	0,0061	0,4748	0,8810	0,4462
10	0,0087	0,6725	0,6806	0,5112
Ukupno	0,0936	0,4651*	0,7521*	0,4033*

*Prosječne vrijednosti izvedenih statističkih pokazatelja (MEAN)



Slika 26. Prosječne vrijednosti tri odabrana metrička pokazatelja površinske točnosti kartiranja jaruga OBIA pristupom (COR – *Correctness*; COM – *Completeness*; OQ - *Overall quality*)

Primijećeno je kako su najmanje vrijednosti *LOC* pokazatelja prisutne kod jaruga koje bilježe najveće vrijednosti površinske točnosti kartiranja, ali i da je u pravilu bolja lokacijska točnost kod površinom većih objekata. Prosječna vrijednost *LOC* pokazatelja iznosi 55,0326 m, iz čega proizlazi da lokacija kartiranih objekata u pravilu odstupa od referentnih jaruga za malo više od 55 m. Ako se u obzir uzme da je prostorna rezolucija DMR-a korištenog za kartiranje OBIA pristupom 15 m, tada je vidljivo da se ne radi o toliko velikom odstupanju, posebice ako se u obzir uzme da se radi o odstupanju od svega 3,6 piksela korištenog DMR-a.

Tablica 6. Statistički lokacijski pokazatelji kvalitete kartiranja jaruga OBIA pristupom

Statistički pokazatelj	LOC (m)
Minimum	13,3239
Maksimum	121,0102
Suma	550,3262
Prosječna vrijednost	55,0326
Standardna devijacija	32,4907


Navedeni rezultati potvrđuju postavljenu hipotezu kako je *moгуće primijeniti OBIA pristup za kartiranje jaruga na relativno velikim površinama prema rasterskim podacima srednje rezolucije*, ali da detaljnost i točnost takvog kartiranja još uvijek zaostaje za

konvencionalnim metodama (poput ručne digitalizacije) ili kartiranju prema rasterskim podacima visoke prostorne rezolucije. Iako je potvrđeno kako ukupno 135 objekta predstavljaju postojeće jaruge, neki od tih izdvojenih objekta predstavljaju zasebne kanale većih i složenijih jaruga. Zbog toga je u konačnici moguće izdvojiti 120 jaruga, različitih značajki i dimenzija. Ako se u obzir uzme da je u istraživanju Lončar (2009.) samo na prostoru srednjeg i južnog dijela otoka Paga zabilježeno postojanje 337 jaruga, može se zaključiti kako je stvarni, zbirni broj jaruga na cijelom otoku daleko veći od broja jaruga izdvojenih OBIA pristupom. Međutim, u obzir treba uzeti činjenicu da je izdvajanje jaruga OBIA pristupom u sklopu ovog diplomskog rada izvedeno na temelju DMR-a srednje prostorne rezolucije (PR = 15 m), zbog čega se može pretpostaviti kako bi se korištenjem kvalitetnijih rasterskih podataka moglo provesti daleko detaljnije kartiranje. Ako se pogleda metodološka susljednost izdvajanja jaruga OBIA pristupom te mogućnost primjene na razmjerno velikim područjima, kao što je otok Pag, može se ustvrditi da ova metoda ima velik potencijal za primjenu u raznovrsnim daljnjim istraživanjima. Posebice bi OBIA pristup mogao biti koristan za točno izdvajanje prostornog obuhvata pojedinih jaruga, što se pokazalo problematičnim prilikom provođenja analiza na razini jaruge Santiš, ali o čemu su pisali i drugi autori. Naime, za točno kvantitativno opisivanje geometrije jaruga egzaktno definiranje njihova prostornog obuhvata je nužno (Casalí i dr., 2015.).

7.4. Značajke jaruga izdvojenih OBIA pristupom


Prikaz prostornog rasporeda 120 jaruga kartiranih OBIA pristupom na prostoru otoka Paga dan je na Slici 28.

Prema podacima o pojavnosti jaruga izdvojenim OBIA pristupom jaruge se na otoku Pagu javljaju na ukupno 5,939 km² površine, što predstavlja 2,091% ukupne površine otoka. Kartirane jaruge su razvrstane prema njihovoj *složenosti*, *primijećenoj aktivnosti* te prevladavajućoj *orijentaciji* (Sl. 27.).



Slika 27. Udio jaruga prema orijentaciji (A); udio jaruga prema aktivnosti (B); udio jaruga prema složenosti (C)

Ako se u obzir uzme prevladavajuća orijentacija kartiranih jaruga (Sl. 27. A) vidljivo je kako na otoku Pagu dominiraju jaruge orijentirane prema istoku (68,33% svih jaruga), nakon čega slijede jaruge zapadne orijentacije (30,01% svih jaruga), dok tek 1,66% svih kartiranih jaruga karakterizira sjeverna orijentacija. Ovakav ishod može se pripisati prije svega odgovarajućim značajkama reljefa, koji pogoduje nastanku brojnih dimenzijama manjih, jednostavnih jaruga (87,81% svih jednostavnih jaruga je istočne orijentacije) te većoj ogoljenosti istočno orijentiranih dijelova otoka, uzrokovanoj olujnim udarima sjeveroistočnog vjetra – bure. Prema kriteriju aktivnosti jaruge su razvrstane pod aktivne jaruge (49,16%) te pod neaktivne jaruge (50,83%). Aktivnim jarugama su pridodane sve one jaruge kod kojih su na korištenom DOF-u primijećeni bilo kakvi tragovi jaruženja, pri čemu je ukupno detektirano 59 takvih jaruga. Treba napomenuti kako je od 59 detektiranih aktivnih jaruga čak njih 54 istočne orijentacije (91,52%), što se također može povezati sa izostankom razvijenijeg vegetacijskog pokrova na istočnim dijelovima otoka. Naime, izostanak vegetacije uvjetuje veću izloženost površinskih slojeva djelovanju različitih denudacijskih čimbenika, ali isto tako i olakšava otkrivanje tragova jaruženja unutar jaruga (Poesen, 2011.).



Slika 28. Prostorni razmještaj 120 jaruga otoka Paga kartiranih OBIA pristupom;
 A – uvećani prikaz šireg prostora jaruge *Starca draga*

Kod kriterija složenosti jaruge su klasificirane kao jednostavne jaruge, ukoliko je zamijećeno postojanje samo jednog prevladavajućeg kanala, dok su pod razgranate jaruge svrstane sve jaruge sa više od jednog kanala. Vidljivo je kako na prostoru otoka Paga uvelike prevladavaju jednostavne jaruge (88,23% svih jaruga), što se može povezati sa dužinom jaruga. Naime, primijećeno je kako su razgranate jaruge (12,51% svih jaruga) u pravilu znatno duže od jednostavnih jaruge te da se javljaju na onim dijelovima otoka na kojima su postojali preduvjeti za razvoj duže i kompleksnije mreže površinskog otjecanja. S druge strane, kraće jaruge prevladavaju na strmijim padinama te se najčešće javljaju u neposrednoj blizini hidrološke baze (npr. mora ili jezera).

8. Višekriterijska GIS analiza podložnosti terena jaruženju

U ovom dijelu diplomskog rada izvedena je višekriterijska GIS analiza (u nastavku GIS-MCDA) podložnosti terena jaruženju na prostoru otoka Paga. Tim je ujedno provedena prostorna raščlamba otoka prema različitim razinama podložnosti terena procesu jaruženja. Danas GIS-MCDA nalazi primjenu u brojnim prostorno orijentiranim djelatnostima i znanstvenim istraživanjima (Modica i dr., 2014; Rikalovic i dr., 2014; Chen i dr., 2015; Çetinkaya i dr., 2016; Pinto i dr., 2017.), među kojima su i različita istraživanja iz područja geomorfologije. Kroz primjenu višekriterijskih GIS analiza u geomorfološkim istraživanjima najčešće se nastoje odrediti zone različite podložnosti za pojavu određenih morfoloških tipova ili procesa (Feizizadeh i Blaschke, 2013; Kumar i dr., 2016; Erener i dr., 2016.), pa se na taj način ove analize primjenjuju i za određivanje podložnosti terena jaruženju (Agnesi i dr., 2011; Confronti i dr., 2011; Lucà i dr., 2011; Conoscenti i dr., 2013; Rahmati i dr., 2016a; Rahmati i dr., 2016b.). Podložnost (eng. *susceptability*) se može odrediti kao vjerojatnost prostorne pojavnosti određenog procesa, određene na temelju odnosa između prostornog razmještaja tog procesa u prošlosti i raznovrsnih predisponirajućih čimbenika, koji utječu na pokretanje tog procesa (Lucà i dr., 2011.). Predviđanje lokacija na kojima bi moglo doći do oblikovanja novih jaruga u budućnosti nužna je za pravovremeno planiranje prevencije neželjenih učinaka ovog procesa (Dewitte i dr., 2015; Gómez-Gutiérrez i dr., 2015.). Zbog navedenog, rezultati ovog istraživanja mogu biti od esencijalnog značaja za održivi razvoj i planiranje zaštite preostalih naslaga tla na otoku Pagu. S obzirom na to da brojni različiti čimbenici utječu na pojavnost i intenzitet jaruženja, predviđanje mjesta na kojima će doći do pojave jaruga u budućnosti nije jednostavan proces (Valentin i dr., 2005; Poesen i dr., 2001; Dewitte i dr., 2015.).

Kvaliteta izrađenog modela podložnosti jaruženju ovisi o valjanosti izabranih predisponirajućih kriterija, zbog čega su u ovom istraživanju prije odabira kriterija za GIS-MCDA temeljito proučeni čimbenici korišteni u drugim radovima koji obrađuju podložnost terena jaruženju. Nakon analize dostupne literature ukupno je izdvojeno 11 različitih kriterija, determinantnih za pojavu jaruženja na prostoru otoka Paga. Na temelju determinantnih kriterija provedena je GIS-MCDA te su izdvojene zone različite pogodnosti za pojavnost jaruženja, koje su naknadno kategorizirane *Jenksovom* metodom u pet klasa (*vrlo niska podložnost*, *niska podložnost*, *srednja podložnost*, *visoka podložnost* i *vrlo visoka podložnost*). Krajnji model podložnosti jaruženju predstavlja osnovu za planiranje mjera za ograničavanje i prilagodbu daljnjim negativnim posljedicama procesa jaruženja na prostoru otoka Paga, pri čemu je u nastavku dan poseban osvrt na izloženost prostora u neposrednoj blizini postojećih naselja.

8.1. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju

U nastavku je dan pregled odabranih kriterija provedene GIS-MCDA, s objašnjenim utjecajem svakog od odabranih kriterija na pojavnost i intenzitet jaruženja. Pri tome su zbog bolje preglednosti kriteriji izdvojeni iz DMR-a otoka Paga podijeljeni na: *primarne morfometrijske parametre* i *sekundarne morfometrijske parametre* (Wilson i Gallant, 2000.), dok su preostali svrstani u *ostale kriterije*. Prikaz prostorne zastupljenosti pojedinih kriterija na prostoru otoka Paga vidljiv je na slikama 29. i 30.

Primarni morfometrijski parametri

Za potrebe GIS-MCDA izdvojeni su sljedeći primarni morfometrijski parametri: *nagib padine (SLO)*, *orijentacija padine (ASP)* te *planarna (PLAN)* i *profilna (PROF) zakrivljenost padine*. Iako postoje brojni drugi primarni morfometrijski parametri, koji se mogu izdvojiti iz DMR-a (npr. hipsometrija), njihov utjecaj na pojavnost jaruženja nije značajan te su oni izdvojeni iz ove analize.

Nagib padine

Nagib padine jedan je od glavnih predisponirajućih čimbenika u evoluciji padinskog reljefa, koji izravno utječe na intenzitet različitih denudacijskih procesa (Wilson i Gallant, 2000.). Zbog izraženog utjecaja nagiba padinama na evoluciju padinskog reljefa kriterij nagiba padine ima odlučujuću ulogu u izradi modela podložnosti terena jaruženju (Confronti i dr., 2011.). Prema tome, vrlo je bitno pravilno rangirati pojedine klase nagiba padina, sukladno razini njihovog utjecaja na pojavnost jaruženja. Brzina i erozivna snaga otjecanja povećavaju se sukladno porastu nagiba padine, zbog čega strmije padine karakterizira veća vjerojatnost za pokretanje različitih denudacijskih procesa, pa tako i jaruženja (Valentin i dr., 2005.). Međutim, u slučaju *vrlo strmih terena* ($32^\circ - 55^\circ$) te *strmaca i litica* ($> 55^\circ$) brzina površinskog otjecanja je tolika da se bitno smanjuje mogućnost stvaranja kritične količine usmjerenog otjecanja, potrebnog za pokretanje jaruženja (Valentin i dr. 2005; Poesen, 2003.). S druge strane na *blago nagnutim terenima* ($2^\circ - 5^\circ$) te pogotovo na *ravnicama* ($0^\circ - 2^\circ$) slabo izražen nagib terena ne onemogućava nastanak bržeg otjecanja, zbog čega je i erozivna snaga na ovakvim padinama manja, kao i mogućnost pojave jaruženja. Na ovakvim padinama se jaruženje u pravilu javlja samo kod većih drenažnih bazena, koji imaju sposobnost prikupljanja kritične količine vode, potrebne za odnošenje materijala i formiranje jaruga (Chaplot, 2013.).

Nagibi padina na prostoru otoka Paga klasificirani su prema standardnoj klasifikaciji (IGU, 1968.) (Sl. 29.). Tako na prostoru otoka prevladavaju ravnice ($0^\circ - 2^\circ$) i blago nagnuti

tereni ($2^{\circ} - 5^{\circ}$) koji zajedno obuhvaćaju oko 50 % površine otoka (150,16 km²), uglavnom na prostoru usporednih fliških udolina. Spomenute klase nagiba prevladavajuće su na prostoru novaljsko-caske i paško-dinjiške udoline, te na prostoru nekoliko manjih fliških udolina (Magaš, 2011.). Slijede nagnuti tereni ($5^{\circ} - 12^{\circ}$) koji obuhvaćaju 29,7 % površine otoka (84,54 km²), a najzastupljeniji su na blažim, bočnim obroncima krških hrptova. Značajni nagibi ($12^{\circ} - 32^{\circ}$) prevladavaju na strmijim sjevernim i sjeveroistočnim priobalnim padinama otoka te ukupno obuhvaćaju 16,5 % površine otoka (47,1 km²). Upravo na nagnutim i značajno nagnutim terenima je primjetna najveća pojavnost i razvijenost jaruga na otoku. Vrlo strmi tereni ($32^{\circ} - 55^{\circ}$) i strmci ($> 55^{\circ}$) zastupljeni su na manje od 1 % površine otoka (2,67 km²) te zbog vrlo strmog nagiba na ovakvim padinama gotovo da nije zamijećena pojavnost jaruga.

Kako se iz ranije navedenog može zaključiti da su nagnuti tereni ($12^{\circ} - 32^{\circ}$) najpogodniji za pojavu jaruženja određeno je da klase s ovakvim vrijednostima nagiba padina trebaju dobiti najviše težinske koeficijente. Zatim slijede jako nagnuti tereni ($32^{\circ} - 55^{\circ}$) i blago nagnuti tereni ($2^{\circ} - 5^{\circ}$) s nešto slabijim težinskim koeficijentom. Najniži težinski koeficijent dodijeljen je klasi ravnica ($0^{\circ} - 2^{\circ}$) i klasi strmaca i litica ($> 55^{\circ}$), na kojima nepovoljan nagib padine gotovo da onemogućava pojavu jaruženja (Tabl. 7.).

Tablica 7. Zastupljenost klasa nagiba padine s pripadajućim težinskim koeficijentima

Nagib padine	$0^{\circ} - 2^{\circ}$	$2^{\circ} - 5^{\circ}$	$5^{\circ} - 12^{\circ}$	$12^{\circ} - 32^{\circ}$	$32^{\circ} - 55^{\circ}$	$> 55^{\circ}$
Površina (km ²)	59,307	90,856	84,548	47,154	2,672	0,005
Udio	20,843	31,931	29,714	16,572	0,939	0,002
Težinski koeficijent	1	2	4	5	4	2

Ekspozicija padine (*aspect*)

Iako ekspozicija padine ne spada u čimbenike koji neposredno utječu na pojavnost i intenzitet padinskih procesa, ona može neizravno utjecati na intenzitet jaruženja, jer određuje izloženost terena raznovrsnim klimatskim čimbenicima (npr. trajanje osunčanosti, intenzitet oborina, vlažnost, izloženost vjetru itd.) te uvjetuje razvijenost vegetacijskog pokrova (Wijdenes i dr., 2000; Confronti i dr., 2011.; Rahmati i dr., 2016a). Sjeverne padine obilježava kraća osunčanost i veća vlažnost u odnosu na južnije položene padine, zbog čega na tim padinama može lakše doći do pojave površinskog otjecanja, nego na južnijim sušnijim padinama. Sjeverne, a posebice sjeveroistočne padine otoka Paga su izložene utjecaju snažnog, ponekad i olujnog vjetra – bure. Bura je iznimno jak vjetar, koji puše na mahove, a može doseći brzinu i veću od 150 km/h (Penzar i dr., 2001.). Utjecajem bure gotovo je u potpunosti onemogućen razvoj vegetacijskog pokrova na sjevernim i sjeveroistočnim padinama

na otoku Pagu, što čini ove padine izloženijim djelovanju denudacijskih procesa.

Najzastupljenije padine na otoku Pagu su jugozapadne (29,01 % – 82,54 km²), i padine sjeveroistočne (15,52 % – 44,16 km²) orijentacije, što je odraz izduženosti otoka u pravcu JI – SZ. Ističu se još i južno (12,34 % - 35,11 km²), zapadno (11,74 % - 33,41 km²) i sjeverno (9,18 % – 26,12 km²) orijentirane padine. Najmanju zastupljenost imaju sjeverozapadne (6,49 % – 18,48 km²) i jugoistočne (5,44 % – 15,48 km²) padine, koje su prisutne samo na razmjerno uskim, krajnjem sjeverozapadnom i jugoistočnom dijelu otoka.

Sjevernim, sjeveroistočnim i sjeverozapadnim padinama su pridodani najveći težinski koeficijenti za podložnost pojavnosti jaruženja, dok kod ostalih klasa orijentacije padina težinski koeficijenti postupno opadaju prema jugu (Tabl. 8.). Najnižu ocjenu za podložnost jaruženju dobile su južno orijentirane padine i zaravnjeni prostori, na kojima prevladavaju najnepovoljniji uvjeti za pojavnost jaruga.

Tablica 8. Zastupljenost klasa orijentacije padina s pripadajućim težinskim koeficijentima

Orijentacija padine	Ravno	N	NE	E
Površina (km ²)	5,455	26,125	44,168	23,736
Udio	1,917	9,181	15,522	8,342
Težinski koeficijent	3	5	5	3
SE	S	SW	W	NW
15,489	35,115	82,549	33,409	18,482
5,444	12,341	29,011	11,741	6,495
2	1	2	3	4

Zakrivljenost padine (*Curvature*)

Zakrivljenost površine se može promatrati kao zakrivljenosti linije koju čini sjecište određene ravnine sa topografskom površinom (Wilson i Gallant, 2000.), pri čemu vrijednost zakrivljenosti označava iznos u kojemu određena površina (npr. teren) odstupa od pravocrtne padine. Zakrivljenost padine utječe na konvergenciju ili divergenciju vode prilikom površinskog otjecanja, ali i na brzinu otjecanja vode niz padinu (Moore, 1991.; Agnesi i dr. 2011.; Confronti i dr., 2011.). Dva osnovna tipa zakrivljenosti padine su profilna i planarna zakrivljenost. Profilna zakrivljenost padine utječe na brzinu površinskog otjecanja vode niz padinu te posljedično i na pojavu odnošenja ili sedimentacije materijala. Na konveksnim padinama pretežito dolazi do usporavanja površinskog otjecanja i slabljenja transportnog kapaciteta, čime u konačnici može doći i do sedimentacije materijala. S druge strane na konkavnim padinama prevladava ubrzavanje površinskog otjecanja, koje utječe na povećanje energije otjecanja i izraženije usijecanje toka u padinu te moguću pojavu odnošenja materijala.

Na prostoru otoka Paga zastupljenost konkavnih i konveksnih padina je poprilično ujednačena (Tabl. 9.). Konkavne padine obuhvaćaju 49,08 % (139,65 km²) površine otoka, konveksne imaju zastupljenost od 48,92 % (139,21 km²), a zaravnjene samo 1,98 % (5,64 km²).


Tablica 9. Zastupljenost klasa profilne zakrivljenosti padina s pripadajućim težinskim koeficijentima

Profilna zakrivljenost	Pravocrtne	Konkavne	Konveksne
Površina (km ²)	5,649	139,657	139,213
Udio	1,985	49,081	48,925
Težinski koeficijent	3	1	5


Planarna zakrivljenost padine utječe na homogenost površinskog otjecanja. Kod konkavnih padina vezanih za negativne vrijednosti planarne zakrivljenosti dolazi do konvergencije površinskog otjecanja i formiranja jedinstvenog toka sa znatno većom erozivnom snagom, čime se znatno povećava vjerojatnost za nastanak jaruga. Kod konveksnih padina, vezanih za pozitivne vrijednosti planarne zakrivljenosti dolazi do razdvajanja, odnosno grananja površinskog otjecanja, čime slabi erozivni potencijal otjecanja te je sukladno tome vjerojatnost pojave jaruženja na ovakvim padinama manja. Kod planarne zakrivljenosti na 45,61 % (129,78 km²) površine otoka Paga su zastupljene konkavne padine, dok su konveksne zastupljene na 52,31 % (148,48 km²) površine otoka (Tabl. 10.). Zaravnjene padine obuhvaćaju tek 2,05 %, odnosno 5,85 km² površine otoka i uglavnom su vezane za prostor uz Velo i Malo blato te prostor solana.

Tablica 10. Zastupljenost klasa planarne zakrivljenosti padina s pripadajućim težinskim koeficijentima

Planarna zakrivljenost	Pravocrtne	Konkavne	Konveksne
Površina (km ²)	5,850	129,785	148,849
Udio	2,056	45,612	52,312
Težinski koeficijent	3	5	1



Slika 29. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju (A)



Slika 30. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju (B)

Sekundarni morfometrijski parametri

Za potrebe ovog istraživanja odabrani su oni sekundarni morfometrijski kriteriji, koje je moguće iskoristiti kao indikatore podložnosti određenog prostora jaruženju. Izdvojena su tri hidrološka sekundarna parametra (**TWI**, **SPI** i **WAT**) te jedan morfometrijski sekundarni parametar (**LS faktor**).

Topografski indeks vlažnosti (*TWI*)

Sa stajališta proučavanja jaruga i jaruženja TWI je važan kriterij za određivanje potencijala određenog terena za pojavu jaruženja, jer omogućava identifikaciju prostora zasićenog vodom u kojima je infiltracija površinske vode u podzemlje znatno manja. Manja infiltracija vode u podzemlje uvjetuje pojavu izraženijeg površinskog i plitkog podzemnog otjecanja, čime je i denudacijski učinak ovog otjecanja znatno veći. Izraženije površinsko otjecanje u kombinaciji s destabiliziranom ili izloženom slabije otpornom podlogom preduvjet je pojave jaruženja. Zbog toga rasterske ćelije s višim vrijednostima ovog indeksa predstavljaju područja veće pogodnosti za pojavu jaruženja.

Tablica 11. Zastupljenost klasa topografskog indeksa vlažnosti (TWI) s pripadajućim težinskim koeficijentima

TWI	1	2	3	4
Površina (km ²)	24,023	112,724	122,091	25,677
Udio	8,443	39,616	42,908	9,024
Težinski koeficijent	2	3	4	5

Indeks snage toka (SPI)

SPI je jedan od važnijih čimbenika koji utječu na intenzitet padinskih procesa, pa tako i jaruženja, jer erozivna snaga površinskog otjecanja izravno utječe na intenzitet usijecanja vodotoka u podlogu. Strmije padine većih drenažnih bazena obilježavaju veće vrijednosti ovog indeksa te veća podložnost procesu jaruženja, jer veličina drenažnog bazena utječe na volumen površinskog otjecanja, a nagib padine na brzinu površinskog otjecanja. Utvrđeno je kako područja s većim vrijednostima SPI indeksa imaju veći erozijski potencijal te se često podudaraju s pojavom odnošenja materijala i jaruženja (Favre i dr., 2011.; Confronti i dr., 2011.).

Tablica 12. Zastupljenost klasa indeksa snage otjecanja (SPI) s pripadajućim težinskim koeficijentima

SPI	1	2	3	4
Površina (km ²)	50,548	74,803	115,216	43,963
Udio	17,765	26,289	40,492	15,451
Težinski koeficijent	2	3	4	5

LS faktor

LS faktor, često naveden i kao *topografski faktor* jedan je od osnovnih varijabli korištenih u USLE (engl. *Universal Soil Loss Equation*) i RUSLE (engl. *Revised Universal Soil Loss Equation*) jednadžbama za procjenu erozije tla, kojim se razmatra utjecaj topografskih značajki na intenzitet erozije (Zhang i dr., 2013.). Prije svega ovaj čimbenik analizira utjecaj duljine padine (*L*) i nagiba padine (*S*) na eroziju tla te može poslužiti kao kvantitativna mjera transportnog kapaciteta površinskog otjecanja (Moore, 1992.). Pri tome se s porastom duljine i nagiba padine povećava brzina otjecanja i intenzitet erozije, odnosno sposobnost površinskog otjecanja da odnosi i transportira materijal (Lal, 1988.). Sa stajališta proučavanja jaruženja LS faktor može poslužiti za izdvajanje jaruga, ponajprije jer se jaruženje javlja na strmijim padinama, većih slivnih područja, iz čega proizlazi da rasterske ćelije s većim vrijednostima LS faktora imaju veći potencijal za pojavu jaruženja.

Tablica 13. Zastupljenost klasa LS faktora sa pripadajućim težinskim koeficijentima

LS Faktor	1	2	3	4
Površina (km ²)	230,784	45,058	7,982	0,703
Udio	81,107	15,835	2,805	0,247
Težinski koeficijent	2	3	4	5

Specifično slivno područje (WAT)

Uz nagib padine erozijska snaga površinskog otjecanja najviše ovisi o površini slivnog područja jaruge (Vandekerckhove i dr., 2000; De Vente i Poesen, 2005; Valentin i dr., 2005.), zbog čega su izdvojeni drenažni bazeni otoka Paga uzeti kao kriterij u GIS-MCDA analizi, pod pretpostavkom da unutar većih drenažnih bazena postoji veća vjerojatnost za pojavu kritičnog površinskog otjecanja, potrebnog za pokretanje jaruženja. Ova pretpostavka temelji se na ranijim istraživanjima koja su pokazala kako je veličina slivnog područja u izravnom suodnosu s intenzitetom horizontalnog pomaka u čeonom dijelu jaruge (GHR), pri čemu jaruge sa većim slivnim područjem bilježe intenzivniji horizontalni pomak (Vanmaercke i dr., 2016.).

Tablica 14. Zastupljenost klasa WAT s pripadajućim težinskim koeficijentima

Površina sliva jaruge (km ²)	0,01 – 1,80	1,80 – 3,82	3,82 – 7,20	7,20 – 13,49
Površina (km ²)	120,386	17,458	26,816	13,523817
Udio	67,563	9,798	15,050	7,5898044
Težinski koeficijent	2	3	4	5

Ostali kriteriji

Pod ostale kriterij su svrstani svi oni kriteriji koji nisu izvedeni iz DMR-a, a utječu na pojavnost i intenzitet jaruženja. U prvom redu to su zemljišni pokrov i pedološki sastav podloge, te ograničavajući Boolean kriterij.

Zemljišni pokrov³

Način korištenja zemljišta ima značajan utjecaj na geomorfološku stabilnost padine i pojavu raznovrsnih padinskih procesa. Primjeri iz cijelog svijeta ukazuju kako neprikladno korištenje zemljišta, kao što su prekomjerna sječa šuma ili stočarska valorizacija određenog prostora, mogu znatno ubrzati prirodni proces padinskog jaruženja (Valentin i dr. 2005.). Pojedine tipove zemljišnog pokrova obilježava različita otpornost na procese trošenja materijala, pa tako i na jaruženje. Otpornost na procese trošenja povezana je s vegetacijskim pokrovom i načinom korištenja određenog zemljišta. Vegetacijski pokrov ima umanjujući učinak na podložnost određenog terena jaruženju, jer smanjuje erozivnu sposobnost površinskog otjecanja (Conforti i dr., 2011). Primjerice, gola ili rijetko zasađena područja su uglavnom zahvaćena bržim i intenzivnijim trošenjem i većom nestabilnosti padina od čvrsto ukorijenjenih šuma ili kultiviranih parcela. Nadalje, način korištenja zemljišta može utjecati na odnošenje prirodnog organskog pedološkog pokrova, čime se mijenja strukturna stabilnost tla te potiče površinsko otjecanje i krustacija, što u konačnici vodi ka pojavi jaruženja.

Iako krajolikom otoka Paga prevladava ogoljeni krški krajolik, raznolikost tipova vegetacijskog pokrova na otoku je znatna. Stoga, prilikom dodjeljivanja težinskih koeficijenata različitim tipovima vegetacijskog pokrova, treba obratiti pozornost na stupanj razvijenosti, gustoću i otpornost na denudaciju pojedinih tipova vegetacijskog pokrova. Najveću ocjenu za pogodnost pojavnosti jaruženja svakako trebaju dobiti goli ili slabo vegetacijski prekriveni tipovi zemljišnog pokrova.

³ Zemljišni pokrov obuhvaća prirodnu vegetaciju i poljoprivredne površine, dok su vodene i urbane površine izdvojene u Boolean kriterij

Spomenuti ogoljeni krški kamenjar (Tabl. 15. – 9), čine vrlo rijetke zajednice mediteranskih trava, koje ne ometaju djelovanje denudacijskih procesa, zbog čega se ovakav tip pokrova može smatrati najpogodnijim za pojavu jaruženja (TK – 5). Zatim prema pogodnosti za pojavu jaruženja slijede kamenjarski travnjaci (Tabl. 15. – 7), ujedno i najzastupljeniji tip pokrova na otoku kojeg čine različite zajednice mediteranskih trava, te poljoprivredne površine (Tabl. 15. – 8). Ova dva tipa pokrova također karakterizira slaba otpornost i izloženost denudacijskim procesima, zbog čega im je dodijeljen relativno visok težinski koeficijent (TK – 4). Slijede sub-mediteranski travnjaci (Tabl. 15. – 6) i makija (Tabl. 15. – 5) kojima su zbog povećane vlažnosti, odnosno jače ukorijenjenosti dani slabiji težinski koeficijenti (TK – 3/ TK – 2). Najmanji težinski koeficijent (TK – 1) dodijeljen je zamočvarenim (Tabl. 15. – 3) i šumskim (Tabl. 15. – 4) površinama, kao najnepogodnijim područjima za pojavu jaruženja (TK – 1).

Tablica 15. Zastupljenost vegetacijskih klasa s pripadajućim težinskim koeficijentima

Zemljišni pokrov	1	2	3	4
Površina (km ²)	12,489	1,703	2,878	11,971
Udio	4,389	0,598	1,012	4,207
Težinski koeficijent	0	0	1	1
5	6	7	8	9
39,728	5,393	116,353	9,151	84,296
13,962	1,895	40,891	3,216	29,625
2	3	4	4	5

Pedološki pokrov

Pedološki pokrov vrlo je bitan čimbenik otpornosti podloge na različite oblike denudacijskog djelovanja. Različite tipove tala obilježava različita otpornost na trošenje, što bitno utječe na vjerojatnost za pojavnost jaruženja na određenom području (Chaplot, 2013.). Prema pedološkim kartama u mjerilu 1:50 000 na prostoru otoka Paga prisutno je šest različitih tipova tla, koja se razlikuju po svojim značajkama i stupnju otpornosti na djelovanje denudacijskih procesa (Husnjak, 2014.). Najdominantniji tip tla na prostoru otoka Paga je smeđe tlo na vapnencu, koja prevladava na oko 42% površine otoka (Tabl. 16. – 5). Na ovom tipu tla zapaženi su prilikom terenskih obilazaka jaruga intenzivni procesi jaruženja, zbog čega je ovaj tip tla dobio najvišu ocjenu podložnosti jaruženju. Po zastupljenosti slijedi kamenjar (Tabl. 16. – 3) kod kojega je također zabilježena velika izloženost površinskih slojeva jaruženju. Tipovi tla crvenica (Tabl. 16. – 2) te antropogeno na flišu (Tabl. 16. – 1) zastupljena su na oko 15% površine otoka te su zbog zamijećenog razvijenijeg vegetacijskog pokrova ovim tipovima

tla dodijeljeni manji težinski koeficijenti. Najmanji težinski koeficijent dodijeljen je močvarno-
glejnim (Tabl. 16. – 4) tlima, na kojima je zamijećena vrlo visoka zasićenost tla vodom, zbog
koje je i podložnost ovakvih terena jaruženju manja. Vodene površine (Tabl. 16. – 6) pridodane
su Boolean kriteriju, unutar kojega nije analizirana podložnost jaruženju.

Tablica 16. Zastupljenost klasa pedološkog pokrova s pripadajućim težinskim koeficijentima

Pedologija	1	2	3	4	5	6
Površina (km ²)	42,726	48,729	67,785	1,649	121,627	1,486
Udio	15,016	17,126	23,822	0,579	42,745	0,522
Težinski koeficijent	3	2	4	1	5	0


Boolean kriterij

Boolean kriterij obuhvaća sva ona područja na kojima ne postoje nikakvi uvjeti za
pokretanje određenog procesa, u ovom slučaju jaruženja. U prvom redu pod Boolean kriterij
spadaju sva urbana i industrijska izgrađena područja, u kojima zbog antropogenih modifikacija
terena ne može doći do pojave klasičnog padinskog jaruženja. Zatim u Boolean kriterij spadaju
sve trajne vodene površine, na prostoru kojih također nije moguća pojavnost padinskih procesa.
Na prostoru otoka Paga pod vodene površine je uvršteno nekoliko jezera (Veliko i Malo Blato)
te zaravnjeni prostor solana, u kojima zbog ekstenzivne gospodarske valorizacije i izraženog
antropogenog oblikovanja reljefa nije moguće praćenje prirodnog procesa jaruženja. Navedeni
prostori isključeni su iz višekriterijske analize podložnosti terena jaruženju na način da su
izdvojeni kao prostori nikakve vjerojatnosti za pojavnost jaruženja, s težinskim koeficijentom
 $W_i = 0$.


Tablica 17. Zastupljenost Boolean klasa s pripadajućim težinskim koeficijentima

Boolean	0	1
Površina (km ²)	15,931	268,676
Udio	5,599	94,424
Težinski koeficijent	0	1

Iz priloženih tablica vidljivo je kako su svi odabrani kriteriji GIS-MCDA
standardizirani, na način da su njihovim klasama pridodani odgovarajući težinski koeficijenti
(1 – 5), dok su Boolean kriteriju pridodane binarne ocjene 0 i 1. Prikaz prostorne zastupljenosti
standardiziranih kriterija na prostoru otoka Paga vidljiv je na slikama 31. i 32.



Slika 31. Ocjene pogodnosti pojedinih klasa odabranih kriterija GIS-MCDA (A)



Slika 32. Ocjene pogodnosti pojedinih klasa odabranih kriterija GIS-MCDA (B)

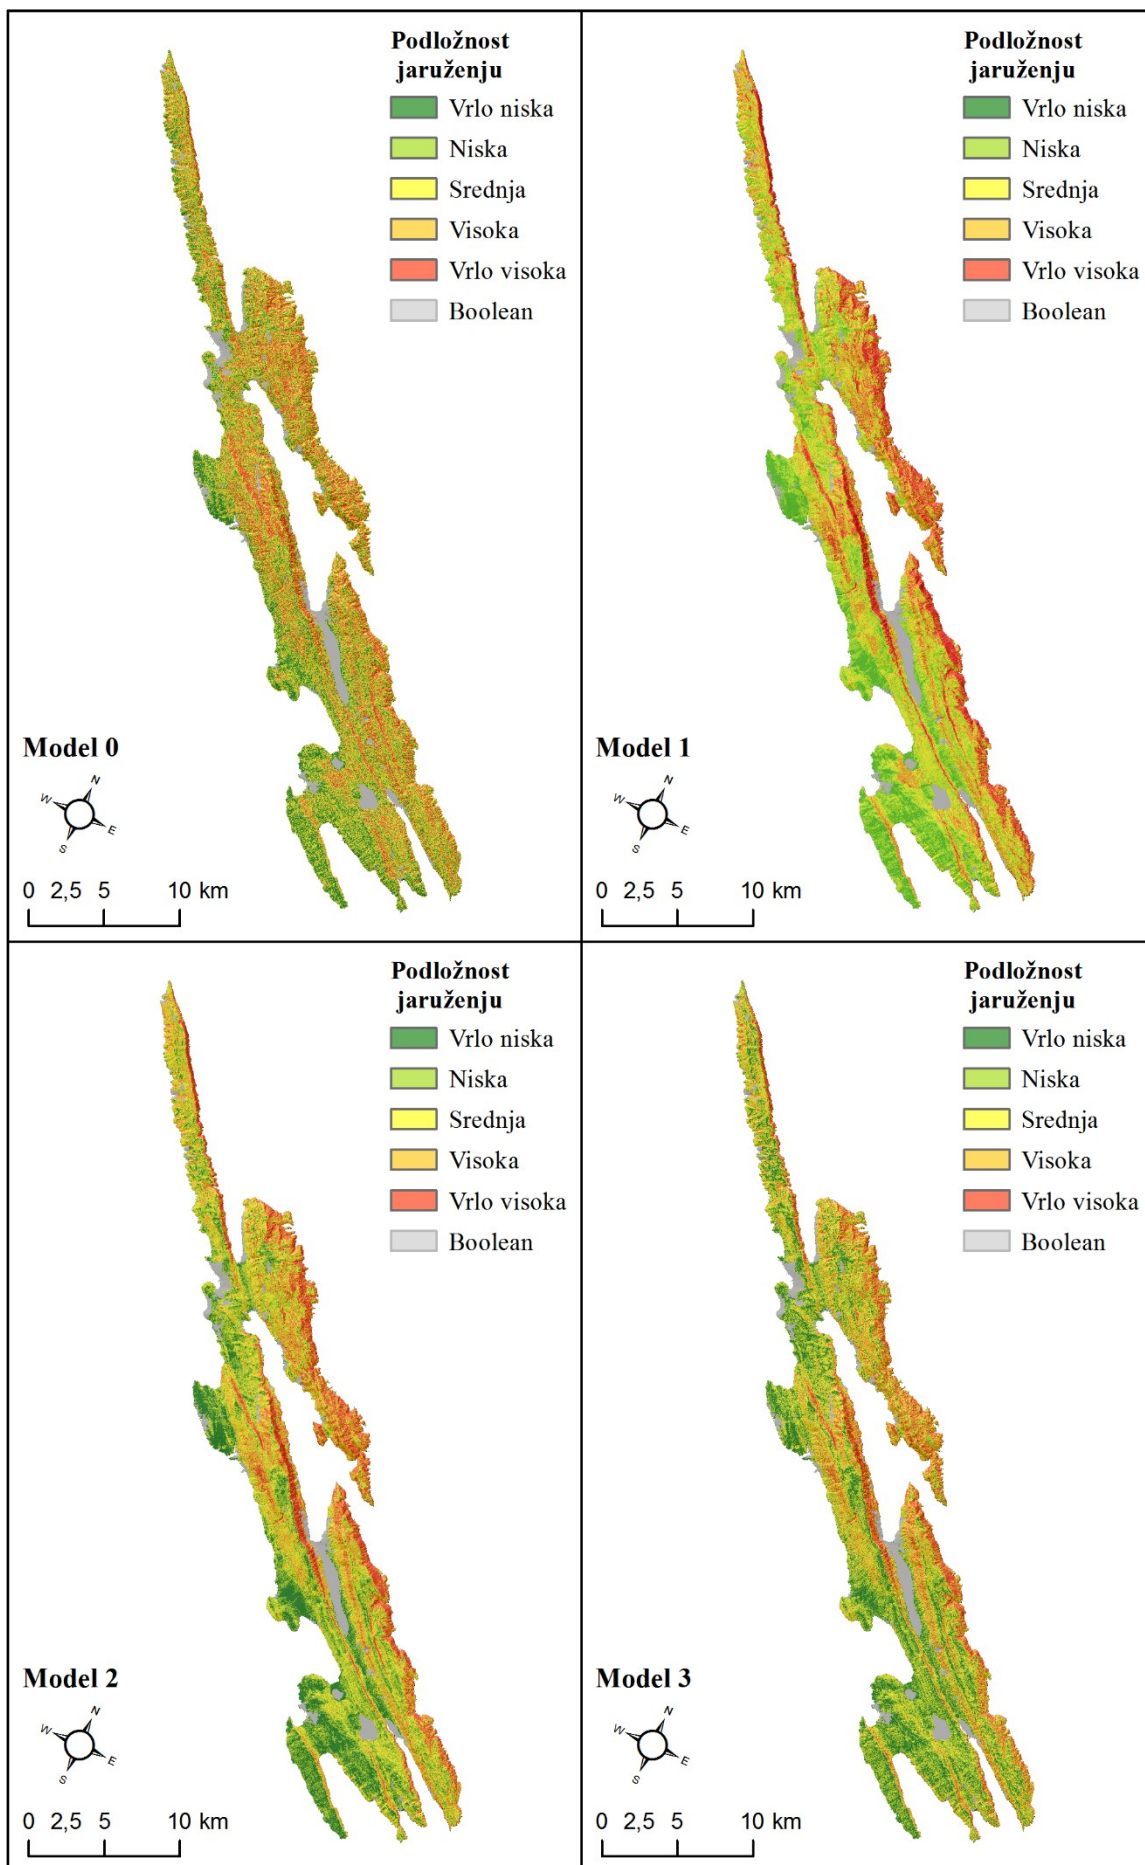
8.2. Procjena kvalitete izrađenih modela podložnosti terena jaruženju

Standardiziranim kriterijima GIS-MCDA podložnosti jaruženju primjenom metode AHP određeni su težinski koeficijenti. Da bi se postigla što veća točnost i vjerodostojnost modela podložnosti jaruženju, testirana su tri modela s različitim težinskim koeficijentima (Talica 18.).

Tablica 18. Težinski koeficijenti odabranih parametara za četiri testirana GIS-MCDA modela


#	Nagib padine	Orijentacija padine	Pedološki pokrov	Zemljišni pokrov	TWI	SPI	LS faktor
Model 0 - težinski koeficijenti	1	1	1	1	1	1	1
Model 1 - težinski koeficijenti	0,185	0,185	0,185	0,185	0,076	0,076	0,031
Model 2 - težinski koeficijenti	0,306	0,134	0,134	0,140	0,085	0,053	0,053
Model 3 - težinski koeficijenti	0,279	0,123	0,029	0,077	0,129	0,129	0,129
#	Profilna zakrivljenost	Planarna zakrivljenost	Specifično slivno područje	Indeks konzistentnosti (CI)	Omjer konzistentnosti (CR)		
Model 0 - težinski koeficijenti	1	1	1	1	1		
Model 1 - težinski koeficijenti	0,031	0,031	0,015	0,023	0,0155		
Model 2 - težinski koeficijenti	0,053	0,025	0,018	0,034	0,0231		
Model 3 - težinski koeficijenti	0,044	0,044	0,018	0,079	0,0524		

Ukupno su izrađena četiri modela s različitim težinskim koeficijentima. Dok su za tri modela (Model 1, Model 2, Model 3) težinski koeficijenti određeni uz pomoć AHP-a, u




Slika 33. Vizualna usporedba modela izrađenih prema različitim težinskim koeficijentima

čtvrtom modelu (Model 0) svima odabranim kriterijima dodijeljen je isti težinski koeficijent. Iz tablice je vidljivo kako sva tri modela napravljena na temelju AHP-a zadovoljavaju kriterij konzistentnosti ($CR = 0,1$), čime je potvrđena ispravnost procesa standardizacije i vrednovanja odabranih kriterija. Međutim, vizualnom usporedbom izrađenih modela uočeno je kako postoji vrlo velika razlika među izrađenim modelima (Sl. 33.). Budući da vizualna interpretacija izrađenih modela ne predstavlja objektivni i kvantitativno utemeljen pristup evaluaciji kvalitete izrađenih modela, ranije navedeni zaključak o postojanju razlike u točnosti modela potvrđen je izradom ROC krivulja (Sl. 36; Sl. 37.). Za potrebe izrade ROC krivulja pojedini modeli su preklapani s 10 referentnih jaruga (Sl. 34.) te sa 120 jaruga kartiranih OBIA pristupom (Sl. 35.).



Slika 34. Vizualna usporedba zona visoke podložnosti jaruženju (**Model 3**) s referentnim jarugama kartiranim metodom ručne digitalizacije (Metodologija 6.4.)




Slika 35. Vizualna usporedba zona visoke podložnosti jaruženju (**Model 3**) s jarugama kartiranim OBIA pristupom

Pri tome treba napomenuti da referentne jaruge predstavljaju znatno točniji podatak, od


jaruga kartiranih OBIA pristupom, ali da zbog njihove malobrojnosti one nisu zastupljene na cijeloj površini otoka. Kvaliteta modela pokazala se boljom prilikom usporedbe s referentnim jarugama, što je bilo i očekivano s obzirom da se radi o evaluaciji provedenoj na temelju podataka sa daleko većom površinskom točnošću.

Model 0, kod kojega su svi kriteriji jednako važni, ne prikazuje vjerodostojno podložnost terena jaruženju, što je potvrđeno izvedenim ROC krivuljama. Očigledno je da za određivanje podložnosti terena jaruženju nisu svi odabrani kriteriji jednako važni, zbog čega se zone *visoke* i *vrlo visoke podložnosti jaruženju* određene **Modelom 0** slabo podudaraju s postojećim jarugama. O tome svjedoče i vrijednosti AUC izračunate prema podudarnosti s jarugama kartiranim OBIA pristupom (Sl. 37.). Također, vidljivo je i kako kvaliteta izrađenih modela ovisi uvelike o dostupnim podacima korištenim za izradu modela podložnosti. Naime, iako je pedološki pokrov itekako bitan čimbenik pojavnosti jaruženja, iz usporedbe izrađenih modela je vidljivo kako ovaj kriterij ne smije dobiti težinski koeficijent koji mu pripada, jer se radi o podacima znatno lošije kvalitete od ostalih podataka. Zbog toga izrađene zone podložnosti jaruženju kod **Modela 1** više prate granice pojedinih klasa ovog parametra, nego što odgovaraju stvarnoj situaciji, te poradi toga ovaj model bilježi najmanje vrijednosti AUC (Sl. 36. i Sl. 37.).

ROC krivulje za **Model 2** i **Model 3** potvrdile su ispravnost smanjivanja težinskih koeficijenata pedologije i vegetacijskog pokrova, u korist kriterija izdvojenih iz DMR-a. Vizualno gledano je vrlo teško zamijetiti veće razlike između **Modela 2** i **Modela 3**, tek je moguće zamijetiti malo bolju detaljnost definiranih zona različite podložnosti jaruženju kod **Modela 3**. Međutim, izrađene ROC krivulje, zajedno s AUC vrijednostima, nedvojbeno pokazuju kako je **Model 3** točniji od svih ostalih izrađenih modela (Sl. 36. i Sl. 37.). Iako su kod **Modela 2** smanjeni težinski koeficijenti vegetacije i pedologije, utjecaj ovih podataka je još uvijek prevelik, te se i dalje može primijetiti prevelika ovisnost izdvojenih zona o klasama navedenih kriterija. Također, kod **Modela 2** je prevelik težinski dodijeljen nagibu padina, koji svakako treba biti među najvažnijim kriterijima za određivanje podložnosti jaruženju, ali ne u ovolikoj mjeri. S druge strane, težinski koeficijenti kod **Modela 3** su znatno ujednačeniji, nego kod drugih modela, pri čemu je naglasak stavljen na važnost morfometrijskih parametara izvedenih iz DMR-a.




Slika 36. ROC krivulje izrađenih modela pogodnosti terena jaruženju napravljene na temelju 10 referentnih jaruga



Slika 37. ROC krivulje izrađenih modela pogodnosti terena jaruženju napravljene na temelju 120 jaruga kartiranih OBIA pristupom


Vrijednosti AUC određene prema referentnim jarugama svrstavaju sva četiri modela u kategoriju modela *vrlo dobre kvalitete* ($AUC = 0,8 - 0,9$) (Sl. 36.). Kod vrijednosti AUC izračunatih prema jarugama kartiranim OBIA pristupom dva modela (**Model 2**, **Model 3**) se mogu svrstati u kategoriju modela *vrlo dobre kvalitete* ($AUC = 0,8 - 0,9$), a dva (**Model 0**, **Model 1**) u kategoriju modela *dobre kvalitete* ($AUC = 0,7 - 0,8$) (Sl. 37.). **Model 3** predstavlja najtočniji model prema svim izrađenim ROC krivuljama, te je zbog toga odabran kao krajnji model (Sl. 38.). Izrađene ROC krivulje potvrđuju hipotezu da se izdvojene zone *visoke* i *vrlo visoke* podložnosti jaruženju podudaraju s postojećim jarugama otoka Paga.



Slika 38. Odabrani krajnji GIS-MCDA model podložnosti terena otoka Paga jaruženju;
 A – uvećani prikaz šireg prostora jaruge Sentiš

8.3. Zonacija podložnosti terena jaruženju

Izvedenim višekriterijskim modelom podložnosti terena jaruženju utvrđena je površinski obuhvat pojedinih klasa, unutar cijele površine otoka (Sl. 39.). Utvrđeno je kako na prostoru otoka Paga prevladavaju zone vrlo niske (15,355 % površine otoka) te niske (25,157 % površine otoka) podložnosti terena jaruženju. Iz prostornog razmještaja ovih klasa vidljivo je kako su one najprisutnije u nižim i zaravnjenijim dijelovima otoka, poput novaljsko-caske i paško-dinjiške flišne udoline. Također, velika zastupljenost ovih klasa opažena je i u zaravnjenom prostoru oko Malog i Velog blata. Vrlo visok udio površine otoka obuhvaćen je klasom srednje podložnosti jaruženju, koja obuhvaća oko 23 % površine otoka. Zone ove klase najzastupljenije su na blažim padinama izraženijih krških bila, gdje ovakve zone predstavljaju svojevrsan prijelaz prema zonama visoke i vrlo visoke podložnosti.



Slika 39. Udio različitih klasa podložnosti terena jaruženju u ukupnoj površini otoka Paga

Zona visoke podložnosti (19,681 % površine otoka) i vrlo visoke podložnosti (10,411 % površine otoka) jaruženju zajedno obuhvaćaju oko trećine ukupne površine otoka Paga. Ove zone dominiraju na blago nagnutim i nagnutim padinama krških bila, pri čemu je zamjetna znatno veća zastupljenost ovih zona na ogoljenom padinama istočne i sjeveroistočne orijentacije. Posebice je velika prisutnost ovih zona na prostoru istočne obale otoka, uz Velebitski kanal, od Ljubačkih vrata na jugu, sve do rta Sv. Nikola na sjeveru, te zatim od poluotoka Metajna sve do rta Lun. Velika prisutnost zona visoke i vrlo visoke podložnosti jaruženju zabilježna je i na severoistočnim padinama krškog hrpta Svetog Vida. Također, vidljivo je i jasno podudaranje ovih zona najviše podložnosti terena jaruženju s postojećim jarugama, koje je ranije dokazano izradom ROC krivulja. Boolean kriterij obuhvaća 5,587% površine otoka Paga, unutar kojih spadaju sve vodene površine i urbano-industrijske zone


otoka.

Detaljni prikaz statističkih pokazatelja vezanih za zastupljenost pojedinih klasa podložnosti terena jaruženju dan je u tablici 19.

Tablica 19. Zastupljenost pojedinih klasa napravljenog modela podložnosti jaruženju

#	Naziv klase	Površina klase (km ²)	Udio u ukupnoj površini otoka (%)
1	Boolean	15,8796	5,587
2	Vrlo niska podložnost	43,6412	15,355
3	Niska podložnost	71,5029	25,157
4	Srednja podložnost	67,6711	23,809
5	Visoka podložnost	55,9374	19,681
6	Vrlo viska podložnost	29,5897	10,411

Na temelju izvedenog modela podložnosti terena jaruženju analizirana je rasprostranjenost klasa vrlo visoke podložnosti jaruženja unutar administrativnih granica 25 naselja otoka Paga. Pri tome je analizirano područje od 500 m oko tlocrta svih urbanih površina unutar naselja (Sl. 40.).



Slika 40. Odabrani krajnji GIS-MCDA model podložnosti terena otoka Paga jaruženju za širi prostor grada Paga

Cilj provedene analize bio je utvrditi u kolikoj je mjeri neposredna okolina urbanih područja potencijalno ugrožena negativnim utjecajima procesa jaruženja. Ova analiza samo je primjer složenijih procjena utjecaja koje mogu biti napravljene na temelju izrađenog modela podložnosti.

Prikaz zastupljenosti zona vrlo visoke podložnosti unutar područja od 500 m oko tlocrta urbanih površina naselja otoka Paga dan je u tablici 20.

Tablica 20. Zastupljenost klase vrlo visoke podložnosti jaruženju unutar 500 m od urbanih zona

#	Naselje	Površina (km ²)	#	Naselje	Površina (km ²)
1	Pag	2,3448	12	Vidalići	0,0999
2	Kolan	0,5418	13	Kustići	0,0917
3	Bošana	0,5107	14	Miškovići	0,0865
4	Lun	0,3945	15	Gorica	0,0758
5	Metajna	0,3603	16	Stara Vas	0,0638
6	Stara Novalja	0,3103	17	Potočnica	0,0531
7	Vlašići	0,1933	18	Vrčići	0,0437
8	Šimuni	0,1748	19	Smokvica	0,0307
9	Dinjiška	0,1698	20	Caska	0,0290
10	Zubovići	0,1614	21	Košljun	0,0058
11	Novalja	0,1384	22	Mandre	0,0008

Najveći udio zona vrlo visoke podložnosti jaruženju u neposrednoj blizini urbane zone nalazi se u naselju Pag, gdje cijeli zapadni i jugozapadni dio naselja direktno graniči s jaruženjem zahvaćenim prostorom. U prvom redu se radi o novije izgrađenim stambenim objektima, koji su izgrađeni pod strmim istočnim padinama vanjskog pašskog krškog hrpta. Prisutnost zona vrlo visoke podložnosti ovako blizu naselju Pag može utjecati negativno na daljnji razvoj naselja, zbog destabilizacije padina i/ili formiranja bujičnih tokova.


Osim naselja Pag značajnija prisutnost zona vrlo visoke podložnosti jaruženju zabilježena je i kod naselja Bošana, koje se također nalazi u neposrednoj blizini jaruženjem zahvaćenih zona. U ostalim naseljima zabilježena je manja znatno manja prisutnost najugroženijih zona, dok u naseljima Povljana, Gajac i Kolanjski Gajac nije zabilježena prisutnost zona najveće ugroze.

9. Kvantitativna analiza intenziteta jaruženja – primjer jaruge Santiš

Svrha kvantitativnog opisivanja i proučavanja geometrijskih obilježja jaruga odnosi se na potrebu za što točnijim određivanjem raznovrsnih prostorno-vremenskih promjena, do kojih dolazi kontinuiranim djelovanjem procesa jaruženja, a koje su nužne za potpuno razumijevanje cjelokupnog procesa evolucije jaruga (Campo-Bescós i dr., 2013; Casalí i dr., 2015; Stöcker i dr., 2015; Wells i dr., 2017.). Među različitim geomorfometrijskim obilježjima većina autora u svojim istraživanjima za pokazatelje prostorno-vremenskih promjena uzima ili pomak čela jaruge (engl. *headcut retreat*) (Vandekerckhove i dr., 2003; Campo-Bescós i dr., 2013; Gómez-Gutiérrez i dr., 2014; Rengers i Tucker, 2014; Vanmaercke i dr., 2016.), ili pak promjene u određenim poprečnim presjecima jaruge (GCs) (Casalí i dr., 2015; Deng i dr., 2015.). Prostorno-vremenska evolucija jaruga proučavana je za razdoblje od šest mjeseci na temelju usporedbe dva periodička DMP-a prostorne rezolucije 2 cm. Korišteni DMP-ovi napravljeni su **Agisoft Photoscan PRO** softveru, prema fotografijama prikupljenima na terenu (DMP 1 – 26. svibnja 2017.; DMP 2 – 20. studenog 2017.), metodom ponovljene UAV fotogrametrije. Osim detekcije prostorno-vremenskih promjena uobičajenom usporedbom dva periodička DMP-a, nastale promjene unutar istraživanog područja proučavane su i pomoću novih razvijenih alata, koji su omogućili automatski izračun i praćenje promjena u odabranim dijelovima jaruge Santiš.

9.1. Detekcija prostorno-vremenskih promjena nastalih na prostoru jaruge Santiš


Substrakcijom DMP-ova napravljen je model *vertikalne razlike*, pomoću kojega su ustanovljene promjene nastale u šestomjesečnom razdoblju (Sl. 41.).



Slika 41. Izrađeni model prostorno-vremenskih promjena unutar jaruge Santiš (A – početni (čeoni) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)


Treba napomenuti kako na svim danim prikazima ustanovljenih promjena (Sl. 41 - Sl. 45.) klasa 0 – 5 cm predstavlja prostor moguće pogreške, koji je u procesu filtracije izdvojen, te se kao takav nije koristio u izračunima površinskih i volumetrijskih pokazatelja promjene (vidi 6.4.4.). Radi lakšeg opažanja nastalih promjena izrađeni model je podijeljen na model *akumulacije materijala* (Sl. 42.) te na model *trošenja materijala* (Sl. 44.).

Već iz prvog prikaza prostornog razmještaja ustanovljenih prostorno-vremenskih promjena vidljivo je kako, suprotno očekivanome, unutar početnog (čeonog) dijela jaruge Santiš prevladava akumulacija materijala (Sl. 41. A). Naime, ako se pogleda prostorni raspored područja akumulacije i trošenja materijala jasno je vidljivo kako u početnom dijelu jaruge na znatno većoj površini prevladava akumulacija materijala. S druge strane, prostorni obuhvat trošenja materijala je u tom početnom djelu jaruge ograničen na površinom manja područja. I prema intenzitetu zabilježene akumulacije je vidljivo kako se većina područja *srednje* (10 – 25 cm), *intenzivne* (25 – 50 cm) te *vrlo intenzivne promjene* (50 – 150 cm) nalaze upravo u početnom dijelu jaruge (Sl. 42.). S obzirom na to da se većina akumuliranog materijala nalazi u neposrednoj blizini strmog čeonog dijela jaruge, kod kojega su zabilježeni izraženi procesi odronjavanja (Sl. 45.), može se zaključiti kako većina materijala potječe od čela jaruge. Međutim, nedvojbeno je za akumuliranje materijala u početnom dijelu jaruge bitno i podzemno procjeđivanje vode, koja posljedično ispire materijal i postupno potkopava strme početne stijenske jaruge.



Slika 42. Intenzitet zabilježene akumulacije materijala unutar jaruge Santiš (A – početni (čeon) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)


U središnjem dijelu intenzivnija akumulacija zabilježena je tek u blizini krajnjeg dijela čela jaruge Santiš. Posebno je zanimljiva zabilježena akumulacija u završnom dijelu jaruge. Iako je prilikom terenskih posjeta jaruzi Santiš uočeno taloženje materijala iz jaruge na prostoru žala, kao i ispod morske razine, ovi sedimenti nisu zabilježeni na izrađenom modelu prostorno-vremenskih promjena. Ponajprije se to može pripisati izraženom utjecaju morskih valova i mijena, koji remete sedimentaciju materijala i uvjetuju gotovo stalno preoblikovanje ovog prostora. Međutim, vrlo je zanimljiva zabilježena akumulacija u završnom dijelu modela promjena, koju se može poistovjetiti s naplavljenim antropogenim materijalom. Naime, unutar istraživanog šestomjesečnog razdoblja došlo je do naplavlivanja raznovrsnog antropogenog materijala (npr. plastične cijevi, drvena građa, boce i sl.) na prostoru žala, zbog čega je taj materijal zabilježen u izrađenom modelu promjena (Sl. 43.). Naplavljeni antropogeni materijal dokaz je ispravnosti izrađenog modela, jer ovi predmeti definitivno nisu bili prisutni na prostoru žala prilikom izrade inicijalnog DMP-a područja, zbog čega se može reći da zapravo oni predstavljaju "antropogeno" inducirano taloženje materijala.




Slika 43. Akumulirani antropogeni materijal u završnom dijelu jaruge (*žalo*) kao dokaz ispravnosti izrađenih modela

Iako je zabilježen intenzitet trošenja materijala (Sl. 44.) prostorno gledano manjeg obuhvata od ustanovljene akumulacije, njegov značaj za oblikovanje prostora jaruge je i dalje vrlo važan. Očigledno je kako je većina trošenja materijala u početnom dijelu jaruge prisutna na najstrmijim dijelovima jaruge, gdje je došlo do odronjavanja materijala (Sl. 45.). O prisutnosti odronjavanja u čeonom dijelu jaruge svjedoči i zabilježena prisutnost tenzijskih pukotina (Sl. 45. A) i nedavno odronjenih dijelova tla (Sl. 45. B), koji su zabilježeni tijekom terenskih obilazaka. Međutim, treba napomenuti kako odronjavanje tla nije zabilježeno

izrađenim modelom prostorno-vremenskih promjena samo na glavnoj čeonj liniji jaruge Santiš, već je isto primijećeno i na manjim mikro čeonim linijama unutar same jaruge (Sl. 44.). Osim toga izraženije trošenje materijala prisutno je i u najdubljim dijelovima erodiranih mikrokanala, unutar glavnog kanala jaruge Santiš. Veći intenzitet trošenja materijala u dubljim dijelovima mikrokanala, posebice u središnjem dijelu jaruge, svjedoči o izraženijoj koncentriranosti površinskog otjecanja. Na temelju izvedenog modela trošenja materijala i



Slika 44. Intenzitet zabilježenog trošenja materijala unutar jaruge Santiš (A – početni (čeonj) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)



Slika 45. Uvećani prikaz prostora čela jaruge na kojemu je vidljivo zabilježeno odronjavanje materijala (lijevo); A – tenzijske pukotine nastale uz rub čela jaruge Santiš; B – odronjavanje zabilježeno tijekom terenskog obilaska jaruge Santiš

terenskih opažanja moguće je pretpostaviti kako se u ovim dijelovima jaruge prilikom intenzivnijih oborinskih događaja uspijeva oblikovati površinsko otjecanje dovoljne erozivne

energije za pojavu snažnijeg linearnog usijecanja mikrokanala u podlogu jaruge.


Navedeni zaključci o prostorno-vremenskim promjenama nastalim unutar jaruge Santiš potvrđeni su izradom površinskih i volumetrijskih pokazatelja (Sl. 46; Tabl. 21.). Promjene uzrokovane jaruženjem obuhvaćaju 468,6601 m površine, što predstavlja oko 40 % ukupne površine jaruge Santiš. Od navedene površine čak 79,4417 % (372,3118 m²) je zahvaćeno akumulacijom materijala, dok na preostalim 20,5582 % (96,3482 m²) površine zahvaćene zabilježenim promjenama prevladava trošenje materijala. O znatno dominantnijoj prisutnosti akumulacije na prostoru jaruge svjedoči i zabilježena promjena volumena (Tabl. 21.). Dok je iz jaruge trošenjem odneseno oko 11,5 m³ materijala, ukupan volumen akumuliranog materijala iznosi oko 36,5 m³, što predstavlja neto razliku volumena od oko 25 m³. Izvorište 25 m³ akumuliranog materijala je vjerojatno vezano za trošenje na višim dijelovima padine, izvan jaruge Santiš, zbog čega bi u daljnjim istraživanjima bilo poželjno proširiti područje istraživanja na cijelu padinu iznad same jaruge.

Tablica 21. Površinski i volumetrijski pokazatelji promjena unutar jaruge Santiš tijekom šestomjesečnog razdoblja

Statistički pokazatelj	Površina (m ²)	Površina (%)*	Volumen (Surfer 14)	Volumen (ArcGIS)	Razlika metoda (m ³)
Povećanje volumena (m ³)	372,3118	32,2318	36,5282	36,9395	0,4113
Smanjenje volumena (m ³)	96,3482	8,3411	-11,5788	-11,8749	-0,2961
Ukupno	468,6601	40,5729	24,9494	25,0645	0,1151

* udio površine ustanovljenih promjena u ukupnoj površini jaruge Santiš

Na temelju zabilježenih volumetrijskih promjena može se definitivno odbaciti hipotezu da na prostoru jaruge Santiš prevladava trošenje materijala. Iako je trošenje materijala vrlo bitan čimbenik oblikovanja topografskih značajki i izgleda prostora jaruge Santiš, napravljeni modeli i izračunati površinski i volumetrijski pokazatelji dokazali su kako je proces akumulacije materijala ipak znatno dominantniji od procesa trošenja materijala.



Slika 46. Zabilježene volumetrijske promjene unutar jaruge Santiš (A – početni (čeon) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)

9.2. Praćenje vertikalnog pomaka unutar jaruge (*gully cross-sections*)

Vertikalne promjene u poprečnim presjecima odabrane jaruge odraz su postupnog vertikalnog usijecanja kanala jaruge u podlogu, čime se jaruga produbljuje, te uzmak bočnih padina jaruge, čime se jaruga postupno proširuje. Uzmak bočnih padina jaruge (engl. *gully side wall retreat*) se smatra vrlo važnim čimbenikom degradacije tla, koji može biti odgovoran i za preko 50 % ukupnog odnešenog sedimenta iz jaruge (Blong i dr., 1982; Martínez-Casasnovas i dr., 2009.). Unatoč vrlo velikoj važnosti ovog procesa za sveukupnu morfološku evoluciju jaruge i izraženog utjecaja na degradaciju tla i odnošenje materijala, ovaj proces je u znatno manjoj mjeri proučavan od primjerice uzmak čeonog dijela jaruge (Martínez-Casasnovas i dr., 2004; Chaplot, 2013.).


Da bi se što bolje razumjela prostorno-vremenska evolucija pojedinih dijelova jaruge potrebno je provesti detaljnu morfometrijsku i tipološku klasifikaciju određenih promatranih kanala i to kroz kvantitativno opisivanje recentnih promjena u širini, dubini i površini promatranih poprečnih presjeka jaruge (*Gully cross-sections (GCs)*) te kroz klasifikaciju oblika presjeka (Gómez-Gutiérrez i dr., 2014; Casali i dr., 2015.). Detaljno kvantitativno opisivanje poprečnih presjeka jaruge (*GCs*) važno je i za izračun ukupnog volumena jaruge te praćenje intenziteta jaruženja, ali i za bolje razumijevanje utjecaja različitih čimbenika koji utječu na intenzitet jaruženja (Deng i dr., 2015.). Postoje brojne konvencionalne metode za terensko praćenje intenziteta jaruženja unutar odabranih *GCs*, poput erozijskih klinova, mjernih traka, totalne stanice, laserskih profilometara, itd. Konvencionalne metode se međusobno razlikuju po točnosti, vremenskoj učinkovitosti, kompleksnosti, ekonomičnosti, prostornoj ograničenosti, itd. (Castillo i dr., 2012). Dok preciznost i točnost ovakvih konvencionalnih

metoda za terensko prikupljanje podataka može biti zadovoljavajuća, njihov glavni nedostatak je prostorna ograničenost, uzrokovana visokom vremenskom neučinkovitosti te ovisnosti preciznosti i težine mjerenja o značajkama terena kojega se uzorkuje (Casalí i dr., 2006; Perroy i dr., 2010.). Zbog toga je upotreba konvencionalnih metoda ograničena na manja područja, unutar kojih je moguće uzorkovati ograničeni broj visinskih uzoraka. S druge strane sve veća dostupnost i kvaliteta raznovrsnih modela visoke prostorne rezolucije predstavlja odličnu osnovu za analiziranje prostorno-vremenskih promjena unutar GCs na sub-decimetarskoj razini (d'Oleire-Oltmanns i dr., 2012; Stöcker i dr., 2015.).

Zbog toga je u ovom dijelu diplomskog rada za potrebe praćenja vertikalnog intenziteta jaruženja unutar poprečnih presjeka jaruge Santiš razvijen novi metodološki pristup, koji se temelji na primjeni razrađenog i unaprijeđenog načela uzorkovanja konvencionalnih terenskih metoda unutar pikseli orijentiranog GIS okruženja. Međutim, za razliku od konvencionalnih metoda, uzorkovanje izrađenim GULIVER alatom je u potpunosti automatizirano, čime se maksimalno smanjuje utjecaj antropogenog čimbenika na preciznost mjerenja.

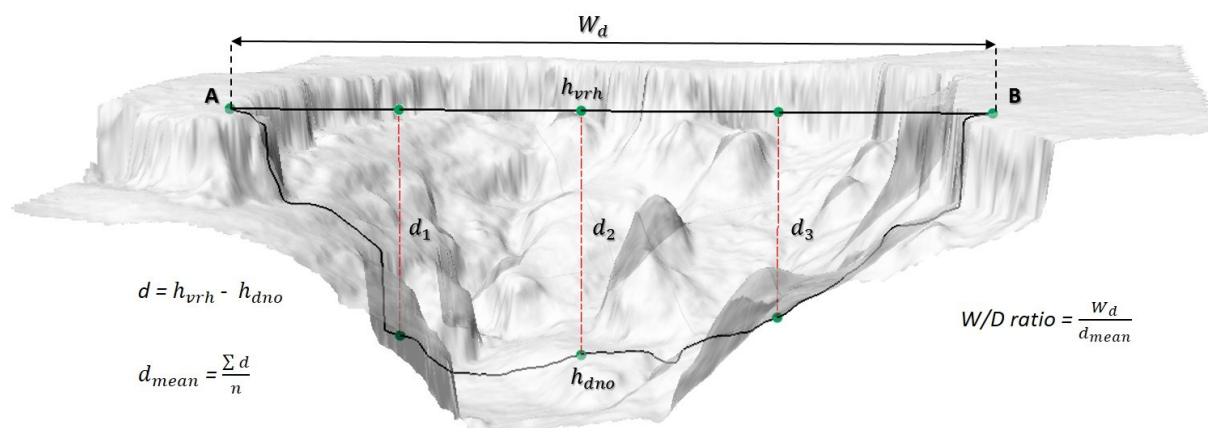
9.2.1. Princip praćenja stope vertikalnog pomaka unutar jaruge

Većina konvencionalnih metoda za praćenje intenziteta jaruženja u odabranim poprečnim presjecima jaruge, poput mjernih vrpca, profilometra ili laserskog mjerača udaljenosti temelji se na odabiru reprezentativnih profila određene jaruge, unutar kojih se vrši povremeno *in situ* uzorkovanje visinskih vrijednosti (Giménez i dr., 2009; Castillo i dr., 2012; Deng i dr., 2015.). Visinske vrijednosti prikupljaju se uzorkovanjem visina u odabranim točkama (xyz) duž svakog odabranog poprečnog presjeka, pri čemu se uzorkovanje vrši ili u pravilnim razmacima (Giménez i dr., 2009; Castillo i dr., 2015.) ili subjektivnim odabirom prema morfološkim značajkama presjeka (Deng i dr., 2015.). Usporedbom uzastopno prikupljenih visinskih vrijednosti unutar promatranih presjeka može se odrediti vertikalni pomak unutar svake točke (Δh_n) određenog presjeka, ili se pak mogu izdvojiti raznovrsni statistički pokazatelji za cijeli promatrani profil.



Slika 47. Načelo određivanja intenziteta jaruženja duž odabranog poprečnog presjeka (GCs_n) jaruge na temelju usporedbe dubina odabranih točaka (h_n)

Na slici 47. je prikazano načelo određivanja prostorno-vremenskih promjena na temelju periodičkog uzorkovanja visinskih točaka unutar odabranog GCs na terenu. U konačnici se iz prikupljenih točkastih visinskih uzoraka rekonstruira izgled poprečnog presjeka jaruge, na temelju kojega se mogu utvrditi osnovni kvantitativni pokazatelji, poput širine, dubine te površine GCs , ali i specifični pokazatelji morfoloških značajki proučavanog presjeka (Deng i dr., 2015; Caraballo-Arias i dr., 2016), poput omjera između širine i dubine GCs (engl. *W/d ratio*) (Sl. 48.)




Slika 48. Izračun odnosa širine i dubine (*W/d ratio*) poprečnog presjeka jaruge (GCs)

9.2.2. Razvoj alata za automatizirano praćenje vertikalnog pomaka u GCs

Metodološki pristup razvijen u sklopu ovog diplomskog rada omogućava praćenje prostorno-vremenskih promjena na razini cijelog prostora promatrane jaruge, kroz proces koji je gotovo u potpunosti automatiziran. Primjenom GULIVER alata kvantitativno opisivanje

morfoloških značajki i praćenje intenziteta jaruženja se također odvijaju kroz prikupljanje točkastih visinskih uzoraka duž poprečnih presjeka promatrane jaruge, ali pri tome se uzorci uzorkuju i uspoređuju izravno s periodički izrađenih DMP-ova te unutar znatno većeg broja poprečnih presjeka nego što je bilo moguće postići kroz *in situ* mjerenja.

Alat GULIVER, koristi sljedeća četiri korisničko definirana ulazna podatka (Sl. 49.):



Slika 49. Četiri ulazna podatka za izrađeni alat GULIVER

Izrađeni koncept praćenja vertikalnog pomaka temelji se na sljedećim koracima:

1. U prvom koraku GULIVER uz pomoć alata *Linear Directional Mean (LDM)* određuje prosječnu orijentaciju linije zadanog talvega jaruge (Sl. 50. A), koja je potrebna za kasnije generiranje poprečnih presjeka okomitih na pravac pružanja jaruge.
2. Nakon toga se s alatom *Densify* proglašuje broj lomnih točaka (*u nastavku LT*) talvega jaruge, pri čemu je definirano da alat izradi *LT* u razmacima od 5 cm. Ovaj korak je vrlo važan jer će prilikom izrade *GCs* u daljnjim koracima izrađene *LT* uvjetovati razmak na kojemu će se izrađivati poprečni presjeci. Da bi alat bio primjenjiv za provođenje analiza u drugim istraživanjima, prilikom izrade alata je ostavljena mogućnost da korisnik alata samostalno prilagodi vrijednost proglašivanja *LT*.
3. Zatim se iz zadane linije talvega promatrane jaruge s alatom *Feature to vertices* izdvajaju sve lomne točke (*LT*) linije talvega (Sl. 50. – B). Izdvojene lomne točke linije talvega jaruge definiraju lokacije gdje će u nastavku biti generirani poprečni presjeci jaruge.
4. Alatom *Ad XY Coordinates* se izdvojenim lomnim točkama (*LT*) pridodaju pravokutne koordinate unutar odabranog koordinatnog sustava (u ovom slučaju kartografska projekcija: HTRS96).


5. Izdvojenim LT je alatom *Ad Field* dodan atribut *Udaljenost (Input distance)*, koji se odnosi na željenu duljinu generiranih poprečnih presjeka. Isto kao i kod drugog koraka, ovdje je ostavljena mogućnost korisničkog definiranja vrijednosti atributa *Udaljenost*. Pri tome treba voditi računa da duljina generiranih poprečnih presjeka mora biti veća od maksimalne širine prostornog obuhvata jaruge (PO).
6. Zatim su s istim alatom dodani atributi *Kut 1 (A_1)* i *Kut 2 (A_2)*, koji označavaju kut pod kojim će poprečni presjeci biti konstruirani u lomnim točkama (LT), u odnosu na vrijednost LDM. Također, svakoj izvedenoj lomnoj točki je pridodan specifični identifikacijski broj (ID) prema kojemu će se izdvajati sumarna statistika za pojedine profile.

Kutovi 1 i 2 izračunati su prema sljedećim formulama:

$$A_1 = \text{LDM} (^\circ) + 90^\circ \quad (22)$$

$$A_2 = \text{LDM} (^\circ) - 90^\circ \quad (23)$$

7. Alatom *Bearing Distance to Line* su za svaku generiranu lomnu točku (LT), na temelju određenih kuteva (A_1 i A_2) izrađeni poprečni presjeci okomiti na LDM jaruge.
8. Izrađeni poprečni presjeci (GCs) su zatim skraćeni s alatom *Clip* tako da odgovaraju prostornom obuhvatu promatrane jaruge (Sl. 50 C).
9. Za uzorkovanje vrijednosti visina u izrađenim poprečnim presjecima jaruge primijenjeno je uzorkovanje u pravilnim razmacima, jer se željela postići što veća gustoća prikupljanja visina sa zadanih DMP-ova. Zbog toga je s alatom *Densify* dodatno povećana gustoća lomnih točaka u profilima (*Distance (d) = 5 cm*), čime se omogućilo uzorkovanje visina unutar jednakog razmaka od 5 cm, duž svakog izrađenog poprečnog presjeka. Međutim, da bi se omogućila prilagodba alata značajkama drugih područja istraživanja, te korištenju DMP-ova drugačije prostorne rezolucije, ostavljen je izbor korisničkog određivanja vrijednosti udaljenosti među točkama unutar profila.
10. Nakon izrade LT unutar izrađenih GCs, s alatom *Feature to vertices* se izdvajaju sve lomne točke (*h*) izrađenih poprečnih presjeka (GCs) (Sl. 50. - D), na temelju kojih će se u sljedećim koracima provesti uzorkovanje i usporedba vrijednosti visina s periodičkih DMP-ova.



Slika 50. Koncept praćenja vertikalnog pomaka unutar GCs jaruge korištenjem GULIVER alata

11. Za uzorkovanje visina s periodičkih DMP-ova (*DMP 1* i *DMP 2*) korišten je alat *Extract values to points*. Ovaj alat prenosi vrijednosti iz rasterskih ćelija zadanog rastera (DMP) u atributnu tablicu točkastog vektorskog sloja, što u zadanom primjeru znači da će svakoj generiranoj lomnoj točki (*h*) biti dodijeljena pripadajuća vrijednost za zadanog DMP-a.
12. Zatim alat GULIVER uspoređuje za svaku točku (*h*) vrijednosti visina s inicijalnog DMP-a (h_{DMP1}) i narednog zadanog DMP-a (h_{DMP2}), prema formuli:

$$\Delta h = h_{DMP2} - h_{DMP1} \quad (24)$$

Gdje je:

Δh = promjena visine u danoj točki GCs_n h_{DMP2} – visina DMP_2 u danoj točki

h_{DMP1} = visina DMP_2 u danoj točki


Pri tome pozitivne vrijednosti ukazuju da je u danoj točki došlo do akumulacije materijala, dok negativne vrijednosti ukazuju na prisutnost trošenja materijala.

13. Konačno u posljednjem koraku se uz pomoć alata Summary statistics generira tablica s preglednom statistikom za svaki pojedini izrađeni GCs. Izvedena statistika omogućava međusobnu usporedbu izrađenih GCs, kao i daljnju izradu različitih kvantitativnih pokazatelja.

Shematski prikaz izrađenog alata dan je na slici 52.

9.2.3. Rezultati primjene GULIVER alata na primjeru jaruge Santiš

Primjenom alata GULIVER unutar istraživanog područja je ukupno generirano 2699 GCs, unutar kojih je na osnovi zadanih periodičkih DMP-ova uzorkovana 871 465 visinska točka (Sl. 51.). Pri tome je korisničko-definirani parametar distanciranja postavljen na 5 cm, čime su definirani međusobna udaljenost izrađenih GCs, te razmak među uzorkovanim visinama (h) unutar GCs.



Slika 51. Izlazni podaci alata GULIVER za prostor jaruge Santiš

Iz slike 51. je vidljivo kako je pokrivenost područja istraživanja podacima generiranim alatom GULIVER izvrsna, ali i da su se pojavile dvije manje praznine u početnom i završnom dijelu jaruge. Veća praznina javila se među uzorkovanim podacima u početnom, istočnom dijelu jaruge, gdje zbog orijentacije izrađenih GCs manji dio čela jaruge nije pokriven izrađenim poprečnim presjecima. Korištenim pristupom izrađeni GCs ne moraju nužno biti u potpunosti okomiti na kanal jaruge, jer su svi poprečnih presjeci izrađivani pod kutem od 90° u odnosu na prosječnu orijentaciju talvega jaruge, a ne prema mikrolokcijskim značajkama kanala jaruge. Zbog toga može doći do otklona izrađenih GCs od idealne, potpuno okomite linije poprečnog presjeka te pojave praznina u početnom i završnom dijelu istraživanog područja. Ovaj nedostatak moguće je riješiti izradom GCs prema specifičnim vrijednostima orijentacije talvega jaruge, pri čemu bi se svaki poprečni presjek morao automatizmom prilagođavati mikrolokacijskim značajkama orijentacije linije talvega jaruge.

Iz prikupljenih visinskih uzoraka moguće je izračunati razliku visina preuzetih s periodičkih DMP-ova, pri čemu se rezultati mogu prikazati sumarno za sve prikupljene točke (Tabl. 22.), ili za pojedine izrađene GCs (Tabl. 23.).

Tablica 22. Sumarna statistika svih 871 465 točaka generiranih alatom GULIVER

Statistički pokazatelj	Vrijednost (m)
COUNT (Δh)	871 465
MIN (Δh)	-3,6841
MAX (Δh)	2,0491
SUM (Δh)	21616,3666
MEAN (Δh)	0,0248
RANGE (Δh)	5,7332
STD (Δh)	0,1414

Tablica 23. Statistički pokazatelji razlike visina (Δh) za prvih 10 GCs izrađenih GULIVER alatom

ID (GCs)	SUM (m)	MEAN (m)	MIN (m)	MAX (m)
1	23,6189	0,1109	-0,0221	0,9080
2	23,7239	0,1109	-0,0221	0,9080
3	23,6205	0,1104	-0,0158	0,9080
4	24,4560	0,1137	-0,0183	0,8806
5	23,7110	0,1098	-0,0146	0,6612
6	22,3798	0,1031	-0,0055	0,2801
7	22,8774	0,1059	-0,0093	0,3165
8	23,1521	0,1062	-0,0055	0,7985
9	22,3986	0,1018	-0,0049	0,3669
10	22,3271	0,1006	-0,0104	0,6148
RANGE (m)	STD (m)	COUNT (m)	FIRST (m)	LAST (m)
0,9302	0,0961	213	0,0886	0,9080
0,9302	0,0955	214	0,9080	0,0559
0,9238	0,0950	214	0,9080	0,0830
0,8988	0,0968	215	0,8806	0,0507
0,6758	0,0745	216	0,2916	0,0666
0,2856	0,0578	217	0,2716	0,0486
0,3258	0,0611	216	0,2716	0,0486
0,8040	0,0796	218	0,7985	0,3354
0,3718	0,0603	220	0,3669	0,2576
0,6252	0,0645	222	0,6148	0,1214

Statistički pokazatelji dani u tablici 23. omogućavaju kvantitativno zasnovanu međusobnu usporedbu i klasifikaciju izrađenih GCs. Primjerice, izrađeni GCs mogu se grupirati prema prosječnoj visinskoj razlici (MEAN (Δh)), pri čemu se zabilježene vrijednosti mogu korelirati s dimenzijama i značajkama danog kanala jaruge, ali i različitim značajkama podloge (npr. pedološkom podlogom, vegetacijskim pokrovom, itd.). Međutim, prikupljene vrijednosti visina mogu se iskoristiti i za izračun površine izrađenih GCs, na temelju koje je zatim moguće

izračunati ukupan volumen jaruge, gdje se volumen računa prema formuli (Castillo i dr., 2012.):

$$V = \sum_{i=1}^n \frac{A_{i-1} + A_i}{2} \times D_i \quad (25)$$

Gdje je:


A_{i-1} = nizvodna površina poprečnog presjeka isječka jaruge

A_i = uzvodna površina poprečnog presjeka isječka jaruge

D_i = udaljenost među susjednim poprečnim presjecima

Međutim, s obzirom na iznimno velik broj uzorkovanih visina i izrađenih GCs, izračun površine svakog poprečnog presjeka i ukupnog volumena jaruge zahtjeva dugotrajnu obradu podataka. Zbog toga prilikom daljnjeg razvoja GULIVER alata treba težiti pronalasku načina za potpuno uključivanje i automatizaciju izračuna površine GCs, iz koje će se tada moći jednostavno i brzo izvesti volumen jaruge.

Osim rezultata detaljne sumarne statistike, dodatnu prednost izrade gustog sloja točkastih visinskih uzoraka predstavlja mogućnost preciznog određivanja mikrolokacije pojedine uzorkovane visinske razlike Δh . Primjerice, dok rasterski prikazi pružaju odličan vizualni uvid u prostornu rasprostranjenost raznovrsnih prostorno-vremenskih promjena nastalih unutar istraživanog prostora, zabilježene vrijednosti promjena su pretežito generalizirane unutar zadanih klasa (npr. ranije korištena skala zabilježene promjene: 0 – 5 cm, 5 – 10 cm...50 – 150 cm). Zbog toga iz rasterskih prikaza nije jednostavno (bez provođenja dodatnih analitičkih operacija) odrediti preciznu xyz lokaciju željene vrijednosti zabilježene promjene (npr. Δh_{MAX}). S druge strane, na temelju kvantitativnih podataka generiranih alatom GULIVER moguće je jednostavno i brzo izdvojiti preciznu mikolokaciju bilo koje izmjerene Δh (Sl. 53.).



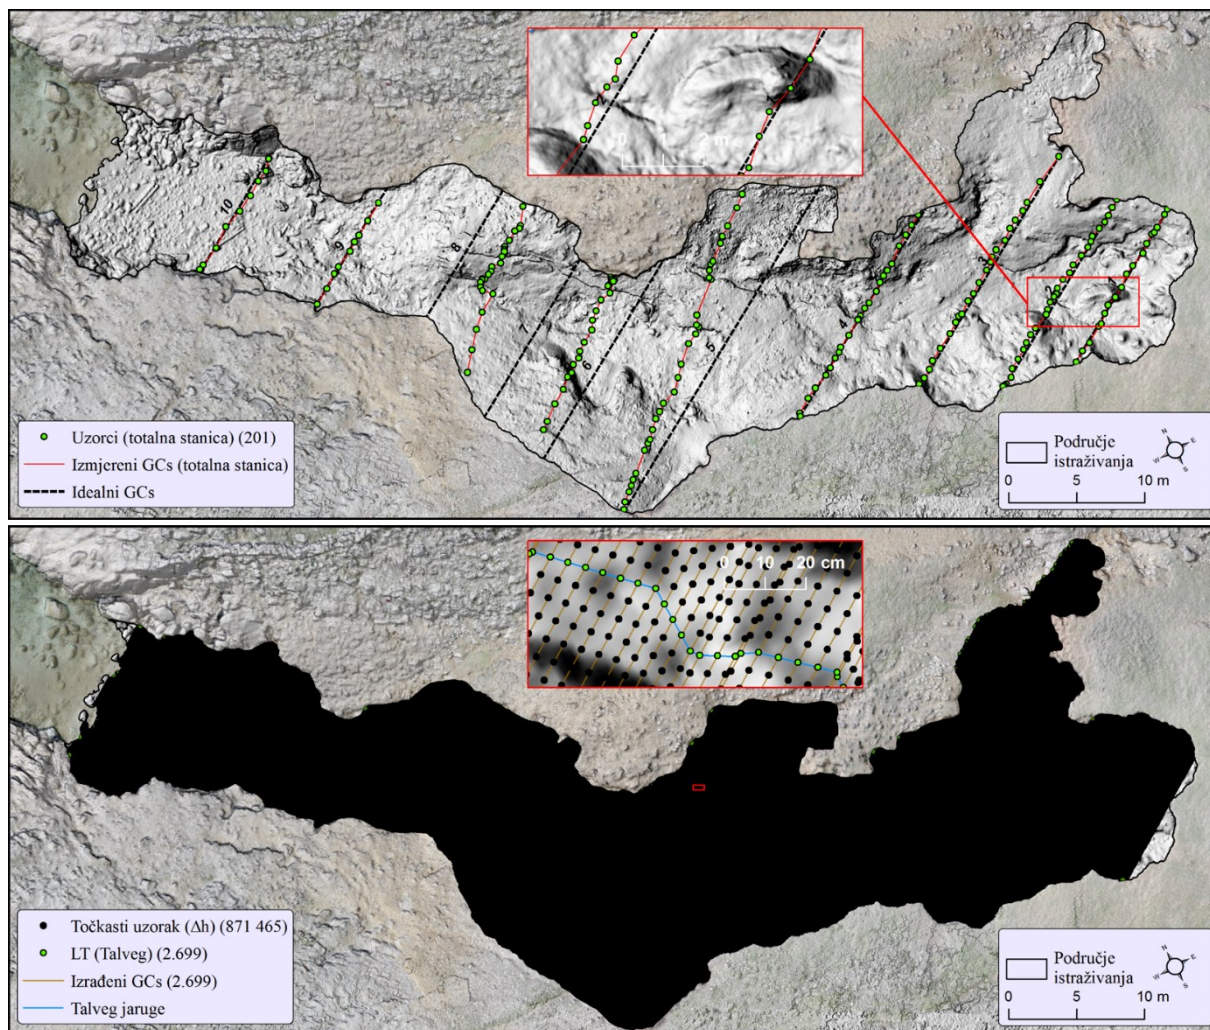
Slika 53. Primjer izdvajanja precizne xyz lokacije ekstremnih vrijednosti Δh

9.2.4. Procjena preciznosti i uspješnosti izrađenog alata

Da bi se procijenila uspješnost izrađenog alata za automatizirano praćenje vertikalnog pomaka, napravljena je usporedba rezultata generiranih GULIVER alatom za prostor jaruge Santiš s podacima prikupljenim totalnom stanicom (vidi 6.2.2. i 6.4.4.). Vizualna usporedba visinskih uzoraka prikupljenih totalnom stanicom (A) s podacima generiranim GULIVER alatom dana je na slici 53.

Prvi pokazatelj uspješnosti GULIVER alata je ukupni broj uzorkovanih visina. Dok je totalnom stanicom ukupno uzorkovan 201 visinski podatak, alatom GULIVER je prikupljen 871 465 visinski uzorak, što predstavlja postotak povećanja uzorkovanja od 433 564 %. Tome treba pridodati kako se izrađeni alat pokazao daleko učinkovitijom metodom uzorkovanja i prema kriteriju brzine uzorkovanja (V_u). Ukupno vrijeme prikupljanja visinskih uzoraka s totalnom stanicom iznosi 3 h i 30 minuta (210 minuta), iz čega proizlazi da brzina uzorkovanja ovom metodom iznosi 0,9571 uzoraka/min. S obzirom na to da vrijeme procesiranja izrađenog alata iznosi 30 minuta i 11 sekundi (30,183 minute), brzina uzorkovanja ove metode je 28872,7098 uzoraka/min. Vidljivo je kako razvijeni alat predstavlja daleko bržu i učinkovitiju metodu uzorkovanja s kojom je moguće prikupiti znatno više visinskih uzoraka u kraćem razdoblju.

Što se kriterija metodološke susljednosti tiče, poprečni presjeci generirani GULIVER alatom predstavljaju pravocrtne linije, koje se u potpunosti podudaraju s idealnim GCs , zbog čega sinusoidnost iznosi 1. S druge strane prilikom provođenja izmjere odabranih GCs totalnom stanicom nije bilo moguće postići takav stupanj preciznosti uzorkovanja, o čemu svjedoče vrijednosti sinusoidnosti. Prosječna sinusoidnost devet GCs izmjerenih totalnom stanicom iznosi 0,9517, iz čega je vidljivo da za razliku od GCs generiranih alatom ovi poprečni presjeci karakterizira blaga vijugavost, odnosno odudaranje od idealne pravocrtne linije ($S = 1$).




Slika 54. Usporedba prostornog rasporeda i brojnosti visinskih uzoraka prikupljenih totalnom stanicom (A) i alatom GULIVER (B)

Usporedba točnosti mjerenja izmjerenih visina nije napravljena, jer točnost GULIVER alata ovisi prije svega o kvaliteti korištenih DMP-ova, a ne samim značajkama metode uzorkovanja. Provedenom usporedbom moguće je potvrditi navedenu pretpostavku kako razvijeni metodološki pristup (GULIVER alat) omogućava detaljnije kvantitativno opisivanje značajki poprečnih presjeka od testirane totalne stanice, kao predstavnika konvencionalnih terenskih metoda.

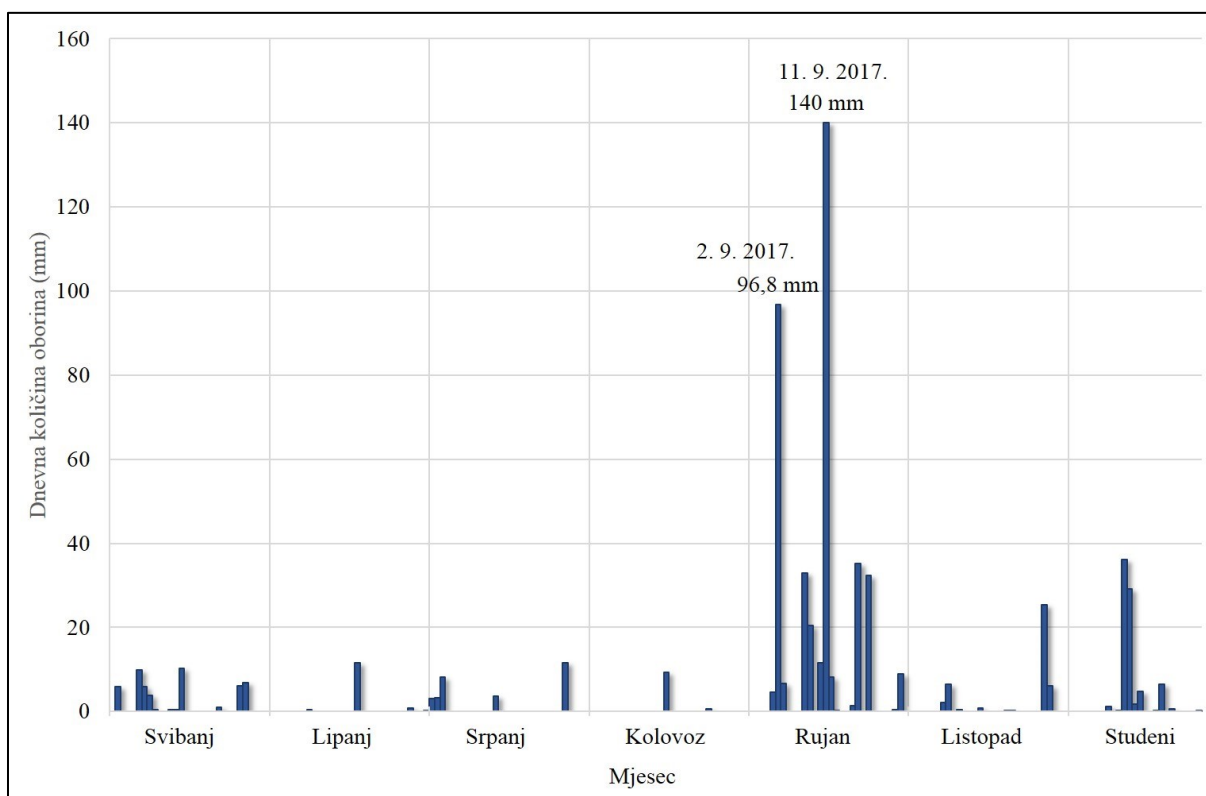
10. Utjecaj oborina na intenzitet jaruženja

Oborine su jedan od ključnih pokretačkih čimbenika trošenja materijala u sklopu procesa jaruženja (Valentin i dr., 2005.). Količina i intenzitet oborina izravno utječu na stvaranje površinskog i podzemnog otjecanja, koje, ako oslobođena energija nadjača otpor podloge, može dovesti do pojave trošenja i odnošenja materijala. Pri tome ključni znanstveni problem u proučavanju utjecaja oborina na pokretanje i izraženost jaruženja, predstavlja određivanje kritične količine oborina potrebne za pojavu jaruženja (Poesen i dr., 2003.). Kritična količina oborina potrebna za pokretanje jaruženja ovisi prije svega o specifičnim lokacijskim čimbenicima, poput otpornosti podloge uvjetovane pedološkim i topografskim značajkama terena, ili pak razvijenosti vegetacijskog pokrova i načinu iskorištavanja zemljišta (Poesen i dr., 2003; Valentin i dr., 2005; Vanmaercke i dr., 2016.). Da bi se odredio utjecaj oborina na pojavu i intenzitet jaruženja unutar istraživanog područja u ovom dijelu diplomskog rada je proučen odnos između zabilježenog intenziteta jaruženja i *in situ* prikupljenih podataka o količini oborina. Pri tome su obrađeni podaci o količini i intenzitetu oborina prikupljeni u razdoblju 1. svibnja. 2017. do 20. studenog 2017., unutar kojega su zabilježena ukupno 626 mm oborina. Iz prikupljenih oborinskih podataka napravljen je izračun ukupne mjesečne količine oborina (Sl. 55.) i ukupne dnevne količine oborina (Sl. 56.), dok je posebna pozornost dana izračunatim vrijednostima intenziteta oborina (mm/h) (Sl. 59.). Za klasifikaciju oborinskih događaja prema njihovom intenzitetu korištena je sljedeća ljestvica vrijednosti intenziteta oborina (*I*): *slaba kiša* ($I \leq 2$ mm/h), *umjerena kiša* ($2 < I \leq 15$ mm/h), *jaka kiša* ($15 < I \leq 30$ mm/h), *vrlo jaka kiša* ($30 < I \leq 60$ mm/h), *bujična kiša* ($I > 60$ mm/h) (Llasat, 2001.).

Kod kretanje ukupnih mjesečnih količina oborina na prostoru jaruge Santiš očigledna je izražena varijabilnost u količini oborina među obrađenim mjesecima (Sl. 55.). Dok ljetni mjeseci (lipanj-kolovoz) bilježe vrlo niske i relativno ujednačene količine oborina, očigledno je naglo povećanje ukupne količine oborina u rujnu. Povećanje količina oborina u razdoblju od rujna do prosinca uobičajeno je za prostor otoka Paga (Magaš, 2011.). Međutim, količina oborina zabilježena za rujna 2017. godine itekako odudara od uobičajenog godišnjeg rasporeda, prema kojemu prosječna rujanska vrijednost količine oborina iznosi 110 mm (Magaš, 2011.). Izrazito veliko povećanje ukupne mjesečne količine oborina, zabilježeno u rujnu 2017. godine, razumljivo je ukoliko se pogledaju ukupne zabilježene dnevne količine oborina (Sl. 56.).




Slika 55. Mjesečna količina oborina za jarugu Santiš - prikupljena unutar promatranog šestomjesečnog razdoblja (svibanj – studeni 2017.)




Slika 56. Dnevna količina oborina za jarugu Santiš - prikupljena unutar promatranog šestomjesečnog razdoblja (svibanj – studeni 2017.)

Iz obrađenih podataka o dnevnoj količini oborina vidljiv je značajan porast broja dana s velikim količinama padalina u rujnu. Posebice se ističu 2. rujna 2017. (96,8 mm) te 11. rujna 2017. (140 mm), unutar kojih je zabilježena znatno veća količina oborina nego u bilo kojem drugom obrađenom danu. Naročito su značajne hidrološke i morfološke promjene nastale na prostoru jaruge Santiš, koje su zapažene nakon navedenih obilnih i intenzivnih oborina. Naime, prilikom terenskog obilaska (13. rujna 2017.) je u samom dnu jaruge, na oko 3 m od morske razine zamijećen nastanak izvora (Sl. 57.), iz kojega je izvirala znatna količina vode. S obzirom na to da se izvor pojavio u samom dnu jaruge, voda se najvjerojatnije nakon obilnih oborina procjeđivala podzemnim šupljinama s cijelog prostora jaruge i njezinog drenažnog bazena. Pri istom terenskom obilasku je također primijećeno taloženje sedimenta u završnom dijelu jaruge te neposredno ispod površine mora. Nataloženi sedimenti bili su granulometrijski raspoređeni, pri čemu su svjetliji i krupniji fragmenti karbonata nataloženi bliže ušću jaruge u more, dok su finiji i sitniji sedimenti smeđeg tla nataloženi dalje od ušća jaruge (Sl. 57. B). Nažalost, ovakva granulometrijska stratifikacija sedimenata poremećena je već pri prvoj sljedećoj pojavi valova, zbog čega nije zabilježena izvedenim modelima prostorno-vremenskih promjena. Primijećena je i aktivacija nekoliko vrulja u neposrednoj blizini jaruge (Sl. 57. A), koje također svjedoče o izraženoj prisutnosti i važnosti podzemnog otjecanja na tom krškom području.



Slika 57. Hidrološke posljedice obilnih i intenzivnih oborina početkom rujna 2017. godine


Prilikom terenskog obilaska jaruge Santiš primijećen je i značajan utjecaj nedavnih oborina na preoblikovanje morfologije jaruge. Tako su u čeonom dijelu jaruge zabilježeni nedavni tragovi odronjavanja i odnošenja materijala (Sl. 58. A), dok je u dnu glavnog kanala jaruge uočena pojava mikro jaruga, uzrokovanih nedavnim površinskim otjecanjem (Sl. 58. B).



Slika 58. Morfološke posljedice obilnih i intenzivnih oborina početkom rujna 2017. godine (A – urušavanje materijala u čelu jaruge, B – odnošenje materijala)

Osim količine oborina vrlo bitan čimbenik za pojavu jaruženja je i intenzitet oborina, koji je izravno povezan s intenzitetom površinskog otjecanja (Faivre i dr., 2011.). Primjerice, eksperimentalna istraživanja provedena od strane Rengers i Tucker (2014.). dokazala su važnost intenzivnim oborinama induciranih bujičnih tokova na preoblikovanje morfologije kanala jaruge. Na temelju eksperimentalnih modela zaključili su kako oborine slabijeg intenziteta mogu uzrokovati odronjavanje materijala u prostoru čela jaruge, ali da ne mogu uzrokovati pojavu površinskog otjecanja dovoljne transportne energije potrebne za odnošenje nastalog materijala. Zbog toga dolazi do postupnog zatrpavanja čeonog prostora jaruge erodiranim materijalom. S druge strane, dokazali su kako intenzivniji oborinski događaji mogu dovesti do pojave bujičnog površinskog otjecanja, koje ima sposobnost odnošenja erodiranog materijala dalje od čela jaruge. Navedeni zaključci mogu se primijeniti na prostor jaruge Santiš, kroz korelaciju uočenih prostorno-vremenskih promjena (vidi 9.1.), s intenzitetom zabilježenih oborina (Sl. 59.). S obzirom na to da na prostoru jaruge Santiš nisu zamijećeni tragovi pojave površinskog otjecanja bujičnog karaktera, te da nije zabilježena pojava *bujična kiša* ($I > 60$ mm/h) može se zaključiti kako unutar proučavanog razdoblja nije došlo do pojave bujičnog površinskog otjecanja. Ovakav zaključak objašnjava pojavu akumulacije materijala u neposrednoj blizini čela jaruge Santiš, utvrđenu napravljenim modelima prostorno-vremenskih promjena.

Analizirani intenzitet oborina također ukazuje na izraženost dva ranije navedena oborinska događaja među svim zabilježenim oborinama. Od ukupno 13 oborinskih događaja za koje je zabilježen intenzitet oborina veći od 10 mm/h, čak četiri su vezana za oborine unutar 2. rujna 2017., dok je njih pet povezano s oborinama zabilježenim unutar 11. rujna 2017.



Slika 59. Zabilježeni intenzitet oborina (mm/h) za 13 najizraženijih oborinskih događaja

Od značajnijih oborinskih događaja prema njihovom intenzitetu, još dva događaja su zabilježena unutar rujna (17. rujna 2017. i 19. rujna 2017.), jedan događaj zabilježen je u listopadu (22. listopada 2017.), a dva događaja su zabilježena u studenom (6. studenog 2017. i 7. studenog 2017.). Prikazane vrijednosti intenziteta oborina pokazuju kako u razdoblju od svibnja do rujna nije bilo intenzivnijih oborina na prostoru jaruge Santiš. Najveći intenzitet oborina zabilježen tijekom ljetnih mjeseci zabilježen je 24. srpnja 2017., kada je registriran intenzitet od 48,2 mm/h.

Obradeni podaci svjedoče o nepravilnom rasporedu oborina unutar proučavanog razdoblja, pri čemu je očigledna sušnost razdoblja od svibnja do kraja kolovoza, kao i izražena vlažnost u rujnu i studenom. Terenskim opažanjima i napravljenim modelima prostorno-vremenskih promjena potvrđena je pretpostavka o povezanosti količine i intenziteta oborina s pojavom jaruženja. S obzirom na to da je u rujnu zabilježena znatno veća koncentracija oborina nego u drugim mjesecima, može se pretpostaviti da je većina promjena unutar jaruge Santiš nastala upravo u tom razdoblju. S druge strane, također je moguće pretpostaviti kako je zbog vrlo male količine oborina pojava jaruženja u ljetnim mjesecima znatno rjeđa. Međutim, ove pretpostavke u potpunosti će se moći dokazati jedino kroz nastavak započetih mjerenja, na temelju kojih će biti moguće utvrditi sezonalne sličnosti i razlike u kretanjima intenziteta oborina i jaruženja.

11. Zaključak

Istraživanjima provedenim u sklopu ovog diplomskog rada prikazano je kako se suvremene kvantitativne analitičke metode mogu primijeniti za analizu morfoloških oblika, pri čemu raspon istraživanja može varirati od vrlo velikih područja (primjerice otok Pag), pa sve do sub-decimetarske razine pojedinih mikro oblika. Na razini otoka Paga posebna pozornost dana je izdvajanju postojećih jaruga te predviđanju podložnosti različitih dijelova otoka pojavi jaruženja u budućnosti.

Pri kartiranju postojećih jaruga otoka Paga primijenjen je objektno-orijentirani pristup detekciji i izdvajanju jaruga iz rasterskih podataka srednje rezolucije. Pri tomu je osnovna pretpostavka bila da će se primijenjenim pristupom moći, neovisno o razmjerno lošoj kvaliteti korištenih rasterskih podataka, provesti kartiranje, barem većih jaruga na otoku. Rezultati provedenog kartiranja potvrđuju navedenu pretpostavku, međutim ujedno pokazuju da detaljnost i točnost takvog kartiranja još uvijek previše ovisi o kvaliteti i značajkama korištenih rasterskih podataka. Zbog toga egzaktnost ove metode za provođenje kartiranja u danom mjerilu još uvijek zaostaje za konvencionalnim metodama, poput ručne digitalizacije. Ako se u obzir uzme metodološka susljednost izdvajanja jaruga OBIA pristupom te mogućnost njezine primjene na razmjerno velikim područjima, može se ustvrditi kako ova metoda ima velik potencijal za primjenu u raznovrsnim daljnjim istraživanjima. Posebice bi trebalo ispitati mogućnosti primjene OBIA pristupa za kartiranje jaruga prema podacima visoke i vrlo visoke rezolucije, gdje bi ovaj pristup mogao ponuditi rješenja za neke od aktualnih znanstvenih problema, poput problematike povezane s točnim određivanjem prostornog obuhvata jaruga.

Na temelju 10 odabranih predisponirajućih kriterija te jednog ograničavajućeg Boolean kriterija izveden je višekriterijski model podložnosti terena otoka Paga jaruženju. Izvedenim višekriterijskim modelom potvrđena je pretpostavka o značajnom podudaranju postojećih jaruga s određenim zonama visoke i vrlo visoke podložnosti jaruženju. Podudaranje postojećih jaruga s višekriterijskim modelom potvrđeno je kroz evaluaciju modela na temelju napravljenih ROC krivulja. Model podložnosti jaruženju predstavlja osnovu za planiranje mjera za ograničavanje i prilagodbu daljnjim negativnim posljedicama procesa jaruženja na prostoru otoka. Prema napravljenom modelu zone visoke i vrlo visoke podložnosti jaruženju obuhvaćaju oko jedne trećine ukupne površine otoka, dok je provedenim analizama ustanovljena neposredna ugroženost pojedinih naselja (npr. grad Pag). U daljnjim istraživanjima treba detaljnije analizirati utjecaj izvedenih zona visoke i vrlo visoke podložnosti na ugroženost ostalih važnih dijelova otoka, poput agrarno i stočarski vrednovanih površina te zaštićenih

područja, kako bi se moglo provesti sustavnije planiranje mjera zaštite ugroženih dijelova otoka.

Provedenom kvantitativnom analizom intenziteta jaruženja ustanovljene su prostorno-vremenske promjene nastale na prostoru jaruge Santiš, unutar promatranog šestomjesečnog razdoblja. Izrađeni modeli te izračunati površinski i volumetrijski pokazatelji nepobitno su dokazali da, unatoč pretpostavljenom, na prostoru jaruge Santiš prevladava akumuliranje materijala, posebice u njezinom početnom, čeonom dijelu. Prisutnost znatnih količina akumuliranog materijala može se povezati sa zabilježenim intenzivnim procesom odronjavanja materijala s čela jaruge, ali i s podzemnim procjeđivanjem koje postupno ispire naslage tla s cijele padine. Najveće vrijednosti trošenja materijala opažene su na strmim, čeonim dijelovima jaruge, gdje se pojavilo već spomenuto urušavanje materijala, te u najdubljim dijelovima mikro jaruga, nastalih unutar glavnog kanala jaruge. Pri tomu je izraženo trošenje materijala u najdubljim dijelovima jaruge odraz stvaranja koncentriranog površinskog otjecanja u tim dijelovima jaruge. S obzirom na uočene nedostatke tehnologije korištene za prikupljanje podataka, a posebice s obzirom na negativan utjecaj vegetacije na točnost napravljenih modela, u daljnjim istraživanjima bi trebalo testirati mogućnosti primjene uređaja zasnovanih na laserskoj tehnologiji prikupljanja podataka, poput terestričkog i aero LiDAR-a. Također, u daljnjim istraživanjima bi trebalo uz jarugu Santiš, koja se prema uočenim značajkama jaruženja pokazala izvrsnim testnim područjem istraživanja, u istraživanja uvrstiti još nekoliko jaruga, nastalih na drugačijim tipovima pedološke podloge. Na taj način bi se mogla provesti korelacija između uočenog intenziteta jaruženja i značajki podloge na kojoj je određeni intenzitet zabilježen.

Razrađenim metodološkim pristupom za automatizirano praćenje vertikalnog pomaka unutar velikog broja poprečnih presjeka (GCs) odabrane jaruge, okupljenim u GULIVER alatu, unaprijeđene su dosadašnje mogućnosti kvantitativnog opisivanja dimenzija kanala jaruga. Primjenom načela konvencionalnih terenskih metoda za izmjernu dimenzija GCs unutar rasterski i vektorski orijentiranog GIS okruženja omogućeno je uzorkovanje znatno većeg broja visinskih uzoraka, nego što je to bilo moguće provesti terenskim izmjerama. Metodološka susljednost i brzina uzorkovanja izrađenog alata višestruko nadilaze vrijednosti, koje je moguće postići konvencionalnim metodama. Što je dokazano usporedbom izlaznih podataka napravljenog alata s rezultatima terenske izmjere provedene totalnom stanicom. Točnost samog alata ovisi prije svega o kvaliteti DMP-ova korištenih za usporedbu, zbog čega se može pretpostaviti da je zbog korištenja modela visoke rezolucije i točnost rezultata veća kod razrađenog alata, nego kod konvencionalnih metoda izmjere. U nastavku istraživanja treba razrađenom alatu dodati korake,

na temelju kojih bi bilo moguće automatizmom izračunati površinu svakog izmjerene *GCs*, te ukupan volumen proučavane jaruge.

Obradom prikupljenih podataka o količini i intenzitetu oborina nad prostorom jaruge Santiš uočen je nepravilan raspored padalina, s izraženim isticanjem nekoliko oborinskih događaja. Na temelju obrađenih podataka te provedenih terenskih istraživanja i opažanja moguće je zaključiti kako su količina i intenzitet oborina definitivno povezani s hidrološkim značajkama površinskog i podzemnog otjecanja, ali i s posljedičnim morfološkim promjenama nastalim unutar prostora jaruge. Zabilježenim vrijednostima količine i intenziteta oborina moguće je također objasniti povećanu akumulaciju materijala unutar početnog dijela jaruge. Unutar proučavanog razdoblja nije zabilježena pojava bujična kiša ($I > 60$ mm/h), niti pojava tragova posljedičnog bujičnog otjecanja, koje bi potencijalno imalo dovoljnu energiju za prijenos većih količina materijala dalje od čela jaruge. Zbog toga materijal nastao urušavanjem čela jaruge i podzemnim ispiranjem s prostora iznad same jaruge nije mogao biti transportiran dalje od čeonog prostora jaruge. Provedenim istraživanjima obrađen je samo manji dio klimatskih i pedološki uvjetovanih čimbenika, povezanih s procesom jaruženja, zbog čega bi u daljnjim istraživanjima svakako trebalo istražiti brojne druge čimbenike, poput temperature zraka, temperature i vlažnosti tla, provodljivosti tla, strukture i kompaktnosti tla, itd. Također, započeta praćenja količine i intenziteta oborina treba nastaviti, kako bi se mogla izvesti korelacija s intenzitetom jaruženja sezonalnog i višegodišnjeg karaktera.

S obzirom na veliku prostornu rasprostranjenost i raznolikost jaruga, prisutnost posebnih klimatskih i reljefnih predisponirajućih čimbenika, slabo razvijen vegetacijski pokrov, te provedenim istraživanjima potvrđenu prisutnost intenzivnog jaruženja, otok Pag se može smatrati, u svjetskim razmjerima, jedinstvenim područjem za proučavanje jaruženja.

Literatura

1. Agnesi, V., Angileri, S., Cappadonia, C., Conoscenti, C., Rotigliano, E. (2011): Multi-parametric GIS analysis to assess gully erosion susceptibility: a test in southern Sicily, Italy, *Landform Analysis*, 17, 15–20.
2. Barada, M. (2017): *Utjecaj korisničko-definiranih parametara na točnost digitalnog modela reljefa*, Diplomski rad, Sveučilište u Zadru, Odjel za geografiju, Zadar.
3. Ben Slimane, A., Raclot, D., Evrard, O., Sanaa, M., Lefevre, I., Le Bissonnais, Y. (2016): Relative contribution of rill/interrill and gully/channel erosion to small reservoir siltation in Mediterranean environments, *Land Degradation & Development*, 27(3), 785-797.
4. Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M. (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of photogrammetry and remote sensing*, 58(3), 239-258.
5. Blaschke, T. (2010): Object-based image analysis for remote sensing, *ISPRS journal of photogrammetry and remote sensing*, 65, 2-16.
6. Blong, R. J., Graham, O. P., Veness, J. A. (1982): The role of sidewall processes in gully development; some NSW examples, *Earth Surface Processes and Landforms*, 7(4), 381-385.
7. Bogunović, M., Šmanjak, I. (1983): Osnovne pedološke karte u mjerilu 1:50 000, sekcije Zadar 1 i 2, Rab 4, Senj 4, Projektni savjet za izradu pedološke karte SR Hrvatske
8. Boroushaki, S., Malczewski, J. (2010): Using the fuzzy majority approach for GIS-based multicriteria group decision-making, *Computers & Geosciences*, 36(3), 302-312.
9. Brown, C. D., Davis, H. T. (2006): Receiver operating characteristics curves and related decision measures: A tutorial, *Chemometrics and Intelligent Laboratory Systems*, 80(1), 24-38.
10. Bull, L. J., Kirkby, M. J. (ur.). (2002): *Dryland rivers: hydrology and geomorphology of semi-arid channels*, John Wiley & Sons, West Sussex, England
11. Cai, L., Shi, W., Miao, Z., Hao, M. (2018): Accuracy Assessment Measures for Object Extraction from Remote Sensing Images, *Remote Sensing*, 10(2), 303.
12. Campo-Bescós, M. A., Flores-Cervantes, J. H., Bras, R. L., Casalí, J., Giráldez, J. V. (2013): Evaluation of a gully headcut retreat model using multitemporal aerial photographs and digital elevation models, *J. Geophys. Res.-Earth*, 118, 1–15.
13. Caraballo-Arias, N. A., Conoscenti, C., Di Stefano, C., Ferro, V., Gómez-Gutiérrez, A. (2016): Morphometric and hydraulic geometry assessment of a gully in SW Spain, *Geomorphology*, 274, 143-151.
14. Casalí, J., Giménez, R., Campo-Bescós, M. A. (2015): Gully geometry: what are we

measuring?, *SOIL*, 1, 509–513.

15. Casalí, J., Loizu, J., Campo, M.A., De Santisteban, L.M., Álvarez-Mozos, J. (2006): Accuracy of methods for field assessment of rill and ephemeral gully erosion, *Catena* 67, 128– 138.
16. Castanedo, F. (2013): A review of data fusion techniques, *The Scientific World Journal*
17. Castillo, C., Pérez, R., James, M. R., Quinton, J. N., Taguas, E. V., 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.
18. Çetinkaya, C., Özceylan, E., Erbaş, M., Kabak, M. (2016): GIS-based fuzzy MCDA approach for siting refugee camp: A case study for southeastern Turkey, *International Journal of Disaster Risk Reduction*, 18, 218-231.
19. Chaplot, V. (2013): Impact of terrain attributes, parent material and soil types on gully erosion, *Geomorphology*, 186, 1-11.
20. Chen, H., Ito, Y., Sawamukai, M., Tokunaga, T. (2015): Flood hazard assessment in the Kujukuri Plain of Chiba Prefecture, Japan, based on GIS and multicriteria decision analysis, *Natural Hazards*, 78(1), 105-120.
21. Chung, C. J. F., Fabbri, A. G. (2003): Validation of spatial prediction models for landslide hazard mapping, *Natural Hazards*, 30(3), 451-472.
22. 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.
23. Conforti, M., Aucelli, P. P. C., Robustelli, G., Scarciglia, F. (2011): Geomorphology and GIS analysis for mapping gully erosion susceptibility in the Turbolo stream catchment (Northern Calabria, Italy), *Natural Hazards*, 56, 881–898.
24. Conoscenti, C., Valerio Agnesi, V., Angileri, S., Cappadonia, C., Rotigliano, E., Märker, M. (2013): A GIS-based approach for gully erosion susceptibility modelling: a test in Sicily, Italy, *Environmental Earth Sciences*, 70(3), 1179–1195.
25. Conrad, O. (2002): Terrain Parameters described in the SAGA-GIS Software v. 2.1. 0.
26. Crouch, R. J. (1987): The relationship of gully sidewall shape to sediment production, *Soil Research*, 25(4), 531-539.
27. d'Oleire-Oltmanns, S., Marzloff, I., Peter, K. D., Ries, J. B. (2012): Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco, *Remote Sensing*, 4(11), 3390-3416.
28. d'Oleire-Oltmanns, S., Eisank, C., Dragut, L., Blaschke, T. (2013): An object-based workflow to extract landforms at multiple scales from two distinct data types, *IEEE Geoscience and Remote Sensing Letters*, 10(4), 947-951.
29. d'Oleire-Oltmanns, S., Marzloff, I., Tiede, D., 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.

30. De Baets, S., Poesen, J., Reubens, B., Muys, B., De Baerdemaeker, J., Meersmans, J. (2009): Methodological framework to select plant species for controlling rill and gully erosion: application to a Mediterranean ecosystem, *Earth Surface Processes and Landforms*, 34(10), 1374-1392.
31. Deng, Q., Qin, F., Zhang, B., Wang, H., Luo, M., Shu, C., Liu, H., Liu, G. (2015): Characterizing the morphology of gully cross-sections based on PCA: A case of Yuanmou Dry-Hot Valley, *Geomorphology*, 228, 703-713.
32. De Reu, J., Bourgeois, J., Bats, M., Zwertvaegher, A., Gelorini, V., De Smedt, P., Chu, W., Antrop, M., De Maeyer, P., Finke, P., Van Meirvenne, M., Verniers, J., Cromb e, P. (2013): Application of the topographic position index to heterogeneous landscapes, *Geomorphology*, 186, 39-49.
33. Dewitte, O., Daoudi, M., Bosco, C., Van Den Eeckhaut, M. (2015): Predicting the susceptibility to gully initiation in data-poor regions, *Geomorphology*, 228, 101-115.
34. De Smith, M. J., Goodchild, M. F., Longley, P. (2007): *Geospatial analysis: a comprehensive guide to principles, techniques and software tools*, Troubador Publishing Ltd.
35. De Vente, J., Poesen, J. (2005): Predicting soil erosion and sediment yield at the basin scale: scale issues and semi-quantitative models, *Earth-Science Reviews*, 71(1), 95-125.
36. Drăguţ, L., Tiede, D., Levick, S. R. (2010): ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data, *International Journal of Geographical Information Science*, 24(6), 859-871.
37. Drăguţ, L., Csillik, O., Eisank, C., Tiede, D. (2014): Automated parameterisation for multi-scale image segmentation on multiple layers, *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 119-127.
38. Eastman, J. R. (1999): Multi-criteria evaluation and GIS, *Geographical information systems*, 1(1), 493-502.
39. Eastman, J. R. (2006): *Idrisi Andes: Guide to GIS and image processing*, Clark Labs, Clark University, Worcester, USA
40. Eisank, C., Smith, M., Hillier, J. (2014): Assessment of multiresolution segmentation for delimiting drumlins in digital elevation models, *Geomorphology*, 214, 452-464.
41. Erener, A., Mutlu, A., Düzg n, H. S. (2016): A comparative study for landslide susceptibility mapping using GIS-based multi-criteria decision analysis (MCDA), logistic regression (LR) and association rule mining (ARM), *Engineering Geology*, 203, 45-55.
42. Erktan, A., C cillon, L., Graf, F., Roumet, C., Legout, C., Rey, F. (2016): Increase in soil aggregate stability along a Mediterranean successional gradient in severely eroded gully bed

- ecosystems: combined effects of soil, root traits and plant community characteristics, *Plant and soil*, 398(1-2), 121-137.
43. Evans, I. S. (2012): Geomorphometry and landform mapping: What is a landform?, *Geomorphology*, 137(1), 94-106.
 44. Faivre, S., Pahernik, M., Maradin, M. (2011): The gully of Potovošća on the Island of Krk – the effects of short-term rainfall event, *Geologica Croatica*, 64(1), 67-80.
 45. Feizizadeh, B., Blaschke, T. (2013): GIS-multicriteria decision analysis for landslide susceptibility mapping: comparing three methods for the Urmia lake basin, Iran, *Natural Hazards*, 65(3), 2105-2128.
 46. Feizizadeh, B., Jankowski, P., Blaschke, T. (2014): A GIS based spatially-explicit sensitivity and uncertainty analysis approach for multi-criteria decision analysis, *Computers & geosciences*, 64, 81-95.
 47. Florinsky, I. (2016): *Digital terrain analysis in soil science and geology*, Academic Press
 48. Frankl, A., Deckers, J., Moulaert, L., Van Damme, A., Haile, M., Poesen, J., Nyssen, J. (2016): Integrated solutions for combating gully erosion in areas prone to soil piping: innovations from the drylands of Northern Ethiopia, *Land Degradation & Development*, 27(8), 1797-1804.
 49. Friedrich, K. (1998): Multivariate distance methods for geomorphographic relief classification, in: *Land Information Systems. Developments for Planning the Sustainable use of Land Resources* (Heineke HJ, Eckelmann W., Thomasson AJ, Jones RJA, Montanarella L., Buckley B., ur.), European Soil Bureau-Research Report, (4), 259-266.
 50. Giménez, R., Marzloff, I., Campo, M. A., Seeger, M., Ries, J. B., Casali, J., Alvarez-Mozos, J. (2009): Accuracy of high-resolution photogrammetric measurements of gullies with contrasting morphology, *Earth Surface Processes and Landforms*, 34(14), 1915-1926.
 51. Greene, R., Devillers, R., Luther, J. E., Eddy, B. G. (2011): GIS- Based Multiple- Criteria Decision Analysis, *Geography Compass*, 5(6), 412-432.
 52. Gómez-Gutiérrez, Á., Schnabel, S., Contador, F. L. (2009): Gully erosion, land use and topographical thresholds during the last 60 years in a small rangeland catchment in SW Spain, *Land Degradation & Development*, 20(5), 535-550.
 53. Gómez-Gutiérrez, Á., Schnabel, S., Berenguer-Sempere, Lavado-Contador, F., Rubio-Delgado, J. (2014): Using 3D photo-reconstruction methods to estimate gully headcut erosion, *Catena*, 120, 91–101.
 54. Gómez-Gutiérrez, Á., Conoscenti, C., Angileri, S. E., Rotigliano, E., 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.

55. Goudie, A. S. (2004): *Encyclopedia of Geomorphology*, International Association of Geomorphologists.
56. Hay, G., J., Castilla, G. (2006): Object-based image analysis: strenghts, weaknesses, opportunities and threats (SWOT), *Proc. 1st INT. Conf. OBIA*, 4-5.
57. Hengl, T. (2006): Finding the right pixel size, *Computers & Geosciences*, 32(9), 1283-1298.
58. Herzig, A., Dymond, J. R., Marden, M. (2011): A gully-complex model for assessing gully stabilisation strategies, *Geomorphology*, 133(1), 23-33.
59. Horn, B. K. (1981): Hill shading and the reflectance map, *Proceedings of the IEEE*, 69(1), 14-47.
60. Husnjak, S. (2014): *Sistematika tala Hrvatske*, Hrvatska sveučilišna naklada, Zagreb
61. IGU, Commission on applied geomorphology, subcommission on geomorphological mapping (1968): The unified key to the detailed geomorphological map of the world, 1:25000 – 1:50000, *Folia geografica, series geographica-physica 2*, Krakow.
62. James, M. R., Robson, S. (2012): Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application, *Journal of Geophysical Research: Earth Surface*, 117(F3).
63. James, M. R., Robson, S., d'Oleire-Oltmanns, S., Niethammer, U. (2017): Optimising UAV topographic surveys processed with structure-from-motion: Ground control quality, quantity and bundle adjustment, *Geomorphology*, 280, 51-66.
64. Jiang, H., Eastman, J. R. (2000): Application of fuzzy measures in multi-criteria evaluation in GIS, *International Journal of Geographical Information Science*, 14(2), 173-184.
65. Katz, H. A., Daniels, J. M., Ryan, S. (2014): Slope-area thresholds of road-induced gully erosion and consequent hillslope–channel interactions, *Earth Surface Processes and Landforms*, 39(3), 285-295.
66. Klaić, B. (1984): *Rječnik stranih riječi: tuđice i posuđenice*, Nakladni zavod MH, Zagreb
67. Kirkby, M. J., Bracken, L. J. (2009): Gully processes and gully dynamics, *Earth Surface Processes and Landforms*, 34(14), 1841-1851.
68. Kumar, S., Srivastava, P. K., Snehmani (2016): GIS-based MCDA–AHP modelling for avalanche susceptibility mapping of Nubra valley region, Indian Himalaya, *Geocarto International*, 1-14.
69. 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.
70. Lesschen, J. P., Kok, K., Verburg, P. H., Cammeraat, L. H. (2007): Identification of vulnerable areas for gully erosion under different scenarios of land abandonment in Southeast Spain,

Catena, 71(1), 110-121.

71. Liu, K., Ding, H., Tnag, G., Na, J., Huang, X., Xue, Z., Yang, X., 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.
72. 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*, 21(11), 1385-1400.
73. Lončar, N. (2009): Geomorfološka regionalizacija srednjeg i južnog dijela otoka Paga, *Geoadria*, 14/1, 5-25.
74. Lucà, F., Con Magiulo forti, M., 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.
75. Magaš, D. (2011): Zemljopisna obilježja otoka Paga u funkciji upoznavanja njegove toponimije, *Toponimija otoka Paga*, 5-49.
76. Magaš, D. (2013): *Geografija Hrvatske*, Zadar, Samobor: Odjel za geografiju Sveučilišta u Zadru, Meridijani.
77. Malczewski, J. (2004): GIS-based land-use suitability analysis: a critical overview, *Progress in planning*, 62(1), 3-65.
78. Malczewski, J. (2006): GIS-based multicriteria decision analysis: a survey of the literature, *International Journal of Geographical Information Science*, 20(7), 703-726.
79. Malczewski, J., Rinner, C. (2015): *Multicriteria decision analysis in geographic information science*, Springer.
80. Mancini, F., Dubbini, M., Gattelli, M., Stecchi, F., Fabbri, S., Gabbianelli, G. (2013): Using unmanned aerial vehicles (UAV) for high-resolution reconstruction of topography: The structure from motion approach on coastal environments, *Remote Sensing*, 5(12), 6880-6898.
81. Martinez-Casasnovas, J. A., Ramos, M. C., Poesen, J. (2004): Assessment of sidewall erosion in large gullies using multi-temporal DEMs and logistic regression analysis, *Geomorphology*, 58(1), 305-321.
82. Marzloff, 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.
83. Marzloff, I., Ries, J. B., 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), 1604-1623.
84. Mas, J. F., Soares Filho, B., Pontius, R. G., Farfán Gutiérrez, M., Rodrigues, H. (2013): A

- suite of tools for ROC analysis of spatial models, *ISPRS International Journal of Geo-Information*, 2(3), 869-887.
85. Miller, C., Laflamme, R., 1958: The digital terrain model — theory and applications, *Photogrammetric Engineering*, 24, 433-442.
 86. Modica, G., Laudari, L., Barreca, F., Fichera, C. R. (2014): A GIS-MCDA Based Model for the Suitability Evaluation of Traditional Grape Varieties: The Case-Study of 'Mantonico'Grape (Calabria, Italy), *International Journal of Agricultural and Environmental Information Systems (IJAEIS)*, 5(3), 1-16.
 87. Moges, A., Holden, N. M. (2008): Estimating the rate and consequences of gully development, a case study of Umbulo catchment in southern Ethiopia, *Land Degradation & Development*, 19(5), 574-586.
 88. Möller, M., Volk, M., Friedrich, K., 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-Zeitschrift Fur Pflanzenernahrung Und Bodenkunde*, 171 (3), 419–430.
 89. Möller, M., Koschitzki, T., Hartmann, K. J., Jahn, R. (2012): Plausibility test of conceptual soil maps using relief parameters, *Catena*, 88(1), 57-67.
 90. Moore, I.D., Grayson, R. B., Ladson, A. R. (1991.): Digital Terrain Modelling: A review of Hydrological, Geomorphological and Biological applications, *Hydrological Processes*, 5, 3-30.
 91. Morgan, R. P. C., Nearing, M. (Eds.), (2016): *Handbook of erosion modelling*, John Wiley & Sons.
 92. Penzar, B., Penzar, I., Orlić, M. (2001): Vrijeme i klima hrvatskog Jadrana, Hrvatski hidrografski institut, Zagreb-Koprivnica-Split.
 93. Perroy, R. L., Bookhagen, B., Asner, G. P., Chadwick, O. A. (2010): Comparison of gully erosion estimates using airborne and ground-based LiDAR on Santa Cruz Island, California, *Geomorphology*, 118(3), 288-300.
 94. Pike, R. J., Evans, I. S., Hengl, T. (2009): Geomorphometry: a brief guide, *Developments in Soil Science*, 33, 3-30.
 95. Pike, A., Mueller, T., Rienzi, E., Neelakantan, S., Mijatovic, B., Karathanasis, T., Rodrigues, M. (2012): Terrain analysis for locating erosion channels: Assessing LiDAR data and flow direction algorithm, u: *Research on Soil Erosion*, InTech.
 96. Pinto, D., Shrestha, S., Babel, M. S., Ninsawat, S. (2017): Delineation of groundwater potential zones in the Comoro watershed, Timor Leste using GIS, remote sensing and analytic hierarchy process (AHP) technique, *Applied Water Science*, 7(1), 503-519.

97. Poesen, J., Vandekerckhove, L., Nachtergaele, J., Oostwoud Wijdenes, D., Verstraeten, G., van Wesemael, B. (2002): Gully erosion in dryland environments, u: Bull, LJ, Kirkby, MJ (ur.), *Dryland rivers: hydrology and geomorphology of semi-arid channels*, Wiley, Chichester, UK, 229-262.
98. Poesen, J., Nachtergaele, J., Verstraeten, G., Valentin, C. (2003): Gully erosion and environmental change: importance and research needs, *Catena*, 50, 91– 133.
99. Poesen, J., Vanwalleghem, T., de Vente, J., Knapen, A., Verstraeten, G., Martínez-Casasnovas, J. A. (2006). Gully erosion in Europe, *Soil erosion in Europe*, 515-536.
100. Poesen, J. (2011): Challenges in gully erosion research, *Landform analysis*, 17, 5-9
101. Rahmati, O., Haghizadeh, A., Pourghasemi, H.R., Noormohamadi, F. (2016a): Gully erosion susceptibility mapping: the role of GIS-based bivariate statistical models and their comparison, *Natural Hazards*, 82(2), 1231-1258.
102. Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H. R., Feizizadeh, B. (2016b): 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.
103. Rengers, F. K., Tucker, G. E. (2014): Analysis and modeling of gully headcut dynamics, North American high plains, *Journal of Geophysical Research: Earth Surface*, 119(5), 983-1003.
104. Rikalovic, A., Cosic, I., Lazarevic, D. (2014): GIS based multi-criteria analysis for industrial site selection, *Procedia Engineering*, 69, 1054-1063.
105. Saaty, T. L. (1980): *The AHP: Planning, Priority Setting, Resource Allocation*, McGraw-Hill, New York
106. Saaty, T. L. (1990): How to make a decision: the analytic hierarchy process, *European journal of operational research*, 48(1), 9-26.
107. Saaty T.L. (2001): The Seven Pillars of the Analytic Hierarchy Process, u: Köksalan M., Zionts S. (ur.) *Multiple Criteria Decision Making in the New Millennium*, Lecture Notes in Economics and Mathematical Systems, Springer, vol 507.
108. Saaty, T. L. (2008): Decision making with the analytic hierarchy process, *International journal of services sciences*, 1(1), 83-98.
109. Shervais, K. (2017): *Structure from Motion Introductory Guide*
110. Shruthi, R. B., Kerle, N., Jetten, V. (2011): Object-based gully feature extraction using high spatial resolution imagery, *Geomorphology*, 134 (3), 260-268.
111. Shruthi, R. B., Kerle, N., Jetten, V., Stein, A. (2014): Object-based gully system prediction from medium resolution imagery using Random Forests, *Geomorphology*, 216, 283-294.
112. Shruthi, R. B., Kerle, N., Jetten, V., Abdellah, L., Machmach, I. (2015): Quantifying temporal

- changes in gully erosion areas with object oriented analysis, *Catena*, 128, 262-277.
113. Soil Science Society of America (2008): *Glossary of soil science terms*, ASA-CSSA-SSSA, Madison, WI, SAD
 114. Stöcker, C., Eltner, A. Karrasch, P. (2015): Measuring gullies by synergetic application of UAV and close range photogrammetry — A case study from Andalusia, Spain, *Catena* 132, 1–11.
 115. Šiljeg, A. (2013): *Digitalni model reljefa u analizi geomorfometrijskih parametara – primjer PP Vransko jezero*, doktorski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek, Zagreb.
 116. Valentin, C., Poesen, J., Li, Y. (2005): Gully erosion: Impacts, factors and control, *Catena*, 63, 132–153.
 117. 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.
 118. Vandekerckhove, L., Poesen, J., Wijdenes, D. O., Gyssels, G. (2001): Short-term bank gully retreat rates in Mediterranean environments, *Catena*, 44(2), 133-161.
 119. Vandekerckhove, L., Poesen, J., Govers, G. (2003): Medium-term gully headcut retreat rates in Southeast Spain determined from aerial photographs and ground measurements, *Catena*, 50(2), 329-352.
 120. Vanmaercke, M., Poesen, J., Van Mele, B., Demuzere, M., Bruynseels, A., Golosov, V., i dr. (2016). How fast do gully headcuts retreat?, *Earth-Science Reviews*, 154, 336-355.
 121. Wang, T., He, F., Zhang, A., Gu, L., Wen, Y., Jiang, W., Sao, H. (2014): A quantitative study of gully erosion based on object-oriented analysis techniques: a case study in Beiyanzikou catchment of Qixia, Shandong, China, *The Scientific World Journal*
 122. Wells, R. R., Momm, H. G., Castillo, C. (2017): Quantifying uncertainty in high-resolution remotely sensed topographic surveys for ephemeral gully channel monitoring, *Earth Surface Dynamics*, 5(3), 347.
 123. Westby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., Reynolds, J. M. (2012): ‘Structure-from-Motion’ photogrammetry: A low-cost, effective tool for geoscience applications, *Geomorphology*, 179, 300-314.
 124. Whiteside, T. G., Maier, S. W., Boggs, G. S. (2014): Area-based and location-based validation of classified image objects, *International Journal of Applied Earth Observation and Geoinformation*, 28, 117-130.
 125. Whitford, J. A., Newham, L. T. H., Vigiak, O., Melland, A. R., Roberts, A. M. (2010): Rapid assessment of gully sidewall erosion rates in data-poor catchments: a case study in Australia,

Geomorphology, 118(3), 330-338.

126. Wijdenes, D. J. O., Poesen, J., Vandekerckhove, L., Ghesquiere, M. (2000): Spatial distribution of gully head activity and sediment supply along an ephemeral channel in a Mediterranean environment, *Catena*, 39(3), 147-167.
127. Wilson, J. P., Gallant, J. C. (ur.). (2000): *Terrain analysis: principles and applications*, John Wiley & Sons, New York, SAD
128. Zevenbergen, L. W., Thorne, C. R. (1987): Quantitative analysis of land surface topography, *Earth surface processes and landforms*, 12(1), 47-56.
129. Zhan, Q., Molenaar, M., Tempfli, K., Shi, W. (2005). Quality assessment for geo-spatial objects derived from remotely sensed data, *International Journal of Remote Sensing*, 26(14), 2953-2974.
130. Zhang, H., Yang, Q., Li, R., Liu, Q., Moore, D., He, P., Ritsema, C.J., Geissen, V. (2013): Extension of a GIS procedure for calculating the RUSLE equation LS factor, *Computers & Geosciences*, 52, 177-188

Izvori

1. Državna geodetska uprava Republike Hrvatske, (2018.): Digitalni model reljefa - vektorski podatci o visinama prikupljeni fotogrametrijskom izmjerom i restitucijskom obradom
2. Državna geodetska uprava Republike Hrvatske, (2018.): WMS server Republike Hrvatske: DOF 1:5000, HOK 1:5000 (geoportal.dgu.hr/wms)

URL 1 <http://www.seos-project.eu/modules/remotesensing/remotesensing-c03-p02.html> (31. 9. 2017.)

URL 2 <https://pix4d.com/> (1. 4. 2017.)

URL 3 <http://www.stonex.hr/S10.pdf> (1. 4. 2017.)

URL 4 <http://www.onsetcomp.com/products/data-loggers/rg3-m> (2. 5. 2017.)

URL 5 <http://www.dgu.hr/proizvodi-i-usluge/sluzbene-drzavne-karte-i-podaci-topografske-izmjere/digitalni-model-reljefa-dmr.html> (1. 4. 2017.)

URL 6 <http://lexicon.ft.com/Term?term=multiple-criteria-decision-analysis&mhq5j=e7> (29. 10. 2017.)

URL 7 <https://www.projectsmart.co.uk/smart-goals.php> (29. 10. 2017.)

URL 8 <http://gim.unmc.edu/dxtests/roc3.htm> (23. 1. 2018.)

URL 9 <http://desktop.arcgis.com/en/arcmap/latest/extensions/spatial-analyst/a-quick-tour-of-spatial-analyst.htm> (31. 10. 2017.)

URL 10 <https://sentinel.esa.int/web/sentinel/missions/sentinel-2> (10. 9. 2017.)

URL 11 <http://gis4geomorphology.com/basin-basics-i/> (2. 10. 2017.)

URL 12 <http://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/how-focal-statistics-works.htm> (2. 10. 2017.)

URL 13 <http://desktop.arcgis.com/en/arcmap/latest/extensions/arcscan/about-vectorization-settings.htm> (9. 12. 2017.)

URL 14 <http://desktop.arcgis.com/en/arcmap/10.3/analyze/modelbuilder/what-is-modelbuilder.htm> (3. 11. 2017.)

Popis grafičkih priloga

1. Slika 1. Detaljnosti prikaza prostora jaruge Santiš s ortofoto snimcima (DOF) različite prostorne rezolucije
2. Slika 2. Prostorni obuhvat i razdioba istraživanog područja na mezo (A) i mikro (B) razinu
3. Slika 3. Jaruga Santiš i okružujući krški krajolik
4. Slika 4. Smještaj jaruge Santiš u ogoljenom priobalnom dijelu otoka Paga (A); naslage tla u čeonom dijelu jaruge Santiš (B)
5. Slika 5. Odnos između površine jaruge Santiš (desno) i površine njezinog slivnog područja (lijevo)
6. Slika 6. Plan aerofotogrametrijskog snimanja šireg prostora sliva jaruge Santiš (A), plan aerofotogrametrijskog snimanja užeg prostora jaruge Santiš i snimanja poprečnih presjeka totalnom stanicom (B)
7. Slika 7. Izmjera GCs uz pomoć uređaja LEICA TCR805 Power (A); označavanje poprečnog presjeka uz pomoć mjerne trake (B)
8. Slika 8. Plan snimanja prostora sliva jaruge Santiš (lijevo); primjer označavanja orijentacijskih točaka i prikupljanja njihovih preciznih koordinata (desno – A i B)
9. Slika 9. Prikaz utjecaja vertikalne raščlanjenosti terena i mjesta uzleta na prostornu rezoluciju modela (PR – prostorna rezolucija modela; h – visina leta; A – mjesto uzleta)
10. Slika 10. Načelo postizanja konstantne visine aerofotogrametrijskog snimanja nad vertikalno

raščlanjenim terenom kroz korištenje više misija snimanja

11. Slika 11. Plan snimanja prostora jaruge Santiš (lijevo); primjer označavanja orijentacijskih točaka i prikupljanja njihovih preciznih koordinata (desno – A i B)
12. Slika 12. Utjecaj vegetacije na pojavu artefakata na izrađenom DMP-u; A - artefakti na prikazu reljefa sjenčanjem; B - artefakti na modelu nagiba padina
13. Slika 13. Unutrašnjost mjernog uređaja Hobo Onset RG3-M postavljenog na ravnu drvenu dasku i obloženog kamenjem
14. Slika 14. A - uređaj M1 postavljen na uzvišenje nedaleko od jaruge Santiš; B - uređaj M2 postavljen na zid staje nedaleko od sela Dinjiška
15. Slika 15. A – lokacija postavljenih uređaja u jugoistočnom dijelu otoka Paga; B – lokacija primarnog (M1) i sekundarnog (M2) postavljenog Hobo Onset RG3-M uređaja; C – udaljenost M1 uređaja od jaruge Santiš
16. Slika 16. Prikaz odabranih faza izrade DMP u APP softveru (A – orijentacija snimaka; B – dodavanje GCPs; C – izrada teksture modela)
17. Slika 17. Referentne jaruge kartirane metodom ručne digitalizacije prema DOF-u visoke prostorne rezolucije (PR = 0.5 m)
18. Slika 18. Utjecaj definiranih parametara MRS na izgled rezultatnih objekata
19. Slika 19. Načelo određivanja točnosti izdvojenih objekata preklapanjem referentnih jaruga (A) s jarugama kartiranim OBIA pristupom (B)
20. Slika 20. Tijek primijenjene višekriterijske GIS analize (prema Eastman, 1999.)
21. Slika 21. Ulazni podaci za izradu ROC krivulja (A – model podložnosti jaruženju; B – binarni prikaz referentnih jaruga)
22. Slika 22. Primjer izračuna sumarne statistike za središnji piksel pravokutnog pokretnog prozora veličine 3 x 3 piksela (prema URL 12)
23. Slika 23. Načini izdvajanja linije prostornog obuhvata jaruge Santiš
24. Slika 24. Filtracija objekata izdvojenih OBIA pristupom (A – pojava "lažnih" kandidata jaruga na prostoru obalnih strmaca; B1 – primjer izostanka kartiranja slabije izraženih jaruga; B2 – primjer lošijeg kartiranja dimenzijama manjih jaruga)
25. Slika 25. Usporedba referentnih jaruga s jarugama kartiranim prema OBIA pristupu
26. Slika 26. Prosječne vrijednosti tri odabrana metrička pokazatelja površinske točnosti kartiranja jaruga OBIA pristupom (COR – Correctness; COM – Completeness; OQ - Overall quality)
27. Slika 27. Udio jaruga prema orijentaciji (A); udio jaruga prema aktivnosti (B); udio jaruga prema složenosti (C)
28. Slika 28. Prostorni razmještaj 120 jaruga otoka Paga kartiranih OBIA pristupom; A – uvećani

prikaz šireg prostora jaruge Starca draga

29. Slika 29. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju (A)
30. Slika 30. Odabrani kriteriji GIS-MCDA podložnosti terena jaruženju (B)
31. Slika 31. Ocjene pogodnosti pojedinih klasa odabranih kriterija GIS-MCDA (A)
32. Slika 32. Ocjene pogodnosti pojedinih klasa odabranih kriterija GIS-MCDA (B)
33. Slika 33. Vizualna usporedba modela izrađenih prema različitim težinskim koeficijentima
34. Slika 34. Vizualna usporedba zona visoke podložnosti jaruženju (Model 3) s referentnim jarugama kartiranim metodom ručne digitalizacije (Metodologija 6.4.)
35. Slika 35. Vizualna usporedba zona visoke podložnosti jaruženju (Model 3) s jarugama kartiranim OBIA pristupom
36. Slika 36. ROC krivulje izrađenih modela pogodnosti terena jaruženju napravljene na temelju 10 referentnih jaruga
37. Slika 37. ROC krivulje izrađenih modela pogodnosti terena jaruženju napravljene na temelju 120 jaruga kartiranih OBIA pristupom
38. Slika 38. Odabrani krajnji GIS-MCDA model podložnosti terena otoka Paga jaruženju; A – uvećani prikaz šireg prostora jaruge Santiš
39. Slika 39. Udio različitih klasa podložnosti terena jaruženju u ukupnoj površini otoka Paga
40. Slika 40. Odabrani krajnji GIS-MCDA model podložnosti terena otoka Paga jaruženju za širi prostor grada Paga
41. Slika 41. Izrađeni model prostorno-vremenskih promjena unutar jaruge Santiš (A – početni (čeoni) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)
42. Slika 42. Intenzitet zabilježene akumulacije materijala unutar jaruge Santiš (A – početni (čeoni) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)
43. Slika 43. Akumulirani antropogeni materijal u završnom dijelu jaruge (žalo) kao dokaz ispravnosti izrađenih modela
44. Slika 44. Intenzitet zabilježenog trošenja materijala unutar jaruge Santiš (A – početni (čeoni) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)
45. Slika 45. Uvećani prikaz prostora čela jaruge na kojemu je vidljivo zabilježeno odronjavanje materijala (lijevo); A – tenzijske pukotine nastale uz rub čela jaruge Santiš; B – odronjavanje zabilježeno tijekom terenskog obilaska jaruge Santiš
46. Slika 46. Zabilježene volumetrijske promjene unutar jaruge Santiš (A – početni (čeoni) dio jaruge; B – središnji dio jaruge; C – završni dio jaruge)
47. Slika 47. Načelo određivanja intenziteta jaruženja duž odabranog poprečnog presjeka (GCs_n) jaruge na temelju usporedbe dubina odabranih točaka (h_n)
48. Slika 48. Izračun odnosa širine i dubine (W/d ratio) poprečnog presjeka jaruge (GCs)

49. Slika 49. Četiri ulazna podatka za izrađeni alat GULIVER
50. Slika 50. Koncept praćenja vertikalnog pomaka unutar GCs jaruge korištenjem GULIVER alata
51. Slika 52. Shematski prikaz izrađenog GULIVER alata za praćenje vertikalnog pomaka
52. Slika 51. Izlazni podaci alata GULIVER za prostor jaruge Santiš
53. Slika 53. Primjer izdvajanja precizne xyz lokacije ekstremnih vrijednosti Δh
54. Slika 54. Usporedba prostornog rasporeda i brojnosti visinskih uzoraka prikupljenih totalnom stanicom (A) i alatom GULIVER (B)
55. Slika 55. Mjesečna količina oborina za jarugu Santiš - prikupljena unutar promatranog šestomjesečnog razdoblja (svibanj – studeni 2017.)
56. Slika 56. Dnevna količina oborina za jarugu Santiš - prikupljena unutar promatranog šestomjesečnog razdoblja (svibanj – studeni 2017.)
57. Slika 57. Hidrološke posljedice obilnih i intenzivnih oborina početkom rujna 2017. godine
58. Slika 58. Morfološke posljedice obilnih i intenzivnih oborina početkom rujna 2017. godine (A – stanje prije oborina, B – stanje nakon oborina)
59. Slika 59. Zabilježeni intenzitet oborina (mm/h) za 13 najizraženijih oborinskih događaja

Popis tabličnih prikaza

1. Tablica 1. Pregled korisničko definiranih parametara korištenih pri izradi DMP-a u Agisoft PhotoScan Professional software-u
2. Tablica 2. Morfometrijski parametri korišteni za kartiranje postojećih jaruga OBIA pristupom
3. Tablica 3. Pragovi definirani pri manualnoj klasifikaciji objekata izdvojenih OBIA pristupom
4. Tablica 4. Prikaz odabranih kriterija za GIS-MCDA (A) i autora koji su u svojim radovima koristili pojedine kriterije (B)
5. Tablica 5. Statistički površinski pokazatelji kvalitete kartiranja jaruga OBIA pristupom
6. Tablica 6. Statistički lokacijski pokazatelji kvalitete kartiranja jaruga OBIA pristupom
7. Tablica 7. Zastupljenost klasa nagiba padine sa pripadajućim težinskim koeficijentima
8. Tablica 8. Zastupljenost klasa orijentacije padina sa pripadajućim težinskim koeficijentima
9. Tablica 9. Zastupljenost klasa profilne zakrivljenosti padina sa pripadajućim težinskim koeficijentima
10. Tablica 10. Zastupljenost klasa planarne zakrivljenosti padina sa pripadajućim težinskim koeficijentima
11. Tablica 11. Zastupljenost klasa topografskog indeksa vlažnosti (TWI) sa pripadajućim težinskim koeficijentima
12. Tablica 12. Zastupljenost klasa indeksa snage otjecanja (SPI) sa pripadajućim težinskim koeficijentima

koeficijentima

13. Tablica 13. Zastupljenost klasa LS faktora sa pripadajućim težinskim koeficijentima
14. Tablica 14. Zastupljenost klasa LS faktora sa pripadajućim težinskim koeficijentima
15. Tablica 15. Zastupljenost vegetacijskih klasa sa pripadajućim težinskim koeficijentima
16. Tablica 16. Zastupljenost klasa pedološkog pokrova sa pripadajućim težinskim koeficijentima
17. Tablica 17. Zastupljenost Boolean klasa sa pripadajućim težinskim koeficijentima
18. Tablica 18. Težinski koeficijenti odabranih parametara za četiri testirana GIS-MCDA modela
19. Tablica 19. Zastupljenost pojedinih klasa napravljenog modela podložnosti jaruženju
20. Tablica 20. Zastupljenost klase vrlo visoke podložnosti jaruženju unutar 500 m od ubrane zone
21. Tablica 21. Površinski i volumetrijski pokazatelji promjena unutar jaruge Santiš
22. Tablica 22. Sumativna statistika svih 871 465 točaka generiranih alatom GULIVER
23. Tablica 23. Statistički pokazatelji razlike visina (Δh) za prvih 10 GCs izrađenih GULIVER Alatom

Prilog 1 - Python skripta napravljenog alata GULIVER

```
# -*- coding: utf-8 -*-  
  
# -----  
  
# alat - skripta-brisi.py  
  
# Created on: 2018-03-13 13:27:33.00000  
  
# (generated by ArcGIS/ModelBuilder)  
  
# Usage: alat - skripta-brisi <Talveg_jaruge> <Vrijednost_udajenosti> <Područje_istraživanja>  
<Ulazni_DMP_1> <Ulazni_DMP_2> <Profili___output> <Tablica___Output> <GCs___Finalno>  
  
# Description:  
# -----  
  
# Set the necessary product code  
  
# import arcinfo  
  
  
# Import arcpy module  
  
import arcpy  
  
  
# Script arguments
```


Talveg_jaruge = arcpy.GetParameterAsText(0)

if Talveg_jaruge == '#' or not Talveg_jaruge:

 Talveg_jaruge = "Glavni_tok_KV" # provide a default value if unspecified

Vrijednost_udajenosti = arcpy.GetParameterAsText(1)

if Vrijednost_udajenosti == '#' or not Vrijednost_udajenosti:

 Vrijednost_udajenosti = "50" # provide a default value if unspecified

Područje_istraživanja = arcpy.GetParameterAsText(2)

if Područje_istraživanja == '#' or not Područje_istraživanja:

 Područje_istraživanja = "Područje_istraživanja" # provide a default value if unspecified

Ulazni_DMP_1 = arcpy.GetParameterAsText(3)

if Ulazni_DMP_1 == '#' or not Ulazni_DMP_1:

 Ulazni_DMP_1 = "DMP1_20mm_KV" # provide a default value if unspecified

Ulazni_DMP_2 = arcpy.GetParameterAsText(4)

if Ulazni_DMP_2 == '#' or not Ulazni_DMP_2:

 Ulazni_DMP_2 = "DMP2_20mm_KV" # provide a default value if unspecified

Profili___output = arcpy.GetParameterAsText(5)

if Profili___output == '#' or not Profili___output:

 Profili___output = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C1_SpatialJoin" # provide a default value if unspecified

Tablica___Output = arcpy.GetParameterAsText(6)

if Tablica___Output == '#' or not Tablica___Output:

 Tablica___Output = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C1_Statistics" # provide a default value if unspecified

GCs___Finalno = arcpy.GetParameterAsText(7)

if GCs___Finalno == '#' or not GCs___Finalno:

GCs___Finalno = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Merge_Clip_Dissolve" # provide a default value if unspecified

Local variables:

Progušćene_LT = Talveg_jaruge

Talveg___LT = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice"

Talveg___LT_XY_ = Talveg___LT

LDM_ID_2 = Talveg___LT_XY_

ID_LDM_2_dodan = LDM_ID_2

Prosječni_smjer_jaruge = ID_LDM_2_dodan

Output_Layer = "Glavni_tok_KV_Layer"

LDM_izračunat = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_DirectionalMea"

LDM_ID = LDM_izračunat

ID_LDM_dodan = LDM_ID

Udaljenost = Prosječni_smjer_jaruge

Širina_GC_s = Udaljenost

Kut_1 = Širina_GC_s

Kut_GC_s_1 = Kut_1

Kut_2 = Kut_GC_s_1

Kut_GC_s_2 = Kut_2

ID_GC_s = Kut_GC_s_2

ID_GC_s_dodan = ID_GC_s

GCs_2 = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1"

GCs_1 = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2"

GCs_izrađeni = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Merge"

GCs___Skraceni = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Merge_Clip"

Densify__LT__GCs_ = GCs__FinalNo

LT__GCs_ = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Merge_Clip_Dissolve_FeatureV"

LT__GCs__XY_ = LT__GCs_

h__DMP_1 = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C1"

Visine__DMP_1 = h__DMP_1

h__DMP_2 = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C3"

Visine__DMP_2 = h__DMP_2

GCs_spojani = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C1_SpatialJoin"

Statistics_Field_s_ = "Z_DMP1 MIN;Z_DMP1 MAX;Z_DMP1 MEAN;Z_DMP1 RANGE;Z_DMP1 FIRST;Z_DMP1 LAST"

Case_field = "ID"

Tablica__DMP_1 = "H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Extract_Merge_C1_Statistics"

Tablica__Join = Tablica__DMP_1

Statistics_Field_s__2_ = "Z_DMP2 MIN;Z_DMP2 MAX;Z_DMP2 MEAN;Z_DMP2 RANGE;Z_DMP2 FIRST;Z_DMP2 LAST"

Case_field__2_ = "ID"

Tablica__DMP_2 = "C:\\Users\\Fran\\Desktop\\Alat - proba\\Alat_baza\\Proba_STACK\\STACK_proba.gdb\\Extract_GT_Feat1_Statistics2"

Process: Densify (2)

arcpy.Densify_edit(Talveg_jaruge, "DISTANCE", "5 Centimeters", "0,1 Meters", "10")

Process: Feature Vertices To Points

arcpy.FeatureVerticesToPoints_management(Progušćene_LT, Talveg__LT, "ALL")

Process: Add XY Coordinates

arcpy.AddXY_management(Talveg__LT)

Process: Add Field (7)

```
arcpy.AddField_management(Talveg__LT__XY_, "ID_AZIMUT", "LONG", "", "", "", "", "NULLABLE",  
"NON_REQUIRED", "")
```

```
# Process: Calculate Field (7)
```

```
arcpy.CalculateField_management(LDM_ID_2, "ID_AZIMUT", "1", "VB", "")
```

```
# Process: Make Feature Layer
```

```
arcpy.MakeFeatureLayer_management(Talveg_jaruge, Output_Layer, "", "", "OBJECTID OBJECTID  
VISIBLE NONE;Shape Shape VISIBLE NONE;arcid arcid VISIBLE NONE;grid_code grid_code VISIBLE  
NONE;from_node from_node VISIBLE NONE;to_node to_node VISIBLE NONE;Shape_Leng  
Shape_Leng VISIBLE NONE;Shape_Length Shape_Length VISIBLE NONE")
```

```
# Process: Linear Directional Mean
```

```
arcpy.DirectionMean_stats(Output_Layer, LDM_izračunat, "ORIENTATION_ONLY", "")
```

```
# Process: Add Field (6)
```

```
arcpy.AddField_management(LDM_izračunat, "ID", "SHORT", "", "", "", "", "NULLABLE",  
"NON_REQUIRED", "")
```

```
# Process: Calculate Field (6)
```

```
arcpy.CalculateField_management(LDM_ID, "ID", "1", "VB", "")
```

```
# Process: Join Field (3)
```

```
arcpy.JoinField_management(ID_LDM_2_dodan, "ID_AZIMUT", ID_LDM_dodan, "ID", "DirMean")
```

```
# Process: Add Field
```

```
arcpy.AddField_management(Prosječni_smjer_jaruge, "Udaljenost_spojnice", "DOUBLE", "", "", "",  
"", "NULLABLE", "NON_REQUIRED", "")
```

```
# Process: Calculate Field
```

```
arcpy.CalculateField_management(Udaljenost, "Udaljenost_spojnice", Vrijednost_udajenosti, "VB",  
"")
```

```
# Process: Add Field (3)
```

```
arcpy.AddField_management(Širina_GCs, "Kut_1", "DOUBLE", "", "", "", "", "NULLABLE",  
"NON_REQUIRED", "")
```

```
# Process: Calculate Field (3)
```

```
arcpy.CalculateField_management(Kut_1, "Kut_1", "[DirMean] +90", "VB", "")
```

```
# Process: Add Field (2)
```

```
arcpy.AddField_management(Kut_GCs_1, "Kut_2", "DOUBLE", "", "", "", "", "NULLABLE",  
"NON_REQUIRED", "")
```

```
# Process: Calculate Field (2)
```

```
arcpy.CalculateField_management(Kut_2, "Kut_2", "[DirMean] -90", "VB", "")
```

```
# Process: Add Field (4)
```

```
arcpy.AddField_management(Kut_GCs_2, "ID", "LONG", "", "", "", "", "NULLABLE",  
"NON_REQUIRED", "")
```

```
# Process: Calculate Field (4)
```

```
arcpy.CalculateField_management(ID_GCs, "ID", "[OBJECTID]", "VB", "")
```

```
# Process: Bearing Distance To Line - Kut 2
```

```
arcpy.BearingDistanceToLine_management(ID_GCs_dodan, GCs_2, "POINT_X", "POINT_Y",  
"Udaljenost_spojnice", "9001", "Kut_2", "9102", "0", "ID",  
"PROJCS['HTRS96_Croatia_TM',GEOGCS['GCS_HTRS96',DATUM['D_Croatian_Terrestrial_Reference_S  
ystem',SPHEROID['GRS_1980',6378137.0,298.257222101]],PRIMEM['Greenwich',0.0],UNIT['Degree',0  
.0174532925199433]],PROJECTION['Transverse_Mercator'],PARAMETER['False_Easting',500000.0],P  
ARAMETER['False_Northing',0.0],PARAMETER['Central_Meridian',16.5],PARAMETER['Scale_Factor',0.  
9999],PARAMETER['Latitude_Of_Origin',0.0],UNIT['Meter',1.0]];-5122600 -10001100 10000;-100000  
10000;-100000 10000;0,001;0,001;0,001;IsHighPrecision")
```

```
# Process: Bearing Distance To Line - Kut 1
```

```
arcpy.BearingDistanceToLine_management(ID_GCs_dodan, GCs_1, "POINT_X", "POINT_Y",  
"Udaljenost_spojnice", "9001", "Kut_1", "9102", "0", "ID",  
"PROJCS['HTRS96_Croatia_TM',GEOGCS['GCS_HTRS96',DATUM['D_Croatian_Terrestrial_Reference_S  
ystem',SPHEROID['GRS_1980',6378137.0,298.257222101]],PRIMEM['Greenwich',0.0],UNIT['Degree',0  
.0174532925199433]],PROJECTION['Transverse_Mercator'],PARAMETER['False_Easting',500000.0],P  
ARAMETER['False_Northing',0.0],PARAMETER['Central_Meridian',16.5],PARAMETER['Scale_Factor',0.  
9999],PARAMETER['Latitude_Of_Origin',0.0],UNIT['Meter',1.0]];-5122600 -10001100 10000;-100000  
10000;-100000 10000;0,001;0,001;0,001;IsHighPrecision")
```

10000;-100000 10000;0,001;0,001;0,001;lsHighPrecision")

Process: Merge

```
arcpy.Merge_management("H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1';H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2", GCs_izrađeni, "POINT_X \\\"POINT_X\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1,POINT_X,-1,-1,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2,POINT_X,-1,-1;POINT_Y \\\"POINT_Y\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1,POINT_Y,-1,-1,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2,POINT_Y,-1,-1;Udaljenost_spojnice \\\"Udaljenost_spojnice\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1,Udaljenost_spojnice,-1,-1,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2,Udaljenost_spojnice,-1,-1;Kut_2 \\\"Kut_2\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1,Kut_2,-1,-1;ID \\\"ID\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice1,ID,-1,-1,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2,ID,-1,-1;Kut_1 \\\"Kut_1\\\" true true false 0 Double 0 0 ,First,#,H:\\Diplomski rad\\GIS\\7. Alati - Kvantitativna analiza\\1. Vertikalni pomak - alat\\1. Izrada poprecnih presjeka (GCs)\\Testiranje 1\\Test_VER_1.gdb\\Glavni_tok_KV_FeatureVertice2,Kut_1,-1,-1")
```

Process: Clip

```
arcpy.Clip_analysis(GCs_izrađeni, Područje_istraživanja, GCs___Skraćeni, "")
```

Process: Dissolve

```
arcpy.Dissolve_management(GCs___Skraćeni, GCs___Finalno, "ID", "", "MULTI_PART", "DISSOLVE_LINES")
```

Process: Densify

```
arcpy.Densify_edit(GCs___Finalno, "DISTANCE", "5 Centimeters", "0,1 Meters", "10")
```


Process: Feature Vertices To Points (2)

```
arcpy.FeatureVerticesToPoints_management(Densify__LT__GCs_, LT__GCs_, "ALL")
```

Process: Add XY Coordinates (2)

```
arcpy.AddXY_management(LT__GCs_)
```

Process: Extract Values to Points

```
arcpy.gp.ExtractValuesToPoints_sa(LT__GCs__XY_, Ulazni_DMP_1, h__DMP_1, "NONE",  
"VALUE_ONLY")
```

Process: Alter Field

```
arcpy.AlterField_management(h__DMP_1, "RASTERVALU", "Z_DMP1", "", "", "8",  
"NON_NULLABLE", "false")
```

Process: Extract Values to Points (2)

```
arcpy.gp.ExtractValuesToPoints_sa(LT__GCs__XY_, Ulazni_DMP_2, h__DMP_2, "NONE",  
"VALUE_ONLY")
```

Process: Alter Field (2)

```
arcpy.AlterField_management(h__DMP_2, "RASTERVALU", "Z_DMP2", "", "", "8",  
"NON_NULLABLE", "false")
```

Process: Spatial Join

```
arcpy.SpatialJoin_analysis(Visine__DMP_1, Visine__DMP_2, GCs_spojени, "JOIN_ONE_TO_ONE",  
"KEEP_ALL", "", "INTERSECT", "", "")
```

Process: Delete Field

```
arcpy.DeleteField_management(GCs_spojени, "Join_Count;TARGET_FID")
```

Process: Summary Statistics

```
arcpy.Statistics_analysis(Visine__DMP_1, Tablica__DMP_1, Statistics_Field_s_, Case_field)
```

Process: Summary Statistics (2)

```
arcpy.Statistics_analysis(Visine___DMP_2, Tablica___DMP_2, Statistics_Field_s___2_,  
Case_field___2_)
```

Process: Join Field

```
arcpy.JoinField_management(Tablica___DMP_1, "ID", Tablica___DMP_2, "ID", "")
```

Process: Delete Field (2)

```
arcpy.DeleteField_management(Tablica___Join, "FREQUENCY;ID_1;FREQUENCY_1")
```