Razvoj višekriterijskog modela održivog upravljanja na području sedrotvornih vodotokova - primjer Skradinskog buka

Marić, Ivan

Doctoral thesis / Disertacija

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:039710

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-18**

Sveučilište u Zadru
Universitas Studiorum
Jadertina | 1396 | 2002 |

Repository / Repozitorij:

University of Zadar Institutional Repository

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

JADRAN - POVEZNICA MEĐU KONTINENTIMA

Ivan Marić

RAZVOJ VIŠEKRITERIJSKOG MODELA ODRŽIVOG UPRAVLJANJA NA PODRUČJU SEDROTVORNIH VODOTOKOVA - PRIMJER SKRADINSKOG BUKA

Doktorski rad

Zadar, 2020.

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

JADRAN - POVEZNICA MEĐU KONTINENTIMA

Ivan Marić

RAZVOJ VIŠEKRITERIJSKOG MODELA ODRŽIVOG UPRAVLJANJA NA PODRUČJU SEDROTVORNIH VODOTOKOVA - PRIMJER SKRADINSKOG BUKA

Doktorski rad

Mentor

Izv. prof. dr. sc. Ante Šiljeg

Komentorica

Izv. prof. dr. sc. Nina Lončar

Komentor

Izv. prof. dr. sc. Admir Mulahusić

Zadar, 2020.

SVEUČILIŠTE U ZADRU

TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Ivan Marić

Naziv studijskog programa: Poslijediplomski sveučilišni studij Jadran – poveznica među kontinentima

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

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

Komentor 1: Izv. prof. dr. sc. Admir Mulahusić

Datum obrane: 10. lipnja, 2020.

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

II. Doktorski rad

Naslov: Razvoj višekriterijskog modela održivog upravljanja na području sedrotvornih vodotokova - primjer Skradinskog buka

UDK oznaka: 502.13:[556.18:553.9](497.5-751.2Krka)(043)

Broj stranica: 377

Broj slika/grafičkih prikaza/tablica: 212/0/41

Broj bilježaka: 100

Broj korištenih bibliografskih jedinica i izvora: 421/53

Broj priloga: 0

Jezik rada: hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu doktorskog rada

1. dr. sc. Neven Cukrov, viši znanstveni suradnik (predsjednik)
2. Izv. prof. dr. sc. Ante Šiljeg, član
3. Izv. prof. dr. sc. Sanja Lozić, član

Stručno povjerenstvo za obranu doktorskog rada:

1. dr. sc. Neven Cukrov, viši znanstveni suradnik (predsjednik)
2. Izv. prof. dr. sc. Ante Šiljeg, član
3. Izv. prof. dr. sc. Sanja Lozić, član

UNIVERSITY OF ZADAR

BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Ivan Marić

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

Mentor: Associate Professor Ante Šiljeg, PhD

Co-mentor 1: Assistant Professor Nina Lončar, PhD

Co-mentor 2: Associate Professor Admir Mulahusić, PhD

Date of the defence: 10 June 2020

Scientific area and field in which the PhD is obtained: Interdisciplinary science, Geography

II. Doctoral dissertation

Title: Development of multicriteria sustainable management model on the area of tufa forming watercourse - example of Skradinski buk

UDC mark: 502.13:[556.18:553.9](497.5-751.2Krka)(043)

Number of pages: 377

Number of pictures/graphical representations/tables: 212/0/41

Number of notes: 100

Number of used bibliographic units and sources: 421/53

Number of appendices: 0

Language of the doctoral dissertation: Croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Senior Research Associate, Neven Cukrov, PhD, chair
2. Assistant Professor Ante Šiljeg, PhD, member
3. Assistant Professor Sanja Lozić, PhD, member

Expert committee for the defence of the doctoral dissertation:

1. Senior Research Associate, Neven Cukrov, PhD, chair
2. Assistant Professor Ante Šiljeg, PhD, member
3. Assistant Professor Sanja Lozić, PhD, member

Izjava o akademskoj čestitosti

Ja, **Ivan Marić,** ovime izjavljujem da je moj **doktorski** rad pod naslovom **Razvoj višekriterijskog modela održivog upravljanja na području sedrotvornih vodotokova - primjer Skradinskog buka** 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, 1. srpnja, 2020.

ZAHVALA

Zahvaljujem mom prijatelju i mentoru izv. prof. dr. sc. Anti Šiljegu na usmjeravanju, savjetima, pomoći i velikoj podršci tijekom pisanja moje doktorske disertacije.

Zahvaljujem svojoj komentorici izv. prof. dr. sc. Nini Lončar i komentoru izv. prof. dr. sc. Admiru Mulahusiću na savjetima i pomoći tijekom pisanja disertacije.

Zahvaljujem članovima povjerenstva za ocjenu i obranu doktorske disertacije: izv. prof. dr. sc. Anti Šiljegu, dr. sc. Nevenu Cukrovu te izv. prof. dr. sc. Sanji Lozić na konstruktivnim kritikama, stručnim savjetima i susretljivosti prilikom obrane.

Zahvaljujem dr. sc. Nevenu Cukrovu na velikoj pomoći prilikom terenskih istraživanja te na svim stručnim savjetima vezanima za sedru.

Zahvaljujem tvrtki Prehnit d.o.o, a posebno gospodinu Vlatku Rolandu na brojnim savjetima. Hvala Upravi NP „Krka“ na ustupljenim podatcima bez kojih izrada ove disertacije ne bi bila moguća. Posebne zahvale idu gospodinu Dragi Margušu te stručnoj voditeljici Gordani Goreti.

Hvala gospodinu Iviću Loli Tokaru, koji je konceptualni model CMD-a pretvorio u stvarnost.

Hvala djelatnicima NP „Krka“, posebno Nikolini Smolić, na pomoći prilikom izvođenja terenskih istraživanja te uvijek ugodnom dočeku u Park.

Hvala Franu Domazetoviću i Tomislavu Bulatu na pomoći prilikom terenskih istraživanja.

Hvala izv. prof. dr. sc. Renati Matoničkin Kepčija i doc. dr. sc. Ana Previšić na pomoći u determinaciji makrozoobentosa.

Veliko hvala mojim profesorima i radnim kolegama na prenesenom znanju, potpori i poticaju u znanstvenom radu. Posebne zahvale idu doc. dr. sc. Silviji Šiljeg i izv. prof. dr. sc. Snježani Mrđen.

Hvala mojim dragim prijateljima na pružanju potpore prilikom pisanja disertacije.

Na kraju, najveće hvala mojim roditeljima Zvonimiru i Mariji te sekama Ivi i Ani na pruženoj potpori, razumijevanju i vjeri u moj uspjeh koje su mi pružili tijekom pisanja doktorske disertacije.

SADRŽAJ

1. UVOD 11
1.1 Ciljevi istraživanja 17
1.2 Temeljne hipoteze istraživanja 18
1.3 Prostorni obuhvat istraživanja 24
1.3.1 Nacionalni park "Krka" (NPK) 24
1.3.1.1 Prirodno-geografske značajke šireg područja NP Krka 25
1.3.2 Šire područje Skradinskog buka (SB) 27
1.3.3 Testna ploha na širem području SB-a 28
1.3.4 Testna ploha na širem području Roškog slapa (RS) 29
1.4 Pregled dosadašnjih istraživanja 30
2. TEORIJSKA OSNOVA 37
2.1 Višerezolucijsko modeliranje krajobraza 37
2.2 Višekriterijske GIS analize (GIS-MCDA) 41
2.3 Upravljanje zaštićenim područjima u RH 45
2.3.1 Upravljanje Nacionalnim parkom „Krka" (NPK) 48
2.3.2 Turizam u NPK u kontekstu upravljačkih mehanizama 49
2.3.2 Prilagodljivo upravljanje u NPK 51
2.3.2.1 Vizija održivog upravljanja NPK 54
2.3.3 Čimbenici pritiska na NPK 55
2.3.3.1 Širenje (ne)invazivnih vegetacijskih vrsta 58
2.3.3.1.1 Metode uklanjanja pajasena 61
2.3.3.1.2 Pajasen u NPK 63
2.4 Sedra i travertin - pojmovno određenje 64
2.4.1 Nastanak sedre 69
2.4.2 Morfologija sedre 71
2.4.3 Značajke aktivnih sedrotvornih sustava 76
2.4.4 Inhibitori sedrenja 82
2.4.5 Važnost fizikalno-kemijskih obilježja vode u procesu sedrenja 86
2.4.6 Važnost bioloških čimbenika u procesu sedrenja 87
2.4.7 Metode mjerenja dinamike sedrenja 93
2.4.7.1 Modificirani mikro-erozijski metar (MEM) 100

2.5 Primjena suvremenih geoprostornih tehnologija u upravljanju zaštićenim prostorom 106
2.5.1 Fotogrametrija 108
2.5.1.1 Aerofotogrametrija 109
2.5.1.2 Ciklično fotografiranje 110
2.5.1.3 Blizupredmetna fotogrametrija 111
2.5.1.3.1 Trokut ekspozicije 113
2.5.1.3.2 Koncepti snimanja u blizupredmetnoj fotogrametriji 114
2.5.1.3.3 Snimanje i obrada fotografija u procesu CRP-a 116
2.5.1.4 Makrofotogrametrija 119
2.6.1 LiDAR (eng. *Light Detection and Ranging*) 121
2.6.1.1 Terestričko lasersko skeniranje (TLS) 122
2.6.1.2 Zračno lasersko skeniranje (ALS) 123
2.6.2 3D projekcijski skeneri 124
3. METODOLOGIJA ISTRAŽIVANJA 126
3.1 Makro razina 128
3.1.1 Terenska istraživanja 128
3.1.2 Zračno lasersko skeniranje NP "Krka" 128
3.1.3 Vektorizacija Austro-Ugarske topografske karte 133
3.1.4 Primjena GIS-MCDA u odabiru testne plohe 135
3.2 Mezo razina 141
3.2.1 Terestričko lasersko skeniranje testne plohe 141
3.2.2 Izrada hibridnog DMR-a testne plohe 145
3.2.3 Izvođenje modela mreže površinskog otjecanja 146
3.2.4 Provjera modela površinskog otjecanja 147
3.2.5 Aerofotogrametrijska ciklična snimanja testne plohe 149
3.2.5.1 Proces obrade fotografija 152
3.2.6 Kartiranje stabala i vegetacijskog pokrova na testnoj plohi 154
3.2.7 Selektivna sječa invazivne vegetacije 155
3.2.8 Postavljanje sustava za praćenje stanja sedrotvornog okoliša na testnoj plohi 157
3.2.8.1 Mjerenje brzine protoka vode na testnoj plohi 157
3.2.8.2 Postavljanje multiparametne sonde YSI EXO2 160
3.3 Mikro razina 172
3.3.1 Razvoj uređaja za praćenje dinamike formiranja sedre (TFD) 172

3.3.2 Kalibracija kamere 177
3.3.3 Utvrđivanje kvalitete mjerenja s CMD-om 178
3.3.4 Odabir vrste pločica za praćenje dinamike formiranja sedre 184
3.3.5 Postavljanje i snimanje testnih pločica (testna ploha SB) 187
3.3.6 Postavljanje i snimanje testnih pločica (testna ploha RS) 202
3.3.6.1 Snimanje pločica RS-a Artec Evom 206
3.3.6.1.1 Obrada skenova snimljenih *Artec Evom* 207
3.3.7 Metodologija obrade fotografija 209
3.3.8 Morfometrijske analize digitalnih modela sedre visoke rezolucije 213
4. REZULTATI ISTRAŽIVANJA 215
4.1 Makro razina 215
4.1.1 Terenska istraživanja šireg područja SB-a 215
4.1.2 Digitalni model reljefa (DMR) šireg područja SB-a 217
4.1.3 Georeferencirana A-U topografska karta šireg područja SB-a 218
4.1.4 Indeks pogodnosti testne plohe za šire područje SB-a 218
4.2 Mezo razina 221
4.2.1 Model mreže površinskog otjecanja testne plohe 221
4.2.2 Katastar stabala nultog stanja testne plohe 222
4.2.2 Promjene na plohi nakon selektivnog uklanjanja vegetacije 225
4.2.3 Rezultati cikličnog fotografiranja testne plohe 228
4.2.4 Brzina protoka vode na testnoj plohi 230
4.2.5 Fizikalno-kemijska obilježja vode na testnoj plohi 232
4.3 Mikro razina 237
4.3.1 Kvaliteta mjerenja uređajem za koordinatnu mjernu makrofotogrametriju (CMD) 237
4.3.2 Digitalni modeli sedre visoke rezolucije (eng. DTHRM) 244
4.3.2.1 DTHRM – testna ploha Skradinski buk (SB) 244
4.3.2.2 DTHRM – testna ploha Roški slap (RS) 250
4.3.3 Stope prirasta sedre (mm a^{-1}) 251
4.3.3.1 Stope prirasta sedre (mm a^{-1}) – testna ploha SB 251
4.3.3.2 Stope prirasta sedre – testna ploha (RS) 253
4.3.3.3 Praćenje dinamike sedrenja po poprečnim profilima 254
4.3.4 Stope prirasta sedre (mm a^{-1}) susjednih pločica 256
4.3.4.1 Stope prirasta sedre (mm a^{-1}) susjednih pločica - SB 256

4.3.5 Stope prirasta (mm a^{-1}) sedre prema frekvenciji vađenja 260
4.3.6 Stope prirasta (mm a^{-1}) sedre prema temperaturnom razdoblju (sezoni) 261
4.3.7 Stope prirasta (mm a^{-1}) sedre prema tipu fluvijalnog okruženja na SB..... 263
4.3.8 Volumetrijska analiza testnih pločica – utvrđivanje pojave prirasta i erozije..... 264
4.3.9 Utjecaj frekvencije snimanja pločica na količinu i intenzitet erozije..... 277
4.3.9 Utvrđivanje makrozoobentosa u rekativiranom sedrotvornom sustavu 278
4.4.0 Dinamika formiranja sedre na pločicama mjerenim u tromjesečnim intervalima. 310
5. RASPRAVA..... 312
6. ZAKLJUČAK 324
SAŽETAK 327
SUMMARY 328
LITERATURA I IZVORI..... 329
ŽIVOTOPIS 367
POPIS RADOVA 368
POPIS OZNAKA I KRATICA..... 369
POPIS SLIKA 371
POPIS TABLICA..... 376

1. UVOD

Krški prostori su iznimno osjetljivi i podložni vanjskim poremećajima koji mogu uzrokovati nepovratne promjene u njegovom sustavu (Ford i Williams, 2007, De Waele i dr., 2011). Osim znanstvenog značaja, koji je predstavljen složenošću abiotičkih i biotičkih čimbenika, krški prostori imaju velik ekološki značaj i turistički potencijal (Goldscheider i Ravbar, 2010). Jadransko krško područje kao kontaktni pojas dinarskog i sredozemnog krša (Lewin i Woodward, 2009) predstavlja mozaik različitih krajobraza. Na tom prostoru nalazi se jedna od najljepših prirodnih znamenitosti Republike Hrvatske (RH), Nacionalni park „Krka" (NPK) koji spada u zaštićeni fluvijalni krajobraz. Prepoznat je kao prostorno-dinamičan entitet formiran i izmijenjen hidrološkim procesima (Kudrnovsky i Lazowski, 2017) s velikom biološkom raznolikošću i visokim stupnjem endemizma. Svrstan je u II. kategoriju IUCN[1] zaštićenih područja (Bulat, 2012) koje spada pod državnu razinu upravljanja, a uz znanstvenu, kulturnu, odgojno-obrazovnu i rekreativnu, namjenu mu je i očuvanje izvornih prirodnih vrijednosti (NN 80/13). Navedena kategorija zaštićenog prostora zahtjeva upravljanje u skladu s mogućnostima njegove raznovrsne namjene.

NPK je prema posjećenosti drugo zaštićeno područje u RH s preko milijun posjetitelja godišnje i trendom rasta (Palčić, 2016). Ima dvije glavne, često oprečne funkcije: zaštitu prostora usmjerenu na očuvanje i unapređenje posebnih prirodnih vrijednosti te razvoj turističke (odgojno-obrazovna i rekreativna namjena) djelatnosti (Jovičić i Ivanović, 2004). Iako je njihov odnos ponekad suprotstavljen (Zhang dr., 2012, Gu i dr., 2013), turizam je kritična sastavnica koju se treba uvažiti prilikom upravljanja ovakvim zaštićenim područjima (Eagles i dr., 2002). Naime, uspješni razvoj turizma podrazumijeva pobuđivanje interesa posjetitelja za prirodnim fenomenom zaštićenog područja uz istovremeno podizanje svijesti o potrebi njegova očuvanja (Megerle, 2012). Izvorna prirodna sredina, sa složenom geomorfološkom i ekosistemskom strukturom, atraktivnija je za turističke posjete (Jovičić i Ivanović, 2004). Stoga zaštitna funkcija mora biti usmjerena prema očuvanju posebnih prirodnih vrijednosti tog prostora. Na prostoru današnjeg NPK, prije proglašenja zaštite, antropogen utjecaj prisutan je dugo kroz povijest, a očitovao se kroz rušenje i isušivanje sedrenih barijera radi dobivanja plodnog tla i smanjenja močvara, gradnju suhozida, mlinica, nekad provođenoj pastoralnoj ekonomiji (Perica i dr., 2005). Danas antropogeni utjecaj u NPK uključuje: uređivanje i nasipavanje staza, gradnju odmorišta, širenje invazivnih vrsta itd.

[1] International Union for Conservation of Nature

Dominantna sastavnica zaštite NPK je voda, a praćenje prostorno-vremenskih promjena hidroloških obilježja rijeke Krke i njenih pritoka od ključne je važnosti za njeno očuvanje (Rubinić i dr., 2017) osobito u okolnom krškom bezvodnom krajobrazu. Bonacci i dr. (2017) analizirajući hidrologiju Skradinskog buka ističu potrebu uspostave složenog interdisciplinarnog sustava nadzora te navode da je: *hidrologija, odnosno njena varijabilnost ključna u razumijevanju ostalih interaktivnih, kemijskih, fizikalnih, bioloških, ekoloških pa i društvenih procesa vezanih za Skradinski buk* (Bonacci i dr. 2017; 34). Naime, promjene hidrološke mreže i vodnog režima, iako se uglavnom odvijaju sporom dinamikom i smanjenim intenzitetom, mogu uzrokovati trajne promjene u ekosustavu. Osobito ako je ekosustav građen od elemenata čija je egzistencija uvjetovana specifičnim rasponom vrijednosti i pojavnosti abiotičkih i biotičkih čimbenika (Rubinić i dr., 2017). Jedan od primjera takvih osjetljivih elemenata je sedra, odnosno sedrene barijere, temeljni prirodni fenomen NPK (URL 1). Sedra je porozna, monomineralna stijena koja nastaje precipitacijom kalcijeva karbonata ($CaCO_3$) u krškim vodotocima (Viles i Pentecost, 2007, Bonacci i dr., 2017) te djelovanjem specifičnih vrsta algi, mahovina, bakterija i drugih sedrotvoraca na mjestima prirodnih ili umjetnih prepreka. Čini je sekundarno istaložen $CaCO_3$ uz različite ostatke mikro i makrofita (više vodene biljke), beskralježnjaka i bakterija (Matoničkin Kepčija i dr., 2018). Proces sedrenja vrlo je osjetljiv na svaku pa i najmanju promjenu okolišnih uvjeta (Goudie i dr., 1993, Yuan, 1997, Horvatinčić i dr., 2006, Cukrov i Lojen, 2010, Mikac i dr., 2011, Zhang i dr. 2012, Liu, 2017) zbog čega su sedrotvorni sustavi vrlo dobri pokazatelji stabilnosti okoliša (González i Rubio, 2000). Precipitirani karbonat stvara sedrene barijere i pragove koji potom formiraju atraktivne slapove (Cukrov i dr., 2008) od kojih su u NPK najpoznatiji Skradinski buk (SB) i Roški slap (RS) (Ternjej i dr., 2010). Sedrene barijere predstavljaju geomorfološke oblike univerzalnih znanstvenih i estetskih vrijednosti te pružaju životni prostor za neke ugrožene vrste (Cukrov i Lojen, 2010). Prepoznate su kao svjetska turistička atrakcija, a nerijetko su uvrštene na listu UNESCO[2] svjetske prirodne baštine (Trpčić, 2016). Najpoznatija (Bonacci i dr., 2017), najposjećenija (Brajković, 2016) i najduža sedrena barijera (URL 2) na rijeci Krki je SB.

U „Planu upravljanja NPK“ očuvanje sedrenih barijera, odnosno *kvalitete vode, i svih fizikalno-kemijskih i bioloških čimbenika koji osiguravaju prirodni razvoj sedrotvoraca i procesa taloženja sedre* definiran je kao jedan od temeljnih dugoročnih ciljeva (Marguš, 2017: 356). Međutim, zbog složenosti i „nepredvidivog ponašanja“ prirodnih procesa u krškim

[2] The United Nations Educational, Scientific and Cultural Organisation

sustavima, pravilno upravljanje tim područjima zahtjeva često zanemarene savjete stručnjaka iz različitih znanstvenih područja i polja (De Waele i dr., 2011, Liu, 2017). Naime, potreba uvođenja niza upravljački mjera prepoznata je u drugim (ne)zaštićenim prostorima u kojima sedra predstavlja temeljni element krajobraza i jedan je od glavnih prirodnih fenomena. Neki od njih su: nacionalni rezervat prirode Jiuzhaigou (Kina) (Gu i dr., 2013, Lugli i dr., 2016, Liu, 2017), poznati krajobraz travertina Huanglong (Kina) (Zhang i dr., 2012), NP Plitvička jezera (NPPJ) (RH), NP Pieniny Mountains i Ojców (Poljska) (Alexandrowicz, 2004), NP Ruidera jezera (Španjolska) (García Del Cura i dr., 1999), Urah i Güterstein vodopadi (Njemačka) (Megerle, 2012). U suvremenom pristupu upravljanja zaštićenim područjima u kojima je glavna sastavnica zaštite vodni resurs potreban je aktivan odnos upravljača (Gu i dr., 2013) prema mogućim, zabilježenim te očekivanim promjenama (Rubinić i dr., 2017). Posljednjih godina NPK suočen je s prijetnjom prestanka procesa sedrenja na nekim lokacijama u Parku. Na širem prostoru SB uočene su negativne hidrološke promjene, odnosno izmjena smjera sedrotvornih vodotokova te trendovi smanjenja srednjih i minimalnih godišnjih protoka (Rubinić i dr., 2017) uz smanjen intenzitet sedrenja. Glavni uzrok navedenog problema prepoznat je u nekontroliranom rastu i širenju različitih vrsta (ne)invazivne vegetacije te neuklanjanju nanesenih akumuliranih biljnih ostataka na mjestima prirodnih prepreka u tokovima. Budući da NPK spada pod državnu razinu upravljanja, intervencije u prostoru su ograničene. To može rezultirati pojavom „zaraštanja barijera“ (Gulin i dr., 2018), odnosno izmjenom smjera i brzine protoka vode, što u konačnici utječe na količinu organske tvari u vodi (Srdoč i dr., 1985, Walpersdorf i dr., 2004, Horvatinčič i dr., 2006) čime se uvjeti sedrenja mijenjaju. Bujni razvoj viših vodenih biljaka u dužem razdoblju može rezultirati isušivanjem sedrotvornih tokova (Matoničkin Kepčija i dr., 2018) dok na sedrenim barijerama stabla i vegetacija težinom ugrožavaju statiku što za posljedicu može imati urušavanja barijere (Pribičević i dr., 2010). Navedeni problem uočen je na prostoru NPPJ (Pribičević i dr., 2010) gdje je pokusno uklanjanje makrovegetacije provedeno 2002. godine (Horvatinčić i dr., 2006, Matoničkin Kepčija i dr., 2018, URL 3). Iz navedenih razloga nameće se potreba za donošenjem aktivnih mjera upravljanja s ciljem očuvanja sedre, odnosno procesa sedrenja kao temeljnog fenomena Parka (Matoničkin Kepčija i dr., 2018). S obzirom na to da održavanje procesa sedrenja ovisi primarno o fizikalno-kemijskim obilježjima vode te opstanku sedrotvoraca provođenjem specifičnih upravljačkih mjera potrebno je iste parametre postići i očuvati kako bi se proces izgradnje barijera i dalje odvijao (Habdija i Primc-Habdija, 2006).

Uprava NPK je prepoznala važnost uočenih problema te je 2017. godine pokrenula interdisciplinarni znanstveni projekt pod nazivom *Upravljanje i održavanje makrovegetacije na Skradinskom buku – izrada višekriterijskog modela održivog upravljanja*. Glavni cilj projekta je provođenje odgovarajućih akcijskih planova s ciljem zaštite temeljnog fenomena NPK, postizanjem održivih uvjeta sedrenja te reaktivacijom ugaslih sedrotvornih vodotokova na odabranoj testnoj plohi unutar SB. Dakle, zbog rastućeg antropogenog utjecaja (Palčić, 2016), specifičnosti institucionalnog modela upravljanja NPK (Bulat, 2012) te osjetljivosti krškog (vodenog) ekosustava i procesa sedrenja na male promjene u okolišu (Prohić i Juračić, 1989, Srdoč i dr., 1992, Goudie i dr., 1993, Cukrov i Lojen, 2010, Mikac i dr., 2011) javlja se potreba održivog pristupa upravljanju koji bi povezao očuvanje prirodne i kulturne baštine s održivim razvojem NPK (Zmijanović, 2015).

Sukladno navedenom, svrha disertacije je izrada višekriterijskog modela održivog upravljanja na području sedrotvornih vodotokova koji bi pružio smjernice za upravljanje osjetljivim i zaštićenim ekosustavom NPK te bio usmjeren prema postizanju i očuvanju održivih uvjeta sedrenja. Pojam *višekriterijsko* se odnosi na potrebu implementacije složene strukture metoda i alata u procesu praćenja interaktivnih kriterija koji na različitim mjerilima istraživanja (engl. *multiscale*) utječu na proces formiranja sedre. Pojam *održivo* pretpostavlja pristup koji pomiruje specifične antropogene mjere (npr. selektivno uklanjanje vegetacije, postavljenje sondi, intervalnih kamera, testnih pločica) sa propisanim mjerama zaštite sve s ciljem ostvarenja održivog razvoja NPK (očuvanje uvjeta sedrenja) (Marguš, 2017: 358). U disertaciji je predložen metodološki okvir, odnosno struktura metoda i alata, koji upravitelju omogućuje uvažavanje i integraciju abiotičkih i biotičkih elemenata u zaštiti i upravljanju područjima s izvanrednom prirodnom raznolikošću (Pellitero i dr., 2011).

Temeljni preduvjet za održivo upravljanje i razumijevanje dinamike sedrotvornih sustava je uspostava i monitoring svih relevantnih interaktivnih kriterija koji mogu utjecati na proces sedrenja (Gu i dr., 2013). Oni po svojim obilježjima mogu biti podijeljeni u nekoliko tematskih grupa: 1) morfometrijski, 2) hidrološki, 3) biološki, 4) fizikalno-kemijski i 5) klimatološki. Naime, iako je proces sedrenja proučavan na međunarodnoj (Ford i Pedley, 1996, Arenas i dr. 2010, Vázquez-Urbez i dr., 2010, Auqué i dr., 2013, Arenas i dr., 2014, Auqué i dr. 2014) i nacionalnoj razini (Primc-Habdija i dr., 2001, Špoljar i dr., 2011, Medunić i dr., 2013) još uvijek postoje brojne nedoumice vezane za uvjete formiranja sedre, osobito ako na njih djeluju specifični vanjski čimbenici.

Ključan parametar u razumijevanju dinamike formiranja sedrotvornih sustava (TFD[3]) predstavlja izračun stope prirasta (TGR[4]) i erozije sedre (TER[5]) izražene u volumenu (mm^3) ili visini ($mm\ a^{-1}$) (Drysdale i Gillieson, 1997). Ovaj morfometrijski parametar daje odgovor na temeljno geomorfološko pitanje nastanka i evolucije pojedinog elemenata krajobraza. Njegov točan izračun je ključan jer morfometrija sedre korelira s biohidrokemijskim parametrima na temelju čega se utvrđuju značajke specifičnog sedrotvornog sustava. Postizanje primjerene točnosti mjerenja nije jednostavno s obzirom na to da prosječne godišnje stope prirasta sedre u svijetu variraju od nekoliko stotinki milimetara do nekoliko centimetara (Tablica 6), zbog čega netočan izračun u konačnici može rezultirati daljnjim nerazumijevanjem dinamike sedrotvornih sustava. Mjerenje stopa prirasta i erozije sedre se dosad izvodilo pomoću različitih izravnih i neizravnih metoda. Unatoč tome što je napredak geomatike revolucionirao sposobnost kvantitativnog snimanja Zemljine površine (Smith i dr., 2016) te je slijedom toga širok spektar uređaja za prikupljanje i obradu geoprostornih podataka korišten u istraživanjima različitih mjerila (Verma i Bourke, 2019), kao jedna od najpopularnijih izravnih metoda u procesu mjerenja stopa prirasta i erozije sedre ostao je mehanički uređaj s brojnim nedostatcima - modificirani mikroerozijski metar (MEM[6]).

U disertaciji je predložen novi metodološki pristup beskontaktnog intervalnog praćenje dinamike sedrenja temeljen na makrofotogrametriji, odnosno SfM[7] fotogrametriji. Unatoč činjenici da je SfM fotogrametrija jedna od najpopularnijih geoprostornih metoda ona do sada prema saznanju autora nije primjenjivana u istraživanjima TFD-a. Slične vrste mjerenja koriste se u istraživanjima koja zahtijevaju vrlo visoku razinu točnosti (Percoco i dr., 2017) i izvođenje visoko-preciznog 3D modela objekta ili scene (González i dr. 2015, Gajski i dr., 2016, Rodríguez-Martín i dr., 2016). Primjenom novog metodološkog pristupa generirat će se modeli sedre submilimetarske rezolucije te će se odgovoriti na temeljno geomorfološko pitanje koje se odnosi na brzinu razvoja/rasta određenog elementa u prirodi (Drysdale i Gillieson, 1997). Potrebno je istaknuti da poseban naglasak disertacije nije stavljen na detaljan opis značajki reaktiviranog sedrotvornog sustava, koji će se zasigurno dati, već predstavljanje novog uređaja kojim će se omogućiti točnije i preciznije praćenje TFD-a, uklanjajući sve probleme karakteristične za dosadašnje metode mjerenja.

[3] Tufa Formation Dynamics
[4] Tufa Growth Rate
[5] Tufa Erosion Rate
[6] Modified Micro-Erosion Meter
[7] Structure from Motion

Potencijalni korisnici predloženog metodološkog okvira mogu biti nacionalne, regionalne i lokalne vlasti, kao i upravni odbori zaštićenih i ugroženih prirodnih područja (Nacionalni park, Park prirode, Rezervati i sl.). Rezultati mogu biti korisni i znanstvenicima koji se bave proučavanjem TFD-a, (paleo)rekonstrukcijom i zaštitom okoliša te svima koji proučavaju aspekte primjene suvremenih geoprostornih tehnologija (GST[8]) u upravljanju zaštićenim područjima. Podaci prikupljeni ovim istraživanjem čine polaznu osnovu (referentno stanje) prilikom izvođenja prostorno-vremenskih analiza varijacija stopa sedrenja i pratećih parametara. Time će se moći utvrditi da li je došlo do degradacije procesa sedrenja u istraživanom razdoblju. Nadalje, povećat će se znanje o dinamici formiranja sedre u različitim okolišnim uvjetima.

[8] Geospatial Technologies

1.1 Ciljevi istraživanja

Glavni cilj disertacije je nadogradnja i proširenje znanstvenih spoznaja o dinamici formiranja sedre na prostoru šireg područja SB-a. Svrha doktorskog rada je izrada višekriterijskog modela održivog upravljanja sedrotvornih vodotokova koji bi dao smjernice za upravljanje tim osjetljivim ekosustavom. Ostvarenje glavnog cilja podrazumijevalo je provođenje istraživanja u više faza. Navedeno je uvjetovalo postavljanje dodatnih (sekundarnih) ciljeva:

1) Odrediti kriterije i utvrditi najpogodniji mikrolokalitet (testna ploha) na prostoru SB-a za praćenje dinamike sedrenja;
2) Izraditi GIS bazu podataka (inventarizacija prirodnih i antropogenih fenomena) odabrane testne plohe u krupnom mjerilu;
3) Razviti uređaj za izravno beskontaktno intervalno praćenje dinamike sedrenja temeljen na metodi SfM fotogrametrije;
4) Odabrati vrstu i oblik testnih pločica na kojima će se pratiti dinamika sedrenja te izraditi 3D modele uzoraka sedre prateći plan snimanja;
5) Predložiti metrike i izraditi alate za praćenje dinamike sedrenja;
6) Identificirati kritične parametre koji utječu na dinamiku rasta sedre.

1.2 Temeljne hipoteze istraživanja

Iz postavljenih ciljeva istraživanja proizašle su sljedeće hipoteze doktorske disertacije:

- **H1 Razvijen sustav izravnog, beskontaktnog, intervalnog praćenja dinamike sedrenja postići će točnost od ±0,1 mm.**

  Vrijednost prihvatljive točnosti veoma je teško odrediti iz nekoliko razloga. U većini istraživanja koja se bave dinamikom formiranja sedre točnost uređaja koji je korišten za mjerenje TGR-a i TER-a nije navođena. Nadalje, stope prirasta sedre izrazito variraju ovisno o obilježjima sedrotvornog sustava. Stoga granica prihvatljive točnosti ne može biti konstantna za sve sedrotvorne sustave. Na lokacijama gdje je godišnji prirast sedre malen, uređaj za mjerenje dinamike formiranja sedre mora biti točniji. Primjerice, ako stopa prirasta sedre godišnje iznosi oko desetinke milimetra, točnost mjerenja mora biti manja od stotinke milimetra (10% godišnje akumulacije) (Drysdale i Gillieson, 1997). Dakle, granica prihvatljive točnosti uvelike ovisi o očekivanom prirastu sedre koji nije jednostavno predvidjeti jer ovisi o biohidrokemijskim značajkama mikro lokacije. Primjerice, Rubinić i dr. (2017) navode da sedra na rijeci Krki raste 10-30 mm a^{-1}, dok za prostor SB-a Bonacci i dr. (2017) spominju rast sedrenih barijera u od tek 1,6 mm a^{-1}. Vrijednost od ±0,1 mm odabrana je kao prihvatljiva s obzirom na očekivani prirast sedre. Očekivani prirast sedre u konačnici je određen prema istraživanjima Arenas i dr. (2014), Arenas i dr. (2010), Auqué i dr. (2013), Auqué i dr. (2014), Vázquez-Urbez i dr. (2010) te Drysdale i Gillieson, (1997). Oni su stope prirasta mjerili u klimatskom području sličnom NPK-a, koristeći veći broj pločica te u fluvijalnim okruženjima koji odgovaraju klasifikaciji korištenoj u ovom istraživanju. Primjerice, ako prosječan prirast sedre bude iznosio 5,17 mm a^{-1} kao u istraživanju Auqué i dr. (2013) tad će sustavna pogreška iznositi tek 1,94% godišnje akumulacije.

- **H2 Razvijen sustav izravnog, beskontaktnog, intervalnog praćenja dinamike sedrenja postići će vertikalnu i horizontalnu preciznost od ±0,1 mm.**

  U većini istraživanja koja se bave dinamikom formiranja sedre preciznost uređaja koji je korišten za mjerenje TGR-a i TER-a nije navođena. Ipak, Drysdale i Gillieson, (1997) navode da je preciznost MEM-a prije svega uvjetovana čvrstinom precipitata da te pogreške pri ponovljenim mjerenjima mekanijih sedrenih površina iznose do 0,53 mm. Navedena pogreška u takvim slučajevima je iznosila između 5 i 10 % godišnje akumulacijske stope te se smatra da je unutar prihvatljivih granica. Dakle, granica prihvatljive preciznosti

ponovno ovisi o očekivanom prirastu sedre. Stoga je u istraživanju kao prihvatljiva razina vertikalne i horizontalne preciznosti odabrana vrijednost SD od 0,1 mm).

- **H3 Selektivno uklanjanje vegetacije reaktivirat će sedrotvorne vodotokove.**
  Proglašenjem NPK zaštićenim područjem došlo je do prirodne sukcesije vegetacije uslijed zabrane i izostanka nekadašnjih djelatnosti (npr. ispaša i poljoprivreda) na velikom djelu Parka. Danas šire područje SB-a te određeni dio sedrenih barijera obilježava izrazito gust vegetacijski pokrov. Međutim, nekontroliran rast vegetacije može dovesti do zaraštavanja barijera, isušivanja njenih dijelova (Gulin i dr. 2018), promjene smjera i nestanka sedrotvornih vodotokova ili može utjecati na izmjenu količina organskih tvari u vodi (Walpersdorf i dr. 2004, Horvatinčič i dr., 2004) te dovesti do degradacije vodnog ekosustava. Posebnu opasnost predstavlja nekontrolirano širenje invazivnih vegetacijskih vrsta koje je u NPK-a već uočeno (Novak i Kravarščan, 2014). Presušeni sedrotvorni vodotokovi na odabranoj testnoj plohi identificirati će se pomoću Austro-Ugarske topografske karte (1883 god.), terenskim istraživanjem te hidrološkim analizama iz visoko-rezolucijskog hibridnog LiDAR[9] modela. Uz invazivnu vegetaciju izvršit će se selektivno uklanjanje i čišćenje drugih nezaštićenih oblika vegetacije koji su naneseni djelovanjem vode te su polaganom akumulacijom biljnih fragmenata uzrokovali promjenu smjera i presušenje pojedinih dijelova sedrotvornih vodotokova.
  Selektivnim uklanjanjem (ne)invazivne vegetacije nastojat će se u što manjoj mjeri kratkoročno poremetiti postojeći ekosustav testne plohe s ciljem ostvarenja dugoročnih ciljeva: reaktivacija sedrotvornih tokova, postizanja održivih uvjeta sedrenja te povećanja bioraznolikosti. Uprava NPK se obvezala ishoditi dozvole *Ministarstva zaštite okoliša RH*. Uvažavajući navedene čimbenike pretpostavlja se da će se provođenjem selektivnog uklanjanja (ne)invazivne vegetacije na definiranoj testnoj plohi postići reaktivacija sedrotvornih vodotoka te održivi uvjeti sedrenja).

- **H4 U razdoblju od godine dana na postavljenim pločicama zabilježit će se maksimalna stopa prirasta sedre veća od 15 mm.**
  Dinamika sedrenja proučavana je u velikom broju znanstvenih radova primjenjujući različite izravne i neizravne metode mjerenja. Detaljan pregled stopa prirasta sedre pružen je u poglavlju *2.4.7 Metode određivanja dinamike sedrenja*. Poznato je da prirast sedre

[9] Light Detection and Ranging

ovisi o širokom spektru biohidrokemijskih parametara, broju uzoraka te metodi mjerenja. U pravilu postoji značajna varijabilnost rezultata u stopama prirasta za isti sedrotvorni sustav ovisno o biohidrokemijskim obilježjima fluvijalnog mikrookruženja. Prirast sedre se u RH uglavnom određivao hidrološkim pristupom (Zwicker i Rubinić, 2004, Bonacci i dr., 2017, Rubinić i dr., 2017), odnosno analizom visine vode u jezeru kroz specifično razdoblje, dok inozemni autori uglavnom koriste MEM te prirast sedre proučavaju na određenom broju uzoraka testnih pločica (Drysdale i Gillieson, 1997, Arenas i dr., 2010, Auqué i dr., 2013, Auqué i dr., 2014, Arenas i dr., 2014).

U disertaciji je, prema vrijednostima maksimalnog prirasta sedre u sedrotvornim sustavima koji se nalaze u sličnom klimatskom području kao NPK te u kojima je korištena izravna metoda mjerenja, odlučeno da se kao pretpostavka maksimalnog prirasta sedre postavi vrijednost od 15 mm a^{-1}. Primjerice, na prostoru središnje Španjolske Arenas i dr. (2014) utvrđuju maksimalnu stopu prirasta od 16,53 mm a^{-1}, Vazquez-Urbez i dr. (2010) 17,45 mm a^{-1}, dok Arenas i dr. (2010) bilježe 13,10 mm a^{-1}. Svi autori ističu značajnu varijabilnost rezultata stopa prirasta. Istraživanja prirasta sedre u sedrotvornim sustavima RH-a također su rezultirala značajnom varijabilnošću. Primjerice, Rubinić i dr. (2017) navode da sedra na rijeci Krki raste u prosjeku 10-30 mm a^{-1}, dok Bonacci i dr. (2017) ističu mogućnost porasta sedrenih barijera na SB u prosjeku od tek 1,6 mm a^{-1}. Zwicker i Rubinić (2004) navode da prirast sedre na jezeru Kozjak iznosi 5,6 mm a^{-1}, dok Srdoč i dr. (1985) spominju vrijednost od 15 mm a^{-1}. Za Prošćansko jezero Zwicker i Rubinić (2004) utvrđuju stopu prirasta sedre od 13,50 mm a^{-1}. Postavljena vrijednost maksimalne stope prirasta sedre od 15 mm a^{-1} služi kao polazna (referentna) mjera za usporedbu odabrane testne plohe i drugih sedrotvornih sustava u svijetu).

- **H5 Stopa prirasta sedre bit će veća u hladnijem u odnosu na toplije razdoblje.**

  Postavljena hipoteza je suprotna onome što se smatra dominantnim trendom i što je uočeno u većini fluvijalnih sedrotvornih sustava. Generalno precipitacija sedre je izraženija u toplijim klimatskim uvjetima (Drysdale i Gillieson 1997, Kano dr., 2007), a snažan sezonski uzorak sedrenja koje je izrazitiji u toplijim razdobljima navodi velik broj autora (Arenas i dr., 2014, Auqué i dr., 2014, Arenas i dr., 2010, Kano i dr., 2003, Kawai i dr., 2006, Merz-Preiß i Riding, 1999, Vázquez-Urbez i dr., 2010, Matoničkin Kepčija i dr., 2017). Naime, visoke temperature pogoduju otplinjavanju CO_2, čime povećavaju taloženje kalcita (Špoljar i dr., 2011) te potiču razvoj mikroorganizama (Vazquez-Urbez i dr., 2010, Auqué i dr., 2014) odnosno u konačnici procesa laminacije koji ima jasan sezonski uzorak

(Kano i dr., 2003, Kawai i dr., 2009). Međutim, u sedrotvornim sustavima postoje iznimke koje odstupaju od sezonskog uzorka sedrenja. U ovom slučaju pretpostavljeno je da će sezonski uzorak sedrenja odstupati od dominantnog trenda zbog dva razloga. Prvi razlog navode Auqué i dr. (2013). U njihovom istraživanju brzina prirasta sedre je bila veća u hladnijim nego u toplijim razdobljima. Razlog tome je izrazito slab protok vode u toplim razdobljima, što je za posljedicu imalo presušivanje određenih dijelova sedrotvornih vodotokova te slabo mehaničko otpuštanje CO_2. Naime, zabilježeno je da uzorci sedre koji su podvrgnuti sušnim periodima u toplijim razdobljima bilježe vrlo niske ili čak negativne stope sedimentacije (Auqué i dr., 2013) te su podložnije eroziji. S obzirom na to da područje rijeke Krke obilježava velika vlažnost i plavljenje tijekom zime, a česta oskudica vode ljeti (Šandrić, 2016), što je potvrđeno terenskim istraživanjima (Slika 1), pretpostavlja se da će brzina sedrenja biti veća u hladnijem razdoblju. Također, zbog većih količina vode očekuje se snažnija turbulencija koja mogu povećati mehaničko otplinjavanje CO_2 (Liu, 2017).

Slika 1. Izgled Skradinskog buka u A) toplom u odnosu na B) hladno razdoblje

Drugi razlog je povezan s frekvencijom snimanja pločica. Naime, za potrebe disertacije dinamika sedrenja je proučavana u jednogodišnjem razdoblju u intervalnim mjerenjima od tri i šest mjeseci. Većina pločica je vađena i snimana u intervalu od šest mjeseci. Prvi period vađenja i snimanja se naziva kolonizacijska faza, a odnosi se na toplo razdoblje odnosno vrijeme od ožujka, 2018. do rujna 2018. U tom razdoblju dolazi do inicijalne kolonizacije površine pločice s ličinkama vodenih insekata i mikroflorom. U pravilu stopa prirasta sedre je niža za vrijeme kolonizacijskog, u ovom slučaju toplog, u odnosu na druga razdoblja mjerenja, u ovom slučaju hladno (rujan, 2018 - ožujak, 2019) razdoblje. S obzirom na to da se kolonizacijska faza u ovom slučaju podudara s toplim razdobljem pretpostavilo se da će stope sedrenja biti veće u drugoj fazi koja odgovara hladnom razdoblju).

- **H6 Učinak erozije bit će zabilježen na pločicama snimljenim u intervalnim razmacima.**

  Erozivni događaji na površini sedre izmjereni su u većini istraživanja dinamike formiranja sedre. Razlozi tome mogu biti: intenzivan protok vode uslijed pojačanih oborina ili dotoka vode, sušna razdoblja za vrijeme ljeta, ljudski čimbenik (gaženje ili diranje pločice), frekvencija snimanja umjetnih podloga koja se može podudarati s fazom gubitka perifitona uslijed emigracija ili intenzivnije ispaše te problem kompakcije odnosno pojava lažne erozije koja se javlja uslijed mjerenja s MEM-om.

  Erozija sedre je analizirana na svim pločicama koje su iz vode vađene intervalno u razmaku od tri ili šest mjeseci. Očekivano je da će se na visokorezolucijskim modelima sedre mjerenim u intervalnim razdobljima od tri i šest mjeseci uočiti posljedice erozivnih procesa, odnosno lokacije gdje je došlo do djelomičnog uklanjanje sedre deponirane u razdoblju koje je prethodilo snimanju).

- **H7 Stopa prirasta sedre bit će veća u fluvijalnim okruženjima bržeg protoka i turbulencije vode.**

  Stopa prirasta sedre prema vrsti fluvijalnog okruženja proučavana je u većini istraživanja dinamike formiranja sedre. Usporedba stopâ prirasta sedre prema tipovima fluvijalnog okruženja moguća je jedino ako su pločice u proučavanom razdoblju bile izložene relativno stabilnim hidrauličnim uvjetima (brzina, turbulencija i dubina vode), odnosno ako se fluvijalna obilježja lokacija nisu značajnije mijenjala između intervalnih snimanja.

  U pravilu prosječne stope prirasta sedre prema vrstama fluvijalnog okruženja značajno variraju. Postavljena hipoteza se podudara s obilježjima većine aktivnih sedrotvornih sustava (Arenas i dr., 2014, Arenas i dr., 2010, Auqué i dr., 2014, Auqué i dr., 2013, Bono i dr., 2001, Drysdale i Gillieson 1997, Gradziński, 2010, Lu, i dr., 2000, Liu, 2017, Liu i dr., 1995, Vázquez-Urbez i dr., 2010, Zhang i dr., 2012) gdje su najveće stope prirasta sedre izmjerene u fluvijalnom okruženju brzo protočne turbulentne vode, najmanje u sporo-protočnoj i stagnantnoj vodi, a prijelazne vrijednosti u zonama prskanja i udara vode.

- **H8 Stopa prirasta sedre će biti veća na lokacijama šireg prostora Skradinskog buka u odnosu na lokacije na Roškom slapu.**

  Postavljena hipoteza se podudara s obilježjima većine aktivnih sedrotvornih sustava (Drysdale i dr., 2002, Auqué i dr., 2013). Naime, očekivani tip razvoja sedrotvornog

sustava je onaj u kojem se intenzivnije sedrenje bilježi u nizvodnom dijelu vodenog sustava uslijed većeg oslobađanja CO_2, viših vrijednosti pH-a, povišenih temperatura, bržeg metabolizma organizama itd. Ipak, Matoničkin Kepčija i dr. (2017) su primjenjujući metodu masenog prirasta izmjerili 10 puta veće količine sedre na lokaciji brze vode RS-a (0,9 g/cm^2) u odnosu na lokaciju brze vode SB-a (0,09 g/cm^2) gdje su izmjerene količine sedre manje od četiri do šest puta u usporedbi s prethodnim rezultatima (Primc-Habdija i dr., 2010).

S ciljem provjere spomenutih rezultata, 13,2 km uzvodno od testne plohe SB-a postavljeno je osam testnih pločica na četiri lokacije unutar šireg područja RS-a. Pločice su postavljene u sklopu projektnih aktivnosti GAL-a[10], a iz toka će se vaditi i mjeriti u intervalima od šest mjeseci. Uvažavajući propisani radni plan, vremenske (ne)prilike te fluvijalna obilježja RS-a, broj testnih pločica i njihovo vrijeme postavljanja nije moglo biti usklađeno s istraživanjem na testnoj plohi SB. Usprkos tome, izmjerene stope prirasta sedre dat će generalnu sliku intenziteta sedrenja s obzirom na lokaciju (uzvodno, nizvodno) pločica u vodenom sustavu.

[10] Laboratorij za geoprostorne analize (*Geospatial Analysis Laboratory*) pri Odjelu za geografiju Sveučilišta u Zadru. Projekt je HrZZ-a (Hrvatske zaklade za znanost) UIP-2017-05-2694 koji okuplja interdisciplinarni tim znanstvenika iz različitih znanstvenih polja (geografija, arheologija, geodezija, agronomija).

1.3 Prostorni obuhvat istraživanja

Prostorni obuhvat je prema metodološkom okviru rada podijeljen na tri razine istraživanja. Makro razina obuhvaća šire područje SB-a. Mezo razina se odnosi na odabranu testnu plohu (mikropodručje) unutar šireg područja SB-a, dok se mikro razina odnosi na postavljene testne pločice na kojima će se pratiti dinamika formiranja sedre.

1.3.1 Nacionalni park "Krka" (NPK)

NPK je smješten na području Šibensko-kninske županije, između ravnokotarskog prostora, zaravni rijeke Čikole i Dalmatinske zagore, dok ga sa zapada, sjevera i istoka nadvisuju Velebit, Dinara, Svilaja i Mosor (Marguš, 2017). Smješten je između 43° 47′ 036" i 44° 03' 218" sjeverne geografske širine te između 15° 55' 894" i 16° 09' 919" istočne geografske dužine (Bulat, 2011) (Slika 2). Spada u najmlađe NP[11] u RH-a te predstavlja javnu ustanovu koja je utemeljena s isključivim ciljem očuvanja prirodne i kulturne baštine rijeke Krke (Botić, 2010). Proteže se pedesetak kilometara uz tok rijeke Krke, počevši dva kilometra nizvodno od Knina do Skradina uključujući i 3,5 km donjeg kanjonskog toka rijeke Čikole (Slika 1) (Marguš i dr., 2017). Potreba za njegovom pravnom zaštitom prepoznata je od sredine 20. stoljeća (Vatavuk, 2018).

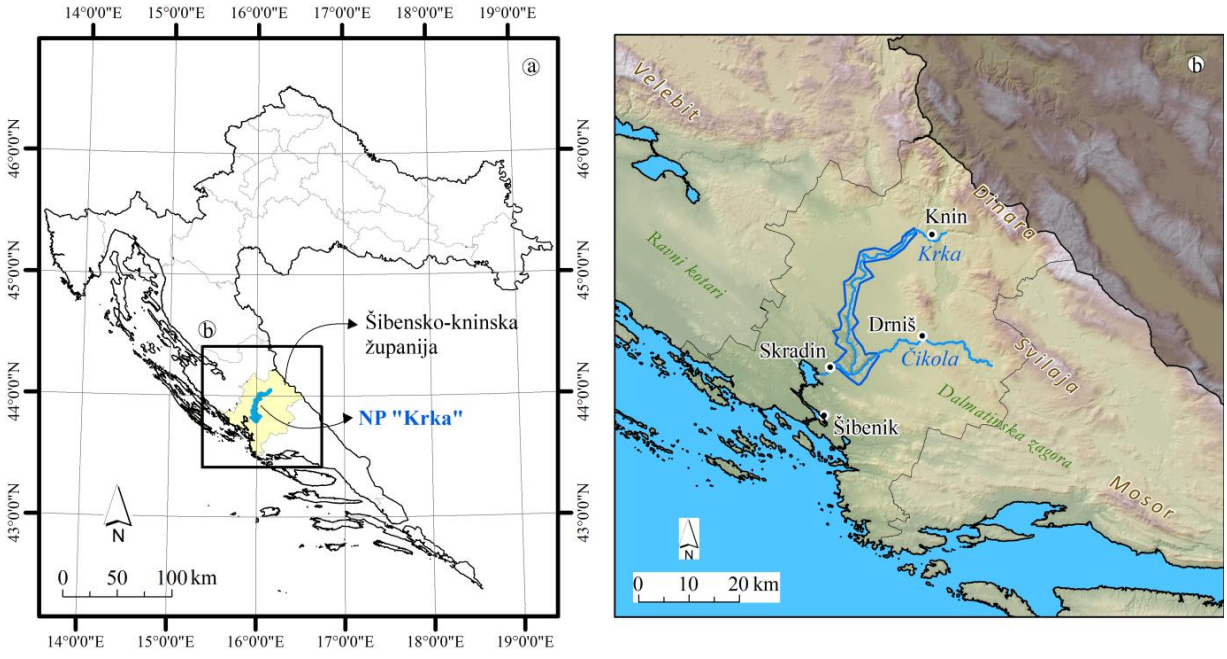

Slika 2. Geografski smještaj a) NPK-a u RH-a te b) Šibensko-kninskoj županiji

Prvi pravni akt o zaštiti dijela tog prostora, *Odluka o proglašenju Skradinskog buka zaštićenom prirodnom rijetkošću* (Marguš, 2017), donesen je 22. studenog, 1948. godine, a bio

[11] Nacionalni park

je usmjeren prema očuvanju vodotoka Krke od Bilušića buka do Skradinskog buka (Cukrov i dr., 2010). Inicijativa za proglašenjem rijeke Krke NP-om seže od 1971. godine kad je izrađen prostorni plan pod nazivom *Nacionalnih park Krka: razvojni prostorni plan* (Vatavuk, 2018). Prvim proglašenjem 24. siječnja 1985. godine od strane Sabora SR[12] Hrvatske, NPK je obuhvaćao površinu od 142 km². Površina mu je smanjena 1997. godine odlukom Sabora RH zbog toga što u jugozapadnom dijelu Parka nije bilo moguće primijeniti odgovarajući zaštitni režim uslijed pojačanog antropogenog utjecaja (Radeljak i Pejnović, 2008, Vatavuk, 2018). Danas NPK obuhvaća površinu od 109 km² gornjeg i srednjeg toka rijeke Krke te donjeg toka rijeke Čikole od kojih 9 km² tvore vodene površine (Bonacci i dr., 2016). Do trenutka proglašenja područje NPK je bilo dio tradicionalno korištenog krškog prostora s ekstenzivnim stočarstvom kao temeljnom djelatnošću (Hršak i dr., 2017). Posljednjih desetljeća socioekonomske i demografske promjene u strukturi stanovništva rezultirale su procesom vegetacijske sukcesije (Šakić, 2017).

1.3.1.1 Prirodno-geografske značajke šireg područja NP Krka

Dolina rijeke Krke na području Sjevernodalmatinske zaravni predstavlja poseban krški fenomen (Perica i dr., 2005). Sjevernodalmatinska zaravan je nastala krajem pliocena i početkom pleistocena, a uslijed intenzivne kasnopleistocenske glacijacije, litološki i tektonski predisponiranim smjerovima u nju se usjekao kanjon rijeke Krke (Bulat, 2011). Krka se proteže kroz priobalni krški pojas zone sjevernodalmatinskih bora i reverznih rasjeda Vanjskih Dinarida (Medunić i dr., 2013). Duga je 72,5 km, od čega na slatkovodni dio otpada oko 49 km (Bulat, 2011). Morfologija doline rezultat je geološke građe i klimatskih promjena koji su se dogodili tijekom gornjeg pleistocena i holocena (Cukrov i dr., 2010). Međutim, na današnji izgled okolnog područja rijeke te njene specifične hidrološke elemente u velikoj mjeri svojim aktivnostima utjecao je i čovjek (Perica i dr., 2005).

Područje nizvodno od Knina najvećim dijelom izgrađuju vodopropusne (vapnenci) i djelomično vodonepropusne (dolomiti, laporoviti i pločasti vapnenci i vapnenački lapori) stijene. Karbonatne naslage na tom prostoru su izrađene od otopljenog kalcijevog bikarbonata koji gradi najprepoznatljivije obilježje rijeke, sedrene barijere i pragove (Perica i dr., 2005) stvarajući time atraktivne vodopade (Cukrov i dr., 2008). Najistaknutije značajke ovog biotopa su brzo strujanje i raspršivanje vode koja je bogata otopljenim bikarbonatima s makro i mikro biološkim zajednicama koje cvjetaju na sedrenim barijerama time pridonoseći njihovoj izgradnji (Medunić i dr., 2013). Dakle, s nizom spektakularnih slapova i kaskada i iza njih

[12] Socijalistička Republika

jezera, rijeka Krka predstavlja poznati krški fenomen te osnovni prirodni fenomen NPK (Cukrov i dr., 2008, Medunić i dr., 2013). Inače, nastanak sedre je na tom području započeo u razdoblju pleistocena te s povremenim prekidima traje do danas (Perica i dr., 2005). Na području NPK-a dominantni su lapori foraminiferskih vapnenaca, konglomerati i rudistni vapnenci. Navedeno je uvjetovalo razvoj rendzina[13] koji predstavljaju jedan od najzastupljenijih tala. Od nerazvijenijih tala prisutan je kamenjar (Bulat, 2011).

Veći dio područja NPK ima umjereno toplu sredozemnu kišnu klimu (Csa) sa sušnim i vrućim razdobljima ljeti. Ljeta su vruća sa srednjom temperaturom najtoplijeg mjeseca većom od 22°C, a četiri mjeseca u godini imaju srednju mjesečnu temperaturu veću od 10°C (Bulat, 2011). Prema podatcima *Državnog hidrometeorološkog zavoda* u razdoblju od 1948. do 2018. godine srednja godišnja temperatura zraka je kod ušća Krke bila viša za oko 2°C u odnosu na njezin gornji tok. Nadalje, NPK ima maritimni oborinski režim. U prosjeku gornji tok rijeke Krke (Knin 1 059 mm) godišnje primi oko 200 mm padalina više od njenog ušća (Šibenik 808 mm). U zaleđu Parka izrazite suhoće nema dok je na obali (Šibenik) suho razdoblje u toplom dijelu godine kad najsuši mjesec (srpanj) u pravilu ima manje od trećine padalina (oko 30 mm) najkišovitijeg mjeseca u hladnom dijelu godine (Bulat, 2011; URL 18).

[13] Šumsko tlo razvijeno na rastresitom karbonatnom supstratu; slabije plodnosti.

1.3.2 Šire područje Skradinskog buka (SB)

Na makro razini prostorni obuhvat istraživanja se odnosi na šire područje SB-a (Slika 3), odnosno najnizvodnije, najduže, najpoznatije i najposjećenije slapište Parka (Ford i Pedley, 1996., Bonacci i dr., 2016, Klanjšček i dr., 2017) kojeg čine brojne sedrene kaskade, otoci i jezera. Voda rijeke Krke se prelijevanjem preko SB-a obrušava s 46 m nadmorske visine na manje od 2 m. Od tog mjesta tok rijeke pod izravnim je utjecajem mora.

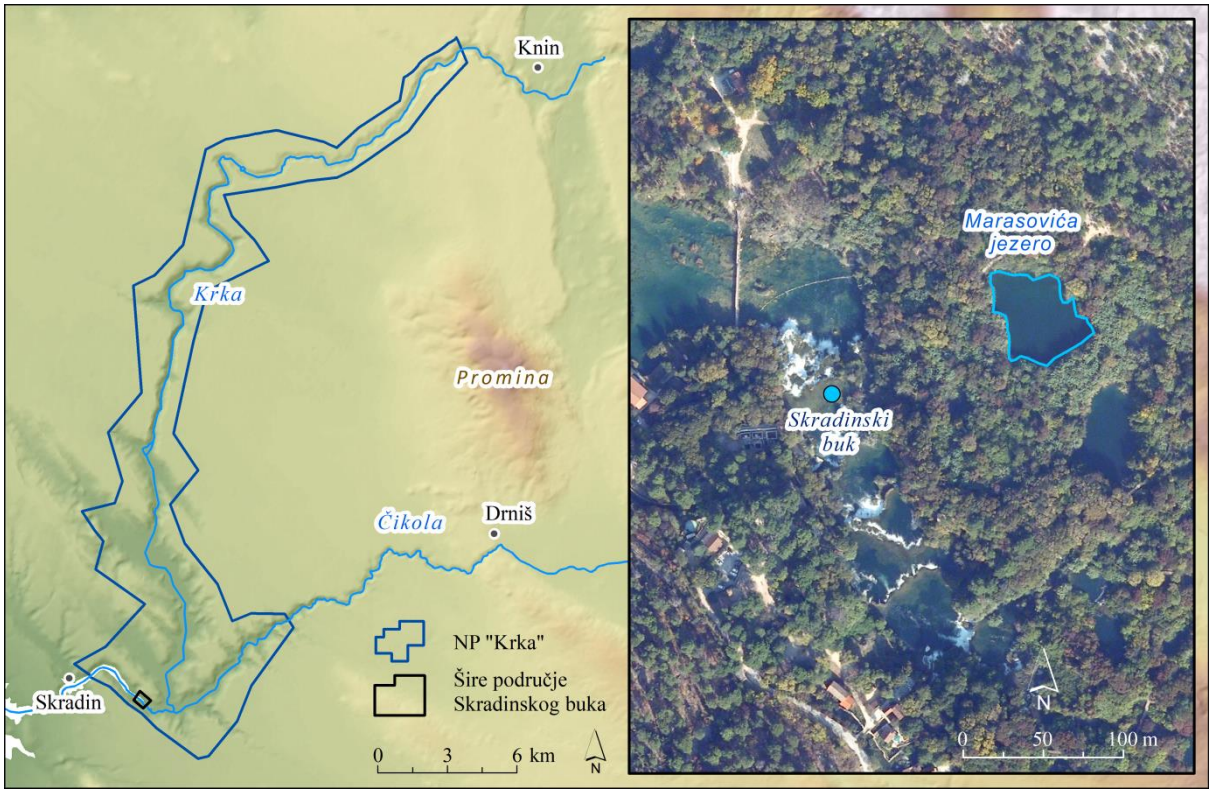

Slika 3. Geografski položaj SB-a u NPK

SB spada u nizvodni tip slapa koje obilježava relativno visok pad, s gornje strane dobro razvijena mrežasta sedrena struktura te male barijere koje u nizvodnom smjeru postaju sve veće (starije). Najmlađe sedrene tvorevine nalaze se iznad slapa (Matoničkin i Pavletić 1960). Šire područje SB-a sastoji se od kružne staze, odvojka za pristanište uzvodno, etnosela, vidikovaca na sjevernoj strani rijeke, biciklističke staze, livade s kupalištem i ugostiteljskim sadržajima, pristaništa, mosta, elektrane s vidikovcima i etno sela (Klanjšček i dr., 2017).

Rast sedre na SB-u uzorkovao je ujezerenje vode stvarajući tako prepoznatljivu krajobraznu sliku NPK. SB čini sedrenu barijeru koja na toku rijeke Krke formira jezero dužine oko 8 km. Dno mu se nalazi na razini Jadranskog mora u dolini koja je nastala postglacijalnim izdizanjem morske razine (Bonacci i dr., 2016). Svrstan je u *najvrjednije i najupečatljivije krške krajobrazne fenomene planetarnog krša* (Bonacci i dr., 2016: 27). Procjenjuje se da je sedra na tom prostoru stara oko 9000 godina (Roglić, 1967). Struktura SB je obilježena sa 17

sedrenih stepenica s ukupnom dužinom od oko 800 m. Važnu ulogu u oblikovanju sedrenih barijera na SB ima voda s pritoka Čikole koja se u Krku ulijeva neposredno pred slap. Slap je širok od 200 do 400 m, te se sužava nizvodno s desnim, za 5 do 10 metara višim dijelom (Šandrić, 2016). Površinsko i potpovršinsko otjecanje vode utječe na morfološko oblikovanje samog slapa u čemu važnu, još uvijek nedovoljno istraženu ulogu, ima razvoj vegetacije. Na lijevoj obali SB je 1895. godine izgrađena prva hidroelektrana u svijetu te druga u Europi, HE Jaruga (Šandrić, 2016). Potom su početkom dvadesetog stoljeća napravljene još dvije, da bi danas duž toka Krke u funkciji bile četiri HE Miljacka, HE Roški slap, HE Jaruga te HE Krčić što je za posljedicu imalo izmjenu prirodnog režima rijeke.

Iz podataka o karakterističnim mjesečnim vodostajima i protocima na postaji SB gornji može se uočiti jasna sezonalnost u intenzitetu protoka i visini vodostaja. Naime, tijekom lipnja, srpnja i kolovoza srednji mjesečni vodostaji su gotovo za dva puta niži u odnosu na prosinac, dok su srednji mjesečni protoci gotovo za četiri puta manji u odnosu na prosinac (Bulat, 2011). Od listopada od prosinca padnu najveće količine oborina u godini tako da je tad rijeka najbogatija vodom (URL 17). U razdoblju od 1990. do 2015. godine srednji godišnji protok na Nacionalni park vodomjernoj postaji iznosio je 20,6 $m^3 s^{-1}$ (Bonacci i dr., 2017).

1.3.3 Testna ploha na širem području SB-a

Na mezo razini istraživanja prostorni obuhvat se odnosi na odabranu testnu plohu unutar šireg prostora SB-a. Smještena je na sjeveroistočnoj strani šireg područja SB-a u neposrednoj blizini Marasovića jezera (Slika 3). Površina plohe iznosi oko 8000 m^2. Proces odabira testne plohe unutar šireg područja SB-a izvršen je primjenom višekriterijskih GIS analiza (MCDA[14]-GIS). Na definiranoj testnoj plohi izvršeno je selektivno uklanjanje (ne)invazivne vegetacije. Na 14 definiranih lokacija postavljene su po dvije testne pločice na kojima je praćena dinamika formiranja sedre unutar reaktiviranih tokova. Praćen je intenzitet protoka na sedam odabranih lokacija te je postavljena multiparametarska sonda za praćenje fizikalno-kemijskih obilježja vode. Na slici 4 prikazano je referentno stanje testne plohe, prije selektivnog uklanjanja vegetacije, s presušenim sedrotvornim tokovima te depresijama.

[14] Multiple-Criteria Decision Analysis

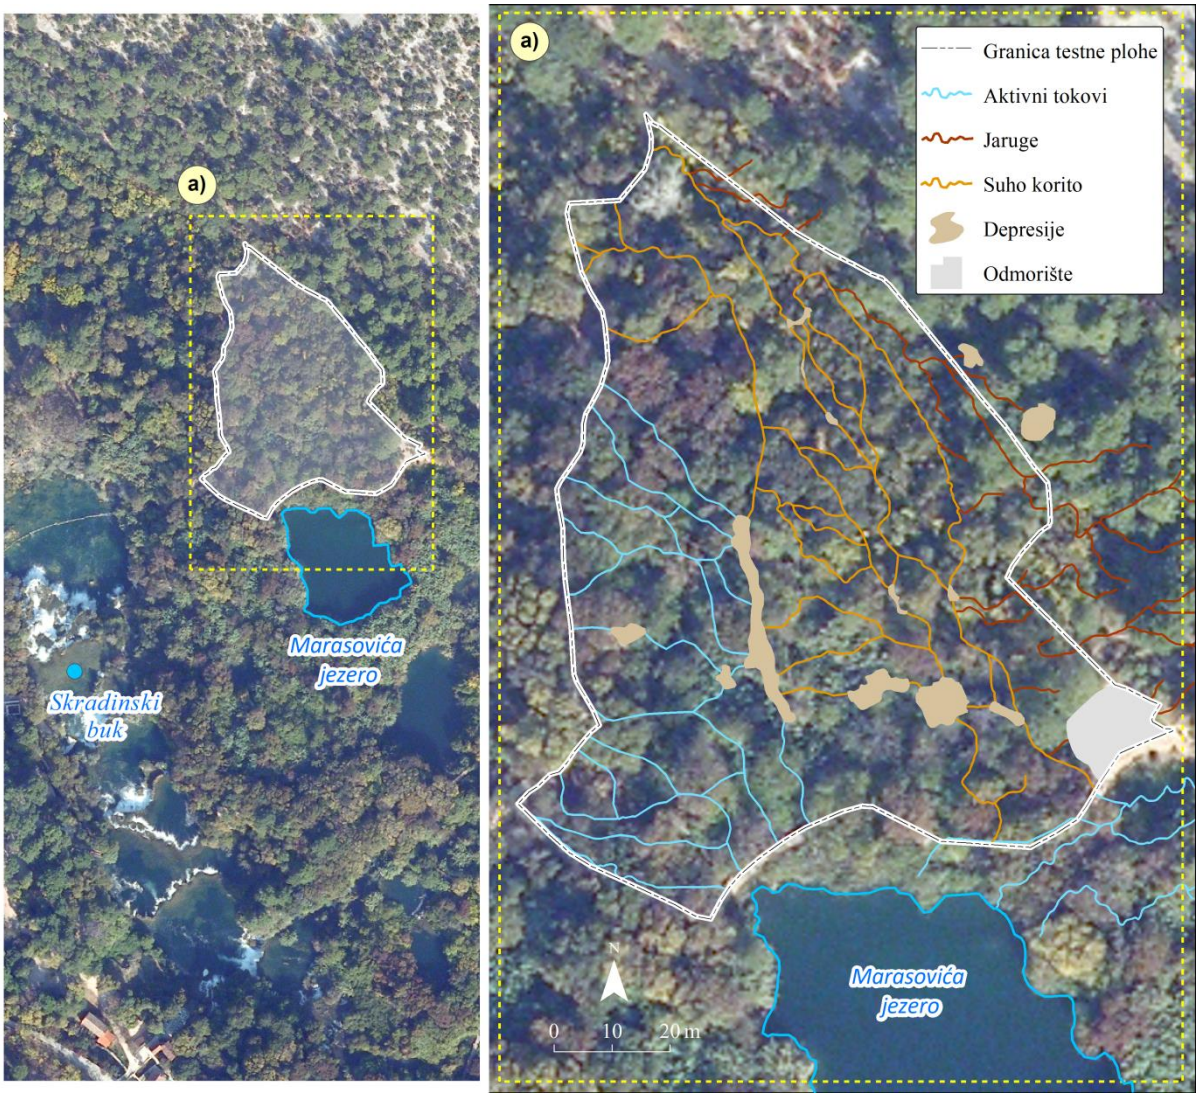

Slika 4. Geografski smještaj testne plohe SB

1.3.4 Testna ploha na širem području Roškog slapa (RS)

Na mezo razini istraživanja izvršeno je praćenje dinamike formiranja sedre kroz šestomjesečno razdoblje (srpanj, 2019. – siječanj, 2020.) na prostoru RS-a. RS je pretposljednji slap na rijeci Krki, a nalazi se 14 km nizvodno od Miljacka slapa te 13,2 km uzvodno od odabrane testne plohe na SB (Slika 5). Dug je 650, a širok 450 m s visinskom razlikom od 22,5 m (Ridl, 2015). Veoma je zanimljiv zbog specifičnosti kanjonske vegetacije na kontaktima suhih, vlažnih, svijetlih i sjenovitih staništa te zbog kaskada koje su popularno prozvane *srebrene ogrlice*, a čine početak sedrene barijere. Prostor RS-a je odabran s ciljem usporedbe stopa sedrenja s onima izmjerenima na odabranoj testnoj plohi SB-a.

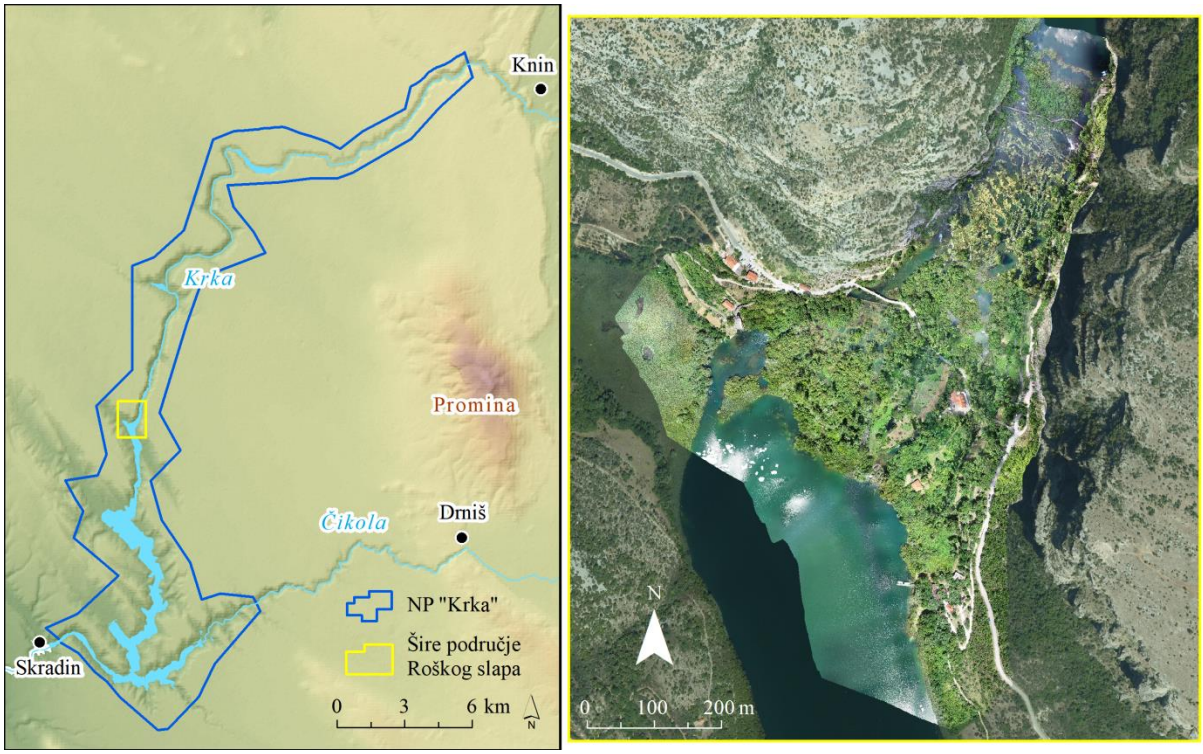

Slika 5. Geografski položaj RS u NPK

1.4 Pregled dosadašnjih istraživanja

Uvažavajući interdisciplinarnost osnovnog cilja i svrhe disertacije konzultirana je literatura iz različitih znanstvenih polja i područja, koji u potpunosti ili parcijalno, obrađuju teorijski ili praktični dio problematike povezane s istraživanjem. Problematika uključuje: sedru i uvjete sedrenja, metode mjerenja dinamike formiranja sedre, principe upravljanja zaštićenim područjima te primjenu geoprostornih tehnologija (makrofotogrametrija, zračni LiDAR itd.) u sličnim istraživanjima. Analizirana literatura je stoga podijeljena u tri tematske cjeline. Prva cjelina obuhvaća literatura koja u širem kontekstu obrađuje dinamiku formiranja sedre i travertina te parametre koji na to utječu.

Dinamika formiranja sedre proučavana je u velikom broju znanstvenih radova koristeći različite izravne i neizravne metode mjerenja. Stope prirasta sedre primjenom MEM-a utvrđuju: **Drysdale i Gillieson, (1997), Arenas i dr. (2010), Vázquez-Urbez i dr. (2010), Arenas i dr. (2014), Auqué i dr. (2013) te Auqué i dr. (2014).** Metodu masenog prirasta (engl. *mass increments*) koriste **Liu i dr. (1995), Bono i dr. (2001), Wróblewski, i dr. (2017), Pentecost i Coletta (2007), Gradziński (2010), Liu i dr. (2010), Zhang i dr. (2012)**, **Liu (2017)** te **Matoničkin Kepčija i dr. 2017.** Dinamiku formiranja sedre kroz praćanje inkrustacije biljnih fragmenata ili umjetnih supstrata te primjenom skenirajućeg elektronskog

mikroskopa (SEM[15]) utvrđivali su **Wallner (1934), Mägdefrau (1956), Irion i Müller (1968), Schnitzer (1974), Weijermars i dr. (1986), Merz-Preiß i Riding (1999), Arp i dr. (2001), Kano i dr. (2003), Lojen i dr. (2004)** te **Tran i dr. (2019)**. Od drugih izravnih metoda **Statham (1977)**, **Thorpe (1981)** koriste akrecijske igle, a **Baker i Smart (1995)** digitalni mikrometar. Od neizravnih metoda autori **Srdoč i dr. (1985), Chafetz i dr. (1994), Kempe i Emeis, (1985), Zwicker i Rubinić (2004), Rubinić i dr. (2017**), u radovima navode i/ili primjenjuju metodu hidrološkog pristupa. Metodu prijenosa mase (engl. *mass transfer* ili *mass balance*) primjenjuju i/ili navode **Kempe i Emeis, (1985), Weijermars i dr. (1986), Bono i dr. (2001), Yoshimura i dr. (2004)** te **Arp i dr. (2010).** Nadalje, određivanje stopa prirasta sedre metodom izotopa primjenjuju **Kerney i dr. (1980), Pazdur i dr. (1988), Heimann i Sass (1989), Preece i Day (1994), Pedley i dr. (1996), Peña i dr. (2000), Meyrick i Preece (2001), Limondin-Lozouet** i **Preece (2004), Petryshyn i dr. (2012)** te **Demott i dr. (2019).** Druge geokronološke metode koriste i/ili navode **Peña i dr. (2000), Yoshimura i dr. (2004)** i **Rosen i dr. (2004).** Konzultiran je velik broj radova gdje metoda nije jasno definirana, odnosno rezultati istraživanju su citirani od strane drugih autora. Oni uključuju autore: **Lu i Li (1992), Benson i dr. (1996), Laval i dr. (2000), Matsuoka i dr. (2001), Brady i dr. (2009), Soles i dr. (2012)** U nastavku su sažeto opisani zaključci radova čija su saznanja u ovoj disertaciji najviše korištena, a u širem kontekstu obrađuje temu sedrenja.

Matoničkin i Pavletić (1960) proučavaju biološke značajke sedrenih slapova u glavnim krškim rijekama RH. Ističu da u procesu izgradnje slapova važnu ulogu igraju živi organizmi koji omogućuju zadržavanje istaloženog karbonata. Zadržavanjem tih organizama se dovodi u vezu s brzinom vode koje mora biti ispod erozijskog djelovanja, što iznosi od 0,5 do 3,5 m/s.

Weijermars i dr. (1986) analiziraju stope prirasta travertinskih terasa (Checa, Španjolska). Analizom fosilnih i živih primjeraka različitih vrsta mahovina utvrđuju vrlo visoke stope kalcifikacije. Srednju stopu prirasta od 42 mm a^{-1} izračunavaju metodom prijenosa mase. Primjećuju da specifične vrste mahovina mogu oblikovati spužvaste travertinske slojeve uz maksimalne stope prirasta od čak 110 do 140 mm a^{-1}.

Srdoč i dr. (1985) opisuju fizikalno-kemijske uvjete koji pogoduju ili inhibiraju taloženje $CaCO_3$ u vodenim tokovima i jezerima krškog područja Plitvičkih jezera. Utvrđuju da sedrene barijere rastu brže u odnosu na taloženje jezerskog sedimenta. Ističu da prirast sedre na jezeru Kozjak iznosi 15,00 mm a^{-1}. Primjenjujući isti pristup u proučavanju **Rubinić i dr. (2017)** navode da sedra u rijeci Krki raste 10-30 mm $a^{-1.}$

[15] Scanning Electron Microscope

Drysdale i Gillieson (1997) prvi predlažu i proučavaju dinamiku formiranja travertina MEM-om na prostoru Queenslanda (Australija). Bilježe značajnu varijabilnost u stopama taloženja. Najveća je u visoko-energetskim hidrauličkim zonama, a najmanje u depresijama, koje odvajaju pojedine barijere. Utvrđuju pozitivnu korelaciju između najvećih stopa taloženja i pojave alohtonog biogenog materijala.

Peña i dr. (2000) analiziraju uzorke sedre u kanjonu rijeke Mijares (Španjolska) koristeći geomorfološke, stratigrafske, mikromorfološke, mineraloške i kronološke (U/Th i 14C) tehnike. Uspoređuju različite facijese sedre te utvrđuju kontinuirani minimalni prirast sedre u rasponu između 1 do 5 mm a^{-1}. Utvrđuju da su topla klimatska razdoblja pogodovala intenzivnom prirastu sedre u fluvijalnom sustavu.

Arp i dr. (2001) analiziraju nastanak sedre u tokovima s naglaskom na fotosintetskoj ulozi cijanobakterija u toku Deinschwanger Bach (Njemačka). Analizom hidrokemijskih podataka utvrđuju da je precipitacija $CaCO_3$ duž toka primarno uvjetovana otpuštanjem CO_2, dok fotosintetska asimilacija ugljika (C) nema uočljiv učinak na karbonatni ekvilibrijum. Navode da brzina formiranja sedre na postavljenim uzorcima (pločicama) iznosi do 1,5 mm kroz 10 mjeseci.

Bono i dr. (2001) su pratili stope precipitacije kalcita, hidrokemijske parametre i uvjete toka (*Tartare* krškog izvora) u središnjoj Italiji. Na četiri lokacije u različita fluvijalna okruženja su postavili umjetne pločice. Stope precipitacije su izračunali metodom masenog prirasta. Dobivene vrijednosti su usporedili s teorijskim stopama koje su izveli iz hidrokemijskih podataka (metoda prijenosa mase) i uvjeta protoka. Utvrdili su da su stope precipitacije kalcita u brzo protočnoj vodi veće za čimbenk 4 u odnosu na stope u stagnantnoj vodi.

Zwicker i Rubinić (2004) na temelju hidroloških podataka (promjene u razinama vodostaja) u razdoblju od 1952. do 1990. godine utvrđuju da stopa prirasta sedre na jezeru Kozjak iznosi 5,6 mm a^{-1}, dok je na Prošćanskom jezeru gotovo tri puta veća.

Arenas i dr. (2010) prate fizikalne i hidrokemijske parametre te dinamiku sedrenja na području NP Monasterio de Piedra (Španjolska), rijeka Pierda. Utvrdili su pet specifičnih struktura sedre u odnosu na različita fluvijalna okruženja. Stope taloženja su zabilježile jak sezonski uzorak s višim vrijednostima u toplijim, nego u hladnijim razdobljima, dok je najveći zabilježen prirast iznosio 13,10 mm a^{-1}.

Gradziński (2010) analizira dinamiku formiranja sedre u sedrotvornim područjima Slovačke i Poljske s ciljem utvrđivanja čimbenika koji utječu na rast i teksturu sedre na vapnenačkim i bakrenim pločicama. Utvrđuje da brzina taloženja ovisi o zasićenosti vode kalcitom te da sedra brže taloži na vapnenačkim u odnosu na bakrene pločice. Ističe mikroorganizme kao ključne

čimbenike u rastu sedre, te veću stopu rasta u bržoj tekućoj vodi. Prirast sedre mjeri na temelju masenog prirasta.

Vazquez-Urbez i dr. (2010) su proučavali su širok spektar čimbenika koji utječe na dinamiku sedrenja kroz šestogodišnje razdoblje na području NP Monasterio de Piedra (Španjolska). Utvrdili u četiri vrste sedre prema strukturnim i teksturalnim obilježjima. Stopa prirasta sedre je bila veća u brzo tekućim riječnim područjima i stepenastim vodopadima, a niža u sporo tekućim ili stagnantnim vodama te u zonama prskanja. Mehaničko otpuštanje CO_2 su prepoznali kao glavni čimbenik koji kontrolira precipitiranje kalcita.

Špoljar i dr. 2011 analiziraju proces sedrenja u krškim tokovima kroz indikator kvalitete vode. Prate dinamiku sedrenja i prateće zajednice perifitona na umjetnim površinama u toku Jankovac (PP Papuk). Na temelju prikupljenih podataka zaključuju da s radi o oligotrofnim uvjetima te navode da dinamika sedrenja pozitivno korelira s porastom temperature, protoka, količine organske tvari i biomase algi. Pretpostavljaju da oligotrofni uvjeti u vodi krša pospješuju proces sedrenja.

Auqué i dr. (2013) primjenom modificranog mikro-erozijskog metra proučavaju dinamiku sedrenja u promjenjivim hidrološkim uvjetima rijeke Mesa (Španjolska). Utvrdili su da stope prirasta iznose prosječno 2 mm a^{-1} (max. 4,53 mm a^{-1}) te da je brzina taloženja već u hladnijim (jesen + zima) nego toplijim (proljeće + ljeto) razdobljima.

Auqué i dr. (2014) su proveli trogodišnje istraživanje dinamike formiranja sedre u rijeci Anamaza (Španjolska). Navode da su stope prirasta sedre u fluvijalnim okruženjima kontrolirane količinom mehaničkog izlučivanja CO_2, što je povezano s lokalnim uvjetima protoka, biološkom vrstom supstrata i kemijskim svojstvima vode. U toplijem periodu godinu zabilježene su veće stope taloženja.

Arenas i dr. (2014) analiziraju sedimentološke i hidrokemijske parametre rijeke Pierda (Španjolska) u polugodišnjim i godišnjim intervalima na 24 lokacije s ciljem utvrđivanja unutarnjih i vanjskih čimbenika koji kontroliraju prostorne i vremenske varijacije moderne fluvijalne sedimentacije sedre. Kao primarni čimbenik utjecaja na različite vrste istaloženog facijesa sedre prepoznaju obilježja fluvijalnog okruženja. Najveće stope prirasta bilježi stromatolitna (engl. *stromatolites*), mahovinasta (engl. *moss-tufa*) i algalna sedra (engl. *alga-tufa*) dok rastresita sedra (engl. *loose tufa*) formirana u sporoj vodi ima tanji pokrov. Utvrđena je povećana precipitacija tijekom toplijeg razdoblja.

Liu (2017) istražuje čimbenike koji su doveli do degradacije sedre u nacionalnom rezervatu prirode Jiuzhaigouu (Kina). Utvrđuje stopu porasta sedre s maksimalnom debljinom depozita od 0,322 mm a^{-1}. Zaključuje da je povećana koncentracija dušika (N) i fosfora (P) koji potječu

od atmosferskog onečišćenja i pretjerane antropogene aktivnosti izazvala prekomjeran rast dijatomeja koji inhibiraju proces sedrenja.

Matoničkin Kepčija i dr. (2017) su na prostoru SB i RS pratili sezonsku dinamiku sedrenja i razvoj perifitona na predmetnim stakalcima tijekom jednogodišnjeg razdoblja. Sedrenje je zabilježilo jak sezonski uzorak s pet puta većim količinama sedre u toplijim razdobljima. Najveće količine sedre su izmjerene na RS u brzoj struji vode.

Druga cjelina obuhvaćaliteraturu koja u širem kontekstu obrađuje primjenu suvremenih geoprostornih tehnologija (GST) u istraživanjima koja zahtijevaju izvođenje visokorezolucijskih modela makro, mezo i mikro razine.

French (2003) analizira primjenu aero LiDAR-a kao sustava podrške u geomorfološkom i hidrološkom modeliranju. Utvrđuje da se primjenom LiDAR podataka mogu uočiti važne topografske varijacije unutar hidrološkog sustava. **Kincey i Challis (2009)** analiziraju primjenu aero LiDAR podataka u snimanju i praćenju osjetljivih gorskih krajobraza, s naglaskom na analizu erozije.

Nagendra i dr. (2013) analiziraju primjenu metoda daljinskih istraživanja u konzervacijskom monitoringu, odnosno procesima utvrđivanja zaštićenih područja, opsega i stanja staništa, raznolikosti vrsta i različitih prijetnji. Navode da primjena daljinskih istraživanja ima snažan, ali nedovoljno iskorišten potencijal u praćenju zaštićenih područja.

Samaan i dr. (2013) su usmjereni prema pronalasku jeftinog, učinkovitog sustava snimanja, obrade fotografija i kontrole kvalitete u izvođenju visoko-preciznih modela malih objekata u arheologiji. Ističu važnost postizanja optimalnih uvjeta osvjetljenja te automatiziranja procesa fotogrametrije. Sličan primjer navode **Gajski i dr. (2016)** te **González i dr. (2015)** koji primjenjuju makro fotogrametriju u modeliranju specifičnih ureza malih dimenzija na kostima.

Gallo i dr. (2014), Rodríguez-Martín i dr. (2015) i **Rodríguez-Martín i dr. (2016)** analiziraju mogućnost rekonstrukcije te provjeru točnosti malih objekata na temelju slijeda fotografija uslikanih makro objektivom u različitim područjima primjene. Sličan primjer navode **Marziali i Dionisio (2017)** koji provode 3D digitalizaciju 17 vrlo malih arheoloških objekata primjenom visoko-kvalitetne SfM fotogrametrijske tehnike. Navode da je ovakav proces prikupljanja i obrade podataka te izrade modela postignut uz niske kapitalne troškove te malo vrijeme obrade.

Nicolae i dr. (2014) kroz nekoliko studija slučaja obrađuju problematiku izvođenja preciznih 3D modela u kontekstu onih tipova površina koje nisu pogodne za izvođenje blizupredmetne fotogrametrije. Glavni cilj rada je pokazati kako fotogrametrija može biti valjana i pouzdane

tehnike izrade 3D modela čak i u slučaju snimanja materijala koje obilježavaju složena optička svojstva (reflektivnost, raspršenje), izazovna tekstura i složen oblik / geometrija. U konačnici pružaju smjernice za snimanje navedenih objekata.

Gajski i Gašparović (2015) ispituju važnost kalibracije kamere u procesu generiranja 3D modela mikro veličine. Analiziraju utjecaj distorzije objektiva na točnost podataka generiranih fotogrametrijskom izmjerom. U radu predlažu algoritam koji omogućuje preciznu eliminaciju distorzije objektiva kamere proizvodeći idealiziranu sliku s koje je uklonjena većina geomtrijskih pogrešaka.

Fraser (2015) daje detaljnu sliku razvoja i primjene blizupredmetne fotogrametrije u posljednjih nekoliko desetljeća s aspektima primjene. Problematiku rekonstrukcije 3D modela mikro objekata primjenom makro objektiva obrađuju **Yanagi i Chikatsu (2010)** a kao glavni nedostatak ističu vrlo malu dubinu polja (DoF[16]).

Posljednja cjelina obuhvaća literaturu koja u širem kontekstu obrađuje problematiku upravljanja zaštićenim područjima.

U knjizi *Managing Protected Areas in Central and Eastern Europe Under Climate Change* **ur. Rannow i Neubert (2009)** dostupno je dvadesetak radova koji obrađuju problematiku upravljanja zaštićenim područjima u kontekstu klimatskih promjena. Naglasak je stavljen na primjenu tehnologije daljinskih istraživanja i odgovarajućih setova kriterija kao sustava nadzora tih područja. Ključnu ulogu u razvoju scenarija prilagodbe i njihovoj implementaciji na lokalnoj razini imaju znanstvenici.

Bulat (2011) analizira institucionalni okvir zaštite prirode u RH. Ističe probleme (neusklađenost propisa i zakonska nedorečenost, nemogućnost vlastitog financiranja, nepostojanje stručnog tijela oko zajedničkog pristupa u upravljanju, velika fluktuacija zaposlenika te pretežno sezonsko zapošljavanje) koji se javljaju u svakodnevnom funkcioniranju zaštićenih područja RH te predlaže odgovarajuće mjere koje bi unaprijedile funkcioniranje parkovnog sustava RH.

Pellitero i dr. (2011) analiziraju bioraznolikost u zaštićenom području Španjolske. Predlažu uvođenje niza alata koji upravitelj zaštićenog područja može primijeniti u integraciji abiotičkih čimbenika u evaluaciji i zaštiti navedenog područja.

[16] Depth of Field

De Waele i dr. (2011) daju pregled prirodnih prijetnji koje se mogu javiti unutar krških područja. Ističu da je zbog specifičnosti i složenosti krških sustava, potrebno donijeti odgovarajuće planove upravljanja, uz suradnju širokog spektra znanstvenika.

Zhang i dr. (2012) analizirajući prostorno-vremenske varijacije u stopama prirasta travertina na prostoru Huanglonga (Kina) utvrđuju da je od ranih 90-ih došlo značajnog smanjenja dinamike taloženja. Za potrebe održivog upravljanja predlažu analizu procjene utjecaja turističkih aktivnosti na okoliš, određivanje prihvatnog kapaciteta te bolje upravljanje otpadom. Ističu potrebu primjene navedenih mjera na sve sedrene krajobraze svijeta.

Gu i dr. (2013) predlažu uspostavu praćenja kvalitete okoliša u nacionalnom rezervatu prirode Jiuzhaigou, putem programa nadzora koji bi uključivao analizu kemijskog sastava vode, kakvoće zraka, bioloških indikatora itd. Ističu da bi kvalitetu vode, količinu dušika i fosfora, biomasu algi, vodostaj te pojavu stranih vegetacijskih vrsta trebalo redovno pratiti.

Liu (2017) ističe potrebu uvođenja niza upravljačkih mjera u nacionalnom rezervatu prirode Jiuzhaigou poznatom po sedrenom krajobrazu. Utvrđuje da antropogene aktivnosti, uključujući industrijsko zagađenje te pojačana turistička aktivnost pridonose povećanju hranjivih tvari u vodi što djeluje kao inhibitor sedrenja.

U zborniku radova *Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj*, ur. **Marguš, D. (2017)** u odlomku *Upravljanje i održivi razvoj zaštićenih područja* naveden je velik broj radova koji obrađuje aktualne trendove u upravljanju zaštićenim prirodnim područjima.

Nadalje, u Planu upravljanja NP Krka (Bulat, 2011) definirani su dugoročni temeljni ciljevi upravljanja NPK postavljeni u skladu s izvornim ciljevima proglašenja NP-a. Oni uključuju zaštitu prirodne i kulturne baštine, očuvanje prirodnog procesa precipitacije sedre, temeljnog fenomena i okosnice današnje hidrogeološke slike NP „Krka“.

2. TEORIJSKA OSNOVA

2.1 Višerezolucijsko modeliranje krajobraza

Krajobraz rijeke Krke je jedna od temeljnih vrijednosti zbog kojih je NPK proglašen zaštićenim prostorom. Unutar NPK krajobraz na makro razini sačinjavaju duboki kanjon usječen u vapnenačku zaravan, sedrene barijere i slapišta različitih dimenzija i oblika, ujezereni dijelovi toka, otoci, vegetacijski pokrov, stara naselja i povijesne utvrde (Bulat, 2011). Učinkovito upravljanje tim ekološkim resursima krajobraza zahtjeva njihovo praćenje i analizu u različitim prostornim i vremenskim mjerilima (McGarigal i Marks, 1995).

U literaturi postoji širok spektar interpretacija pojma krajobraz. Univerzalno, krajobraz predstavlja određeni prostor sastavljen od različitih elemenata (McGarigal i Marks, 1995, Burnett i Blaschke, 2003, Šiljeg i dr., 2017) između kojih se odvija interaktivni mozaik odnosa koji je relevantan za specifičan fenomen, odnosno određenu razinu proučavanja (McGarigal i Marks, 1995). Struktura krajobraza se odnosi na prostorne odnose između njegovih osnovnih dijelova (McGarigal i Marks, 1995). Kvantificiranje strukture krajobraza osnovni je preduvjet u proučavanju krajobraznih funkcija i promjena (McGarigal i Marks, 1995). Potreba za kvantificiranjem je rezultirala primjenom različitih metoda, tehnika i procedura u krajobraznim analizama (Turner i Gardner, 1991, Wu i Marceau, 2002). Njihova primjena ovisi o prostornom opsegu krajobraza i veličini odabranog mjernog uzorka (Johnson i Patil, 1998).

Element (eng. *patches*), biotop, ekotop, geotop, stanište ili jedinica predstavlja osnovnu jedinicu krajobraza (McGarigal i Marks, 1995, Šiljeg i dr., 2017). Isprepleteni obrasci vremenske, prostorne i funkcionalne heterogenosti oblikuju osnovne elemente krajobraza (Farina 1998, Burnett i Blaschke, 2003). Da bi se razumjela dinamika elemenata i procesa te njihove interakcije u heterogenom krajobrazu nužno je točno određivanje elementa i njegove vremenske promjene u krajobrazu (Wu i dr., 2000). Definiranje elementa nije jednostavan zadatak (Blaschke i Hay, 2001). Primjerice, iz perspektive osoba zaduženih za upravljanje NOK element krajobraza predstavlja struktura sedrenih barijera ili šume itd. Međutim iz perspektive sedrotvornih organizama element ima u potpunosti drugačije granice.

Krajobraz se sastoji od hijerarhije mozaika elemenata u rasponu različitih mjerila (Burnett i Blaschke, 2003) koji predstavljaju konceptualne grupacije prostorne heterogenosti (Wu, 1999). Interakciju tih elemenata opisuju uzorci i procesi koji se mijenjaju s mjerilom istraživanja. Analiza dinamike elemenata omogućuje praćenje prostorne heterogenosti krajobraza. Wu i Loucks (1995) sugeriraju integraciju teorije hijerarhije i dinamike elemenata

(HPD[17]) i daju teorijski okvir za razbijanje ekoloških složenosti kroz hijerarhijsku strategiju mjerenja. Tek od 1980-ih interakcije između elemenata, procesa i mjerila počinju zauzimati središnje mjesto u istraživanjima (Wu i dr., 2000). U disertaciji je hijerarhija dinamika elemenata (HDP) usvojena kao osnovni teorijski okvir u rješavanju problema heterogenosti, mjerila, povezanosti i ravnoteže u krajobrazima. Naime, ključni problem u istraživanjima strukture krajobraza predstavlja odabir odgovarajućeg mjerila (Levin, 1992, Burnett i Blaschke, 2003). Određivanje mjerila je složen problem zato što su istraživanja u hidrologiji, meteorologiji, krajobraznoj ekologiji i drugim znanostima pokazala da različiti elementi i procesi imaju sklonost dominacije u jasno određenim prostorno-vremenskim okvirima. Stoga bi zapažanja izražena samo na jednoj razini mjerila mogla, u najboljem slučaju, uhvatiti samo one obrasce i procese koji se odnose na tu razinu proučavanja (Wu, 1999).

U literaturi ne postoji jedinstvena definicija mjerila (Schneider, 1994), već se ono može sagledavati kroz različite aspekte (Marceau i Hay, 1999). Konceptualno, mjerilo reprezentira *prozor percepcije* kroz koji se sagledava i doživljava krajobraz (Levin, 1992). Iz takvog prikaza proizlazi da se promjenom mjerila mijenjanju uzorci elemenata što utječe na razumijevanje dinamike krajobraza (Marceau i Hay, 1999). U kontekstu suvremene GST mjerilo reprezentira prostornu rezoluciju (Woodcoock i dr., 1988). Podatci prikupljeni takvom tehnologijom uključuju dvije sastavnice: zrno (eng. *grain*) i obuhvat (eng. *extent*). Zrno predstavlja prostornu rezoluciju, odnosno kvantitativno opisuje mogućnost razlučivanja detalja na modelu. Obuhvat odgovara rasponu svih identificiranih entiteta koji čine ukupnu površinu unutar jednog skeniranja ili snimanja (Allen i Hoeskstra, 1991). Neki autori (Levin 1992, Burnett i Blaschke, 2003) ističu da ključni problem u istraživanju strukture krajobraza nije odabir ispravnog (jedinstvenog) mjerila već nemogućnost uočavanja da su promjene u krajobrazu rezultat interakcije raznih uzoraka i procesa na različitim razinama mjerila. Istraživanja su pokazala da je jedna od najvažnijih i univerzalnih značajki prostorne heterogenosti širok raspon rezolucija (mjerila) u prostoru (Kolasa i Pickett 1991, Wu i dr. 2000). Naime, prostorna heterogenost je najosnovnija karakteristika svih krajobraza, a u njoj je sadržana multiplikativnost mjerila. Stoga primjena višerezolucijskih analiza predstavlja imperativ za razumijevanje strukture, funkcije i dinamike krajobraza (Wu i dr., 2000).

Višerezolucijski aspekt proučavanja krajobraza ima nekoliko važnih postavki:

a) krajobraz može biti hijerarhijski strukturiran;

[17] Hierarchical Patch Dynamics

b) razumijevanje promjena krajobraza zahtjeva višerezolucijsku analizu prostornih obrazaca i procesa jer su analize temeljene na uniformnom mjerilu često varljive i pogrešne;

c) modeli razvijeni na jednom mjerilu ne mogu se primjenjivati na drugim razinama zbog čega ih je potrebno povezati ili razviti višerezolucijski ili hijerarhijski strukturirani model proučavanja (Wu i dr. 2000).

U kvantificiranju višerezolucijskog krajobraza mora biti primijenjen višerezolucijski hijerarhijski pristup. U hijerarhijskim sustavima više razine obilježavaju veći i sporiji entiteti, s niskom frekvencijom promjene, dok niže razine manji i brži entiteti s visokom frekvencijom promjene (Slika 6). Odnos između njih je asimetričan (Wu i dr. 2000), više razine djeluju kao ograničenja, odnosno postavljaju granične uvjete nižim razinama (npr. protočna voda je potrebna za nastanak i oblikovanje sedre), dok niže razine pružaju inicijalne uvjete višim razinama (npr. specifične vrijednosti biohidrokemijskih parametara osiguravaju uvjete sedrenja) (Slika 6) (Wu, 1999). Teorija hijerarhije sugerira da prilikom proučavanja jednog fenomena (elementa) na određenoj hijerarhijskoj razini (*žarišna*, promatrana, razina 0), mehaničko razumijevanje procesa dolazi s niže razine (razina -1), a značaj tog fenomena se može otkriti na višoj razini (razina +1) (Wu, 1999). Dakle, dinamika promjene uzoraka specifičnih elemenata (npr. uzorci sedre) vezana je uz kolektivno ponašanje velikih skupova elemenata niže (npr. hidrokemijski parametri, mikroorganizmi) ili više (npr. gustoća vegetacije, morfologija tla) hijerarhijske razine te obrnuto. Stoga, ispitivanje takvih pojava zahtjeva proučavanje promjene uzoraka u različitim mjerilima (Levin, 1992). Dakle, ključ predviđanja i razumijevanja specifičnog elementa krajobraza NPK (npr. sedre) leži u objašnjavanju mehanizama koji se nalaze u pozadini promatranih uzoraka (npr. površinsko otjecanje, gustoća i tip vegetacije, biohidrokemijski parametri). Tipično ti mehanizmi djeluju unutar različitih hijerarhijskih razina od onih u kojima se nalaze promatrani elementi (Levin 1992). S obzirom na to da se nalaze na različitim hijerarhijskim razinama, analiza krajobraza, koji je po svojoj prirodi višerezolucijski (eng. *multiscale landscape structure*), kroz uniformiranu rezoluciju (mjerilo) nije moguća. Iz navedenoga se nameće potreba razvoja metodološkog okvira za potrebe praćenja prostorne heterogenosti takvog tipa krajobraza (Burnett i Blaschke, 2003). Takav tip metodologije podrazumijeva uključivanje prostornih podatka različitih mjerila (rezolucije) (Johnson i Patil, 1998, Marceau i Hay, 1999) koji reprezentiraju elemente različitih hijerarhijskih razina (Slika 6).

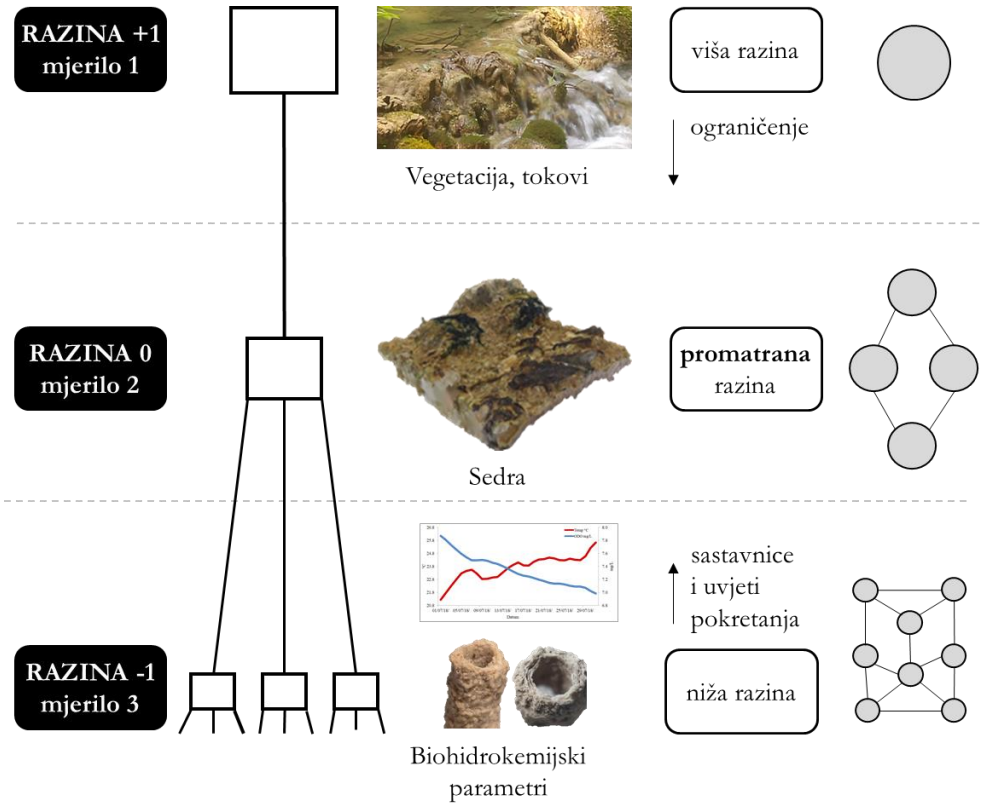

Slika 6. Shematski prikaz višerezolucijskog (hijerarhijskog) modeliranja na primjeru sedrenog krajobraza

Izvor: modificirano prema Wu, 1999.

U tom kontekstu višerezolucijsko modeliranje krajobraza predstavlja proces utvrđivanja uzročne povezanosti ili podudarnosti elementa različite hijerarhijske razine (Johnson i Patil, 1998) te pruža okvir za razumijevanje njihova „ponašanja“ prilikom narušavanja ravnoteže krajobraza ili promjene mjerila istraživanja (Marceau i Hay, 1999). Dakle, prikupljanjem, analizom i integracijom podataka različite rezolucije odstupa se od paradigme jedinstvenog mjerila, odnosno proučavanja elemenata na istim hijerarhijskim razinama te se omogućuje višerezolucijska analiza vertikalne povezanosti različitih razina (Slika 6) (Marceau i Hay, 1999). Primjerice u disertaciji, kako širenje, uklanjanje ili promjena elementa više hijerarhijske razine i lošije prostorne rezolucije (npr. selektivno uklanjanje vegetacije, izmjena smjerova površinskog otjecanja), utječe na element niže hijerarhijske razine (npr. polugodišnji prirast sedre na X, Y i Z lokaciji). Prema drugom aspektu, kako promjena biohidrokemijskih parametara (niža hijerarhijska razina) utječe na dinamiku formiranja sedre (viša hijerarhijska razina). Višerezolucijsko modeliranje krajobraza u ovom kontekstu se odnosi na implementaciju različitih tipova podataka (morfometrijskih, bioloških,

kemijskih itd.) specifičnih prostornih rezolucija (mjerila) u procesu izvođenja održivog modela upravljanja na prostoru sedrotvornih vodotokova.

2.2 Višekriterijske GIS analize (GIS-MCDA)

Donošenje odluka u zaštićenim područjima je složen proces koji se temelji na primjeni multidisciplinirani istraživanja koje uključuju podatke prirodnih, društvenih i političkih znanosti te etike (Huang i dr., 2011). Da bi prikupljeni podaci bili primjenjivi u procesu donošenja odluke oni moraju biti transformirani u informacije. Informacija predstavlja obrađene podatke koji su prikazani u obliku prihvatljivom za primatelja (donosioca odluke, interesne grupe), a imaju stvarnu vrijednost u procesu donošenja odluka (Malczewski, 1999). Donosioci odluka unutar zaštićenih prostora se u velikoj mjeri oslanjaju na eksperimentalne testove, matematičke modele te primjenu napredne tehnologije i pratećih alata u nadzoru i procjeni rizika (Huang i dr. 2011). Navedeno osobito vrijedi za složeni krški krajobraz (Ford i Wiliams, 2007) gdje se zahtijeva primjena, uvažavanje i razumijevanje širokog spektra često suprotstavljenih kriterija i alternativa.

Procesom donošenja odluka nastoji se odabrati jedinstveno rješenje za uočeni problem. Nažalost, jedinstveno rješenje postoji samo ako se razmatra jedan kriterij. U većini slučajeva takva odluka nije dobra. U analizu je potrebno uključiti nekoliko sukobljenih i često neusporedivih kriterija (Løken, 2007). Iz te spoznaje proizašlo je višekriterijsko donošenje odluka (MCDM[18]). MCDM označava generički pojam svih metoda koje pomažu u procesu donošenja odluka u slučajevima jednog i više sukobljenih kriterija (Løken, 2007). U novije vrijeme u upotrebu je ušao naziv višekriterijska analiza donošenja odluka (MCDA) (Løken, 2007). MCDA se može definirati kao skup formalnih pristupa koji nastoje eksplicitno uzeti u obzir ključne kriterije koji mogu pomoći u donošenju odluka (Greene i dr., 2011). Cilj MCDA je pomoći donositeljima odluka u organiziranju i sintetiziranju podataka kako bi mogli opravdati svoju konačnu odluku. MCDA pruža sustavnu metodologiju kombiniranja različitih tipova ulaznih podataka i stavova donosioca odluka u procesu rangiranja alternativa (Huang i dr. 2011). Može se definirati kao metoda procjene koja rangira varijante rješenja u odnosu na veći broj kriterija (Deluka-Tibljaš i dr., 2013).

MCDA tehnike se koriste u širokom spektru problematike upravljanja (Linkov i dr., 2006, Ananda i Herath, 2009): analizama energetske politike (Haimes i Hall, 1974), upravljanju šumama (Wolfslehner i dr., 2005), zaštiti prirodnih područja (Kiker i dr., 2005), upravljanju vodama (Keeney i dr., 1996), močvarnim područjima (Herath, 2004) te zaštićenim

[18] Multiple Criteria Decision Making

područjima (Prato, 2006, Khalili i Duecker, 2013). Između ostalog i u analizama gdje je potrebno uspostaviti ravnotežu između ponekad suprotnih zahtjeva (Linkov i dr., 2006). MCDA tehnike se često povezuju s paradigmom prilagodljivog (adaptivnog) upravljanja koje uvažava da donositelj odluka nema potpuno znanje o sustavu kojim upravlja (Slika 7). Kao posljedica toga smatra se da ne može biti odabrana jedna najbolja politika upravljanja, već treba postaviti skup različitih alternativa/kriterija koje je potrebno pratiti kako bi se stekle informacije o smjeru djelovanja (Linkov i dr., 2006).

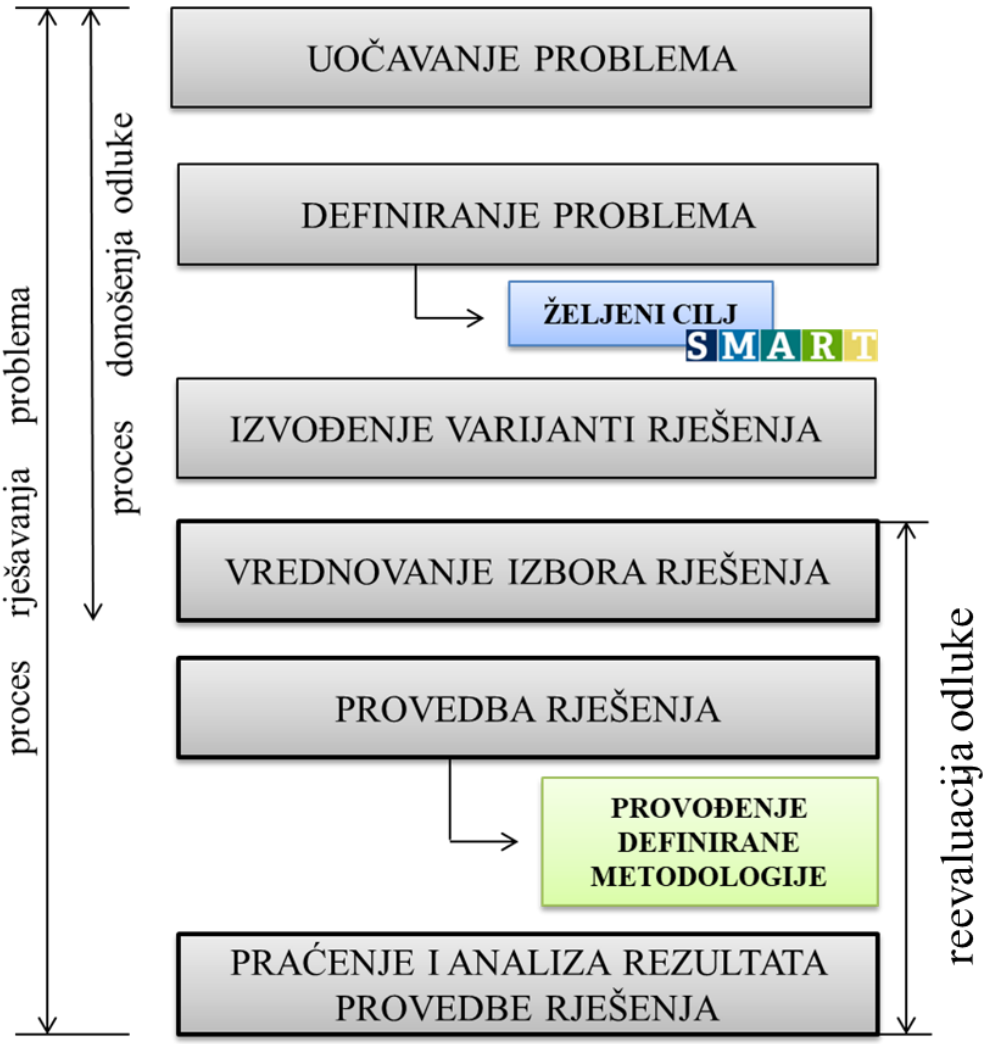

Slika 7. GIS-MCDA u paradigmi adaptivnog upravljanja

Izvor: prema Deluka-Tibljaš i dr., 2013.

Većina kriterija koji se koriste u upravljanju nekog prostora su podaci s prostornom komponentom. Stoga primjena suvremene GST postaje neizostavan aspekt u interpretaciji i vrednovanju kriterija te prioritizaciji odluka (Phua i Minowa, 2005). Konvencionalne višekriterijske analize donošenja odluka su uglavnom zanemarivale prostornu komponentu

kroz pretpostavljanje prostorne homogenosti unutar istraživanog područja. Takva pretpostavka u mnogim slučajevima odstupa od stvarnosti jer vrednovanje kriterija ovisi o specifičnom prostoru (Malczewski, 1999). Stoga donošenje primjerenih prostornih odluka sve više zahtjeva kombinaciju MCDA i GIS-a (Malczewski, 2006). Integracija MCDA i GIS-a poboljšava strukturu donošenja odluka kroz izvođenje prostornih analiza i vizualizaciju podataka (Uhde i dr., 2015) zbog čega predstavljaju značajno odstupanje od konvencionalnih tehnika (Malczewski, 1999). Integracija MDCA i GIS je bila ključna u razvoju paradigme potpore prostornom odlučivanju (Goodchild, 1993) u kojima je GST donositeljima odluka postala neizostavan alata (Malczewski, 2006). Na najosnovnijoj razini GIS-MCDA se može sagledati kao proces koji transformira i kombinira geografske podatke u procesu izvođenja informacija prilikom donošenja odluka (Malczewski, 2006).

Proces GIS-MCDA se sastoji od šest koraka (Malczewski i Rinner, 2015). Donošenje odgovarajućih odluka uključuje niz aktivnosti koji započinju s prepoznavanjem i definiranjem problema te postavljanjem cilja. Za početak se uočava problem koji se može riješiti primjenom različitih tehnoloških rješenja (Deluka-Tibljaš i dr., 2013). Problem se može definirati kao uočena razlika, odnosno *praznina* između željenog i postojećeg stanja nekog sustava (Malczewski, 1999) gdje:

1) pojedinac ili grupa na raspolaganju imaju različite alternative djelovanja;

2) izbor radnje može utjecati na uočenu razliku;

3) pojedinac ili grupa nije sigurna *a priori* koju alternativu odabrati (Janssen, 2012).

Rješavanje uočenog problema predstavlja konačni cilj istraživanja. Izvode se varijante njegova rješenje te se odabire najbolja odluka koja se može primijeniti kako bi se problem uklonio, a željeni cilj ostvario. Odluka označava odabrani izbor između više alternativa (npr. najbolji izbor testne plohe unutar šireg područja Skradinskog buka), dok je cilj ono čemu višekriterijska analiza prethodi. Željeni cilj mora biti SMART (Domazetović, 2018). Akronim SMART označava poželjne značajke zadanog cilja. (S) (eng. *specific, significant*) označava jasno i dobro definiran problem koji je kao takav značajan u proučavanom kontekstu. (M) (eng. *measurable*) predstavlja mogućnost kvantitativnog praćenja procesa ostvarenja tog cilja. (A) *(*eng. *agreed upon, attainable, achievable, acceptable)* se uglavnom odnosi na prihvatljivost i ostvarivost rješavanja problema. (R) (eng. *realistic, relevant*) predstavlja (ne)realnost i relevantnost rješavanja definiranog problema. (T) (eng. *time-based, time-bound, timely, tangible, trackable*) se odnosi na vremensku komponentu cilja (URL 4). Nakon što se problem definira i cilj postavi, potrebno je odrediti (mjerljive) kriterije u procesu njegova ostvarivanja.

Kriteriji označavaju skup zahtjeva koji se primjenjuju kao osnova za odlučivanje. Postoje dvije vrste kriterija: čimbenici i ograničenja. Čimbenici predstavljaju parametre koji pojačavaju ili smanjuju pogodnost nekog kriterija za razmatranu alternativu. Pogodnost je značajka poželjnosti atributa ili zahtjeva za specifičnu namjenu. Ograničenja reprezentiraju isključujuće elemente unutar neke razmatrane alternative. Postupak izvođenja višekriterijskih analiza uključuje tri glavna problema: skaliranje vrijednosti (standardizacija), određivanje pondera i okupljanje kriterija (Malczewski i Rinner, 2015). Nakon definiranja, kriterije je potrebno standardizirati (3). Standardizacija se odnosi na postavljanje vrijednosti kriterija na istu skalu kako bi bilo moguće njihovo međusobno uspoređivanje. Nakon standardizacije određuju se težinski koeficijenti (ponderi) za svaki kriterij (4). Postoji nekoliko različitih metoda određivanja pondera (Malczewski i Rinner, 2015). Potom se standardizirani kriteriji sa zadanim ponderima okupljaju u model (5) izveden prema preferencijama interesne grupe ili donositelja odluka. Završni korak je provjera i analiza rezultata (6) kojom se procjenjuje pouzdanost rješenja, odnosno ostvareni cilj. Nakon odabira najboljeg rješenja stupa faza nadzora rezultata njezine provedbe. Odabrano rješenje se vrednuje primjenom različitih kvantitativnih i kvalitativnih mjera (Deluka-Tibljaš i dr., 2013). Takav proces je iterativan što znači da se omogućuje integracija novih spoznaja u proces rješavanja uočenih problema.

Postoje brojni pristupi koji spadaju pod MCDA, a razlikuju se prema strukturi ulaznih podataka, primjeni algoritama njihova vrednovanja te načinu interpretacije formalnih rezultata u kontekstu donošenja odluka (Pohekar i Ramachandran, 2004, Huang i dr. 2011). Općenito postoje dvije vrste odlučivanja: višeatributno- (MADM[19]) i višeciljno (MODM[20]) (Deluka-Tibljaš i dr., 2013). MADM procjenjuje mogući skup alternativa i odabire najbolje rješenje na temelju bodova. MODM odabire najbolje rješenja na temelju niza proturječnih ciljeva (Nordström i dr., 2013). U istraživanju su primijenjene obje vrste višekriterijskog odlučivanja.

MODM proces se sastoji od 5 koraka. Započinje kada interesna skupina uoči potrebu mijenjanja sustava kojim se upravlja (1 - eng. *initiation step*) (Chankong i Haimes, 2008). U kontekstu istraživanja navedeni korak se odnosi na uočavanje problema izmjene smjera vodotokova i prestanka procesa sedrenja od strane Uprave NPK. Kontekst problema se jasno definira te se daju generalne izjave i ciljevi. Potom se kreće u korak formulacije problema (2 - eng. *problem-formulating step*) koji uključuje transformaciju općeg cilja u operativni skup specifičnih ciljeva te definiranje svih elemenata unutar sustava (Chankong i Haimes, 2008).

[19] Multi-Attribute Decision Making
[20] Multi-Objective Decision Making

Opći cilj u istraživanju se odnosi na vraćanje sustava u izvorno stanje, kroz postavljene specifične ciljeve: selektivno uklanjanje vegetacije, reaktivaciju ugaslih vodotokova te ponovno postizanje održivih uvjeta sedrenja. Nakon što se proučavani sustav i set ciljeva definira izgrađuju se odgovarajući modeli (3 - eng. *system-modeling setup*). Model podrazumijeva kolekciju ključnih varijabli (kriterija) te njihov logični odnos koji olakšava sveobuhvatnu analizu relevantnih aspekata sustava (Chankong i Haimes, 2008). U istraživanju su analizirane sve grupe kriterija koji mogu utjecati na postavljeni set ciljeva. Navedeni korak se u disertaciji odnosi na definiranje metodološkog okvira kojim će se nastojati postići zadani cilj. Potom se kriteriji specificiraju prema vrijednostima koje se žele ostvariti (npr. očekivani prirast sedre (mm a^{-1}), količina organske tvari u vodi, količina makrozoobentosa, pH vrijednost vode, volumen uklonjene vegetacije itd). Vrijednosti tih kriterija se mjere kako bi se procijenio stupanj postizanja određenih ciljeva definiranih u prethodnom koraku. U standardnom MODM procesu odabire se alternativa koja ima najveći rank te se kao takva implementira. Ako se izlazni rezultati pokažu kao nezadovoljavajući u odnosu na postavljeni cilj informacije prikupljene njome se iskorištavaju u prvom koraku formulacije problema. Tad se radi o procesu zatvorene petlje (*closed loop*) (Chankong i Haimes, 2008). U disertaciji se korak izgrađivanja modela odnosi na odabir, odnosno izgradnju metodološkog okvira koji je potom praćen na temelju povratnih vrijednosti mjerenih kriterija te unaprjeđivan uvažavajući prikupljene informacije. Dakle, sintagma *razvoja višekriterijskog modela* u naslovu disertacije odnosi se na proces izvođenja smjernica upravljačkog konteksta iz predloženog metodološkog okvira primjenjujući tematski grupirane i analizirane kriterije (hidrološki, morfometrijski, biološki, kemijski, klimatološki, ekološki) u različitim mjerilima. Ovakav pristup omogućit će donositeljima odluka, na temelju skupa željenih preferencija, prioritet u očuvanju sedrenja (Phua i Minowa, 2005). Ako je cilj upravljanja očuvanje sedre ili postizanje održivih uvjeta sedrenja, onda se upravljanje sedrotovornim vodotocima može definirati kao skup aktivnosti koji s odabranim kriterijima vrednuju i prate definirani element krajobraza (Phua i Minowa, 2005).

2.3 Upravljanje zaštićenim područjima u RH

Zaštićena područja su prostori iznimnih prirodnih vrijednosti u kojima se putem upravljačkih mehanizama nastoje uspostaviti odnosi koji bi osigurali trajnu ravnotežu između očuvanja bioraznolikosti, racionalne upotrebe prostora te zadovoljenja potreba zajednice u širem okviru (Martinić, 2017). U svijetu postoji više od 238 000 zaštićenih područja različitih veličina i izazova upravljanja koji čine oko 15 % Zemljine kopnene površine (UNEP-WCMC,

IUCN, NGS 2018). Brzim gubitkom bioraznolikosti i modifikacijom izvornih ekosustava nameće se potreba sve hitnije zaštite i obnove zaštićenih područja (Phillips i WCU, 2002, Dudley, 2008). Ekosustav je dinamičan kompleks biljaka, životinja i mikroorganizama te njihovog neživog abiotičkog okruženja koje djeluje kao funkcionalna jedinica (HAOP, 2015).

Upravljanje zaštićenim područjima javlja se nakon spoznaje da se očuvanje nekog prostora ne može postići isključivo njegovim proglašavanjem zaštićenim, već da je neophodno utjecati i oblikovati aktivnosti i procese koji se unutar njega odvijaju (Zelić, 2017). Upravljanje zaštićenim područjima u RH pretpostavlja provođenje niza mjera i aktivnosti koji su usmjereni prema dugoročnom očuvanju prirodnih i drugih vrijednosti. Provodi se u okviru odgovornosti koje su dodijeljene *Zakonom o zaštiti prirode* (NN 80/2013 i 15/2018). Iako je to temeljni pravni propis koji regulira rad Ustanova koje upravljaju zaštićenim prostorima, potrebno je istaknuti prostorne planove kao vrlo važne zakonske dokumente koji predstavljaju *najprikladnije tehničko sredstvo zaštite i unaprjeđenja pojedinog nacionalnog parka* (Bulat, 2012, 18). Zaštita i očuvanjem temeljnih fenomena zaštićenih područja trebala bi biti ključan element u upravljanju tim prostorima. Zakonom o zaštiti prirode definiraju se kategorije zaštićenih prostora, nadležne ustanove te osnovni dokumenti za upravljanje zaštićenim prostorom (Bulat, 2011).

Najveći dio zaštićenih područja u RH spada u dvije kategorije: Nacionalni park (8) i Park prirode (11) (Tablica 1). Oni zajedno čine preko 90% površine zaštićenih prostora u RH, a proglašava ih Hrvatski sabor. Njima se upravlja na temelju posebnih prostornih planova donesenih od strane Hrvatskog sabora (Bočić i dr., 2007, Bulat, 2012).

Tablica 1. Kategorije zaštićenih područja u RH

KATEGORIJA	NAMJENA	IUCN KATEGORIJA	RAZINA UPRAVLJANJA
Strogi rezervat	znanstveno istraživanje, praćenje stanja prirode, obrazovanje	I	županijska
Nacionalni park (NP)	znanstvena, kulturna, odgojno-obrazovna i rekreativna namjena	II	državna
Posebni rezervat	zaštitia biološke raznolikosti s naglaskom na neku sastavnicu, znanstvena istraživanja, moguće posjećivanje	I/IV	županijska
Park prirode (PP)	zaštita biološke i krajobrazne raznolikosti, odgojno-obrazovna, turističko-rekreacijska namjena	V/VI	državna
Regionalni park	zaštita krajobrazne raznolikosti, održivi razvitak, turizam	V/VI	županijska
Spomenik prirode	zaštita prostorno ograničenog lokaliteta, znanstvena, estetska ili odgojno-obrazovna namjena	III	županijska
Značajni krajobraz	zaštita krajobrazne i biološke raznolikosti, održivi razvitak, turizam, rekreacija	V	županijska
Park-šuma	turizam i rekreacija, zaštita krajobrazne vrijednosti	V	županijska
Spomenik parkovne arhitekture	zaštita prirodne i kulturne baštine i krajobrazne raznolikosti, turizam i rekreacija i edukacija	nema IUCN kategorije	županijska

Izvor: prema Bulat, 2012

NP su zaštićeni prostori u kojima postoje jedan ili više neznatno izmijenjenih ekosustava (Liović i Županić, 2005). Prema tipologiji koja se primijenjuje u RH Nacionalni parkovi spadaju u kombinirani tip koji naginje prema američkom modelu (dozvoljeno turističko posjećivanje, bez značajnijih gospodarskih zahvata) (Vatavuk, 2018). Uspješno upravljanje NP podrazumijeva održivo korištenje prirodnih dobara te osiguranje neometanog odvijanja prirodnih procesa. Međutim, upravljanje ekosustavima tih područja je velik izazov iz nekoliko razloga. Prvo, NP su izloženi brojnim unutarnjim i vanjskim prijetnjama koje se s vremenom povećavaju. Drugo, upravitelji ne mogu točno odrediti i ocijeniti stanje sustava te predvidjeti ishode upravljanja zbog neizvjesnosti predviđanja utjecaja specifičnih provedbenih mjera (teško modeliranje kompleksnih sustava) (Prato, 2006).

Upravo zaštićena područja i prirodni okoliš predstavljaju jednu od osnova gospodarskog razvoja RH, osobito ako se uzme u obzir trend rasta turističke djelatnosti u cjelokupnoj gospodarskoj strukturi (Nekić i Krajnović, 2015). Naime, veliki dio zaštićenih površina RH nalazi se na atraktivnim, ali osjetljivim krškim područjima. Jedan od njih je NPK u čiji su upravljački koncept uključeni turizam i rekreacija, ali samo do onog stupanja koji neće ugroziti ravnotežu njegova ekosustava. Sa svojim pratećim funkcijama (zaštitna, obrazovna, znanstvena, turističko-rekreativna) Park je nužno povezan s okolnim prostorom (Radeljak i Pejnović, 2009). Spada u II. kategoriju zaštićenih područja prema IUCN klasifikaciji koja

uključuje: *velika prirodna ili gotovo prirodna područja izdvojena sa svrhom zaštite cjelokupnih ekosustava, procesa koji se u njima odvijaju i vrsta koje oni podupiru, tako da ona istovremeno pružaju osnovu za okolišno i kulturalno prihvatljive duhovne, znanstvene, edukacijske, rekreativne i posjetiteljske aktivnosti* (URL 6). Manja vrijednost kategorije pretpostavlja očuvanje prirode sličnije njenom izvornom obliku. Primarni cilj II. kategorije (*zaštita prirodne biološke raznolikosti s njegovom temeljnom ekološkom strukturom i zaštite procesa u okolišu s promocijom obrazovanja i rekreacije*) mora biti primjenjiv na najmanje 75% površine zaštićenog područja. Međutim, zbog ekonomske komponente ovih područja (obrazovanje, rekreacija, turizam) IUCN prepoznaje te potrebe te navodi da se s 25% površine unutar zaštićenog područja može upravljati i u druge svrhe, ali pod uvjetom da su one kompatibilne s primarnim ciljem zaštite (Dudley, 2008).

2.3.1 Upravljanje Nacionalnim parkom „Krka“ (NPK)

Upravljanje zaštićenim područjima nije jednostavan proces. Uvažavajući složenost biotičkih i abiotičkih čimbenika, koja u pravilu obilježava te ekosustave, nije moguće sa sigurnošću tvrditi kakve će posljedice planirana aktivnost ili mjera upravljanja ostaviti na ekosustav, odnosno hoće li se željeni cilj ostvariti (UNDEP, 2018). Stoga je upravljanje ciklični proces koji uključuje nekoliko faza (Zelić, 2017, Vurnek i dr., 2018):

1) procjenu i vrednovanje stanja područja;
2) definiranje ciljeva upravljanja;
3) planiranje provedbenih aktivnosti;
4) provedba definiranih aktivnosti;
5) praćenje provedbe putem sustava indikatora;
6) procjena učinkovitosti provedbenih aktivnosti;
7) prilagodba provedbenih aktivnosti (ako se ukaže potreba);

Procjena stanja uključuje analizu svih podataka koji mogu poslužiti kao osnova za argumentaciju i definiranje ciljeva upravljanja. Cilj upravljanja jasno mora naznačiti što se želi postići s upravljanjem, dok su aktivnosti mjere koje je potrebno provesti kako bi se ostvario zadani cilj (Zelić, 2017). Aktivnosti moraju imati svoju svrhu i smjer (Vurnek i dr., 2018). Praćenje provedbenih aktivnosti može uključivati dvije različite stavke. Praćenje ostvarenih mjera (npr. koliko je daleko plan odmakao, u kojoj se fazi plan nalazi) te praćenje učinkovitosti tih mjera u kontekstu ostvarenog cilja (Zelić, 2017).

NPK upravlja Javna ustanova, koju čine Upravno vijeće i ravnatelj/ica, a nalazi pod nadležnošću *Ministarstva zaštite okoliša i energetike* (Vatavuk, 2018). Zakon o ustanovama regulira rad upravljačke ustanove. Njihov rad je javan, a osnova je stalno vršenje djelatnosti zaštite. Djelatnost Ustanove je *zaštita, održavanje i promicanje nacionalnog parka u cilju zaštite i očuvanja izvornosti prirode, osiguravanja neometanog odvijanja prirodnih procesa i održivog korištenja prirodnih dobara, nadziranje provođenja uvjeta i mjera zaštite prirode na području kojim upravljaju te sudjelovanje u prikupljanju podataka u svrhu praćenja stanja očuvanosti prirode* (Bulat, 2011, URL 15).

Upravljanje se provodi na temelju planova upravljanja koji se donose za razdoblja od deset godina, uz mogućnost izmjene i dopune nakon pet. Njime su propisani ciljevi upravljanja, aktivnosti za postizanje ciljeva i pokazatelji učinkovitosti upravljanja (indikatori) (URL 15). Planovi upravljanja su dokumenti koji identificiraju ključne značajke i vrijednosti zaštićenog područja, jasno utvrđuju ciljeve upravljanja i radnje koje je potrebno provesti. Moraju biti dovoljno fleksibilni kako bi se moglo intervenirati u slučaju pojave nepredviđenih pojava tijekom njegova provođenja Proces izrade plana upravljanja ovisi o: ciljevima zaštićenog područja, rizicima i prijetnjama tim ciljevima, broju uključenih sudionika itd. (Thomas i Middleton, 2003).

Važnu ulogu obavlja Stručni voditelj koji vodi stručni rad Ustanove (URL 15). On nadzire i provodi izvršenje pojedinih stručnih poslova (Bulat, 2011). Na temelju donesenog Plana između ostalog: *predlaže i koordinira istraživačke aktivnosti*, *prati i proučava stanje prirode, predlaže i poduzima mjere zaštite*, *organizira i razrađuje prijedloge za aktualne znanstveno istraživačke projekte itd.* (URL 15).

Bulat (2012) navodi da prilikom primjene zakonskih rješenja postoji mnogo problema, navodeći primjer NPK gdje boravi širok spektar različitih gospodarskih subjekata (HEP, Hrvatske vode, Hrvatske šume, Vodovod i odvodnja itd.) koji zaobilaze zakon o *Zaštiti prirode* koji bi trebao regulirati njihovo ponašanje.

2.3.2 Turizam u NPK u kontekstu upravljačkih mehanizama

Krajobraz zaštićenih mediteranskih područja obilježavaju mnoge specifične pedološke, topografske, klimatološke i hidrološke osobitosti. Izvorna prirodna sredina, sa što složenijom geomorfološkom i ekosistemskom strukturom, postaje sve atraktivnija za turističke posjete (Jovičić i Ivanović, 2004). Obuhvaćajući velike i uglavnom nenaseljene prostorne cjeline, s visokim stupnjem očuvanosti prirodne sredine, NP spadaju među najznačajnije turističke vrijednosti. Međutim, turizam je po svojoj prirodi dinamična i disperzivna aktivnost, sklona

stihiji i degradiranju prirodne sredine, osobito ako nije dobro programski utemeljena i kontrolirana prikladnim planskim i organizacijskim mjerama (Jovičić i Ivanović, 2004). Ipak, odnos turizma i zaštićenog područja se najbolje može opisati kroz sintagmu *zaštićena područja trebaju turizam - turizam treba zaštićena područja*.

Uz NP Plitvička jezera, NP Krka je najposjećenije i turistički najviše vrednovano zaštićeno područje u RH. To je posljedica širokog raspona privlačnih čimbenika koji su vezani za temeljni fenomen Parka (sedrene barijere i slapove) uz kulturno-povijesne spomenike te vrlo povoljni turističko-geografski položaj s obzirom na blizinu snažnih emitivnih područja (Radeljak i Pejnović, 2008, Vatavuk, 2018).

NPK je 1988. godine bilježio 385 837 posjetitelja. Snažan impuls rastu dogodio se zbog dovršenja dionice autoceste A1 do Splita, s čvorovima za Skradin i Šibenik. Broj posjetitelja se od 1996. do 2007. godine povećao za oko sedam puta (Radeljak i Pejnović, 2008). Turisti od kojih je 90 % stranaca, Park posjećuju uglavnom kroz organizirane izlete brodovima i autobusima (URL 14). Od 1988. do 2017. godine broj posjetitelja je porastao za oko 3,3 puta (Tablica 2).

Tablica 2. Broj posjetitelja u nacionalnim parkovima RH

Nacionalni park	Površina (ha)	Nadmorska visina (m)	Broj posjetitelja		
			2015	2016	2017
Brijuni	2700	0-55	160 010	181 560	169 299
Krka	**14200**	**0-253**	**951 106**	**1 071 561**	**1 284 723**
Kornati	30200	0-236	115 000	165 200	229 061
Mljet	3100	0-391	112 156	126 699	140 329
Paklenica	6617	50 - 1571	119 686	127 848	140 561
Plitvička jezera	19479	380 - 1280	1 357 304	1 429 228	1 720 331
Risnjak	3014	680 - 1528	12 715	14 346	16 575
Sjeverni Velebit	10900	518 - 1676	16 471	16 913	22 919

Izvor: prema Palčić, 2016 i Gulić, 2017

Turističke posjete u Parku imaju izražen sezonalan karakter s najvećim broj posjetitelja tijekom ljeta. Najposjećeniji prostori su zona SB, otočić Visovac i RS. Slapovi Miljacka, Brljan, Bilušića buk, Rošnjak i Manojlovac u turističkom kontekstu nisu primjereno iskorišteni (Vatavuk, 2018). Velika koncentracija i usredotočenost turista na samo neke dijelove Parka dovodi do turističke saturacije što može poremetiti ravnotežu između ekološkog, ekonomskog i socijalnog aspekta razvoja. Naime, ugrožavanjem prirodne osnove, odnosno temeljnog fenomena, smanjuje se i kvaliteta turističkog doživljaja što može imati izravne implikacije na održivost i opstanak Parka (Zelić, 2017).

Negativan utjecaj turizma na ekosustav postaje ekstreman ako dođe do nepoštivanja prihvatnog kapaciteta nekog prostora. Stoga koncept *održivosti* postaje glavna vodilja razvoja. Međutim, održivost same turističke industrije ovisi o očuvanju prirodnih i kulturnih atrakcija (McMinn, 1997). Kvaliteta zaštićenog prostora i temeljnog fenomena ostaje ključna za osiguranje konkurentnosti turističke destinacije (Gu i dr., 2013). Stoga održivost prirodnih resursa mora biti prepoznata kao ključni princip vođenja u upravljanju (Newsome i dr., 2012). Održivi turizam ne znači ostvarivanje brzih i kratkoročnih, prije svega, ekonomskih rezultata, nego podrazumijeva efekte koji su s ekonomskog, sociološkog, ekološkog i etičkog stajališta zadovoljavajući u dužem periodu (dugoročni ciljevi) (Jovičić i Ivanović, 2004).

2.3.2 Prilagodljivo upravljanje u NPK

Ciljevi zaštićenog prostora ispunjavaju se isključivo uspješnim upravljanjem. Ono podrazumijeva ostvarivanje ključnih ciljeva očuvanja prirode te društvenog razvitka u cjelini (Marguš i Martinić, 2017). Upravljanje NPK provodi se tako da se ostvaruju ciljevi postavljeni Strategijom i akcijskim planovima zaštite prirode RH, Konvencijom o biološkoj raznolikosti (CBD) i *Achii* ciljevima očuvanja prirode (Šakić, 2017). Plan upravljanja sadrži smjernice razvoja, načine provođenja, upotrebe i upravljanja zaštićenim prostorom, smjernice za očuvanje prirodnih vrijednosti uz uvažavanje potreba lokalnog stanovništva (Bulat, 2012). Ostvarivanje uspješnog upravljanja predstavlja veliki izazov jer uključuje širok broj sastavnica: zaštitu okoliša, očuvanje baštine, zadovoljstvo posjetitelja itd. (Jaafari i dr., 2014, Marguš i Martinić, 2017).

Plan upravljanja je strateški dokument koji propisuje svrhu zaštićenog prostora, mjere i aktivnosti, odnosno strategije koje je potrebno provoditi da bi se ta svrha ostvarila (Vatavuk, 2018). Posljednji Plan upravljanja NPK donesen je u razdoblju od 2006. do 2010. godine, a predviđen je za razdoblje od 2010. do 2020. godine, s revizijom nakon pet godina (Bulat, 2011). Kao jedan od glavnih ciljeva upravljanja navedena je *zaštita i očuvanje vodenih ekosustava.* Za ostvarenje navedenog cilja potrebno je provoditi sljedeće akcijske planove (Bulat, 2011):

a) *praćenje fizikalno-kemijskih svojstava voda;*
b) *praćenje rada hidroelektrane i hidrološkog režima;*
c) *izrada programa selektivne sječe makrovegetacije na sedrenim barijerama,*
d) *istraživanje biodinamičkih procesa sedrenja;*
e) *očuvanje lokvi*.

Indikatori kojima bi se pratio napredak prema ostvarenom cilju su (Bulat, 2011):

i. *dnevni i godišnji izvještaji mjerenja;*
ii. *provedena sječa makrovegetacije;*
iii. *utvrđena dinamika kolonizacije perifitonskih zajednica;*
iv. *utvrđen intenzitet taloženja sedre i procijenjeno organsko opterećenje vode;*
v. *provedene mjere preventivne zaštite sedrenih barijera;*
vi. *očišćenje starih lokvi i pohrana podataka u GIS-u.*

Akcijski planovi su integralni, provedbeni dijelovi Plana upravljanja, a predstavljaju jasne upravljačke dokumente koji su proizašli iz definiranih strateških ciljeva i mjera upravljanja Parkom. U posljednjem Planu utvrđeno je 58 kratkoročnih i dugoročnih akcijskih planova koji Ustanova želi provesti u razdoblju od 2011. do 2020 godine. Oni sadrže definirane ciljeve, glavne aktivnosti, nositelje, vremenski okvir izvođenja i potrebna sredstva za izvršenje (Bulat, 2011).

Iz plana su izdvojeni **akcijski plan 7** (*program selektivne sječe makrovegetacije na slapovima*) i **8** (*istraživanje sedrotvoraca i biodinamičkih procesa sedrenja*) za koje je izrađena i predložena metodologija u sklopu ove disertacije i provedenog projekta. U tablici 3. navedene su glavne postavke navedenih planova:

Tablica 3. Izdvojeni akcijski planovi iz Plana upravljanja NPK

AKCIJSKI PLAN 7	**PROGRAM SELEKTIVNE SJEČE MAKROVEGETACIJE NA SLAPOVIMA**
Ciljevi	- Spriječiti **sukcesiju makrovegetacije** - Očuvati uvjete za **prirodni razvoj sedrotvoraca**
Glavne aktivnosti	- Izraditi program **selektivne sječe** makrovegetacije - Provesti selektivnu sječu makrovegetacije - Pratiti **rast sedre** na očišćenim područjima
Nositelji	JU NPK - SZ, ODK Suradnici: znanstvene i stručne institucije
Vremenski okvir	2012 - 2015
Proračun (kn)	700 000

AKCIJSKI PLAN 8	**ISTRAŽIVANJE SEDROTVORACA I BIODINAMIČKIH PROCESA SEDRENJA**
Ciljevi	- Očuvati uvjete i biodinamičke procese za **taloženje sedre**

Glavne aktivnosti	- Istražiti **mikro** i **makro floru** na sedrenim barijerama - Utvrditi **dinamiku kolonizacije** perifitonskih zajednica - Utvrditi vezu između sezonske strukture perifitonskih zajednica i **intenziteta taloženja - sedre** na umjetnim i prirodnim podlogama - Utvrditi utjecaj **hidrodinamike** na $CaCO_3$ precipitaciju i formiranje sedrenih barijera - Istražiti i procijeniti **organsko opterećenje vode** i koncentracije ekotoksičnih metala u vodi i sedimentu - Izraditi naputke za preventivne mjere zaštite sedrenih barijera
Nositelji	JU NPK - SZ, ODK Suradnici: znanstvene i stručne institucije
Vremenski okvir	2012 - 2016
Proračun (kn)	1 500 000

Izvor: Plan upravljanja NPK

U upravljanju zaštićenih područja važna su načela prilagodljivosti i participativnosti upravljanja (UNDEP, 2018). Uprava NPK vodi se načelima prilagodljivog upravljanja (Martinić i Marguš, 2017). Naime, upravljanje je proces koji mora biti podložan različitim promjenama uslijed stjecanja novih saznanja ili promjena uvjeta okoliša kojim se upravlja (Bulat, 2011). Zbog toga su nužne revizije Plana koje se događaju nakon pete godine njegove implementacije. Glavna svrha revizije je prilagođavanje strateških ciljeva Parka novonastalim okolnostima (Bulat, 2011).

Takav koncept upravljanja se naziva prilagodljivo upravljanje. Prilagodljivo ili adaptivno upravljanje (eng. *adaptive management*) predstavlja kružni, dinamičan proces fleksibilnog donošenja odluka koje se može prilagoditi neizvjesnostima ishoda (Williams, 2011, Vatavuk, 2018). Njegova primjena je neophodna zbog nekoliko razloga: širokog spektra varijabli i međusobnih interakcija, nedostatka podataka, složene i promjenjive prirode ekosustava te promjenjivosti prirodnih i društvenih čimbenika (Vatavuk, 2018).

Vrlo je teško pretpostaviti da će planirana aktivnost dovesti do ostvarenja željenog cilja. Ako do toga ne dođe, potrebno je definiranu aktivnost prilagoditi novonastaloj situaciji. Ostvarenje cilja, odnosno učinaka provedene aktivnosti može se pratiti skupom različitih indikatora (kvantitativni i kvalitativni). Takav oblik djelovanja u najjednostavnijem obliku predstavlja prilagodljivo upravljanje (Vatavuk, 2018). Stoga, pažljivo praćenje aktivnosti i ishoda u prilagodljivom upravljanju unaprjeđuje znanstveno razumijevanje i pomaže prilikom prilagodbe politika i djelovanja kroz iterativni proces učenja (Williams, 2011). Iterativna priroda procesa omogućuje sustavan i kontinuiran napredak temeljen na rezultatima i

iskustvima postojeće prakse. Kontinuiranom prilagodbom osigurava se približavanje konačnim ciljevima upravljanja (UNDEP, 2018). Upravo sustav prilagodljivog upravljanja koji se primjenjuje kao model upravljanja u većini zaštićenih područja zahtjeva generiranje skupova podataka krupnog mjerila za potrebe izvođenja ciljanih modela i zaključaka o funkcioniranju ekosustava ili specifičnog elementa unutar njih.

Uspješno upravljanje zaštićenim područjima treba biti provođeno na holistički način (Thomas i Middleton, 2003, Badalamenti i dr., 2000). Mora se temeljiti na interdisciplinarnom pristupu u kojem će se koristiti metode iz različitih znanstvenih područja (geografija, biologija, kemija, geologija, ICT itd.). Korištenje interdisciplinarnog pristupa podrazumijeva okupljanje stručnjaka i zainteresiranih strana u procesu upravljanja zaštićenim područjem. Tim pristupom uočeni problem se ne "rastavlja" na pojedine elemente već se tretira kao cjelina uvažavajući različite discipline koje zajedno traže rješenje. To rezultira integracijom disciplina te sintezom znanja i tehnologija što u konačnici generira potpunije i djelotvornije rješenje (Kelleher i Kenchington, 1991).

2.3.2.1 Vizija održivog upravljanja NPK

Glavni izazov u zaštićenim područjima je očuvanje biološke raznolikosti uz istovremeno osiguravanje temelja za društveni i gospodarski razvoj stanovništva (URL 27). Vizija NPK usmjerena je prema pravcima održivog razvoja uz aktivno sudjelovanje svih sudionika. Prema *Planu upravljanja* navodi se da sve aktivnosti i smjernice upravljanja moraju biti usuglašene s opstojnošću Parka kroz prizmu održivog razvoja (Bulat, 2010).

Održivi razvoj podrazumijeva kompromisno rješenje u kojem se uz gospodarski rast i razvoj, uvažava ekološka održivost (uvažavanje prihvatnog kapaciteta i opstanka temeljnog fenomena) i društveni napretak nekog područja (Radeljak i Pejnović, 2008). Podrazumijeva uspostavu ravnoteže između svih razina prostornog razvoja. Glavni naglasak *Plana upravljanja* je očuvanje temeljnog fenomena, odnosno današnje hidrogeološke i pejsažne slike Parka (Bulat, 2011). Stoga je dugoročno održivo upravljanje NPK određeno kroz šest temeljnih ciljeva (Bulat, 2010):

1) očuvanje kakvoće vode i taloženja sedre;
2) očuvanje biološke raznolikosti;
3) očuvanje kulturnopovijesne baštine;
4) održivi razvoj posjećivanja (povratak prirodi);
5) obrazovanje domicilnog stanovništva;

6) jačanje suradnje s lokalnom zajednicom u održivom gospodarenju prirodnim dobrima.

2.3.3 Čimbenici pritiska na NPK

Očuvani ekosustavi zaštićenih područja pružaju osnovu za razumijevanje prirodne ravnoteže (Liović i Županić, 2005). Upravo su slatkovodna područja Mediterana prepoznata kao *hot spot* područja bioraznolikosti od globalne važnosti na koja djeluje širok spektar čimbenika pritiska (Darwell i dr., 2014). Mediteranski tipovi ekosustava predstavljaju jedan od najrjeđih terestričkih bioma[21]. Iako je mediteranski biom globalno prepoznat kao prioritet u globalnom očuvanju (Myers i dr., 2000, Olson i Dinerstein, 2002) manje od 5% njegove površine nalazi se unutar formalno zaštićenog područja namijenjenog očuvanju biološke raznolikosti (IUCN klase I-IV) (Cox i Underwood, 2011).

Slatkovodni sustavi su prepoznati kao najugroženiji prostori u svijetu. Naime, obilježava ih velika bioraznolikost s mnogim endemičnim vrstama (Barrios i dr., 2014). Jedan od najvećih prijetnji slatkovodnim sustavima je gubitak ili degradacija staništa u kontekstu izmjene postojećih uvjeta (Collen i dr., 2014, Garcia-Moreno i dr., 2014). Glavni čimbenici koji utječu na povećani pritisak slatkovodnih ekosustava su: preveliko crpljenje vode (hidroenergetske potrebe), širenje invazivnih vrsta vegetacije, pojačana eutrofikacija, degradacija kvalitete vode te antropogeno inducirano onečišćenje (Barrios i dr., 2014). Upravo su krški sustavi, koji čine površinski udio u RH veći od 45%, iznimno osjetljivi i podložni različitim vrstama vanjskih poremećaja (Ford i Williams, 2007). Prema EU Direktivi o staništima (*EU Habitats Directive*) okamenjeni izvori s formacijom sedre (eng. *petrifying springs with tufa formation)* se navode kao staništa čije se čuvanje smatra prioritetom i za koja posebna područja očuvanja moraju biti određena (Heery, 2007). Nadalje, u dokumentu IUCN-a *Freshwater Key Biodiversity Areas in the Mediterranean Basin Hotspot* porječje rijeke Krke navedeno je kao prostor širokog raspona slatkovodnih staništa velike bioraznolikosti koji uključuje rijeku, izvore, jezera, slapove, sedru i podzemne vode (Barrios i dr., 2014). Rijeka Krka i njezin okolni prostor prepoznat je kao osjetljiv i dinamičan hidrološki sustav podložan različitim vrstama vanjskih poremećaja.

Prijetnje zaštićenim područjima se mogu podijeliti na lokalne i globalne. Lokalni čimbenici mogu uključivati lokalna onečišćenja vode i kopna, hidrološke promjene uslijed zahvata i vodoopskrbe, ograničeni antropogeni utjecaj, širenje nametnika, pojava invazivne

[21] Biom se definira kao biocenoza ili veliko područje ekozone na zemlji unutar koje makroklimatski čimbenici određuju tip ekoloških zajednica (URL 53).

vegetacije te biljnih bolesti. Često su povezani s globalnim čimbenikom pritiska koji se odnosi na promjenu klime (Liović i Župani, 2005, Darwell i dr., 2014).

Sedreni krajobrazi su popularne turističke destinacije (npr. NPK, NPPJ, kanjoni Zrmanje, Cetine, kaskade na Mrežnici, Nacionalni prirodni rezervat Jiuzhaigou, Huanglong, Havasupai kanjon, Mono Lake, Dunn's River Falls itd.) (Alexandrowicz, 2004, Gu i dr., 2013, Liu, 2017) koje su uslijed ubrzanog globalnog širenja turističkih djelatnosti i klimatskih promjena suočeni s brojnim prijetnjama. Do njihove degradacije može doći vrlo lako uslijed pojačanog antropogenog utjecaja (URL 24). Primjerice, nagli porast broja turista može uzrokovati onečišćenje vode te eroziju sedre na slikovitim mjestima, što uzrokuje pojačani pritisak na njeno očuvanje (Liu, 2017). Zbog svih navedenih razloga *Agencija za zaštitu okoliša* prepoznala je sedreni krajobraz (sedrene barijere i sedrotvorni vodotoci) kao jedan od ugroženih ekosustava u Hrvatskoj (URL 16). Zaštita sedrenih tvorevina je nužna jer predstavljaju važno stanište te izvor hrane i skloništa za sedrotvorce koji su osnova hranidbenog lanca tog biotopa. Narušavanjem te ravnoteže poremetio bi se čitav ekosustav kruženja hranjivih tvari (Šikić, 2007).

Iako nadležne ustanove zaštićenih područja provode niz mjera i akcijskih planova usmjerenih prema očuvanju temeljnog fenomena (npr. izgradnja pješačkih cesta, zabrana uzgoja i ispaše, uklanjanje neadekvatne infrastrukture, ograničavanje broja dnevnih posjetitelja) ipak se degradacija sedre i onečišćenje vode nerijetko događa (Liu, 2017). Tako je u Nacionalnom prirodnom rezervatu Jiuzhaigou zabilježena intenzivna eutrofikacija vode, gdje je povećana koncentracija algi, prepoznata kao ključni čimbenik koji potiče degradaciju sedre (Liu, 2017). Od ostalih problema istaknuti su: zagađenje vode teškim metalima, povećanje dušika i fosfora u vodi uslijed pojačane turističke aktivnosti, povećanje količine sedimenata u jezerima itd. (Gu i dr., 2013).

Degradacija sedre je pojava koja se događa kao rezultat složene interakcije biofizičkih čimbenika te kao takva može imati značajne posljedice za zaštićeno područje. Degradacija sedre, koja se očituje kroz smanjivanje ili prestanak stopa sedrenja, je izrazito štetna jer utječe na ekološki, ekonomski i socijalni aspekt razvoja zaštićenog područja. Ona može biti uzrokovana različitim čimbenicima, od promjena hidrokemijskih parametara vode do potpunog nestanak sedrotvornih vodotokova. Takve pojave se u potpunosti moraju uzeti u obzir prilikom razvoja novih upravljačkih pristupa i akcijskih planova. Kao najveća prijetnja nestanku i degradaciji sedre na globalnoj razini prepoznat je nekontrolirani turizam (Gu i dr., 2013).

U NPK kao čimbenici pritiska viziji održivog razvoja Parka prepoznati su (Radeljak i Pejnović, 2008, Bulat, 2010, Vatavuk, 2018, Marguš, 2018):

1) **Vodoopskrba**

HE Miljacka, Roški slap i Jaruga II oduzimaju vodu temeljnom fenomenu, izazivajući time presušivanje tokova, istovremeno estetski i biološki ugrožavajući slapove i sedrene barijere osobito za vrijeme niskih voda, dolazi do izmjena režima i ekosustava voda te opasnosti od prestanka taloženja sedre;

2) **Otpadne vode**

Sustavi odvodnje Knina i Drniša su u lošem stanju, javlja se izravno ispuštanje otpadnih voda što za posljedicu ima slijevanja otpadnih voda obogaćenih hranjivim tvarima u Krku što dovodi do antropogene eutrofikacije;

3) **Prirodna eutrofikacija**

Prema Agenciji za zaštitu okoliša prirodna eutrofikacija je …*zbog povećanja bioloških resursa pozitivna za ekosustav, uz rijetke negativne pojave…* (URL 46). Međutim, *jedna od rijetkih negativnih pojava* prirodne eutrofikacije, ako je pristupna u većoj mjeri, može biti ugrožavanje procesa sedrenja, odnosno precipitacije karbonata u formi sedrenih barijera (Horvatinčić i dr., 2005). Nedavna istraživanja pokazala su da neki dijelovi ekosustava rijeke Krke spadaju u *relativno čiste vodene sustave sa slabim antropogenim utjecajem, ali vrlo intenzivnim procesima prirodne eutrofikacije* (Marguš, 2018; 27). Uobičajeni indikatori eutrofikacije su pojava niske prozirnosti vode, visoke koncentracije hranjivih soli i velike planktonske biomase te prezasićenja kisikom površinskog sloja (URL 46).

4) **Zbrinjavanje krutog otpada**

Nekontrolirano odlaganje krutog otpada;

5) **Zapuštene šumske površine**

Prestanak stočarenja je doveo do prirodne sukcesije što je rezultiralo gustom vegetacijom, a time i većom opasnošću od požara;

6) **Distribucija posjećivanja Parka**

Posjećivanje Parka ima snažan sezonski karakter koji proizvodi sekundarne čimbenike pritiska u vidu buke, erozija tla i sedrenih barijera, oštećenja vodene vegetacije itd.

7) **Nekontrolirano širenje (ne)invazivne u blizini sedrotvornih vodotokova**

Zbog navedenih čimbenika pritiska ističe se potreba provođenja prilagodljivog pristupa upravljanja koji bi izuzev zaštite i očuvanja bioraznolikosti podupirao i ekonomsku i kulturnu održivost Parka.

2.3.3.1 Širenje (ne)invazivnih vegetacijskih vrsta

Posljednjih godina kao jedan od glavnih čimbenika remećenja ravnoteže ekosustava NPK prepoznato je nekontrolirano širenje i rast invazivne vegetacije te sukcesija makrovegetacije, osobito makrofita na sedrotvornim vodotocima (Matoničkin Kepčija i dr., 2018). Flora je prema strukturnim i morfološkim značajkama podijeljena na makrofite i mikrofite. Makrofiti kao više vodene biljke mogu osigurati drvenaste ostatke koji se kasnije ugrađuju u sedru. Ovakva sedra ima visoku poroznost te može proizvesti debele naslage (Carthew i dr., 2003).

Naime, pretjerana sukcesija vegetacije, koja se može odnositi na različite invazivne vrste, može transformirati prirodni ekosustav smanjujući protok, mijenjajući biokemiju vode, dinamiku sedimenata, oblik kanala te nadvladavajući autohtonu vegetaciju (Ruwanza i dr., 2013, Richardson i Van Wilgen, 2004). Tako u nekim zaštićenim područjima dolazi do prodiranja prilagodljivih neautohtonih vrsta, dok autohtone vrste u takvim uvjetima više ne mogu održavati svoje ekološke funkcije. U takvom sustavu postaje izazov utvrditi je li potrebno ukloniti vrste koje proširuju svoju distribuciju uslijed klimatskih ili nekih drugih promjena. S takvim problem se može suočiti na četiri načina. Kroz 1) statično upravljanje koje održava trenutne ciljeve upravljanja, 2) pasivno upravljanje koji prihvaća neke promjene kao rezultat klimatskih promjena, 3) prilagodljivo upravljanje koje uključuju mjere ublažavanja radi minimiziranja promjena nastale kao posljedica klimatskih promjena te 4) hibridno upravljanje koje je kombinacija 1) i 3) (Ohsawa i Jones, 2017). Upravljanje prijetnjama biološke invazije, koje predstavljaju vodene biljke u trenutnim i budućim klimama, predstavlja sve veći izazov na zemljištima diljem svijeta (Kriticos i Brunel, 2016).

Biološka invazija neautohtonih vrsta (NIS[22]) globalno je prepoznata kao glavna sastavnica globalnih promjena okoliša koja rezultira značajnim gubitkom u ekonomskom, ekološkom i funkcionalnom aspektu napadnutog ekosustava (Hulme, 2003). Autohtone biljke nekog zaštićenog prostora imaju ogromnu društvenu, ekonomsku i ekološku važnost te osiguravaju brojne funkcije ekosustava (Sladonja i dr., 2015). S druge strane invazivne vrste svojim širenjem mogu ugroziti bioraznolikost, poremetiti ravnotežu ekosustava, ugroziti zdravlje ljudi te u konačnici uzrokovati ekonomske gubitke nekom prostoru (Orešković, 2015, Sladonja i dr., 2015). Imaju značajke samostalnog i brzog razmnožavanja, generiraju gustu pokrovnost (homogenizacija ekosustava) te se lako prilagođavaju uvjetima u novom okolišu (Glišić i dr., 2014, URL 19). Smanjivanje njihova utjecaja i kontrola širenja kroz različite mjere

[22] Non-indigenous species

prevencije danas predstavlja jedan od najvećih izazova zaštite prirode (Orešković, 2015). Njihovo širenje može biti produkt širokog spektra aktivnosti: preraspodjele vrsta tijekom razvoja poljoprivrede, šumarstva, hortikulture, rekreacije, razvoja masovnog turizma, jačanja globalne povezanosti kao i slučajnog uvođenja (Sladonja i dr., 2015). Uz uništavanje prirodnih staništa, širenje invazivnih vrsta je na globalnoj razini prepoznato kao druga najveća prijetnja bioraznolikosti (Trifilo i dr., 2004, Dumitraşcu i dr., 2014, Glišić i dr., 2014, Sladonja i dr., 2015, URL 19). Širenjem i rastom invazivne vrste modificiraju osnovne procese unutar ekosustava (Trifilo i dr., 2004, Glišić i dr., 2014):

a) zauzimaju prostor autohtonim vrstama;
b) smanjuju bioraznolikost;
c) izravno mijenjaju hidrološku mrežu;
d) mijenja izgled ekosustava;
e) okoliš gubi vrijednost i funkcije;
f) mijenjaju ciklus kruženja tvari;
g) utječu na povećanje nutrijenata u vodi, čime u konačnici mogu poremetiti ostale procese (npr. sedrenje);
h) učestalost i intenzitet požara.

Najistaknutija invazivna vegetacijska vrsta koja se proširila u prostoru NPK te predstavlja jedan od čimbenika pritiska na njegov ekosustav je pajasen. Pajasen (*ailanthus altissima*) je poznat kao jelš, rajsko stablo, bogač i žljezdasti pajasen. U Kini ga nazivaju *chouchun*, što u prijevodu znači smrdljivo stablo ili smrdljivo proljeće (URL 19). Brzorastuće je razgranato, listopadno stablo koje vuče podrijetlo iz sušnih i toplih predjela Kine i Vijetnama (Trifilo i dr., 2004, Constán-Nava i dr., 2010, Novak i Kravarščan, 2014, Matoničkin Kepčija i dr., 2018). Prepoznat je kao najopasnija invazivna drvenasta biljka u svijetu te se nalazi na listi Međunarodne europske i mediteranske organizacije za zaštitu vegetacije (EPPO[23]) i listi invazivnih vrsta u Sjevernoj Americi (Sladonja, i dr., 2015). U Hrvatskoj je Državni zavod za zaštitu prirode (DZZP) proglasio pajasen invazivnom vrstom (Sladonja i dr., 2015). Pajasen može narasti do 35 m, kora mu je svijetlosive boje, a starenjem puca (URL 19). U Europu je unesen 1740. godine, kao ukrasna biljka koja može pomoći u kontroli i sprječavanju erozije tla. Danas se nalazi na svim kontinentima osim Antarktike (Novak i Kravarščan, 2014, Sladonja i dr., 2015, Matoničkin Kepčija i dr., 2018, URL 19).

[23] European and Mediterenean Plant Protection Organization

Kolonizirao je brojne ekosustave pa tako i prostor mediteranskog bazena čije mu klimatske prilike najviše odgovaraju (Sladonja i dr., 2015). Listovi pajasena se u umjerenim klimatskim uvjetima pojavljuju oko travnja, a cvjetanje počinje od sredine travnja do srpnja (Sladonja i dr., 2015). Pajasen je izrazito prilagodljiv različitima uvjetima okoliša zbog čega je prepoznata kao agresivna i oportunistička vrsta. Svojim djelovanjem, brzim rastom i visokom stopom spolne reprodukcije istiskuje okolne vrste i formira gustu monokulturu (Constán-Nava i dr., 2010, Sladonja i dr., 2014). Izrazito je nepovoljan za druge vegetacijske vrste zbog prisutnosti alelopatskih[24] spojeva čime utječe na funkcioniranje dinamike i strukture okolne vegetacije (Vilà i dr., 2006, Sladonja i dr., 2014) u radijusu od 5 metara (Novak i Kravarščan, 2014). U te spojeve spada otrov ailanton koji djeluje kao inhibitor rasta drugih biljaka (URL 19). Pajasen ima sposobnost rasta na različitim vrstama tla (širok raspon pH vrijednosti) i po svojoj je prirodi heliofilna (otpornost na dugotrajne suše i visoke temperature) vrsta. Međutim, nije otporan na poplave (iako o tome postoje konfliktne informacije) (URL 23) te na nedostatak svjetlosti (Sladonja i dr., 2015, URL 19). Dakle, sjena i hladnoća kao ograničavajući čimbenici mogu spriječiti uspostavu njegovih sadnica i ograničiti njegovu distribuciju (Sladonja i dr., 2015). Najbolje uspijeva na dobro osvijetljenim, termofilnim staništima (Hruševar i Posavec Vukelić, 2008). Pajasen ima sposobnost bržeg obnavljanja od ostale vegetacije tako da se na devastiranim, opožarenim prostorima puno širi (Novak i Kravarščan, 2014). Zbog navedenih obilježja nužna je njegova kontrola u zaštićenim područjima (Constán-Nava i dr., 2010).

Nadalje, sukcesija makrovegetacije u neposrednoj blizini, i na prostorima sedrotvornih vodotokova (makrofiti), također predstavlja značajan problem jer doprinosi intenzivnijem taloženju anorganskih i organskih čestica što rezultira jačom eutrofikacijom (Meštrov i dr., 1973, Habdija i Perić, 2012, Matoničkin Kepčija i dr., 2018). Vodeni makrofiti utječu na brzinu protoka, turbulenciju vode (hidraulička hrapavost), pružaju mikro stanište za beskralježnjake, hvataju detritus i utječu na ravnotežu otopljenog O_2 u vodi (Miliša i dr., 2006, Kaenel i dr., 2000). Uklanjanja makrofita iz lotičkih ekosustava može stvoriti poremećaje koji mogu značajno izmijeniti funkcije ekosustava. Primjerice, uklanjanje vodenog korova može dovesti do povećanja brzine protoka vode, ali i smanjenje količine makrozoobentosa i bioraznolikosti (Miliša i dr., 2006, Wilcock i dr., 1999). Miliša i dr. (2006) su proveli uklanjanje makrofita u svom istraživanju. Najvažniji utjecaj uklanjanja makrofita bilo je značajno smanjenje brzine protoka vode. Naime, prije uklanjanja tok je bio kanaliziran u uska područja između makrofita

[24] Alelopatija označava utjecaj koji jedna vrsta ima na drugu putem proizvodnje specifičnih kemijskih spojeva koji se najčešće negativno odražavaju na rast, razvoj i razmnožavanje. Ova metode nekoj vrsti omogućava veće šanse za preživljavanje u prirodi.

i stoga je na tim lokacijama brzina toka veća (Sand-Jensen i Mebus, 1996). Uklanjanjem makrofita područje protoka se povećava, količina dolazne vode iz jezera ostaje ista što rezultira sporijim protokom vode. Kaenel i dr. (1998) navode rezultate gdje uklanjanje makrofita rezultira bržim protokom. U konačnici to je posljedica hidroloških samoregulirajućih svojstava izvora vode. U istraživanju Miliša i dr. (2006) reduciranja brzina protoka povezana s uklanjanjem makrofita negativno su utjecala na stope prirasta sedre. Kao razlog tome se navodi izražen vodopadni (eng. *waterfall*) efekt koji se javlja na sedrenim barijerama. Zabilježena je veća stopa prirasta sedre na nizvodnim lokacijama što odgovara istraživanjima Golubić (1969) i Matoničkin Kepčija i dr. (2005). Nadalje, nakon uklanjanja makrofita došlo je do smanjenja gustoće makrozoobnetosa, ali uglavnom onih svojti koje su koristile makrofite kao stanište, što je u skladu s drugim istraživanjima (Dawson i dr., 1991, Kaenel i dr., 1998).

Sukcesija makrovegetacije se učinkovito može riješiti metodom prorjeđivanja (eng. *thinning*) kojom se između ostalog postiže smanjivanje konkurencije između drveća i grmlja, poboljšava rast i sazrijevanje zadržanih stabala te se pomaže obnavljanje drugih vegetacijskih vrsta. Prorjeđivati se ne smiju zaštićeni vegetacijskih oblici te se ono ne smije vršiti na ranjivom zemljišnom pokrovu (NSW, 2014). Prorjeđivanje je kao strategija upravljanja vegetacijskim pokrovom korisna za regeneraciju niske vegetacije i staništa te se preporučuje za korištenje ako se žele obnoviti određene ekološke funkcije (Trentini i dr., 2017, Ruwanza i dr., 2013).

2.3.3.1.1 Metode uklanjanja pajasena

Proces uspješnog sprječavanja uklanjanja i širenja pajasena je težak zbog njegove mogućnosti regeneracije. Postoji nekoliko metoda uklanjanja (Constán-Nava i dr., 2010, Novak i Kravarščan, 2014, Sladonja i dr., 2015). U literaturi je ispitana učinkovitost mehaničkog uklanjanja (sječa, čupanje) stabljike jednom godišnje, nekoliko puta godišnje, kemijsko djelovanje te kombinacija mehaničkog i kemijskog djelovanja (Constán-Nava i dr., 2010). Neki autori su testirali metodu mehaničkog uklanjanja nakon čega se može nanijeti malč[25], rezanje panja uz nanošenje glifosata, samo rezanje panja te korištenje EZJect sustava (Slika 8) koristeći glifosat (Meloche i Murphy, 2006). Glifosat je kemijski spoj koji spada u skupinu fosfonata, a primjenjuje se od druge polovice 1970-ih godina za potrebe suzbijanja korova.

[25] Malčiranje je postupak prekrivanja prostora oko biljaka radi sprečavanja rasta korova i dekoracije.

Slika 8. EZ-Ject sustav unošenja herbicida

Izvor: URL 21

Mehaničko uklanjanje i malčiranje je korisno samo u jednoj godini istraživanja na manjim prostorima, što može dati priliku za aktivno presađivanje autohtonih vrsta. U praksi je teško iščupati cijeli korijen pajasena zbog njegove razgranate strukture te strukture tla na kojoj raste (Novak i Kravarščan, 2014). Ako se pajasen ne ukloni u potpunosti (stabljika + korijenje), već samo posiječe, on će rasti sve brže (URL 19). Dakle, u mehaničkom uklanjanju manja stabalca je potrebno uklanjati s korijenom nekoliko godina uzastopno. Ako se izvrši sječa stabla u panjeve je potrebno zabiti bakrene čavle koji promjenom električnog naboja mogu uništiti korijen. Zbog velikih površina obuhvaćenih pajasenom te visoke sposobnosti regeneracije (pojačano klijanje) biljke smatra se da metoda mehaničkog suzbijanje pajasena nije učinkovita već proizvodi suprotan učinak (Constán-Nava i dr., 2010, Novak i Kravarščan, 2014, URL 22). Ručno vađenje mladih stabljika je djelotvorno kad je tlo vlažno, a cijeli korijenski sustav uklonjen (URL 22).

Kombinacija rezanja stabljika i tretiranje s herbicidima, uklanja ovu mogućnost i stvara manje površinskih poremećaja. Malčenje nije preporučljivo zato što može oštetiti autohtonu vegetaciju te izmijeniti ekosustav (Meloche i Murphy, 2006). Dakle, u istraživanjima se zajednička metoda mehaničkog uklanjanja i primjena herbicida (kemijska metoda) sredinom i krajem ljeta (URL 22) pokazala kao jedina učinkovita u djelotvornom uklanjanju pajasena u mediteranskim prostorima (Constán-Nava i dr. 2010, Novak i Kravarščan, 2014).

Upravitelji zaštićenih područja su u pravilu skloniji prihvaćanju metode ručnog uklanjanja i malčiranja nego rezanja stabljika i primjene glifosata jer ostaju vidljivi izrezani panjevi koji su vizualno neatraktivni za posjetitelje. Primjena herbicida je zabranjena u zaštićenim parkovnim prostorima. Ipak, većina autora preporučuje rezanje stabla pajasena te tretman herbicidima. Primjena glifosata, ako se to radi primjereno, nema neželjenih učinaka na biotu i ljude, ne kreira nepotrebno uznemiravanje tla, može se primijeniti na velikim područjima zaraze te se dugoročno smatra isplativijom i učinkovitijom metodom od mehaničkog uklanjanja (Meloche i Murphy, 2006).

Prilikom mehaničkog i kemijskog uklanjanja treba biti izuzetnom oprezan jer pajasen izaziva alergijske reakcije (URL 19). Također, problem postaje nanošenje herbicida na visoka stabla. Glifosat, triklopir, pikloram su herbicidi koji su se pokazali učinkovitim za pajasen (Novak i Kravarščan, 2014). Iako kombinirana metoda u istraživanju Constán-Nava i dr. (2010) nije smanjila broj jedinki, utjecala je na biomasu, visinu i list. Zbog čega autori navode da kombinirana metoda treba biti uključena u *Planove upravljanja* zaštićenim mediteranskim prostorima. Međutim, potrebno je vršiti sustavan višegodišnji nadzor zaštićenih područja kako bi se procijenio stvarni uspjeh metode te osigurala uspješna rekolonizacija autohtonih vrsta i potpuni oporavak ekosustava (Constán-Nava i dr., 2010). Da bi se postigla minimalna kontrola širenja pajasena na nekom području nadzor i mjere suzbijanja je potrebno kontinuirano provoditi minimalno dvije do tri godine (Novak i Kravarščan, 2014).

2.3.3.1.2 Pajasen u NPK

Iako prostor u kojem je došlo do širenja pajasena djeluje vegetacijski bogat i zelen, u njemu je značajno smanjena bioraznolikost, a time i vrijednost ekosustava (Novak i Kravarščan, 2014). Stoga su zaštićena područja kao *prostori neznatno izmijenjenih ekosustava* posebno osjetljivi na širenje pajasena. Uprava NPK je u posljednjih nekoliko godina uočila nekontrolirano širenje biljke pajasen koje je, uz ostalu nisku, grmoliku vegetaciju, utjecala na izmjenu smjerova sedrotvornih vodotokova na širem području SB (Slika 9). Nestanak tih tokova te prestanak procesa sedrenja uzrokovalo je pad atraktivnosti specifičnih ploha unutar Parka, zbog čega su posjetitelji zaobilazili taj prostor, istovremeno stvarajući saturaciju na drugim područjima, čime se povećalo antropogeno djelovanje na taj dio.

Slika 9. a) Pajsen zaklanja pogled prema Skradinskom buku, b) pajasen raste iz kamena

Izvor: Novak i Kravarščan 2014.

Pajasen je na prostoru NPK proširen na nekoliko tisuća metara kvadratnih. Na tom prostoru on potiskuje i ugrožava autohtone vrste, remeti ekosustav, mijenja okoliš i remeti proces sedrenja. Njegovo učinkovito uklanjanje putem kemijske metode ograničeno je zabranom korištenja sredstava za zaštitu bilja u NP (Novak i Kravarščan, 2014). Unatoč tome što je prepoznat kao najinvazivnija vrsta svijeta, ipak nedostaju učinkoviti planovi kontrole njegova širenja u zaštićenim prostorima (Constán-Nava i dr., 2010). Pretpostavlja se da će u budućnosti potencijali novi problem zaštićenim ekosustavima predstavljati pojava invazivnih vodenih vrsta (URL 20).

2.4 Sedra i travertin - pojmovno određenje

Precipitacija $CaCO_3$ značajka je mnogih slatkovodnih sustava. U literaturi se navode različiti nazivi za hidroprecipitate nastale ovim procesom (Viles i Goudie, 1990). U engleskom jeziku najčešće se spominju dva naziva: 1) *tufa* (sedra) i 2) *travertine* (travertin) (Bonacci i dr., 2017). Sedra i travertin su karbonatni precipitirani sedimenti slatkovodnih sustava koje je moguće pronaći širom svijeta (Viles i Pentecost, 2007). U literaturi često dolazi do krive interpretacije ovih naziva, iako između njih postoje jasne razlike (Tablica 4) (Ford i Pedley, 1996, Capezzuoli, 2014, Bonacci i dr., 2017). U starijim izvorima pojmovi su izjednačavani (Trpčić, 2016). Zajednička značajka im je da spadaju u terestričke karbonate nastale kao rezultat kombiniranih kemijskih i bioinduciranih procesa (Capezzuoli, 2014).

Tablica 4. Glavne razlike u značajkama travertina i sedre

	TRAVERTIN	**TUFA**
Proces precipitacije	dominantno abiotički	dominantno biotički
HCO^-_3 sastav (mmol/l)	>7	<6
$\delta^{13}C$ (PDB ‰)	od -1 do +10	<0
DIC (mmol/l)	>10	<8
Temperatura vode	termalna, općenito veća od 30° C	općenito niža od 20° C
Mineralogija	kalcit, aragonit	kalcit
Stope taloženje	visoka (cm do m/god.)	niska (mm do cm/god.)
Struktura	obloženi mjehurići	petrifikacija algi, cijanobakterija
Veličina kristalnog kalcita	od makro do mikritnih kristala	dominantno mikritni do mikrosparitnih
Primarna poroznost	generalno loša (ispod 30%)	generalno visoka (preko 40%)
Biološki sadržaj	nizak (bakterije i cijanofiti)	vrlo visok (mikro do makrofiti)
Morfologija precipitata	višesimetrično tijelo	aksijalno-simetrična tijela
Prepoznatljivost litofacijesa	obloženi mjehurići	petrifikacija algi, cijanobakterija
Hidrološke postavke	uglavnom stalni protok	promjenjivi protok, ovisan o oborinama
Klimatski utjecaj na precipitaciju	manje ovisan	strogo ovisan
Antropogeni utjecaj na precipitaciju	malo utječe	duboko utječe
Tektonski odnos	uvijek prisutan	često odsutan

Izvor: prema Capezzuoli, 2014.

Travertin većina autora veže uz precipitat izlučen iz toplih i vrućih hidrotermalnih voda (Cukrov i dr., 2010), dok se pojam *tufa*, odnosno sedra veže uz precipitat izlučen iz voda koje imaju temperaturu okoline, odnosno ne odstupa bitno od temperature zraka (Ford i Pedley, 1996, Pedley, 2000, Capezzuoli, 2014). Naslage sedre i travertina nalaze se na svim kontinentima osim Antarktike (Pentecost, 1981), pretežno u vapnenačkim prostorima (Viles i Pentecost, 2007). Aktivni i relikti sustavi sedre pojavljuju se u većini svjetskih krških područja (Viles i Goudie, 1990). U nekim područjima masivne naslage sedre i travertina se šire do kilometra i oblikuju krajobraze sačinjene od slapova, jezera i kaskada (Liu, 2017). Većina takvih formacija potječe iz pleistocena ili holocena (Viles i Pentecost, 2007).

Travertin je korišten u izgradnji javnih spomenika, a tufa u narodnoj arhitekturi (ukrasne ploče, zidovi kuća) (Pedley i dr., 2009). Termin travertin potječe od talijanske riječi *travertino*, odnosno derivacije latinskog *lapis tiburtinus*, kamena Tibura (Pentecost i Viles, 1994, Golubić i dr., 2008, Trpčić, 2016). Tibur, danas Tivoli (Italija) (Slika 10) je mjesto velikih ležišta naslaga kalcijevog karbonata koji su povezani s termalnim izvorima (Viles i Goudie, 1990).

Slika 10. Naslage travertina (Tivoli, Italija)

Izvor: URL 12

Dakle, pojam travertin se povezuje s naslagama nastalim iz prezasićenih voda tipično hidrotermalnog podrijetla (eng. *thermogene travertine*) (Viles i Pentecost, 2007). Travetin obilježavaju visoke stope taloženja, pravilni, fino laminirani slojevi niske poroznosti i propusnosti (Capezzuoli, 2014, Bonacci i dr., 2017). Manje količine mikrobnih zajednica sudjeluju u njegovom formiranju (Ford i Pedley, 1996). Neki autori pod pojmom karbonatne sedre opisuju slabo konsolidirane naslage, dok travertin predstavlja manje porozne i otpornije naslage (Lyons i Kelly, 2016).

Engleski naziv *tufa* se donosi na karbonatnu sedru, mekanu, šupljikavu, spužvastu te izrazito poroznu monomineralnu stijenu formiranu u rijekama, slapovima i jezerima vapnenačkih područja kroz izlučivanje isključivo minerala kalcita po mahovinama, cijanobakterijama i vodenom bilju (Slika 11) (Viles i Goudie, 1990, Benac, 2013, Zhang i dr., 2001, Bonacci i dr., 2017, Liu, 2017). Sedra predstavlja jedinstveni krajobraz i važan je izvor paleookolišnih informacija (Carthew i dr., 2003, Gradziński, 2010). Nastanak sedre je vrlo lokaliziran (Pevalek, 1956), odnosno samo u onim tokovima koji zadovoljavaju širok spektar biohidrokemijskih parametara dolazi do njena nastanka. Sedra je stoga *dobar indikator uvjeta u okolišu zbog svojih morfoloških, geokemijskih i izotropnih karakteristika, koje su odraz klimatskih uvjeta u razdoblju njezina rasta, ali i trenutnog stanja vodenih ekosustava zbog precipitacije, izmjene hranjivih tvari i antropogenog utjecaja* (Marguš, 2018; 25). Terestrički je slatkovodni karbonat tipičan za krška područja (Capezzuoli, 2014), bogat makrofitima, mikrofitima, beskralježnjacima i bakterijama (Lyons i Kelly, 2017, Bonacci i dr., 2017, Liu, 2017, Gradziński, 2010) uz obično odsutan aragonit (Capezzuoli, 2014), oblikovan u vodama ambijentalne do gotovo ambijentalne temperature (Carthew i dr., 2003). Viles i Pentecost, (2007) navode izraz meteogene sedre s obzirom na to da CO_2 u sustavima dolazi prvenstveno iz tla i podzemnih voda.

Slika 11. Šupljikava struktura sedre

Izvor: URL 13

Prilikom prepoznavanja sedre potrebno je prepoznati način precipitacije (organski ili anorganski), hidrološke uvjete i poroznost (Bonacci i dr., 2017). S obzirom na to da bilježi godišnju laminaciju i stopu rasta, u nekim slučajevima, preko centimetarske vrijednosti, analizom sedre, moguće je rekonstruirati (pale)oklimatske uvjete okruženja u kojem nastaje i to na godišnje razini. (Hori i dr., 2009). Prema navedenim značajkama karbonatne tvorevine u NPK i NPPJ treba promatrati kao *tufu,* odnosno karbonatnu sedru (Cukrov i dr., 2010). Međutim, u NPK na službenim postavljenim tablama sedrene barijere se navode kao travertin (Slika 12).

Slika 12. Primjer krivog navođenja sedre kao travertina na službenoj tabli u blizini Roškog slapa

Nadalje, na službenim stranicama NPK sedra i travertin se navode kao sinonimi i *definiraju kao kalcijev karbonat (vapnenac) koji se u tekućicama taloži iz vode na različite podloge* (URL 1). Na stranicama NPPJ dana je preciznija definicija: *sedra je produkt istaloženog kalcijevog karbonata pri temperaturnim uvjetima bliskim temperaturi okoliša i često sadrži ostatke mikrofita i makrofita, beskralješnjaka i bakterija* (URL 10). U hrvatskom jeziku postoji nekoliko izraza koji se sinonim za sedru: vapneni mačak, tufa, lehnjak, bigar, vodeni kamen (Trpčić, 2016, Kovač, 2020).

2.4.1 Nastanak sedre

Neovisno o tome o kojem se tipu hidroprecipitata radi zajednička im je postavka da nastaju iz vode koja je prezasićena kalcij hidrogenkarbonatom (Cukrov i dr., 2010). S obzirom na to da protječe kroz vapnenačku podlogu, voda je bogata otopinom kalcijevog karbonata $CaCO_3$ (Trpčić, 2016). Kalcijev karbonat je zbog svog širokog područja primjene jedna od najznačajnijih mineralnih sirovina (URL 8). U prirodi je najrašireniji i najvažniji spoj kalcija, gotovo netopljiv u čistoj vodi. Međutim, u prirodnoj vodi, koja sadrži CO_2 uglavnom biogenog podrijetla (Marguš, 2018), njegova topljivost se povećava (Kovač, 2020). Takav tip otopine je relativno nestabilan (Kovač, 2020).

Sedra nastaje precipitacijom minerala kalcita iz vode u specifičnim fizikalno-kemijskim uvjetima uz sudjelovanje sedrotvornih organizama (bakterije, alge, razni organizmi itd.) (Arp i dr., 2001, Zhang i dr., 2001, Trpčić, 2016). Nastanak sedre može se podijeliti u nekoliko koraka.

1) Prva etapa se odnosi na otapanje $CaCO_3$ u vodi koja sadrži veću količinu CO_2. Na temelju vrijednost pH može se pratiti količina CO_2 u vodi. Naime, otopljeni CO_2 stvara karbonatnu kiselinu povećavajući količinu vodikovih iona. Takva voda ima niži pH (6-7). CO_2 povećava topljivost kalcijeva karbonata jer nastaje kalcij-hidrogenkarbonat (Kovač, 2020). Otapanje $CaCO_3$ može biti prikazano formulom:

(1) $$CaCO_3 + CO_2 + H_2O \rightarrow Ca^{2+} + 2\,HCO_3$$

Ponekad u otopini mogu biti prisutne i koncentracije drugih iona, ovisno o tome kroz kakve tipove stijena voda prolazi. S obzirom na količinu otopljenog $CaCO_3$ voda može imati različite stupnjeve zasićenja. Mjera za izražavanje je indeks zasićenosti (I_{zas}) ili saturacijski indeks kalcitom (S_{Ic}[26]) (URL 7). Precipitacija $CaCO_3$ je funkcija alkaliteta (CO_3^{2-}) i dostupnosti slobodnog Ca^{2+} koji se kombiniraju u indeks zasićenja. Ako S_{Ic} prelazi nultu vrijednost, $CaCO_3$ teži precipitaciji, u suprotnom dolazi do otapanja (Liu, 2017). Međutim, da bi došlo do formiranja sedre osim prezasićenosti $CaCO_3$ potrebno je da voda sadrži pogodne jezgre ili supstrate za odlaganje kalcita. Njih mogu osigurati organizmi ili organske tvari kao što su ostaci lišća, grana i stabljika (Viles i Pentecost, 2007).

2) Druga etapa se odnosi na oslobađanje CO_2 iz vode i istovremeno zasićivanje, odnosno prezasićivanje otopine kalcitom i ostalim modifikacijama $CaCO_3$ (URL 7).

(2) $$2HCO_3^- \rightarrow CO_3^{2-} + CO_2 + H_2O$$

[26] Calcite Saturation Index

Do prezasićenja dolazi isključivo uklanjanjem CO_2 iz vodene otopine (Kovač, 2020). Naime, uslijed otpuštanja ili biokemijskog uklanjanja CO_2 voda postaje neuravnotežena te bogata otopljenim $CaCO_3$ (Viles i Pentecost, 2007). Ako se ne postigne kritično zasićenje, do precipitacije neće doći. Oslobađanje CO_2 iz vode može biti rezultat anorganskog otpuštanja uslijed zagrijavanja (povišena temperatura povećava brzinu svih reakcija u otopini), smanjenja njegovog parcijalnog tlaka u okolnoj atmosferi pri većim turbulencijama vode (Marguš, 2018) te organskog uklanjanja kroz biološke fotosintetske procese. Između stupnja zasićenosti i prosječnih mjesečnih temperatura vode postoji veza. Tijekom ljetnih i jesenskih mjeseci zasićenost vode je veća nego zimi i proljeće (Lorah i Herman, 1988, Srdoč i dr., 1985).

Način oslobađanja CO_2 je istraživan od strane brojnih znanstvenika (Emeis i dr., 1987, Chen i dr., 2004). Naime, razlikovanje organskih i anorganskih procesa u formaciji minerala $CaCO_3$ često nije jednostavno i jednoznačno (Merz-Preiß i Riding, 1999). Proučavanje kratkoročnog (sezonskog) ponašanja aktivnih sedrenih sustava omogućilo je unaprjeđivanje znanja o ulozi mehaničkog otplinjavanja (eng. *degassing*) CO_2 u odnosu na ulogu fotosinteze u procesu sedrenja (Arenas i dr., 2010). Dakle, u objašnjavanju procesa nastanka prezasićenosti hidrogeokemičari raspravljaju o dvije glavne teorije. Jedni tvrde da prevladavaju fizičko-kemijski procesi, dok su prema drugima dominantni biokemijski.

Istraživanja otpuštanja CO_2 prepisuju uglavnom turbulenciji vode te u manjoj mjeri metaboličkoj apsorpciji CO_2 od strane fotosintetskih organizama (Chen i dr., 2004, Liu, 2017). Vodene biljke za svoj rast trebaju CO_2 kojeg uzimaju iz dijela slobodne ugljične kiseline čime se narušava kemijska ravnoteža između slobodne ugljične kiseline i otopljenog kalcijevog bikarbonata. Međutim, to prvenstveno ovisi o tipu fluvijalnog okruženja (Chen i dr., 2004). Naime, detaljnim mjerenjem temperature, pH i koncentracije kalcija utvrđeno je da je glavni uzrok prezasićenja u fluvijalnim okruženjima brzog strujanja vode anorgansko otplinjavanje CO_2 dok je njegov fotosintetski unos zanemariv. Fotosintetska aktivnost može iscrpiti sadržaj CO_2 fluvijalnih oruženja sporijeg protoka do točke prezasićenja (Zhang i dr., 2001). Ipak, mikroorganizmi imaju značajnu ulogu u neposrednom formiranju sedre kroz hvatanje mikročestica i osiguravanje supstrata za rast kalcita (Emeis i dr., 1987, Chen i dr., 2004).

U turbulentnim vodama, glavni uzročnik precipitacije kalcijevog karbonata je otplinjavanje CO_2 dok je njegova fotosintetska apsorpcija zanemariva (Liu, 2017). Stoga proces sedrenja često započinje na brzacima, odnosno neravninama i zaprekama zbog kojih dolazi do rasprskavanja vode i oslobađanja CO_2 (Zhang i dr., 2001). One otopine koje su nisu prezasićene s $CaCO_3$ imaju veliku stabilnost što znači da do precipitacije neće doći (Kovač,

2020). Ubrzano strujanje vode i povećana površina dodira vode i zraka povećavaju brzinu otpuštanja CO_2 i S_{Ic} koji potom induciraju precipitaciju kalcita (Zhang i dr., 2001, Bonacci i dr., 2017). Dakle, opadanje parcijalnog tlaka CO_2 u okolnoj atmosferi uzrokuje njegovo oslobođenje iz otopine. Time se remeti ravnoteža i otopina postaje prezasićena s $CaCO_3$. Oslobađanje CO_2 se događa kada je njegov parcijalni tlak u vodi viši od atmosferskog ($10^{-3,5}$ bara). U krškim područjima to je često jer je voda obogaćena s CO_2 uslijed procjeđivanja s površine. Ponovna uspostava ravnoteže u otopini ostvaruje se precipitacijom viška $CaCO_3$ u nekom od oblika kristalnih alotropa (URL 7). Proces je endoterman što znači da se formiranje sedre ubrzava s povećanjem temperature vode (Liu, 2017). Zasićenost je općenito veća tijekom ljetnih i jesenskih mjeseci nego zimi (Srdoč i dr. 1985, Liu, 2017).

3) Treća etapa se odnosi na precipitaciju viška $CaCO_3$ iz otopine u obliku sitnih kristala (Kovač, 2020). Otopina je prezasićena $CaCO_3$ u obliku kalcijevog bikarbonata (URL 10). Precipitacija se odvija paralelno s prethodnom fazom otpuštanja CO_2 iz otopine (Kovač, 2020). Precipitacija kalcita ima važan utjecaj na hidrokemijsku evoluciju riječnih sustava i globalni ciklus C zbog velike količine CO_2 otpuštenog u atmosferu (Chen i dr., 2004). Sedra se formira kroz sljedeću kemijsku reakciju (Viles i Pentecost, 2007, Lyons i Kelly, 2016, Farr i dr., 2017, Liu, 2017):

(3) $$Ca^{2+} + 2HCO_3^- \leftrightarrow CaCO_3\downarrow + CO_2\uparrow + H_2O$$

Dakle, sedrenje je složen proces koji uključuje kemijsku ravnotežu krutog, tekućeg i plinovitog stanja (Zhang i dr., 2001). Sumirano, otopljen kalcijev bikarbonat koji je u vodu dospio kemijskim trošenjem stijena gubi CO_2 kroz gore opisane procese i potom prelazi u $CaCO_3$, odnosno mineral kalcit. Sedra je stoga izgrađena od kalcitnih kristala (Belić, 2005).

2.4.2 Morfologija sedre

U procesu nastanka sedre i travertina obično sudjeluju različiti biljni i životinjski organizmi što rezultira širokim rasponom morfologija (Slika 13) (Viles i Pentecost, 2007). Precipitati su uglavnom morfološki različiti, ali kemijski dosta slični. Precipitacija $CaCO_3$ u sedri stvara široku lepezu kristalnih oblika koji se mogu povezati s utjecajem cijanobakterija, algi, mahovina, drugih biljki i detritusa[27] (Ford i Pedley, 1996, Forbes i dr., 2010). Sedra je često nepravilnog tijela s vrlo složenom i diferenciranom unutarnjom strukturom koja je rezultat isprepletenih biohidrokemijskih značajki lokacije u kojoj je došlo do njenog formiranja

[27] Detritus označava čestice odumrle organske tvari. Temeljni je izvor energije za bentoske zajednice u tekućicama.

(Alexandrowicz, 2004). Uslijed pojave erozijskih epizoda i dijageneze ponekad je teško prepoznati i klasificirati morfologiju i facijese sedre (Viles i Pentecost, 2007).

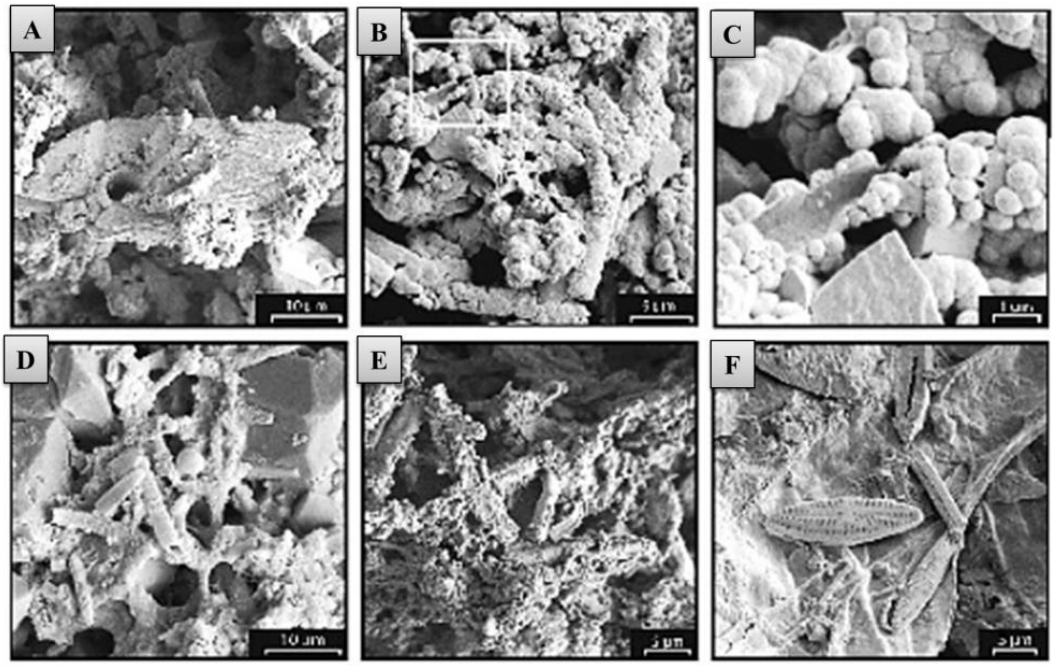

Slika 13. Fotografije skenirajućeg elektronskog mikroskopa (SEM[28]) različitih morfologija sedre

Izvor: Rosen i dr., 2004

Sedra se može klasificirati s obzirom na tri značajke: geokemijsku, teksturu (eng. *fabric*) te morfologiju (Pentecost i Viles, 1994). U literaturi je predloženo nekoliko klasifikacijskih shema, međutim nijedna nije idealna s obzirom na širok raspon varijabilnosti oblika i prirode nastanka samog depozita. Jedna od njih je klasifikacija prema podrijetlu CO_2 u vodi (Viles i Pentecost, 2007). Tekstura se odnosi na strukturu kristalnih rešetki, a predstavlja drugi način klasificiranja koji se može promatrati u različitim mjerilima (Viles i Pentecost, 2007). Naime, razlike u strukturi se mogu vidjeti golim okom (eng. *mezofabric*) ili mikroskopom (emg. *microfabric*) (Pentecost i Viles, 1994). Mikromorfološko mjerilo se odnosi na razlike u poroznost, cementaciji i osnovnim sastavnicama kao što su alohemi[29] (Viles i Pentecost, 2007). Gustoća precipitata ukazuje na poroznost sedimenta i pruža uvid u načinu precipitiranja (Pentecost i Viles, 1994). Na teksturu precipitata utječu brojni čimbenici: temperatura, brzina protoka, otpuštanje CO_2, zasićenje kalcitom, mehanizmi prijenosa iona i utjecaj biljaka i životinja (Pentecost, 2005).

[28] Scanning Electronic Microscop
[29] Klastična zrna kalcita.

Osnovna podjela prema morfološkoj klasifikaciji je na autohtonu (*in situ*) i alohtonu (oblici doneseni na mjesto taloženja) (Viles i Pentecost, 2007). Pentecost i Viles (1994) ističu geomorfološku klasifikaciju autohtone sedre (Slika 14):

1) sedra izvora - humci (eng. *spring mound*);

2) kaskadna sedra (eng. *cascade*);

3) sedra brana ili pregrada (eng. *barrage or dam tufa*);

4) sedrena kora brzih voda (eng. *fluvial stream crust*);

5) sedrena kora jezera (eng. *lacustrine crust*);

6) močvarna sedra (eng. *paludal deposits*);

7) cementirani rudit i klastit (eng. *surface-cemented rudites*).

Općenito morfološki može biti podijeljena na izvorsku, jezersku, riječnu i močvarnu sedru (Trpčić, 2016). Prema navedenoj morfološkoj podjeli sedrene tvorevine na prostoru NPK spadaju u oblike kaskadne sedre (Pentecost i Viles 1994).

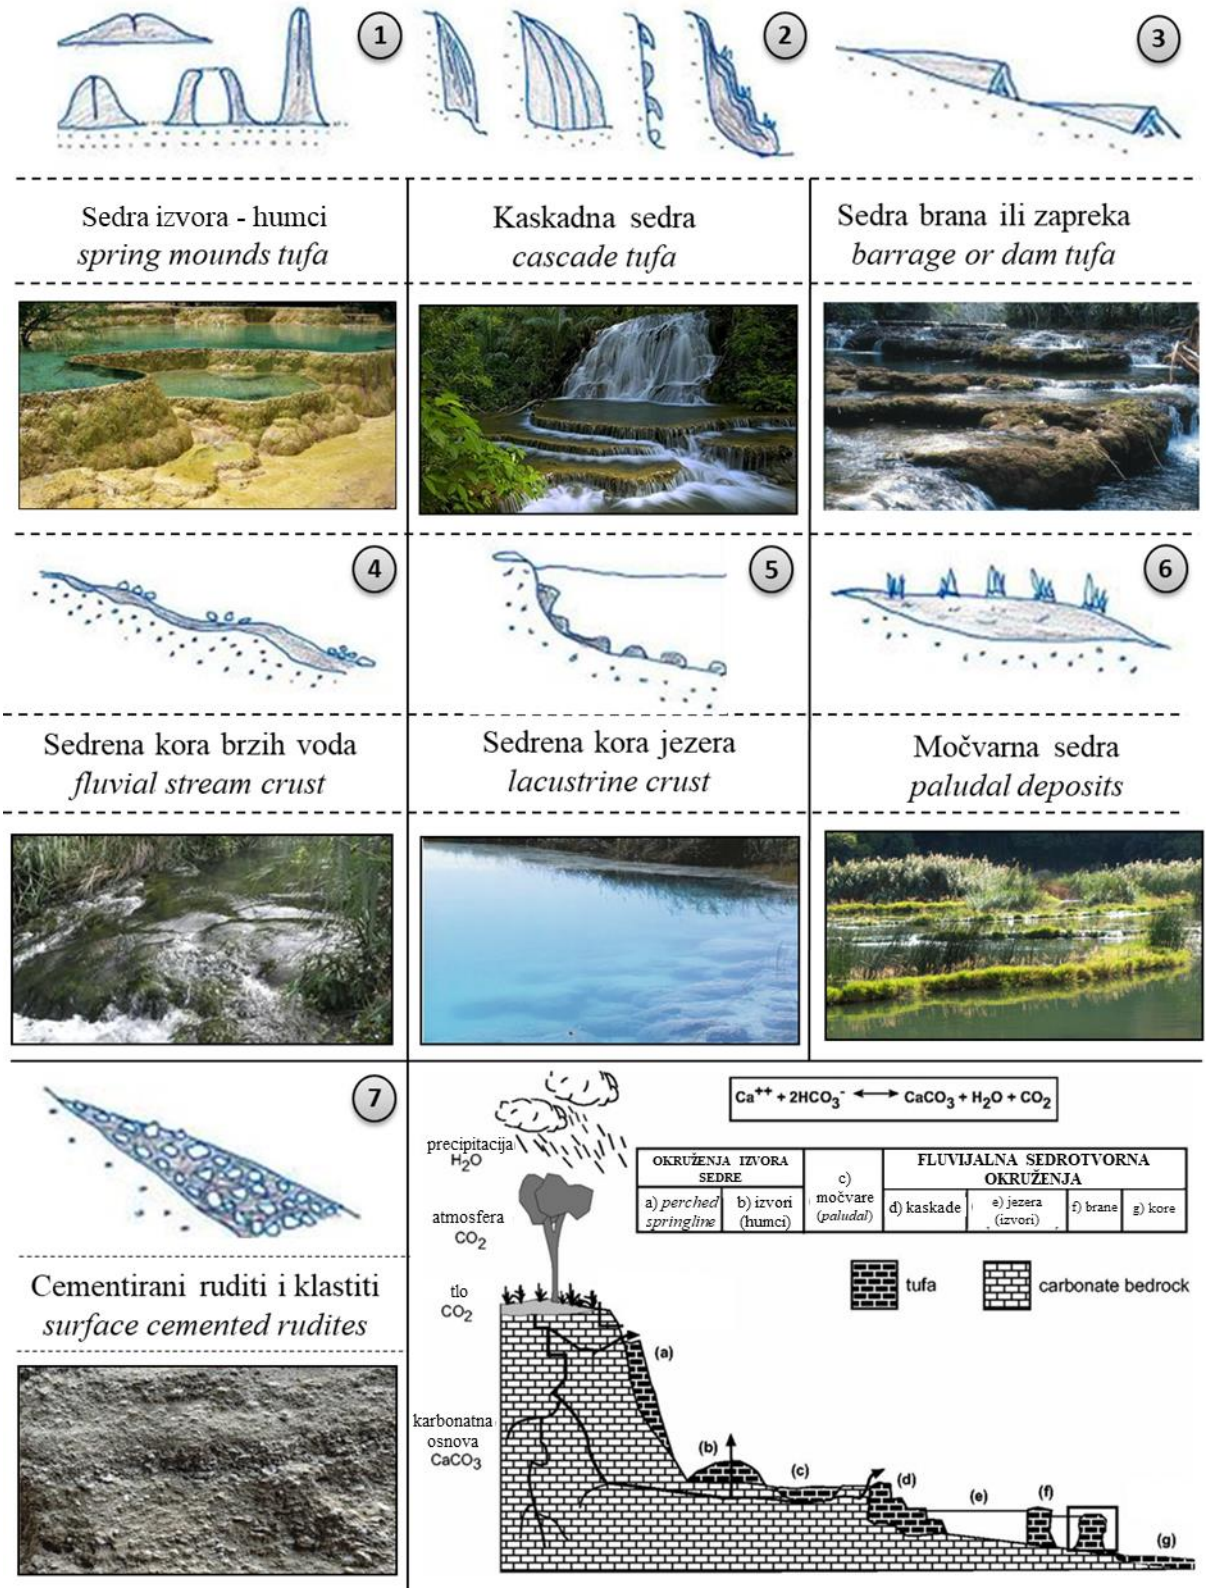

Slika 14. Morfološka klasifikacija autohtonih sedrenih naslaga

Izvor: prema Pentecost i Viles 1994, Carthew i dr., 2003

U literaturi je moguće pronaći sljedeće vrste sedre s obzirom na teksturu (strukturu) uvjetovanu lokacijom sedrenja: porozna (eng. *porous tufa*) (Vazquez-Urbez i dr., 2010, Arenas i dr., 2010, Liu, 2017), kompaktna i zgrušana (eng. *compacted and clotted deposits*) (Liu, 2017), rastresita (eng. *loose deposits*) (Arenas i dr., 2010, Arenas i dr., 2014, Liu, 2017), stromatolitna (eng. *stromatolites*) (Vazquez-Urbez i dr., 2010, Arenas i dr., 2010, Manzo i dr., 2012, Arenas i dr., 2014), mahovinasta (eng. *moss-tufa*) (Irion i Muller 1968, Vazquez-Urbez i dr., 2010, Arenas i dr., 2014) i algalna (eng. *alga-tufa*) (Irion i Muller 1968, Vazquez-Urbez i dr., 2010, Arenas i dr., 2014). Gusta stromatolitna sedra nastaje u brzim fluvijalnim sustavima uz korito rijeke (Slika 15). Rastresita nastaje u sporim vodenim okruženjima dok se porozna i spužvasta formiraju u fluvijalnim sustavima stepeničastih slapova (Arenas i dr., 2010). Stromatolitna, mahovinasta i algalna imaju veće stope prirasta (deblji precipitat) od rastresite sedre formirane u područjima prskanja (Auqué i dr., 2013, Auqué i dr, 2014, Arenas i dr., 2014).

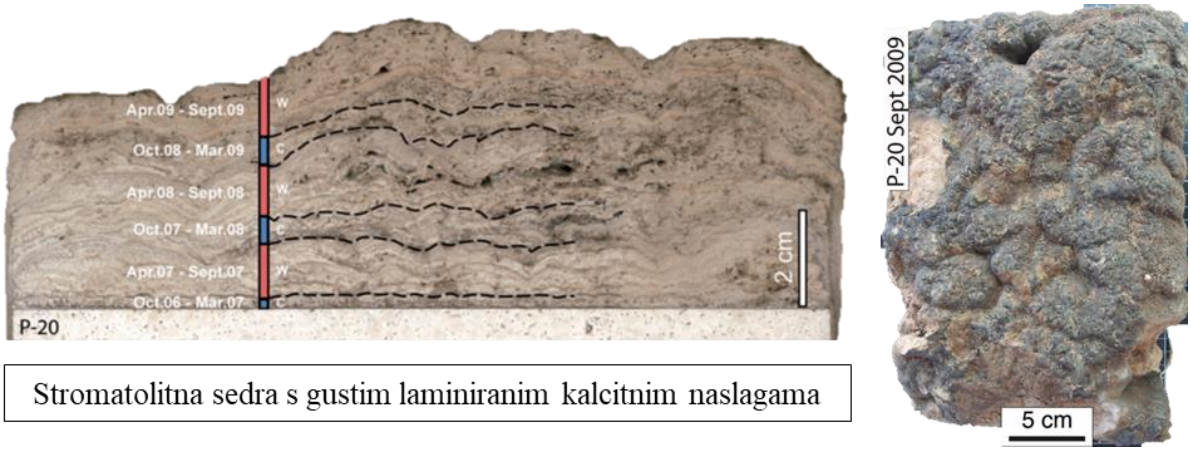

Slika 15. Primjer poprečnog presjeka stromatolitne sedre

Izvor: prema Arenas i dr., 2014.

Na vanjski i unutarnji izgled sedre u velikoj mjeri utječe struktura podloge (supstrata) koja je uglavnom sačinjena od ostataka raznih organizama (Kovač, 2020). Naime, razgradnjom organske tvari nastaju praznine, stoga precipitacijom na takvim podlogama nastaje šupljikava struktura (Kovač, 2020). Prema mineraloškom sastavu radi se isključivo o kalcitu (Tetkov, 2016, Liu, 2017, URL 7). Sadržaj drugih tvari (npr. Mg, Sr, Fe, Mn, P, organski spojevi) u slatkovodnim $CaCO_3$ precipitatima rijetko prelazi 10% (Kovač, 2020). Moguća je, iako rijetka, pojava magnezija, aragonita i ostalih mineralnih vrsta (Forbes i dr., 2010, Kovač, 2020). Ako u precipitatu ima oksida željeza oni potječu iz minerala koji voda mehanički troši (Kovač, 2020). Kristali izlučenog kalcita se razlikuju prema obliku, veličini i orijentaciji, međutim za njihovo proučavanje potreban je SEM (Slika 16).

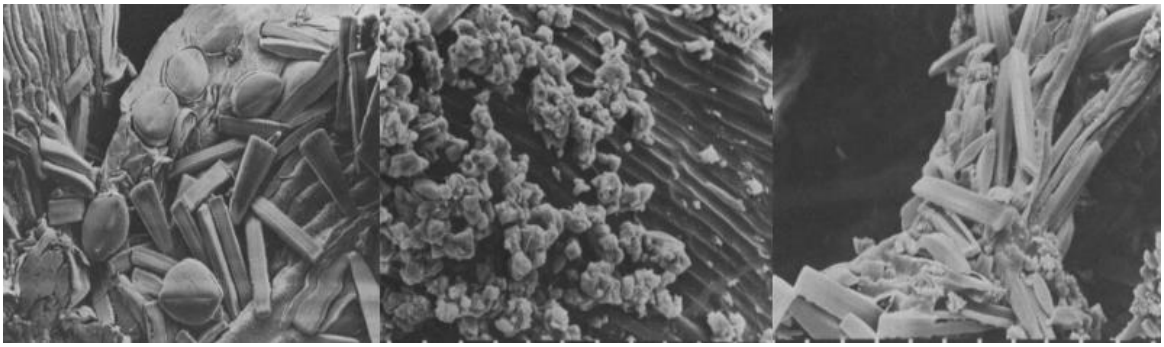

Slika 16. Kristali kalcita na ljepljivim površinama mahovina i cijanobakterija

Izvor: Emeis i dr., 1987

2.4.3 Značajke aktivnih sedrotvornih sustava

Mehanizmi formiranja sedre istraživani su od strane brojnih znanstvenika još od 1980-ih (Zhang i dr., 2001, Chen i dr., 2004). Nastanak sedre je dinamičan proces u kojem interaktivno djeluju klimatološki, geološki, hidrološki te biološki parametri (Primc-Habdija i dr., 2001, Vazquez-Urbez i dr., 2010, Špoljar i dr., 2011, URL 9). Većina istraživanja recentnih sedrenih sustava bavi se geokemijom stabilnih izotopa (Hori i dr., 2009), sedimentologijom (Drysdale i Gillieson, 1997, Gradziński, 2010) i hidrokemijom (Auqué i dr., 2013, Arenas i dr., 2014). Biološka istraživanja (Pedley i dr., 2009, Beraldi-Campesi i dr., 2012) fotosintetskih aktivnosti i djelovanja izvanstanične polimerne tvari (EPS[30]) (Pedley i Rogerson, 2010, Shiraishi i dr., 2010) su također vrlo česta. U tablici 5 pružen je pregled najvažnijih značajki nekih aktivnih sedrotvornih sustava.

[30] Extracellular Polymeric Substance

Tablica 5. Pregled obilježja nekih aktivnih sedrotvornih sustava

LOKACIJA (AUTORI)	KLIMATSKE ZNAČAJKE	MAX. STOPE SEDRENJA (prema tipu protoka)	MIN. STOPE SEDRENJA (prema tipu protoka)	EROZIJA	DINAMIKA SEDRENJA (toplo-hladno razdoblje)	BIOLOŠKI ČIMBENICI
Monasterio de Piedra, Španjolska, (Arenas i dr., 2010)	kontinentalna mediteranska klima, srednja godišnja temperatura 12°C, prosječne padaline oko 400 mm	brzo protočna voda, plitka i turbulentna vodena područja, stepenasti vodopadi	stajaća, sporo protočna voda, prskajuće zone	da	sedrenje veće u toplom (proljeće - ljeto) u odnosu na hladno (jesen - zima) razdoblje	zapažen utjecaj flore – oblikovanje facijesa sedre, visoke stope sedrenja u posljednjem hladnom razdoblju zbog razvoja flore (visoke temperature za to doba godine)
Rijeka Pierda, Španjolska (Arenas i dr., 2014)	kontinentalna mediteranska klima, srednja godišnja temperatura 12°C, prosječne padaline oko 400 mm	uvjeti brzog protjecanja i plitke vode	sporo protočna, stagnantna, duboka voda (*rastresita sedra*)	da	sedrenje veće u toplom (proljeće - ljeto) u odnosu na hladno razdoblja (jesen - zima)	veće temperature - razvoj flore i bakterija (algalna, spužvasta i mahovinasta sedra) - najveće stope sedrenja, njihova fiziološka aktivnost uvjetuje sezonske razlike u sedrenju
Rijeka Mesa, Španjolska (Auqué i dr., 2013)	mediteranska klima, srednja godišnja temperatura 13°C, prosječne padaline 410 mm	uvjeti brzog protjecanja >90 cm/s i plitke vode	veće dubine i smanjena brzina vode	da	sedrenje veće u hladnim (jesen - zima) u odnosu na toplo razdoblje (ljeto - proljeće)	lokacije najvećih stopa sedrenja - sediment sačinjen od filamentoznih algi povezanih s cijanobakterijama, mahovinama i dijatomejama koje čine poroznu sedrenu tkaninu
River Añamaza, Španjolska (Auqué i dr., 2014)	kontinentalna mediteranska, srednja godišnja temperatura 11°C, prosječne padaline 564 mm	brzina protoka i turbulencija vode determinira stope, brzo protočna voda	sporo protočna voda blizu izvora	da	sedrenje veće u toplom (proljeće - ljeto) u odnosu na hladno razdoblja (jesen - zima)	uz čimbenik otpuštanja CO_2, vrsta biološkog supstrata je prepoznata kao jedan od glavnih parametara koji utječu na dinamiku sedrenja
Louie Creek, Queensland, Australija (Drysdale i Gillieson, 1997)	sezonski vlažno tropsko područje, prosječne padaline 535 mm	visoko energetske hidraulične zone, snažan protok	stajaće vode, jezera, spor protok	da	-	korelacija najvećih stopa sedrenja s alohtonim biogenim materijalom (*larve, zelene prostirke algi* i *fitoklasti*)
Karpatsko područje, Slovačka i Poljska (četiri lokacije) (Gradziński, 2010)	srednja godišnja temperatura 5,8 - 8,6 ºC, prosječne padaline 550 - 1000 mm	stope precipitacije veće u brzo protočnim vodama	stope precipitacije manje u usporenim uvjetima protoka	da, zabilježen maseni gubitak sedre između mjerenja	ne postoji univerzalni sezonalni trend, na nekim lokacijama izrazito i malo veće stope ljeti na nekim zimi	mikroorganizmi neophodni za učinkovitiji rast sedre (usporedba vapnenačkih i bakrenih testnih pločica)
Shirokawa, Japan	humidna suptropska, visoke	-	-	-	veće stope u razdoblju ljeto-jesen,	biomasa cijanobakterija (BM) nije ključni

(Kano i dr., 2003)	temperature, jednolika distribucija padalina, prosječna temperatura 10 °C, prosječne padaline 1183 mm				niže u zima-proljeće, temperatura važan čimbenik	čimbenik kontroliranja godišnje laminacije, BM vrijednosti su veće u zimu i proljeće, kada je stopa precipitacije niska
Shimokuraida Japan (Kawai i dr., 2006)	-	stope precipitacije kontrolirane brzinom protoka (pozitivno koreliranje)	-	-	veće stope od ljeta do jeseni, manje od zime do proljeća, utjecaj temperature, sedra formirana (ljeto-jesen) ima gusto kalcificiranu strukturu, (zima-proljeće) poroznu strukturu	-
Baishuitai, Yunnan, JZ Kina (Liu i dr., 2010)	suptropska monsunska, srednja godišnja temperatura zraka oko 8ºC, prosječne padaline oko 750 mm (5-10 mjeseca kišna sezona)	-	-	-	jasan sezonski obrazac, niske stope u toplim kišnim razdobljima i visoke u hladnim sušnim razdobljima.	stope precipitacije i formacija laminacije su uglavnom kontrolirane klimatskim čimbenicima
Huanglong Ravine, Kina (Liu i dr., 1995)	klima Dwb, srednja godišnja temperatura 1,1º C prosječne padaline 739 mm	stope precipitacije su veće u brzo protočnim vodama (veće za faktor 4)	stope precipitacije manje u sporo protočnim i stajaćim vodama	-	-	-
Jiuzhaigou, Kina (Liu, 2017)	suha proljeća i zime, vlažne jeseni i ljeta, prosječne padaline 680 mm, srednja godišnja temperatura 6,8 ºC	brzo protočna voda, slapovi, visoke brzine strujanja i turbulencije (>120 cm/s)	područja vrlo niskog nagiba, sporog protoka vode i veće dubine	povećane količine dijatoma smanjuju otpornost eroziji	-	dijatome prepoznate kao dominantni mikroorganizmi koji sudjeluju u sedrenju, osobito na lokacijama slabijeg protoka
Falling Spring Creek, Virginia (Lorah i Herman, 1988)	-	povećano otplinjavanje CO_2 i prezasićenje kalcitom u blizini vodopada i turbulentnih voda	stope precipitacije niske ili nezabilježene unutar prvih 1120 m mirnog, sporo protočnog, glatkog toka	-	precipitacija kalcita se odvija tijekom cijele godine, najveće vrijednosti su zabilježene ljeti i u ranu jesen	biološki unos CO_2 od strane alge i mahovine ima neznatan učinak na precipitaciju karbonata u odnosu na velike količine anorganskog otpuštanja CO_2

Bad Urach, Njemačka (Merz-Preiß i Riding, 1999)	klima zapadne Europe s umjereno kontinentalna, hladna razdoblja, kišna uglavnom ljeti, srednja godišnja vrijednost padalina 834 mm	anorgansko otplinjavanje CO_2 glavni uzrok precipitacije, najveće na brzacima i slapovima	spori tokovi i jezera, niska razina CO_2 značajniji je utjecaj bakterija	-	prosječne stope precipitacije veće za 25 % u ljetnom razdoblju u odnosu na zimu	fotosintetski učinak mikroorganizama nema značajnu ulogu u brzim tokovima, ipak organski supstrat, mikrobne podloge i biofilm, favoriziraju precipitaciju kalcija osiguravajući pogodna mjesta za nukleaciju kalcita na EPS-u.
NP Monasterio de Piedra, Španjolska (Vazque-Urbez i dr., 2010)	kontinentalna mediteranska sa snažnim sezonskim kontrastima, srednja godišnja temperatura 12ºC, padaline 400 mm (max. u proljeće i jesen)	stope prirasta veće u područjima bržeg protoka i na stepeničastim slapovima	stope prirasta sporije u sporo protočnim i stajaćim vodama te na lokacijama prskanja i raspršivanja	da, (snažni protok, oluje, plavljenje) u svim fluvijalnim okruženjima	prirast (mm) sedre u toplijim razdobljima veći za 2,3 puta, masena bilanca veća za 6,6 puta u odnosu na hladna razdoblja	prirast uvjetovan fizikalno-kemijskim i biološkim procesima, mehaničko otpuštanje CO_2 glavni čimbenik kontrole precipitacije kalcita, flora je dominantna sedimentna komponenta, njezin fotosintetski učinak ne smije biti zanemaren
Huanglong Ravine, Kina (Zhang i dr., 2012)	klima Dwb, srednja godišnja temperatura 1,1ºC, prosječne padaline 739 mm	mjesta s većim protokom vode, utvrđena važnost hidrodinamike u kontroli stopa precipitacije	manje stope u sporijim tokovima, stagnantna voda	-	maksimalne vrijednosti stopa precipitacije od svibnja do kolovoza, minimalne vrijednosti od kolovoza do studenog	precipitacija kontrolirana uglavnom anorganskim kemijskim procesima, mikrobiološke aktivnosti mogu biti isključene

Gradziński (2010) navodi tvrdnju Pentecosta (1995) prema kojoj se većina sedre u Europi pojavljuje u područjima koje obilježava srednja vrijednost godišnje temperature između 5 i 15°C i srednja vrijednosti godišnjih padalina veća od 500 mm. U literaturi su kao neki od ključnih uvjeta formiranja sedre navedeni sljedeći parametri (Srdoč i dr., 1985, Špoljar i dr., 2011, Tetkov, 2016, Trpčić, 2016, Marguš, 2018):

1) prezasićenost $CaCO_3$ od $I_{zas\ ili}\ S_{Ic} > 3$;

2) koncentracija otopljene organske tvari ugljika (DOC[31]) niža od 10 mg L^{-1};

3) pH iznad 8 (u tokovima intenzivnije precipitacije između 8,2 i 8,4);

4) brzina strujanja vode od 0,5 do 3,5 m/s.

[31] Dissolved Organic Carbon

Zasićenost

Zasićenost vode s $CaCO_3$ je važan indikator mogućnosti nastanka sedre. Veće vrijednosti u pravilu znači da će doći do precipitacije. Tekstura sedre na takvim mjestima najčešće je kompaktna i kristalična (Liu, 2017). U prirodnim uvjetima kalcit ne precipitira odmah nakon početne zasićenosti. Laboratorijska i terenska istraživanja su pokazala da se mora postići kritičan stupanj zasićenosti (Zhang i dr., 2001). Do homogene nukleacije dolazi samo ako je indeks zasićenja iznad 10. U prirodi (u vodi) odvija se heterogena nukleacija u prisutnosti anorganskih ili organskih katalizatora, pa do taloženja dolazi i kod znatno manjih indeksa zasićenja. Nukleacijska barijera[32] se potom savladava i dolazi do precipitacije (Zhang i dr., 2001). Nadalje, niske količine hranjivih tvari otopljenih u vodi pogoduju formiranju sedre, a okruženje alkalne vode precipitaciji $CaCO_3$.

Brzina vode

Brzina vode je jako bitan faktor u nastanku sedre zbog svoje erozijske i taložne djelatnosti. Može varirati na dnevnoj i sezonskoj razini ovisno o hidrometeorološkim utjecajima i prirodi slivnog područja (Chapman, 1996). Matoničkin i Pavletić (1960) navode da je za razvoj i opstanak sedrotvoraca optimalna brzina vode od 0,5 do 1,5 m/s. Marguš (2018) navodi da se s povećanjem brzine do 100 cm/s povećava i količina istaložene sedre. Brzina vode veća od 3,5 m/s dovodi do potpunog odnošenja organizama (Šargaš, 2010). Pri takvim brzinama na bokovima i dnu otvorenih vodotoka ne postoje uvjeti za naseljavanje biljnih i životinjskih vrsta koji igraju važnu ulogu u formiranju sedre (Bonacci i dr., 2017). Optimalna brzina vode za mahovine iznosi između 1 i 2,5 m/s (Bulat, 2010). Brzina strujanja vode uvjetuje tri fizička procesa: pričvršćivanje, prijenos hranjivih čestica i otplavljivanje. Prirast sedre u pravilu je veći na lokacijama bržeg protoka vode (Arenas i dr., 2010, Auqué i dr., 2013, Arenas i dr., 2014). Naime, visoke brzine strujanja i turbulencija vode povećavaju otpuštanje CO_2 što pogoduje precipitaciji $CaCO_3$ (Liu, 2017). Uvjeti protjecanja vode kontroliraju precipitaciju koje je uglavnom veće u plitkim, brzo tekućim vodama (Arenas i dr., 2014). Međutim, visok i nagli protok vode (uzrokovan velikim padalinama) ponekad može izazvati fizičku eroziju precipitata te razrjeđivanje riječne vode. Stoga preokret u sezonskom obrascu brzine taloženja može biti indikator erozije i izuzetnih hidroloških uvjeta (Arenas i dr., 2014). Mnoge rijeke su zasićene kalcitom no sedra se obično formira na preprekama, barijerama i vodopadima. Fizičke promjene tokova su uglavnom odgovorene za njeno formiranje. One mogu uzrokovati pojavu efekta aeracije *(*eng. *aeration*), jet-flow (eng. *mlazni tok*) i tlak niskih voda (eng. *low-water*

[32] „Točka“ u kojoj spoj vidljivo mijenja svoju termodinamičku fazu

pressure effect) koji proizvode dvije osnovne promjene u fizikalnim uvjetima vode: veličinu dodirne površine vode i zraka te brzinu protoka. Povećanje oba stanja dovodi do brzog otplinjavanja CO_2 i precipitacije kalcita. Nadalje, kada se dodirna površina vode i zraka te brzina vode poveća, oni podižu pH otopine tako da se može dobiti višak slobodne energije. Nukleacijska barijera se prolazi i dolazi do precipitacije kalcita (Zhang i dr., 2001). Dakle, važnost abiotičkih čimbenika je izraženija u uvjetima bržeg toka vode, dok je u sporijim značajnija uloga biotičkih čimbenika.

U efektivnom sustavu precipitacije $CaCO_3$ koncentracija alkaliteta i kalcita se postupno smanjuju nizvodno niz tok (Arenas i dr. 2010). Razlike u hidrokemijskim podacima toplih i hladnih razdoblja jasno se mogu vidjeti uglavnom u kalciju i alkalitetu koji bilježe jači pad tijekom toplijih razdoblja (Arenas i dr., 2010). Naime, jedan od važnih uvjeta stvaranja sedre je izloženost svjetlosti koja određuje pojavu različitih tipova biocenoza (vegetacije svjetla ili sjene) koje se mogu naseliti na određeni slap (Belić, 2005, Bonacci i dr., 2017). Strukturu zajednice koja će se razviti na specifičnoj lokaciji uvelike uvjetuje količina svjetlosti. Tako će pri dovoljnim količinama svjetlosti dominirati mikroalge, dok će u prostorima smanjenih eufotičkih zona ili potpunog mraka dominirati veći udio heterotrofa. Navedeno je indikator intenzivnije precipitacije u toplim razdobljima (Arenas i dr. 2010, Arenas i dr., 2014). Periodičan uzorak viših vrijednosti stopa sedrenja u toplijim nego u hladnim razdobljima bilježi većina istraživanja (Kano i dr., 2003, Auqué i dr., 2013). Iznimke u uzorku se objašnjavaju erozijskim pojavama nastalima uslijed snažnih protoka, velike količine padalina, oluja itd. (Arenas i dr., 2010). Bonacci i dr. (2017) navode da se proces osedravanja u normalnim uvjetima ne odvija tijekom zime. Dakle, precipitacija je intenzivnija u toplijim razdobljima zbog izraženije fotosinteze, primarne proizvodnje, jačeg isparavanja i oslobođenja CO_2 te porasta pH-vrijednosti (Trpčić, 2016). Međutim, u nekim slučajevima (River Mesa) nije moguće uspostaviti uzročnu vezu između značajki precipitacije sedre i procesa koji se uobičajeno koriste u objašnjavanju varijacije stopa sedrenja (Auqué i dr., 2013).

Najprikladnija sedra za istraživanja sezonalnih promjena je ona koja ima laminirani facijes formiran u brzim vodenim područjima iz razloga jer ima najkontinuiraniji sedimentološki zapis s najvišim stopama prirasta (Arenas i dr., 2010). Uz navedene čimbenike, proces sedrenja ovisi o obliku i padu riječnih korita te hrapavosti površine (supstrata) na koji se sedra hvata (Belić, 2005).

2.4.4 Inhibitori sedrenja

Osedravanje je složen fizikalno-kemijski i biotički proces stvaranja organogenih karbotnatnih naslaga za koji su potrebne pogodna temperatura, dovoljne količine otopljenog bikarbonata, te odgovarajuća brzina strujanja vode (Tetkov, 2016). Njime nastaju sedrene barijere, jezera i slapovi koji predstavljaju jedinstvene prirodne vrijednosti. Ako dođe do poremećaja fizikalno-kemijskih i bioloških čimbenika proces rasta i razvoja sedrenih barijera je ugrožen (Liu, 2017). Sedrene tvorevine su zbog svoje uglavnom krhke strukture osjetljive na mehanička oštećenja i dinamička opterećenja. Iako bakterije, alge i mahovine generalno gledano imaju pozitivne učinke na proces sedrenja prekomjerne količine organske tvari, mutnoća te velike količine makrofita mogu djelovati kao inhibitori sedrenja (Matoničkin Kepčija i dr., 2018). Povećana koncentracija biljnog materijala (Slika 17) na sedrenim barijerama može svojom težinom ugroziti njihovu statiku što može rezultirati odlamanjem .

Slika 17. Izgled Skradinskog buka kroz povijest

Izvor: Gulin i dr., 2019., URL 50

Nadalje, prevelika gustoća vodenih makrofita direktno kontrolira brzinu protoka (Marguš, 2018) te može uzrokovati promjenu vodenih tokova što rezultira njihovim isušivanjem te u nekim slučajevima odlomljavanjem (Slika 18) (URL 11). Pojave odrona sedrenih barijera spadaju u njihovu normalnu fazu razvoja, ali ako istovremeno dođe do smanjenja vitaliteta ili potpunog nestanka sedrotovoraca, tad prognoze *zacjeljivanja* barijere nisu povoljne (Pevalek, 1956).

Slika 18. Odlomljen dio sedrene barijere Ciginovac/Okrugljak (NPPJ)

Izvor: URL 11

Povećana bujnost vegetacije veže se uz povećanu biološku produkciju. Zbog navedenoga potrebno je sustavno uklanjati prekomjernu vegetaciju (invazivno i više vodeno raslinje) duž sedrenih barijera (Matoničkin Kepčija i dr., 2018). Više biljke nisu baš pogodne kao supstrat za nukleaciju zbog toga što im listovi imaju voštanu hidrofobnu prevlaku. Stoga bujno razvijena vegetacija može sniziti pH oko svog korijenja što može uzrokovati otapanje kalcita, odnosno imati negativni utjecaj na sedru (Matoničkin Kepčija i dr., 2018). U istraživanju Miliša i dr. (2006) izvršeno je uklanjanje sedre na nekoliko lokacija na prostoru Plitvičkih jezera te je utvrđeno da to nije imalo posljedice na stope sedrenja. Osobito je štetno ako dođe do porasta organski otopljenih tvari (DOM[33]), izrastanja korijena vegetacije, prevelike brzine i snage toka čime se ugrožava stabilnost sedrenih barijera. Naime, poznato je da otopljene organske tvari sprječavaju izlučivanje kristala različitih soli, pa tako i one $CaCO_3$ (Habdija i Primc-Habdija, 2006). Prevelika količina organske tvari djeluje kao *omekšivač* te se smatra najjačim inhibitorom precipitacije $CaCO_3$ (Belić, 2005, Matoničkin Kepčija i dr., 2018, Kovač, 2020). Organski spojevi s kalcijevim ionima mogu u otopini stvoriti kelate i time smanjiti aktivnost kalcija (Kovač, 2020). Sviben (2012) navodi negativnu korelaciju između udjela nastale sedre i postotka organske tvari. Nadalje, povećane količine otopljene organske tvari mogu ubrzati proces eutrofikacije. Eutrofikacija je proces obogaćivanja vode hranjivim tvarima koje potiču rast različitih vrsta vodenih biljaka (više vodene biljke, ljutak, trska) (Belić, 2005) što može rezultirati pojavom cvjetanja algi (URL 42), odnosno nastanka štetnih i gustih fitoplanktonskih nakupina koje mogu smanjiti kvalitetu vode (Soloviy i Malovanyy, 2019). Cvjetanje algi predstavlja nagli porast koncentracije fitoplanktona. Uglavnom se javlja sezonski kada voda postaje bogata hranjivim tvarima, stvarajući idealno okruženje za njegovu

[33] Dissolved Organic Matter

produktivnost. Pod odgovarajućim uvjetima cvjetanje algi može trajati od jednog tjedna do cijelog ljeta unatoč kratkom životnom vijeku fitoplanktona. Jedan cvat traje samo jedan do dva tjedna, jer populacija fitoplanktona umire uslijed nedostatka hranjivih sastojaka. Međutim, ako su vodni uvjeti povoljni, može doći do uzastopnih cvjetanja što je čini kao jednu neprekidnu populaciju. Najčešće se odvija u kasno ljeto i ranu jesen (URL 42). Na slici 19. prikazan je primjer cvjetanja algi na području RS.

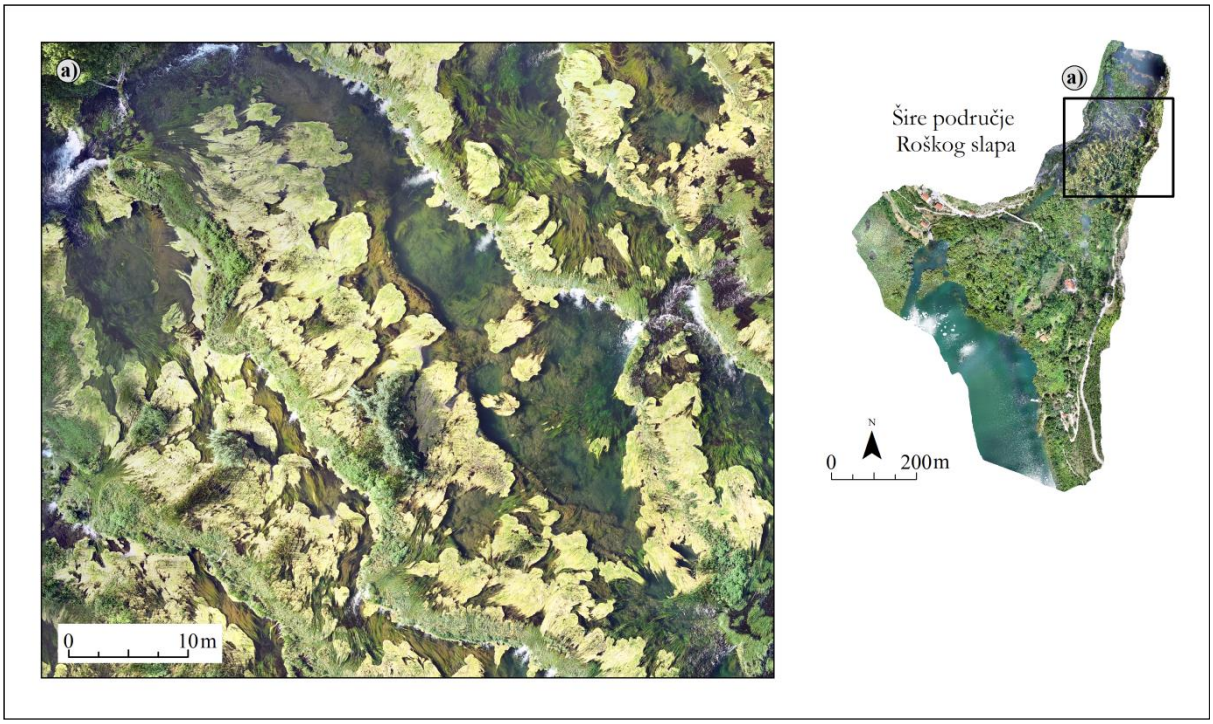

Slika 19. Primjer cvjetanja algi na Roškom slapu

Povećane koncentracije organske tvari se posredovanjem mikroorganizama postupno razlažu na jednostavnije spojeve što generira hranjivu podlogu za daljnji razvoj razne vegetacije. U konačnici može doći do pretjeranog zaraštavanja rubnih obalnih zona tokova i jezera što može izazvati smanjenje dubine, promjenu smjera otjecanja toka (Horvatinčić i dr., 2006), smanjenje energije protoka vode i povećanje proizvodnje organskih tvari.

Odumiranjem i otpadanjem makrofita dolazi do njihove razgradnje na sedrenim barijerama što može uzrokovati izražene fizikalno-kemijskih promjena u vodi (povećana razina CO_2, snižavanje pH, koncentracija hranjivih soli). Te kemijske promjene mogu izazvati značajne promjene u osedravanju i trofiji (Matoničkin Kepčija i dr., 2018). Istraživanja su pokazala da je povećana koncentracija DOC doprinijela zaustavljanju sedrenja na Plitvičkim jezerima (Horvatinčić i dr., 2006, Miliša i dr., 2006), zbog čega je, između ostalog, Uprava NPPJ počela uklanjati prekomjernu vegetaciju na sedrenim vodotocima (Miliša i dr., 2006). Također, za isto područje je dobro dokumentirana povećana biomasa fitoplanktona (Miliša i

dr., 2006). Postoji i antropogeno uvjetovana eutrofikacija (Horvatinčić i dr., 2006, Miliša i dr., 2006).

Sedrotvorci su vrlo osjetljivi na gibanje i dostupnost vode. Za potrebe rasta sedrenih barijera važna je nesputanost vodotoka, osobito za vrijeme niskih voda. Samo nesputani vodotoci mogu dovesti do povišenja cjelokupne sedrene barijere. Osjetljivost sedrotvoraca je toliko velika da oni kod znatnijih promjena toka brzo uginu, kod manjih promjena stagniraju određeno vrijeme te onda uginu. Nadalje, kobno u procesu sedrenja može biti i situacija da za vrijeme najvećih aktivnosti sedrotvoraca vode budu izrazito niske (Pevalek, 1956). Promjena smjera otjecanja i snage vodnog toka može biti uzrokovana akumulacijom i sedimentacijom palog granja i lišća na specifičnoj lokaciji unutar vodnog toka. Time se blokira protok vode kroz korito. S obzirom na to da je nacionalni park definiran kao prostor posebne zaštite gdje su ljudske intervencije ograničene, često se dopuštenje za intervenciju ne može osigurati, što u NPK može rezultirati preusmjeravanjem otjecanja vodenog toka ovisno o konfiguraciji terena.

Kao inhibitore sedrenja potrebno je istaknuti ione teških metala (Cu, Zn, Ni, Mn i dr.). Oni se ugrađuju i remete kristalnu rešetku kalcita tako sprječavajući njegovo odlaganje (Sviben, 2012). Od anorganskih inhibitora potrebno je istaknuti magnezij (Mg) i fosfat (P) (URL 7). Inače, prirodne vodene sustave obilježavaju izrazito niske koncentracije kontaminanata (tragovi metala) te su vrlo osjetljivi na antropogeni utjecaj (Cukrov i dr., 2008). Zbog toga voda koja je zasićena s $CaCO_3$ ne mora nužno precipitirati sedru ako u njoj postoje inhibitori koji sprječavaju taj proces. Oni mogu biti fosfati (polifosfati), neki drugi ioni i organske tvari (Trpčić, 2016). Inhibitorsko djelovanje ima i humusna kiselina koja se veže na aktivna mjesta rasta površine kristala remeteći sedrenje (Sviben, 2012).

Atraktivni sedreni krajobrazi su popularna odredišta turista zbog čega se suočavaju s neočekivanim problema. Porast broja turista dovodi do smanjenja kvalitete vode te gaženja precipitata što povećava pritisak na opstanak sedrenih krajobraza (Dreybrodt i dr., 1997, Liu, 2017). Organske i hranjive tvari unijete od strane kupača i turista mogu utjecati na formiranje sedre. Ipak, taj dotok tvari u pravilu je zanemariv u odnosu na ukupan prirodni dotok. Primjerice, broj kupača uzvodno od SB je mali te su im aktivnosti ograničene na malobrojna kupališta. Njihov utjecaj nizvodno je također zanemariv, ali isključivo iz razloga jer je u tom dijelu toka Krka formiranje sedre irelevantno (Marguš, 2018).

2.4.5 Važnost fizikalno-kemijskih obilježja vode u procesu sedrenja

Prema mjerenjima kakvoće vode od 1998. do 2002. voda se neposredno prije ulaska u Park svrstava u I do III kategorije, a prema trofičkom smislu spada od oligotrofne do mezotrofne vode. Unutar samog područja Parka voda Krka je oligotrofna (niska razina nutrijenata) (Marguš, 2018).

Sedrotvorni kompleks NPK rezultat je sinergističkog djelovanja brojnih bioloških, kemijskih i geoloških procesa. Fizikalno-kemijska obilježja vode samo su jedan skup parametara koji utječu na proces sedrenja. Očuvanje kakvoće vode rijeke Krke i procesa sedrenja je postavljen kao dugoročni cilj upravljanja Parkom. Kakvoća, odnosno kvaliteta vode se odnosi na kemijske, fizičke, biološke i radiološke karakteristike vode. Predstavlja mjeru stanja vode u odnosu na specifičnu svrhu ili potrebe jedne ili više biotskih vrsta. Procjena kakvoće vode sastavni je dio istraživanja složenog sedrotvornog ekosustava (Auqué i dr., 2013, Arenas i dr., 2014, Arenas i dr., 2010, Belančić i dr., 2009, Horvantinčić i dr., 2006, Cukrov i dr., 2008, Kano i dr., 2003). Kakvoća vode se utvrđuje na temelju analize fizikalno-kemijskih parametara (Patil i dr., 2012). Neki fizikalno-kemijski čimbenici uključuju temperaturu vode, boju, dubinu, prozirnost, pH, količinu otopljenog kisika u vodi (DO[34]), zasićenje vode kisikom (%), električnu vodljivost (EC[35]), ukupne otopljene tvari (TDS[36]), salinitet, alkalitet, nitrate i nitrite (Ridl, 2015, Matoničkin Kepčija, 2014, Arenas i dr., 2010, Forbes i dr., 2010). Odabir parametara za ispitivanje kvalitete vode ovisi isključivo o ciljevima istraživanja (Chapman, 1996). Primjerice, pH vrijednosti vode moraju biti veće od 8, kako bi se zadovoljio samo jedan od preduvjeta nastanka sedre, dok povećane količine otopljenih organskih tvari inhibiraju proces sedrenja (Pribičević i dr., 2010).

Dugoročno praćenje kvalitete vode unutar NPK omogućuje da se pravovremeno djeluje ako se uoče promjene u tom osjetljivom ekosustavu. Neke od negativnih promjena fizikalno-kemijskih obilježja vode u kontekstu opstanka sedrotvornih zajednica uključuju: povećanje temperature vode, smanjenje vrijednosti pH, smanjenje koncentracije otopljenog kisika te povećanje količine toksičnih produkata. One stvaraju nepovoljne uvjete za razvitak tvorbenih zajednica na barijerama čime se cjelokupni proces rasta barijera dovodi u pitanje.

Prema Uredbi o standardu kakvoće voda (NN 96/2019) izvor rijeke Krke je kategoriziran kao voda vrlo dobrog ekološkog stanja (Grgić i Redžović, 2016). Neovisna

[34] Dissolved Oxygen
[35] Electrical Conductivity
[36] Total Dissolved Solid

ispitivanja su na nekoliko lokacija pokazala da je voda NPK bogata DO, dok je svaka kratkotrajna mutnoća prirodna posljedica podizanja sedimenata uslijed temperaturnih razlika vode na specifičnim mikrolokacijama ili bujičnih tokova nakon velikih padalina.

Stručnjaci *Odjela za biologiju Prirodoslovno-matematičkog fakulteta* Sveučilišta u Zagrebu i Instituta Ruđer Bošković su 22. srpnja 2019. godine proveli analize kakvoće vode u NPK. Utvrdili su da je kvaliteta vode izvrsna, u skladu sa svim važećim propisima, te je potvrđeno da na predmetnom području ne postoji onečišćenje rijeka. Analizom je utvrđeno da voda u NPK ne sadrži teške metale, otrovne tvari ili fekalne bakterije u koncentracijama i količinama koje bi mogle potencijalno ugroziti čistoću vode i ekosustave povezane s njom. Na mjestima sa značajnom biološkom aktivnošću izmjerene su najviše vrijednosti *klorofila a* i primijećene su visoke vrijednosti DO što potvrđuje da nije došlo do značajnije razgradnje organske tvari (URL 44).

2.4.6 Važnost bioloških čimbenika u procesu sedrenja

Vidljiva povezanost biota (biljke, životinje, gljive i bakterije) i sedre proizvela je širok niz istraživanja o ulozi flore i faune u procesu formiranja sedre (Lyons i Kelly, 2016). Točna uloga biota u procesu nastanka sedre još uvijek nije potpuno razjašnjena (Matoničkin Kepčija i dr., 2006). Općenito, njihova uloga može biti podijeljena na fizikalne i kemijske učinke (Chen i dr., 2004, Liu, 2017). Fizikalni učinci organizama uključuju: inkrustaciju[37] (eng. *encustration*), hvatanje i vezivanje (eng. *trapping and binding*), asimilaciju (eng. *assimilation*), nukleaciju (eng. *nucleation*) i izlučivanje (eng. *secretion*) (Chafetz i Folk, 1984, Emeis i dr., 1987, Viles i Goudie, 1990). Međutim, fizički učinci ne mogu dovesti do toga da voda bude prezasićena $CaCO_3$ što je glavni preduvjet precipitacije. Kemijski učinak uglavnom leži u fotosintezi kojom se uzima CO_2 iz vode te time izaziva prezasićenost (Chen i dr., 2004).

U literaturi je stoga predloženo nekoliko mehanizama precipitacije kalcita, od isključivo abiotičkih do biotičkih (Viles i Pentecost, 2007). Abiotička fizikalno-kemijska kontrola precipitacije je poticana kroz otplinjavanje CO_2 iz vode što dovodi do pasivne kalcifikacije organskih i anorganskih supstrata (Manzo i dr., 2012). Neki mehanizmi zauzimaju srednje stavove objašnjavanja formiranja sedre mješavinom abiotičkih i biotičkih procesa (Ford i Pedley, 1996, Merz-Preiß i Riding, 1999, Arp i dr., 2001) uz istaknutu, ali ne ključnu ulogu biofilma[38] (Pedley i dr., 2009, Manzo i dr., 2012). Predstavnici abiogenetskog

[37] Inkrustacija ili oblaganje organizma ili pojedinih njegovih dijelova anorganskom ili organskom tvari. Javlja se u živih (npr. očvršćivanje oklopa) ili uginulih organizama (tijekom fosilizacije).
[38] Biofilm predstavlja zajednicu mikroorganizama koji su ireverzibilno povezani sa površinom.

mehanizma ne smatraju biljke bitnim ili čak u potpunosti zanemaruju njihovu ulogu u precipitaciji $CaCO_3$. Tako je u nekim istraživanjima primjenom bakrene podloge dokazano da se precipitacija može dogoditi bez prisustvovanja organizama (Carthew i dr., 2003). S obzirom na to da su bakrovi ioni otrovni za niže organizme jasno je da njegove površine ne mogu biti obrasle s algama i cijanobakterijama Kovač, 2020).

Ranije se djelovanje organizama povezivalo s isključivo fotosintetskom aktivnošću. Ipak terenska i laboratorijska istraživanja sa SEM-om su pokazala da biljke i mikroorganizmi imaju drugu važnu ulogu u formiranju sedre (Zhang i dr., 2001). Utvrđeno je da su kristali precipitata prepuni šupljina različitih veličina. Te šupljine potječu od vlakna biljaka ili cijanobakterija, a uglavnom prolaze kroz središnji dio kristala. Takav položaj šupljine pretpostavlja kontrolu rasta koju vrši organizam (Carthew i dr., 2003). Dakle, one ključnu ulogu igraju u stvaranju i oblikovanju mikrookoliša u kojem dolazi do precipitacije. Naime, iako ne mogu značajno mijenjati geokemiju ukupnog riječnog toka one značajno utječu na neposredno okruženje u kojem se precipitacija odvija (Cukrov i dr., 2010).

U istraživanjima dinamike sedrenja se stoga često stavlja naglasak na praćenje dinamike kolonizacije perifitona (eng. *periphyton*). Primc-Habdija i dr. (2001) navode da mehanizam precipitacije kalcita još uvijek nije u potpunosti objašnjen, ali da je sedra proizvod fizikalno-kemijske i biogene precipitacije povezane s kolonizacijom perifitona (Pedley, 1994, Ford i Pedley, 1996). U *Planu upravljanja NPK* jedna od glavnih aktivnosti akcijskog plana 8 je utvrđivanje dinamike kolonizaciju perifitonskih zajednica te utvrđivanje veza između sezonske strukture perifitonskih zajednica i intenziteta taloženja. Perifiton ili obraštaj su epifitski[39] vodeni mikroorganizmi koji posredno pomažu u stvaranju debljih naslaga $CaCO_3$, odnosno čine matricu sedre (Tetkov, 2016, Matoničkin Kepčija i dr., 2017, Kovač, 2020). Predstavlja složenu zajednicu primarno autotrofnih (cijanobakterije i neke alge) (Freytet i Verrecchia, 1998) i heterotrofnih (beskralježnjaci, praživotinje, gljive i bakterije) organizama, mineralnih čestica, detritusa (neživa organska tvar) te ekstracelularnog matriksa, koji se razvija na supstratu (biotičke ili abiotičke prirode) privremeno ili stalno uronjenima u vodu (Šargač, 2010). Biomasa perifitona na podlogama rasta može značajno varirati. U početnom razdoblju, koja se naziva faza prirasta, se kroz kolonizaciju i rast biomase perifiton značajno povećava te može postići maksimum kroz nekoliko dana pa do nekoliko mjeseci. Ona ovisi o dostupnom svjetlu, hranjivim tvarima i drugim čimbenicima. Nakon rasta nastupa faza gubitka koja se

[39] Epifit je biljka koja raste neškodljivo na drugim biljakama. Od parazita se razlikuju prema tome što rastu na drugim biljkama isključivo zbog fizičke podrške, ne utječući nužno na domaćina. Tzv. „zračne biljke“, koje ne puštaju svoje korijenje u tlu.

javlja uslijed odumiranja jedinki, odljepljivanja s podloge uslijed intenzivnijeg djelovanja vode, emigracije ili intenzivnije ispaše (Moschini-Carlos i dr., 2000).

Eksperimentalni dokazi su pokazali da fotosintetske aktivnosti biljaka čine mali doprinos u procesu formiranja sedre dok su dominantna pokretačka snaga, osobito u brzim fluvijalnim okruženjima, abiotički čimbenici koji potiču prozračivanje vode (Zhang i dr., 2001, Chen i dr., 2004). Najniže stope otpuštanja CO_2 su najmanje 10 puta veće nego najbrže stope apsorpcije CO_2 kod algi. Stoga, kemijska (fotosintetska) aktivnost ne može biti glavni uzrok formiranja sedre na mjestima brzog protoka vode, iako i ona može igrati važnu ulogu u precipitaciji kalcita tamo gdje je voda spora ili stagnantna (npr. voda u jezeru) (Cheng i dr., 2004). Njihov učinak ne može značajno kemijski utjecati na proces precipitacije $CaCO_3$ (Cukrov i dr., 2010). Navedeno se može provjeriti kroz varijacije pH vrijednosti. Naime, mnoge bakterije imaju metabolični učinak koji stimuliraju stvaranje kalcijevog karbonata, ali povoljni ambijentalni uvjeti su potrebni za pojavu precipitacije (Merz-Preiß i Riding, 1999). Odsustvo jasnih dnevnih varijacija u pH pokazuje da fotosintetski unos CO_2 organizama, koji bi se trebao povisiti tijekom dana, ima u pravilu mali učinak (Merz-Preiß i Riding, 1999). Primjerice, hidrokemijski podaci ukazuju da je precipitacija sedre u Deinschwanger Bachu uzrokovana fiziokemijskim otplinjavanjem CO_2. Nema dokaza značajnijeg utjecaja fotosintetske fiksacije CO_2 na karbonatnu ravnotežu (Arp i dr., 2001). Dakle s obzirom na njihovu obilnost smatralo se da je cijanobakterijsko uzimanje CO_2 trebao biti najčešći proces koji je uključen u biološku induciranu precipitaciju. Međutim izneseno je mnogo dokaza prema istaknutoj ulozi egzopolimera, odnosno EPS-a u procesu formiranja sedre (Pedley i dr., 2009) koja može dovesti do organomineralizacije, odnosno kalcifikacije ekstracelularnog matriksa (Matoničkin Kepčija i dr., 2017). Pedley i dr. (2009) su zaključili da je proces formiranja sedre usko povezan s EPS-om proizvedenim od prokariotskog mikrofitnog (cijanobakterije, alge, dijatomeje) biofilma. Naime, neki predstavnici spužvi, mekušaca, algi, člankonožaca imaju izlučen kalcit ili aragonit u tkivu s ciljem povećanja njegove čvrstoće (Kovač, 2020).

Istraživanjima na Plitvicama (Emeis i dr., 1987, Golubić i dr., 2008) utvrđeno je da mikroorganizmi (cijanobakterije i dijatomeje) prerastaju ne-fotosintetske stabljike mahovine te razne ostatke. Sluzne izlučevine tih mikroorganizama formiraju ljepljivu podlogu time zarobljavajući kristale kalcita koji djeluju kao mjesta nukleacije na kojima se odvija daljnja formacija, dok male nevaskularne biljke (eng. *bryophytes*) daju arhitektonski (okvir) skelet za taloženje (Lyons i Kelly, 2016). Dakle, organizmi mogu pomoći u taloženje sedre kroz hvatanje i vezivanje čestica $CaCO_3$ te kroz fotosintezu, odnosno apsorpcijom CO_2 iz vode (Chen i dr., 2004, Liu, 2017). S obzirom na važnost sedrotvoraca (alge, bakterije, mahovine i drugi

organizmi) u procesu formiranja sedre, ona se još naziva i *živi kamen* (Trpčić, 2016). Ona sedra koja ima pozitivne stope prirasta te je prekrivena sedrotvornim organizmima naziva se *živa sedra*. Po njoj voda lagano protječe zahvaljujući elastičnom živom pokrovu. *Mrtva sedra* je ona na kojoj više nema živih sedrotvoraca, nije prekrivena elastičnim živim pokrovom, vodi pruža veliki otpor te ima negativne ili uopće ne bilježi stope prirasta. Takva sedra lako erodira (Pevalek, 1956).

Formiranje organske podloge koja uključuje mikrobiološki tepih značajno lokalizira precipitaciju zbog osiguranog početnog položaja (Cukrov i dr., 2010). Naime, inicijalno formiranje hrapave površine sedre dalje stvaraju kompleksnija mikrostaništa omogućujući time masovni razvoj algi. Uz navedeno, osedreni perifitonski matriks postaje otporniji na erozijsko djelovanje vode (Matoničkin Kepčija i dr., 2017). Nadalje, Manzo i dr., (2012) u istraživanju pokazuju da do precipitacije neće doći ako je biofilm odsutan. Dakle, rast algi i mahovina na mjestima zapreka ili postavljenim umjetnim podlogama mogu osigurati supstrate za nukleaciju kalcita te mogu uhvatiti detritalni kalcit ubrzavajući time taloženje sedre. One neizravno pomažu kroz hvatanje mikročestica kalcita te osiguravanjem podloge (supstrata) za njih rast (Zhang i dr., 2001).

U procesu stvaranja sedre važnu ulogu igraju modrozelene alge (eng. *cyanobacteria*), posebno vrsta *phormidium crustatum* (Davis i dr., 1989), razne bakterije, alge kremenjašice (*diatomeae*), jednostanični (*protozoa*) i višestanični organizmi mikroskopske veličine. Oni su životna zajednica koja se uglavnom razvija na predmetima koji obitavaju u vodi. Na tvari koji oni luče lijepe se mikrokristali kalcita, koji potom predstavljaju daljnja mjesta kristalizacije oko kojih precipitira kalcijev karbonat iz vode. Pedley (2000) ističe da makrofiti zauzimaju značajnu ulogu u depozicijskom okviru sedre (Matoničkih Kepčija i dr., 2006). Mahovina koja najčešće sudjeluje u stvaranju sedre je *palustriella (cratoneuron) commutata* (Heery, 2007, URL 10) (Slika 20).

Slika 20. Utjecaj mahovina iz roda *Cratoneuron* u formiranju sedre RH (NPPJ)

Izvor: URL 5

Emeis i dr. (1987) ističu nekoliko faza formiranja sedre djelovanjem različitih organizama (Slika 21). Prva se donosi na nakupljanje, odnosno naseljavanje mahovina na neku podlogu. Potom se na površini mahovina talože epifiti (dijatomeje i cijanobakterije) (Emeis i dr., 1987) koji omogućuju heterogenu kristalizaciju (Kovač, 2020). Naime, mikroorganizmi biljnog podrijetla imaju sposobnost lučenja galerte (sluz) za koju se hvataju mikrokristali kalcita i stvaraju jezgre oko kojih se potom taloži sedra (Matoničkin Kepčija, 2019). Proces sedrenja će uglavnom početi na onim površinama koje su obrasle epifitima s izlučivanjem ljepljive tvari na bazi polisaharida tj. mukopolisaharide koji dodatno stabiliziraju sediment. Kao centri kristalizacije mogu poslužiti organski i mineralni detritus, skeleti mikroorganizama te mikrokolonije bakterija (Chafetz i Folk, 1984, Kovač, 2020). Važna je uloga organizama jer osiguravaju supstrat za nukleaciju i djeluju na zarobljavanje kalcita, što povećava brzinu sedrenja. Međutim, to se događa samo kada se dosegne kritični stupanj supersaturacije (Zhang i dr., 2001).

Briofiti[40] zbog svojih preferencija prema brzo tekućoj vodi predstavljaju vrlo pogodan supstrat za precipitaciju sedre. Njezini filoidi (bilateralni, lisnati dijelovi) i rizoidi (bazalna ploča - prihvataljka) (Linardić, 1949) zarobljavaju detritus i time posreduju u procesu precipitacije (Špoljar i dr., 2011). Sljedeći korak se donosi na resuspendiranje mikritnih čestica

[40] Briofiti su botanički skupni naziv za mahovine.

s dna jezera uhvaćenih slinovitim nitima dijatomeja. Završni korak je precipitacija anorganskog kalcita kao sparita na mjestima nukleacije osiguranim kristalnim sjemenkama (eng. *crystal seed*) (Emeis i dr., 1987). Potrebno je istaknuti da organizmi (biljke, alge, bakterije, cijanobakterije, dijatomeje i mahovine) (Chen i dr., 2004) mogu i usporiti nastajanje sedre (Liu, 2017). Neki metabolički tipovi proizvode organske kiseline koje ubrzavaju otapanje $CaCO_3$. Diatome su jedne od takvih skupina koje imaju dvostruku ulogu u procesu (Liu, 2017).

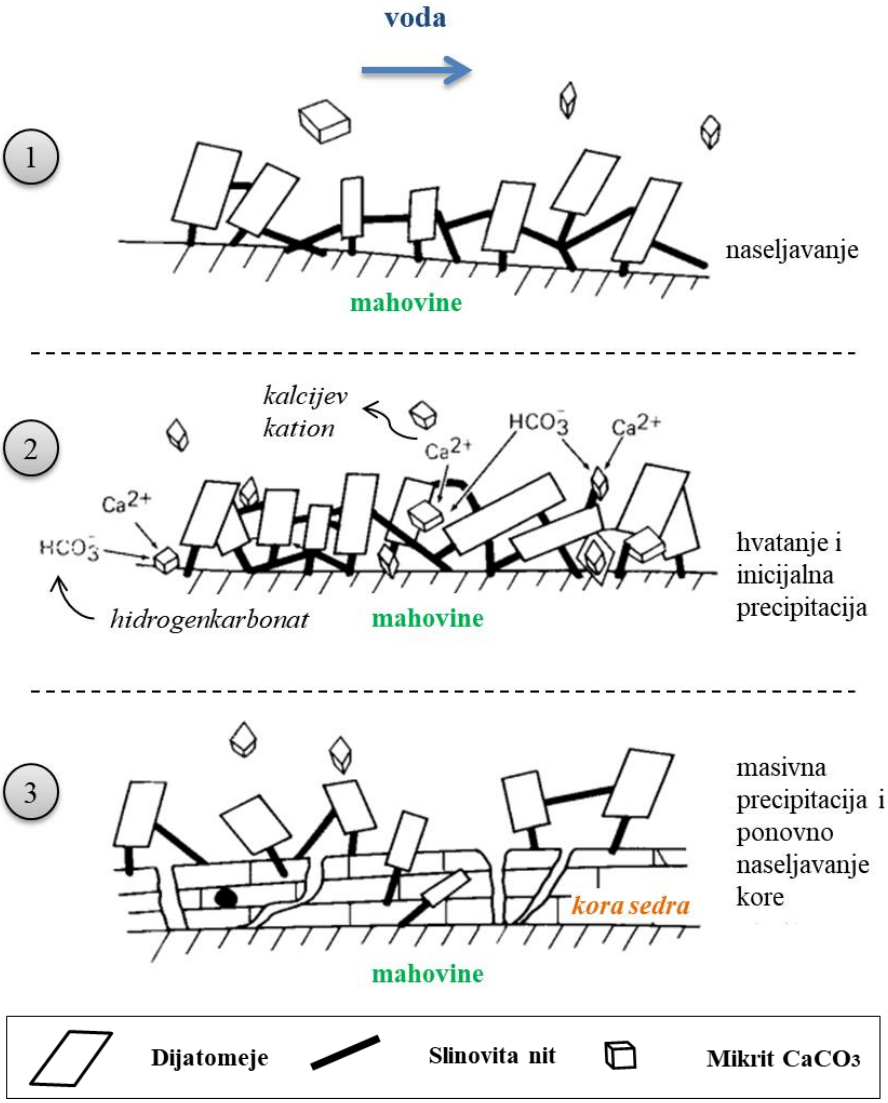

Slika 21. Faze inkrustacije mahovina organskim i anorganskim procesima tijekom stvaranja precipitata

Izvor: prema Emeis i dr., 1987

Uz alge i mahovine različiti životinjski organizmi sudjeluju u procesu formiranja sedrenih barijera (Bonacci i dr., 2017). Uz pionirsku vegetaciju postupno se mijenjaju i zajednice životinja (Bulat, 2010). Uglavnom se radi o reikofilnim životinjama koje grade

tvorevine kao što su kućice, cjevčice i tulce (Bonacci i dr., 2017). Prema veličini bentonski[41] organizmi se mogu podijeliti u tri veličine. U mikrobentos spadaju organizmi veličine manje od 0,063 mm, u meiobentos oni od 0,063 do 1,00 mm te u makrobentos veći od 1 mm. Najveća gustoća makrozoobentosa je u mahovini koja je idealno stanište zbog svoje heterogene uloge u vidu zaklona od strujanja vode, potencijalnog izvora hrane te zaštite od predatora (Grbavac, 2015). Od životinjskih organizama u doktorskoj disertaciji je djelomično detektiran makrozoobentos. Makrozoobentos su beskralježnjaci koji žive na dnu vodenih tijela, a osjetljivi su na okolišne uvjete čija se promjena može prepoznati u njihovoj strukturi i sastavuSlučajevi presušenja ili smrzavanja toka mogu dovesti do potpunog nestanka makrozoobentosa i cijelih biocenoza, međutim čim dođe do ponovne uspostave okolišnih uvjeta započet će proces doseljavanja (Bućan, 2016).

U procesu formiranja sedre dokazana je uloga makrozoobentosa kao što su ličinke tulara (*caddisflies*) iz različitih porodica koje naseljavaju vodeni okoliš, trzalca (eng. *chiromonidae*) te puževa (*gastropoda*) (Carthew i dr., 2003, Šikić, 2007, Kučinić, 2017) koje imaju sposobnost hvatanja i zadržavanja kristala kalcita putem svojih svilenih proteinskih izlučevina. Prema sudjelovanju pojedinih sedrotvornih životinjskih skupina razlikuje se hironomidna, gastropodna i trihopterska sedra (Matoničkin Kepčija i dr., 2006, Bulat, 2010,). Ličinke svakog od ovih obitelji insekata osiguravaju supstrat za precipitaciju kalcita i nakon toga postaju kalcificirane i ugrađene u naslage sedre. To značajno povećava primarnu poroznost i akumulacijske stope (Trpčić, 2016). Osim toga, ličinske konstrukcije fizički ometaju protok vode i povećavaju lokalnu (mikro) turbulenciju vode povećavajući time otpuštanje CO_2 (Carthew i dr., 2003). Dakle, uz prateće fizikalne, kemijske i geološke čimbenike sastav i gustoća biljnih i životinjskih zajednica ima veliku ulogu u procesu formiranja sedre (Trpčić, 2016).

2.4.7 Metode mjerenja dinamike sedrenja

Dinamika formiranja sedre i travertina je jedan od malobrojnih geoloških fenomena koji u realnom vremenom može biti uočen, mjeren i nadziran. Kinetika precipitacije $CaCO_3$ je temeljna za razumijevanje mnogih prirodnih geokemijskih sustava (Dreybrodt i dr., 1997). U istraživanjima dinamike formiranja sedre (TFD) nastoji se kvantificirati mehanizam precipitacije i stope formiranja sedre (TGR i TER). Stope formiranja sedre su u istraživanjima računate pomoću različitih metoda i tehnika (Viles i Pentecost, 2007). Precizno utvrđivanje

[41] Bentos je skupni naziv za sve biljne i životinjske organizme koji žive na dnu mora ili slatke vode.

dinamike sedrenja važno je iz nekoliko razloga. Za početak adresira se temeljno geomorfološko pitanje koliko brzo raste i evoluira pojedinačni element sedrenog krajobraza. Drugo, recentne stope sedrenja mogu se usporediti sa starijim, a utvrđene razlike mogu ukazati na važne promjene u okolišu (npr. degradacija sedrenja) (Liu i dr., 2011, Liu, 2017). Konačno, detaljno utvrđivanje dinamike sedrenja omogućuje bolje razumijevanje prostorno-vremenskih varijacija u sedrenju unutar različitih fluvijalnih sustava (Drysdale i Gillieson, 1997). Nadalje, proučavanje TFD-a stvar je velikog znanstvenog interesa zbog mogućnosti njihove upotrebe kao paleo-proxy podataka (Liu i dr., 2011, Vazquez-Urbez i dr., 2010, Arenas i dr., 2014), proučavanju globalnog ciklusa CO_2 (Dreybrodt i dr., 1997) te promjena u okolišu (Liu i dr., 2011, Liu, 2017). Brojna laboratorijska i terenska istraživanja su provedena kako bi se utvrdile eksperimentalne stope precipitacije $CaCO_3$. Većina tih istraživanja je usmjerena na izvođenje stopa precipitacija iz kemijskog sastava otopine na površini minerala (Dreybrodt i dr., 1997).

Potrebno je razlikovati prosječan rast sedrenih barijera od prirasta sedre na točkastim, pojedinačnim lokacijama, odnosno tek postavljenim umjetnim testnim uzorcima. Naime, prosječan rast barijere uključuje dvije suprotne komponente, brzinu taloženja sedre (+) te eroziju postojećeg hidroprecipitata (-) (Rubinić i dr., 2017).

Stope dinamike sedrenja mogu biti izražene kao visina formirane sedre prema jedinici vremena (npr. godina dana) (npr. mm a^{-1}) ili kao masa akumulirana na jedinici površine u nekoj jedinici vremena (npr. mg cm^2 a^{-1}). U pravilu se preferira prva varijanta izražavanja zbog velikih varijacija u poroznosti sedre i činjenici da se rast površine lakše konceptualizira (Drysdale i Gillieson, 1997). Nadalje, u sedru se često ugrađuju različite strane tvari kao što su mineralna zrna, biljni ostaci i lišće. Spomenute tvari nerijetko povećavaju masu sedre, stoga se ponekad njezine vrijednosti precjenjuju (Gradziński, 2010). Ispitivanje linearne (cm ili mm a^{-1}) ili volumetrijske (cm^3 ili mm^3 a^{-1}) stope rasta sedre u dugoročnim vremenskim intervalima je rijetko (Demott i dr., 2019).

U gotovo svim istraživanja TFD-a u zabilježena je vrlo velika varijabilnost u stopama što je rezultat specifičnih uvjeta taloženja, njihove prostorne raspodjele duž vodenog tijela te odabrane metode mjerenja (Arenas i dr., 2010, Arenas i dr., 2014, Auqué i dr., 2014) (Tablica 6). Stope prirasta sedre izražene kao povećanje visini unutar specifičnog vremena ne mogu biti izravno preračunate u maseni prirast zbog ekstremnih varijacija u njenoj poroznosti. Dakle, ne postoji jedinstven odnos između masenog prirasta i debljine/visine (eng. *thickness*) sedre. Odstupanja u vrijednostima rezultat su specifičnih razlika u teksturi i poroznosti (Gradziński, 2010).

U literaturi su korištene različite metode mjerenja i procjena stopa sedrenja od kojih su neke izdvojene u tablici 6. U starijoj literaturi najpotpuniji pregled stopa prirasta sedre su pružili autori Viles i Goudie (1990) koji navode velike varijacije u rasponu od oko <1 mm do oko 50 cm a^{-1}. Velika varijabilnost stopa prirasta (Pentecost, 2005, Demott i dr., 2019) je rezultat širokog spektra čimbenika: razlika u tipu proučavanog precipitata (sedra, travertin), korištenoj metodi mjerenja (izravne ili neizravne), broja uzoraka, prostornoj raspodjeli uzoraka duž tokova, specifičnih mikrookolišnih uvjeta te klimatskom području svijeta (Arenas i dr., 2014, Arenas i dr, 2010, Auqué i dr., 2014). Viles i Pentecost (2007) ističu da su unutar meteogenskih depozita izmjerene stope prirasta od < 1 mm a^{-1} do 0,5 m a^{-1}, s većinom brojem rezultata unutar nižih vrijednosti raspona. Dugoročnije procjene stopa prirasta daju slične rezultate 0,8-5 mm a^{-1} (Peña i dr., 2000). Stope do 1 m a^{-1} zabilježene su unutar termogenskih naslaga (Viles i Pentecost, 2007). Dakle, najveće stope ima travertin koji nastaje u vrućim ili geotermalnim izvorima (Heimann i Sass, 1989, Drysdale i Gillieson, 1997) kao što su izvori u Italiji i SAD-u (Drysdale i Gillieson, 1997).

Tablica 6. Pregled stopa prirasta sedre (mm a^{-1}) u svijetu

ID	STUDIJA SLUČAJA (AUTORI)	STOPA PRIRASTA SEDRE (mm a^{-1})	METODA MJERENJA
1	Monasterio de Piedra, Španjolska (Arenas i dr., 2010)	0,04-13,10	Modificirani mikro-erozijski metar (MEM) **Izravna metoda**
2	rijeka Pierda, Španjolska (Arenas i dr., 2014)	0,74-16,53 srednjak (7,86)	
3	rijeka Mesa, Španjolska (Auqué i dr., 2013)	srednjak 2	
4	rijeka Añamaza, Španjolska (Auqué i dr., 2014)	0,86-18,30 srednjak (5,51)	
5	Louie Creek, Australija (Drysdale i Gillieson, 1997)	0,19-4,38 srednjak (4,15)	
6	NP Monasterio de Piedra, Španjolska (Vázquez-Urbez i dr., 2010)	0,00-17,45 srednjak (7,52)	
7	Karpatsko područje, Slovačka i Poljska (Gradziński, 2010)	0,06-24,00 (426 dana)	Maseni prirast (eng. *mass increments* - MI) **Izravna metoda**
8	Huanglong Ravine, Kina (Liu i dr., 1995)	1,00-5,00	
9	Baishuitai, Yunnan, Kina (Liu i dr., 2010)	6,00-10,00	
10	Jiuzhaigou, Kina (Liu, 2017)	0,08-0,32	
11	Huanglong Ravine, Kina (Zhang i dr., 2012)	0,004 (10 dana)	
12	Krasnohorska and Drienovska špilje, Slovačka (Wróblewski i dr., 2017)	0.3	
13	Le Zitelle, Lazio, Italija (Pentecost i Coletta, 2007)	na nekim pločicama > 1 mm	
14	Glenasmole, IE (Statham, 1977)	oko 15,00	Igle za srašćivanje (eng. *accretion pins*) **Izravna metoda**
15	Špilje i rudnici, JZ Engleska (Baker i Smart, 1995)	0,018-0,201	Digitalni mikrometar (eng. *vernier caliper)* **Izravna metoda**
16	Istočne Alpe		

	(Tran, Rott & Sanders, 2019)	5 mm (max. vertikalna kalcifikacija)	
17	Schwäbische Alb, Njemačka (Irion i Müller, 1968)	0,6-7	
18	Checa, Španjolska (Weijermars i dr., 1986)	srednjak 40 (min. 10, max. 140)	
19	Nije navedeno (Wallner, 1934)	7-14	Skenirajući elektronski mikroskop (SEM) ili laserski pretražni konfokalni mikroskop (CLSM[42]) za pregledavanje prirasta kalcita na supstratima, mahovinama i biljnim fragmentima. **Izravna metoda**
20	blizu Aringsdorfa, Njemačka (Mägdefrau, 1956)	10-20	
21	Shirokawa, JZ Japan (Kano i dr., 2003)	1,5-4	
22	Bl. Erlangen-Nord, Njemačka (Schnitzer, 1974).	raspon od 0,6-7	
23	Deinschwanger Bach, Njemaćka (Arp i dr., 2001)	1,8	
24	Bad Urach, Njemačka (Merz-Preiß i Riding, 1999)	2,2	
25	Krka river, RH (Lojen i dr., 2004)	oko 1,5	
26	Plitvička jezera, RH (Chafetz i dr., 1994)	10,00-30,00	Hidrološki pristup (eng. *hidrological approach* - HA) **Neizravna metoda**
27	Plitvička jezera, RH (Kempe i Emeis, 1985)	oko 10,00	
28	rijeka Krka, RH (Rubinić i dr., 2017)	10,00-30,00	
29	Prošćansko jezero, HR (Zwicker i Rubinić, 2004)	oko 15,00	
30	jezero Kozjak, RH (Zwicker i Rubinić, 2004)	oko 5,60	
31	Westerhofer i Deinschwanger Bach, Njemačka (Arp i dr., 2010)	1,60-7,60	Maseni transfer ili bilanca (eng. *mass transfer* - MT) **Neizravna metoda**
32	Plitvička jezera, RH (Kempe i Emeis, 1985)	oko 2,00	
33	Huanglong Ravine, Kina (Yoshimura i dr, 2004)	1	
34	Checa, Španjolska (Weijermars i dr., 1986)	42	
35	Tartare Spring, središnja Italija (Bono i dr., 2001)	0,5	
36	Južna Poljska (Pazdur i dr., 1988)	1-10	Metoda izotopa (eng. *isotope dating*) **Neizravna metoda**
37	Oxfordshire, JI Engleska (Preece i Day, 1994)	0,13-0,54	
38	Hula Valley, Izrael (Heimann & Sass, 1989)	0,32	
39	English Midlands, središnja Engleska (Meyrick i Preece, 2001)	0,27-0,70	
40	St Germain-le-Vasson, Francuska (Limondin-Lozouet i Preece, 2004)	1,44-1,65	
41	Ruidera Pools, središnja Španjolska (Pedley i dr., 1996)	1,5-2,5	
42	Holywell Coombe, Ujedinjeno Kraljevstvo Velike Britanije i Sjeverne Irske (Kerney i dr., 1980)	0,49	
43	Winnemucca Dry Lake, SAD (Demott i dr., 2019)	srednjak (0,16) raspon 0,05-0,32	
44	Walker Lake, Nevada, SAD (Petryshyn i dr., 2012)	max. 0,39	
45	središnja Španjolska (Andrews i dr., 2000)	1,2-2,4	
46	Huanglong Ravine, Kina (Yoshimura i dr., 2004)	5	Geokronološki, povijesni podaci **Neizravna metoda**
47	River Mijares, Španjolska	0,80-5,00	

[42] Confocal Laser Scanning Microscopy

	(Peña i dr., 2000)		
48	Big Soda Lake, SAD (Rosen i dr., 2004)	>30,00	
49	Gordale Beck, North Yorkshire, Ujedinjeno Kraljevstvo Velike Britanije i Sjeverne Irske (Pentecost, 1978)	0,15- 8,00	
50	Gwynedd, GBR (Pentecost, 1978)	0,21-0,80	Različite metode
51	Miyako Island, Japan (Kano i dr., 2007)	4,3-9,8	u Gradziński, 2010.
52	Huanglong Ravine, Bathing špilja, Kina (Lu i Li, 1992)	max. 19	u Lu i Lyons, 2000.
53	Shimokuraida, Japan (Kano i dr., 2004)	3,8	u Kano i dr., 2007.
54	Shirokawa, JZ Japan (Matsuoka i dr., 2001)	3,8	u Kano i dr., 2007.
55	jezero Kozjak, RH (Srdoč i dr.,1985)	oko 13,50	u Zwicker i Rubinić, 2007.
56	Pavilion jezero, Kanada (Laval i dr., 2000)	0,03	u Demott i dr., 2019.
57	Pavilion jezero, Kanada (Brady i dr., 2009)	0,05	u Demott i dr., 2019.
58	Kelly jezero, Kanada (Soles i dr., 2012)	0,02-0,14	u Demott i dr., 2019.
59	Pyramid jezero, SAD (Benson i dr., 1996)	0,05	u Demott i dr., 2019.
60	Plitvička jezera, RH (Emeis i dr., 1987)	10	Nije navedeno
61	The Güterstein waterfall, Njemačka (Megerle, 2012)	1,00-3,00	

Dinamika formiranja sedre je u uglavnom praćena primjenom neizravnih metoda: metodom masenog transfera ili bilance (MT) (Jacobson i Usdowski, 1975, Kempe i Emeis, 1985, Herman i Lorah, 1988, Lorah i Herman, 1988, Dreybrodt i dr., 1992, Arp i dr., 2010) koja izračunava promjene u kemizmu vode između nizvodnih i uzvodnih lokacija (Heimann i Sass, 1989, Dreybrodt i dr., 1992, Dreybrodt i dr., 1997, Kano i dr., 2003, Chen i dr., 2004, Yoshimura i dr., 2004, Kawai i dr., 2009), ekstrapolacijom dnevnih laminacija (Okumura i dr., 2011, Okumura i dr., 2013), varijantama Plummer-Wighley-Parkhurst (PWP[43]**)** jednadžbe (Plummer i dr., 1978, Herman i Lorah, 1988, Dreybrodt i dr., 1992, Dreybrodt i dr., 1997, Kano i dr., 2003, Kawai i dr., 2006, Kano i dr., 2007, Kawai i dr., 2009, Arenas i dr., 2014) te **radiometrijskim datiranjem** (Pazdur i dr., 1988, Preece i Day, 1994, Petryshyn i dr., 2012). Nadalje, stope prirasta sedre su određivane na temelju drugih **geokronoloških** (slojevi sedre koji prekrivaju povijesna nalazišta) **podataka** (Pentecost, 1978, Liu i dr., 1995, Peña i dr., 2000, Rosen i dr., 2004, Yoshimura i dr., 2004), ali ti su izračuni podložni pogreškama uslijed naknadnih izmjena ležišta (erozija, dijageneza) (Viles i Gouide, 1990). Naime, sedra je vrlo podložna eroziji, a neki organizmi koji se mogu naći na naslagama sedre (npr. endolitske zeleno-plave alge) potpomognute vremenskim uvjetima mogu uništiti sedru (Viles i Goudie,

[43] PWP model (formula) predviđa brzinu taloženja kalcita u zasićenim tokovima.

1990). Nadalje, stope prirasta sedre su procjenjivane na temelju datiranih artefakata (npr. građevine i spomenici) koji su bili prekriveni sedrenim formacijama određenih debljina.

Najšire prihvaćena metoda izračuna stopa precipitacije je PWP jednadžba koja je prvotno razvijana za opisivanje otapanja kalcita (Kovač, 2020). Ona sumira sveobuhvatne laboratorijske podatke o otapanju i precipitaciji te omogućuje izračun brzine reakcije, ako su HCO_3^-, Ca^{2+}, H^+ poznati (Dreybrodt i dr., 1992). Model je nadograđivan nakon što je utvrđeno da postoji velika razlika u brzini precipitacije u nepokretnoj i turbulentnoj vodi (Kovač, 2020). Metodom masenog transfera ili bilance stope precipitacije kalcita duž tokova se određuju na temelju mjerenja promjena koncentracija u CO_2 i Ca^{2+} s udaljenosti (Jacobson i Usdowski, 1975, Dreybrodt i dr., 1992). Na temelju razlike ulaznih i izlaznih hidrokemijskih podataka izračunava se gubitka $CaCO_3$ u nizvodnom toku (Drysdale i Gillieson, 1997). Primjerice, Kempe i Emeis (1985) su na prostoru NPPJ utvrdili da se u prosjeku deponira 2 mm a^{-1} čvrstog karbonata na površini od 2 km^2. Iako pruža potencijalno korisne podatke ukupne procjene precipitacije uglavnom se oslanja na premalo podataka, pravi prekomjerne hidrološke pretpostavke te ignorira sezonske i prostorne varijacije ulaznih i izlaznih podataka (Drysdale i Gillieson, 1997). Stoga u nekim slučajevima ti rezultati nisu u skladu sa stopama izvedenim primjenom preciznijih metoda (Lorah i Herman, 1990). Prosječne stope rasta kvartarne, uglavnom holocenske, sedre procjenjivane su izotopnim datiranjem, uglavnom radiokarbonski (Gradziński, 2010). Ono predstavlja metodu određivanja starosti organskih tvari na temelju omjera atoma izotopa ugljika; stabilnog ^{12}C i nestablinog (radioaktivnog) izotopa ^{14}C. Naime, ^{14}C metodom se mogu datirati i uzorci anorganskog porijekla koji djelomično sadrže ^{14}C izotop. Time određivanje starosti sekundarnih karbonata (morski i jezerski sedimenti, sige i sedra) postaje moguće (Bronić, 2009). Navedene tehnike spadaju u neizravnu metodu određivanja prirasta sedre budući da generiraju vrijednosti bez fizičkog mjerenja deponiranog sedimenta (Drysdale i Gillieson, 1997, Gradziński, 2010). To su neizravne metode koje se ne temelje na fizičkom mjerenju taloga (Drysdale i Gillieson, 1997).

Izravne metode mjerenja stopa prirasta i erozije se odnose fizička mjerenja sedre te se smatraju pouzdanijom metodom mjerenja (Gradziński, 2010). Metoda masenog prirasta (MI) stope prirasta utvrđuje kao masenu razliku između izvađenog osušenog uzorka testne pločice (npr. vapnenačke, staklene, bakrene pločice) s precitipiranom sedrom i početnim stanjem pločice bez precitipirane sedre (Slika 22). Izračunava se povećanje u masi akumulirane sedre na različitim podlogama postavljenima unutar zone protoka (Emeis, 1987 i dr., Gradziński, 2010, Liu i dr., 1995, Pentecost i Colleta, 2007, Liu i dr., 2010, Zhang i dr., 2012, Matoničkin Kepčija i dr., 2017, Wróblewski i dr., 2017). U obzir se uzima vrijeme koje je testni uzorak

proveo u toku, te površina plohe uzorka (Dreybrodt i dr., 1992, Pentecost 1978, Gradziński, 2010, Liu, 2017). Stopa prirasta se izračunava formulom (Liu i dr., 2010):

(4) $$R = (W_{ts} - W_s) / A * T$$

gdje W_{ts} i W_s predstavljaju težinu testnih pločica nakon vađenja i prije postavljanja u tok, A je ukupna površina testne pločice, dok je T vrijeme izlaganja pločice precipitiranju karbonata.

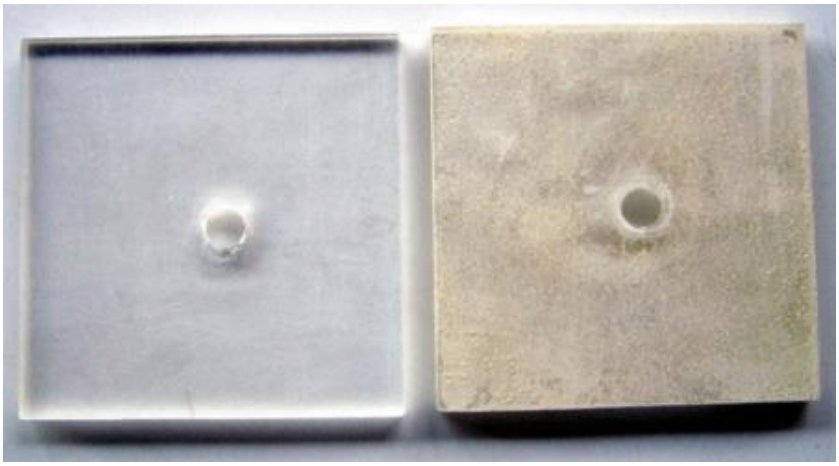

Slika 22. Izgled testne pločice prije postavljanja (lijevo) i nakon vađenja iz toka (desno)

Izvor: Zhang i dr., 2012

Drysdale i Gillieson (1997) navode da su Statham (1977) i Thorpe (1981) koristili igle za mjerenje srašćivanja u izravnim mjerenjima stopa precipitacije (Drysdale i Gillieson, 1997). To su igle ili stupići koji se zabijaju u podlogu, a na sebi imaju mjernu skalu odgovarajuće točnosti. Nedostatak im je što generiraju ograničen broj uzoraka, mogu uzorkovati promjene lokalnog toka, može doći do oštećenja precipitata prilikom intervalnih mjerenja i vraćanja igle u tok te mogu stvoriti erozijske džepove (Takekawa i dr., 2010). Nadalje, stope prirasta sedre su određivane na temelju bioloških aktivnosti mahovina, odnosno kroz ponovljena fizička mjerenja kalcificiranih organskih zajednica (Irion i Muller, 1968, Weijermars i dr., 1986, Pentecost, 1978, Merz-Preiß i Riding, 1999, Viles i Pentecost, 2007) posebice tamo gdje je prirast sezonski izražen i gdje postoji jasno utvrđena veza između određenog organizma te sedra i travertina (Drysdale i Gillieson, 1997). U novije vrijeme u mjerenju dinamike sedrenja popularna su volumetrijska mjerenja, odnosno primjena modificiranog mikroerozijskog metra (MEM) (Drysdale i Gillieson, 1997, Arenas i dr., 2010, Auqué i dr., 2013, Auqué i dr., 2014, Arenas i dr., 2014).

2.4.7.1 Modificirani mikro-erozijski metar (MEM)

Modificirani mikro-erozijski metar (MEM) je mjerni uređaj koji omogućuje izravno praćenje prirasta sedre (Slika 23). MEM je izvorno korišten za mjerenje površinske denudacije, odnosno erozije kopnenih i špiljskih vapnenačkih područja (Stephenson i Finlayson, 2009). Za potrebe mjerenja dinamike formiranja sedre i travertina modificirali su ga Drysdale i Gillieson (1997). Sastoji se od 5x10 koordinatnog sustava u pravokutnom okviru na koji je postavljen digitalni mikrometar koji mjeri visinu na 50 uzoraka (lokalnih koordinata).

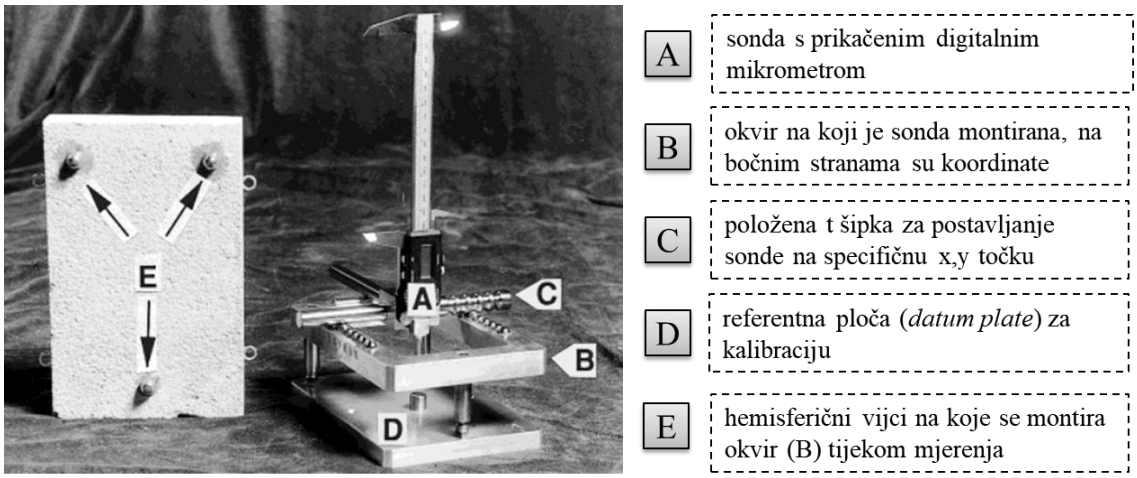

Slika 23. Modificirani mikro-erozijski metar za praćenje dinamike sedrenja

Izvor: Drysdale i Gillieson 1997. (modificirano)

Proces mjerenja u svim radovima je isti. Mjerenje se izvodi prije i nakon vađenja umjetnih podloga iz toka te sušenja. Srednja vrijednost razlika između vrijednosti visina na 50 uzoraka predstavlja stopu prirasta za svaku pločicu. Mjerenja su izražavana u milimetrima po polugodišnjem ili godišnjem razdoblju (Arenas i dr., 2010). Proces mjerenja započinje tako da se prije instalacije svaka pločica ispire i osuši te se mjeri njeno referentno stanje. Prije postavljanja i svakog vađenja pločice mjere se hidrološki uvjeti njenog fluvijalnog okruženja. Nakon određenog intervala pločice se vade iz toka i suše u istim uvjetima kao prije postavljanja. Nakon svakog mjerenja MEM se ponovno pokreće koristeći instrument referentne ploče (eng. *datum plate*) (Drysdale i Gillieson, 1997). Međutim, potrebno je naglasiti nekoliko ključnih nedostataka primjene MEM-a.

1. Problem zbijanja (eng. *compaction problem*)

Prvi problem se odnosi na nemogućnost razlikovanja erozije sedre od problema zbijanja koji je izazvao MEM (Spate i dr., 1985, Drysdale, Gillieson 1997). Problem zbijanja se odnosi na kontakt koji digitalni mikrometar stvara prilikom dodira površine sedre stvarajući time *umjetnu* udubinu, odnosno prostor erozije koja nije nastala prirodnim putem, djelovanjem toka

ili nekog organizma. Spate i dr. (1985) ističu da je prilikom korištenja MEM-a jako teško razlikovati prirodno spuštanje površine od onoga induciranim djelovanjem instrumenta (Slika 24) ili tijekom radnih uvjeta. Drysdale i Gillieson, (1997) također navode problem zbijanja koji se događa kada digitalni mikrometar dotakne mekšu površinu sedre.

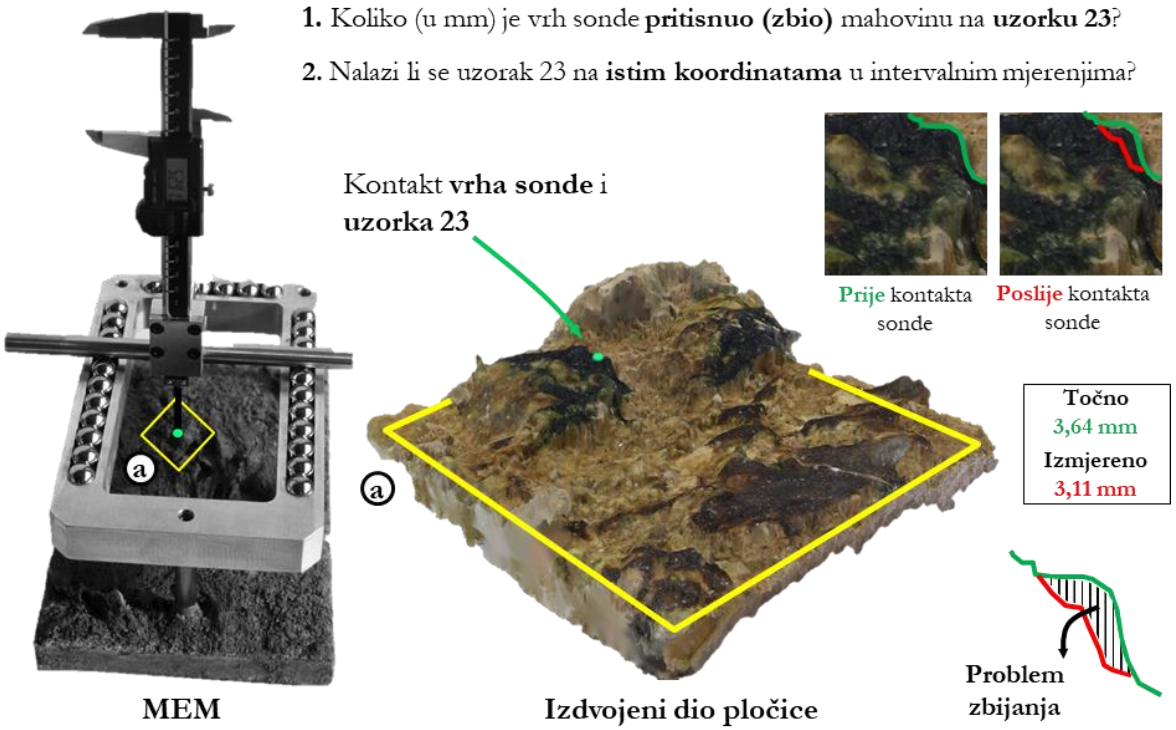

Slika 24. Shematski prikaz primjena problema zbijanja (0,53 mm) izvedenog MEM-om

Zbijanjem se generira rezultat koji podcjenjuje ukupne akumulaciju, a precjenjuje eroziju, stoga sva mjerenja reprezentiraju minimalne vrijednosti. Samo oni uzorci s vrijednostima većim od 0,2 mm a^{-1} mogu predstavljati istinsku, a ne induciranu eroziju (Drysdale i Gillieson, 1997). Međutim, isti autori navode da je sedra u većini slučajeva kompaktna i dovoljno tvrda da omogućava 800 ponovljenih mjerenja na istoj lokaciji s preciznošću od 0,01 mm. Takve tvrdnje su upitne ako znamo da vrh digitalnog mikrometra mora 800 puta dotaknuti površinu sedre koja se u velikom broju slučajeva sastoji od nakupina spužvastih zelenih algi, mahovina te obilja krhkih fitoklasta. Sedra u najboljem slučaju (najtvrđi uzorci) prema Mohsovoj ljestvici ima vrijednost manju od 3 (Bezerra i dr., 2010, URL 10). Iz navedenoga proizlazi da će točnost i preciznost mjerenja isključivo ovisiti o kompaktnosti i tvrdoći sedre te vještini i osjećaju samog korisnika uređaja.

2. Visoke mjerne pogreške (eng. *large measurement error*)

S obzirom na to da je točnost mjerenja MEM-om uvjetovana tvrdoćom sedre ono je otežano ako se na umjetnoj pločici nakupi puno spužvastih zelenih algi, mahovina, zoobentosa, obilja krhkih fitoklastima i sličnih kombinacija, gdje relativna mekoća ovog materijala, odnosno podložnost udubljenjima nakon zbijanja još više otežava mjerenje (Slika 25).

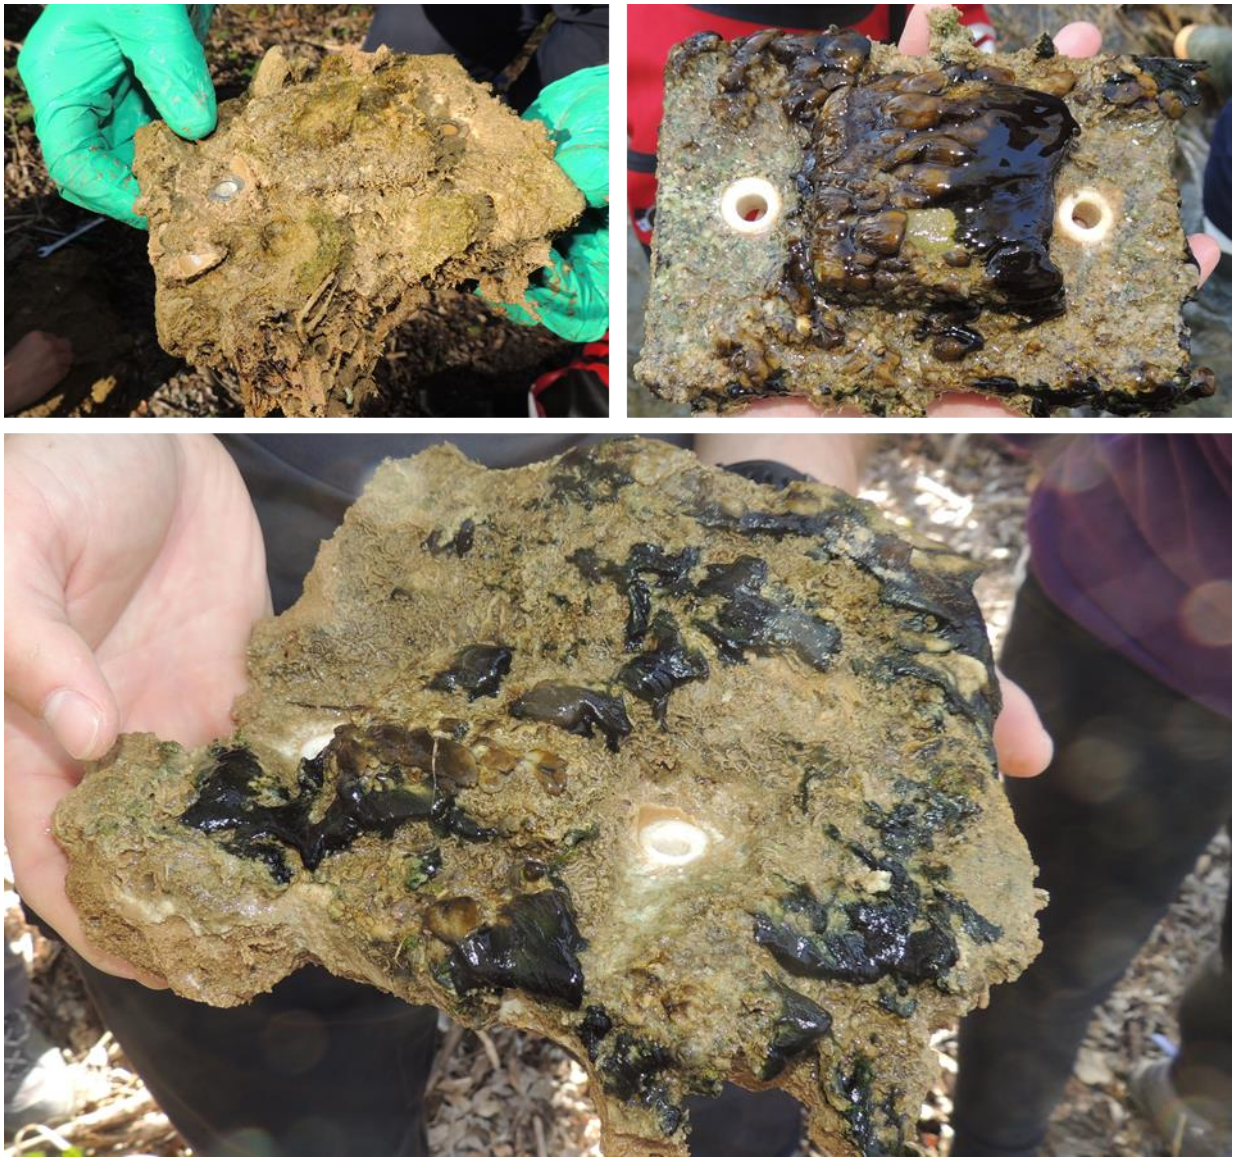

Slika 25. Primjer površina na kojima MEM generira velike mjerne pogreške

Izvor: Arenas i dr., 2014

Pogreške mjerenja u tom slučaju mogu iznositi više od pola centimetra, odnosno između 5 do 10% godišnje akumulacije nekih sedrotvornih sustava, koje autori Drysdale i Gillieson (1997) smatraju unutar prihvatljivih granica pogreške. Međutim, pogreška od pola centimetra u velikoj većini aktivnih sedrotvornih sustava (Tablica 6) iznosi značajno više od 5 do 10% godišnje akumulacije. Naime, u velikom broju sedrotvornih sustava godišnja

akumulacija sedre iznosi manje od pola centimetra (Kempe i Emeis, 1985, Heimann i Sass, 1989, Liu i dr., 1995, Drysdale i Gillieson, 1997, Merz-Preiß i Riding, 1999, Arp i dr., 2001, Kano i dr., 2003, Lojen i dr., 2004, Yoshimura i dr., 2004, Megerle, 2012, Auqué i dr., 2013, Liu, 2017). Takva pogreška je stoga neprihvatljiva te je potrebno koristiti drugu metodu mjerenja koja potencijalno neće izravno dodirivati površinu sedre.

3. Mjerna ograničenja uređaja (eng. *measuring limitations of device*)

Treći problem se odnosi na mjerna ograničenja MEM-a. Ograničen je u mjerenju izrazito malih i jako velikih uzoraka sedre (Slika 26) (Drysdale i Gillieson, 1997). Naime, ako se dinamika formiranja sedre promatra kroz dugogodišnje razdoblje te ako se u njima bilježi vrlo intenzivan vertikalni i horizontalni rast sedre onda testna pločica neće moći biti montirana unutar MEM-a te se mjerenje ne može izvršiti. Nadalje, najmanji uzorak, odnosno čestica sedre na pločici koju MEM može izmjeriti je određen tipom (standardna, sferna, šiljasta, itd.) i debljinom, odnosno promjerom (Ø) mikroskopske igle na sondi.

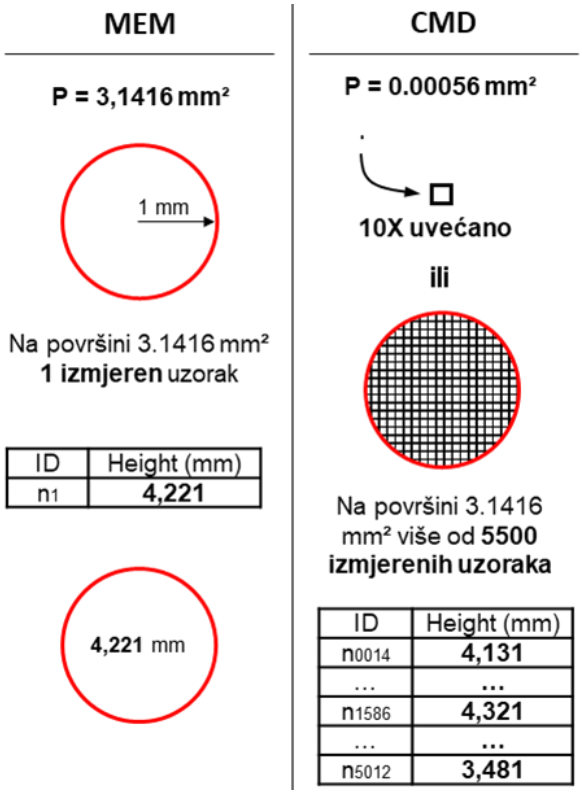

Slika 26. Shematski primjer ograničenja MEM-a u mjerenju jako malih uzoraka sedre

Debljina može značajno varirati (0,25 do 7 mm) ovisno o vrsti digitalnog mikrometra. S druge strane, najmanji uzorak sedre izmjeren u ovom istraživanju (s obzirom na zadane postavke snimanja) ima promjer 0,0236 mm. Ta vrijednost može biti i manja. Na slici 26.

ilustrirano je zašto izravna usporedba MEM-a i CMD[44]-a preko pojedinačnih uzoraka može biti vrlo osjetljiva te je stoga izlazne rezultate teško interpretirati. Primjerice, ako je igla na sondi MEM-a kružnog oblika te ima polumjer od 1 mm, površina najmanjeg uzorka sedre koji se može izmjeriti iznosi 3,1416 mm². Na njoj MEM bilježi jednu vrijednost visine (npr. n_1 = 4,221 mm). S druge strane, CMD na površini od 3,1416 mm² ima oko 5500 visinskih uzoraka (broj može biti veći ovisno o postavkama). Površina sedre je vrlo složena te varijabilnost vrijednosti visina na tako malom prostoru može biti velika (npr. n_{14} = 4,131, n_{1586} = 4,321, n_{5012} = 3,481 mm). Iz toga proizlazi opravdano pitanje: koji od 5500 uzoraka usporediti s jednim uzorkom izmjeren MEM-om? Usporedba prosječne vrijednosti značila bi svjesno zanemarivanje složenosti površine sedre i prilagođavanje kriterija ispitivanja nižoj gustoći uzorkovanja.

4. Mala gustoća uzorkovanja (eng. *small sampling density*)

Četvrti problem se odnosi na gustoću uzorkovanja na temelju koje se izračunava stopa sedrenja za pojedinu pločicu. Naime, primjenom MEM-a stope prirasta i erozije sedre se izračunavaju na temelju samo 50 uzoraka koristeći pravilni metodom uzorkovanja (Slika 27a).

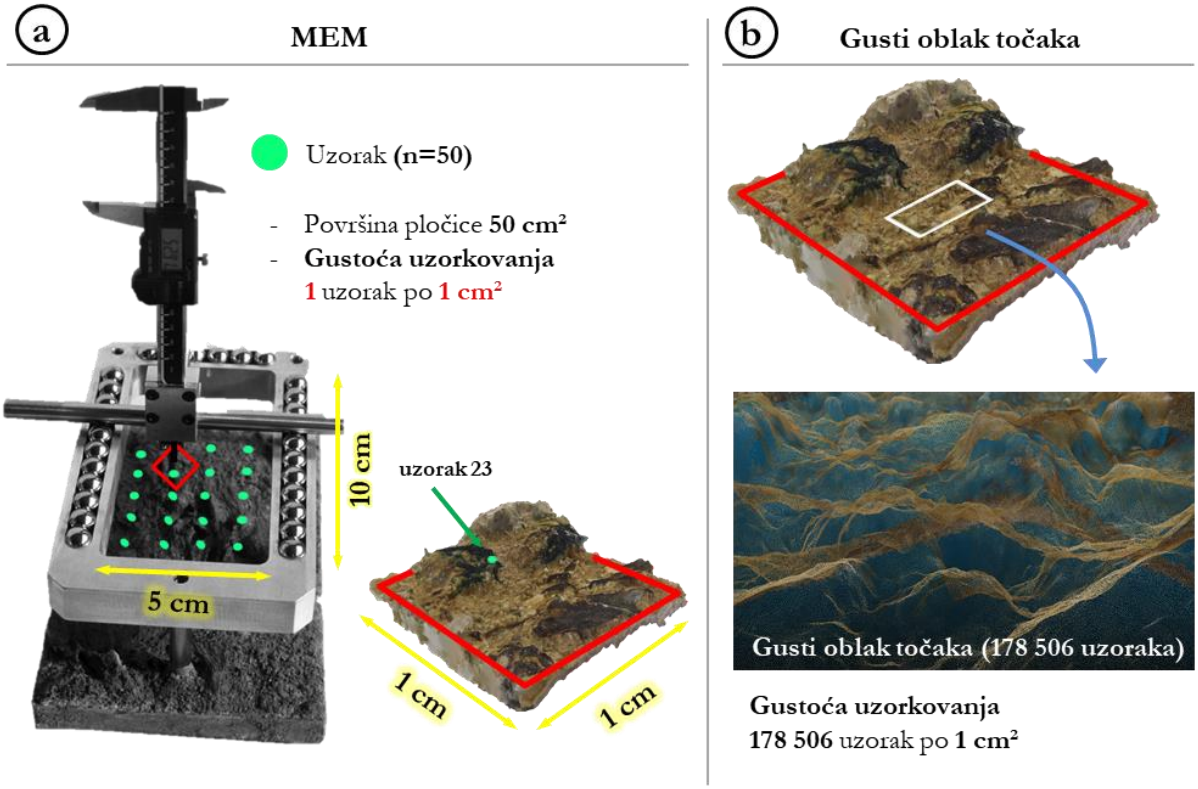

Slika 27. Usporedba gustoće uzorkovanja a) MEM-a i b) gustog oblaka točaka

[44] Coordinate Measuring Macrophotogrammetry Device

Ipak, opće je poznato da mala gustoća i neprikladna metoda uzorkovanja mogu značajno utjecati na točnost, a time i kasniju interpretaciju izvedenih modela (Aguilar i dr., 2005, Šiljeg i dr., 2018). Stoga 2.5D i 3D modeli visoke rezolucije nastala na gustim oblacima točaka (Slika 26b) postaju sve popularniji u generiranju specifičnih morfometrijskih parametara malog objekta ili scene (Remondino i El-Hakim, 2007, Jun, 2012). Usprkos činjenici da je napredak geomatike revolucionirao mogućnosti kvantitativnog snimanja Zemljine površine (Smith i dr., 2016) uslijed kojeg je širok spektar naprednih geoprostornih uređaja korišten na različitim mjerilima (Verma i Bourke 2019), moderne geoprostorne tehnologije, poput visokokvalitetnih ručnih uređaja za lasersko skeniranje, 3D projekcijskih skenera te SfM fotogrametrije, prema autorovom saznanju, još uvijek nisu korištene u postupku mjerenja TFD-a.

4. Ograničenost primjene izvedenih podataka (eng. *limited use of derived data*)

Primjenom MEM-a za 50 uzoraka na pločici se izvodi X, Y i Z vrijednost. Uređaj nema mogućnost generiranja digitalnih kontinuiranih modela iz kojih bi se mogli izvoditi primarni ili sekundarni morfometrijski parametri (Slika 28). Jedini podaci koji može generirati su stopa prirasta ili erozije sedre za uzorak ili pločicu.

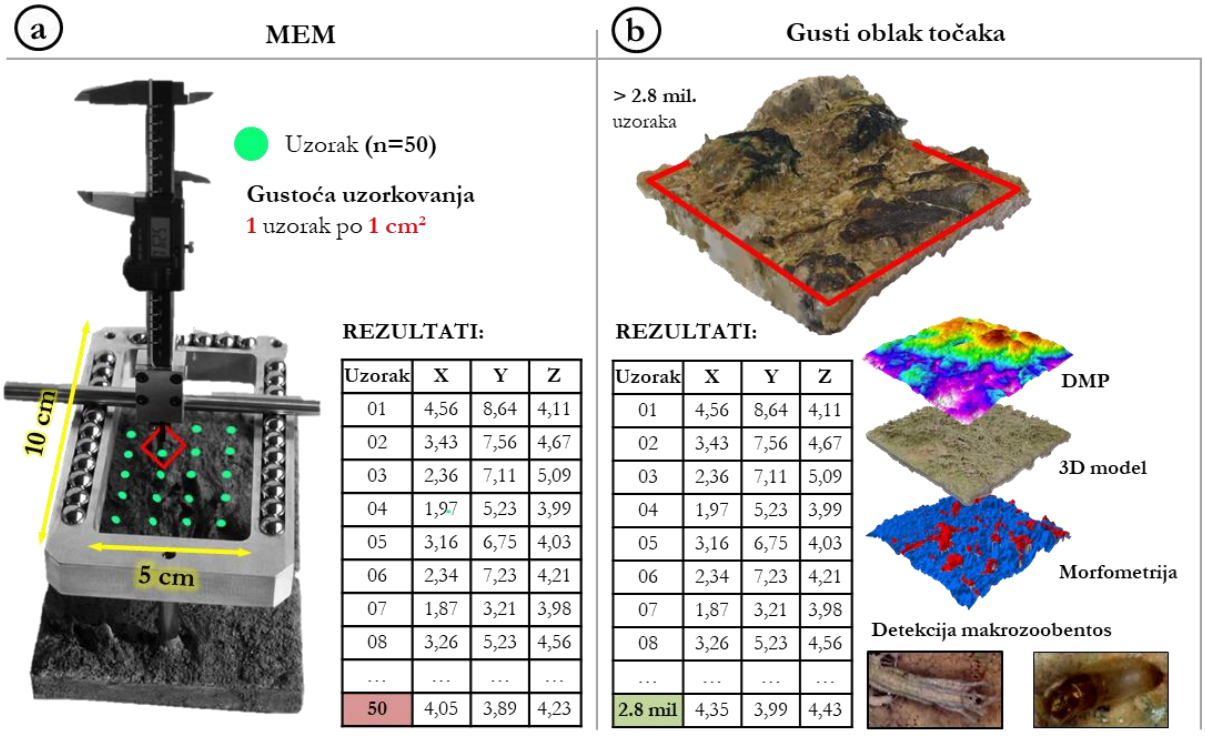

Uzorak	X	Y	Z
01	4,56	8,64	4,11
02	3,43	7,56	4,67
03	2,36	7,11	5,09
04	1,97	5,23	3,99
05	3,16	6,75	4,03
06	2,34	7,23	4,21
07	1,87	3,21	3,98
08	3,26	5,23	4,56
…	…	…	…
50	4,05	3,89	4,23

Uzorak	X	Y	Z
01	4,56	8,64	4,11
02	3,43	7,56	4,67
03	2,36	7,11	5,09
04	1,97	5,23	3,99
05	3,16	6,75	4,03
06	2,34	7,23	4,21
07	1,87	3,21	3,98
08	3,26	5,23	4,56
…	…	…	…
2.8 mil	4,35	3,99	4,43

Slika 28. Izlazni rezultatu primjenom a) MEM-a te b) trokoordinatnih mjernih uređaja

Suprotno, suvremeni trokoordinatni mjerni uređaji (npr. 3D projekcijski i laserski skeneri, SfM RGB[45] i multispektralna fotogrametrija) omogućuju izvođenje kontinuiranih visoko-rezolucijskih digitalnih modela te izuzev X, Y i Z vrijednosti prikupljaju podatake o teksturi i spektralnoj refleksiji površine (u tri ili više kanala). Nadalje, iz dobivenih modela mogu se izvesti različiti morfometrijski parametri ili napraviti detekcija, kartiranje i klasifikacija bentosa (Slika 27).

S obzirom na navedene nedostatke spomenutih metoda, nameće se potreba razvoja novog izravnog, beskontaktnog, intervalnog koncepta praćenja dinamike sedrenja koji će omogućiti izvođenje submilimetarskog modela sedre kontinuiranih površina te u potpunosti ukloniti mogućnost oštećenja njenog površinskog sloja. Time bi se omogućilo preciznije određivanje akumulacijskih stopa različitih hidroloških okruženja. Zbog istaknutih nedostataka, koje spominju i sami autori, predložen je novi pristup u mjerenju dinamike sedrenja. Ipak, navedeni rezultati o stopama taloženja sedre i travertina daju vrijedne procjene i referentne vrijednosti za buduća istraživanja.

2.5 Primjena suvremenih geoprostornih tehnologija u upravljanju zaštićenim prostorom

Ustanove se u procesu upravljanja zaštićenim područjima podložnim na najmanje promjene u okolišu, suočavaju sa širokim spektrom odluka koje je potrebno provesti (Gross i dr., 2008). Višerezolucijsko praćenje ekoloških procesa se nameće kao potreba zbog osjetljivosti zaštićenog područja na antropogene pritiske, zaštite temeljnog fenomena, očuvanja bioraznolikosti te ispunjavanja nacionalnih i međunarodnih direktiva (Nagendra i dr., 2013, Willis, 2014). Upravo se praćenje dinamike zaštićenih područja označava kao prioritet upravljačkog tijela (Willis, 2014). Praćenje okoliša pretpostavlja sustav mjerenja, prikupljanja i obrade podataka na temelju kojih se vrše procjene i prognoze elemenata i procesa. Niz navedenih procedura provodi se primjenom usklađenih metoda i kalibriranih istraživačkih uređaja (Zielińska, 2010).

Primjena geoprostornih tehnologija (eng. *geospatial technologies*) u upravljanju okolišem započela je 60-ih godina dvadesetog stoljeća kada se u SAD-u i Kanadi nastojao automatizirati i digitalizirati proces kartiranja (Hoalst-Pullen i Patterson, 2010). Razvoj GST-a kreirao je nove mogućnosti primjene GST u procesima upravljanja zaštićenim područjima (Gross i dr., 2008). GST označavaju termin koji se koristi za opisivanje širokog spektra senzora, softvera, alata i metoda (URL 28) (znanstveni i komercijalni sateliti, laserski sustavi, bespilotne letjelice, GIS sustavi, GPS sustavi, programi za obradu podataka, procedure rada

[45] Red Green Blue

itd.) koji doprinose kartiranju i analizama Zemljine površine (URL 25). U kontekstu upravljanja zaštićenim prostorom ona je izuzetno bitna jer se smatra nepristranom, učinkovitom, u nekim slučajevima neinvazivnom (eng. *remote sensing*) kvantitativnom metodom ekološkog praćenja, primjenjivom na različitim prostorno-vremenskim mjerilima (Kennedy i dr., 2009, Willis, 2014). Najbrži način inventarizacije i evaluacije prirodnih resursa izvodi se primjenom tehnologije daljinskih istraživanja koja obuhvaća uređaje od naprednih ultraspektralnih senzora, raznih vrste laserskih sustava do jednostavnih digitalnih kamera (Frohn i Lopez, 2017).

Podaci prikupljeni daljinskim istraživanjima omogućuje sinoptičke, frekventne, u stvarnom vremenu (eng. *real time*) točne procjene prirodnih resursa. Posebna privlačnost primjene GST-a je mogućnost izvođenja odgovarajućih varijabli te indikatora, što omogućava otkrivanje naglih promjena ili sporih trendova u nekom razdoblju (Kennedy i dr., 2009). One omogućuju kvantificiranje referentnog stanja bioraznolikosti, kvantificiranje gubitaka, degradacije ili praćenje oporavka ekosustava povezanog s određenim događajem ili procesima (Nagendra i dr., 2013).

Ustanove su obično zainteresirane za aktivnosti upravljanja na razini mikro lokacije, ali suvremene geoprostorne tehnologije, s naglaskom na metode daljinskih istraživanja, pružaju mogućnost generiranja informacija o specifičnim pojavama i procesima na širokom spektru mjerila (makro/mezo/mikro/submikro) (Gross i dr., 2008).

Dugoročno praćenje pruža bolji uvid u čimbenike stresa okoliša (npr. degradacija procesa sedrenja) i pokretače tih promjena (npr. nekontrolirano širenje invazivne i niske vegetacije, fizikalno-kemijske promjene vode). Time se ciljani akcijski planovi mogu usmjeriti prema rješavanju uzroka pojave (npr. izrada plana selektivnog uklanjanja vegetacije), a ne prema detekciji simptoma (Kennedy i dr., 2009).

Usprkos rastućoj svijesti o korisnosti GST-a u upravljanju zaštićenih područja, mali broj upravnih tijela primjenjuje takve metode zbog nedostatka tehničkih vještina, vremenski zahtjevnog procesa obrade podataka, te financijskih ograničenja (Nagendra i dr., 2013). Stoga odgovornost uspješne primjene GST-a počiva na obje strane: upravljačkoj strukturi (Uprava, donosioci odluka), te znanstvenicima. Znanstvenici moraju razumjeti potrebe i ciljeve upravljačke strukture i biti upoznati s ograničenjima unutar kojih mogu djelovati ovisno o stupnju zaštićenosti prostora (npr. nemogućnosti upotrebe metode kemijskog tretiranja invazivne vegetacije), dok Uprava mora razviti razumijevanje o mogućnostima i važnosti primjene tehnologije u spomenutoj problematici (npr. financijska i logistička potpora istraživanju, dopuštenje za intervenciju u prostoru) (Kennedy i dr., 2009).

Dakle, primjena GST-a u nadzoru specifičnih elemenata nekog krajobraza (npr. sedrene barijere, vodotoci, vegetacija) pruža osnovu za kvantificiranje i predviđanje promjena koje mogu imati neželjene (npr. degradacija procesa sedrenja) ili pak očekivane učinke (npr. reaktivacija procesa sedrenja) na prirodne i društvene resurse tog prostora (Jones i dr., 2009, Frohn i Lopez, 2017). S obzirom da ovakvo upravljanje zahtjeva praćenje učinka provedenih aktivnosti i mjera (akcijski planovi), nužno je definirati i uspostaviti kvantitativne indikatore[46] (npr. očekivani prirast sedre, kolonizacija mikro faune, makrozoobentosa) kojima bi se pratio napredak prema postavljenom cilju (HAOP, 2015). Navedeni indikatori ekosustava (eng. *ecosystem indicators*) mogu biti organizirani prema hijerarhijskoj razini (mjerilu) (Jones i dr., 2009), a ocrtavaju kvalitetu šireg ekološkog sustava kojem pripadaju (Willis, 2014).

U procesu razvoja višekriterijskog modela održivog upravljanja koji bi osigurao metodološki okvir i dao smjernice za održivo upravljanje sedrotvornim vodotocima korišten je širok spektar GST-a, te ostalih mjernih uređaja (multiparametarske sonde, intervalne kamere, uređaj za mjerenje brzine protoka) kroz različite razine istraživanja. U nastavku teksta pružena je kratka teorijska osnova primijenjene geoprostorne tehnologije.

2.5.1 Fotogrametrija

Fotogrametrija je u disertaciji korištena na više razina istraživanja (mezo i mikro) te u različitim oblicima (aerofotogrametrija te makrofotogrametrija). Fotogrametrija je pasivna 3D digitalizacijska tehnika koja koristi centralnu projekciju kao svoj temeljni matematički model. ASPRS[47] definira fotogrametriju kao znanost, tehnologiju i umjetnost prikupljanja pouzdanih informacija o prostoru kroz proces snimanja, obrade i interpretacije preklapajućih fotografija te uzoraka reflektiranog elektromagnetskog zračenja (Ansari i Gondaliya, 2013). Pojam fotogrametrija je složenica tri grčke riječi *phos* ili *phot* što znači svjetlo, *gramma* što predstavlja crtanje,a *metrein* mjerenje (Schenk, 2005). Prema položaju platforme može se podijeliti na orbitalnu, zračnu, terestričku, blizupredmetnu i makrofotogrametriju (Luhmann i dr. 2007, Percoco i dr. 2015). Temelji na postavkama da fotografija nastaje prema geometrijskim (lokacija i nagib kamere u prostoru) i optičkim (metričke značajke kamere) zakonitostima. Njihovim poznavanjem moguće je napraviti 3D rekonstrukciju snimljenog modela. Naime,

[46] Indikatori ili pokazatelji pružaju informaciju u kojoj se fazi nalazi ostvarenje postavljenog cilja. Dobar indikator mora biti SMARTI. Eng. *specific* (ograničen, specifičan); ograničen na cilj koji mjeri. Eng. *measurable* (mjerljiv); kvantitativno ili kvalitativno iskazan. Eng. *available* (dostupan); uz prihvatljive troškove ga je moguće izvesti. Eng. *relevant* (vjerodostojan); promjene koje su uočene rezultat su provedenih aktivnosti. Eng. *time-bound* (vremenski-određen); poznato je kada se može očekivati ispunjenje cilja. Eng. *independent* (nezavisan); isti indikator ne bi smio biti korišten u praćenju ostvarenja aktivnosti više ciljeva (URL 26).

[47] American Society for Photogrammetry and Remote Sensing

fotografiranjem dolazi do preslikavanja 3D prostora u ravninu (centralna projekcija) te gubljenja informacija o 3D prostoru, dok se procesom fotogrametrije dolazi do ponovne transformacije 2D podatka (fotografije) u 3D podatak (oblak točaka). Fotogrametrija ima nekoliko prednosti u odnosu na konvencionalne istraživačke metode: ne remeti objekt snimanja, u kratkom vremenu se mogu snimiti velike površine nedostupnih prostora, omogućuje trajno spremanje izgleda nekog prostora (prostorno-vremenske analize), brža je i jeftinija od terenskog i laserskog prikupljanja podataka itd. Nedostatci se odnose na: vremenske (ne)prilike koje ograničavaju mogućnosti snimanja, problem pojave sjena, nemogućnost prikupljanja podataka na prostorima visoke i guste vegetacije, snježnom pokrovu te dubokim vodama (URL 35).

Brz tehnološki napredak u razvoju digitalnih kamera i povećane mogućnosti hardvera i softvera dramatično su proširi raznolikost situacija u kojima se fotogrametrija primjenjuje (Percoco i dr., 2015). To je posebno vrijedi u područjima blizupredmetne fotogrametrije (Luhmann i dr. 2007). Danas različit spektar stručnjaka (hidrolozi, pedolozi, arheolozi, paleontolozi, biolozi, konzervatori, inženjeri) primjenjuje neku od fotogrametrijskih tehnika (Yakar i Yilmaz, 2008, Nicolae i dr., 2014, Gajski i dr., 2016, Samaan i dr., 2016).

Najnovija razvojna faza je digitalna fotogrametrija koja primjenjuje digitalne snimke te napredne softvere i algoritme u izvođenje fotogrametrijskih postupaka. Suvremene digitalne nemjerne kamere su postale jedan od najkorištenijih softvera u fotogrametriji. Razvoj digitalne fotografije, kontinuirana evolucija u rezoluciji i kvaliteti senzora te povećanje snage softvera za obradu slika smanjili su potencijalni objekt i/ili scenu istraživanja te potaknuli razvoj blizupredmetne fotogrametrije i makrofotogrametrije (Percoco i dr., 2015).

2.5.1.1 Aerofotogrametrija

Aerofotogrametrija je u disertaciji korištena na mezo razini istraživanja. Detaljni proces snimanja i obrade podataka opisan je u metodologiji. Aerofotogrametrijsko snimanje je snimanje iz zraka izvedeno mjernom ili kalibriranom nemjernom kamerom. Kamera je montirana na posebna žiroskopski stabilizirana postolja u donjem dijelu trupa aviona ili bespilotne letjelice, a uglavnom je usmjerena vertikalno na teren (Ansari i Gondaliya, 2013). Snimanje se vrši po planiranim profilima postižući poprečno i uzdužno preklapanje. Gustoća prikupljanja podataka se prilagođava svrsi istraživanja i morfološkim obilježjima terena. Područje predviđeno za snimanje iz zraka mora biti bez snijega, visokih voda, zelene vegetacije

ili drugih prirodnih čimbenika koji mogu prekriti dijelove tla. Prije plana leta potrebno je postići ravnotežu između prostorne rezolucije (GSD[48]) i broja snimaka.

GSD označava prostornu veličinu slikovnog elementa, odnosno udaljenost između dva uzastopna središta piksela. Što je veća vrijednost GSD-a to je prostorna rezolucija modela lošija (URL 29). Ovisi o visini leta (udaljenosti kamere od objekta snimanja), veličini senzora te kutu snimanja. Veća udaljenost proizvodi površinski veći GSD što generira slabiju prostorna rezolucija. GSD je bitan jer u praksi točnost modela ne može biti veća od njegove rezolucije. Prilikom planiranja projekta snimanja potrebno je paziti da razlike u vrijednostima GSD-u zbog energije reljefa snimanog prostora ne prelaze 15% (NN 65/2016).

2.5.1.2 Ciklično fotografiranje

U prethodnim poglavljima kao jedan od čimbenika pritiska na ravnotežu ekosustava NPK je istaknuto nekontrolirano širenje invazivnih i drugih oblika vegetacije. Invazivne vrste karakterizira izuzetna dinamika širenja i brzina regeneracije. Iz toga proizlazi nekoliko primarnih pitanja koja se često navode u zaštićenim područjima: koja je stopa širenja biljne vrste nakon što je došlo do uspostave na jednom mjestu te koja je stopa regeneracije nakon provedene mjere uklanjanja? (Müllerová i dr., 2005).

Zračne i terestričke snimke te videozapisi su najkorištenije metode daljinskih istraživanja koje se koriste u detekciji invazivnih vrsta. One mogu generirati podatke o zahvaćenoj površini i dinamici njihova širenja (Everitt i dr., 1995, Müllerová i dr., 2005). Stoga važnu ulogu u proučavanju prostorno-vremenskih promjena u zaštićenim područjima ima ciklično fotografiranje i snimanje (eng. *repeat photography*). Ono podrazumijeva jednostavnu metodu ponavljajućeg, intervalnog fotografiranja istog predmeta ili prostora. Osnovni zahtjev ove metode je precizno pozicioniranje fotoaparata na specifičnu lokaciju (Swetnam i dr., 1999, Roush i dr., 2007, Nyseen i dr., 2008, Brady, 2009).

Metoda cikličnog fotografiranja u upravljanju zaštićenim područjima korištena je u velikom broju istraživanja (Klasner i Fagre, 2002, Müllerová i dr., 2005, Roush i dr., 2007, Herrero i dr., 2017). Primjenjuje se od 1888. godine, a u početku se koristila za praćenje dinamike ledenjaka (Roush i dr., 2007). Predstavlja vizualnu metodu vrednovanja i interpretacije promjena u krajobrazu (Byers, 1987, Swetnam i dr., 1999, Brady, 2009, Garrard i dr., 2012), a primjenjuje se u analizama sastava i strukture ekosustava (Webb i dr., 2007), povlačenja/napredovanja ledenjaka (Byers, 2007), transformaciji kulturnog i prirodnog

[48] Ground Sampling Distance

krajobraza (Kull, 2005, Roush i dr., 2007, Nyseen i dr., 2008, Frankl i dr., 2011, Garrard i dr., 2012) itd.

U disertaciji su korištena tri oblika cikličnog fotografiranja. Terestrički oblik cikličnog fotografiranja (Swetnam i dr., 1999, Klasner i Fagre, 2002, Nyseen i dr., 2008) je korišten na odabranoj testnoj plohi pomoću montirane kamere za intervalno praćenje. Iako terestrička ciklična fotografija može učinkovito prikazati kvalitativnu promjenu krajobraza ona se rijetko primjenjuje za tu svrhu. Razlog tome je kosa perspektiva snimka koja stvara kontinuirano promjenjivo mjerilo (Roush i dr., 2007). Zračnim cikličnim fotografiranjem (Swetnam i dr., 1999, Klasner i Fagre, 2002, Müllerová i dr., 2005) nastojala se kvantificirati promjena u vegetacijskom pokrovu nakon provođenja plana uklanjanja selektivne vegetacije na odabranoj testnoj plohi. Na mikro razini istraživanja primijenjen je princip cikličnog fotografiranja (ciklična fotogrametrija) testnih pločica iz kojih su potom izrađeni 3D modeli te praćena dinamika formiranja sedre.

2.5.1.3 Blizupredmetna fotogrametrija

Napredak u razvoju i ekonomičnosti fotogrametrijskih softvera, fotoaparata visoke rezolucije, hardvera i bespilotnih letjelica uzrokovalo je preklapanje granica blizupredmetne i tradicionalne fotogrametrije. Granica između blizupredmetne i tradicionalne fotogrametrije iznosi 300 m udaljenosti između objekta i kamere (Matthews, 2008). Ona označava minimalnu sigurnu visinu letenja iznad naseljenih područja zahtijevanu od strane Federalne uprave za zrakoplovstvo (FAA[49]). S obzirom na navedenu udaljenost između objekta i senzora, prikupljanje podataka u blizupredmetnoj fotogrametriji (eng. *Close Range Photogrammetry* - CRP) može biti terestričko ili zračno (Salmon, 2014). Primjenom blizupredmetne fotogrametrije teoretski ne postoji ograničenje koja rezolucija može biti postignuta (Matthews, 2008). Blizupredmetna fotogrametrija pretpostavlja korištenje jedne ili više digitalnih kamera i uzastopnih preklapajućih fotografija (Yakar i Yilmaz, 2008) radi dobivanja površinskih visina na prostorima njihova preklapanja (Bertin i Friedrich, 2016). To je tehnika prikupljanja podataka koja izvodi geometriju objekta (X, Y i Z) iz digitalnih snimaka, a ne izravno kroz njegovo mjerenje (Stylianidis i dr., 2003, Yakar i Yilmaz, 2008). Zbog komercijalne dostupnosti blizupredmetna fotogrametrija postaje sve primjenjivija u brojnim znanstvenim istraživanjima (Ramos i Pierto, 2015), od analize fluvijalnih procesa (Bertin i Friedrich, 2016), stabilnosti stijenskog materijala (Pate i Hanberg, 2011), restauraciji i virtualizaciji sakralnih i

[49] Federal Aviation Administration

kulturnih objekata i spomenika (Yastikli, 2007, Koch i Kaehler, 2009, Ramos i Pierto, 2015, Santoši i dr., 2015), volumetrijskim analizama u rudnicima (Rahnama i dr., 2012), analizama koraljnih grebena (Young i dr., 2017) analizi arheoloških terestričkih i podvodnih artefakata (Sumner i Riddle 2008, Al-Kheder i dr., 2009, Evin i dr., 2016, Yamafune, 2016, Porter i dr., 2016, Brutto i Dardanelli, 2017), zoologiji (Lavy i dr., 2015) itd.

Osnovu za određivanje 3D koordinata u tehnici blizupredmetne fotogrametrije predstavlja skup orijentiranih snimaka, što znači da prije izrade modela položaji i rotacijski kutovi kamere moraju biti određeni. Neki od naziva za ovakav tip fotogrametrije u literaturi su *Structure from Motion* (SfM) (Westoby i dr., 2012), *Merge Image Photogrammetry, Computer Vision Photogrammetry* (Yamafune, 2016, Brutto i Dardanelli, 2017), *Image-based 3D Modeling* (Evin i dr., 2016) itd.

SfM je automatizirani algoritam strukturiranja iz pokreta. Revolucionarna, jeftina fotogrametrijska tehnika koja se koristi za dobivanje skupova podataka visoke rezolucije u različitim rasponima mjerila (Westoby i dr., 2012, Barilar i dr., 2015). Ona rješava probleme određivanja lokacije i kuta kamere koristeći algoritam podešavanja svjetlosnih snopova na temelju podudarnih značajki (piksela) u višestruko preklapajućim slikama (Westoby i dr., 2012, Verhoeven i dr., 2013). Podešavanje svjetlosnih snopova (eng. *Bundle Adjustment* - BA) je metoda skupnog izjednačavanja koja proizvodi optimalnu 3D rekonstrukciju i procjenu parametara unutarnje orijentacije kamere minimiziranjem funkcije globalnih troškova (Zhang i dr., 2006). Pojam *snop* (eng. *bundle*) se odnosi na svjetlosne zrake koje se reflektiraju od 3D objekt i konvergiraju u centar kamere (Ciceli, 2007, URL 40). Razvoj sličnih *soft-copy* triangulacijskih algoritama radikalno je poboljšao kvalitetu podataka koji se mogu izvesti iz preklapajućih stereo-parova. SfM se od konvencionalne fotogrametrije razlikuje po tome što se geometrija scene (lokacija i orijentacija kamere u prostoru) rješava automatski. Ona ne zahtijeva poznavanje 3D pozicije i orijentacije kamere kako bi se mogla izvršiti rekonstrukcija 3D scene. Umjesto toga, navedeni parametri se rješavaju putem iterativne procedure prilagodbe svjetlosnih snopova koja se temelji na bazi podudarajućih značajki (lokalne interesne točke/pikseli) koje se ističu ili su okružene prepoznatljivom teksturom, a automatski su izdvojene iz skupa preklapajućih slika (Westoby i dr., 2012, Verhoeven i dr., 2013). Prvi korak u tom procesu predstavlja identifikacija značajki koje se mogu koristiti za slikovno podudaranje. Popularno rješenje za navedeni problem je SIFT[50] algoritam za prepoznavanje značajki (Westoby i dr., 2012).

[50] Scale-Invariant Feature Transform

Za razliku od tradicionalne fotogrametrije, gusti oblak točaka proizveden tehnikom SfM nalazi se u relativnom *slikovnom* (eng. *image-space*) koordinatnom sustavu te se potom usklađuje s *objektno-prostornim* (eng. *object-space*) koordinatnim sustavom. U većini slučajeva ovo se ostvaruje s poznatim vrijednostima orijentacijskih točaka (GCP[51]). U praksi, one se dodaju prije snimanja, a predstavljaju jasne, visoko kontrastne značajke s jasno definiranim centroidom te poznatim X, Y i Z vrijednostima (Westoby i dr., 2012).

2.5.1.3.1 Trokut ekspozicije

Prikupljanje fotografija se u literaturi opisuje kao "osjetljiv korak u (inače) automatiziranom procesu fotogrametrije" (Micheletti i dr., 2015). Osnovni razlog za to je međuovisnost i utjecaj tri osnovna elementa fotografije na njenu ekspoziciju i kvalitetu te u konačnici na 3D model. Oni uključuju:

a) Brzinu zatvarača (eng. *shutter speed)*;

Brzina zatvarača označava podešavanje vremena u kojem je *zaslon* otvoren, a senzor izložen svjetlosti iz okruženja. Ako je brzina zatvaranja velika (npr. 1/500) to znači da je digitalni senzor petstoti dio sekunde izložen svjetlu. Suprotno, ako je brzina zatvaranja mala (npr. 1) može doći do stvaranja zamućenja/zamagljenja (eng. *motion blur*) duž smjera kretanja objekta ili pomicanja kamere.

b) Osjetljivost senzora na svjetlo (ISO);

ISO predstavlja brojčanu vrijednost koja ukazuje na to koliko je digitalni senzor osjetljiv na svjetlo. Niži broj znači manju osjetljivost. S većim brojem je moguće snimiti fotografiju u okruženju slabog osvjetljenja bez potrebe za uključenjem bljeskalice. Međutim, povećana osjetljivost može rezultirati pojavom zrnaca ili šuma na slikama. Kod veće ISO vrijednosti signal koji se dobije od fotona svjetla na senzoru se elektronički pojačava. Pojačanjem signala intenzivira se pozadinski elektronički šum koji je prisutan u svim elektroničkim napravama. Svaka kamera ima osnovni ISO, odnosno najniži broj s kojim senzor može proizvesti najvišu kvalitetu slike bez dodavanja šuma. Nije moguće uvijek koristiti bazni ISO, osobito ako se radi o uvjetima slabog osvjetljenja, velikog f-broja (npr. f/22) ili velike brzine zatvaranja (npr. 1/2000). ISO brojevi počinju od 100, a potom se povećavaju geometrijskom progresijom. Svako povećanje ISO-a udvostručuje osjetljivost senzora na svjetlo. U procesu snimanja se općenito predlaže postavljanje manjih ISO vrijednosti kako bi se izbjegla pojava šuma (URL 32).

[51] Ground Control Point

c) Otvor blende (eng. *f-stop* ili *aperture*);

Otvorenost blende se opisuje s f-brojem. Manji otvor blende znači veći f-broj (npr. f/22) što podrazumijeva manju količinu ulaznog svjetla. Većina digitalnih kamera ima vrijednosti f-broja od 2 do 22 (URL 30). F-broj je ključni parametar koji utječe na dubinu polja (DoF) (URL 31). Manja vrijednost f-broja generira manju dubinu polja. Najveći f-broj u pravilu rezultira slikom na kojoj su svi predmeti izoštreni. Iako veća vrijednost generira veću dubinsku oštrinu, ona isto tako uzrokuje pojavu difrakcije[52], odnosno ogiba svjetlosti. To cjelokupnu sliku čini slabije kontrastnom iako joj je parametar dubine polja velik. Da bi se izbjegla difrakcija svjetlosti preporučuje se postavljanje f-broja na vrijednosti od 11 do 16 (URL 32). Ipak, u procesu snimanja makrofotogrametrije to često nije moguće.

Navedena tri elementa čine trokut eksponiranja (eng. *exposure triangle*). Eksponiranje označava izloženost digitalnog senzora upadnoj svjetlosti, a rezultat je otvora blende i brzine zatvarača. Prevelika ekspozicija generira presvijetle, a premala tamne i zamućene slike. Korisnik prilikom fotografiranja može sam odrediti najprimjerenije vrijednosti navedenih parametara (eng. *manual mode*) kako bi dobio odgovarajuću ekspoziciju. Time prilagođava osjetljivost kamere prema trenutnim uvjetima okoline te vrsti objekta kojeg snima. Fotografiranje u *manual modu* znači da će sve fotografije imati iste vrijednosti navedenih elemenata.

2.5.1.3.2 Koncepti snimanja u blizupredmetnoj fotogrametriji

Prvi korak u generiranju 3D modela SfM fotogrametrijom se odnosi na konstrukciju fotogrametrijskog mjernog sustava (eng. *photogrammetric expert measurement systems*) (Ergun i Baz 2006) koji omogućava izradu plana snimanja kvalitetnih fotografija (Yamafune, 2016). Snimanje fotografija mora biti provedeno tako da se minimiziraju uobičajeni problemi koji se javljaju u procesu blizupredmetne fotogrametrije: neravnomjerni intenzitet svjetla, pojave sjene, plitka dubina polja (DoF), zamagljene fotografije i nedovoljno preklapanje fotografija. Ključni izazov u izvođenju procesa CRP-a predstavlja razvoj fotogrametrijskog mjernog sustava koji bi osigurao potrebnu stabilnost i kvalitetu od snimanje fotografija do generiranja 3D modela površinskih struktura (Wrackrow i dr. 2007, Bertin i Friedrich, 2016). Taj se postupak može podijeliti u pet dijelova (Ergun i Baz, 2006):

a) Dizajn i konstrukcija koncepta snimanja;

b) Kalibracija senzora;

[52] Difrakcija je optički efekt koji limitira ukupnu rezoluciju fotografije (Medić, 2015: 55)

c) Prikupljanje fotografija;

d) Obrada fotografija;

e) Izrada modela.

Kvalitetan fotogrametrijski mjerni sustav mora imati mogućnost određivanja prednjeg i bočnog preklapanja fotografija, prostorne rezolucije modela, kalibracije kamere, te postizanja istih uvjeta ekspozicije fotografija. Primjerice, snimljene fotografije bi se trebale preklapati najmanje 60% kako bi se osigurala podudaranja između homolognih točaka na temelju kojih softver rekonstruira objekt ili scenu (Ramos i Pierto, 2015). Ako nema dovoljnog preklapanja, značajke na slikama se ne mogu povezati čime se gubi mogućnost točnog određivanja lokacije kamere u prostoru. Poznavanje vanjskog položaja kamere u SfM fotogrametriji nije ključno, jer se geometrija objekta uspostavlja izravno iz slika, ali je poželjno ako se 3D model želi izvesti izravnim georeferenciranjem. Nadalje, jedan od glavnih problema izvođenja procesa CRP-a je postizanje odgovarajućih i ujednačenih svjetlosnih uvjeta cijelog procesa snimanja (Lluis i dr., 2014). Fotografije moraju biti snimljene u sobi s difuznim izvorom svjetla koji ravnomjerno raspršuje svjetlost. Potrebno je izbjeći pojavu refleksije i stvaranje oštrih sjena na objektu (Evin i dr., 2016). Naime, točkasti ili usmjereni izvori svjetlosti mogu stvoriti odsjaj na površini snimanog objekta smanjujući time kvalitetu izrađene teksture i 3D modela (Samaan i dr., 2013). Prilikom snimanja treba obratiti pozornost na teksturu objekta. Potrebno je izbjegavati prozirne, reflektivne i monokromne objekte (Nicolae i dr., 2014, Bodrožić i dr., 2015). Na takvim objektima gotovo je nemoguće obaviti uspješan proces CRP-a.

Poželjno je da objekt u procesu snimanja bude fiksiran. Idealno bi bilo da se kamera kreće oko i/ili iznad objekta snimajući preklapajuće fotografije. U literaturi se navodi i obrnuti koncept. Međutim, time se mijenja položaj objekta u odnosu na izvor svjetlosti što može promijeniti uzorak sjene ili teksture na objektu. To prilikom pronalaska homolognih veznih točaka (eng. tie points) na snimcima softveru može prouzročiti značajne probleme. Problem sjene se može izbjeći *poplavljivanjem* cijelog objekta ili prostorije sa svjetlom iz svih kutova vidljivih kameri (Porter i dr., 2016).

U literaturi su predloženi različiti konceptualni i fizički fotogrametrijski mjerni sustavi za uspješno izvođenje procesa CRP-a. Porter i dr. (2016) su koristili rotacijsku plohu na kojoj je smješten objekt snimanja. Postigli su uvjete difuzne osvijetljenosti te kreirali odgovarajuću monokromnu pozadinu kako bi osigurali jednostavnije maskiranje dijelova fotografija. Svakih 10° su rotirali plohu te snimali fotografiju dok je položaj kamere bio fiksiran (Slika 29). Sličan koncept su napravili Evin i dr. (2016) snimajući u pravilnim razmacima od otprilike 10°

istovremeno pomičući kameru po stalku (Slika 29). Ergun i Baz (2006) su konstruirali složeniji sustav za potrebe mjerenja deformacija na površini betonskih materijala.

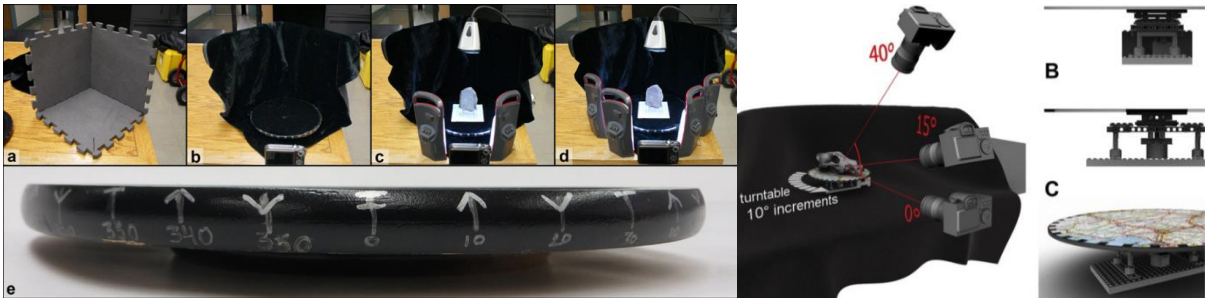

Slika 29. Primjer jednostavnih fotogrametrijskih mjernih sustava u CRP-u

Izvor: Evin i dr., 2016, Porter i dr., 2016

2.5.1.3.3 Snimanje i obrada fotografija u procesu CRP-a

Proces snimanja u fotogrametriji može biti izveden s dvije vrste kamera: mjernom (eng. *metric*) i nemjernom (eng. *non metric*). U tradicionalnoj fotogrametriji snimanje se izvodi mjernim kamerama koje imaju stabilne i poznate parametre unutarnje orijentacije i nisku distorziju leće. Njihovi parametri distorzije se mogu iščitati iz testa kalibracije koji je laboratorijski proveo proizvođač (Ansari i Gondaliya, 2013). Dakle, kod mjernih kamera poznata je sistemska pogreška objektiva (Ciceli, 2007). Distorzija je pogreška objektiva koja nastaje u preslikavanju prostora u ravninu slike. Ona utječe na geometrijska izobličenja i nedovoljno oštre snimke (Ciceli, 2007, Gajski i Gašparović, 2015, Gašparović i Gajski, 2016). Međutim, za dobivanje kvalitetnih 3D modela u većini slučajeva nije potrebno investirati u skupe mjerne kamere, već uz ispravnu kalibraciju digitalne nemjerne kamere mogu postati mjerne (Percoco i dr., 2015). DSLR[53] kamere su opterećene brojnim pogreškama čiji su izvor optički sustav, odnosno nesavršenost njihove izrade (Gašparović i Gajski, 2016). One ne posjeduju značajke mjernih kamera, ali imaju određene prednosti: široko su dostupne, lagane, moguća je zamjena leća i fokusiranje na različite udaljenosti (Ansari i Gondaliya, 2013).

Procesom kalibracije se definira geometrija svjetlosnog snopa koji kroz sustav leće prolazi u kameru (Ciceli, 2007). Utvrđuje se intrinzična matrica (eng. *intrinsic matrix*), odnosno pet unutarnjih orijentacijskih parametara kamere (Schenk, 2005, Percoco i dr., 2015, NN 65/2016, URL 40) koji opisuju metričke karakteristike kamere. Glavna svrha unutarnje orijentacije je definiranje lokacije perspektivnog centra slike i krivulje radijalnog iskrivljenja (URL 40). Univerzalni standard za kalibraciju kamere ne postoji (Schenk, 2005, Ansari i Gondaliya, 2013). Postoji velik broj kalibracijskih softvera: *MATLAB, Agisoft Lens*,

[53] Digital Single-Lens Reflex

PhotoModeler, *iWitness*, *Camera Calibrator*, *LISA-FOTO* (Ansari i Gondaliya, 2013), matematičkih modela (Gašparović i Gajski, 2016) te metoda geometrijske kalibracije kamere od kojih su neke: autokalibracijska, kalibracijski kavez, kalibracija ravninom i štapom (Kosanović, 2010).

Pet osnovnih unutarnjih (intrinzičnih) orijentacijskih parametara uključuju (Kosanović, 2010, URL 40):

1) f_x, f_y - žarišna (fokalna) duljina izražena u pikselima;
2) x_p i x_y - koordinate perspektivnog centra slike u pikselima;
3) s - koeficijent iskrivljenja između x i y osi.

Prva dva parametar se odnose na vrijednosti žarišnih (fokalnih) udaljenosti (f_x i f_y) izraženim u pikselima. S obzirom na to da pikseli nisu kvadratnog oblika daju se dva čimbenika skale x i y. Treći i četvrti opisuju položaj perspektivnog centra slike koji nastaje uslijed nesavršenosti postavljanja leće u kućište kamere, tako da ono ne mora nužno biti središnji piksel senzora (x_p i x_y). Izražava se u pikselima jer je u 2D koordinatnom sustavu slikovne ravnine mjerenje udaljenosti moguće izraziti samo u toj vrijednosti. Posljednji parametar se odnosi na iskošenost (eng. *skew*) senzora, koji opisuje izgled piksela, odnosno u kolikoj mjeri on ima oblik paralelograma. Ovaj parametar se uglavnom zanemaruje u procesu kalibracije.

U ostale unutarnje parametre kamere spada distorzija, odnosno izobličenje objektiva (URL 40). Postoje dva tipa distorzije: radijalna i tangencijalna (Gašparović i Gajski, 2016). Radijalna može biti bačvasta (eng. *barrel*) koja znači preslikavanja točaka bliže optičkoj osi te jastučasta (eng. *pincushion*) gdje dolazi do preslikavanja točaka dalje od optičke osi (Ciceli, 2007, Kosanović, 2010). Radijalna distorzija je u središtu slike jednaka nuli te se povećava udaljavanjem od centra (Kosanović, 2010). Drugim riječima zrake svjetlosti se više savijaju u blizini rubova leće nego u optičkom središtu (URL 41). Kalibracijom se određuju k_1, k_2, i k_3 koeficijenti radijalne distorzije (Kosanović, 2010). Obično su dovoljna prva dva koeficijenta. Za veće distorzije (širokokutni objektivi) potrebno je uključiti k_3 (URL 41). Tangencijalna distorzija predstavlja neparalelan položaj leće i senzora u kućištu kamere. Reprezentirana je s dva parametra p_1 i p_2 koje je potrebno odrediti geometrijskom kalibracijom kamere. U modernijim kamerama ovaj parametar se zanemaruje (Kosanović, 2010).

Vanjskih orijentacijskih parametara ima šest. Tri translacijska parametra (X_C, Y_C, Z_C) opisuju lokaciju perspektivnog centra slike u lokalnom ili globalnom koordinatnom sustavu, dok se tri rotacijska parametra odnose na kutne vrijednosti lateralne (*pitch* – θ), longitudinalne (*roll* – φ) i vertikalne osi (*yaw* – ψ) poznate kao glavne osi ili osi rotacije. Oni definiraju lokaciju i kutnu orijentaciju kamere u definiranom koordinatnom sustavu. Mogu se odrediti

izravno (GPS[54] i IMU[55] sustavi) ili tijekom fotogrametrijskog procesa (URL 40). Određivanje vanjskih orijentacijskih parametara izravno, odnosno u trenutku kad je slika prikupljena preduvjet je izravnom georeferenciranju (DG[56]).

Proces obrade snimaka u SfM fotogrametriji generalno se može podijeliti u četiri koraka (Ansari i Gondaliya, 2013, Percoco i dr., 2015, Eltner i dr., 2016):

1) Prikupljanje fotografija (eng. *image acquisition*)

Snimanje kvalitetnih fotografija ključan je preduvjet izvođenja točnih modela (Ansari i Gondaliya, 2013). Kvalitetne fotografije se generiraju uvažavanjem sljedećih postavki:

- Odrediti odgovarajuću dubinu polja;
- Podešavanje vrste fokusa ovisno o veličini snimanog objekta te položaju kamere (tripod ili ručno snimanje);
- Postavljanje brzine zatvarača uvažavajući uvjete snimanja s ciljem izbjegavanja zamućenih fotografija;
- U uvjetima slabije osvijetljenosti podesiti odgovarajuću ISO vrijednost;
- Odabir odgovarajuće platforme snimanja s ciljem fiksiranja kamere;
- Kalibriranje kamere prema definiranim postavkama snimanja;
- Praćenje plana snimanja uvažavajući postotak preklapanja te održavajući konstantnu udaljenost kamere od objekta;
- Prikupljanje većeg broja fotografija od planiranog;
- Postizanje uvjeta jednake osvijetljenosti objekta;
- Analiziranje kvalitete fotografija;

2) Relativna orijentacija (eng. *image matching*)

Relativna orijentacija pretpostavlja orijentaciju vanjskih snopova više fotografija kako bi na presjeku bio stvoren umanjeni nedeformirani model snimljenog terena. Posljednjih godina ovaj problem se rješava identifikacijom homolognih piksela na preklapajućim fotografijama, njihovim usklađivanjem (eng. *align*), rekonstrukcijom orijentacije i položaja fotoaparata te konfiguracije unutarnjih geometrijskih parametara kamere primjenom iterativne BA tehnike (Lowe, 1999, Stöcker i dr., 2015, Smith i dr., 2016).

3) Apsolutna orijentacija modela (eng. *scale and georeferencing*)

[54] Global Positioning System
[55] Inertial Measurement Unit
[56] Direct Georeferencing

Apsolutna orijentacija predstavlja proces orijentacije i georeferenciranja rekonstruiranog stereomodela u odnosu na lokalni ili globalni koordinatni sustav. Transformacija se rješava uvođenjem minimalno tri GCP-a. GCP su objektne točke s poznatim X, Y i Z vrijednostima unutar nekog koordinatnog sustava (URL 40).

4) Izvođenje modela

Točnost generiranih modela ovisit će o nizu čimbenika: rezoluciji kamere, točnosti kontrolnih točaka, kalibraciji kamere, prostornoj rezoluciji modela (udaljenosti kamere, mjerilo snimanja), algoritmu za usklađivanje fotografija (Eltner i dr., 2016), broju, preklapanju i kvaliteti fotografija (Percoco i dr., 2015) te uvjetima snimanja (Eltner i dr., 2016). Veličina piksela izlaznog modela može biti izračunata kroz formulu (Ansari i Gondaliya, 2013).

2.5.1.4 Makrofotogrametrija

Usprkos recentnom napretku SfM fotogrametrije ona tek treba biti široko primijenjena u modeliranju objekata ili scene na mikro razini (Verma i Bourke 2019). Takva razina detaljnosti zahtjeva generiranje modela submilimetarske (< 1 mm) prostorne rezolucije i točnosti. Tehnike koje se primjenjuju kada se zahtjeva izvođenje takvih modela su blizupredmetna fotogrametrija (eng. *very close range photogrammetry*) (Yanagi i Chikatsu, 2010) te makrofotogrametrija (eng. *macro-photogrammetry*) (Hlongwa i dr., 2007, Rodríguez-Martín i dr., 2015, Rodríguez-Martín i dr., 2016, Gajski i dr., 2016, Marziali i Dionisio, 2017). Makro fotografija (eng. *macro photography*) se odnosi na ekstremno blizu uslikanu fotografiju, obično vrlo malog objekta u kojima je njegova veličina na senzoru uređaja jednaka ili veća od njegove stvarne vrijednosti (URL 39). Prema najstrožoj definiciji makrofotogrametrija je vrsta snimanja u kojem je veličina subjekta na negativu ili senzoru slike u stvarnoj veličini ili veća (mjerilo 1:1) (Percoco i dr., 2015, Gajski i dr., 2016, URL 33). Krupno mjerilo snimanja se može postići koristeći produžne cijevi (eng. *extension tube*), te makro objektiv (Gajski i dr., 2016). Inače, mali objekti i scena se najpouzdanije mogu snimiti primjenom aktivnih triangulacijskih senzora čija se točnost mjeri u mikrometrima. Takva tehnologija je financijski nedostupna većini korisnika te nije praktična (Nicolae i dr., 2014) zbog čega se većina okreće primjeni različitih fotogrametrijskih tehnika (Yanagi i Chikatsu, 2010).

Makroobjektivi su posebno dizajnirani objektivi koji imaju mogućnost snimanja kvalitetnih fotografija malih objekata s malih udaljenosti postižući veliku detaljnost prikaza (Yanagia i Chikatsu, 2010, Percoco i dr., 2015). Makro objektivom se moguće izrazito približiti objektu snimanja što rezultira velikim faktorom povećanja (npr. 3:1, 2:1). Makrofotogrametrija može biti izvrsna za snimanje vrlo malih objekata, ali to dolazi pod cijenu smanjene dubine

polja. Taj problem se može riješiti tehnikom slaganja fokusa (eng. *focus stacking*), odnosno spajanja više fotografija snimljenih prema različitim postavkama proizvodeći fotografiju jedinstvenog fokusa (izoštrenost slike na svim dubinama) (Brown i dr., 2015)

Uspješno snimanje malih objekata ili scene podrazumijeva rješavanje nekoliko temeljnih problema koji su karakteristični za makrofotogrametriju. Oni uključuju:

1. Smanjenu dubinu polju (DoF)
2. Pojava sjena (eng. *shadow occurance*)
3. Podešavanje fokusa (URL 33).
4. Zamućene fotografije (eng. *motion blur*)
5. Nedovoljno preklapanje fotografija (eng. *insufficient photo overlap*)
6. Nejednaka osvijetljenost (eng. *uneven light intensity*)

Dubina polja je najkritičniji i glavni problem makrofotogrametrije (Gajski i Gašparović, 2016, Marziali i Dionisio, 2017). DoF predstavlja udaljenost između najbližeg i najdaljeg objekta na sceni koji se na slici čini prihvatljivo oštar (eng. *acceptably sharp*). Ovisi o žarišnoj udaljenosti, f-broju i udaljenosti objektiva od objekta, a izražava se formulom (Yanagia i Chikatsu, 2010, Marziali i Dionisio, 2017):

$$DoF = \frac{2NcF^2d^2}{F^4 - N^2c^2d^2} \quad (2)$$

gdje je:

DoF = dubina polja

N = dijafragma leće koja kontrolira otvor blende (f-broj)

F = žarišna udaljenost

c = krug konfuzije (eng. *circle of confusion*)

d = udaljenost objektiva od objekta

Dijafragma je fotoosjetljiv element napravljen od polukružnih sfera koje reguliraju ulaz svjetlosti. Manji promjer otvora dijafragme, znači da je f-broj postavljen na veću vrijednost. To generira veću vrijednost dubine polja, ali smanjuje količinu dolazne svjetlosti. Žarišna ili fokalna udaljenost je udaljenost od žarišne točke na senzoru do središta optičkog elementa. Krug konfuzije (CoC[57]) ili *disk zbunjenosti* je pojava kad zrake svjetlosti ulaze u objektiv tako da proizvode veću optičku točku. To je mjera koja opisuje točku svjetlosti gdje svjetlo konvergira padajući na žarišnu ravninu.

[57] Circle of Confusion

Nejednaka osvijetljenost i pojava sjena je često povezan problem u makrofotogrametriji (Nicolae i dr., 2014, Percoco i dr., 2015). To ne čudi s obzirom na to da su pasivni senzori, ovisni o vanjskom izvoru zračenja (Nicolae i dr., 2014). Kao idealno rješenje nameće se postizanje difuzne osvijetljenosti oko objekta snimanja kako bi se mogla izbjeći pojava sjena te generiranje krivih X, Y i Z vrijednosti. Zbog toga se predlaže korištenje kružne bljeskalice (eng. *ring flash*) koja usmjerava svjetlo iz objektiva izravno na objekt.

Nadalje, uvažavajući postavljene vrijednosti brzine zatvarača (dulja ekspozicija), potrebno je osigurati stabilnost kamere, zbog čega je poželjno da kamere montiraju na različite stative (URL 32). Naime, prilikom snimanja u mjerilom 1:1 ili 2:1 pomicanjem fotoaparata od nekoliko milimetara dolazi do izbacivanja cijele fotografije iz fokusa (URL 33). Mala dubina polja u ovakvom načinu snimanja stvara velike poteškoće prilikom fokusiranja (URL 34). Zbog toga se često preporučuje montiranje kamere na fiksnu poziciju te postavljanje manualnog fokusa (URL 33, URL 34). Promjenjive (automatske) postavke fokusa mogu uzrokovati promjenu svojstava leće (Eltner i dr. 2016), pogreške u povezivanju fotografija (eng. *misalignment*) te razlike u balansu bijele boje (Frey, 2019).

Snimanje malih objekata u mjerilu 1:1 ili većem zahtjeva postavljanje velike žarišne udaljenosti (manji kut snimanja). To generira vrlo plitko područje scene u fokusu što rezultira zamućenim slikama. Takve slike mogu uzrokovati poteškoće u procesu spajanja fotografija, izvođenju gustih oblaka točaka te mogu generirati artefakte u konačnoj teksturi modela. Rješavanje ovog problema se postiže postavljanjem f-broja na veće vrijednosti (npr. 22). Iako to odstupa od optičkog optimuma f-11, ipak daje odgovarajući kompromis između dubine polja i oštrine slike (Marziali i Dionisio, 2017).

2.6.1 LiDAR (eng. *Light Detection and Ranging*)

Lasersko skeniranje predstavlja aktivnu tehniku daljinskih istraživanja koja primjenjuje laser u brzom, automatiziranom, efektivnom i obilnom prikupljanje prostornih podataka u obliku oblaka točaka (X, Y i Z) koji prezentiraju mjerljiv 3D model (Miler i dr., 2007, Novak, 2007, Hantson i dr., 2012). Posljednjih desetljeća smatra se tehnologijom koja je najviše napredovala u razvoju (Ansari i Gondaliya, 2013). Danas ima vrlo široku primjenu te se smatra najučinkovitijom metodom prikupljanja prostornih podataka (Barada, 2017). Laser[58] predstavlja koherentno (ista brzina i energija), monokromatsko (ista valna duljina), usko usmjereno zračenje (paralelno kretanje fotona u uskom snopu) (Kičić, 2017). Obilježava ga brzina i točnost te izrazita gustoća prikupljanja prostornih podataka (Novak, 2007). Lokacija

[58] Light Amplification by Stimulated Emission of Radiation

(X, Y i Z) točaka se određuje na temelju vremenske razlike emitiranog i povratnog laserskog impulsa, kuta ispuštenog impulsa te apsolutnog položaja uređaja (Gallagher i Josephs, 2008). Oblak točaka može biti apsolutni (georeferencirani) i relativni (lokalni) te izuzev prostorne komponente sadržavati podatke o intenzitetu i vremenu refleksije (Miler i dr., 2007). Dovoljno gust oblaka točaka u potpunosti opisuje topografiju snimljenog područja (Collins i dr., 2008). Prikupljanje oblaka točaka vrši se uglavnom kroz softver koji u pravilu dolazi sa skenerom (Miler i dr., 2007). Prednost LiDAR-a u odnosu na fotogrametriju je bolja točnost te mogućnost eliminacije vegetacijskog pokrova čime se dobiva model čvrstog terena (Gallagher i Josephs, 2008, Ansari i Gondaliya, 2013).

Različite vrste laserskog skeniranja korištene su u istraživanjima krajobraza zaštićenih područja. Oni uključuju: utvrđivanje optičke grubosti koraljnih grebena (Brock i dr., 2004, Kičić, 2017), određivanje složenosti bentonskih[59] staništa (Wedding i dr., 2008), detekciju kulturnih resursa u šumskom okruženju (Gallagher i Josephs, 2008), kartiranje visina i biomase šuma (Simard i dr., 2006), kvantifikacije štete nastale uraganima i udarima gromova (Zhang i dr., 2008), praćenje geomorfnih promjena na arheološkim lokalitetima (Collins i dr., 2008), ispitivanje ranjivosti obala (Stockdon i dr., 2009), detekciju invazivnih vrsta (Asner i dr., 2008, Huang i Asner, 2009, Hantson i dr., 2012) itd.

U sklopu disertacije lasersko skeniranje je korišteno na makro i mezo razini istraživanja. Na makro razini je za potrebe određivanje testne plohe na širem području Skradinskog buka izvršeno zračno skeniranje, dok je na mezo razini izvršeno terestričko skeniranje odabrane testne plohe. Metodologije procesa skeniranja detaljnije su objašnjena u poglavlju metodologije.

2.6.1.1 Terestričko lasersko skeniranje (TLS)

Terestrički laserski skeneri (TLS[60]) su uređaji koji snimaju prostor s tla na principu laserske tehnologije (Miler i dr., 2007). TLS se postavi na fiksnu lokaciju, uglavnom na tronožac, s otvorenim vidnim poljem koji je usmjeren na okolni prostor (Collins i dr., 2008). Posljednjih godina popularna je montaža na automobile, brodove ili na naprtnjače čime se dobije mobilni uređaji za kartiranje. TLS se može razlikovati prema dometu i tehnološkim obilježjima. Osim oblaka točaka i intenziteta refleksije, mogu prikupljati i fotografije ako

[59] Bentos (grč. *benthos* = dubina) je ekološka grupa organizama, koja životne aktivnosti ostvaruje na dnu vodenih ekosistema.
[60] Terrestrial Laser Scanning

skener posjeduje digitalnu kameru. Prema načinu skeniranja mogu se podijeliti na: kamera skenere, panoramske te hibridne (Slika 30).

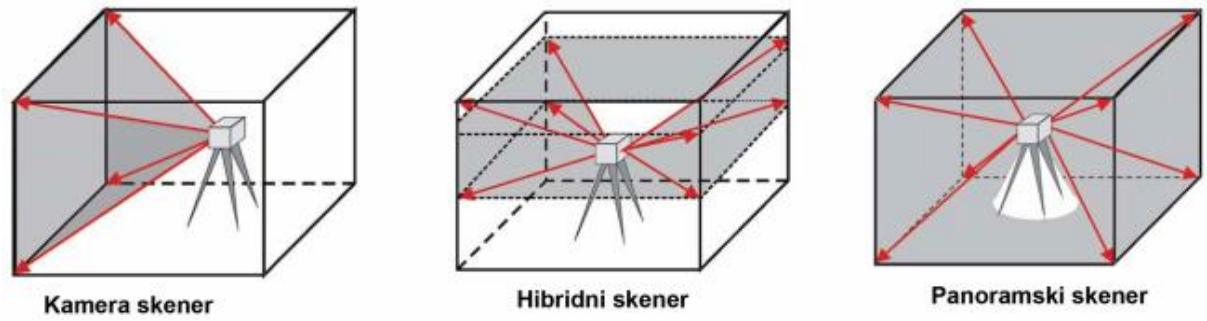

Slika 30. Vrsta TLS-a prema načinu skeniranja

Izvor: prema Miler i dr., 2007

Prema načinu mjerenja udaljenosti postoje: pulsni, fazni i triangulacijski skeneri (Miler i dr., 2007). Neke vrste triangulacijskih skenera rade na principu strukturiranog svjetla prema čemu strogo gledajući ne spadaju u kategoriju laserskih skenera. Fazni skeneri koriste velike frekvencije, a udaljenost određuju prema faznoj razlici između primljenog i odaslanog vala (Kičić, 2017). Obilježava ih visoka točnost (do nekoliko milimetara), te brzina prikupljanja podataka. Negativne strane primjene su im ograničen domet i štetnost laserskog zračenja za vid. Pulsni laserski (TOF[61]), precizno mjeri vrijeme puta laserske zrake do prepreke te nazad do senzora (vremenski interval). Triangulacijski funkcionira na principu rada optičke triangulacije, nedostatak mu je ograničen domet, ali se točnost mjeri u mikrometrima (Miler i dr., 2007).

2.6.1.2 Zračno lasersko skeniranje (ALS)

Zračno lasersko skeniranje (ALS[62]) predstavlja krajnje dostignuće geodetskih izmjera, a odnosi se na primjenu LiDAR tehnologije u zračnom snimanju (French, 2003, Novak, 2007, Kincey i Challis 2009). Avion, helikopter ili bespilotna letjelica je uz skener opremljena s inercijalnim mjernim sustavom (IMU), GNSS[63]-om koji određuju orijentaciju i lokaciju senzora u prostoru te računalom za pohranu i obradu laserskih podataka (French, 2003, Kičić, 2017). Oni zajedno tvore POS[64] sustav (Barada, 2017). Zračno lasersko skeniranje ima mogućnost identificiranja i klasificiranja više povratnih faza odaslanog signala čime se oblak

[61] Time of Flight
[62] Airborne Laser Scanning
[63] Global Navigation Satellite System
[64] Position Orientation System

točaka može klasificirati, najčešće u građevine, čvrsti teren i vegetaciju. Vidni kut skenera (FOV[65]) te visina leta utječu na površinu snimljenog područja tijekom preleta (Kičić, 2017).

2.6.2 3D projekcijski skeneri

3D projekcijski skeneri su beskontaktni mjerni sustavi koji koriste projekciju strukturiranog svjetla u različitim bojama i princip triangulacije prilikom generiranja 3D koordinata. Ne spadaju u laserske skenere, a namijenjeni su snimanju objekata od približno 1 cm do 3 m (URL 38). Strukturirani svjetlosni uzorci se projiciraju na površinu snimanog objekta uglavnom u obliku višestrukih paralelnih zraka (URL 38). Potom se uspoređuje deformacija projiciranog svjetlosnog uzorka u odnosu na referentni (Slika 31).

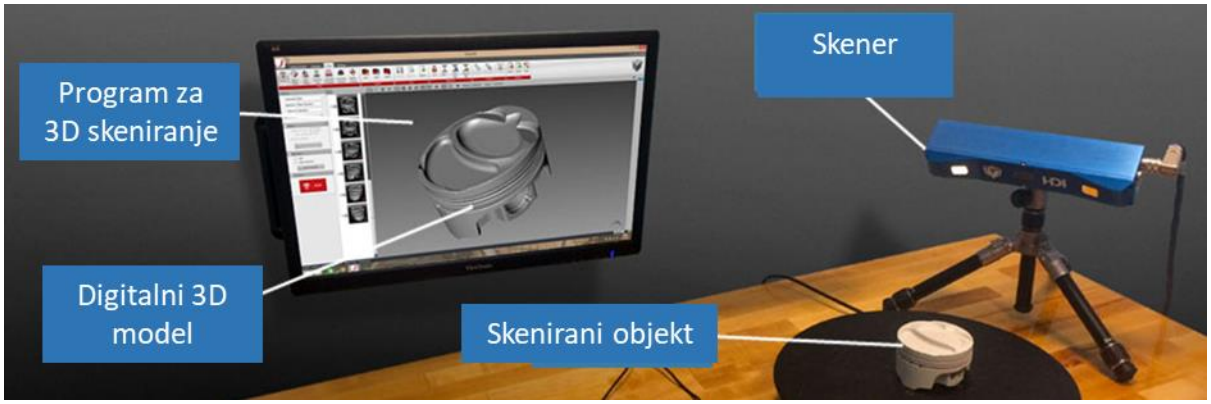

Slika 31. Sastavnice 3D skenera strukturiranog svjetla

Izvor: URL 38

Proces 3D optičkog mjerenja sastoji se od nekoliko koraka:

a) Kalibracija;
b) Projekcija svjetlosnog uzorka;
c) Snimanje slike;
d) Dekodiranje uzorka;
e) Triangulacija;
f) Rekonstrukcija površine.

Izlazni rezultat je gusti oblak točaka unutar kojega svaka točka ima svoje precizne prostorne koordinate. Gusti oblak točaka se pohranjuje na memoriju prijenosnog računala ili tableta, na kojemu se podaci prikazuju u realnom vremenu. Ono znatno olakšava skeniranje promatrane površine, jer omogućava detekciju prostora koje treba dodatno skenirati u realnom vremenu. Povezivanjem prikupljenih točaka vrši se rekonstrukcija skeniranog modela. Neki skeneri prikupljaju i podatke o teksturi. U većini slučajeva jedno skeniranje nije dovoljno da

[65] Field of View

se ocrtaju sve točke prostora te se pomoću njih ne može izraditi cjeloviti model. Nakon spajanja dijelova i linearizacije podataka generira se prostorni 3D model na kojeg se ugrađuje tekstura koja može biti proizvoljna, ili stvarna. U konačnici je unutar odgovarajućeg softverskog okruženja moguće iz prikupljenog gustog oblaka točaka izraditi 3D modele sub-milimetarske preciznosti. U sklopu disertacije korišteni su ručni 3D projekcijski skeneri *Artec Eva* i *Space Spider*.

3. METODOLOGIJA ISTRAŽIVANJA

Metodologija istraživanja se temelji na interdisciplinarnom pristupu u kojem su korištene metode iz različitih znanstvenih polja. Interdisciplinarni pristup podrazumijeva tretiranje uočenog problema kao cjeline uvažavajući saznanja stručnjaka iz različitih disciplina. Integracija znanja i tehnologija rezultira potpunijim i djelotvornijim rješenjem. Metodološki okvir istraživanja je rezultat provedbe interdisciplinarnog znanstvenog projekta pod nazivom *Upravljanje i održavanje makrovegetacije na Skradinskom buku – izrada višekriterijskog modela održivog upravljanja* kojeg je pokrenula Javna ustanova NPK.

Glavni razlog za pokretanje projekta je primjećeno ugrožavanje održivih uvjeta sedrenja na nekim lokacijama u NPK, te remećenje bioraznolikosti sedrenog krajobraza. Glavni uzrok navedenog problema prepoznat je u nekontroliranom rastu i širenju pajasena. Naime, na širem prostoru Skradinskog buka uočeno je pretjerano zaraštavanje rubnih obalnih zona pojedinih tokova i jezera, što je izazvalo promjenu smjera otjecanja sedrotvornih tokova, smanjenje energije protoka, povećanu proizvodnju organskih tvari te isušivanje tokova. Sličan problem je uočen u NPPJ gdje je izvršeno uklanjanje prekomjerne vegetacije na sedrotvornim vodotocima. Iz navedenih razloga Uprava NPK je prepoznala potrebu za donošenjem i implementacijom aktivnih mjera zaštite, odnosno metodološkog okvira koji se učinkovito može primijeniti u rješavanju ovog biohidrodinamičkog problema, s cilju očuvanja temeljnog fenomena Parka, odnosno održivog upravljanja sedrotvornim vodotocima.

Metodologija istraživanja je podijeljena u tri razine uvažavajući princip višerezolucijskog (hijerarhijskog) modeliranja krajobraza. Razumijevanje uočenih promjena u Parku zahtjeva višerezolucijsku analizu elemenata i procesa jer su analize temeljene na uniformnom mjerilu u ovom slučaju neprimjenjive. Teorija hijerarhije krajobraza navodi da mehaničko razumijevanje proučavanog elementa dolazi s niže, a značaj s više hijerarhijske razine. Stoga je dinamika promjene žarišnog elemenata (sedre) pod utjecajem velikih skupova elemenata niže (biohidrokemijski parametri) i više (gustoća vegetacije, morfologija tla) hijerarhijske razine. Ispitivanje takvih pojava zahtjeva proučavanje promjene elemenata u različitim mjerilima (Levin, 1992).

Prvu (makro) razinu istraživanja čini skup aktivnosti usmjerenih prema odabiru testne plohe unutar šireg područja Skradinskog buka. Druga (mezo) razina je usmjerena na kartiranje tokova i vegetacije, selektivno uklanjanje vegetacije na definiranoj plohi. U posljednjoj (mikro) razini proučava se dinamika sedrenja na postavljenim pločicama s naglaskom na reaktivirane tokove (Slika 32).

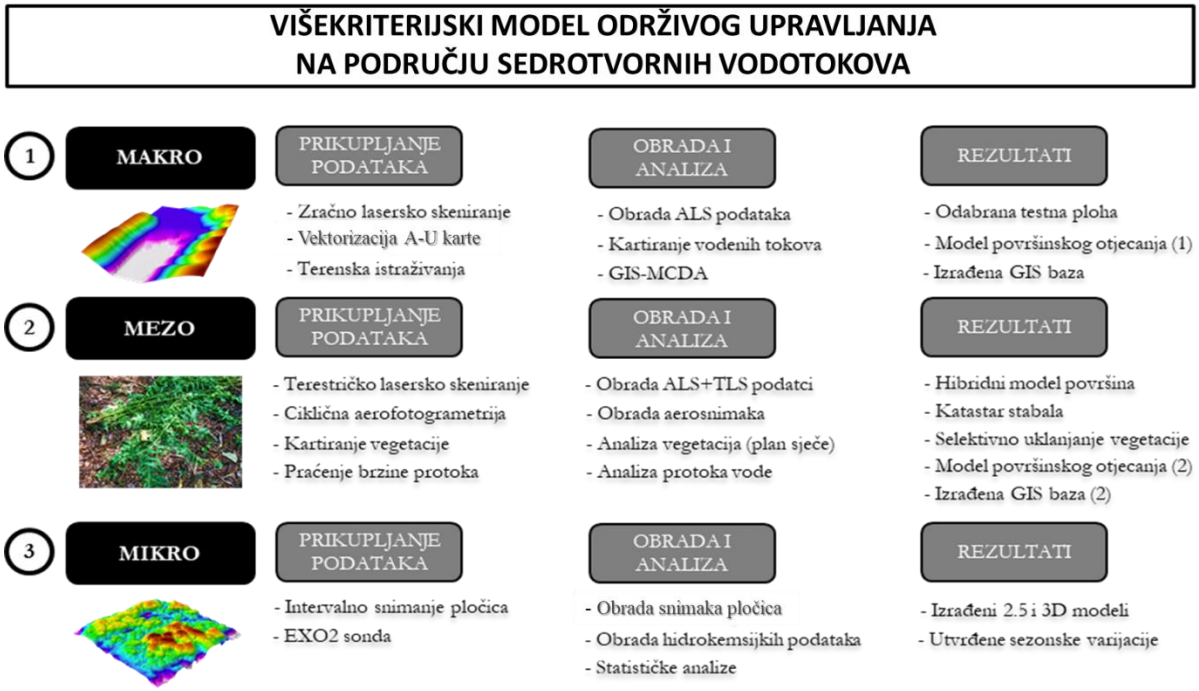

Slika 32. Shema metodološkog okvira istraživanja

Poseban dio metodološkog okvira na mikro razini obuhvaća izradu novog koncepta, temeljenog na makrofotogrametriji, za izravno, beskontaktno, intervalno praćenje dinamike sedrenja kroz 3D modele sedre submilimetarske rezolucije i točnosti. U odnosu na dosadašnje metode mjerenja stopa prirasta sedre ovim konceptom bi se uklonila mogućnost oštećenja površinskog sloja sedre te omogućilo preciznije određivanje akumulacijskih i erozijskih stopa u različitim hidrološkim okruženjima.

3.1 Makro razina

Na (1) makro razini istraživanja kao glavni cilj je postavljen odabir testne plohe unutar šireg područja SB-a. Na širem prostoru SB-a uočene su spomenute negativne hidrološke promjene. Implementaciju predloženih upravljačkih mjera (selektivno uklanjanje vegetacije, modeliranje površinskog otjecanja, praćenje dinamike sedrenja itd.) na cijeloj površini šireg prostora SB-a nije bilo potrebno i moguće provoditi zbog financijskih i tehničkih ograničenja projekta. Nadalje, s obzirom na to da se radi o pokusnim akcijskim mjerama zaštite temeljnog fenomena Parka, koji u ovom opsegu dosad nisu primijenjeni u drugim zaštićenim područjima RH, za početak je trebalo ispitati njihovu učinkovitost na manjoj površini, odnosno testnoj plohi.

3.1.1 Terenska istraživanja

Prvi korak u odabiru testne plohe uključivao je terenska istraživanja interdisciplinarnog znanstvenog tima sa stručnim osobljem Parka uz vodstvo mr. sc. Gordane Gorete. Zaključeno je da terensko istraživanje nije dovoljno za identificiranje najbolje testne plohe već je zbog specifične morfometrije terena, velike gustoće vegetacije te povijesnih podataka (lokacije nekad aktivnih tokova), potrebno napraviti GIS-MCDA analizu. GIS-MCDA uključuju modeliranje indeksa pogodnosti plohe na temelju odgovarajućeg skupa kriterija. Odabrana testna ploha morala je zadovoljiti nekoliko čimbenika u koje spadaju:

a) Pojavnost proučavane problematike (obrašteni rubni dijelovi vodenih tokova, neaktivni tokovi, lokacije mrtve sedre itd.)
b) Pristupačnost terena za snimanje (poželjna staza za kretanje, pristupni put)
c) Mala energija reljefa (mali nagibi i vertikalna raščlanjenost)
d) Bogatstvo sedrotvornih tokova (postojanje trenutno aktivnih i presušenih tokova).

3.1.2 Zračno lasersko skeniranje NP "Krka"

Za potrebe izvođenja kriterija u GIS-MCDA analizi, generiranja referentnog stanja Parka, izvođenja digitalnog modela površina Parka, kartiranja visoke vegetacije te drugih potreba Javne ustanove, izvršeno je zračno lasersko skeniranje Parka (Slika 33). Helikopterom je snimljeno područje od šest slapišta i obje obale rijeke Krke. Podaci su obrađeni za prostor Lozovca, odnosno šireg prostora SB-a jer je to prostor unutar koje će se izvršiti GIS-MCDA analiza, odabrati testna ploha te pratiti dinamika sedrenja. Zračno LiDAR snimanje je izvršeno 14. prosinca 2014. godine koristeći punovalni (eng. *full waveform*) laserski mjerni sustav (skener) *Riegl LMS-Q780*. Zračno LiDAR snmanje je provela tvrtka Vektra, a podatke je na korištenje ustupila Uprava NP Krka. Laserski mjerni sustav je priključen na helikopter

Eurocopter EC120B s integriranom foto kamerom *Hasselblad H39* i GPS prijamnikom *Novatel OEV/OEM4* internal. Visina leta, vidni kut te brzina leta utjecali su na gustoću prikupljenih točaka, frekvenciju prostornog uzorkovanja te brzinu prikupljanja podataka. Karakteristike izvršenog aero LiDAR snimanja šireg područja Skradinskog buka su (RIEGL, 2015):

a) PRR[66] = 400 kHZ

b) visina leta = 500 - 600 m

c) brzina leta = 112,12 km/h

d) FOV = 60°

e) širina terena (eng. *swath width*) = 600 – 700 m

f) gustoća prikupljenih točaka = 24,7 točka/m²

g) objektiv = 50 mm

h) orijentacija objektiva = poprečna

i) interval između snimki = 5 s

Snimanje je izvedeno na visini od 500 - 600 m, pri brzini od 112,12 km/h, s vidnim kutom skenera od 60°. Skener je prikupio podatke oko šireg prostora Skradinskog buka u smjeru letenja (SZ i JI). Točnost stabilizacije, odnosno odstupanja laserske zrake iznosila je oko 0,25 mrad, što odgovara položajnoj pogrešci od oko 25 cm na terenu pri relativnoj visini leta od 1000 m. Učestalost pulsiranja iznosila je 400 000 HZ. Prosječna gustoća prikupljenih točaka, prije klasifikacije na temelju vremena refleksije, iznosila je 24,7 točaka/m², s preciznošću od 20 mm.

[66] Pulse Repetition Rate

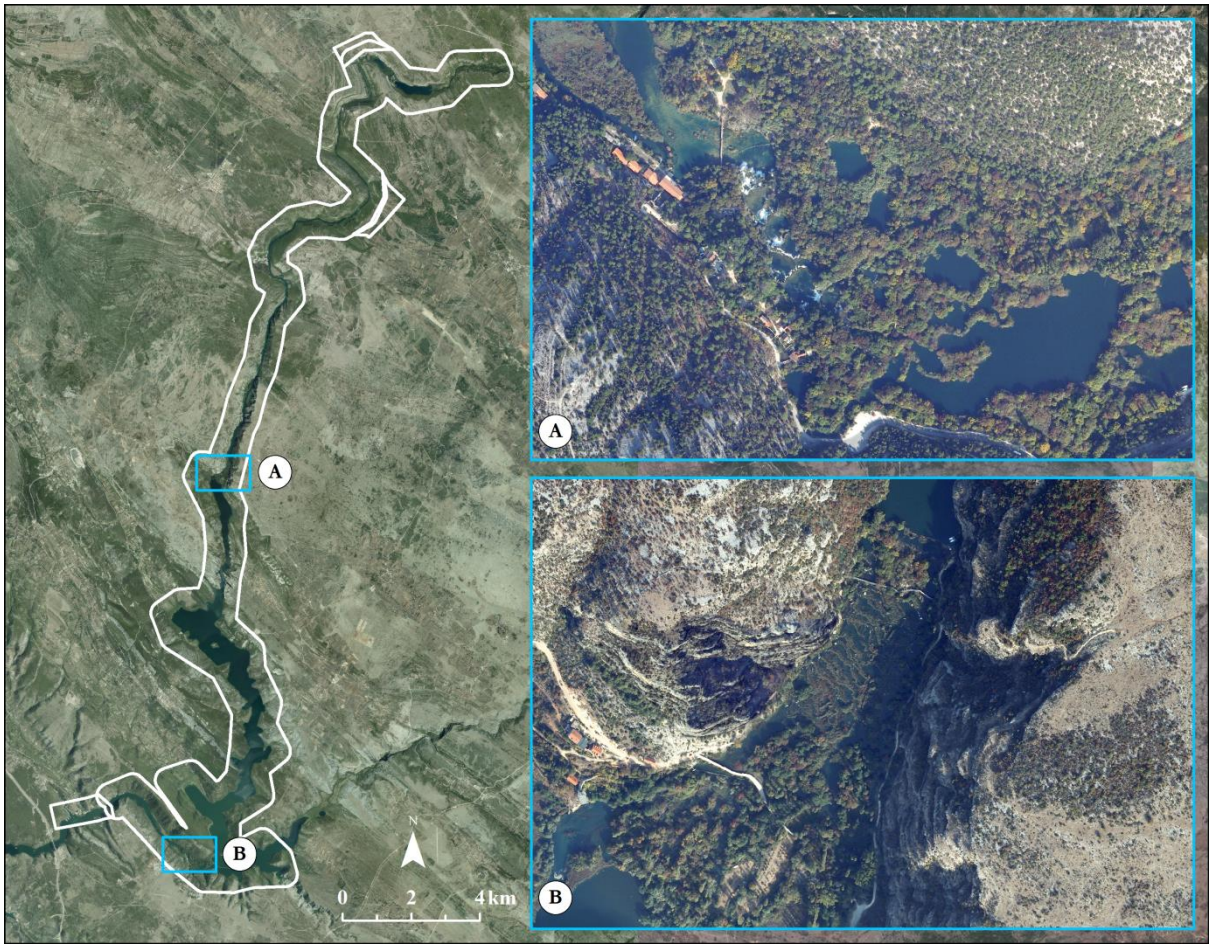

Slika 33. Snimljeno područje NPK – uz označena šira područje A) SB-a i B) RS-a

Proces obrade prikupljenih podataka obavljen je koristeći softverske pakete: *Microstation* (v2004) i *Terrasolid*, dok je za obradu GPS podataka korišten softver *Grafnav i IGI Aerooffice*. Proces uključuje unos i klasifikaciju točaka, prilagodbu oblaka točaka po linijama izmjere, automatsku klasifikaciju terena, ručnu kontrolu i korekciju automatske klasifikacije, transformaciju te u konačnici izradu DMR-a šireg područja Skradinskog buka. Proces filtriranja i klasifikacije oblaka točaka podataka izveden je na temelju vremena refleksije. Točke su klasificirane kao prva refleksija (eng. *first pulse*) koje se uglavnom odnose na visoku vegetaciju te prema posljednjoj refleksiji (eng. *ground* ili *last pulse*) koja se odnosi na signal reflektiran od čvrste zemljine površine. Klasa *ground* je uključivala 350 oblaka točaka za cijeli prostor NPK s ukupno nešto više od 781 milijuna točaka (Slika 34).

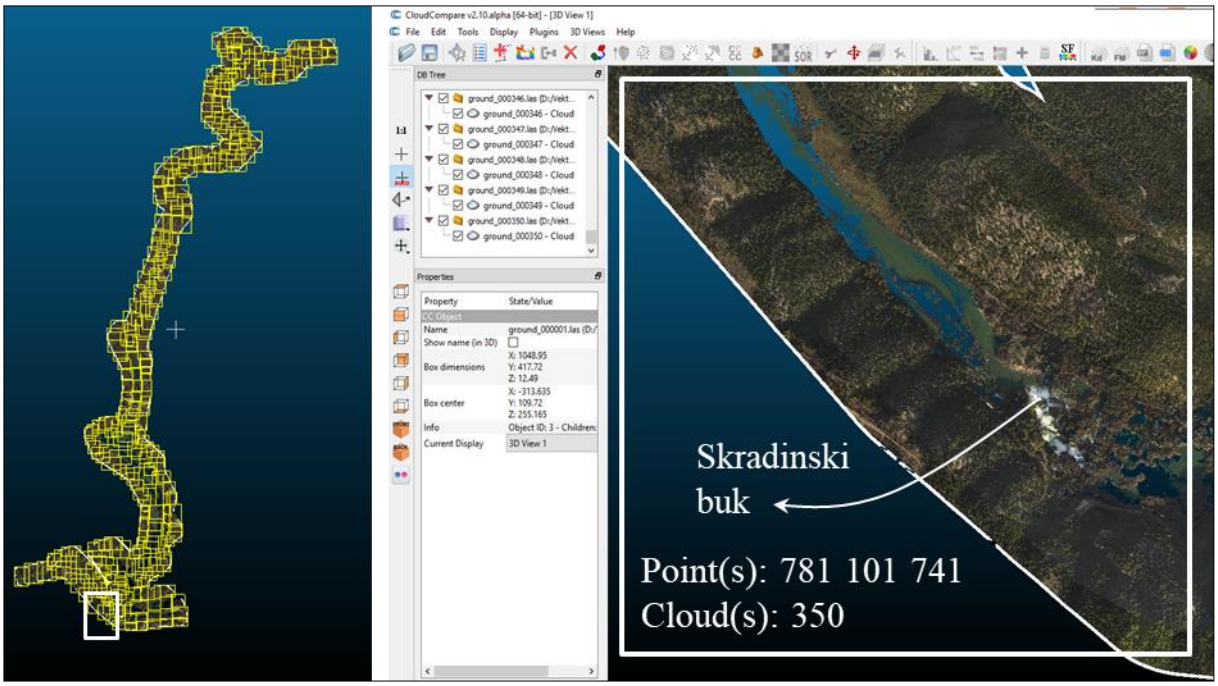

Slika 34. Oblaci točaka (.las format) unutar softvera *Cloud Compare*

Klasificirani podaci su spremljeni u *.las* format (LAS[67] file). LAS *file* predstavlja industrijsko-standardizirani binarni zapis koji služi za spremanje lidarski podataka (Barada, 2017). Za potrebe izvođenja DMR[68]-a klase točaka posljednje refleksije su pretvorene u LAS DATASET strukturu koristeći alat *Create LAS Dataset* unutar programa *Arc Map 10.1* (Slika 35). Dataset omogućava generiranje detaljne statistike klasificiranog oblaka točaka. Prosječni razmak između točaka (eng. *point spacing)* iznosio je 0,293 m.

[67] LIDAR Data Exchange File
[68] Digitalni model reljefa

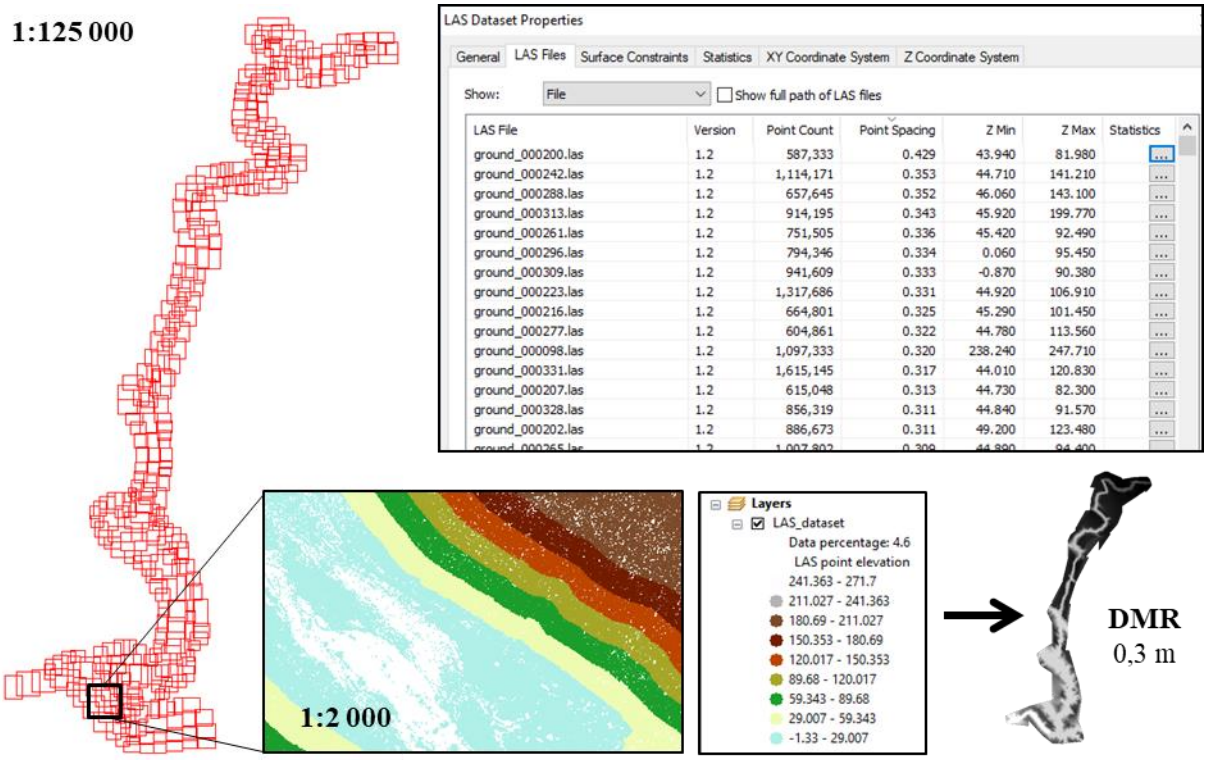

Slika 35. Shematski prikaz izvođenja DMR iz *LAS Dataseta*

Nakon izdvajanja točaka koje se odnose na čvrstu površinu, prosječna gustoća uzorkovanja je pala na 10-15 točaka po m², ovisno o gustoći vegetacijskog pokrova. DMR je izrađen koristeći alat *LAS Dataset to Raster*. Odabran je *binning* tip interpolacijske tehnike. U njemu je moguće odabrati metodu izračuna visine svakog piksela na temelju točaka koje spadaju u njegov opseg (*Cell Assignment Method*) te visinu piksela koji u svojem opsegu ne sadrže LAS točke (*Void Fill Method*). U potparametaru *Cell Assignment Method* odabran je NEAREST. U određivanju visine ćelije na temelju skupa točaka odabrana je funkcija najbližeg susjeda (eng. *nearest neighbor*). Ova tehnika određuje vrijednost piksela tako da piksel dobiva vrijednost LAS točke koja je najbliža njegovom središtu. Prednosti su mu jednostavnost i očuvanje izvornih vrijednosti točaka. Za potrebe određivanja visine piksela koji u svojem opsegu ne sadrže LAS točke odabrana je MI[69] prirodni susjed (eng. *natural neighbor*). NaN[70] je jedna od najpopularnijih MI, koja se često primjenjuje u geofizičkom i geografskom modeliranju (Šiljeg, 2013). Prostorna rezolucija DMR je postavljena na 0,3 metra prema prosječnom razmaku između točaka (Slika 36).

[69] Metoda Interpolacije
[70] Natural Neighbour

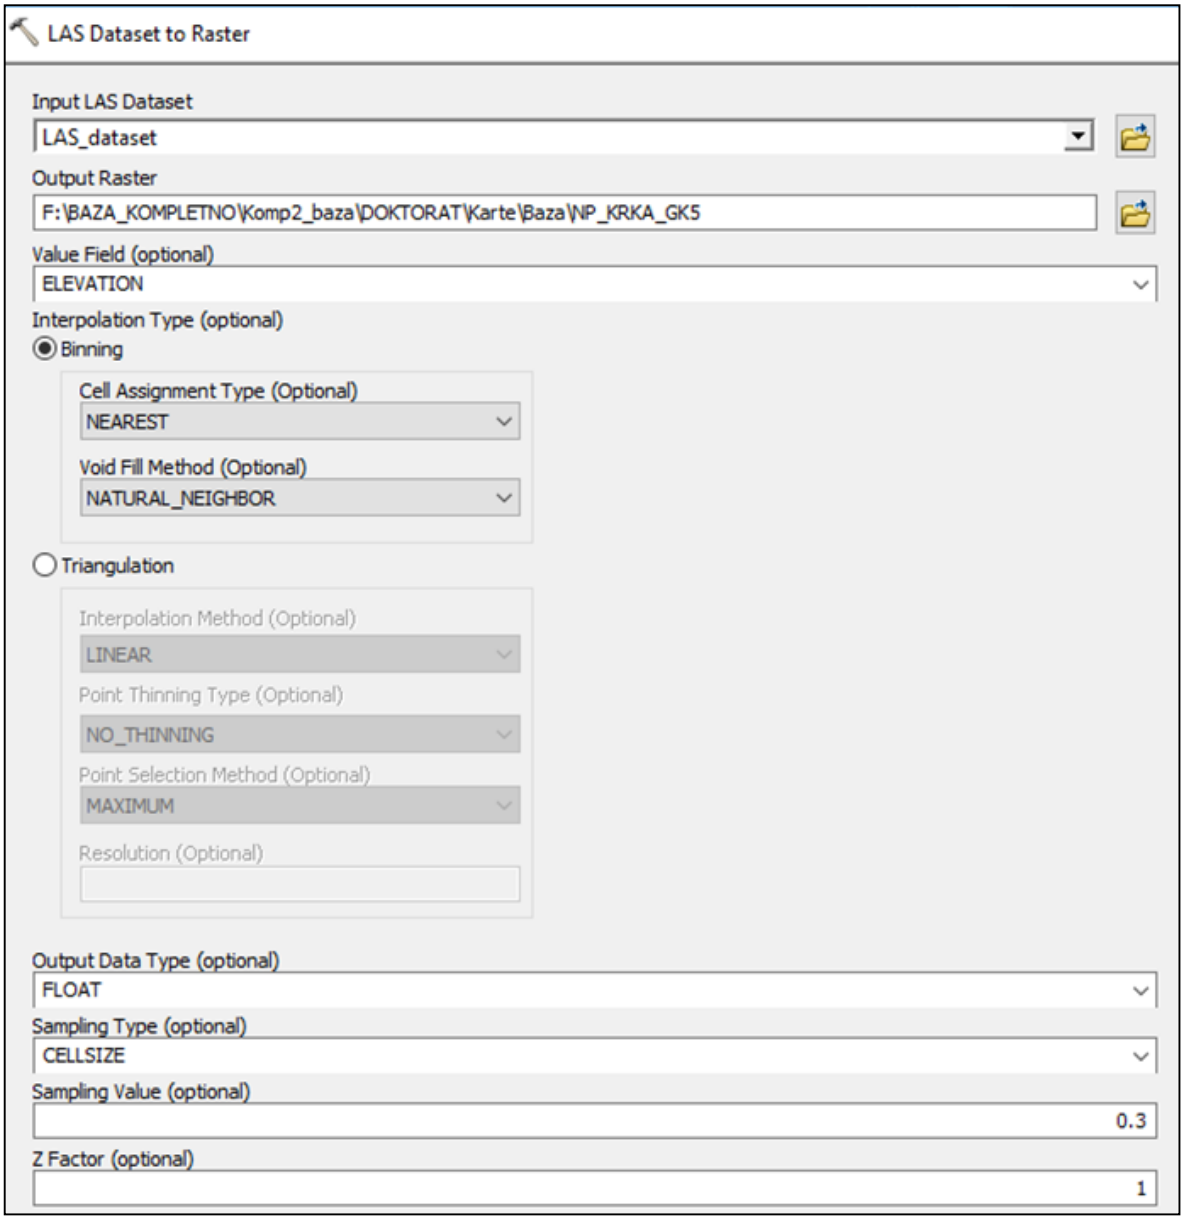

Slika 36. Zadane postavke unutar alata *LAS Dataset to Raster*

3.1.3 Vektorizacija Austro-Ugarske topografske karte

Analiza topografske A-U karte šireg područja SB izrazito je bitna jer može ukazati na intenzitet hidroloških i geomorfoloških promjena koje su odvijale od izrade karte do danas. U razdoblju od 17. do 19. stoljeća mnoge europske zemlje su se odlučile za provođenje preciznih nacionalnih izmjera. Za područje RH osobitu važnost imaju Jozefinska (1774.-1784.) i Franciskanska (1806.-1869.) topografska izmjera iz kojih su proizašle topografske karte u mjerilu 1:28 800. Iz treće ili Franc-jozefinske (1869.-1887.) izmjere proizašla je topografska karta u mjerilu 1:75 000 (Poslončec-Petrić, 2010). Četvrtom izmjerom (1896.-1916.)

započetom 1896. godine, nastalo je, do prekida 1916. godine, samo 388 listova karte u mjerilu 1:25 000 (Špoljarić i dr. 2010).

Analizirana A-U topografska karta (Slika 37a) izrađena je 1883. godine, 12 godina prije izgradnje HE Jaruga, u vrijeme treće ili franc-jozefinske izmjere. Franc-jozefinska topografska izmjera provedena u Dalmaciji krajem 19. stoljeća predstavlja iznimno važan povijesni izvor koji svjedoči o daljnjoj preobrazbi područja oko rijeke Krke. Franc-jozefske topografske karte Pokrčja prikazuju prve efekte promijenjenih odnosa u prostoru u kojem su trgovina i promet postali dominantnim čimbenicima razvoja (Slukan Altić, 2007). U sklopu izmjere, kartiranje područja oko rijeke Krke obavljeno je između 1881. i 1884. godine (Slukan Altić, 2007). Puni naziv A-U karte je: *SITUATIONS-PLAN des KRKAFALL-GEBIETES BEI SCARDONA* (prev. Stanje (plan) – Slapovi Krke – područje Skradina) (Slika 37b). Karta je napravljena u mjerilu 1:720. Podaci o vodenim tokovima na širem području Skradinskog buka prikupljeni su metodom vektorizacije. Tokovi na karti su označeni strelicama (Slika 37c).

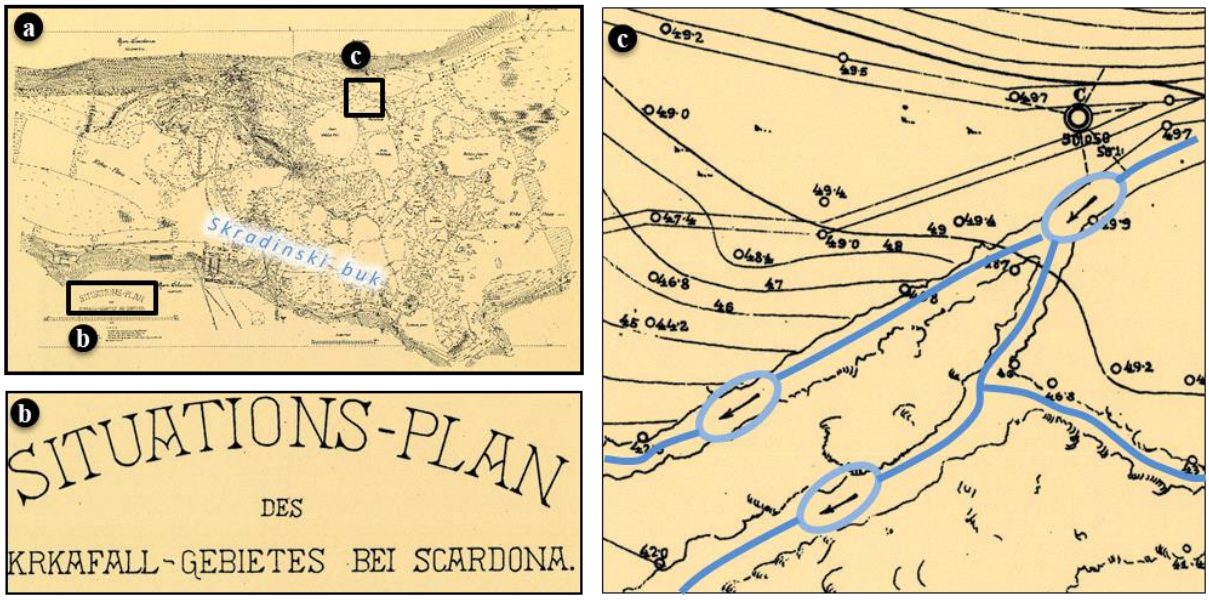

Slika 37. a-b) Isječci Austro-ugarske topografske karte korištene za potrebe analiza c) oznake tokova na širem području SB-a

Izvor: Arhiv Nacionalnog parka „Krka“

Vektorizacija je dugotrajan proces koji zahtijeva skeniranje analognih karata, georeferenciranje, vektorizaciju sadržaja karte i pridruživanje atributa. Georeferenciranje je proces pridruživanja geografskih koordinata u određenoj kartografskoj projekciji pojedinim točkama koje nemaju prostornu komponentu. Topografska karta šireg područja SB-a izrađena za vrijeme A-U uprave georeferencirana je u službenoj kartografskoj projekciji RH.

3.1.4 Primjena GIS-MCDA u odabiru testne plohe

GIS-MCDA su korištene u valoriziranju šireg područja SB-a za odabir najpogodnije testne plohe prilikom praćenje promjena vegetacije, tokova i dinamike sedrenja. Korištena su dva pristupa: *Boolean* i kontinuiranih vrijednosti. Boolean varijable predstavljaju isključujuće kriterije (ograničenja) jer ocrtavaju područja koja nisu prikladna za razmatranje. Oslanjaju se na binaran iskaz (eng. *true/false*) pogodnosti nekog kriterija za razmatrani cilj ili odluku. Kriteriji kontinuiranih vrijednosti nisu isključujući već u određenom stupnju, pozitivno ili negativno, prikazuju prikladnost specifičnog kriterija u odnosu na zadan cilj ili odluku (Domazetović, 2018).

Za područje istraživanja odabrano je šire područje SB-a ukupne površine 50 ha. Glavni cilj GIS-MCDA je izdvajanje najpogodnije testne plohe na kojoj će se pratiti promjena vegetacije, tokova i dinamika sedrenja u jednogodišnjem razdoblju. Prema *boolean* pristupu izdvojena su četiri isključujuća kriterija (Slika 38):

1) Vodene površine;
2) Izgrađeno područje;
3) Pobrđe;
4) Domet TLS-a (Z+F Imager5600i)

U *boolean* pristupu kriteriji se opisuju ocjenom 0 (eng. *false*) ili 1 (eng. *true*). Primjerice, vrijednost 1 označava čvrsti dio terena na koji je moguće postaviti TLS, dok 0 predstavlja nemogućnost izvođenja te aktivnosti, odnosno označava vodene površine (npr. jezera, slapove itd.).

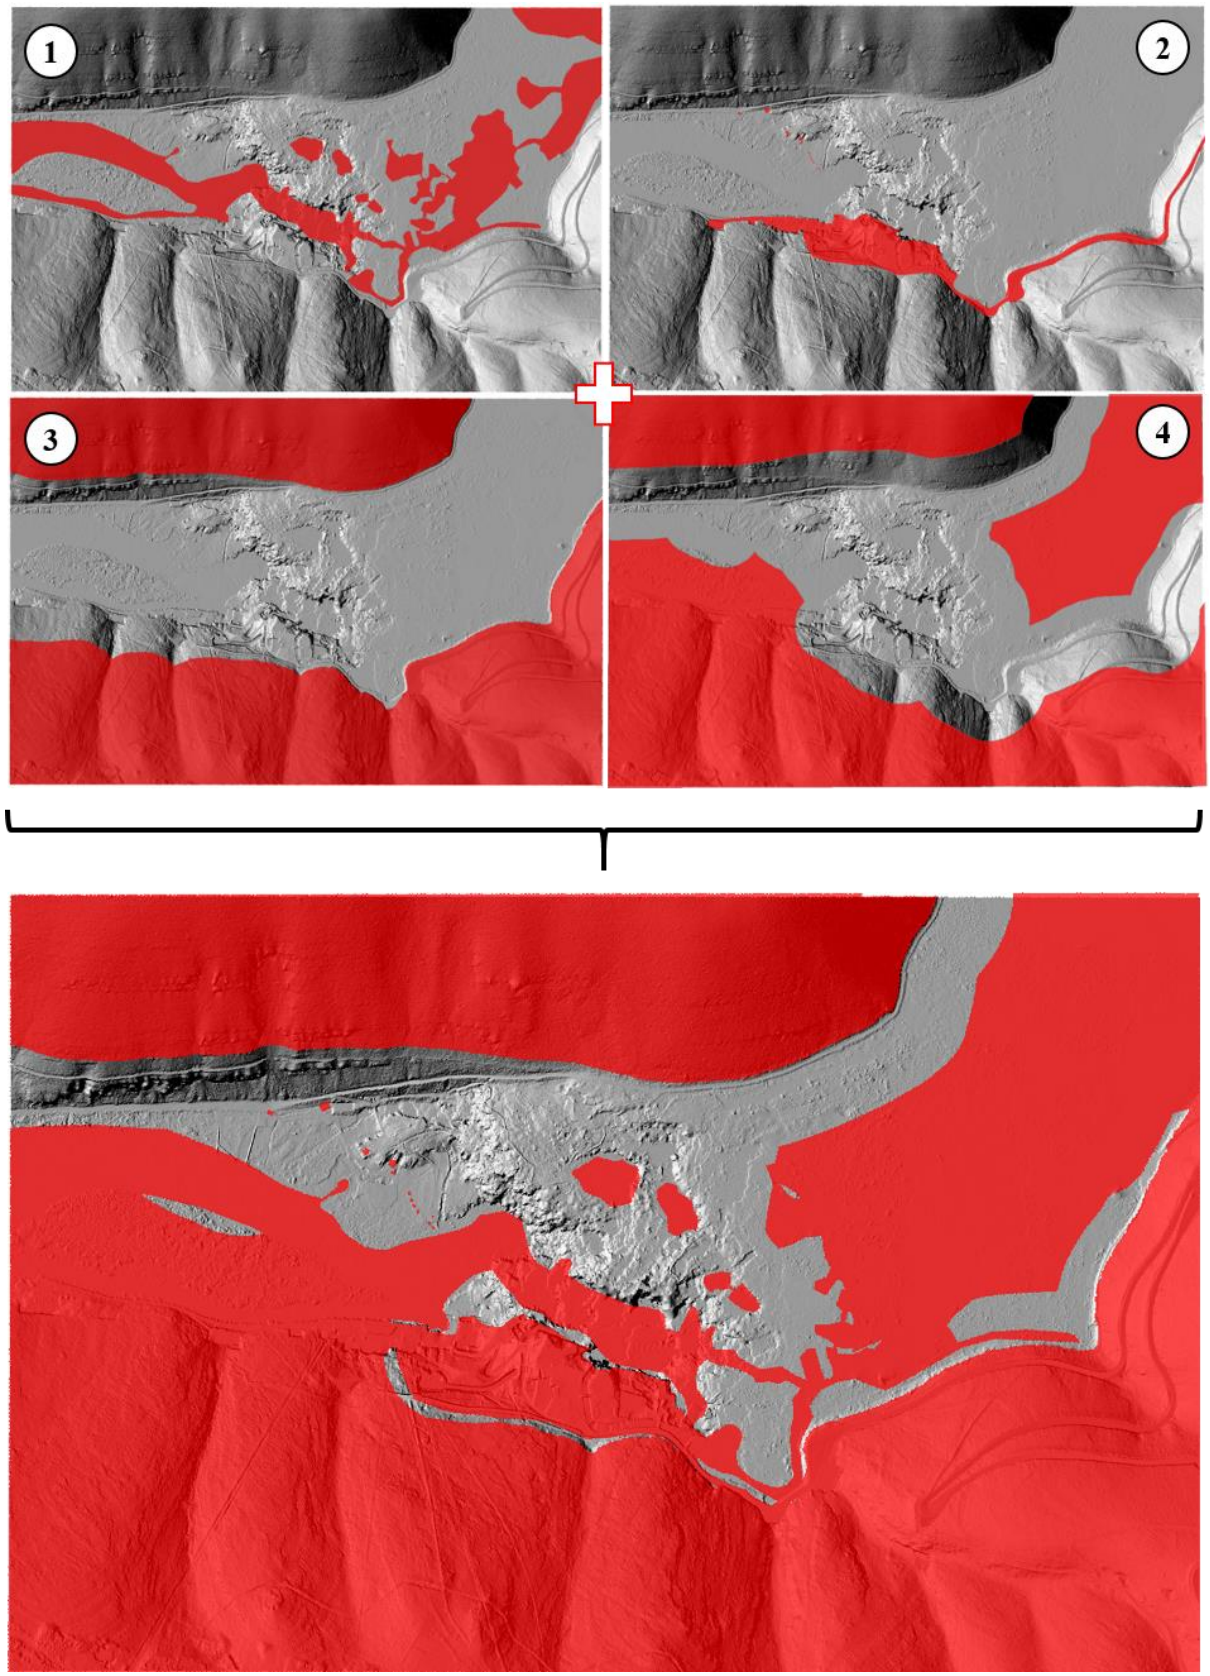

Slika 38. Površina na širem području SB-a koja je primjenom *boolean pristupa* isključena iz odabira najpogodnije testne plohe

U pristupu kontinuiranih vrijednosti korištena su tri kriterija:

1) Pogodnost za snimanje (*Viewshed Analysis*);
2) Vertikalna raščlanjenost (*Terrain Ruggedness*);
3) Nagib (*Spatial Analysis - Slope*).

Nakon definiranja kriterija izvršena je standardizacija (Slika 39 - 41). Standardizacijom je svaki kriterij rangiran u 5 klasa (1-5) gdje klasa 5 predstavlja vrlo visoku pogodnost, 4 visoku, 3 srednju, 2 nisku i 1 vrlo nisku pogodnost. Standardizacija je važan korak GIS-MCDA jer se njome usklađuju vrijednosti varijabli na istu skalu kako bi bilo moguće njihovo međusobno uspoređivanje. Primjerice, kriterij vertikalne raščlanjenosti iskazuje se u metrima (m), a nagib u stupnjevima (º). Standardizacijom njihova međusobna usporedba je moguća. Klase za svaki kriterij su određene na temelju *Jenksove* metode klasifikacije.

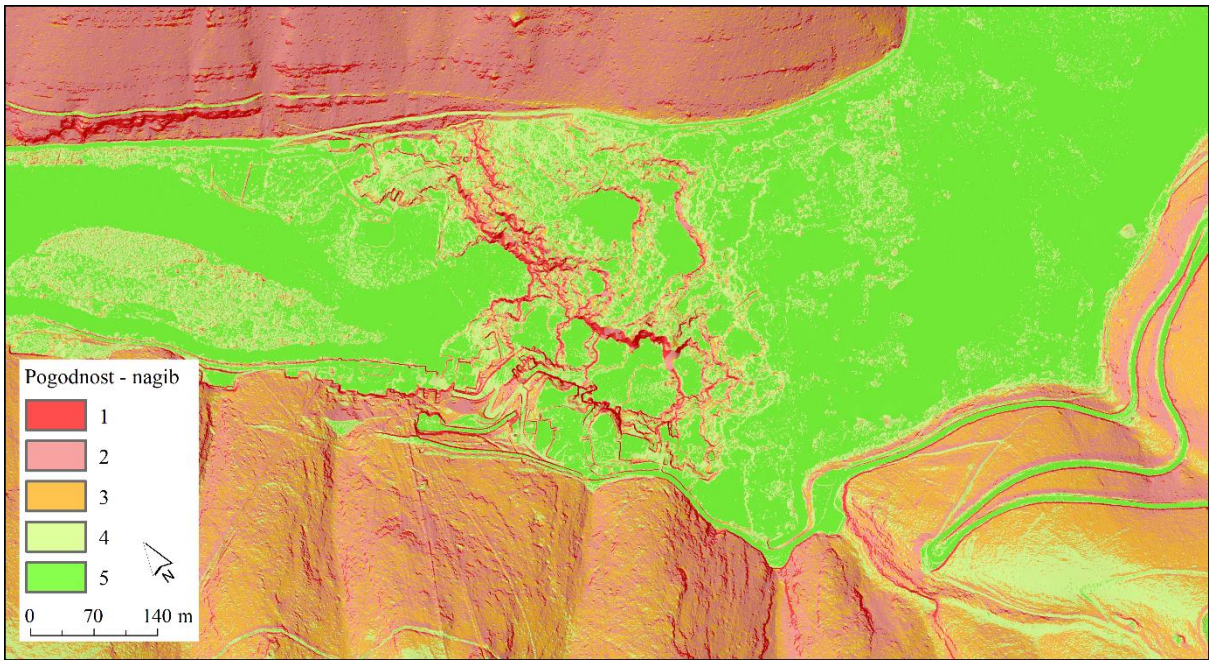

Slika 39. Standardiziran kriterij nagiba u procesu GIS-MCDA

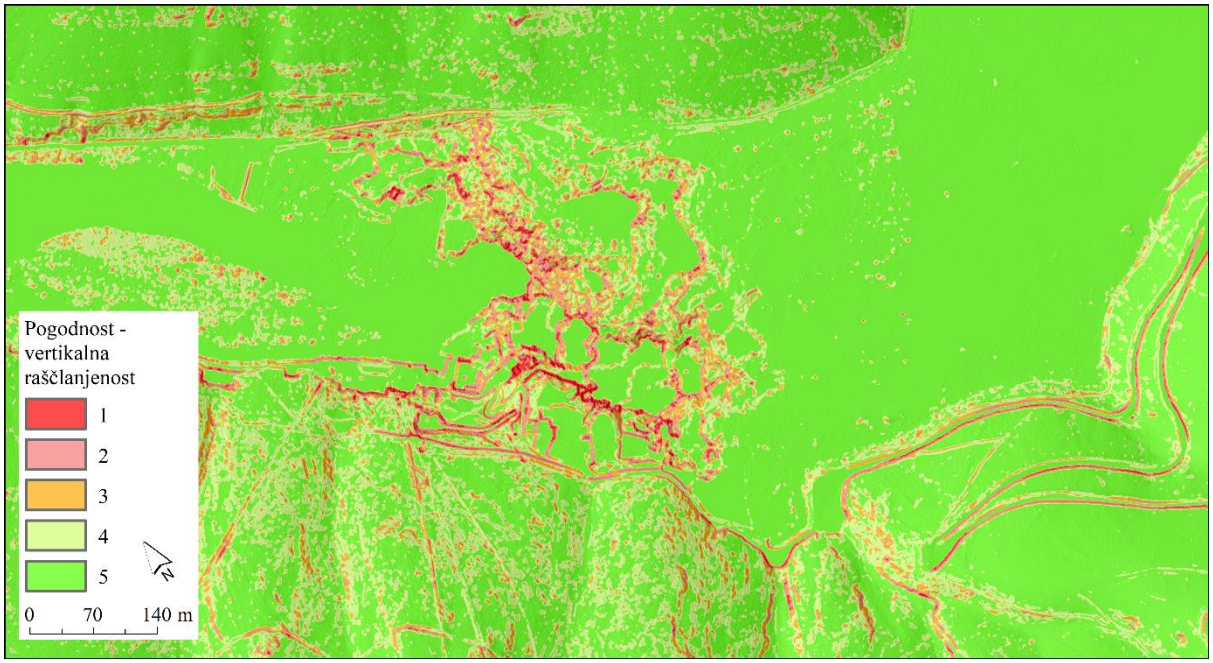

Slika 40. Standardiziran kriterij vertikalne raščlanjenosti u procesu GIS-MCDA

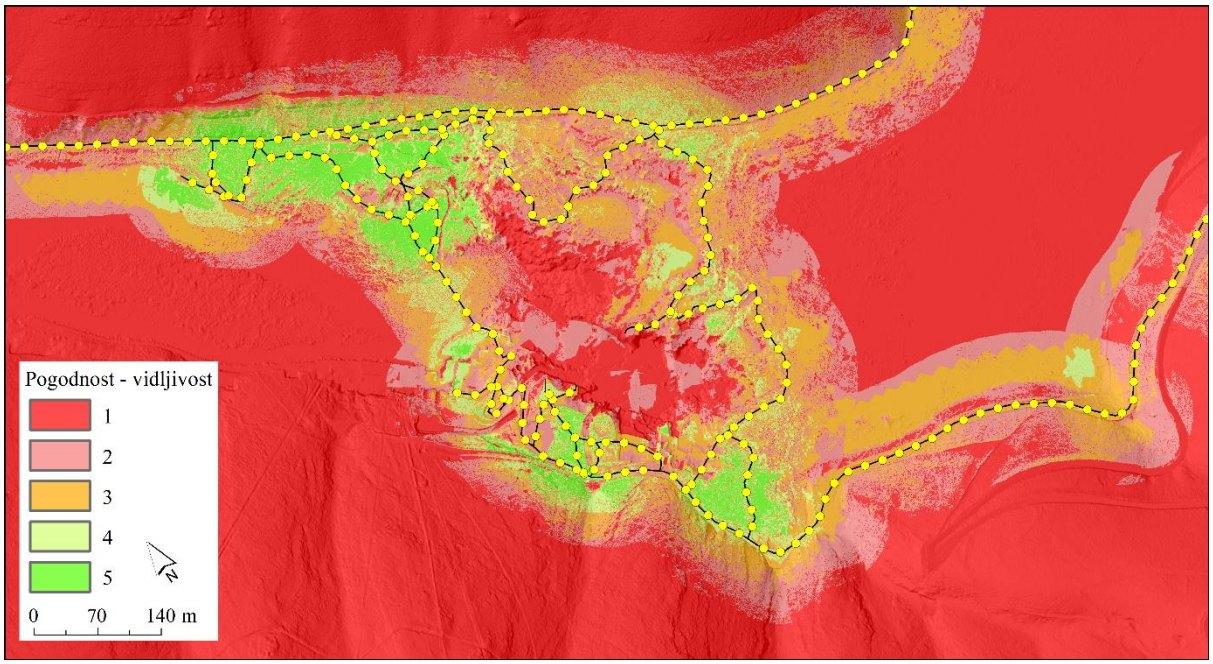

Slika 41. Standardiziran kriterij vidljivosti u procesu GIS-MCDA

Nakon standardizacije izračunati su težinski koeficijenti za svaki kriterij. Korištena je metoda usporedbe među kriterijima, poznata pod nazivom analitički hijerarhijski proces (AHP). AHP je popularna metoda koje se pokazala izuzetno korisna u donošenju odluka i planiranju te modeliranju nestrukturiranih problema u različitim područjima (Harker i Vargas, 1987, Yu, 2002, Domazetović, 2018). Temelji se na međusobnoj usporedbi važnosti definiranih kriterija, odnosno mjerenju njihova utjecaja na postavljeni cilj (Saaty, 2008). Međusobna usporedba kriterija vrši se primjenom Saatyeve skale u kojoj postoji mogućnost

dodjeljivanja vrijednosti stupnjeva utjecaja od 9 do 1/9. Vrijednosti definirane na skali predstavljaju odnos relativne važnosti dva uspoređena kriterija te imaju velik utjecaj na dosljednost i točnost ishoda (Ji i Jang, 2003). U tablici 7 prikazana je semantika stupnjeva utjecaja na cilj.

Tablica 7. Semantika Saatyeve skale

Stupanj utjecaja	Definicija stupnja utjecaja	Objašnjenje stupnja utjecaja
1	**Istog značaja** (eng. *equally important*)	Dva kriterija su identičnog utjecaja u odnosu na cilj
3	**Slaba dominantnost** (eng. *moderately more important*)	Iskustvo ili prosudba neznatno favoriziraju utjecaj jednog kriterija u odnosu na drugi
5	**Jaka dominantnost** (eng. *strongly more important*)	Iskustvo ili prosudba znatno favoriziraju utjecaj jednog kriterija u odnosu na drugi
7	**Dokazana dominantnost** (eng. *demonstrably more important)*	Utjecaj jednog kriterija potvrđena je u praksi
9	**Apsolutna dominantnost** (eng. *extremely more important*)	Utjecaj najvišeg stupnja
2, 4, 6, 8	**Međuvrijednosti** (eng. *values between*)	Međuvrijednosti stupnjeva utjecaja

Izvor: prema Ji i Jang, 2003

Kriteriji su poredani prema važnosti te međusobno uspoređeni prema stupnju utjecaja (Tablica 8): pogodnost plohe za snimanje i terenski rad, vertikalna raščlanjenost te nagib. Svakom kriteriju je određen stupanj utjecaja u odnosu na drugi. Inverzijom uspoređenih kriterija (unakrsnost) dodjeljuju se obrnuto proporcionalne ocjene u odnosu na prvu usporedbu. Primjerice, ako stupanj utjecaja kriterija 1 u odnosu na kriterij 3 iznosi 5 (jaka dominantnost), onda stupanj utjecaja kriterija 3 u odnosu na kriterij 1 iznosi 0,20.

Tablica 8. Matrica usporedbe stupnja utjecaja između kriterija

Kriteriji	Pogodnost za snimanje	Vertikalna raščlanjenost	Nagib
Pogodnost za snimanje	1,000	2,000	3,000
Vertikalna raščlanjenost	0,500	1,000	2,000
Nagib	0,333	0,500	1,000

Posljednji korak se odnosu na izračun težinskih koeficijenata (Tablica 9) i stupnja konzistentnosti (CR[71]). CR predstavlja indikator provjere objektivnosti dodavanja težinskih koeficijenata (Domazetović, 2018). Ova mjera omogućuje identifikaciju nedosljednosti u vrednovanju elemenata hijerarhije (kriterija). Prvi korak u izračunu CR-a se odnosi na izračun

[71] Consistency Ratio

indeksa konzistentnosti CI[72] te slučajnog indeksa (RI[73]). RI predstavlja srednju vrijednost CI-a izračunatu za matrice usporedbi različitih dimenzija (Holjevac i dr., 2014). Različiti autori predlažu izračune vrijednosti RI-a ovisno o metodi simulacije i broju generiranih matrica (Alonso i Lamata, 2005). Određivanje težinskih koeficijenata je valjano ako je vrijednost CR manja od 0,1, odnosno ako je pogreška manja od 10% (Holjevac i dr., 2014). U ovom slučaju CR iznosi 0,01 (Tablica 9). Potrebno je istaknuti da ova mjera ne pokazuje koliko su izvedeni težinski pokazatelji točni u kontekstu utjecaja na postavljeni cilj, već ukazuje na to koliko su međusobne usporedbe kriterija bile dosljedne. Najveći težinski koeficijent dobio je kriterij pogodnost za snimanje (0,539), potom slijedi vertikalna raščlanjenost (0,273), dok najmanji ima nagib (0,164).

Tablica 9. Izvedeni težinski koeficijenti odabranih kriterija

Kriteriji	**Pogodnost za snimanje**	**Vertikalna raščlanjenost**	**Nagib**	**Total**	**Ponderi**	**Consistancy Measure**
Pogodnost za snimanje	0,546	0,570	0,500	1,617	0,539	3,014
Vertikalna raščlanjenost	0,273	0,290	0,330	0,892	0,297	3,008
Nagib	0,182	0,140	0,170	0,491	0,164	3,004
Ukupno	1,000	1,000	1,000		1,000	
				CI (eng. *consistency index*)		**0,005**
				RI (eng. *random index*)		**0,580**
				CR (eng. c*onsistency ratio*)		**0,010**

[72] Consistency Index
[73] Random Index

3.2 Mezo razina

3.2.1 Terestričko lasersko skeniranje testne plohe

Na makro razini odabrana je najpogodnija testna ploha unutar šireg područja SB-a na kojoj će se izvršiti aktivnosti na mezo i mikro razini istraživanja. Mezo razina uključuje: kartiranje vegetacije i tokova, selektivno uklanjanje vegetacije, kartiranje reaktiviranih tokova, te praćenje hidrokemijskih parametara. Mikro razina uključuje: praćenje dinamike formiranja sedre na testnim pločicama postavljenima u različita fluvijalna okruženja. S ciljem dobivanja referentnog (vegetacijskog, hidrološkog i morfometrijskog) stanja plohe, prije intervencije u prostoru, izvršeno je terestričko lasersko skeniranje i zračno snimanje plohe bespilotnom letjelicom (UAV[74]). Vegetacijska, hidrološka i morfometrijska obilježja plohe uvjetovala su primjenu TLS-a kao jedina metode prikupljanja podataka koja može osigurati dovoljno kvalitetne rezultate (točnost, preciznost i gustoća) za navedenu primjenu.

Lasersko skeniranje odabrane testne plohe provođeno je od 5. do 7. travnja 2016. godine. Gustoća uzorkovanja uvjetovala je trajanje skeniranja, a rezultat je dogovora stručnog osoblja NPK-a, tvrtke Vectra d.o.o (koja je ustupila TLS) te doktoranda Ivan Marića. Skeniranje je izvršeno početkom travnja zbog praćenja dinamike projekta *Upravljanje i održavanje makrovegetacije na Skradinskom buku – izrada višekriterijskog modela održivog upravljanja* te činjenice da gustoća vegetacije na plohi još uvijek nije bila izrazita. Trajanje skeniranja rezultat je veličine odabrane plohe, broja stajališta te rezolucije snimanja. Skeniranje je izvršeno uređajem *Z+F Imager5600i* (Slika 42) jer gustoća vegetacije na odabranoj testnoj plohi ne dozvoljava korištenje TLS-a koji skeniraju udaljenosti veće od 100 m. Dakle, naglasak je stavljen na preciznost i točnost prikupljanja podataka. U vrijeme skeniranja *Z+F Imager5600i* je opisivan kao najbrži, visoko- rezolucijski[75] terestrički laserski skener na svijetu u klasi malog i srednjeg dometa (Tablica 10). Ima integriranu HDR kamera, veliku preciznost i sferno vidno polje.

[74] Unmanned Aerial Vehicle
[75] 1,7 mm razmaka između točaka na 25 m udaljenosti

Tablica 10. Osnovne specifikacije *Z+F Imager5600i*

Divergencija snopa	< 0,3 mrad	**Vertikalna rezolucija**	0,0004°
Minimalna udaljenost	0,3 m	**Horizontalna rezolucija**	0,0002°
Raspon rezolucije	0,1 mm	**Brzina rotacije**	max. 50 rps (3,000 rpm)
Stopa prikupljanja podataka	max. 1,016 mil. pixel/sec	**Radna temperatura**	od -10 °C do 45 °C
Pogreška linearnosti	< 1 mm	**Težina skenera**	9,8 kg
Vertical FoV	320°	**Fokus kamere**	1 m -∞
Hotizontal FoV	360°	**Vrijeme snimanja kamerom**	ca. 3:30 min

Izvor: URL 51

Slika 42. *Z+F Imager5600i* na odabranoj testnoj plohi

Rezolucija je postavljena na vrijednost *high* dok je kvaliteta postavljena na *normal.* Vrijeme skeniranja svakog stajališta prema određenim postavkama iznosilo je 3:22 min. Ukupno je na 156 stajališta (Slika 44) snimljeno 244 736 910 točaka, nešto više od 1,5 milijuna točaka po stajalištu (Slika 43).

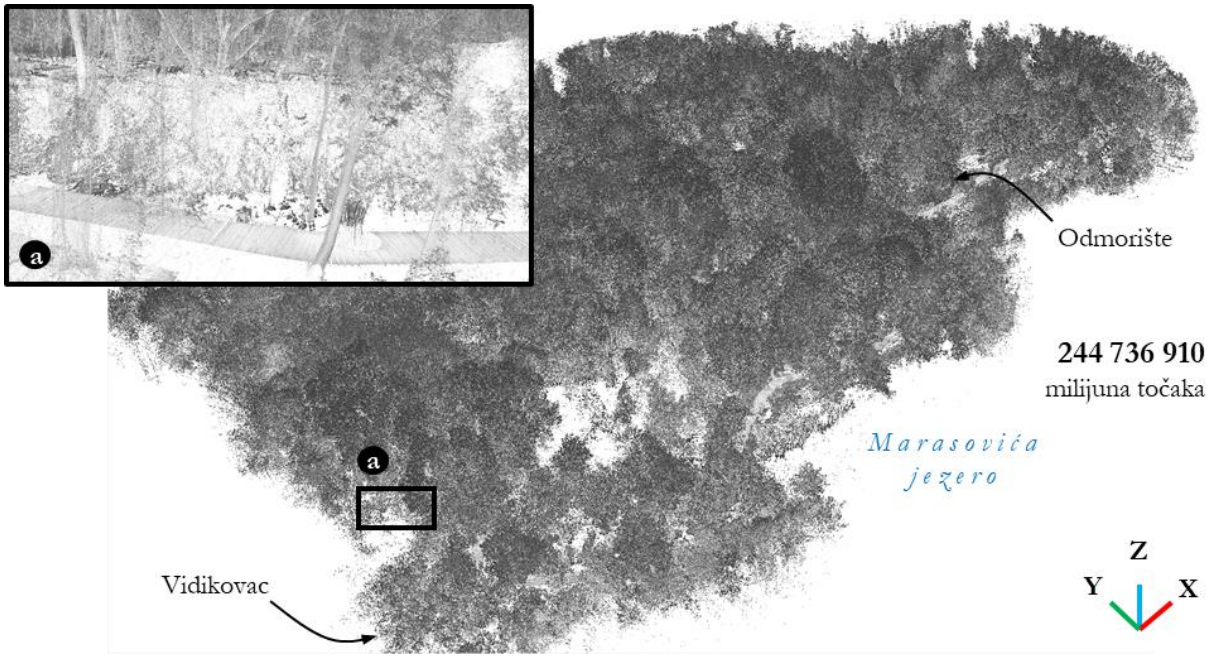

Slika 43. Gusti oblak točaka testne plohe te isječak a) manjeg dijela iznad vidikovca

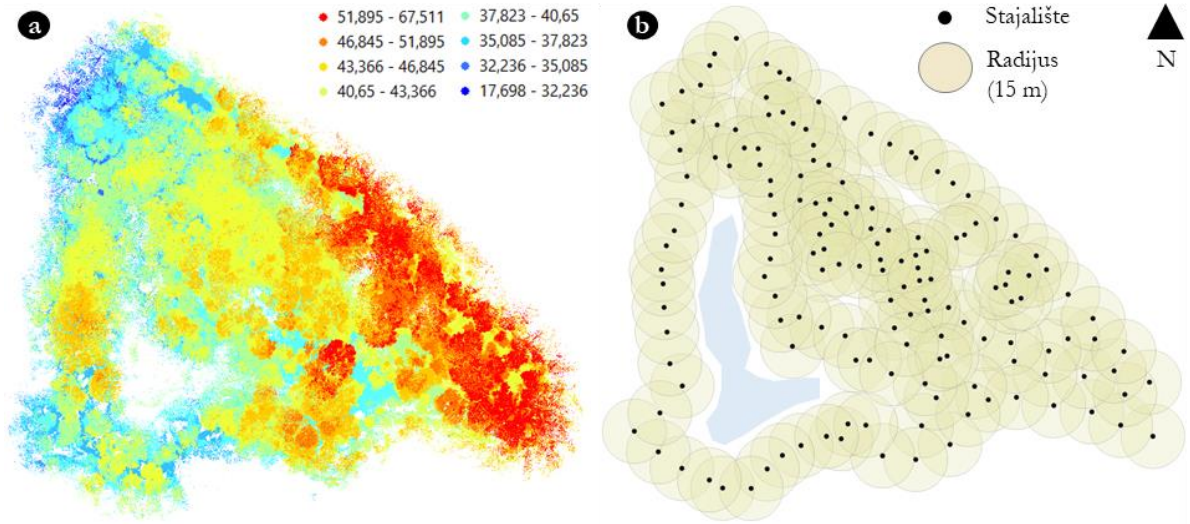

Slika 44. a) *LAS Dataset* gustog oblaka točaka te b) raspored stajališta TLS-a

Oblak točaka je pretvoren u *LAS Dataset* (Slika 45a) za potrebe izvođenja DMR-a testne plohe te kartiranja vegetacije. Raspored i broj stajališta TLS-a (156) posljedica su konfiguracijske pristupačnosti plohe (staza oko testne plohe, rimski put iznad testne plohe, mala vertikalna raščlanjenost) te guste vegetacije (uglavnom pajasen) koja je djelomično blokirala laserske zrake. Gusta vegetacija prevladava u središnjem, sjevernom, sjeveroistočnom i istočnom dijelu testne plohe. Jugozapadni i zapadni dio je djelomično prekriven vodom te bogat makrofitima zbog čega je pokrivenost skeniranja bila nešto slabija

(Slika 45b). Ipak. rasporedom stajališta obuhvaćena je cijela plohe te su se oblaci točaka mogli povezati pomoću postavljenih markica.

Prilikom izmjere, za potrebe orijentiranja, povezivanja i apsolutnog georeferenciranja oblaka točaka različitih stajališta, korištene su mjerne markice. Markice su postavljane na vidljivo mjesto unutar raspona skeniranja (Slika 45) te su procesom skeniranja prenošene. Između dva skena na istim lokacijama su ostavljane minimalno po dvije markice. Koordinate šest markica su prikupljene RTK[76]-GPS-om te su korištene za apsolutno georeferenciranje modela.

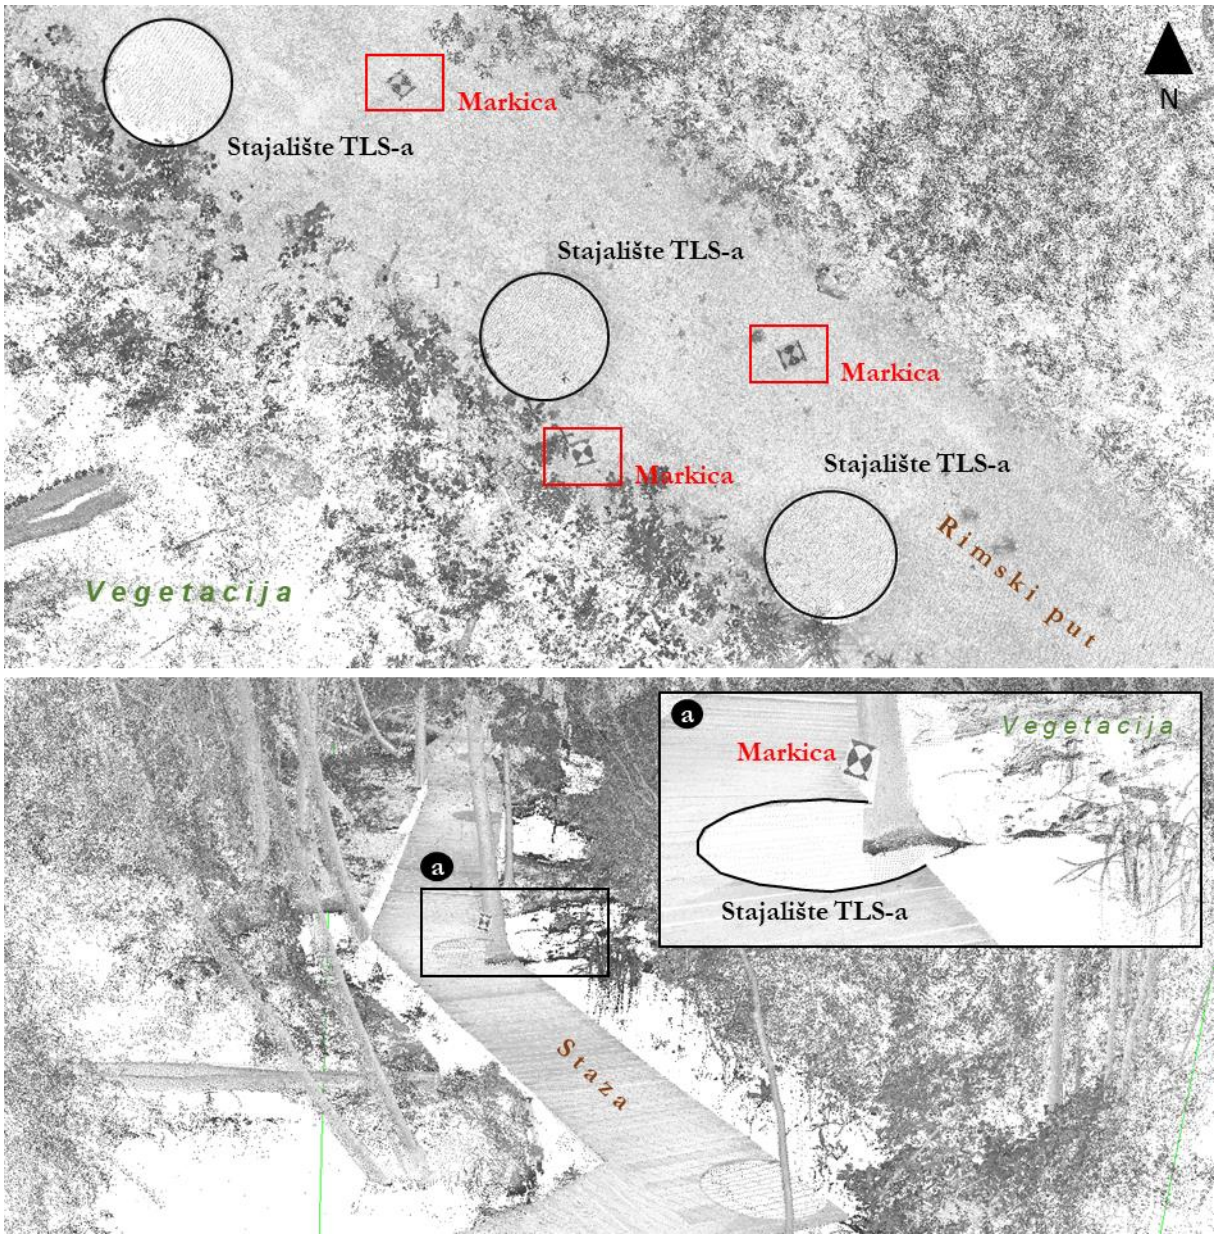

Slika 45. Oblak točaka s markicama za orijentaciju i georeferenciranje oblaka točaka

[76] Real Time Kinematic

3.2.2 Izrada hibridnog DMR-a testne plohe

Na temelju vremena i intenziteta refleksije iz gustog oblaka točaka prikupljenog TLS-om izdvojene su točke koje reprezentiraju čvrsti dio zemljine površine. Automatskim procesom klasifikacije i filtriranja iz 244 736 910, izdvojeno je nešto više od 5,6 mil. točaka (Slika 47).

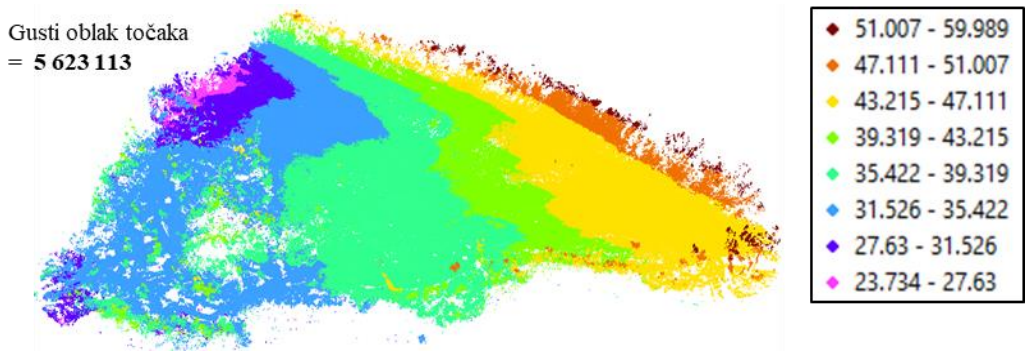

Slika 46. Točke izdvojene iz gustog oblaka za potrebe izrade hibridnog modela

Podaci koji se odnose na čvrsti dio terena, na određenim područjima testne plohe nisu dali očekivane rezultate. Zbog guste vegetacije i suhozida, kroz koje laserska zraka s obzirom na položaj TLS-a nije mogla prodrijeti, određeni dijelovi terena su ostali nepokriveni ili su imali nedovoljnu gustoću točaka. S obzirom na to da je generiranje referentnog DMR-a testne plohe izrazito bitno zbog potrebe izvođenja geomorfometrijskih, a posebice mreže površinskog otjecanja, zaključeno je da će se za daljnje analize izraditi „hibridni“ model reljefa koji će biti rezultat zračne i terestričke metode prikupljanja visinskih podataka. Hibridni digitalni model reljefa u ovom slučaju predstavlja visoko-rezolucijski DMR koji je nastao kombinacijom visinskih podataka prikupljenih različitim geoprostornim tehnologijama (TLS + aeroLiDAR) (Slika 47). *LAS Dataset* prikupljen aeroLiDAR-om te TLS-om spojeni su koristeći alat lasmerge unutar seta alata LAStools.

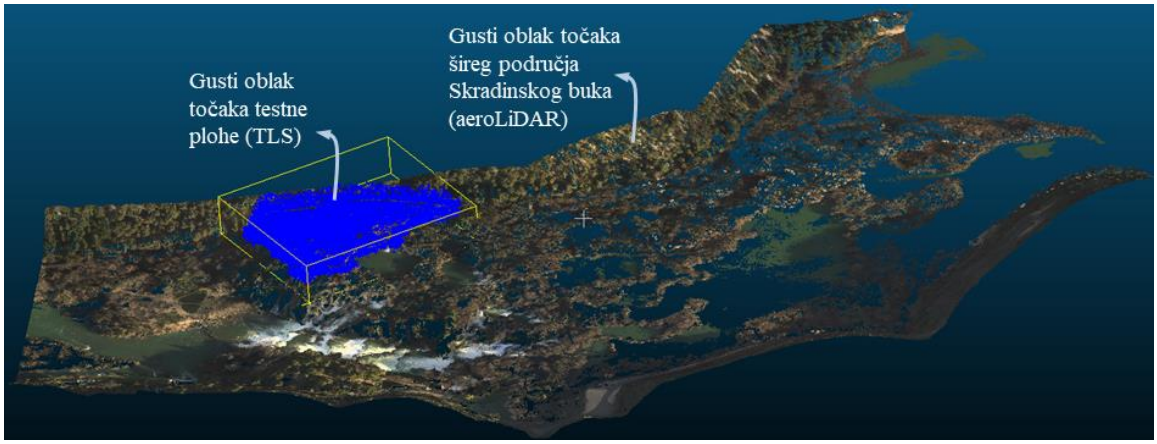

Slika 47. Gusti oblak točaka TLS-a preklopljen s oblakom točaka šireg područja SB-a (aeroLiDAR)

DMR je izrađen koristeći alat *LAS Dataset to Raster*. Korišten je *binning* tip interpolacijske tehnike Postavljeni su isti parametri (*Cell Assignment Method – NEAREST* i *Void Fill Method – nearest neighbor*) kao prilikom izrade DMR-a cijelog područja Nacionalnog parka „Krka“. Na temelju izrađenog modela izvedeni su osnovni geomorfometrijski parametri (nagib, ekspozicija, zakrivljenost padina, vertikalna raščlanjenost te hipsometrija) te inicijalna mreža površinskog otjecanja (prije selektivnog uklanjanja vegetacije). Mreža površinskog otjecanja je klasificirana na aktivne i suhe tokove. Nadalje, iz DMR-a su detektirane presušene depresije (jezera) na plohi. Mreža površinskog otjecanja je bitna zbog praćenja hidroloških promjena nakon uklanjanja vegetacije te plana postavljanja testnih pločica na kojima će se pratiti dinamika formiranja sedre.

3.2.3 Izvođenje modela mreže površinskog otjecanja

Mreža površinskog otjecanja generirana je u nekoliko koraka. Neki od njih su neizostavni, dok drugi ovise o obilježjima, odnosno točnosti DMR-a koji služi kao osnovni predložak. Prvi korak u modeliranju mreže površinskog otjecanja se odnosi na 1) ispravak DMR-a. Naime, DMR-u pravilu sadrži pogreške koje su prepoznate kao lažni sinkovi ili vrhovi (elementi grida nelogično niži ili viši od okolnog prostora). Oni su posljedica točnosti uređaja kojim su prikupljeni visinski podaci, odabira krive metode interpolacije ili prostorne rezolucije. S tih lokacije voda ne može otjecati. Ipak, algoritmi integrirani unutar GIS softvera omogućuju ispravljanje, odnosno uklanjanje tih pogrešaka. Oni se ispravljaju na temelju pomične mreže kvadrata procjenjivanjem vrijednosti visine odstupajućeg piksela u odnosu na visine okolnih piksela (Slika 48).

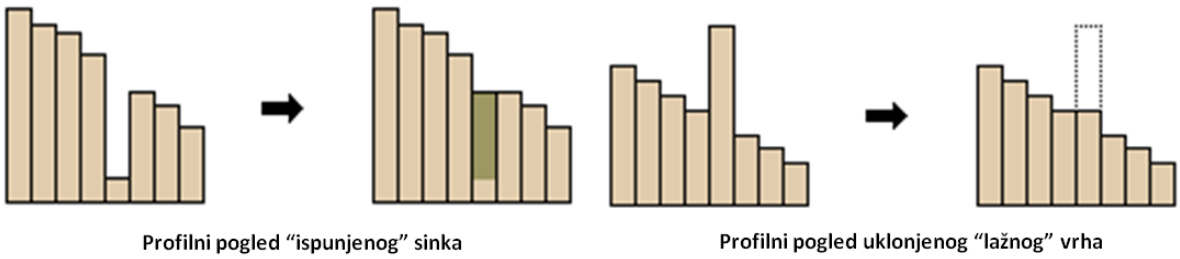

Slika 48. Shema ispravka lažnog sinka i lažnog vrha

Drugi korak u modeliranju mreže površinskog otjecanja se odnosi na 2) izvođenje modela smjera otjecanja (eng. *flow direction*). Na ispravljenom DMR-u generirat će se osam izlaznih smjerova koji se odnose na osam okružujućih, susjednih elemenata grida na koje voda može otjecati iz središnjeg (devetog) piksela za kojeg se utvrđuje smjer (Slika 49). Smjer

otjecanja određuje se na temelju najstrmijeg pada koji se izračunava kroz promjenu u Z vrijednosti između dva piksela / udaljenost između dva piksela x 100.

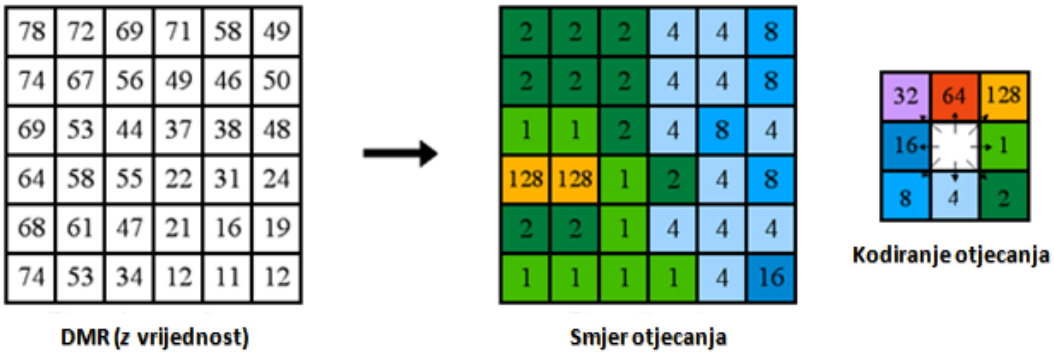

Slika 49. Shema klasificiranja smjera modela površinskog otjecanja vode

Kad je poznat smjer otjecanja vode, utvrđuje se s koliko piksela voda otječe u drugi element grida stvarajući time model akumulacije (eng. *flow accumulation*). Akumulacija vode se određuje za svaki piksel unutar cijelog modela. Postavlja se faktor težine koji najčešće iznosi 1 te se pridodaje svakom pikselu. Izlazni rezultat je rasterski model u kojem svaki element grida ima specifičnu vrijednost (1,2,3 itd.) akumulacije. Ta vrijednost ukazuje na to s koliko se ostalih okružujućih piksela voda slijeva na onaj piksel za koji se procjenjuje akumulacija. Pikseli s velikim vrijednostima ukazuju na područja veće akumulacije i mogu služiti za identifikaciju tokova. Elementi grida s vrijednosti nula ukazuju na lokalne topografske uspone, odnosno prostore gdje se akumulacija vode ne odvija (identifikacija grebena).

Na temelju modela smjera otjecanja ispravljenog DMR-a generirani su modeli akumulacije protoka za prostor testne plohe. Izvedeni model akumulacije je klasificiran u dvije klase. Kao povremeni i stalni tokovi izdvojeni su oni elementi grida koji imaju vrijednost akumulacije veću od 600, time određujući gustoću mreže površinskog otjecanja. Drugim riječima kao mogući tokovi izdvojeni su oni pikseli na koje se s više od 600 okružujućih piksela slijeva voda. Nakon reklasifikacije, rasterski model mogućih tokova pretvoren je u vektorski oblik podatka (liniju) koji je potom neznatno uglačan.

3.2.4 Provjera modela površinskog otjecanja

S ciljem klasificiranja, te identifikacije segmenata mreže površinskog otjecanja koji u stvarnosti ne postoje (aktivni i presušeni tokovi) ili na modelu nisu generirani, izvršena je provjera točnosti modela. Naime, prilikom generiranja modela mreže površinskog otjecanja algoritam uzima u obzir varijable nagiba, visine i smjera otjecanja te na temelju toga identificira prostore akumulacije. Generirani tokovi ne moraju odražavati stvarnu situaciju, već reprezentiraju prostore na kojem bi se, ako se uzmu u obzir spomenuti parametri, tokovi trebali

nalaziti. Zbog toga se u modelu često javljaju „lažni“ tokovi koje je potrebno identificirati, ukloniti ili korigirati. U ovom slučaju provjera modela površinskog otjecanja je izvršena terenskim istraživanjem. Kartiranje ispravljene mreže otjecanja, odnosno korekcija i klasificiranje tokova je izvedeno pomoć geodetskog RTK-GPS uređaja *STONEX 10* (Tablica 11).

Tablica 11. Specifikacije STONEX-a S10

Kanali	220
Praćeni sateliti	GPS, GLONASS, SBAS, GALILEO, COMPASS, QZSS
Stopa pozicije	do 50 Hz
Visoko precizna statička izmjera (*Long time observation*)	horizontalno 2.5 mm + 0.1 ppm RMS vertikalno 3.5 mm + 0.4 ppm RMS
Real time kinematic (< 30 km)	fiksirano RTK horizontalno 8 mm + 0.8 ppm RMS fiksirano RTK vertikalno 15 mm + 1 ppm RMS
Težina	1,37 kg

U uređaj su, radi lakše orijentacije na testnoj plohi, prebačeni podaci pravilne mreže poligona (eng. *fishnet*) površine 4 m² i mreža površinskog otjecanja generirana iz hibridnog modela testne plohe. Izuzev GPS uređaja, kao sredstvo orijentiranja prilikom kartiranja korištena je i analogna karta odabrane testne plohe u A1 formatu na kojoj je bio iscrtan model mreže površinskog otjecanja, suhozid, staza, stabla, rimski put odmorište itd. (Slika 50).

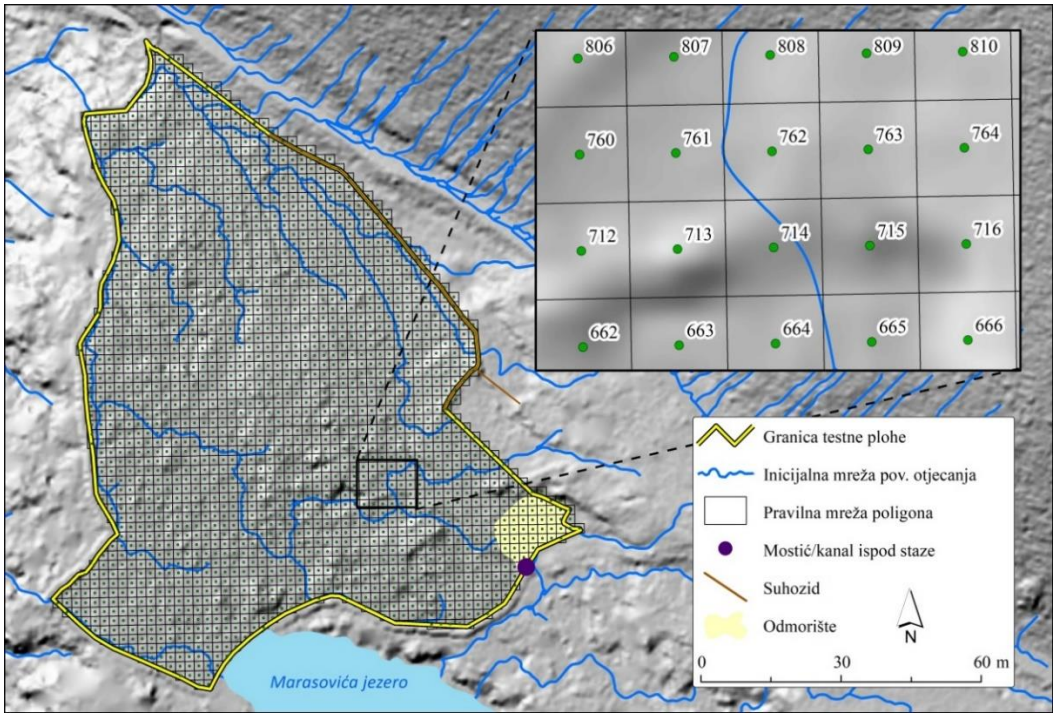

Slika 50. Pravilna mreža poligona koja je služila za orijentaciju na testnoj plohi

Klasifikacija tokova na aktivne i presušene olakšana je lociranjem ostatka stare sedre koja je korištena kao pokazatelj presušenih sedrotvornih tokova. Na slici 51. prikazani su tokovi izvedeni iz hibridnog modela testne plohe (referentno stanje) i tokovi kartirani na topografskoj A-U karti. Crveni poligoni ukazuju na izostanak mosta/staze i odmorišta na A-U karti u odnosu na danas te na veća odstupanja (manja gustoća) mreže površinskog otjecanja. Na tim lokacijama potencijalno se mogu detektirati presušeni sedrotvorni tokovi koje algoritam iz hibridnog modela nije uspio detektirati. Identifikacija presušenih tokova te prostori intenzivnog rasta invazivne vegetacije olakšalo je prepoznavanje ključnih lokacija s kojih bi se trebao uklanjati višak vegetacije kako bi došlo do obnove sedrotvornog procesa.

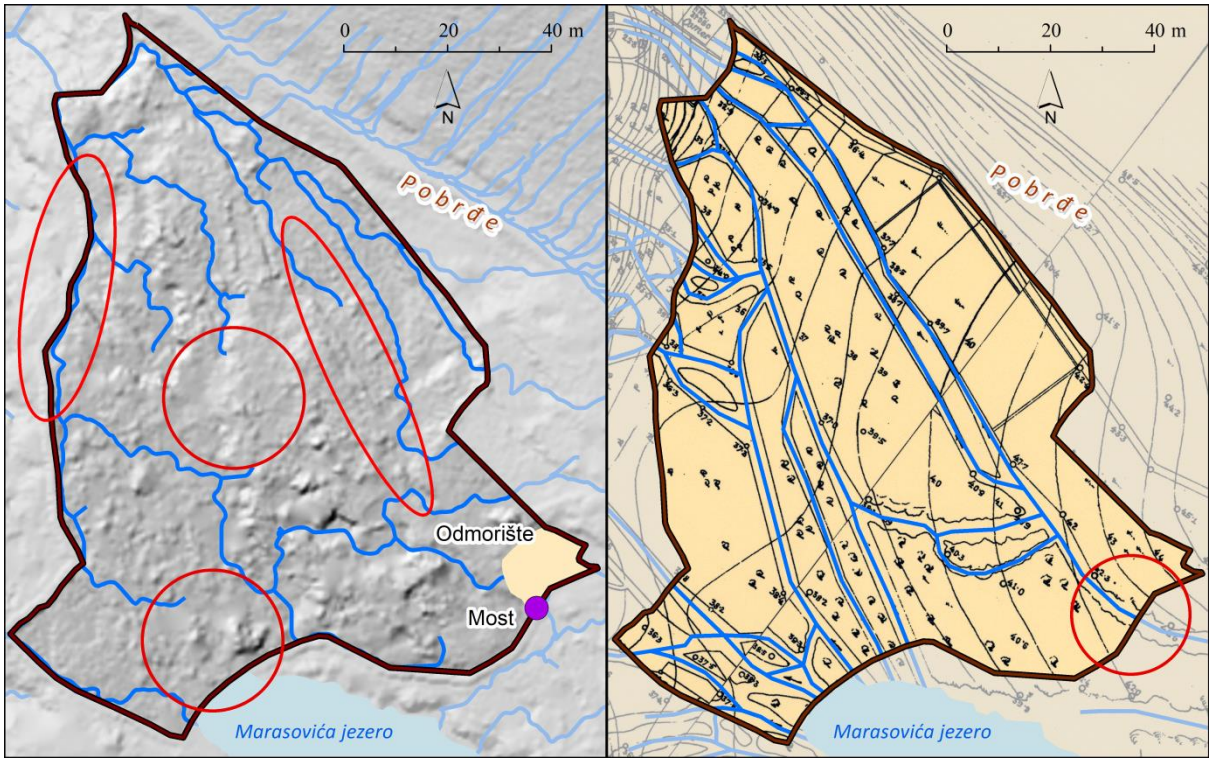

Slika 51. Mreža površinskog otjecanja na a) hibridnom modelu te b) A-U karti

3.2.5 Aerofotogrametrijska ciklična snimanja testne plohe

Cilj cikličnog zračnog snimanja je bio prikupljanje fotodokumentacije i inventarizacija nultog stanja (vegetacija, turistička staza, vodeni tokovi, jezera, itd.) prije i nakon selektivnog uklanjanja vegetacije na testnoj plohi. Ciklična, aero i terestrička, snimanja mogu imati iznimno značenje u pokušaju rekonstrukcije nultog stanja okoliša uslijed pojave nepoželjnih učinaka nakon provedbe akcijskih planova ili mjera. Nadalje, na temelju fotodokumentacije moguće je izvršiti kvantifikaciju promjena vegetacije u određenom razdoblju. To omogućuje interpretaciju promjena između nultog stanja krajobraza i budućih uzoraka. Ciklično zračno

snimanje je izvršeno koristeći bespilotnu letjelicu *Phantom 4* kineske tvrtke *Dà-Jiāng Innovations Science and Technology Co*. (DJI) (Tablica 12).

Tablica 12. Specifikacija UAV Phantom 4

Senzor	1/2, 3" CMOS[77] Efektivan broj piksela: 12,4 M
Leća	FOV 94° 20 mm (35 mm format equivalent) f/2,8 focus at ∞
ISO raspon	100-1600 (fotografija)
Brzina zatvarača	8 - 1/8000 s
Rezolucija slika	4000×3000
Raspon točnosti lebdenja	Vertikalno: ±0,1 m (s *Vision* pozicioniranjem) ±0,5 m (s GPS pozicioniranjem) Horizontalno: ±0,3 m (s *Vision* pozicioniranjem) ±1,5 m (s GPS pozicioniranjem)
Praćeni sateliti	GPS/GLONASS
Maksimalna otpornost na vjetar	10 m/s
Maksimalno vrijeme leta	oko 28 min.
Težina (baterije + propeleri)	1380 g

Prvo aerofotogrametrijsko snimanje izvršeno je u ožujku 2017. godine. Drugo snimanje izvršeno je u ožujku 2018. godine, neposredno nakon postavljanja pločica u reaktivirane sedrotvorne tokove. Proces obrade snimaka za oba snimanja je bio identičan. Prvi korak se odnosio na označavanje i prikupljanje točaka lokalne geodetske osnove. Označene geodetske točke su prikupljene koristeći *RTK-GPS Stonex S10* (Slika 52 i 53). Točke su prikupljene u službenom projekcijskom koordinatnom referentnom sustavu poprečne Mercatorove projekcije (HTRS96/TM).

Slika 52. Prikupljanje točaka lokalne geodetske osnove, ožujak 2017. godine

[77] Complementary Metal Oxide Semiconductor

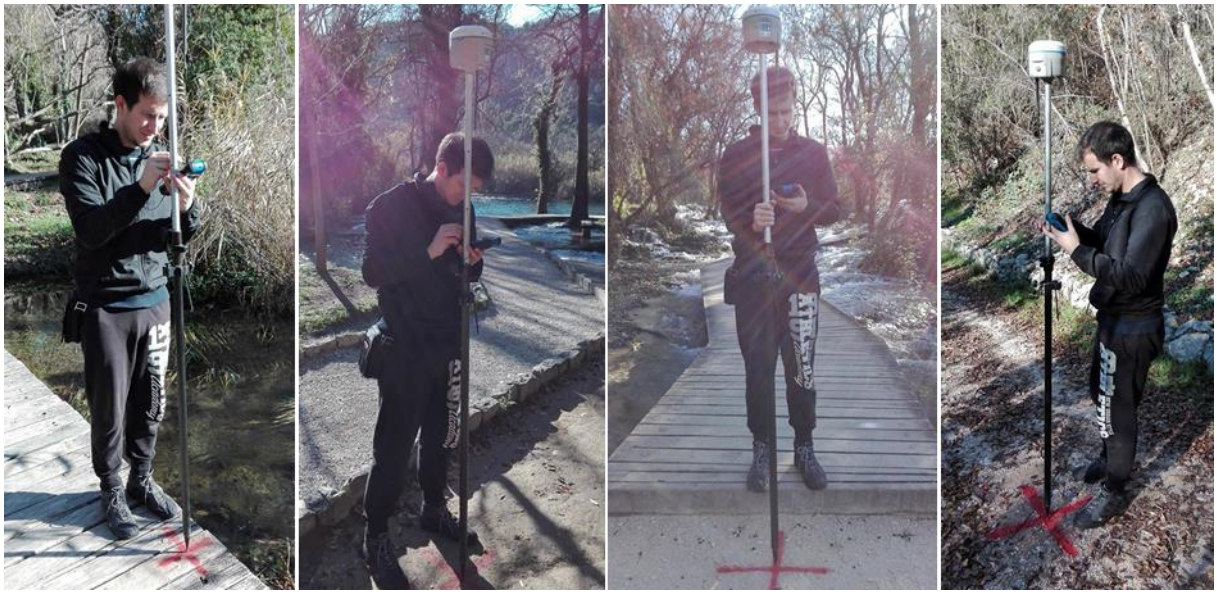

Slika 53. Prikupljanje točaka lokalne geodetske osnove, ožujak 2018. godine

Orijentacijske točke su prikupljene s ciljem postizanja bolje apsolutne orijentacije modela. GCP se mogu prepoznati na snimcima ili rekonstruiranom modelu, a imaju poznate (X, Y i Z) koordinate u specifičnom koordinatnom sustavu. Označene su i prikupljene četiri orijentacijske (OT01-04) uvažavajući morfologiju terena. Zbog guste vegetacije nije bilo moguće prikupiti veći broj orijentacijskih točaka u središtu testne plohe. Naime, dolazio bi do gubitka signala GPS-a ili bi se procijenilo da točke ne bi bile vidljive iz zraka. Plan postavljanja točaka je napravljen u softveru *ArcMap 10.1*. Prilikom označavanja GCP-a vođeno je računa da su oznake dovoljno velike, korištena je kontrastna boja u odnosu na lokalni teren te se pazilo na otvorenost horizonta iznad oznaka. Prije snimanja izvršeno je kalibriranje *vision* pozicijskog sustava, inercijalnog mjernog sustav (IMU) te kompasa UAV-a (Slika 54).

Slika 54. Kalibriranje sustava senzora Phantoma 4, ožujak, 2018

Snimanje definirane testne plohe obavljeno je prije i nakon selektivnog uklanjanja vegetacije. Cijela testna ploha je snimljena s nekoliko *Double Grid* misija na različitim visinama. *Double Grid* misija se preporučuje za korištenje prilikom izvođenja 3D modela. Korišteno je prednje i bočno preklapanje od 80%. Ukupno je prikupljeno 700 fotografija u oba snimanja.

3.2.5.1 Proces obrade fotografija

U procesu obrade fotografija korišten je računalni program *Agisoft Metashape Professional* 1.5.1 specijaliziran SfM-MVS[78] za fotogrametriju. To je napredni softver za 3D modeliranje koji kroz obradu digitalnih fotografija stvara visokokvalitetne 3D prostorne podatke (Barilar i dr., 2015). Primjenjuje metodu SfM koja omogućuje da se tehnikom prilagođavanja snopova istodobno odredi orijentacija i položaj kamere u prostoru (vanjski orijentacijski parametri) kao i 3D koordinate točaka objekta za veliki broj slika (Eltner i dr., 2016, Barilar i dr., 2015). Proces obrade fotografija te generiranja izlaznih modela, digitalnog modela površina (DSM[79]), digitalnog ortofota, oblaka točaka i 3D model, izvršen je u nekoliko koraka. Obrada fotografija je izvršena na radnoj stanici INSTAR 1950X, procesora AMD Ryzen Threadripper 1950X do 4.0GHz, radne memorije 64GB DDR4 te grafičke kartice NVIDIA Quadro P4000 8GB.

Prvi korak odnosio se na filtraciju prikupljenih aero snimaka kroz automatsku procjenu kvalitete (eng. *image quality).* Zamućene i loše fokusirane fotografije mogu negativno utjecati na rezultate povezivanja stoga su uklonjene sve fotografije s vrijednošću manjom od 0,4. Potom su isključni (maskirani) pomični (npr. ljudi unutar plohe ili na stazi) i nepotrebni dijelovi na fotografijama koje prilikom izvođenja rijetkog oblaka točaka mogu otežati povezivanje fotografija. Nakon filtracije i maskiranja slijedila je relativna orijentacija, odnosno povezivanje fotografija (eng. *align*). Ovim procesom se utvrđuje lokacija i orijentacija svake fotografije (kamere) u prostoru istovremeno kreirajući vezne točke (rijetki oblak točaka) (Slika 55a). Time se obavlja automatska kalibracija nemjernih kamera te se procjenjuju parametri unutarnje orijentacije kamere koji se nakon svake optimizacije neznatno mijenjaju. Nakon orijentacije prikazuju se izračunate pozicije kamere i rijetki oblak točaka. Reprojekcijska pogreška izvedenog oblaka točaka se dodatno smanjuje primjenom alata gradualne selekcije (eng. *gradual selection*) i optimizacije kamere (eng. *optimize camera*). Iz procijenjenih lokacija kamera izračunava se gusti oblak točaka. Kvaliteta (gustoća) gustog oblaka točaka postavljena

[78] Structure from Motion-Multi View Stereo
[79] Digital Surface Model

je na nisku vrijednost (eng. *low quality*) jer se rekonstruirana scena koristi samo za dodavanja točaka lokalne geodetske osnove (GCP-a). Potom se na temelju gustog oblaka točaka rekonstruira površina testne plohe. Prilikom generiranja mreže poligona korištena je algoritamska metoda *arbitrary* (3D podatak). Kao izvor podataka je odabran gusti oblak točaka s parametrom niske kvalitete. Sljedeći korak uključivao je dodavanje markera za četiri označene orijentacijske točke (OT1-OT4) (Slika 55b). Parametar točnosti markera je ostavljen na zadanoj softverskoj vrijednosti od 0,5 mm. Filtrirane su fotografije na kojima se pojedini marker nalazi te je ručnim ispravljanjem njihova lokacija na modelu poboljšana.

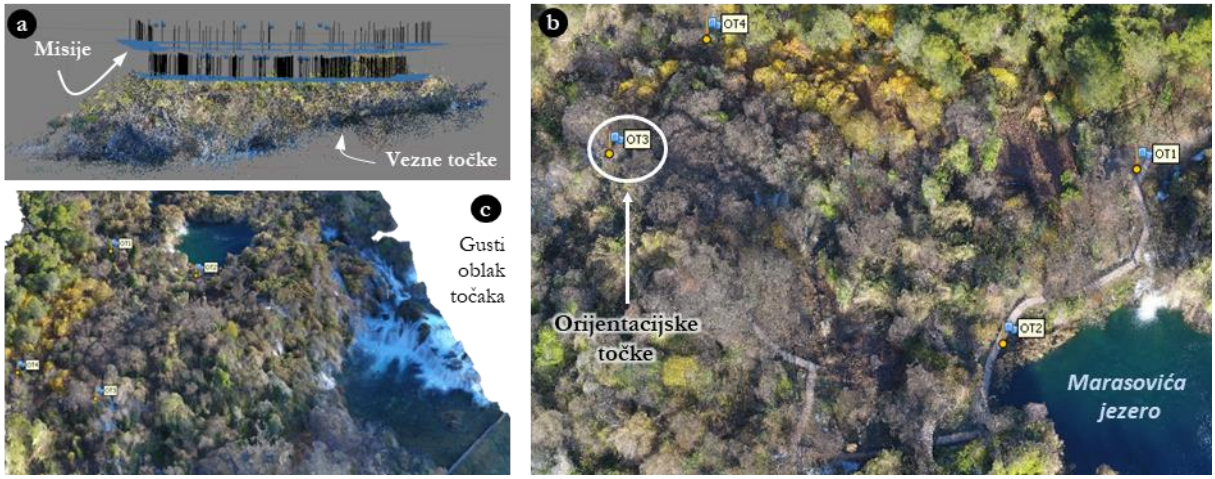

Slika 55. Screen shotovi najvažnijih koraka u SfM fotogrametriji

Nakon georeferenciranja modela izvršena je nova rekonstrukcija scene s boljim postavkama parametra kvalitete. Izveden je gusti oblak točaka te mreža poligona *arbitray* s visokom vrijednosti kvalitete (*eng. high*) (Slika 55c). Potom je poligonska mreža teksturirana. Konačni rezultat obrade fotografija su DSM, DOF i fotorealističan 3D model.

3.2.6 Kartiranje stabala i vegetacijskog pokrova na testnoj plohi

U prvoj polovici 2017. godine na testnoj plohi je izvršeno detaljno kartiranje stabala i veće vegetacije s ciljem inventarizacije, kvantificiranja te izrade plana sječe invazivnih vrsta. Fitosociološka klasifikacija vegetacije je previše općenita da bi bila upotrebljiva u konkretnom slučaju. U procesu kartiranja korišteni su stajališta TLS-a, oblaci točaka prikupljeni na svakom stajalištu te pravilna mrežu poligona (Slika 56). Svi podaci su uneseni u tablete. Obilazak i kontrola svakog stajališta olakšana je korištenjem RTK-GPS uređaja i provjerom analogne karte sa šifriranim poligonima.

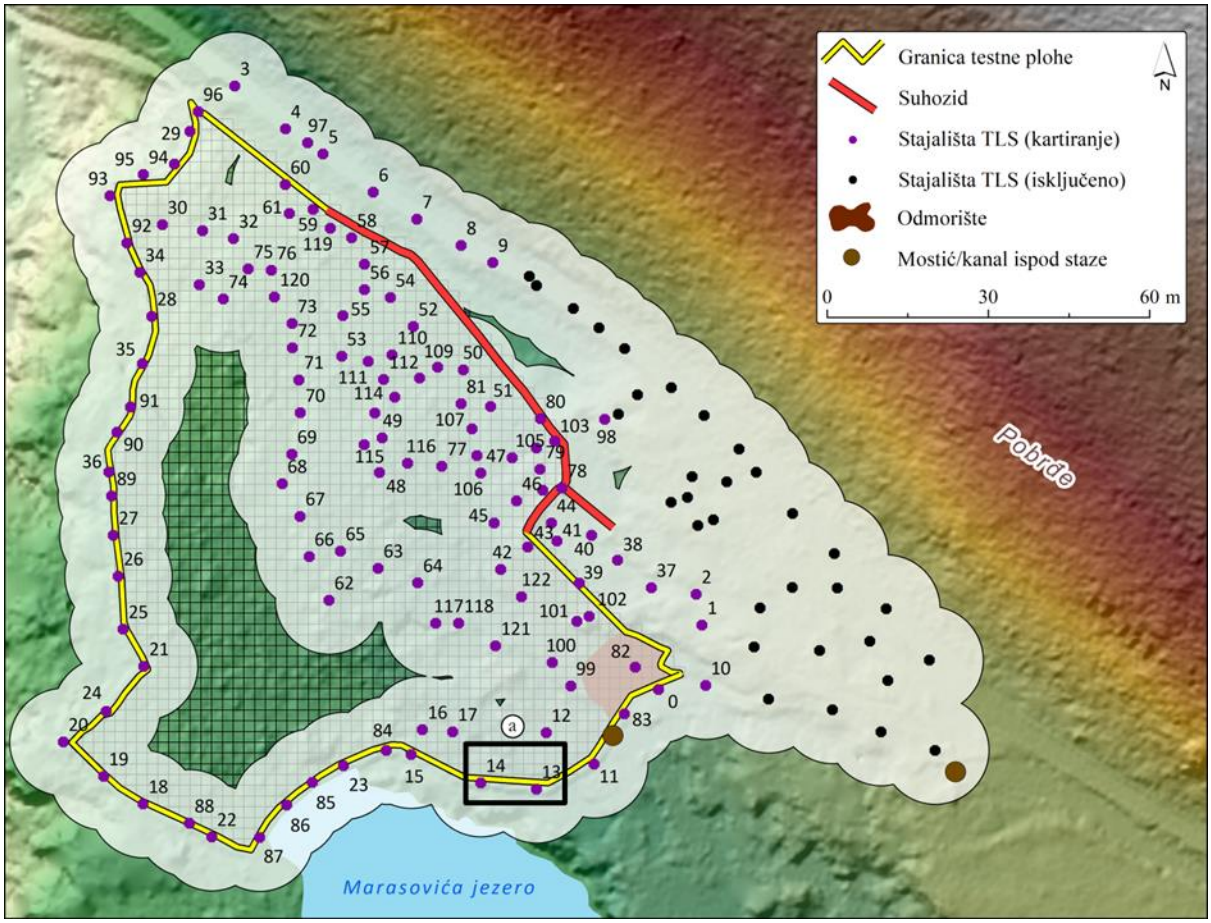

Slika 56. Stajališta TLS-a korištena u procesu kartiranja vegetacije

U procesu kartiranja korišteno je ukupno 124 od 156 stajališta TLS-a. Dolaskom na točku stajališta analiziran je gusti oblak točaka prikupljen na toj lokaciji pod određenim azimutom. Prepoznat je tip visoke i srednje vegetacije koji tu prevladava te je za svaki element dodan atribut vrste (tipa) vegetacije (Slika 57a). Kartiranje vegetacije izvršeno je stručnu pomoć prof. Vladimira Hršaka.

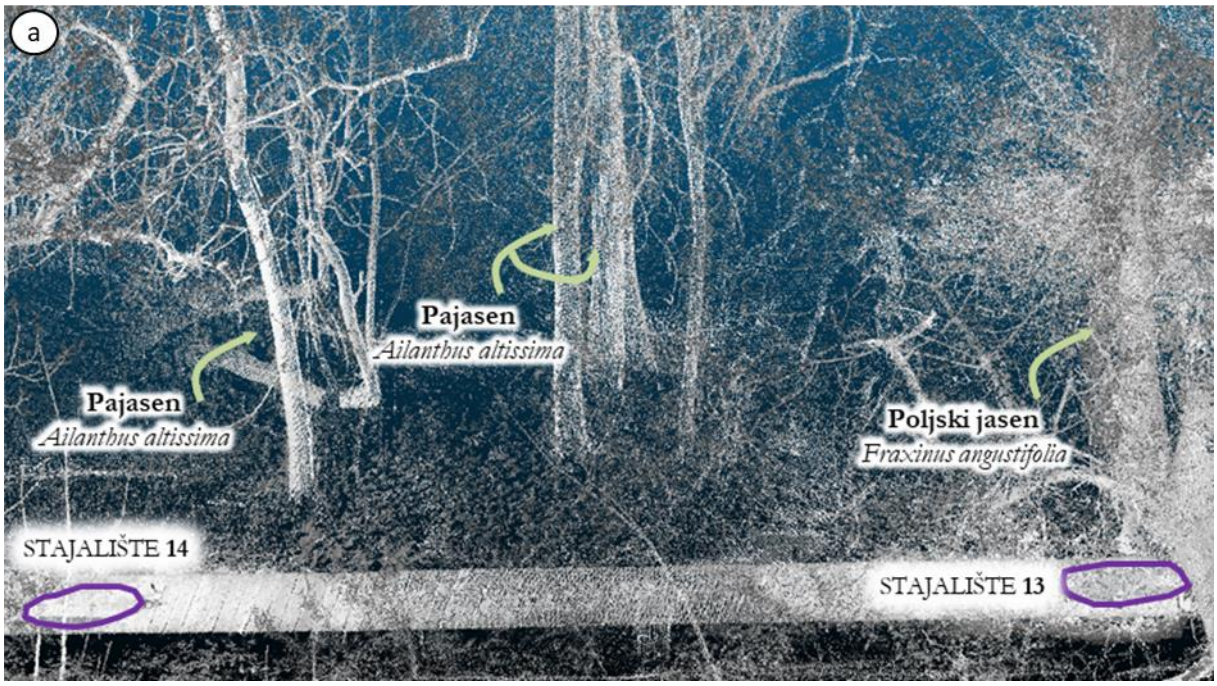

Slika 57. a) Kartiranje vrste stabala na isječku oblaka točaka između stajališta 13 i 14

Stabla su georeferencirana iz LiDAR podataka, a grmlje je popisano na svakom stajalištu samo kvalitativno. Na temelju učestalosti dominantnih vrsta drveća mogu se izdvojiti zone koje se razlikuju prema stupnju vlažnosti staništa.

3.2.7 Selektivna sječa invazivne vegetacije

Iskorjenjivanje invazivnih vrsta ima pozitivne učinke na autohtonu biotu. Invazivne vrste interaktivno djeluju s drugim elementima prirodnih sustava zbog čega mogu nanijeti znatnu štetu autohtonim prirodnim sustavima i stvoriti velike štete društvu. Kao odgovor na navedeno u istraživanjima je razvijeno nekoliko mjera kontrole, ograničavanja i iskorjenjivanja invazivnih vrsta u pogođenim područjima. Ondje gdje je to moguće, iskorjenjivanje postaje favorizirani pristup. Kontrola i ograničavanje zahtijevaju znatna financijska ulaganja te neodređeni utrošak vremena. Iako iskorjenjivanje može zahtijevati velika kratkoročna ulaganja ono ipak daje najbolje šanse za oporavak autohtone biološke raznolikosti (Zavaleta i dr., 2001). U velikom broju zaštićenih područja primjenjujući različite metode djelovanja nastoji se sustavno ukloniti invazivna vegetacija (van Wilgen, 2012, Foxcroft i Richardson, 2007, Cowie i Werner, 1993).

Prije izvođenja selektivne sječe vegetacije na testnoj plohi dobivena je dozvola *Ministarstva zaštite okoliša* da se pokusno ukloni vegetacija invazivne biljke pajasena (*Ailanthus altissima (Mill.) Swinge*) koja svojom velikom agresivnošću smanjuje biološku raznolikost staništa umanjujući vrijednost prirodnih ekosustava. Nanosi nemjerljivu štetu

krškim ekosustavima, parkovima prirode, nacionalnim parkovima, poljoprivredi i turizmu. Prije izvođenja selektivnog plana uklanjanja vegetacije testna ploha je prema svojim morfometrijskim i vegetacijskim obilježjima podijeljena u četiri zone čije su značajke detaljnije objašnjene u poglavlju *4.2.2 Katastar vegetacije nultog stanja testne plohe*. S ciljem zaštite ostalih vegetacijskih vrsta te reaktivacije tokova napravljen je plan sječe pajasena prema određenim vegetacijskom zonama na testnoj plohi u skladu s primjerima dobre prakse (NSW, 2014). U praksi se najčešće koriste tri tehnike uklanjanja pajasena:

1) ručne i mehaničke tehnike;

2) kemijski postupci;

3) ostali postupci (Lodeta i dr., 2010).

Zbog osjetljivog i zaštićenog ekosustava NPK-a odlučeno je da će se primijeniti ručna i mehanička tehnika uklanjanja pajasena. Odlučeno je da uklanjanje izvrši stručno osoblje „NP Krka“ u lipnju, 2017. godine koji uz srpanj predstavlja najbolji termin jer su rezerve hrane iz korijena potrošene za rast izbojaka i listova (Lodeta i dr., 2010). S obzirom na to da su na mikrolokalitetu zastupljene četiri kategorije pajasena prema starosti odlučeno je da se:

1) mladi sjemenjaci - ručno čupaju (Slika 58);

2) stabalca do 1-1,5 m visine - ručno čupaju ili sijeku;

3) stabla do 15 cm promjera - sijeku;

4) stabla koja nisu u fazi plodonošenja te zrela stabla koja se osjemenjuju – sijeku.

Slika 58. Primjer ručnog čupanja mladih izdanaka pajasena

Potrebno je istaknuti kako sječa potiče rast izbojaka iz debla i korijenovih izdanaka. Ovaj problem trebao bi se riješiti kontinuiranim ručnim čupanjem mladih sjemenjaka te reaktivacijom tokova. Naime, istraživanja su pokazala da pajasen ne može podnijeti dugotrajno vlažna i poplavljena tla, ali kad jednom dođe do njegovog naseljavanja može preživjeti na

suhim tlima i tolerirati sušne uvjete (Miller, 1990, Fryer, 2010, Wenning, 2014). Uklanjanjem vegetacije te reaktivacijom tokova na testnoj plohi nastojat će se postići nepovoljni uvjeti za regeneraciju i opstanak pajasena.

3.2.8 Postavljanje sustava za praćenje stanja sedrotvornog okoliša na testnoj plohi

Pod pretpostavkom da će selektivnim uklanjanjem invazivne te čišćenjem srušene i akumulirane (djelovanje vremenskih neprilika) vegetacije doći do postupne reaktivacije sedrotvornih tokova te obnove sedrotvornih uvjeta na testnoj plohi je uspostavljen sustav praćenja sedrotvornog okoliša koji se sastoji od četiri sastavnice:

1) Praćenje dinamike formiranja sedre na vapnenačkim pločicama (mikro razina);
2) Praćenje protoka vode na odabranim lokacijama testne plohe (mezo razina);
3) Praćenje fizikalno-kemijskih parametara vode (mezo razina);
4) Praćenje regeneracije invazivne vegetacije nakon selektivne sječe (mezo razina).

U reaktivirane sedrotvorne vodotoke postavit će se vapnenačke pločice i predmetna stakalca[80] kako bi se na njima mogla pratiti dinamika formiranja sedre (prirast i erozija) te dinamika kolonizacije biljnih i životinjskih zajednica (sedrotvoraca). Vapnenačka podloga na kojoj će se pratiti dinamika formiranja sedre izabrana je kako bi se simulirala prirodna podloga okoliša rijeke Krke koja je dominantno karbonatna iz mezozojske starosti. Uz mjerenje prirasta i erozije sedre, pratit će se brzina protok te fizikalno-kemijski parametri vode. Fizikalno-kemijski parametri mjerit će se na glavnoj lokaciji utoka vode na testnu plohu pomoću multiparametarske sonde. Regeneracija invazivne vegetacije pratit će se metodom cikličnog fotografiranja.

3.2.8.1 Mjerenje brzine protoka vode na testnoj plohi

Brzina protoka vode je na testnoj plohi praćena na sedam lokacija. Lokacije mjerenja protoka vode su odabrane tako da pokrivaju sve glavne dotoke vode na testnu plohu (P1-P4), ključne vodene tokove na plohi (P5-P6) i otjecanje vode s plohe (P7) prema staroj vodenici na presušenom slapu (Slika 59). Brzina protoka je mjerena instrumentom CMD[81] (eng. *current meter digitizer*), *Rickly Hydrological Co*. (Tablica 13).

[80] Aktivnosti koje u sklopu projekta izvode kolege s Biološkog odsjeka s Prirodoslovno-matematičkog fakulteta, Sveučilišta u Zagrebu.
[81] Current Meter Digitizer

Tablica 13. Specifikacije uređaja za mjerenje brzine protoka vode

Veličina	18 cm x 10 cm x 3 cm
Težina	400 g
Raspon mjerenja brzine protoka	0 – 7.6 m/s
Raspon temperature vode	od -20 do +70°C
Rezolucija prikaza	0.001

Iako bi za potrebe korelacijskih analiza bilo idealno da je brzina protoka praćena na pojedinačnim lokacijama vapnenačkih pločica (n=14) zbog mjernih ograničenja uređaja za mjerenje protoka to nije bilo moguće izvesti. Naime, u većini slučajeva na lokacijama postavljanja pločica. dubina vode je veći dio godine manja od 30 cm što predstavlja minimalnu dubinu na kojoj instrument može izmjeriti brzinu protoka.

Na lokacijama P1 (tok Matica ispod Mostića), P5 (početak toka Vrtnjak), P6 (neposredno prije Jezera šest stabala) i P7 (najnizvodnija točka toka Vrtnjak na testnoj plohi) prije uklanjanja vegetacije nije bilo vode.

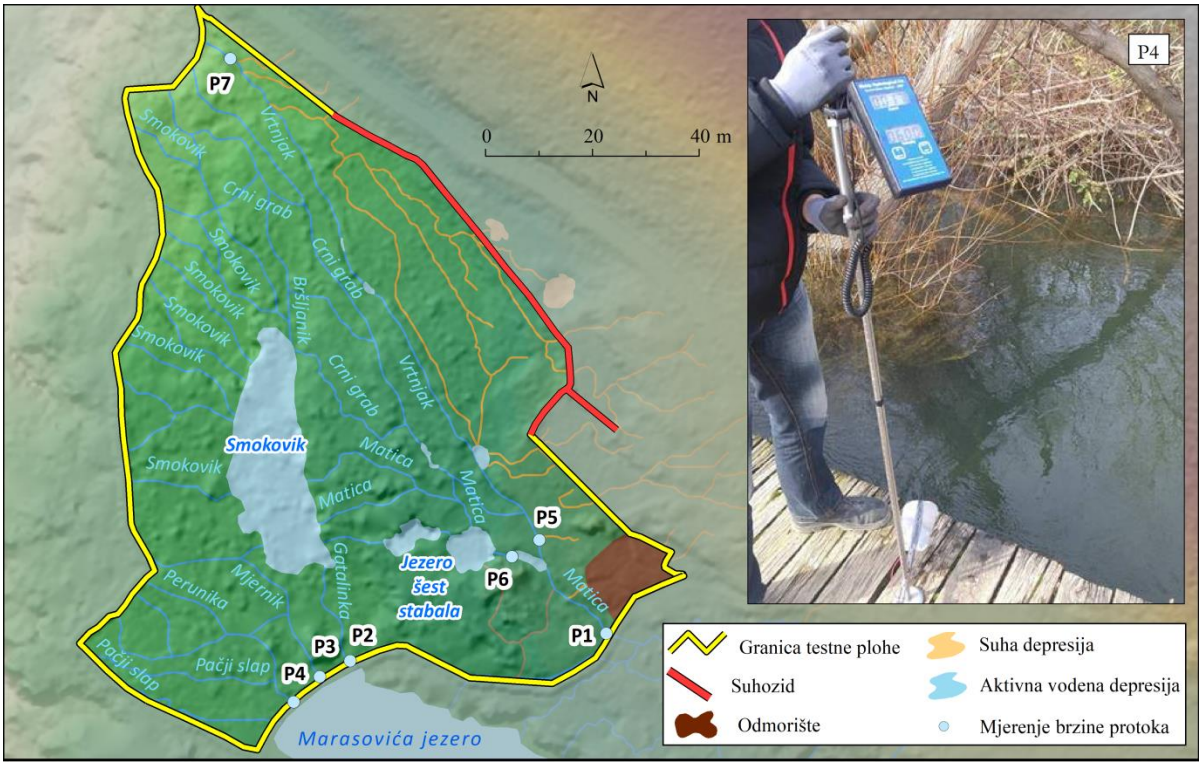

Slika 59. Lokacije mjerenja protoka vode na testnoj plohi

Mjerenje brzine protoka vode na odabranim lokacijama počelo je prije postavljanja vapnenačkih pločica (ožujak, 2018), ali nakon uklanjanja vegetacije. Prvo mjerenje je

obavljeno 15. veljače 2018. Brzina protoka je mjerena jednom mjesečno. Na slikama 60-63. prikazane su sve lokacije mjerenja protoka vode na testnoj plohi.

Slika 60. Mjerenje brzine protoka vode na lokaciji P1 (tok Matica kod odmorišta)

Slika 61. Mjerenje brzine protoka vode na lokacijama P2-P4 (kod Marasovića jezera)

Slika 62. Mjerenje brzine protoka vode na lokacijama P5 (ulaz u tok Vrtnjak) P6 (ulaz u Pačji slap)

Slika 63. Mjerenje brzine protoka vode na lokaciji P7 (najnizvodnija točka toka Vrtnjak na testnoj plohi)

3.2.8.2 Postavljanje multiparametne sonde YSI EXO2

Ispitivanje kakvoće vode na odabranoj testnoj plohi unutar NP "Krka" dio je sustava za praćenje stanja reaktiviranog sedrotvornog krajobraza. Loša kakvoća vode ne utječe samo na život vodenih organizama, već i na cijeli ekosustav Parka. Nadzor kakvoće vode pomaže u praćenju prirodnih procesa (npr. prirodna eutrofikacija) te utvrđivanju čovjeka utjecaja (npr. prisutnost zagađivača, toksičnih metala itd.) na ekosustav. U blizini lokacije P3 za mjerenje protoka vode, u toku Mjernik (po čemu je tok i dobio ime), 18. svibnja 2018. godine, postavljena je multiparametna sonda YSI EXO2 (Slika 64). Sonda je postavljena ispod šetnice (staze) te je od trenutka postavljanja kontinuirano mjerila kvalitetu vode koja dolazi na testnu plohu.

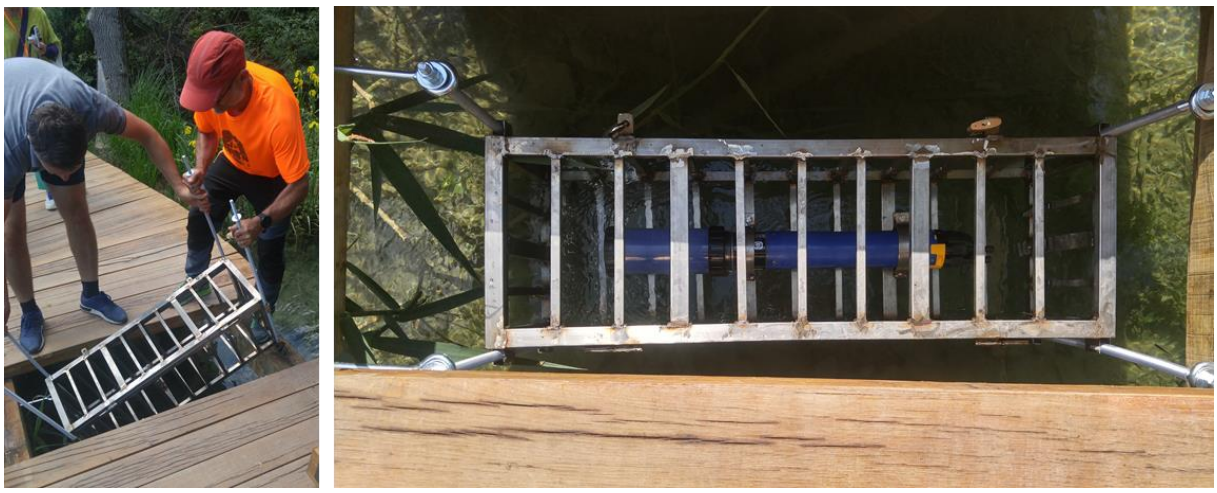

Slika 64. Postavljanje multiparametnae sonde YSI EXO2 na odabranu lokaciju

Postavljenje sonde na lokaciju P1, od kuda nakon selektivnog uklanjanja vegetacije te uklanjanja akumuliranog šljunka, dolazi većina vode koja opskrbljuje testnu plohu, nije bila moguća zbog male dubine staze te povećanog rizika uočavanje sonde od strane turista (blizina odmarališta). Sonda je zbog smanjenja rizika od krađe postavljena u metalni kavez od neoksidirajuće legure željeza na dubini od oko 40 cm (Slika 65).

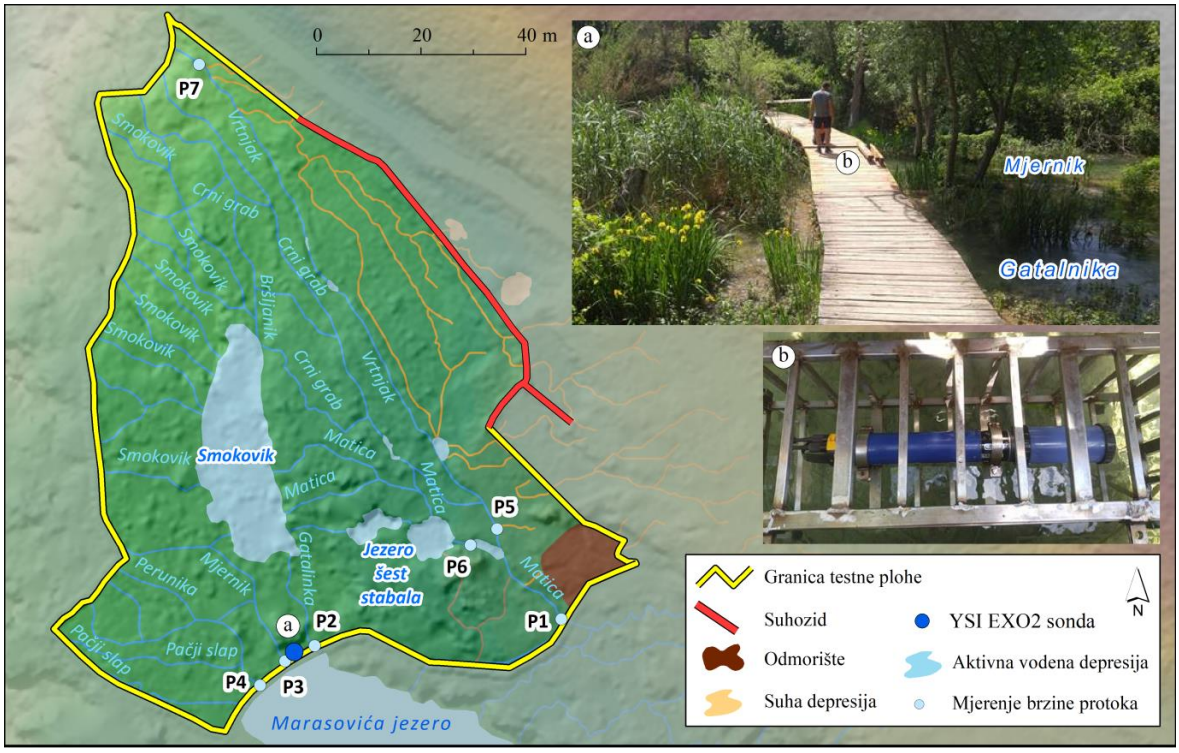

Slika 65. Lokacija postavljanja multiparametarske sonde na testnoj plohi

Programirana je da obavlja kontinuirana mjerenja u petnaestominutnim intervalima Prikupljeni podaci su preuzimani pomoću *Bluetootha*. Nakon dvadeset dana u vodi uočeno je da su sonda i kavez potpuno osedreni stoga je u nastavku istraživanja provođeno intervalno čišćenje sonde (Slika 66).

Slika 66. Osedreni kavez i sonda nakon dvadesetak dana izloženosti toku

Multiparametna YSI EXO2 sonda (URL 48) je namijenjena za nadzor kakvoće vode, a obilježavaju je senzori visoke preciznosti s ugrađenom memorijom, mogućnosti bežičnog povezivanja te jednostavna integracija u sustav morskih, slatkovodnih i podzemnih voda (Tablica 14).

Tablica 14. Specifikacije sonde YSI EXO2

Trajanje baterije	90 dana
Promjer	7,62 cm
Duljina	71.10 cm
Stopa uzorkovanja	do 4 Hz
Ulaz za senzore	7
Težina	3,60 kg
Radna temperatura	-5 to +50°C
Memorija	>1,000,000 očitanja, 512 MB ukupne memorije
Mjerenje	Morska, slatkovodna i zagađena voda

Prema službenim specifikacijama sonda mjeri 23 parametra. Međutim, neki od njih su duplo izraženi (npr. mjerenje dubina do različitih vrijednosti ili iskazivanje istog parametra kroz različite jedinice). Pregled parametara, točnost i rezolucija mjerenja prikazani su u tablici 15.

Tablica 15. Parametri mjerenja sonde YSI EXO2

Parametar	Senzor	Točnost	Rezolucija
Amonij (slatkovodna voda)	Amonijev senzor *Ammonia with pH sensor* SKU: 599710	±10% očitane vrijednosti ili 2 mg/L-N, w.i.g.	0.01 mg/L
Tlak zraka	Integralni barometar	±1.5 mmHg od 0 to 50°C	0.1 mmHg
Plavo-zelene alge, fikocijanin (eng. *blue-green algae, phycocyanin)*	*Total Algae Sensor* SKU: 599102-01	**Linearnost:** R^2 >0.999 za serijsko razrjeđivanje otopine Rhodamine WT od 0 to 100 µg/mL BGA-PC ekvivalenata	0.01 µg/L; 0.01 RFU
Plavo-zelene alge, fitoketrin (eng. *blue-green algae, phycoerythrin*)	*Total Algae Sensor* SKU: 599103-01	**Linearnost: :** R^2 >0.999 za serijsko razrjeđivanje otopine Rhodamine WT od 0 to 280 µg/mL BGA-PE ekvivalenta	0.01 µg/L; 0.01 RFU
Klorid (slatkovodna voda)	Senzor klorida SKU: 599711	±15% očitane vrijednosti ili 5 mg/L-Cl, w.i.g.	0.01 mg/L
Klorofil	*Total Algae Sensor* SKU: 599102-01, 599103-01	**Linearnost: :** R^2 >0.999 za serijsko razrjeđivanje otopine Rhodamine WT od 0 to 400 µg/L Chl *a* ekvivalenta	0.01 µg/L Chl; 0.01 RFU

Provodljivost	Senzor provodljivosti / temperature SKU: 599870	**0 to 100:** ±0.5% očitane vrijednosti ili 0.001 mS/cm, w.i.g.; **100 to 200**: ±1% očitane vrijednosti	0.0001 to 0.01 mS/cm (range dependent)
Dubina - 10 m	*Integral, Non-vented Depth Sensor*	±0.04% FS (±0.004 m or ±0.013 ft)	0.001 m (0.001 ft) (auto-ranging)
Dubina - 100 m	*Integral, Non-vented Depth Sensor*	±0.04% FS (±0.04 m or ±0.13 ft)	0.001 m (0.001 ft) (auto-ranging)
Dubina - 250 m	*Integral, Non-vented Depth Sensor*	±0.04% FS (±0.10 m or ±0.33 ft)	0.001 m (0.001 ft) (auto-ranging)
Otopljeni kisik, % zasićenja (eng. *dissolved oxygen, % air saturation*)	Optički senzor otopljenog kisika SKU: 599100-01	**0 to 200%:** ±1% očitane vrijednosti ili 1% zasićenja, w.i.g.; **200 to 500%:** ±5% očitane vrijednosti	0.1% zasićenje zraka
Otopljeni kisik mg/L	Optički senzor otopljenog kisika SKU: 599100-01	**0 to 20 mg/L:** ±0.1 mg/L ili 1% očitane vrijednosti, w.i.g.; **20 to 50 mg/L:** ±5% očitane vrijednosti	0.01 mg/L
fDOM *(CDOM)*	fDOM senzor SKU: 599104-01	**Linearnost: :** R2 > 0.999 za serijsko razrjeđivanje of 300 ppb QS otopine **Granica detekcije:** 0.07 ppb QSU	0.01 ppb QSU
Level, Vented - 10 m	Integral Vented Level Sensor	±0.03% FS (±0.003 m or ±0.010 ft)	0.001 m (0.001 ft)
Nitrate *(freshwater only)*	Senzor nitrata SKU: 599709	±10% očitane vrijednosti ili 2 mg/L-N, w.i.g.	0.01 mg/L
pH	pH senzor SKU:599701 guarded, 599702 unguarded pH/ORP senzor SKU:599705 guarded, 599706 unguarded	±0.1 pH jedinica unutar ±10˚C od temperature kalibracije; ±0.2 pH jedinica za cijeli raspon temperature	0.01 units
ORP	pH/ORP senzor SKU:599705 guarded, 599706 unguarded	±20 mV u Redox standardnoj otopini	0.1 mV
Temperatura	Senzor provodljivosti / temperature SKU: 599870	±0.01°C[2] ±0.05°C[2]	0.001 °C
Zamućenost	Senzor zamućenosti SKU: 599101-01	**0 to 999 FNU:** 0.3 FNU or ±2% očitane vrijednosti, w.i.g.; **1000 to 4000 FNU:** ±5% očitane vrijednosti	0 to 999 FNU = 0.01 FNU; 1000 to 4000 FNU = 0.1 FNU

Salinitet	Izračunato iz provodljivosti i temperature	±1.0% očitane vrijednosti ili 0.1 ppt, w.i.g.	0.01 ppt
Specifična provodljivost	Izračunato iz provodljivosti i temperature	±0.5% očitane vrijednosti ili .001 mS/cm, w.i.g.	0.001, 0.01, 0.1 mS/cm (auto-scaling)
Ukupna količina otopljenih krutih tvari (eng. *Total Dissolved Solids - TDS*)	Izračunato iz provodljivosti i temperature	Nije navedeno	Varijabla
Ukupna količina suspendiranih tvari (eng. *total suspended solids -TSS*)	Izračunato iz zamućenosti i referentnih uzoraka korisnika	Nije navedeno	Varijabla

Izvor: URL 52

Na slici 67 je isječak korisničkog sučelja na kojem su prikazani primjeri očitanih vrijednosti parametara izmjerenih sondom EXO2. U nastavku je dan kratak opis značenja izmjerenih parametara, koje su očekivane unutar aktivnih sedrotvornih sustava te njihov utjecaj na vodene organizme i okolni ekosustav.

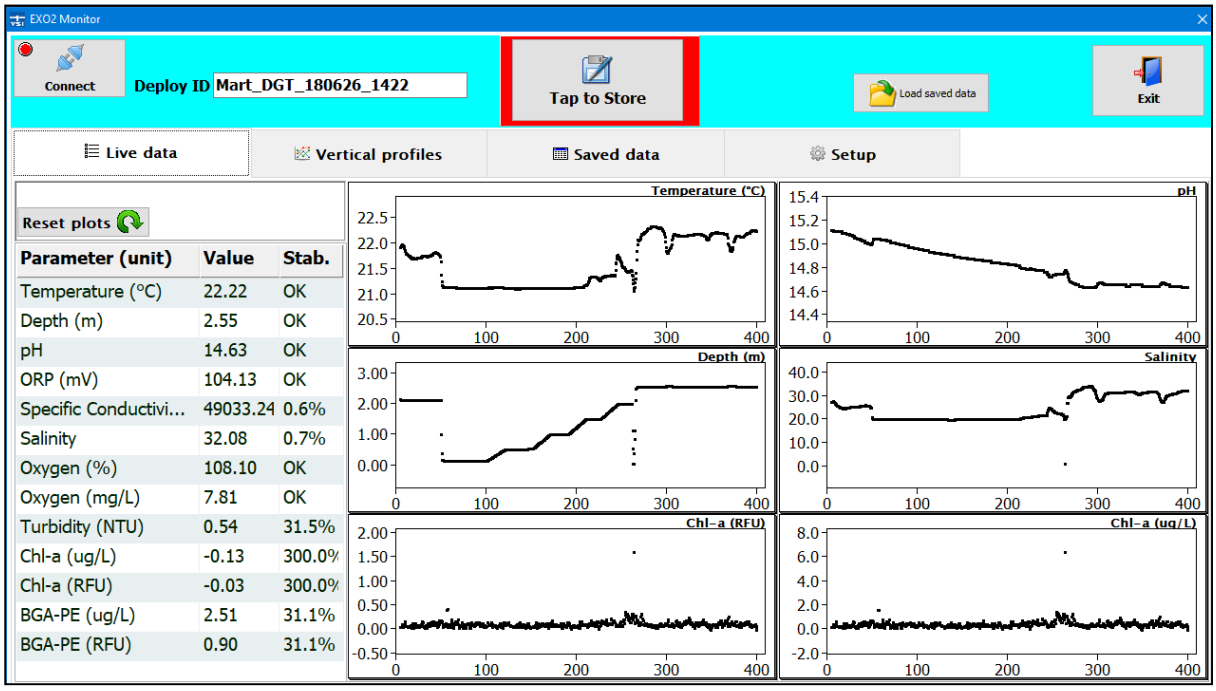

Slika 67. Screen shot izmjerenih parametara s EXO2 monitora

Otopljeni kisik (DO) se odnosi na razinu slobodnog kisika (O_2) prisutnog u vodi ili drugim otopinama. Obično se izražava miligramima po litri (mg/L) ili kao % zasićenosti O_2 u

vodi (URL 45). Vrijednosti ispod 80% ukazuju na povećanu potrošnju O_2 (URL 42). U sporo tekućim vodama vrijednost pada ispod 50% (Matoničkin Kepčija, 2014). Postotni udio O_2 od 80 do 120 se smatra veoma dobrim, dok vrijednosti ispod 60 % i iznad 125 % mogu biti štetne za živi svijet u vodi (Dundović, 2013). Povećanjem temperature vode dolazi do smanjivanja DO što kao posljedicu može imati smanjenje brojnosti živog svijeta u njoj.

Temperatura (°C) vode je fizičko svojstvo koje opisuje njenu prosječnu termalnu energiju. Važan je abiotički čimbenik koji se analizira prilikom procjene kakvoće vode jer utječe na fizičke, kemijske i biološke procese (Chapman, 1996, URL 42). Indirektno utječe na brzinu metabolizma i biološke aktivnosti (razmnožavanje, probava hrane, brzina disanja, rast) vodenih organizama (Grgić i Redžović, 2016, Matoničkin Kepčija, 2014, URL 45) što dovodi do povećane potrošnje O_2 i povećane razgradnje organske tvari. Povećanjem temperature vode raste brzina kemijskih reakcija s isparavanjem (Chapman, 1996).

Konduktivitet ili vodljivost je mjera koja opisuje sposobnost vode da provodi električnu struju (Chapman, 1996). Vodljivost je indirektna mjera za ukupnu količinu otopljenih tvari u vodi (Matoničkin Kepčija, 2014). Povećanjem TDS-a u vodi povećava se i električna vodljivost. Vodljivost većine slatkih voda se kreće od 10 do 1000 $\mu S/cm^{-1}$. Prirodne vode imaju veću vodljivost ako se nalaze na podlozi od topljivih stijena (npr. vapnenac) (Matoničkin Kepčija, 2014). U sušnim područjima evaporacija vode može uzrokovati visoke koncentracije otopljenih tvari u vodi što može dovesti do visoke vodljivosti (Matoničkin Kepčija, 2014).

Zamućenost se odnosi na optičko određivanje bistrine vode. Povećana koncentracija suspendiranih i otopljenih tvari smanjuje bistrinu vode stvarajući mutan, neproziran izgled (Matoničkin Kepčija, 2017). Čimbenici koji utječu na zamućenje vode mogu biti: koncentracija i veličina čestica te valna duljina ulaznog zračenja. Zamućenost može inhibirati fotosintezu blokirajući sunčevu svjetlost. Zaustavljen ili smanjen intenzitet fotosinteze znači smanjenu količinu DO (URL 42). Mjera zamućenosti često se koristi kao pokazatelj kvalitete vode, a izvodi se iz procijenjenih ukupnih suspendiranih krutih (TSS) tvari u vodi (URL 42).

Klorofil (eng. *chlorophyl*) je pigment koji se nalazi u biljkama, algama i fitoplanktonu. Može se izražavati u mikrogramima po litri u (µg/L). RFU[82] je mjerna jedinica koja se koristi u analizama detekcije fluorescencije. RFU vrijednosti se pretvaraju u koncentracije klorofila te su potom izražavaju u mikrogramima po litri (µg/L) (URL 45). Koncentracija klorofila s koncentracijom i postotnim udjelom O_2 upućuju na razinu primarne produkcije (Dundović, 2013). Pokazatelj je biomase fitoplanktona (URL 45) te služi za procjenu razine eutrofikacije

[82] Relative Fluorescence Unit

(Espinola, 2017). U tablici 16 navedene su smjernice za određivanje razine eutrofikacije prema koncentraciji klorofila a u površinskoj slatkoj vodi.

Tablica 16. Razina eutrofikacije prema koncentraciji klorofila a

Kakvoća vode	Odlična	Dobra	Zadovoljavajuća	Prolazna	Loša
Razina eutorfikacije	I	II	III	IV	V
Klorofil a (µg/l)	<4	<10	<20	≤50	>50

Izvor: Espinola, 2017.

Prema nekim izvorima vrijednost klorofila ispod 7 µg/L spada u poželjan raspon, 7-15 µg/L je manje poželjno, dok se iznad 15 µg/L smatra problematičnim (URL 43). Dakle, vodene mase s niskim razinama hranjive tvari (npr. oligotrofna jezera) imaju nisku razinu klorofila (<2,5 µg/L), dok vode s visokim sadržajem hranjivih tvari imaju visoku razinu klorofila (5-140 µg/L) čak do 300 µg/L (Chapman, 1996). Cijanobakterije, modrozelene ili plavozelene alge jedine su bakterije koje sadrže klorofil *a* (URL 42). U krškim vodotocima čine osnovu zajednica koje sudjeluju u stvaranju sedrenih barijera. Previše plavozelenih algi u jezerima može biti štetno za vodeni život jer alge troše kisik potreban za vodene biljke i životinje (URL 45).

Otopljena organska tvar u boji (CDOM) prirodna je otopljena tvar koja apsorbira UV[83] svjetlost u vodi. Optički je aktivna frakcija DOM-a (Makarewicz i dr., 2018). Otopljena organska tvar (DOM) najveći je rezervoar organskog ugljika (OC[84]) u vodenom okolišu (URL 42). Otopljeni organski ugljik (DOC) u vodi potječe uglavnom iz raspadanja organske materije ili iz dotoka bioloških otpadnih tvari koji mogu djelovati kao izvor DOC-a ili povećati topljivost organskih tvari (Bolan i dr., 1999). Jedan od glavnih kemijskih preduvjeta koji moraju biti zadovoljeni da bi došlo do nastanka sedre je taj da koncentracija DOC-a u vodi mora biti niža od 10 mg/L^{-1}. Vrlo niske koncentracije organskih spojeva reduciraju kristalizaciju kalcita, vrijednosti od 0,2 mg/L usporavaju rast kristala dok ga 5 mg/L potpuno inhibira (URL 7).

CDOM je poznat kao humusna mrlja "boje čaja" proizvedena iz podvodnih raspadajućih biljaka i listova uslijed oslobađanja tanina i drugih molekula (URL 47). To je karakteristično za vodena tijela koja sadrže velike količine raspadajuće vegetacije. Voda s vrlo malo CDOM-a se čini plavom, dok pri većim koncentracijama poprima zelenkastu i smeđu boju. Subfrakcija CDOM-a koja fluorescira kada se apsorbira svjetlo određenog zračenja naziva se fDOM (Makarewicz i dr., 2018). fDOM se promatra kao surogat za CDOM te

[83] Ultra-Violet
[84] Organic Carbon

predstavlja brz i jednostavan način praćenja DOM-a u prirodnim vodama (Lee i Kim, 2018). Može se koristiti kao posrednik za otopljeni organski ugljik (DOC) (URL 45). U priobalnim vodama fDOM čini 20–70% DOC-a, kontrolira prodiranje štetnog UV zračenja u površinsku vodenu zonu, zbog čega igra kritičnu ulogu u ciklusima ugljika i biološke proizvodnje (Lee i Kim, 2018).

pH[85] vrijednost je mjera za kiselost vode izražena kao aktivitet vodikovih iona (H^+) u otopini (Grgić i Redžović, 2016, Matoničkin Kepčija, 2014). Izražava se na temelju definirane logaritamske skale od 0 do 14 koja ukazuje koliko je kiselo (višak H^+ iona) ili alkalno (lužnato) (manjak H^+ iona) tijelo vode. Što je vrijednost manja to je voda kiselija (URL 42). pH vode određuje topljivost i biološku dostupnost hranjivih sastojaka (fosfora, dušika i ugljika) za vodeni život. Rijeka Krka spada u neutralno-alkalične vode. pH vrijednosti u rijeci Krki se kreću oko 8 što je čini optimalnom za učinkovitu biološku produktivnost (Grgić i Redžović, 2016). Kad pH dosegne vrijednosti 8,3 naznačeno je prisustvo karbonata (Patil i dr., 2012). Male promjene u pH mogu imati dugoročne posljedice. Naime, smanjenjem vrijednosti pH vode povećava se topljivost fosfora i drugih hranjivih sastojaka što ih čini dostupnima za rast biljaka. U oligotrofnom jezeru to može izazvati lančanu reakciju, gdje uslijed pristupačnijih hranjivih tvari dolazi do bujanja vodenih biljki i algi što povećava potrebu za otopljenim kisikom (DO). Time se stvara eutrofikacijsko jezero koje je bogato hranjivim tvarima i biljnim životom, ali ima nisku koncentraciji DO. Različiti čimbenici mogu utjecati na promjenu vrijednosti pH vode. Većina prirodnih promjena nastaje uslijed interakcija s okolnim stijenama i drugim materijalima. pH također može varirati s oborinama (posebno kiselom kišom) i otpadnim vodama ili rudarskim ispuštanjem. Uz navedeno, koncentracije CO_2 mogu utjecati na razinu pH (URL 42). Naime, razine pH mogu svakodnevno oscilirati uslijed fotosinteze i disanja u vodi (Slika 68).

[85] Power of Hydrogen

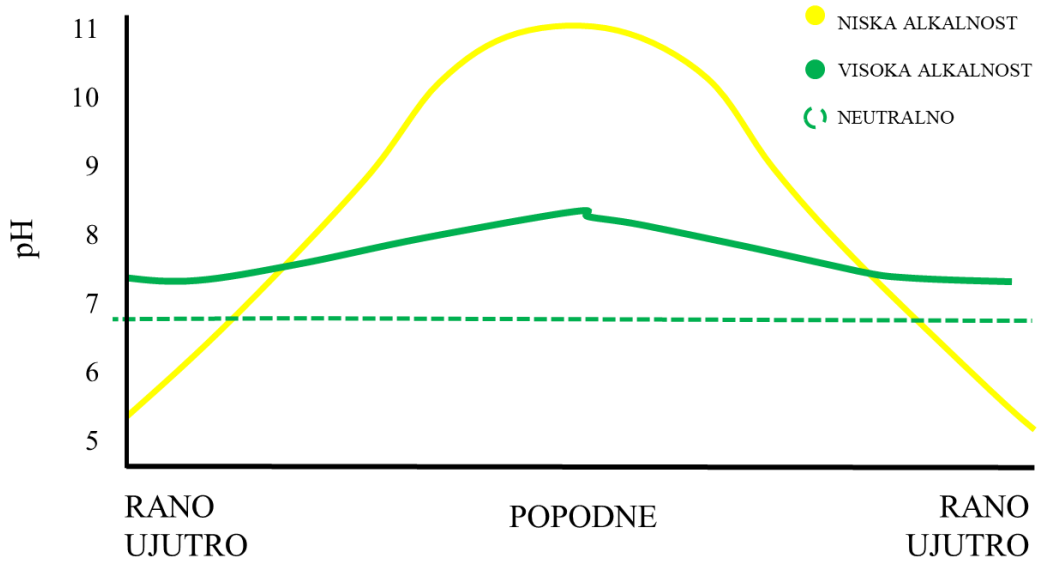

Slika 68. Primjer dnevnih varijacija pH vrijednosti

Oksidacijsko-redukcijski potencijal (ORP[86]) ukazuje na dostupnost slobodnih elektrona te oksidacijsku ili redukcijsku sposobnost vode (James i dr., 2004). Može se promatrati kao mjera čistoće vode koja predstavlja sposobnost razgrađivanja specifičnih kontaminanata. Raspon vrijednosti joj može varirati od -2000 do +2000, a izražava se u mjernoj jedini milivolta (mV). Visoke vrijednosti ORP-a indikator su prisutnosti veće količine otopljenog O_2 u vodi. Nizak ORP znači male količina otopljenog O_2 čim se u vodi povećava toksičnost određenih metala i kontaminanata i javlja mnogo uginulih tvari koji se ne mogu razgraditi. Takvo okruženje nije pogodno za okoliš i vodene organizme. U zdravim vodama ORP bi trebao imati vrijednosti od 300 do 500 mV (URL 49). Dakle, viša vrijednost ORP-a ukazuje na veću sposobnost vode da razgradi različite zagađivače (mikroorganizmi, kontaminanti). Pozitivno očitanje ORP-a ukazuje da je tvar oksidant, odnosno da ima sposobnost prihvaćanja elektrona.

Ukupno otopljene tvari (TDS) su u vodi uglavnom otopljene anorganske soli od koji većinu čine kationi Ca, Mg, Na i K te anioni karbonata, hidrogenkarbonata, klorida, sulfata i nitrata (Dadić, 2012) uz male količine organske tvari. Izražavaju se u mg/L. U "čistoj" vodi TDS je otprilike jednak salinitetu.

Interval mjerenja parametara na sondi je postavljen na 15 min. Po danu je prikupljeno oko 97 logova podataka. Proces obrade prikupljenih podataka je podijeljen u nekoliko koraka. Prvo su podaci grupirani prema danima te je za svaki dan izmjerena srednja, maksimalna i minimalna vrijednost te standardna devijacija (SD) (Tablica 18). Na slici 69. prikazan je primjer dnevnog kretanja temperature vode.

[86] Oxidation–Reduction Potential

Tablica 17. Primjer fizikalno-kemijskih podataka grupiranih po danima (1. srpanj, 2018)

Mjerenje	Dan (MM/DD/G)	Vrijeme	1 ODO% sat	2 ODO mg/L	3 Temp °C	4 SpCond µS/cm	5 Sal ppt	6 Turbidity FNU	7 Chlorophyll RFU
1.	07/01/218	00:02:28	88.8	7.88	21.188	480.4	0.23	3.14	0.48
2.	07/01/218	00:17:28	88.9	7.88	21.197	480.3	0.23	3.15	0.47
3.	07/01/218	00:32:28	88.8	7.88	21.188	480.3	0.23	3.1	0.5
…	…	…	…	…	…	…	…	…	…
97.	07/01/218	23:47:28	89	7.86	21.436	476.2	0.23	3.21	0.49
	MAX.		89.3	7.89	21.47	480.4	0.23	3.53	0.52
	MEAN		88.77	7.87	21.23	478.32	0.23	3.24	0.42
	MIN.		88.2	7.85	20.995	476.2	0.23	1.52	0.28
	SD		0.36	0.01	0.17	1.43	0.00	0.21	0.06

	Datum (MM/DD/G)	Vrijeme	8 Chlorophyll µg/L	9 BGA-PC RFU	10 BGA-PC µg/L	11 fDOM RFU	12 fDOM QSU	13 pH	14 pH mV	15 ORP mV
1.	07/01/218	0:04:12	6.05	-0.07	-0.07	3.25	9.75	8.66	-94.8	396.7
2.	07/01/218	0:19:12	6.24	-0.07	-0.07	3.25	9.76	8.65	-94.7	396.9
3.	07/01/218	0:34:12	6.22	-0.05	-0.05	3.25	9.74	8.65	-94.6	397.1
…	…	…	…	…	…	…	…	…	…	…
97.	07/01/218	23:47:28	1.98	-0.32	-0.32	1.87	5.6	8.41	-82.4	338.4
	MAX.		2.06	-0.28	-0.28	2.28	6.85	8.44	-81.40	338.40
	MEAN		1.69	-0.32	-0.32	1.85	5.54	8.42	-82.99	333.40
	MIN.		1.13	-0.36	-0.36	1.51	4.52	8.40	-84.20	327.60
	SD		0.25	0.02	0.02	0.08	0.25	0.01	0.68	2.95

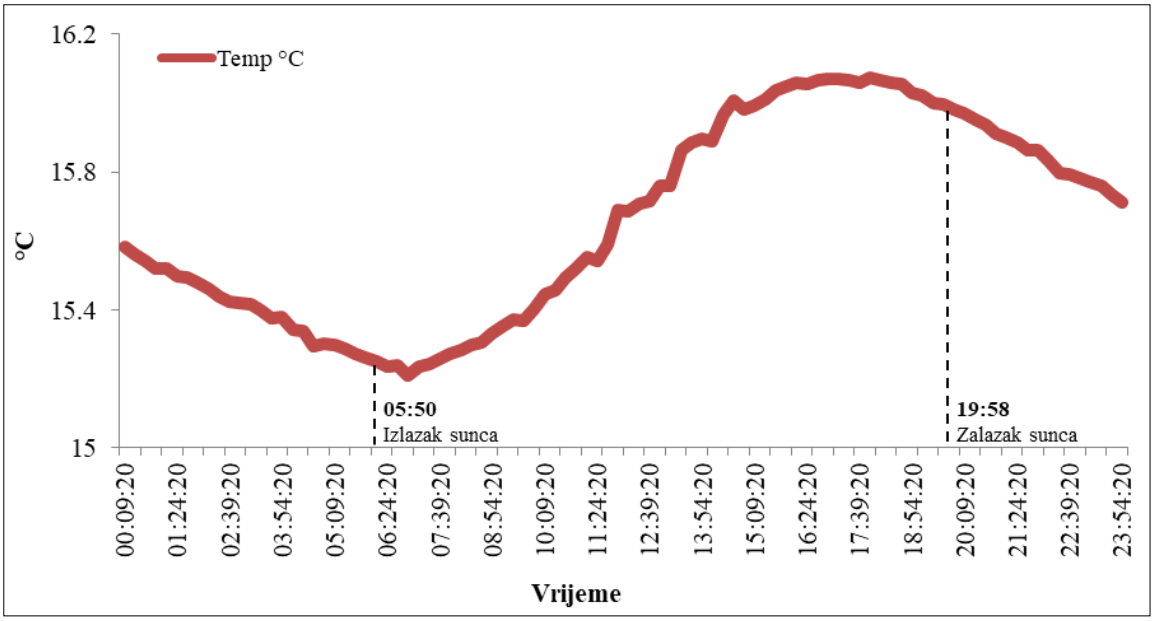

Slika 69. Kretanja vrijednosti temperature vode kroz 2. svibanj, 2019.

U drugom koraku je izvršeno grupiranje izvedenih podataka prema danima u mjesecu. Kao osnovni ulazni podatak korištena je srednja vrijednosti izmjerenih podataka po danu. Potom je za svaki mjesec izvedena maksimalna, srednja i minimalna vrijednost te standardna devijacija (SD) (Tablica 19) pojedinog parametra. Na slici 70. prikazan je primjer kretanja prosječnih dnevnih temperatura vode te prosječnog udjela otopljenog kisika (mg/L) za 2. srpnja, 2018. Može se uočiti da količina otopljenog kisika u vodi opada s porast temperature vode.

Tablica 18. Primjer fizikalno-kemijskih podataka grupiranih po mjesecima (srpanj, 2018).

Mjerenje	**Dan (MM/DD/G)**	**1 ODO% sat**	**2 ODO mg/L**	**3 Temp °C**	**4 SpCond µS/cm**	**5 Sal ppt**	**6 Turbidity FNU**	**7 Chlorophyll RFU**
1.	07/01/218	88.77	7.87	21.23	478.3	0.23	3.243	0.422
2.	07/02/218	88.93	7.80	21.76	474.0	0.23	3.303	0.399
…	…							
97.	07/31/218	85.52	6.98	25.63	251.7	0.12	5.227	0.408
	MAX.	89.04	7.87	25.63	478.32	0.23	5.94	0.84
	MEAN	86.68	7.34	23.69	376.06	0.18	4.31	0.56
	MIN.	84.71	6.98	21.23	251.74	0.12	2.69	0.35
	SD	1.42	0.24	0.95	73.99	0.04	1.04	0.14

	Datum (MM/DD/G)	**8 Chlorophyll µg/L**	**9 BGA-PC RFU**	**10 BGA-PC µg/L**	**11 fDOM RFU**	**12 fDOM QSU**	**13 pH**	**14 pH mV**	**15 ORP mV**
1.	07/01/218	1.686	-0.319	-0.319	1.846	5.536	8.42	-82.99	333
2.	07/02/218	1.596	-0.324	-0.324	1.777	5.331	8.42	-83.05	338
…	…								
97.	07/31/218	1.575	-0.327	-0.327	1.830	5.491	8.41	-82.55	341
	MAX.	3.34	-0.27	-0.27	2.13	6.40	8.45	-81.80	367.25
	MEAN	2.23	-0.31	-0.31	1.65	4.95	8.42	-83.25	357.25
	MIN.	1.39	-0.34	-0.34	1.43	4.29	8.39	-85.18	333.40
	SD	0.56	0.02	0.02	0.16	0.48	0.01	0.77	9.17

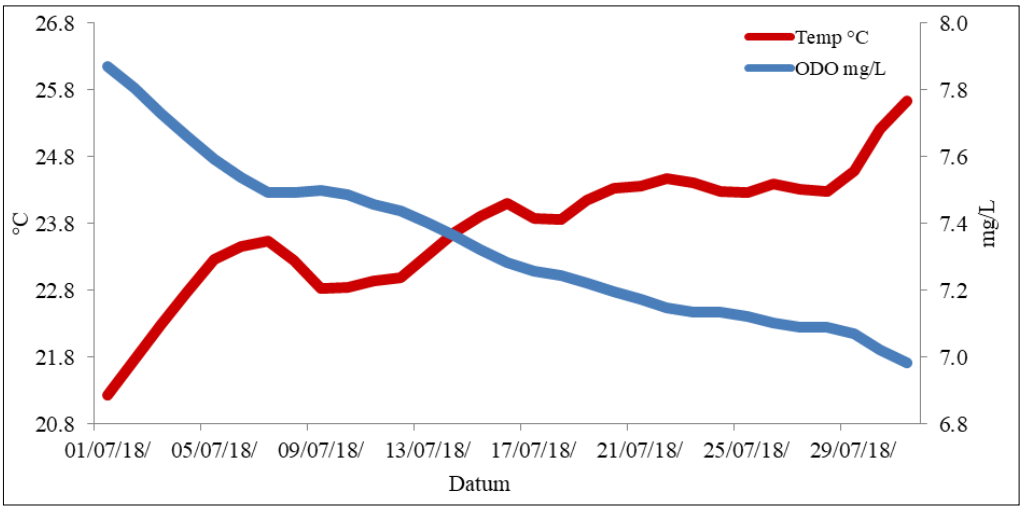

Slika 70. Kretanja vrijednosti temperature vode i otopljenog kisika kroz srpanj, 2018

U trećem koraku je utvrđeno godišnje kretanje srednjih vrijednosti odabranih fizikalno-kemijskih podataka grupiranih po mjesecima. Srednja vrijednost parametara pojedinog mjeseca preuzeta je iz prethodnog koraka.

3.3 Mikro razina

3.3.1 Razvoj uređaja za praćenje dinamike formiranja sedre (TFD)

Za praćenje dinamike formiranja sedre osmišljen (Slika 71b) je i konstruiran uređaj za mjernu makrofotogrametriju (CMD[87]) koji omogućuje beskontaktno, intervalno te izravno praćenje dinamike formiranja sedre temeljeno na metodi makrofotogrametrije. CMD nalikuje trokoordinatnim mjernom stroju (CMM[88]) koji služe za prostorno mjerenje složenih tijela (Slika 71a).

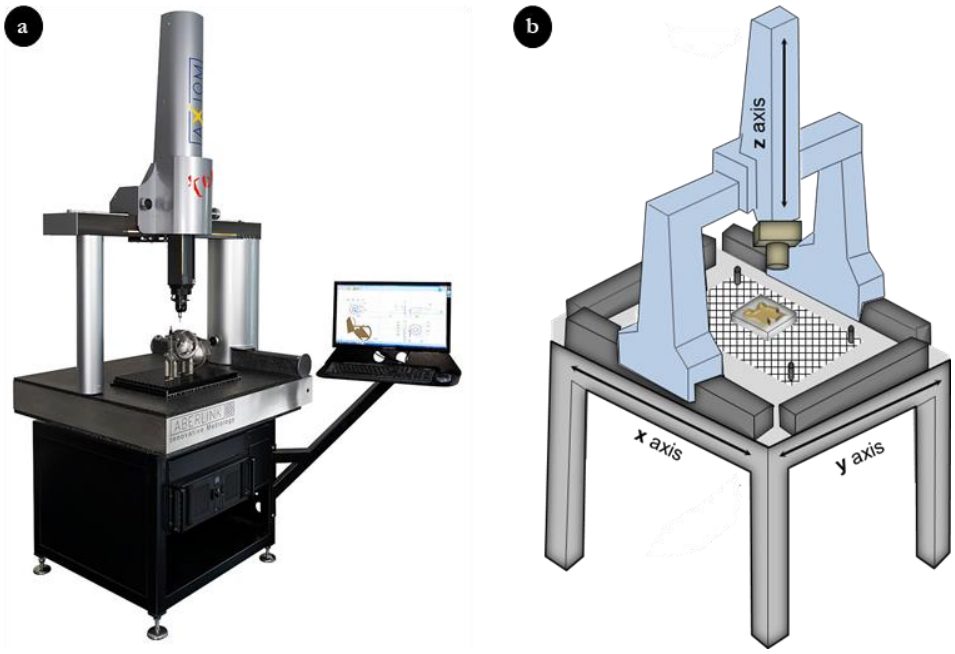

Slika 71. a) Izgled trokoordinatnog mjernog stroja (CMM) te b) konceptualni model CMD-a

Uređaj je konstruiran i izrađen (Slika 72) tako da se minimaliziraju česti problemi koji su karakteristični za proces makrofotogrametrije. Oni uključuju: plitku dubinu polja (DoF), nejednak intenzitet svjetlosti, pojavu sjena, zamućenje te nedovoljno preklapanje fotografija. DoF je glavni problem izvođenja makrofotogrametrije (Gajski i Gašparović, 2015, Marziali i Dionisio, 2017). Predstavlja udaljenost između najbližeg i najdaljeg objekta na sceni koji se na slici čine prihvatljivo oštrim. Scena izvan tog područja je zamućena što može uzrokovati poteškoće u procesu spajanja fotografija, izvođenju gustih oblaka točaka te proizvodi artefakte u konačnoj teksturi modela (Marziali i Dionisio, 2017). Problem nejednakog osvjetljenja (Nicolae i dr., 2014, Percoco i dr., 2015) uzrokuje pojavu sjena na objektu, a može se riješiti primjenom bljeskalice koja usmjerava svjetlo izravno na objekt. Nadalje, kako se ne bi izgubio

[87] Coordinate Measuring Macrophotogrammetry Device
[88] Coordinate Measuring Machine

fokus bitno je održavati fotoaparat stabilnim zbog čega se u snimanju često primjenjuju različiti stativi (URL 32).

Slika 72. Proces izrade mehaničkog okvira CMD-a

CMD se sastoji od šest glavnih dijelova (Slika 75)

1. Postolje
2. Pomična metalna ploča s fiksnim držačima
3. Profili za pomicanje mehaničkog okvira
4. Pomični mehanički okvir
    4.1 X os
    4.2 Y os
    4.3 Z os
5. Sustav senzora (eng. *sensor system*)
    5.1 DSLR kamera *Nikon D5300* (Tablica 20)
    5.2 Makro objektiv *Venus LAOWA 60mm f/2.8 2:1* (Tablica 21)
    5.3 Kružna bljeskalica *Aperture AHL-HC100 Amaran Halo LED Ring Flash*
    5.4 Daljinski okidač
6. Lokalni koordinatni sustav (LCS[89])
    6.1 Utori za postavljanje LCS-a
    6.2 Otvor za testnu pločicu
    6.3 Digitalni šubler

[89] Local Coordinate System

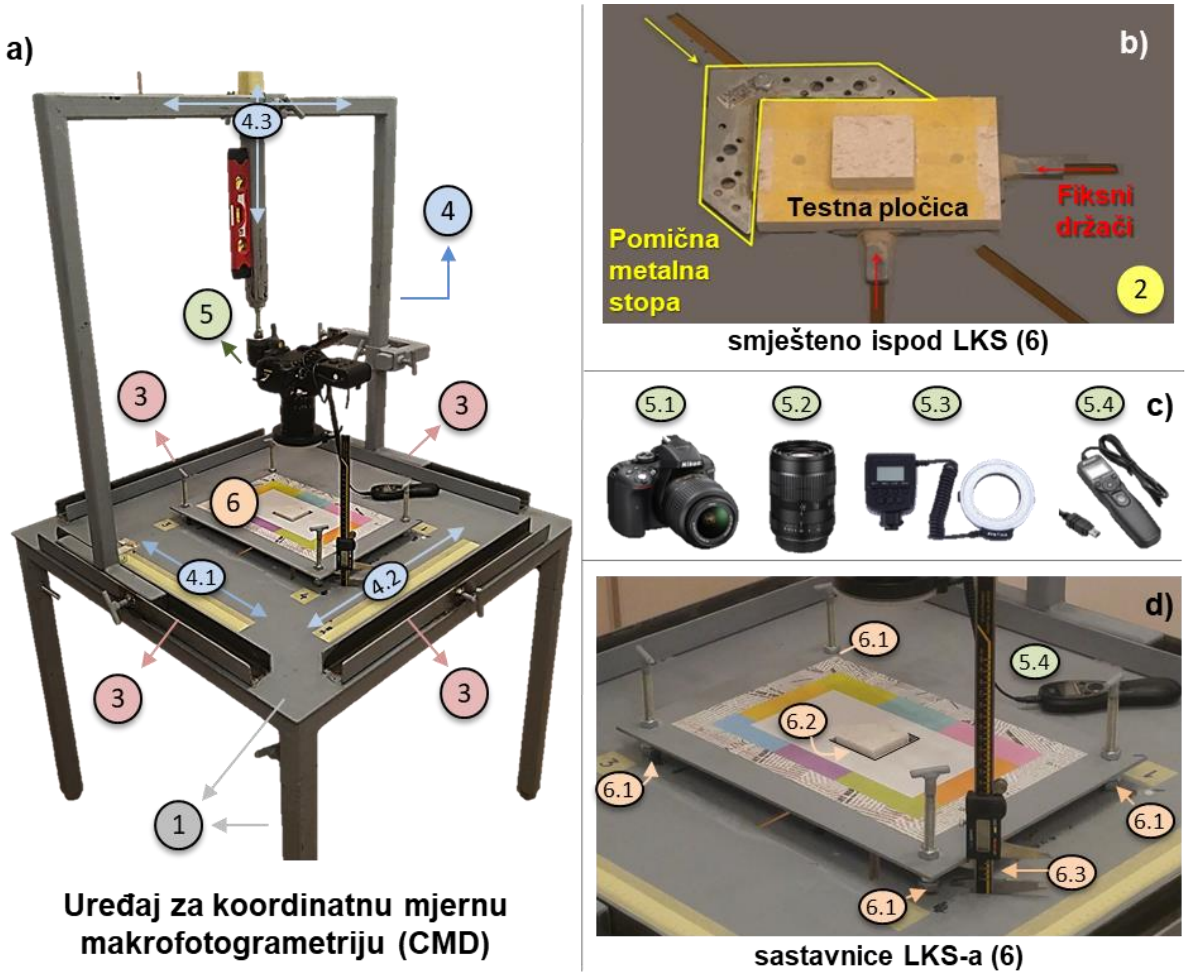

Slika 73. a) CMD sa svim sastavnicama b) pomična metalna stopa i držači koji fiksiraju pločicu te c) sastavnice LCS-a

Na postolje (1) je postavlja pomična metalna ploča s fiksnim držačima (Slika 73b) te profili za pomicanje mehaničkog okvira (3) (Slika 73a). Vapnenačka pločica na kojoj se prati dinamika sedrenja se na postolje učvrsti pomoći pomične metalne stope s fiksnim držačima. Time se pločica uvijek nalazi na istim koordinatama unutar LCS-a što omogućuje intervalno praćenje prirasta i erozije sedre prema specifičnim profilima i/ili uzorcima.

Pomični mehanički okvir (4) se horizontalno pomiče po X (4.1), Y (4.2) te horizontalno i vertikalno po Z (4.3) osi. Horizontalno pomicanje određuje uzdužno i poprečno preklapanje između fotografija, dok vertikalno određuje udaljenost sustava senzora od pločice. Time je omogućeno podešavanje odgovarajuće DoF. Poznavanjem udaljenosti senzora od pločice te geometrijskih obilježja kamere moguće je izračunati i) prostornu rezoluciju modela (GSD) sedre te ii) veličinu snimljenog kadra (eng. *footprint*) fotografije.

i) $$GSD = \frac{S_w \times D}{F_r \times imW} \quad (5)$$

gdje je:

S_w = širina digitalnog senzora kamere (mm)

D = udaljenost kamere od objekta snimanja (mm)

F_r = žarišna udaljenost objektiva (mm)

imW = širina slike (pikseli)

ii) $Dw = GSD \times imX, \quad Dh = GSD \times imH$ (6)

gdje je:

Dw = širina snimljene slike (mm)

Dh = visina snimljene slike (mm)

GSD = prostorna rezolucija

imW = širina slike (pikseli)

imH = visina slike (pikseli)

Iz veličine snimljenog kadra fotografije te željenog postotka uzdužnog i poprečnog preklapanja određuje se intervalno pomicanje mehaničkog okvira po X, Y i Z osi. Na postolju u predviđena četiri utora (6.1) postavljen je pomični LCS (6). Razvoj LCS-a omogućuje georeferenciranje modela početnog i intervalnih stanja te njihovu međusobnu usporedbu. Prije pravljenja fizičkog modela LCS-a koji je postavljen na CMD napravljen je njegov konceptualni i fizički model (Slika 74A-B) te je napravljena simulacija prirasta sedre (Slika 74C).

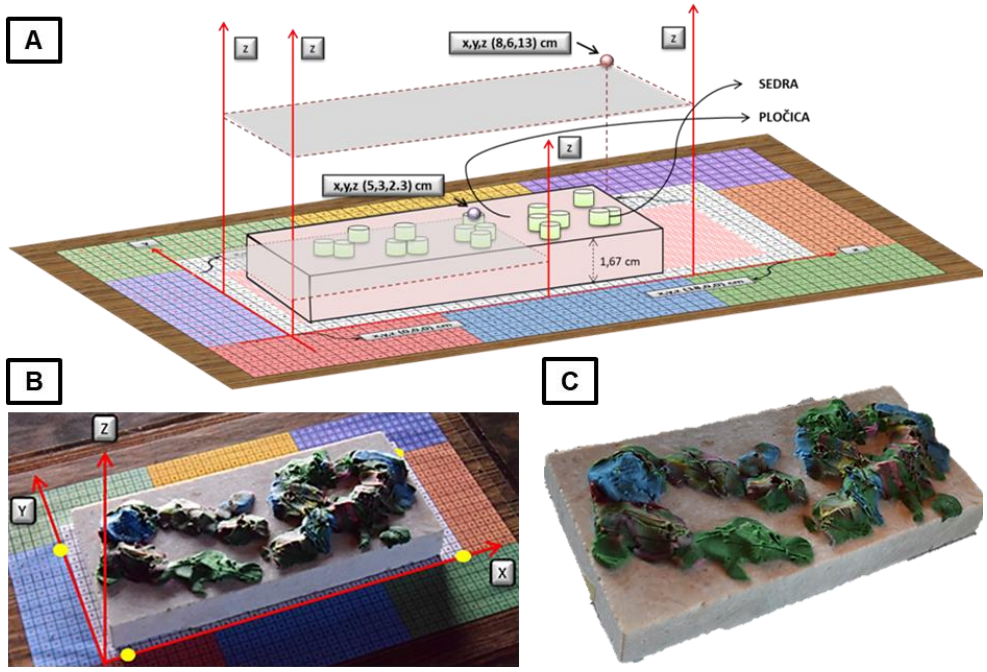

Slika 74. A) Konceptualni model i B) fizički model LCS-a te C) simuliranje prirasta sedre

Kvalitetan LCS je važna sastavnica procesa izvođenja blizupredmetne fotogrametrije. Osobito u ovom slučaju gdje se submilimetarski digitalni modeli primjenjuju u praćenju TFD-a. LCS može biti konstruiran na više načina ovisno o: stručnosti operatora, željenoj točnosti modela, istraživačkoj svrsi te dostupnoj tehnologiji. Uglavnom se dizajnira pomoću kodiranih oznaka (eng. *markers*) koji predstavljaju referentne točke za definiranje koordinatnog sustava i mjerila (Tushev i dr., 2017, Verma i Bourke, 2019). Koordinate oznaka mogu se odrediti različitim metodama: totalnom stanicom (Skarlatos i dr., 2019), koordinatografom velike točnosti (Barilar i dr., 2015), izravnim metodama mjerenja (DSM[90]) (Balletti i dr, 2015) itd. LCS je u obliku vektorske grafike izrađen u programu *CorelDRAW 2017* te tiskan pomoću tehnike sitotiska koja omogućuje visoku kvalitetu ispisa te jasne i oštre konture. U sredini ima otvor (6.2) kroz koju prolazi vapnenačka pločica za praćenje prirasta sedre (Slika 73d). Visina LCS-a za potrebe intervalnih usporedbi modela sedre je u svakom snimanju podešena na istu visinu pomoću digitalnog šublera (6.3) s preciznošću od 0,01 mm.

Na pomičnoj Z osi (4.3) mehaničkog okvira montiran je sustav senzora (5) za izvođenje procesa makrofotogrametrije. Prema najstrožoj definiciji makro-fotografija je vrsta snimanja u kojem veličina subjekta na senzoru slike odgovara stvarnoj veličini (1:1) ili je veća (Percoco i dr., 2015, Gajski i dr., 2016). Takvo mjerilo se može se postići koristeći produžne cijevi ili makro objektiv (Gajski i dr., 2016). Makro objektivi su posebno dizajnirani objektivi koji imaju mogućnost snimanja oštrih slika malih objekata s malih udaljenosti postižući veliku detaljnost prikaza (Yanagia i Chikatsu, 2010, Percoco i dr., 2015). Ovakve vrste mjerenja koriste se u istraživanjima koja zahtijevaju vrlo visoku razinu točnosti (Percoco i dr. 2017) te izvođenje visoko-preciznog 3D modela kvalitetne teksture (González i dr. 2015, Gajski i dr., 2016).

Tablica 19. Specifikacije *DSLR NIKON D5300*

Tip senzora	CMOS
Rezolucija (pikseli)	6016 X 4016
Foto detektori na senzoru	24,16
Veličina piksela na senzoru	0,00389 mm
ISO raspon	100 0 25600
Veličina senzora (mm)	15,6 x 23,5
Brzina zatvarača	1/4000 - 30
Težina (bez baterije)	480 g

[90] Direct Survey Method

Tablica 20. Specifikacije makro objektiva *Venus LAOWA 60mm*

Žarišna udaljenost	90 mm (35 mm Equiv. on DX Format)
Otvor blende (raspon)	f/2.8 do f/22
Raspon uvečanja	2,0x fo 0,1x
Raspon fokusa	2,4” do beskonačnosti
Kut pogleda	40º
Težina	800 g
Autofokus	Ne

Od pomoćnih elemenata u procesu snimanja je korišteni luminometar UT380, pomoću kojeg je intenzitet svjetlosti unutar ikone fokusa kamere održavan na konstantnoj razini (1500±20 lux) tijekom snimanja.

3.3.2 Kalibracija kamere

Točna kalibracija kamere je bitna sastavnica fotogrametrijskog mjerenja i preduvjet za visokokvalitetno generiranje metričkih podataka (Clarke i Fryer 1998). Prije izvođenja procesa rekonstrukcije točaka potrebno je poznavati i odrediti parametre unutarnje (IO[91]) i vanjske orijentacije (EO[92]) te koordinate točke u objektnom prostoru (Jurjević, 2017). Prije snimanja pločica izvršena je kalibracija kamere pomoću softvera *Agisoft Lens* koji ima implementiran algoritam za detekciju točaka na šahovskoj ploči. Kalibraciju kamere vrši skupnim izjednačenjem zrakovnih snopova (eng. *bundle block adjustment*) (Jurjević, 2017). 2D šahovsko polje je kreirano u programu CorelDRAW, isprintano tehnikom sitotiska s veličinom individualnog kvadrata od 5 mm. Binarizirana slika šahovskog polja je pričvršćena na ravnu površinu LCS-a. Kalibracija kamere je obavljena nad skupom od trideset fotografija snimljenih po različitim orijentacijama i rotacijama kamere, ali nad istom udaljenosti od senzora. Distorzija fotoaparata određena je pomoću Brownovog modela distorzije (Brown, 1971). U tablici 22 navedeni su unutarnji orijentacijski parametri kamere.

[91] Interior Orientation
[92] Exterior Orientation

Tablica 21. Unutarnji orijentacijski parametri kamere

Žarišna udaljenost (f_y)	20069,69863
Glavna točka (c_x)	-5,91249
Glavna točka (c_y)	2,67424
Zakošenost piksela (b_2)	0,48115
Radijalna distorzija (k_1)	0,69753
Radijalna distorzija (k_2)	1,68146
Tangencijalna distorzija (p_1)	0,00025
Tangencijalna distorzija (p_2)	0,00046

Kalibracijom kamere je utvrđena kalibrirana žarišna udaljenost u pikselima koja pomnožena s veličinom piksela na digitalnom senzoru (0,00389) daje vrijednost od 78,07 mm. Određeno je odstupanje perspektivnog centra ili glavne točke (c_x, c_y) kamere u odnosu na slikovni koordinatni sustav u pikselima. Uz navedene, parametri unutarnje orijentacije su prošireni s pogreškama preslikavanja (radijalna $k_{1\text{-}2}$ i tangencijalna $p_{1\text{-}2}$ distorzija te zakošenost ili nejednakost stranica piksela b_2). Dobiveni rezultat je potom eksportiran u formatu čitljivom softveru *Agisoft Metashape 1.5.1* te je obrada fotografija izvršena tako da su parametri unutarnje orijentacije ostali fiksirani tijekom cijelog procesa.

3.3.3 Utvrđivanje kvalitete mjerenja s CMD-om

Izmjerena vrijednost je uvijek aproksimacija stvarnosti, bez obzira na točnost i preciznost mjernog uređaja. Rezultat mjerenja može se smatrati potpunim samo ako su mu pridružene vrijednosti mjerenja nesigurnosti (Mellenbergh, 2019). Preciznost je mjera koja opisuje pouzdanost i ponovljivost mjerenja, a predstavlja statističke fluktuacije u obliku raspršenih mjernih vrijednosti. Točnost se definira kao blizina izmjerene ili procijenjene vrijednosti nekoj referentnoj, odnosno *stvarnoj* vrijednosti (Eltner i dr., 2016). Mjerenja koja su precizna i točna su kvalitetna. Točnost i preciznost su slični samo u činjenici da se odnose na kvalitetu, ali imaju vrlo različite pokazatelje mjerenja.

Točnost i preciznost mjerenja ispitivana je prema odabranim i fiksiranim postavkama snimanja pločica. Pri visini sustava senzora od 23,4 cm od LCS-a te odabranim postavkama kamere (pogledaj poglavlje 3.3.7). Utvrđena točnost i preciznost CMD u radu može biti bolja ili lošija ovisno o udaljenosti sustava senzora od LCS-a. Postavljanjem sustava senzora na veću udaljenost generirat će se lošija prostorna rezolucija i detaljnost modela. Takav model će biti manje točan jer jedan piksel (uzorak) generalizira veće područje sedre na pločici. Nižom

visinom i pravilnim odabirom postavki kamere postići će se bolja prostorna rezolucija i detaljnost, a time i točnost modela.

Točnost CMD-a je prikazana kroz nekoliko pokazatelja. U prvoj fazi procesa ispitivanja točnosti, kroz dodavanje CP-a (P01-P04) s poznatim X, Y i Z vrijednostima, ispitana je točnost kreiranog LCS-a. CP su dodane u pet različitih projekata: referentni model PL03, PL13 nakon 3 mjeseca, PL15 nakon 6 mjeseci, PL25 nakon 9 mjeseci te PL29 nakon godine dana. Uloga dodanih točaka je provjera relativne točnosti kreiranog modela, odnosno točnosti samog LCS-a koji je služio za orijentaciju. Točnost mjerenja je izražena s dvije statističke varijable: srednjom kvadratnom pogreškom RMSE[93] i srednjom apsolutnom pogreškom MAE[94] GCP-a i CP-a u referentnom LCS-u. Pogreška CP-a je izračunata kao razlika između izvorne (eng. *source*) (stvarna vrijednost točke u LCS-u) te procijenjene (eng. *estimated*) vrijednosti točke u modelu. RMSE je statistička metrika koja se vrlo često koristi kao mjera za ispitivanje kvalitete površine modela (Smith i Vericat, 2015), dok je MAE prirodna i usporediva mjera performanse modela te indikacije neusmjerenih pogrešaka (Smith i Vericat, 2015).

U drugoj fazi ispitana je apsolutna točnost CMD-a usporedbom izmjerenih vrijednosti volumena (mm^3) odabrane pločice s vrijednostima referentnog stanja koje je generirano mjerenjima *Artec Evom* i *Space Spiderom*. *Eva* i *Spider* su *state-of-art* 3D projekcijski ručni skeneri sa službenom 3D točnošću točaka od 0,1 mm i 0,05 mm (Artec 3D, 2019) (Slika 75). Volumen pločice je izračunat iznad specifične plohe od LCS-a na visini od 2 mm. Volumen pločice je izračunat u softveru *Artec Studio* iz 3D modela pločice u *.obj* formatu. Točnost CMD-a je izražena kroz apsolutnu i postotnu pogrešku. Apsolutna pogreška (A_{er}) je izračunata kao razlika između referentne (volumen generiran *Space Spiderom*) i izmjerene vrijednosti (volumen generiran CMD-om).

$$A_{er} = stvarna\ vrijednost - izmjerena\ vrijednost$$

Postotna pogreška (P_{er}) je izražena kao postotak razlike između izmjerene i referentne vrijednosti. Postotna pogreška je izražena kao pozitivna vrijednost prema formuli:

$$P_{er} = \frac{|Ar|}{stvarna\ vrijednost} \times 100 \quad (7)$$

gdje je:

P_{er} = postotak pogreške

stvarna vrijednost = volumen PL izmjeren *Artec Evom* i *Space Spiderom*

[93] Root Mean Square Error
[94] Mean Absoulte Error

izmjerena vrijednost = volumen PL izmjeren CMD-om

Iako su *Eva* i *Space Spider* visokokvalitetni 3D skeneri, njihova je primjena u mjerenju stopa prirasta i erozije sedre ograničena zbog činjenice da nemaju fiksni lokalni koordinatni sustav što otežava intervalnu usporedbu generiranih 3D modela.

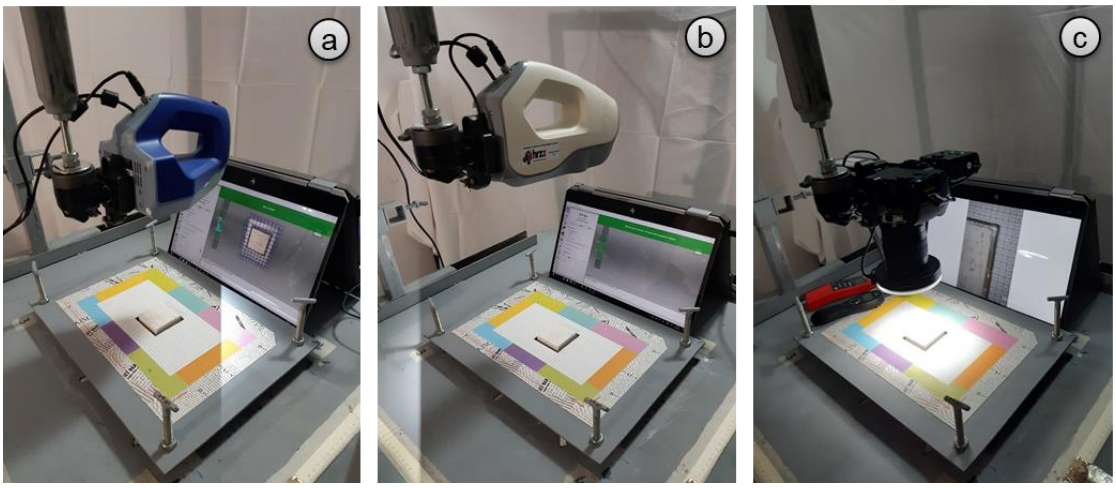

Slika 75. Snimanje pločice s a) *Spiderom*, b) *Evom* i c) CMD-om
(svi uređaji su preko navoja spojeni na mehanički okvir)

Preciznost mjerenja CMD-om je određena metodom *split* testova na temelju pet intervalnih mjerenja iste pločice izvedenim na različite datume. Cilj *split* testova je generiranje više skupova podataka (modela) istog objekta ili scene služeći se istim metodološkim pristupom prilikom prikupljanja i obrade podataka. Mjerenje objekta ili scene se mogu izvršiti na različite datume, a osnovni cilj je ispitivanje ponovljivosti (preciznosti) mjerenja (James i dr., 2019). Prije svakog mjerenja CMD je rastavljen, sastavljen te je pločica ponovno fiksirana na postelje. Visina LCS-a u svakom intervalnom mjerenju je na istu visinu nanovo postavljena s digitalnim šublerom. Točnost određivanja visine LCS-a s digitalnim šublerom utječe na preciznost Z koordinate dok fiksiranje pločice pomoću metalne stope utječe na preciznost X i Y koordinata.

Proces prikupljanja i obrade fotografija za svih pet mjerenja je bio isti (*poglavlje 3.3.7*). Potom je na svakom DOF-u označeno istih 70 uzoraka. Idealno, označeni uzorci bi se trebali nalaziti na istoj X, Y i Z koordinati s obzirom na to da je visina LCS-a uvijek postavljana na istu vrijednosti te da je pločica fiksirana pomoću pomične metalne stope. Ovim procesom se utvrđuje koja je pouzdanost mjerenja, odnosno intervalno odstupanje prema X, Y i Z osi. Na temelju tih odstupanja izračunat će se horizontalna i vertikalna preciznost mjernog uređaja. Na slici 76. ilustriran je proces izračuna preciznosti CMD-a.

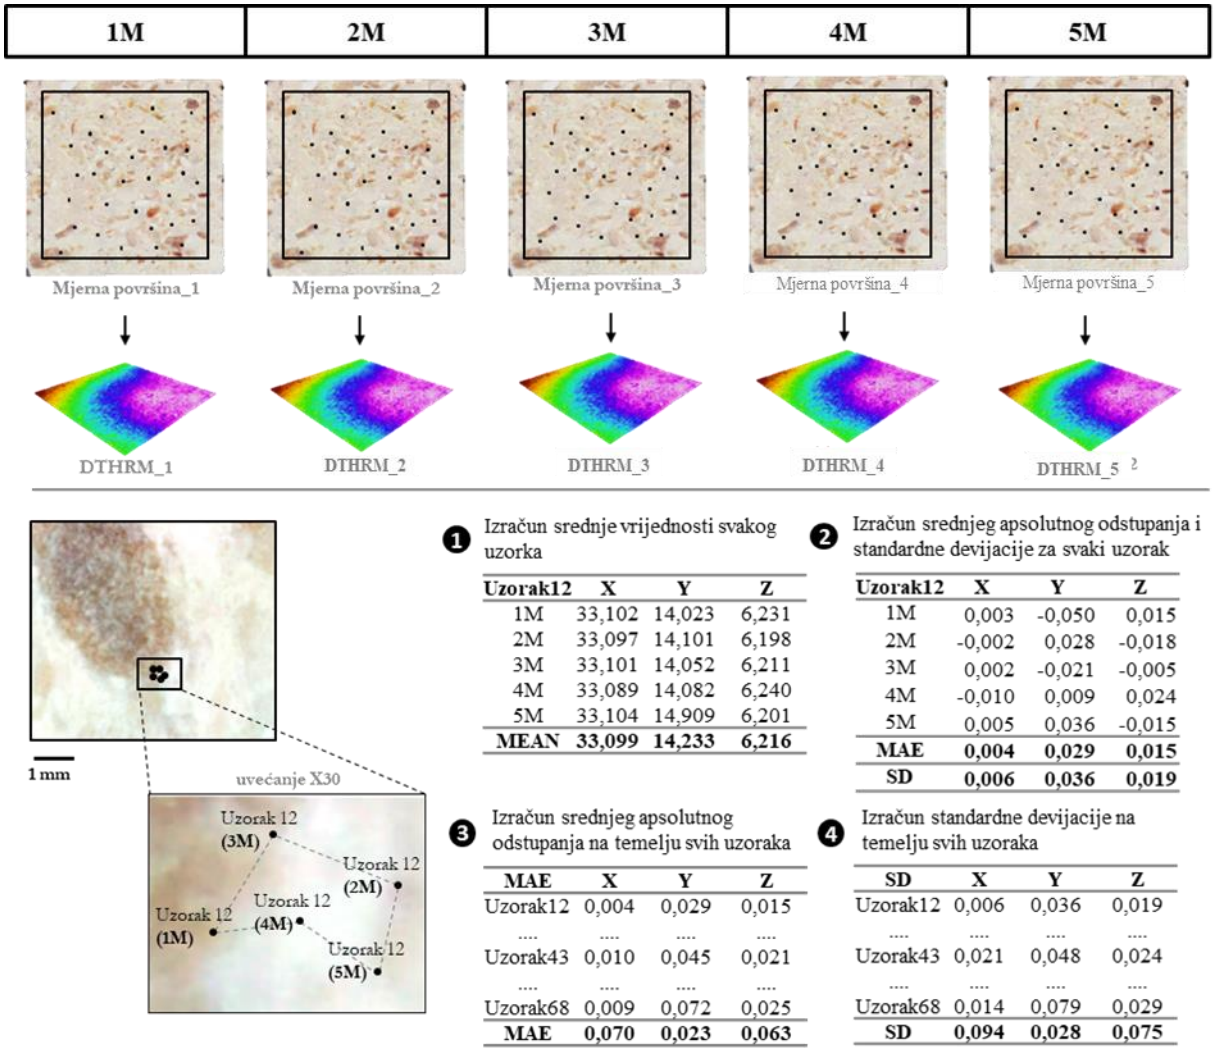

Uzorak12	X	Y	Z
1M	33,102	14,023	6,231
2M	33,097	14,101	6,198
3M	33,101	14,052	6,211
4M	33,089	14,082	6,240
5M	33,104	14,909	6,201
MEAN	**33,099**	**14,233**	**6,216**

Uzorak12	X	Y	Z
1M	0,003	-0,050	0,015
2M	-0,002	0,028	-0,018
3M	0,002	-0,021	-0,005
4M	-0,010	0,009	0,024
5M	0,005	0,036	-0,015
MAE	**0,004**	**0,029**	**0,015**
SD	**0,006**	**0,036**	**0,019**

MAE	X	Y	Z
Uzorak12	0,004	0,029	0,015
....	....	....	....
Uzorak43	0,010	0,045	0,021
....	....	....	....
Uzorak68	0,009	0,072	0,025
MAE	**0,070**	**0,023**	**0,063**

SD	X	Y	Z
Uzorak12	0,006	0,036	0,019
....	....	....	....
Uzorak43	0,021	0,048	0,024
....	....	....	....
Uzorak68	0,014	0,079	0,029
SD	**0,094**	**0,028**	**0,075**

Slika 76. Shematski prikaz izračuna preciznosti mjerenja CMD-om

X, Y i Z vrijednosti svakog uzorka su izvučene iz DSM-a koristeći alat *Extract Values to Points* u ArcMap 10.1 programu. Preciznost uređaja izražena je kroz statističku metriku standardna devijacija (SD) koja se često koristi prilikom utvrđivanja kvalitete površine modela (Smith i Vericat, 2015) te srednju apsolutnu pogrešku (MAE). To su najpopularnije metrike za izračun varijabilnosti skupova podataka (Kalla, 2009). Iako su relativno slične, izračun i interpretacija im se razlikuju. SD je najpopularnija mjera varijabilnosti čiji se izračun temelji na udaljenosti od srednjaka, a opisuje raspršenost podataka u skupu mjerenja. Interpretira se kao prosječno odstupanje od srednjaka u apsolutnom iznosu. Na nju izrazito utječu grube pogreške (eng. *outliers*), odnosno ekstremno visoke ili niske vrijednosti u odnosu na srednjak. U pravilu je uvijek viša od MAE-a. Mala SD znači da su vrijednosti uzorka vrlo blizu izračunatom srednjaku, odnosno da je mala raspršenost vrijednosti u uzorku. Manja SD znači manju nesigurnost, odnosno veću pouzdanost u eksperiment. Velika SD znači da su vrijednosti u skupu podataka udaljenije od prosjeka, odnosno da je velika raspršenost vrijednosti u uzorku,

što znači da je mjerenje nesigurnije/nepouzdanije. SD nikad ne može biti manja od nula te se uvijek izražava u jedinici mjerenja. U normalnoj (Gaussovoj) distribuciji, vrijednosti uzoraka koje padaju 68,2% od srednjaka se nalaze unutar jednog standardnog odstupanja. Primjerice, ako je prosječna procijenjena vrijednost X koordinate na temelju 70 uzoraka 32,14 mm, a SD za X os iznosi 0,071 mm, pretpostavlja se da će 48 uzoraka (68,2% uzoraka) imati izmjerenu X koordinatu unutar vrijednosti od 32,069 mm (32,14 - 0,071) do 32,211 mm (32,14 + 0,071).

U nastavku je opisan proces izračuna MAE-a koji se sastoji od nekoliko koraka. U prvom koraku izračunata je iii) srednja vrijednost X, Y i Z koordinate za svaki uzorak (n=70) unutar pet mjerenja.

iii. $\bar{x} = \frac{1}{n}(x_1 + x_2 + \ldots x_n)$ (6)

gdje je:

$\bar{x}$ = srednja vrijednost uzorka (npr. točka 1)

n = broj mjerenja (n=5)

x_n = vrijednost pojedinog uzorka (npr. 7,4932 mm)

Primjerice, uzorak 01 ima vrijednosti za X koordinatu: 1M[95] (36,858), 2M (36,897), 3M (37,121), 4M (36,986) te 5M (36,936 mm). Srednja vrijednost X koordinate za uzorak 01 iznosi 36,960 mm. Izračun je proveden za sve ostale uzorke te Y i Z koordinatu. Potom je izračunato apsolutno odstupanje (AD[96]) izmjerenih X, Y i Z vrijednosti svakog uzorka (n=70) u pojedinom mjerenju (n=5) od utvrđenih srednjih vrijednosti X, Y i Z koordinata. Korištena je *Excel* funkcija =*abs*(C4“izmjereno“ - „R4“average). Funkcija *abs* negativne vrijednosti pretvara u pozitivne, čime se prilikom izračuna MAD-a sprječava poništavanje negativnih i pozitivnih pogrešaka. Na navedenom primjeru AD od izračunatog srednjaka X koordinate za uzorak 01 iznosi: 1M (0,102), 2M (0,063), 3M (0,162), 4M (0,027) te za 5M (0,024). Isti izračun je napravljen za sve ostale uzorke (n=70) te Y i Z koordinatu. Potom je izračunat MAE za X, Y i Z koordinate pojedinog uzorka koristeći formulu:

iv. $M_{AD} = \frac{1}{n}\sum_{i=n}^{n}|x_1 - \bar{x}|$ (7)

gdje je:

M_{AD} = srednje apsolutno odstupanje

n = broj uzoraka

x_n = vrijednost uzorka

[95] Prvo mjerenje
[96] Apsolute Deviation

$\bar{x}$ = srednja vrijednost uzorka

Nastavljajući se na navedeni primjer MAE za koordinatu X uzorka 01 iznosi 0,076 mm (0,102 + 0,063 + 0,162 + 0,027 +0,024 / 5 mjerenja). Nadalje, za koordinatu Y i Z iznosi 0,018 te 0,063. Isti izračun je napravljen za sve ostale uzorke (n=70) te X, Y i Z koordinate. U konačnici je preciznost CMD uređaja reprezentirana kao srednjak MAE-a svih uzoraka (n=70) za pojedinu X, Y i Z koordinatu. Nadalje, preciznost mjerenja CMD-om je reprezentirana standardnom devijacijom. SD je navedena za X, Y i Z koordinatu, a izračunata je sljedećim postupkom:

1. Izračunata je srednja vrijednost X, Y i Z koordinata za sve uzorke (n=70). Primjerice, uzorak 01 iz pet mjerenja ima srednju vrijednost koordinate (X) 36,96 mm. Izračun je proveden za sve ostale uzorke (n=70) te Y i Z koordinatu.

2. Potom je izračunat AD, odnosno oduzeta je vrijednost X, Y i Z koordinata svih uzoraka (n=70) u svim mjerenjima (n=5) od srednje vrijednosti X, Y i Z koordinata izračunatim u prvom koraku. Time je dobiveno AD vrijednosti koordinata svih uzoraka od srednjaka dobivenih na temelju pet mjerenja. Primjerice, AD X koordinate uzorka 01 u prvom iznosi -0,102 mm (36,858 - 36,960) dok je u drugom mjerenju -0,063 itd. Ovaj proces je izveden za X, Y i Z koordinate svih uzoraka (n=70) u svakom mjerenju (n=5).

3. Nakon toga je za X, Y i Z koordinatu svakog uzorka izračunata SD koristeći *Exel* funkciju =*stdev*. Primjerice SD za X koordinatu uzorka 01 iznosi 0,102. Izračunata je koristeći formulu =stdev(-0,102, -0,063, 0,162, 0,027, -0,024). U zagradama se nalaze apsolutna odstupanja X koordinate uzorka 01 od izračunatog srednjaka. Izračun je proveden za sve ostale uzorke (n=70) te Y i Z koordinatu. Time je za svaki uzorak, od 01 do 70, definirana SD za X, Y i Z koordinatu. Primjerice, SD uzorka 01 za x koordinatu iznosi 0,102 za y 0,023, a za z 0,074 mm.

4. U konačnici preciznost CMD-a je reprezentirana kao prosječna SD za X, Y i Z koordinatu pojedinačnih SD-a svakog uzorka (n=70).

U procesu određivanja kvalitete mjerenja CMD-om izračunata je i relativna nesigurnost mjerenja na temelju pet snimanja iste pločice. Relativna nesigurnost (R_{un}) ili relativna pogreška se koristi za izračun nesigurnosti mjerenja u odnosu na veličinu mjerenja. Veći postotak predstavlja veću mjernu nesigurnost. Izračunava se kao omjer apsolutne nesigurnosti i najbolje procjene mjerenja. Važnost relativne nesigurnosti se očituje u tome što stavlja pogrešku mjerenja u perspektivu. U odnosu na apsolutnu nesigurnost koja se iskazuje u istoj jedinici kao

i mjerenje (npr. mm) te daje raspon unutar kojeg leži istinska vrijednost (npr. X koordinata = 12,3±0,074 mm) relativna pogreška se izražava kao postotak:

$$\text{v. } R_{un} = \frac{\text{RANGE} \times 100\%}{\bar{x}} \quad (8)$$

gdje je:

R_{un} = relativna nesigurnost (%)

RANGE = raspon mjerenja za pojedini uzorak (npr. uzorak 01 = raspon 0,087 mm)

$\bar{x}$ = srednja vrijednost pojedinog uzorka (npr. uzorak 01 = 13,21 mm)

U navedenoj formuli raspon (RANGE) se koristi umjesto apsolutne nesigurnosti jer ona nije poznata. Da bi se apsolutna nesigurnost sa sigurnošću mogla utvrditi potrebno je vrijednosti (X, Y i Z) označenih uzoraka (n=70) izmjeriti s tehnologijom (ručni laserski skeneri, triangulacijski laserski skeneri, skeneri na principu strukturiranog svjetla itd.) koja prema specifikacijama ima znatno bolju horizontalnu i vertikalnu točnost od CMD uređaja ili metode makrofotogrametrije. Usporedbom X, Y i Z vrijednosti uzoraka dobivenih tom tehnologijom i CMD-om dobila bi se apsolutna nesigurnost koja bi bila reprezentirana rasponom vrijednosti (npr. ±0,05) za sve koordinate. Međutim, s obzirom na to da je označavanje uzoraka (n=70) na modelu bilo uvjetovano specifičnostima teksture pločice, a napredni ručni projekcijski skeneri koji su testirani u radu nemaju mogućnost prikupljanja tako kvalitetne teksture te fiksni LCS, korištenje parametra apsolutne nesigurnosti nije bilo moguće. Stoga je u nazivniku kao najbolja procjena vrijednosti nekog uzorka uzeta njegova srednja izmjerena vrijednost ($\bar{x}$). Prihvatljivost postotka relativne nesigurnosti ovisi o primjeni samog modela. Generalno se smatra da kad je relativna nesigurnost niža od 5% mjerenje je pouzdano i ponovljivo.

3.3.4 Odabir vrste pločica za praćenje dinamike formiranja sedre

Terenskim istraživanjem na testnoj plohi 05. rujna 2017. analizirane su potencijalne lokacije za postavljanje pločice. S obzirom na širinu aktivnih i reaktiviranih tokova te vrstu podloga koja u njima prevladava zaključeno je da bi idealna dimenzija pločica trebala iznositi 10X15 cm. Veličina pločice je smanjena od prvotnih dimenzija 10X20 cm zbog poteškoća koje bi se javile prilikom stavljanja i učvršćivanja pločica unutar manjih tokova. Razlog tome je mala širina tokova, mekoća podloge i činjenica da bi se na svaku od predloženih lokacija trebalo učvrstiti minimalno po dvije pločice, za što na pojedinim lokacijama jednostavno ne bi bilo dovoljno prostora.

U procesu odabira vrste pločica na kojima će se pratiti dinamika formiranja sedre, testirano pet je različitih vrsta (biano kristal, plano, bračko veselje, sabia i roso porrino) svaka sa specifičnim površinskim uzorcima (Slika 77).

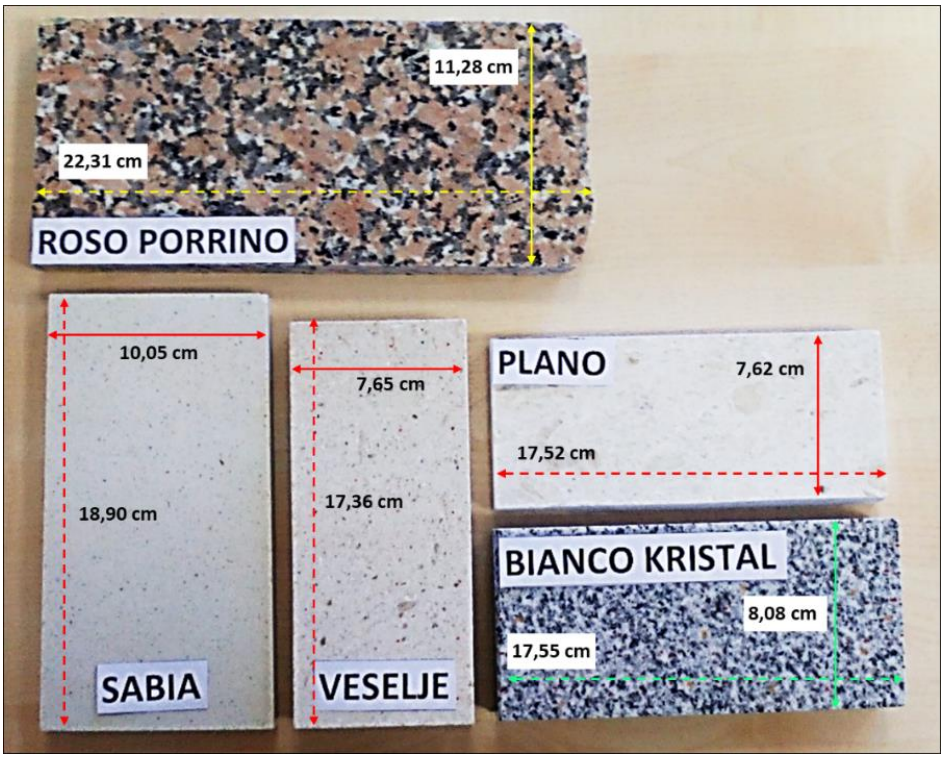

Slika 77. Testirane vrste pločica za potrebe praćenja TFD-a

Uvažavajući sastav i površine uzorke na pločicama odabran je optimalan tip - plano (Slika 78). Površinska tekstura mu nije homogena, a osnovno obilježja su: gustoća (2,69 g/cbm), poroznost (3,81%), upijanje vode (0,97%), čvrstoća na pritisak (123 Mpa), čvrstoća na savijanje (13 Mpa), otpornost na habanje (23,5 $g^3/50cm^2$) (URL 53).

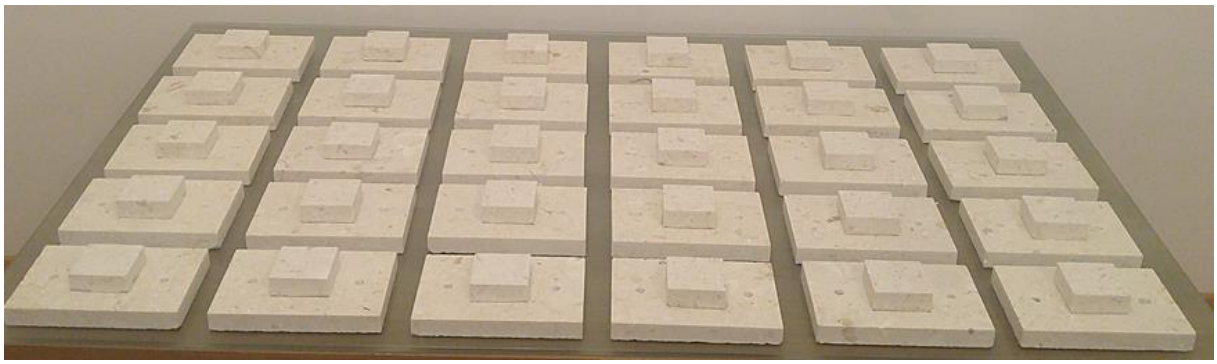

Slika 78. Pločice plano postavljene na odabranu testnu plohu

Dinamika formiranja sedre je praćena izravnim, intervalnim mjerenjem na 28 pločica. Predložen je novi dizajn pločice. Testna (vapnenačka) pločica je sačinjene od dva dijela. A) Baznu (glavnu) pločicu predstavlja postolje debljine 18 mm s dimenzijama (150 x 100 mm).

Na sebi ima dvije rupe predviđene za vijke od neoksidirajućeg čelika koji su osigurani maticama i s njima se pločica pričvršćuje u podlogu. S bazne plohe se prikupljaju uzorci sedre za potrebe kemijskih analiza. Na nju je pričvršćena B) manja pločica iste debljine, dimenzija 50x50 mm na čijoj je mjernoj plohi (MS[97]) efektivne površine 16 cm² (Slika 79) praćena dinamika formiranja sedre.

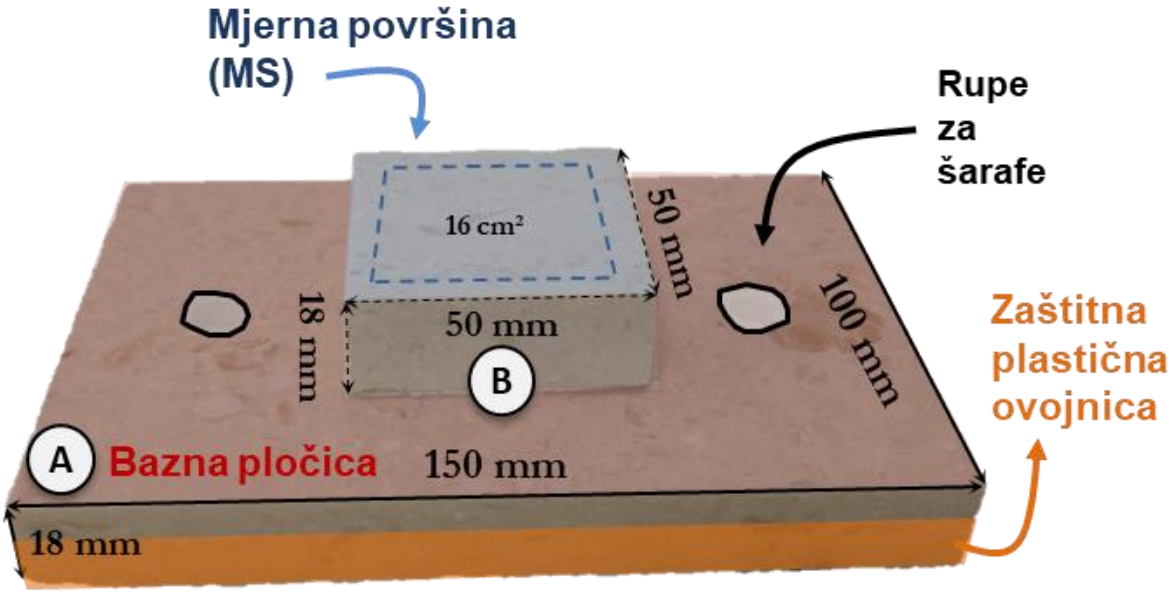

Slika 79. Dizajn vapnenačke pločice za praćenje TFD-a

Ispod podnožja bazne pločice postavljen je zaštitni plastični omotač kako bi se spriječila precipitacija sedre i olakšalo postavljanje pločice na postolje CMD-a (Slika 80).

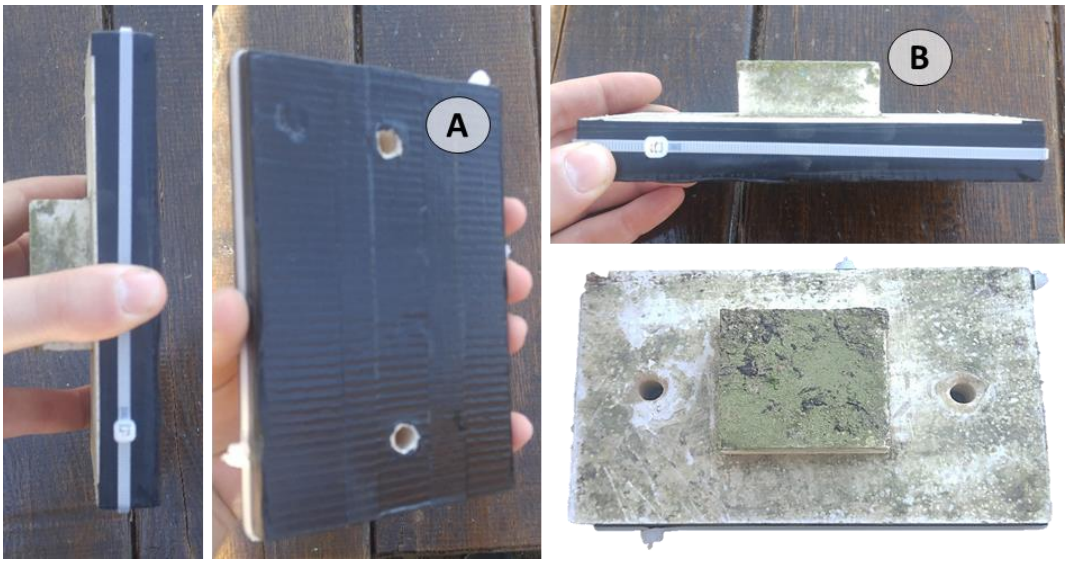

Slika 80. Zaštitni plastični omotač koji sprječava nastanak sedre na podnožju bazne pločice

[97] Measuring Surface

3.3.5 Postavljanje i snimanje testnih pločica (testna ploha SB)

Pločice (n=28) su postavljene na 14 lokacija unutar odabrane plohe u blizini Marasovića (Slika 86-99). U tokove različitih fluvijalnih okruženja pričvršćene su s dva neoksidirajuća vijka i osigurane s maticama. Za potrebe praćenja sezonskih promjena, utjecaja frekvencije vađenja te mikrolokacijskih uvjeta na dinamiku formiranja sedre, na svaku lokaciju su postavljene po dvije pločice na udaljenosti manjoj od 30 cm. Lokacije postavljanja pločica prikupljene su *RTK-GPS-om Stonex S10* (Slika 81).

Slika 81. Prikupljanje lokacija pločica RTK-GPS-om

Lokacije su odabrane tako da zadovoljavaju nekoliko kriterija. Prvi se odnosi na stabilnost, odnosno čvrstoću podloge s ciljem smanjenja opasnosti od nestanka ili mogućeg skidanja pločice. Naime, gubitak testnih uzoraka vrlo je čest problem u istraživanjima dinamike formiranja sedre. Nakon pronalaska dovoljno čvrste podloge, utvrđeno je ima li dovoljno prostora za instaliranje dvije pločice po relativno sličnim osima. Treći kriterij se odnosio na

činjenicu da se htjela provjeriti dinamika sedrenja u reaktiviranim tokovima, tako da je jedan dio pločica postavljen na te lokacije. Nadalje, pločice su se postavile u različita fluvijalna okruženja kako bi se mogle odraditi razlike u dinamici sedrenja s obzirom na specifičnost mikrookruženja (Slika 82).

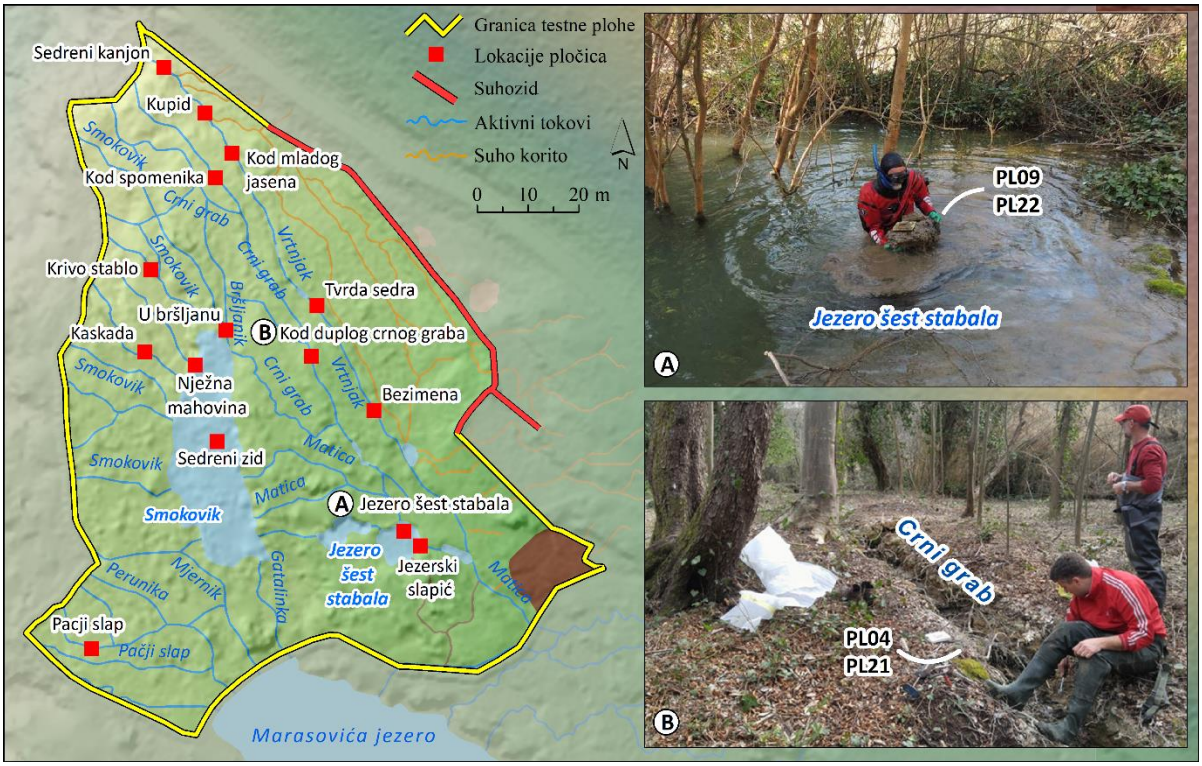

Slika 82. Lokacije postavljanja pločica na testnoj plohi SB

Do konačnog dizajna pločice predloženog u istraživanju došlo se postupno, nakon provjere testne lokacije *Kupid*. Naime, prije postavljanja svih pločica (n=28), 14. veljače, 2018. postavljena je jedna testna pločica na lokaciju *Kupid* u tok Vrtnjak, između lokacije S*edreni kanjon* i *Kod mladog jasena*. Na pločici *Kupid* dinamika formiranja sedre nije mjerena. Ona je poslužila za inicijalnu provjeru predloženog načina instalacije pločica u tok i njihove stabilnosti. Odmah nakon postavljanja uvidjelo se da vijci koji strše iznad mjerne površine pločice (MS) znatno mijenjaju mikrofluvijalne uvjete kroz stvaranje turbulencije vode. Nadalje, dva tjedna nakon postavljanja uočeno je da su vijci i matice te donja podloga bazne pločice u potpunosti obloženi tanki slojem sedre. Time je proces vađenja za potrebe intervalnih mjerenja te montiranje na postolje CMD-a izrazito otežan. S ciljem rješavanja uočenih problema, na svim drugim lokacijama vijci su postavljeni tako da ne vire iznad mjerne površine pločice (MS) te su na njih i matice postavljene bijele plastične kapice (Slika 83) kako bi se priječio nastanak sedrenog omotača. Donja podloga bazne pločice obložena je zaštitnim plastičnim omotačem.

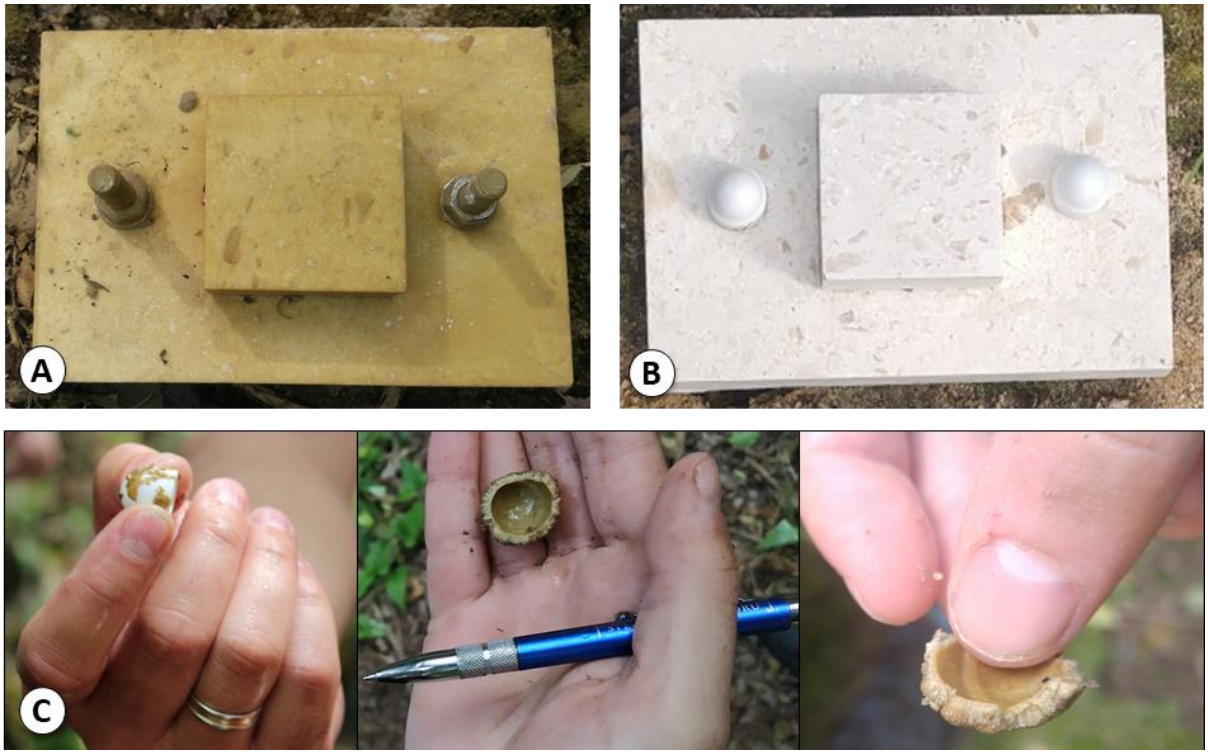

Slika 83. A) Nedostatci na testnoj pločici Kupid B) novi dizajn pločice s kapicama te C) sedre nastala na kapicama tijekom intervalnih vađenja

U nastavku je dan kratak opis značajki lokacije i položaja susjednih pločica. Prva lokacija je *Bezimena*. PL03 i 16 su postavljene tako da tok udara u kraću stranicu pločica. Postavljene u tok *Vrtnjak* koji je prije selektivnog uklanjanja vegetacije bio neaktivan. Nalazi se uzvodno od *Sedrenog kanjona*, *Kupida*, *Kod mladog jasena* i *Tvrde sedre*. Tok je nešto širi, nije usječen kao (*Tvrda sedra*, *Kod duplog crnog graba* i *Sedreni kanjon*). PL16 postavljena je pod nešto većim longitudinalnim nagibom (Slika 84). Pločice su u potpunosti uronjene u vode, ali na maloj dubini ovisno o vodostaju, stoga postoji mogućnost da su kroz ljetna razdoblja periodično bila na suhome. U blizini pločica nije vidljiva veća količine makrofita i mahovina. Prema podjeli fluvijalnog okruženja lokacija je klasificirana u srednje brzi tok (MFW).

Slika 84. PL 03 i 16 na lokaciji *Bezimena*

Na lokaciju *Tvrda sedre* PL02 i 13 su postavljene tako da tok udara u kraću stranicu pločica. Postavljene u tok *Vrtnjak* koji je prije selektivnog uklanjanja vegetacije bio neaktivan. Nalazi se uzvodno od *Sedrenog kao* na lokaciji *Bezimena*. Usječen je, sličan lokaciji *Kod duplog crnog graba.* Pločice imaju sličan nagib po lateralnoj osi (Slika 85). Od samog postavljanja pločice se nalaze ispod vode na većoj dubini (> 20 cm) u odnosu na lokaciju *Bezimena*. Lokaciju obilježava izrazita turbulencija vode. U blizini pločica nema vidljive veće količine makrofita i mahovina. Prema podjeli fluvijalnog okruženja lokacija je klasificirana kao izrazito brzi tok (FFW).

Slika 85. PL02 i 13 pločice na lokaciji *Tvrda sedra*

Na lokaciju *Sedreni kanjon* PL11 i 27 su postavljene tako da tok udara u njihovu kraću stranicu (Slika 86). Nalaze se u toku *Vrtnjak* koji je prije selektivnog uklanjanja vegetacije bio neaktivan, nizvodno od *Kupida, Kod mladog jasena, Tvrde sedre* i *Bezimene*. Na ovoj lokaciji tok nije širok kao kod *Bezimene*. Usječen je, sličan lokaciji *Tvrda sedra,* kanjonskog oblika. U njemu su pločice postavljene na bočne strane, a ne na dno toka. Imaju sličan nagib po svim osima. Lokacija je smješten ispod stabla zbog čega je prodor svjetlosti nešto slabiji. Obilježava ju izrazita turbulencija vode. Pločice nisu u potpunosti uronjene u vodu već se nalaze u zoni prskanja (izrazita turbulencija vode) čiji je intenzitet određen snagom protoka. Postoji mogućnost da su tijekom ljetnog razdoblja periodično bila na suhome, osobito PL11 koja je neznatno izdignutija u odnosu na susjednu PL27. U blizini nema vidljive veće količine makrofita i mahovina. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao zona prskanja (SZ).

Slika 86. PL11 i 27 na lokaciji *Sedreni kanjon*

Na lokaciju *Kod mladog jasena* PL10 i 12 su postavljene tako da tok udara u njihovu kraću stranicu (Slika 87). Nalaze se u toku *Vrtnjak* koji je prije selektivnog uklanjanja vegetacije bio neaktivan, nizvodno od *Tvrde sedre* i *Bezimene*, a uzvodno od *Kupida* i *Sedrenog kanjona*. Tok na ovoj lokaciji nije širok kao u *Bezimene*, ali ni usječen kao kod *Tvrde sedre* i *Sedrenog kanjona*. Pločice su postavljene na dno toka te imaju sličan nagib po svim osima. Lokacija je smještena ispod stabla zbog čega je prodor svjetlosti nešto slabiji. Obilježava ju umjerena turbulencija vode (veća od *Bezimene*, ali slabija u odnosu na *Sedreni kanjon*) te brz protok vode. U blizini nema vidljive veće količine makrofita i mahovina. Pločice su uronjene u vode, ali se nalaze na maloj dubini. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao izrazito brzi tok (FFW).

Slika 87. PL 10 i 12 na lokaciji *Kod mladog Jasena*

Na lokaciju *Kod spomenika* PL19 i 24 su postavljene tako da tok udara u njihovu kraću stranicu. Nalaze se u toku *Crni grab* koji je prije selektivnog uklanjanja vegetacije bio neaktivan. Smještene su nizvodno od lokacije *Kod duplog crnog graba.* Širina toka odgovara lokaciji *Kod mladog Jasena* s nešto slabijim protokom. Pločice su postavljene na dno toka te

imaju sličan nagib po svim osima. PL19 je postavljena nešto niže u odnosu na PL24 koja se nalazi na malenoj sedrenoj kaskadi (Slika 88). Pločice se nalaze na jako maloj dubini, gotovo na površini vode, zbog čega postoji mogućnost da su kroz ljetna razdoblja periodično bila na suhome. To se posebno odnosi na PL24 koja je neznatno izdignutija u odnosu na susjednu PL19. Lokaciju obilježava umjerena turbulencija vode (slično kao *Kod mladog jasena*). U blizini nisu uočene veće količine makrofita i mahovina. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao srednje brzi tok (MFW). Potrebno je istaknuti da fluvijalna obilježja ove lokacije nisu bila konstantna kroz jednogodišnje razdoblje mjerenja. Naime, u posljednjoj fazi praćenja TFD-a došlo je do nestanaka vode na ovoj lokaciji, odnosno preusmjerena i presušenja dijela toka uslijed padanja stabala u neposrednoj blizini te akumulacije biljnih fragmenata.

Slika 88. PL 19 i 24 na na lokaciji *Kod spomenika*

Na lokaciju *Kod duplog crnog graba* PL04 i 21 pločice su postavljene tako da tok udara u njihovu kraću stranicu. Nalaze se u toku *Crni grab* koji je prije selektivnog uklanjanja vegetacije bio neaktivan. Smještene su uzvodno od lokacije *Kod spomenika*. Tok je usječen te mu je širina slična lokaciji *Tvrda sedra*, sa sličnom brzinom protoka. PL21 je postavljena nešto niže, na dno toka, dok PL04 ima izražen nagib po longitudinalnoj osi te se nalazi na izdignutoj poziciji. Pločice se nalaze na dubini većoj od desetak centimetara. Lokaciju obilježava izrazita turbulencija vode (Slika 89) (slično kao *Tvrda sedra*). Osunčanost je slaba zbog dva velika crna graba koja se nalaze iznad toka. U blizini nisu uočene veće količine makrofita i mahovina. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao izrazito brzi tok (FFW). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 89. PL04 i 21 na lokaciji *Kod duplog Crnog graba*

Na lokaciju *Jezerski slapić* PL05 je postavljena tako da joj tok udara u kraću stranu, dok PL18 udara u bočnu, dulju stranu. Nalaze se u toku *Matica* (blizu odmarališta) koji je prije selektivnog uklanjanja vegetacije bio neaktivan. Smještene su ispod manje sedrene kaskade s koje tok *Matica* opskrbljuje vodom *Jezero šest stabala* u kojem se nalazi još jedna lokacija pločica istog naziva. Pločice po longitudinalnoj osi imaju isti nagib, ali PL18 po vertikalnoj osi ima izražen nagib, stvarajući veći otpor odnosno turbulenciju vode. Pločice nisu u potpunosti uronjene u vodu već se nalaze u zoni prskanja (izrazita turbulencija vode) čiji je intenzitet određen snagom protoka (Slika 90). Postoji mogućnost da su kroz ljetna razdoblja periodično bila na suhome. U blizini PL05 uočene su zajednice mahovina. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao zona prskanja (SZ). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 90. PL 05 i 18 na lokaciji *Jezerski slapić*

Na lokaciju *U bršljanu* PL06 i 08 su postavljene tako da im tok udara u kraću stranu. Nalaze se u toku *Bršljanik* koji je prije selektivnog uklanjanja vegetacije bio neaktivan, a vodu

dobiva iz velike reaktivirane akumulacije *Smokovik* i dijela toka *Crni grab*. U neposrednoj blizini, gotovo u istom vodenom tijelu (ovisno o vodostaju), nalazi mu se lokacija *Nježna mahovina.* Tok je veoma širok (širi od *Bezimene*), a ovisno o vodostaju spojen s akumulacijom *Smokovik.* Brzina protoka mu je slična kao lokaciji *Kod spomenika.* Pločice su postavljene tako da im tok udara u kraću stranu. Po longitudinalnoj osi imaju isti nagib, dok po vertikalnoj PL06 ima nešto izraženiji stvarajući veći otpor (Slika 91). Lokaciju obilježava umjerena turbulencija vode (slično kao *Kod spomenika*). Pločice su u potpunosti uronjene u vodu, ali se nalaze na jako maloj dubini zbog čega postoji mogućnost da su kroz ljetno razdoblje bili na suhome. S obzirom na obilježja fluvijalnog okruženja ova lokacija je klasificirana kao umjereno brzi tok (MFW). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 91. PL 06 i 08 na lokaciji *U bršljanu*

Na lokaciji *Kaskada* PL21 i PL26 su postavljene tako da im voda udara u kraću stranu. Nalaze se u jednom od tokova koji izlazi iz akumulacije *Smokovik,* a za vrijeme velikog vodostaj taj cijeli prostor predstavlja jednu veliku akumulaciju. Lokacija je prije selektivnog uklanjanja i čišćenja vegetacije bila aktivna, ali sa slabijim protokom vode. U neposrednoj blizini, gotovo u istom vodenom tijelu (ovisno o vodostaju), ali u potpuno različitom fluvijalnom okruženju, nalazi se lokacija *Nježna mahovina.* Pločice su učvršćene na komad suhe sedre koji je pronađen u blizini. Imaju potpuno iste nagibe po longitudinalnoj, vertikalnoj i lateralnoj osi (Slika 92). Komad sedre je uronjen u vodu malo dalje od samog ruba kaskade. Pločice su u potpunosti uronjene u vodi, a nalaze se na dubini od oko 30 cm, ovisno o vodostaju. Na lokaciji pločica turbulencija vode nije uočena. U blizini pločica nisu uočene veće količina makrofita i mahovina. Brzina vode je nešto manja u odnosu na lokaciju *U bršljanu* zbog čega je ova lokacija klasificirana kao sporiji tok (SFW). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 92. PL 21 i 26 na lokaciji *Kaskada*

Na lokaciji *Krivo stablo* PL15 i 28 su postavljene tako da im voda udara u kraću stranu. Slično kao i na lokaciji *Kaskada* nalaze se u jednom od tokova koji je dio velike akumulacije *Smokovik*. Lokacija je prije selektivnog uklanjanja i čišćenja vegetacije bila aktivna, ali sa slabijim protokom vode. Pločice su učvršćene na dno, odnosno na sam rub kaskada (Slika 93). Po longitudinalnoj osi imaju sličan nagib dok se po vertikalnoj malo razlikuju. U potpunosti su uronjene u vode, ali se nalaze na dubini od desetak centimetara (ovisno o vodostaju). Na lokaciji pločica turbulencija vode je umjerena, znatno se povećavajući nizvodno. U blizini pločica nisu uočene veće količine makrofita i mahovina. Prema klasifikaciji fluvijalnog okruženja lokacija spada u klasu stepenaste kaskade (SC). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 93. PL15 i 28 na lokaciji *Krivo stablo*

Na lokaciji *Nježna mahovina* PL15 i 28 su postavljene tako da im voda udara u kraću stranu. Nalaze se na rubu jedne od kaskada velike akumulacije *Smokovik*. Lokacija je prije selektivnog uklanjanja i čišćenja vegetacije bila aktivna, ali sa slabijim protokom vode. Pločice su učvršćene na dno na sam rub kaskade. Po longitudinalnoj osi imaju sličan nagib dok se po vertikalnoj neznatno razlikuju (Slika 94). U potpunosti su uronjene u vode. Nalaze na dubini od 10-15 cm (ovisno o vodostaju). Na lokaciji pločica turbulencija vode je izrazita. Prema hidrološkim obilježjima *Nježna mahovina* je dosta slična lokaciji *Krivo stablo*. U blizini pločica uočena je velika nakupina mahovina. Točnije, dulja strana PL14 dodiruje veliku nakupinu mahovina po čemu je lokacija dobila ime. Prema klasifikaciji fluvijalnog okruženja lokacija spada u klasu stepenaste kaskade (SC). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

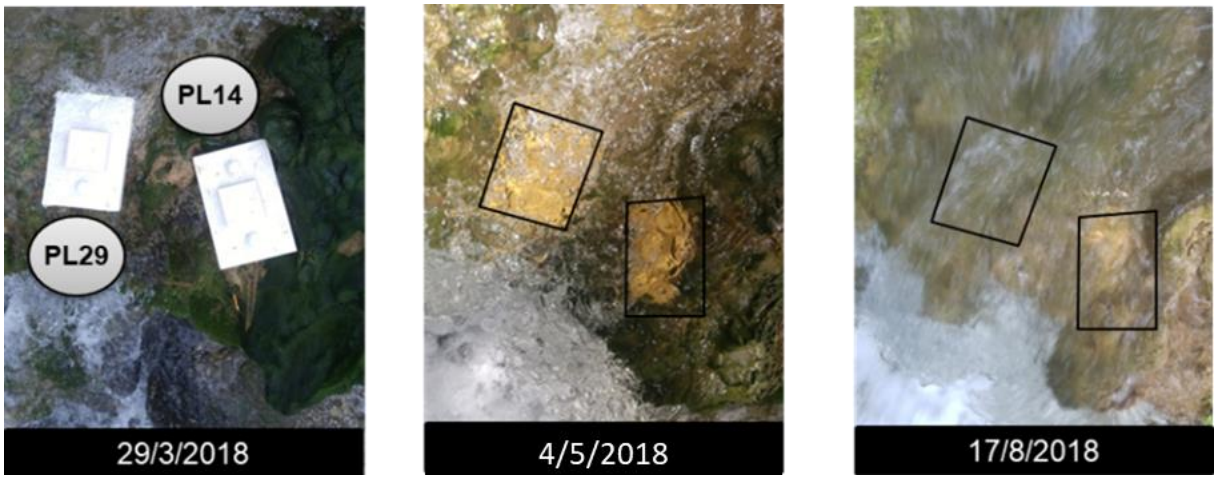

Slika 94. PL 14 i 29 na lokaciji *Nježna mahovina*

Na lokaciji *Pačji slap* PL07 i 25 su postavljene tako da im voda udara u kraću stranu. Nalaze se na rubu kaskade unutar akumulacije *Pačji slap.* Lokacija je prije selektivnog uklanjanja i čišćenja vegetacije bila slabo aktivna u hladnom dijelu godine (viši vodostaj) te je postojala stvarna opasnost od njenog presušenja (Slika 95). U ljetnom periodu lokacija je bila u potpunosti suha. Pločice su učvršćene na dno samog ruba kaskade. Po longitudinalnoj, vertikalnoj i lateralnoj osi imaju gotovo isti nagib. Nalaze se na maloj dubini, gotovo na površini vode. Nema izraženije turbulencije vode. Prema hidrološkim obilježjima lokacija je slična *Nježnoj mahovini* te *Krivom stablu* sa slabijim protokom vode. U blizini pločica uočena je velika nakupina mahovina. Točnije, dulja strana PL07 gotovo da dodiruje veliku nakupinu mahovina. Prema klasifikaciji fluvijalnog okruženja lokacija spada u klasu stepenaste kaskade (SC). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

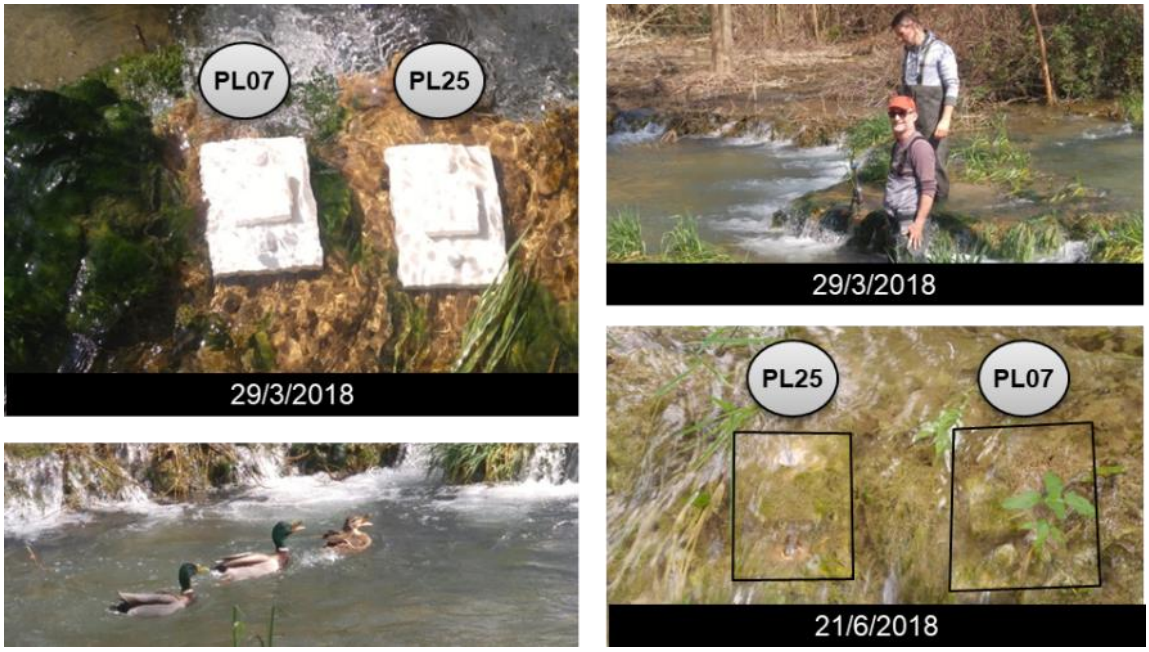

Slika 95. PL07 i 25 na lokaciji *Pačji slap*

Na lokaciji *Sedreni zid* PL23 i 30 su postavljene tako da im voda udara u kraću stranu. Pločice su postavljene na isti način kao na lokaciji *Kaskada.* Učvršćene su na komad suhe (mrtve) sedre koji je pronađen u blizini, stoga imaju potpuno iste nagibe po longitudinalnoj, vertikalnoj i lateralnoj osi (Slika 96). Komad sedre je položen na dno u veliku akumulaciju *Smokovik* koja je u manjoj mjeri bila aktivna prije selektivnog uklanjanja vegetacije. Lokacija ima dobru osunčanost, dok je snaga protoka nešto slabija od lokacije *Kaskada.* Pločice se nalaze na dubini od oko pola metra (tijekom hladnog razdoblja dubina je veća). Turbulencija vode nije zabilježena. Prema hidrološkim obilježjima lokacija je najsličnija *Kaskadi*. U blizini pločice nije uočena značajnija količina makrofita, iako tok biljne fragmente nanosi iz guste vegetacije koja se nalazi nešto uzvodnije, odnosno nizvodno od *Jezera šest stabala*. Prema klasifikaciji fluvijalnog okruženja lokacija je klasificirana kao sporiji tok (SFW). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 96. PL23 i 30 na lokaciji *Sedreni zid*

Na lokaciji *Jezero šest stabala* PL22 i PL09 pločice su postavljene kao na lokaciji *Kaskada* i *Sedreni zid.* Učvršćene su na komad suhe (mrtve) sedre koji je pronađen u blizini, stoga imaju potpuno iste nagibe po longitudinalnoj i lateralnoj osi, a neznatno se razlikuju prema vertikalnoj osi. Komad sedre je položen na dno u akumulaciju *Jezero šest stabala* koja prije selektivnog uklanjanja i čišćenja vegetacije nije bila aktivna. Komad sedre je postavljen na muljevito dno jezera (Slika 97). Pločice se nalaze na najvećoj dubini u odnosu na sve ostale lokacije (> 1m). Lokacija ima slabu osunčanost zbog velike dubine i velikoj broja stabala koji se nalaze iznad pločice. Turbulencija vode nije zabilježena. Prema hidrološkim obilježjima ova lokacija se ističe od drugih. U blizini pločica je uočeno nekoliko većih stabala. Mahovine nisu zamijećene. Prema klasifikaciji fluvijalnog okruženja lokacija je svrstana u stagnantnu vodu (SW). Fluvijalna obilježja lokacije su bila konstantna kroz jednogodišnje razdoblje mjerenja.

Slika 97. PL 09 i PL22 na lokaciji *Jezero šest stabala*

Svakoj lokaciji dodijeljen je jedinstven identifikacijski broj i ime dok je na svaku poleđinu A) bazne pločice ugravirana jedinstvena šifra. U tablici 23 prikazan je plan usporedbe modela (godišnja/godišnja, godišnja/polugodišnja, godišnja/tromjesečna) te vađenja i snimanja pločica po lokacijama. Na dvije lokacije je rađena godišnja, na devet godišnja/polugodišnja, a na tri godišnja/tromjesečna usporedba.

Tablica 22. Plan usporedbe modela te vađenje i snimanje pločica na testnoj plohi SB

ID	Ime lokacije	Šifra pločice	Pozicija pločice u toku	Datumi vađenja pločica 21/6/18	19/9/18	21/12/18	21/3/19	Usporedba modela
01	*Bezimena*	03	desna		+		+	godišnja/
		16	lijeva				+	polugodišnja
02	*Tvrda sedra*	02	lijeva				+	godišnja/
		13	desna	+	+	+	+	tromjesečna
03	*Kod mladog jasena*	10	desna		+		+	godišnja/
		12	lijeva				+	polugodišnja
04	*Sedreni kanjon*	11	lijeva				+	godišnja/
		27	desna		+		+	polugodišnja
05	*Kod spomenika*	19	lijeva				+	godišnja/
		24	desna		+		+	polugodišnja
06	*Kod duplog crnog grada*	04	lijeva				+	godišnja/godišnja
		21	desna				+	
07	*Jezerski slapić*	05	lijeva				+	godišnja/
		18	desna		+		+	polugodišnja
08	*U bršljanu*	06	desna	+	+	+	+	godišnja/
		08	lijeva				+	tromjesečna
09	*Nježna mahovina*	29	desna		+		+	godišnja -
		14	lijeva				+	polugodišnja
10	*Krivo stablo*	28	lijeva				+	godišnja/
		15	desna		+		+	polugodišnja
11	*Sedreni zid*	23	desna		+		+	godišnja/
		30	lijeva				+	polugodišnja
12	*Kaskada*	01	lijeva				+	godišnja/godišnja
		26	desna				+	
13	*Jezero šest stabala*	9	lijeva				+	godišnja/
		22	desna		+		+	polugodišnja
14	*Jezerski slapić*	07	lijeva				+	godišnja/
		25	desna	+	+	+	+	tromjesečna

Na svim lokacijama izuzev 06 i 12, desna pločica je mjerena u intervalima od tri i/ili šest mjeseci, a lijeva nakon godine dana. Pločice su u tokove postavljene u dva navrata. Prvo postavljanje (14 pločica) je izvršeno 16. ožujka 2018. Drugo postavljanje (14 pločica) je obavljeno 29. ožujka iste godine (Slika 98).

Slika 98. Primjeri postavljanja pločica u različita fluvijalna okruženja

Pločice su postavljene u različita fluvijalna okruženja prema hidrauličkoj klasifikacijskoj shemi (Tablica 24) kako bi se mogla uočiti razlika u količini formiranog

precipitata. Fluvijalna okruženja su klasificirana prema mjerenjima brzine protoka na odabranih sedam lokacija te prema izgledu lokacija.

Tablica 23. Klasifikacija i opis fluvijalnih okruženja postavljanja pločica

ID	Šifra pločice	Fluvijalno okruženje (*)	Opis lokacije
01	PL03 PL16	MFW	dubina 0-5 cm, nema značajnije turbulencije ni prskanja, PL16 ima izraženiji nagib prema longitudinalnoj osi
02	PL02 PL13	FFW	dubina >20 cm, izražena turbulencija, pločice imaju sličan nagib po osima, slaba osvijetljenost
03	PL10 PL12	FFW	dubina <5 cm, umjerena turbulencija i prskanje, pločice imaju sličan nagib po osima
04	PL11 PL27	SZ	izražena zona prskanja, pločice imaju sličan nagib po osima, PL11 izdignutija u odnosu na PL27
05	PL19 PL24	MFW	dubina <5 cm, pločice imaju sličan nagib po osima, PL19 je spuštenija u odnosu PL24, u nekim trenutcima zabilježeno je presušenje toka
06	PL04 PL21	FFW	dubina <10 cm, izražena turbulencija i prskanje, PL04 ima izraženiji nagib duž longitudinalne osi i nalazi se na višoj poziciji od PL21, slaba osvjetljenost
07	PL05 PL18	SZ	dubina <5 cm, zona prskanja, pločice imaju različit nagib duž vertikalnih osi
08	PL06 PL08	MFW	dubina <5 cm, umjerena turbulencija i prskanje, pločice imaju sličan nagib po osima
09	PL29 PL14	SC	izražena zona turbulencije, pločice fiksirane duž različitih osi, PL14 ima izraženiji nagib po vertikalnoj osi i nalazi se bliže mahovini
10	PL28 PL15	SC	izražena zona turbulencije, pločice imaju sličan nagib po osima, PL15 je bliža mahovini
11	PL23 PL30	SFW	dubina <50 cm, nema turbulencije ni prskanja, pločice postavljene pod istim nagibom, odlična osvijetljenost
12	PL01 PL26	SFW	dubina <30 cm, nema prskanja ni turbulencije, pločice postavljene pod istim nagibima
13	PL09 PL22	SW	dubina <120 cm, stagnantna, neprotočna voda, nema turbulencije ni prskanja, pločice postavljene pod istim nagibima
14	PL07 PL25	SC	dubina <5 cm, umjerena zona turbulencije i prskanja, pločice postavljene pod istim nagibima, PL07 je bliža mahovini

* SC - stepenaste kaskade (eng. *stepped cascade*) FFW – brzo protočna voda (eng. *fast flowing water*), MFW – umjereno protočna voda (eng. *medium flowing water*), SFW – sporo protočna voda (eng. *slow flowing water*), SZ – zona prskanja (eng. *spray zone*), SW – stagnantna, neprotočna voda (eng. *stagnant water*)

Prije postavljanja, sve pločice su oprane i osušene te im je referentno (nulto) stanje izmjereno pomoću CMD-a. Mjerenje referentnog stanja izvršeno je 17. veljače 2018. godine. Pločice su potom iz tokova vađene prateći plan snimanja nakon tri (21.06.2018), šest (19.09.2018), devet (15.12.2018) i dvanaest mjeseci (15.03.2019) (Slika 99). Nakon vađenja ostavljene su da se suše na sobnoj temperaturi 4-5 dana prije mjerenja. Mjerenja CMD-om su izvršena 26.06, 24.09 i 20.12, 2018. te 19.03. 2019. godine. Dan nakon mjerenja pločice su vraćene nazad u vodu. U prosjeku u vodi provele 357 dana (min. = 347, max. = 364).

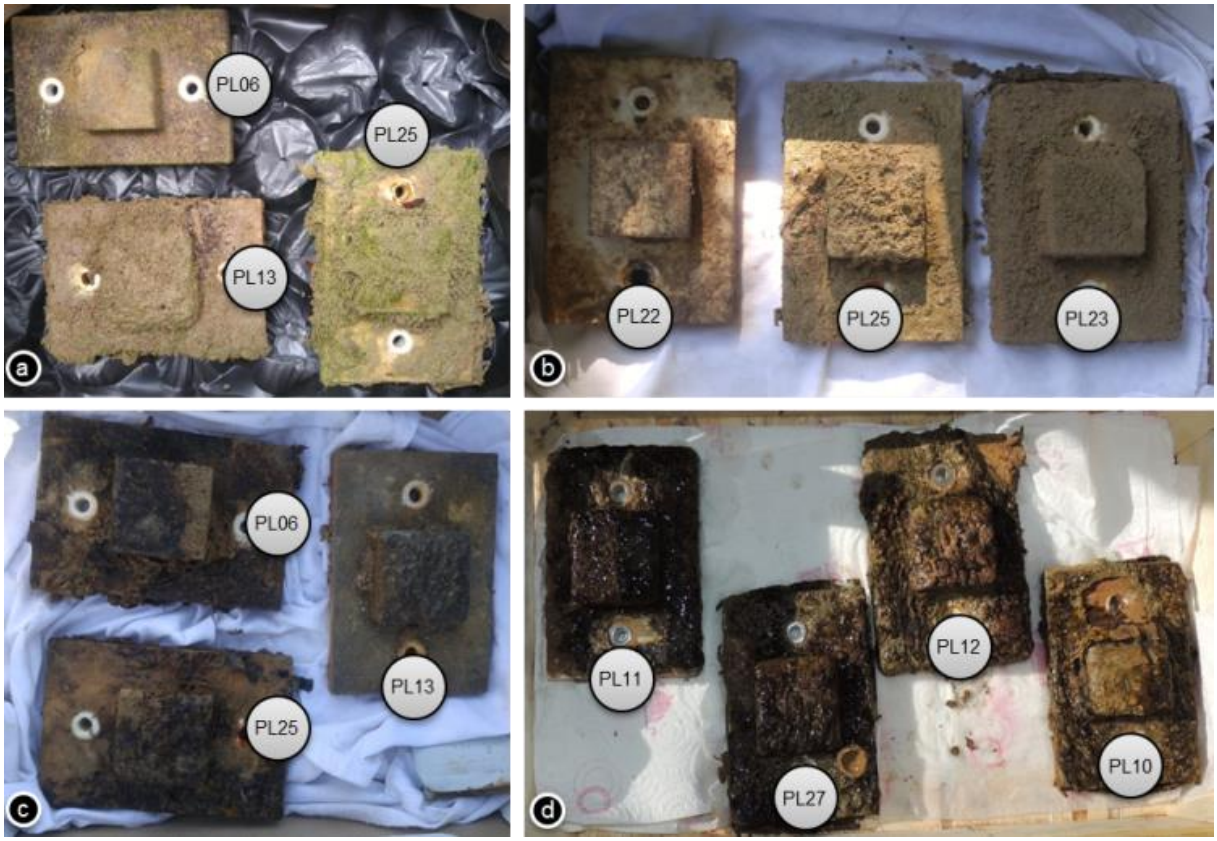

Slika 99. Pločice nakon vađenja iz vode a) 21/6/18 b) 19/9/18 c) 15/12/18 d) 15/3/19

3.3.6 Postavljanje i snimanje testnih pločica (testna ploha RS)

S ciljem usporedbe dinamike formiranja sedre pločice su postavljena na četiri lokacije unutar šireg prostora Roškog slapa (Slika 100) oko 13 km uzvodno od lokacija na testnoj plohi SB-a. Način postavljanja pločica je bio isti kao na testnoj plohi SB. Ukupno je postavljeno osam pločica. Svakoj lokaciji dodijeljen je jedinstven ID i ime dok je na poleđinu bazne pločice ugravirana jedinstvena šifra (Tablica 25).

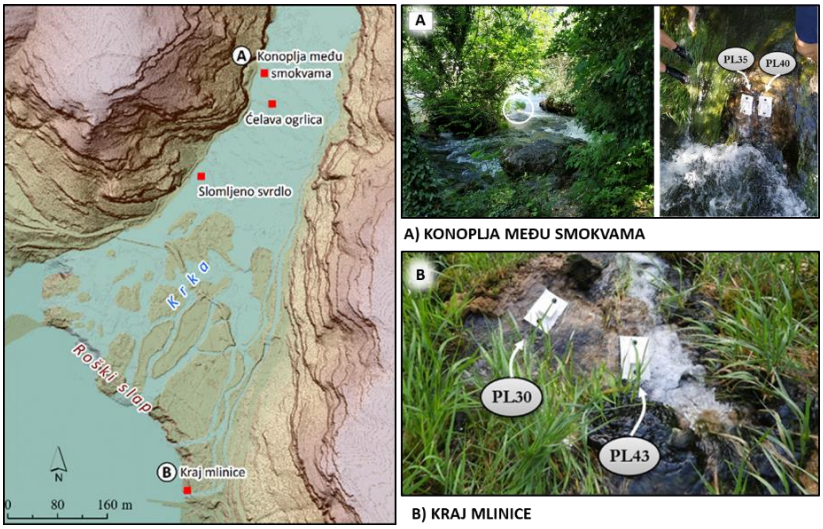

Slika 100. Lokacije postavljanja pločica na testnoj plohi RS

Sve pločice su postavljene 1. srpnja 2019. godine (Slika 101-103). Datum postavljanja te broj pločica nije mogao biti isti kao na testnoj plohi SB-a zbog dogovora s NP „Krka“ te dinamike propisanih aktivnosti na GAL projektu.

Slika 101. PL35 i 40 na lokaciji *Konoplja među smokvama*

Slika 102. PL39 i PL41 na lokaciji *Slomljeno svrdlo*

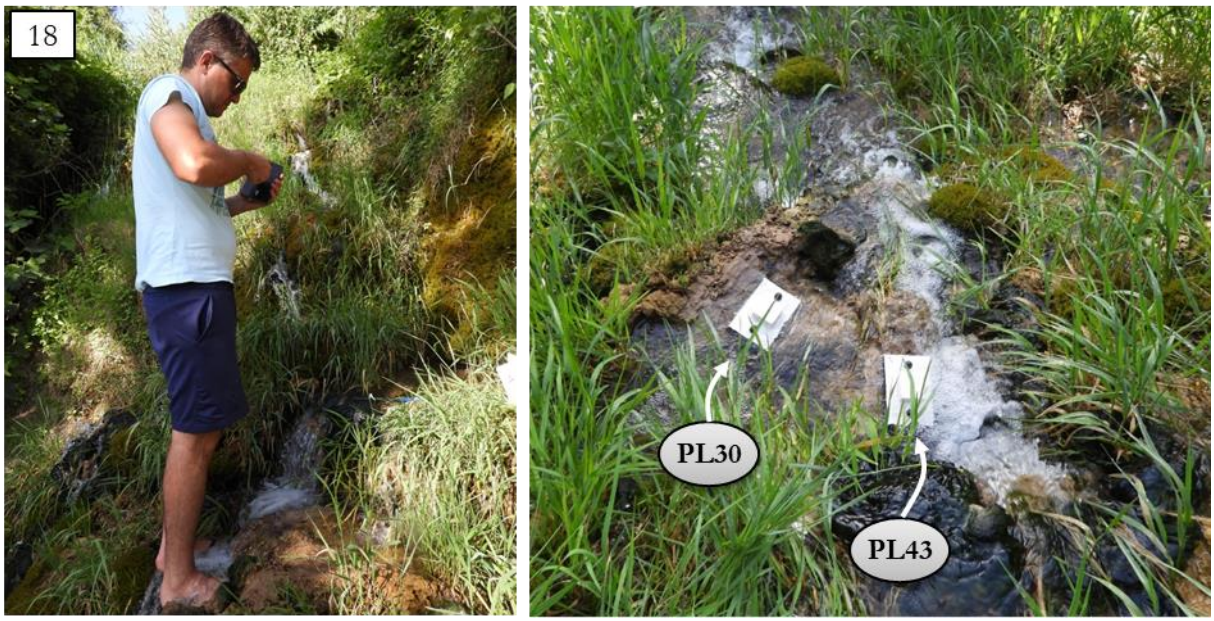

Slika 103. PL30 i PL43 na lokaciji *Kod mlinice*

Prema planu vađenja (Tablica 25) desnu pločicu na svakoj lokaciji (n=4) je trebalo izvaditi nakon šest mjeseci izloženosti toku, početkom siječnja, 2020. godine. Međutim, dolaskom na teren uvidjelo se da aktivnost nije moguće provesti uslijed iznimno velikog vodostaja i brzine protoka što je potencijalno moglo ugroziti sigurnost osobe koja bi pločice vadila (Slika 104). Primjerice, pločice na lokaciji *Ćelava ogrlica* nalazile su se na dubini od preko 1 m.

Slika 104. Veliki vodostaj na testnoj plohi RS koji je onemogućio vađenje pločica

Zbog toga su s ciljem okvirne usporedbe stopa prirasta sedre izvađene su samo one pločice kojima se na dan skidanja moglo pristupiti bez ugrožavanja sigurnosti operatora. Stoga su 10. siječnja, 2020. godine iz vode izvađene PL30 i 43 *Kraj mlinice* te PL41 na lokaciji *Slomljeno svrdlo* (Slika 105).

Tablica 24. Pločice postavljene na testnoj plohi RS

ID	Ime lokacije	Šifra pločice	Pozicija pločice u toku	Predloženi datum vađenja pločica
15	*Konoplja među smokvama*	35	desna	2. siječnja, 2020.
		40	lijeva	1. srpanj, 2020.
16	*Ćelava ogrlica*	36	desna	2. siječnja, 2020.
		38	lijeva	1. srpanj, 2020.
17	*Slomljeno svrdlo*	39	lijeva	2. siječnja, 2020.
		41	desna	1. srpanj, 2020
18	*Kraj mlinice*	30	lijeva	2. siječnja, 2020.
		43	desna	1. srpanj, 2020

Detaljna klasifikacija fluvijalnih okruženja na testnoj plohi RS-a nije napravljena. Međutim, lokacije *Konoplja među smokvama, Ćelava ogrlica* i *Slomljeno svrdlo* imaju gotovo ista obilježja. Karakterizira ih velika brzina protoka, nema značajnije turbulencije (na pločicama), dubina na kojoj se pločice nalaze značajno varira ovisno o vodostaju. Pločice imaju gotovo isti nagib po longitudinalnoj, lateralnoj i vertikalnoj osi. U njihovoj neposrednoj blizini nalaze se različite vrste mahovina i algi čija se dominacija mijenja ovisno o temperaturi vode i brzini strujanja. Suprotno, lokacija *Kraj mlinice* je najsličnija fluvijalnim okruženjima klasificiranim kao zona prskanja (SZ) na testnoj plohi SB-a. Pločice su postavljene pod sličnim nagibom, jedino je PL43 izloženija prskanju vode u odnosu na susjednu PL30.

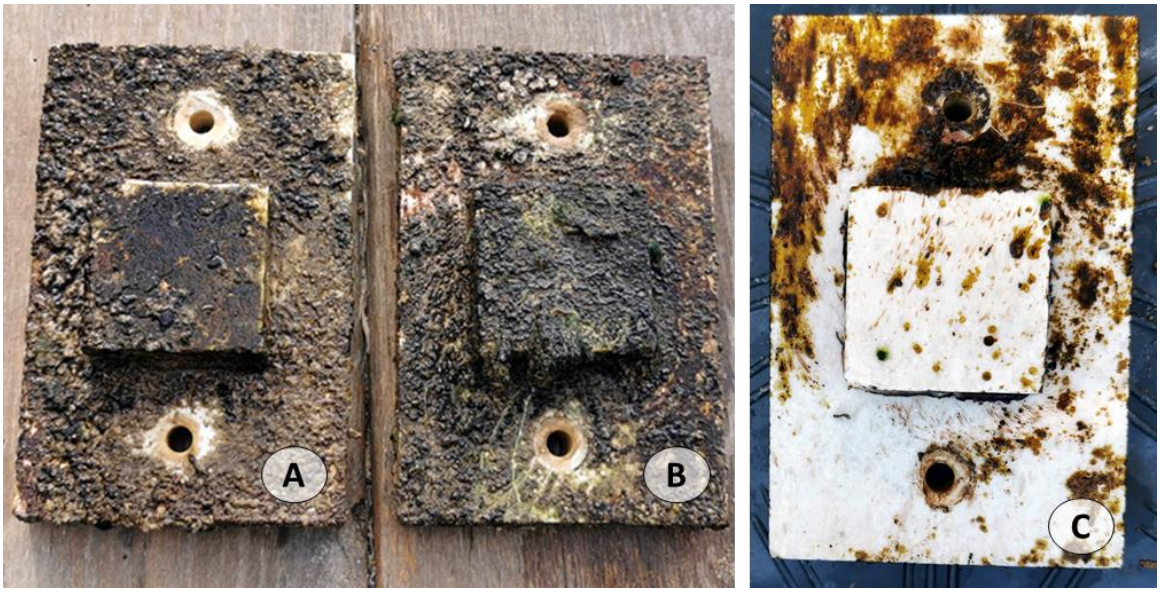

Slika 105. A) PL30, B) PL43 i C) PL41 nakon vađenja iz vode (10. siječanj, 2020).

3.3.6.1 Snimanje pločica RS-a Artec Evom

Pločice postavljene na lokacije unutar plohe šireg područja RS-a su snimljene 3D projekcijskim skenerom *Artec Evom* te CMD-om s ciljem prezentiranja mogućnosti primjene 3D ručnih skenera u praćenju dinamike formiranja sedre te usporedbe izvedenih modela. Danas je dostupan širok raspon 3D skenera. Neki se temelje na laseru, dok drugi koriste strukturirano svjetlo (Shah i Luximon, 2017). *Artec Eva* predstavlja najsuvremeniju tehniku 3D skeniranja koja koristi triangulaciju i strukturirano svjetlo prilikom prikupljanja 3D podataka (URL 36). U odnosu na druge 3D skenere kompaktna je i lagana (Modabber i dr., 2016). Prema službenim specifikacijama 3D rezolucija *Eve* iznosi 0,5 mm na radnoj udaljenosti od 40 cm do 1 m, dok točnost 3D točaka iznosi 0,1 mm (Artec Group, 2016, Modabber i dr., 2016, URL 37), iako Shah i Luximon (2017) te Ozsoyi dr. (2015) navode točnost od 0,05 mm. Kvaliteta mjerenja *Artec Evom* ispitana je laserskim skenerima visoke kvalitete i razlučivosti (ROMER skener) koji imaju točnost 0,04 mm. Rezultati su pokazali da je *Artec Eva* vrlo pouzdan instrument za mjerenje volumena (Seminati, 2017). Modabber i dr. (2016) navode da je *Eva* je pokazala puno bolje rezultate od *FaceScan3D* te bolje rezultate od *Cyberware 3030 Color* 3D skenera i *Occipital Structure* modela prema Shah i Luximon (2017). Autori ističu da su prednosti *Artec Eve* naknadna obrada snimljenog niza slika koja poboljšava točnost modela te mogućnost snimanja testnih uzoraka sa svih strana (mobilnost uređaja) (Modabber i dr., 2016).

Eva obasjava objekt s prugastim uzorcima vidljivog svjetla. Te uzorke potom snimaju dvije kamere koje se nalaze na rubovima skenera. Treća kamera je smještena u sredini skenera, okružena LED bljeskalicama, a zadaća joj je prikupljanje teksture. Tijekom skeniranja *Eva* može snimiti do 16 3D slika u sekundi te ih u realnom vremenu prosljeđuje u program *Artec Studio* koji poravnava slike omogućavajući pregled skeniranog objekta (Modabber i dr., 2016). *Artec Studio* je program za obradu podataka koji dolazi s kupljenim skenerom. Jednostavan je za korištenje te nudi širok spektar mogućnosti obrade neobrađenih skeniranih podataka (Slika 106). Jedna od glavnih funkcija mu je mogućnost obavljanja globalne registracije čime se otklanjaju manje pogreške nastale tijekom skeniranja. Nadalje, ima napredne mogućnosti popunjavanja rupa te zaglađivanja poligona, ali velik nedostatak mu je, u slučaju da su performanse računala slabe, vrijeme potrebno za obradu podataka (Shah i Luximon, 2017).

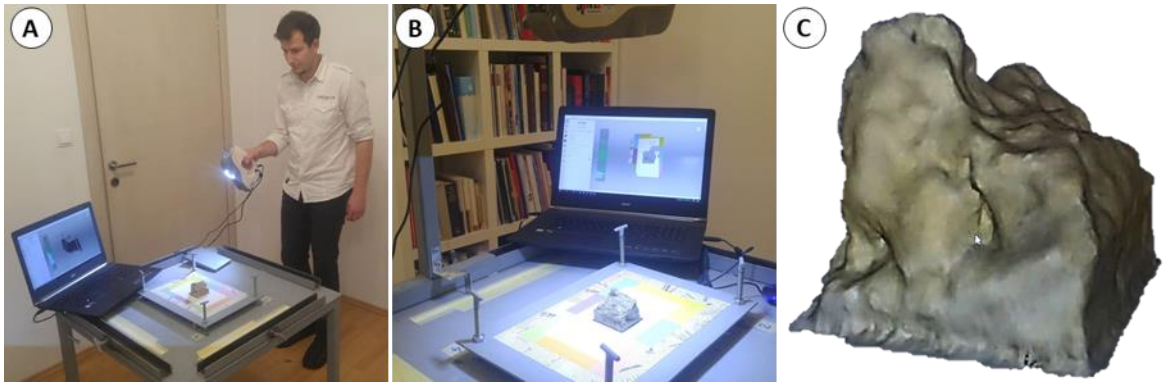

Slika 106. Testiranje *Artec Eve* za potrebe snimanja pločica A) snimanje PL07 (*Pačji slap*) B) obrada skenova u *Artec Studiu* C) teksturirani 3D model pločice

Za postizanje uspješnog skeniranja *Eva* mora više puta snimiti sve točke interesa na objektu ili sceni. Nakon što se skeniranje završi u *Artec Studiu* se spajaju skenovi, odnosno slike, geometrije i tekstura. Korisnik u lokalnom koordinatnom sustavu dobiva teksturiranu 3D mrežu. Izlazni rezultat se obično eksportira u formate za 3D podatke *Stereolithography* (.stl) i *Wavefront Object* (.obj) (Modabber i dr., 2016).

Skeniranje referentnog stanja osam pločica postavljenih unutar testne plohe na RS izvršeno je istog dana (26.5.2018) kao i snimanje s CMD-om. Također, skeniranje pločica (PL 43, 41 i 30) izvađenih nakon šest mjeseci u toku, provedeno je istog dana kao i snimanje CMD-om. S ciljem postizanja kvalitetne usporedbe generiranih rezultata *Artec Eve* i CMD-a snimanje i skeniranje se odvijalo na sljedeći način. Specifična pločica (npr. PL38) je fiksirana na postolje CMD-a pomoću pomične metalne stope s fiksnim držačima. Potom je pomoću digitalnog šublera određena visina LCS-a koja je ostala ista kao u mjerenjima pločica na području SB-a. Podešene su iste postavke kamere (poglavlje 3.3.7). Nakon toga je provedeno snimanje sa sustavom senzora CMD-a. Nakon završetka snimanja izvršeno je skeniranje iste pločice s *Artec Evom*. Pločica nije pomicana iz svoje fiksne pozicije na postolju te visina LCS-a nije mijenjanja. Potom je cijeli proces ponovljen za sve pločice.

3.3.6.1.1 Obrada skenova snimljenih *Artec Evom*

Skenovi pločica su obrađeni u programu *Artec Studio 13 Professional*. To je industrijski priznat programski paket namijenjen za napredno 3D skeniranje i obradu podataka. Završetkom skeniranja, koje je trajalo nešto manje od minute, izveden je proces obrade koji se sastojao od nekoliko koraka. S obzirom na to da prilikom skeniranja nije dolazilo do segmentacije skeniranja (nastanka više skenova) početni korak spajanja skenova nije trebalo provoditi. Stoga je proces obrade uključivao:

1. Brisanje nepotrebnih dijelova (eng. *crop surroundings*)

S obzirom na to da je pločica fiksiranih na postolje CMD-a skenirano je gotovo cijelo postoje uređaja te LCS. Velika količina podataka može usporiti proces obrade te nije potrebna jer je za usporedbu potrebno izračunati samo volumen. Primjenom alata *Editor – Eraser – Rectangular selection* izbrisan je veći skenirani dio oko pločice (Slika 107A).

2. Optimizacija položaja skenova (eng. *global registration*)

Nakon brisanja nepotrebnih dijelova alatom *Tools - Global registration* optimiziran je položaj skeniranih scena čime su pripremljeni za daljnju obradu (Slika 107B). Algoritam konvertira sve *one-frame* površine u jedinstveni koordinatni sustav koristeći informacije o zajedničkoj lokaciji uparenih površinskih točaka. Odabire se skup specifičnih geometrijskih točaka te se potom traže njihovi podudarajući parovi.

3. Eliminacija 3D šumova (eng. *outliner removal*)

Primjenom alat *Tools – Fusion – Outliner removal* izbrisani su šumovi, odnosno veće pogreške na skenovima (Slika 107C).

4. Oštro spajanje (eng. *sharp fusion*)

Pomoću alata *Tools – Fusion – Sharp Fusion* kreirana je jedinstvena površina modela u odnosu na inicijalni ulazni podatak. Prema uputama *Artec Studia* sljedeći korak u procesu obrade trebao bi biti *Simplify Mesh*. Međutim, navedena funkcija nije korištena jer se želio zadržati velik broj poligona, odnosno detaljnost prikaza pločice (Slika 107D).

5. Dodavanje teksture (eng. *apply texture*)

Nakon kreiranja jedinstvene površine modela izrađen je teksturirani model (Slika 110D). Potrebno je istaknuti da se kvaliteta teksturiranog modela dobivenog s *Artec Evom* ne može uspoređivati s kvalitetom teksture generiranom s CMD-om. Razlog tome je velika razlika u rezoluciji kamere CMD-a (24 Mpx), nasuprot *Artec Eve* (1,4 Mpx).

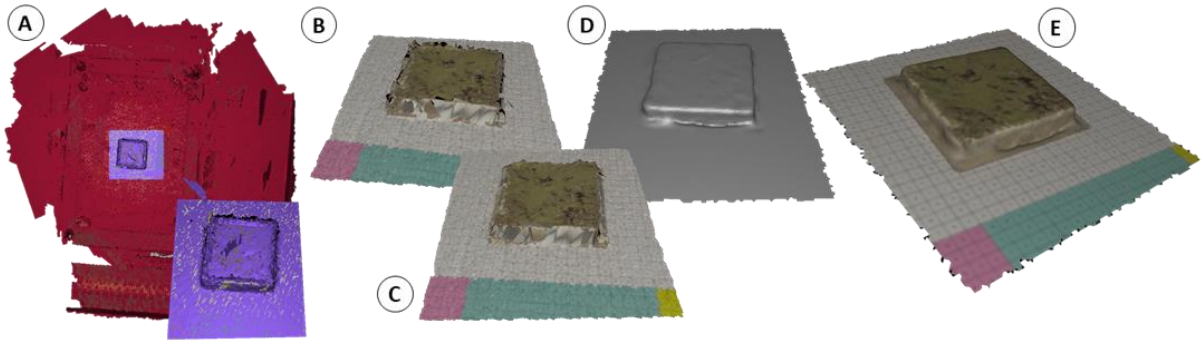

Slika 107. Primjer procesa obrade skenova PL30 (završno stanje) A) brisanje nepotrebnih dijelova B) optimizacija položaja C) eliminacija šumova D) oštro spajanje E) dodavanje teksture

3.3.7 Metodologija obrade fotografija

Proces prikupljanja fotografija se u literaturi opisuje kao "osjetljiv korak u (inače) automatiziranom" procesu fotogrametrije (Micheletti i dr., 2015). Snimanje pločica postavljenih na SB-u i RS-u izvršeno je u mjerilu 1:2 fotoaparatom *NIKON D5300* s montiranim makro objektivom *Venus LAOWA 60 mm f/2.8 2:1* udaljenim 23,4 cm od LCS-a. Otvor blende je postavljen na f/22 kako bi se osigurala veća dubina polja budući da nije moguće točno predvidjeti visinu prirasta sedre (Tablica 6). Iako to odstupa od optičkog optimuma, odnosno otvor blende od 5,6 do 11 daje najoštrije i najčišće slike (Marziali i Dionisio, 2017, Hoiberg, 2018), ova vrijednost ipak predstavlja kompromis između dubine polja i oštrine slike (Marziali i Dionisio, 2017). Ovime se htjela postići oštra slika najvišeg uzorka sedre na pločici te jednako oštra slika LCS-a koji se nalazi u dnu pločice.

Navedeno je smanjilo količinu upadne svjetlosti zbog čega je korištena ring bljeskalica (*Aputure AHL-HC100 Amaran Halo LED Ring Flash*) čime je osigurana jednaka osvijetljenost cijele pločice te uklonjen problem sjena. ISO vrijednost je postavljena na 200 kako bi se uklonila mogućnost pojave šuma na fotografijama, a brzina zatvarača na 1/20. Postavke kamere te unutarnji kalibracijski parametri su bili konstantni tijekom svih snimanja. U fotogrametriji je ključno da sva područja interesa, u ovom slučaju pločica i dio LCS-a na kojeg se dodaju orijentacijske i kontrolne točke, moraju biti vidljiva na minimalno ≥3 fotografije (James i Robson, 2012). Vodoravno pomicanje mehaničkog okvira na kojem se nalazi sustav senzora omogućilo je određivanje prednjeg i bočnog preklapanja između susjednih fotografija. Sustav senzora je na mehaničkom okviru pomican preko pločice u *Double Grid Mission* kretanju s prednjim i bočnim preklapanjem većim od 80%. S obzirom na definirani LCS te poznate vanjske orijentacijske parametre kamere određeno je intervalno pomicanje mehaničkog okvira X, Y i Z osi za 1 cm. Dimenzija fotografije je iznosila 7 cm x 4,6 cm. Time je svaki uzorak na pločici i užem dijelu LCS-a zabilježen na više od 9 preklapajućih fotografija. Drugim riječima, pločica je u svakom snimanju prikazana sa 187 preklapajućih fotografija. *Double Grid Mission* način fotografiranja se preporučuje ako se želi izvesti 3D model nekog prostora (Slika 108) (Frey i dr., 2018).

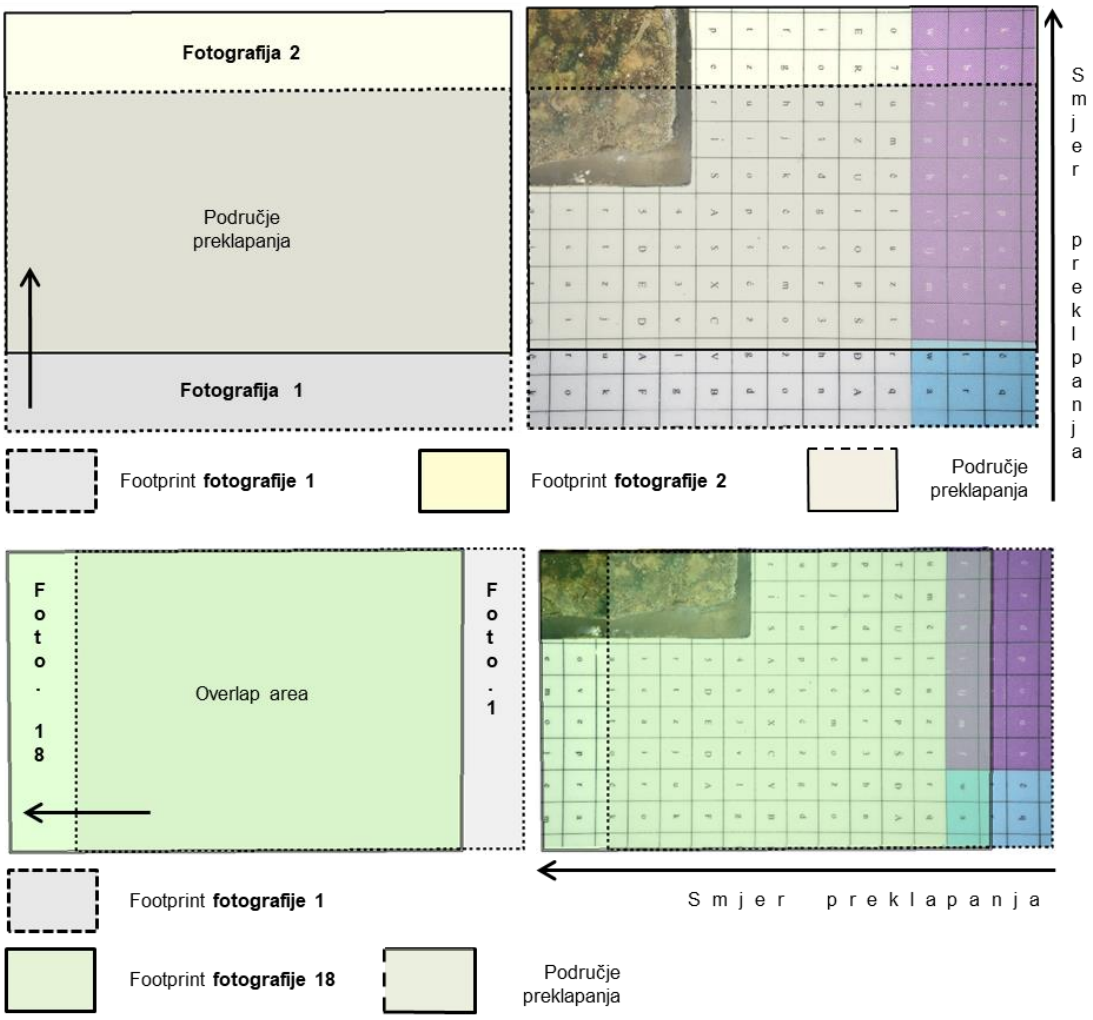

Slika 108. Primjer prednjeg i bočnog preklapanje susjednih fotografija

Digitalni modeli sedre visoke rezolucije (eng. *Digital Tufa High Resolution Models* - DTHRM) izvedeni su koristeći program *Agisoft Metashape Professional 1.5.1* (64 bit) koji primjenjuje algoritam SfM. Proces SfM-a izvršen je prema smjernicama predloženim od James i dr., (2019). Apsolutna orijentacija modela u LCS je poboljšana dodavanjem četiri orijentacijske točke (OT1-OT4) (Slika 109).

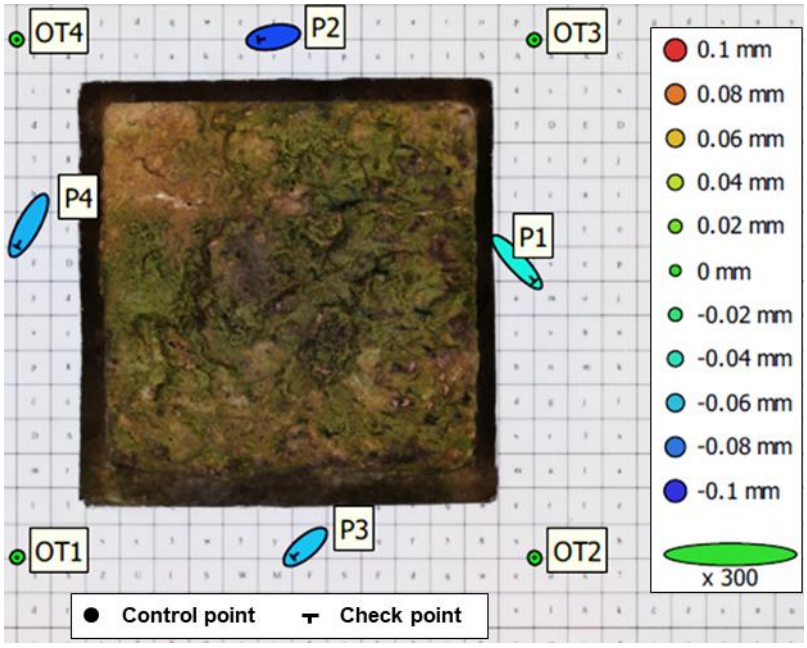

Slika 109. Primjer procjene pogrešaka na orijentacijskim i kontrolonim točkama (PL_{25})

(Z pogreška je reprezentirana bojom elipse, dok su X i Y pogreške prikazane oblikom elipse)

Točnost orijentacijskih točaka je postavljena na 0,00 s obzirom na to da je stvarna točnost lokalnog koordinatnog sustava manja od 2 cm (Agisoft Photoscan, 2019). Cjelokupni metodološki proces obrade fotografija se sastojao od osam koraka (Slika 110).

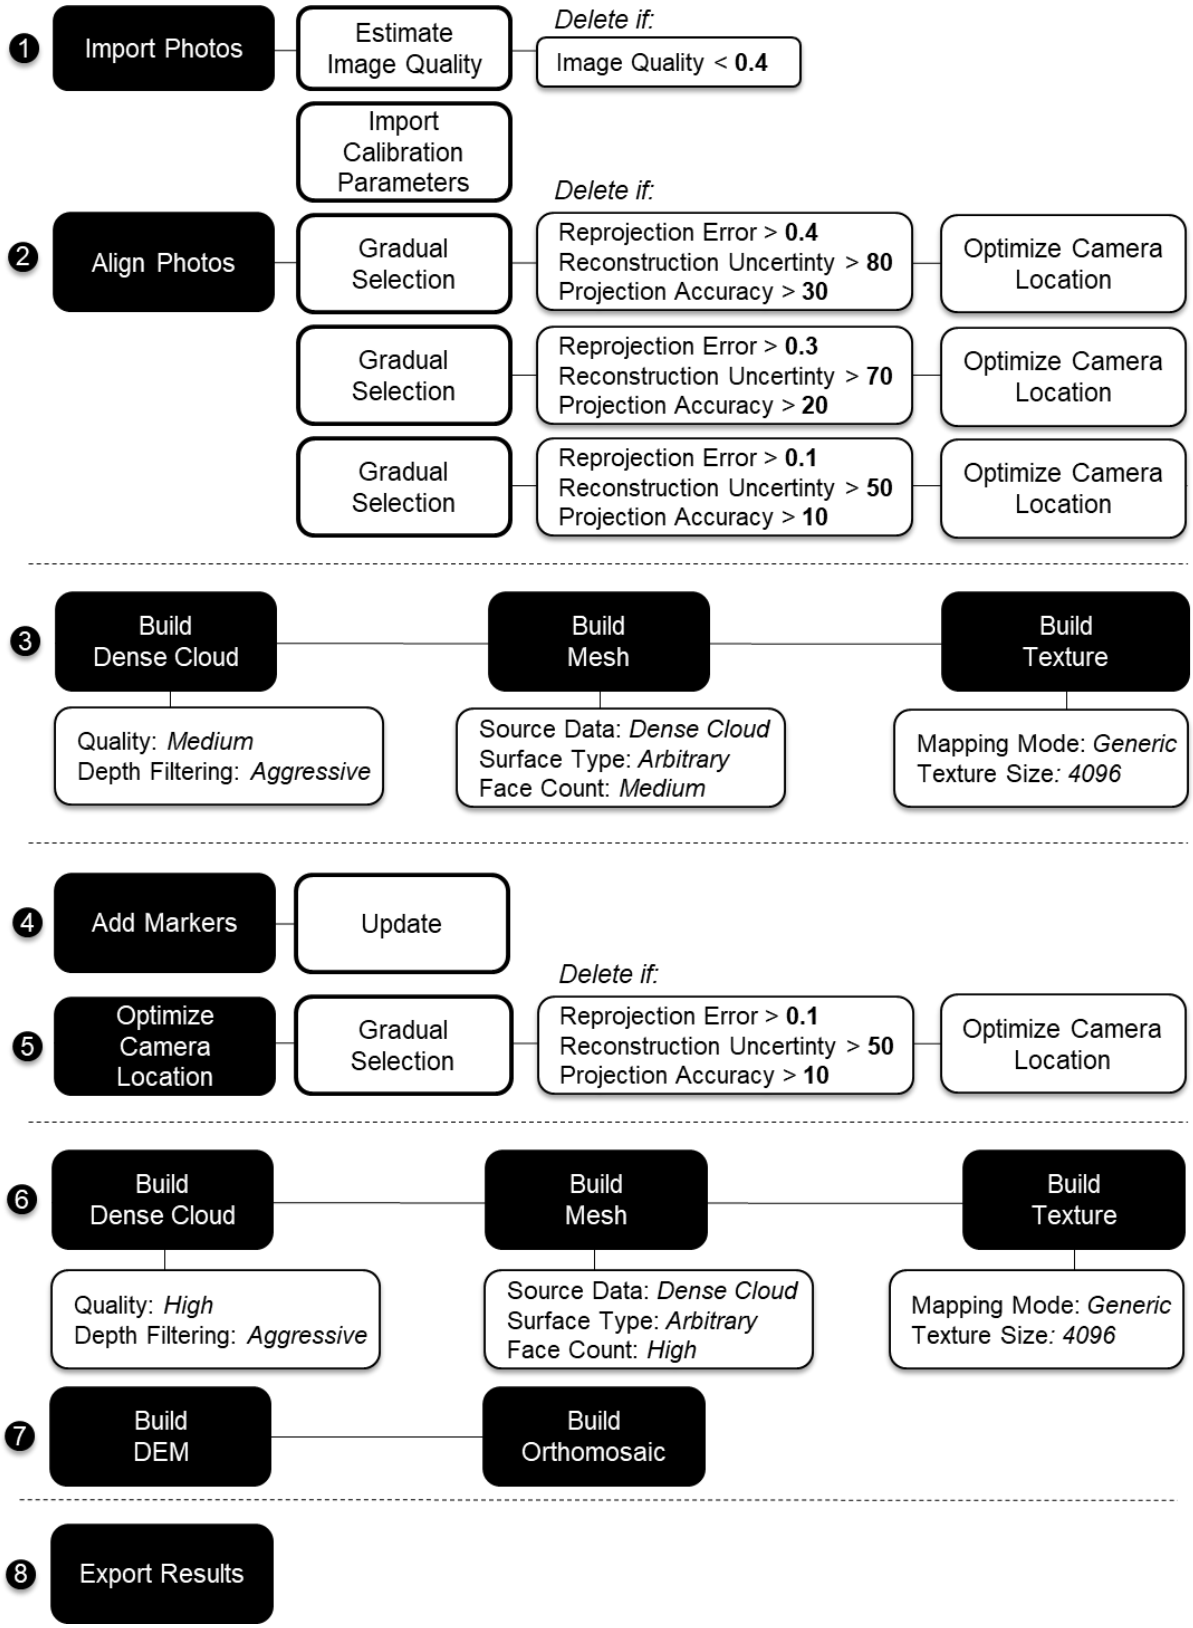

Slika 110. Proces obrade fotografija u *Agisoft Metashapeu 1.5.1*

3.3.8 Morfometrijske analize digitalnih modela sedre visoke rezolucije

Stopa prirasta sedre za svaku pločicu izračunata je iz digitalnih modela sedre submilimetarske rezolucije (eng. DTHRM) koristeći softver alat *Raster Calculator* u programu *Arc Map 10.1*. Prirast sedre po pločici predstavlja razliku između srednje vrijednosti visinskih uzoraka unutar MS-a (16 cm²) inicijalnog (nultog) modela te srednje vrijednosti visinskih uzoraka unutar MS-a završnog stanja. Ako je rezultat negativan došlo je do prirasta sedre, odnosno na specifičnom X, Y uzorku izmjerena je veća visina u odnosu na vrijednosti istog uzorka u inicijalnom (nultom) modelu. Ako je rezultat pozitivan došlo je do erozije sedre, odnosno na specifičnom X, Y uzorku u završenom modelu izmjerena je manja visina u odnosu na vrijednosti istog uzorka u inicijalnom (nultom) modelu (Slika 111).

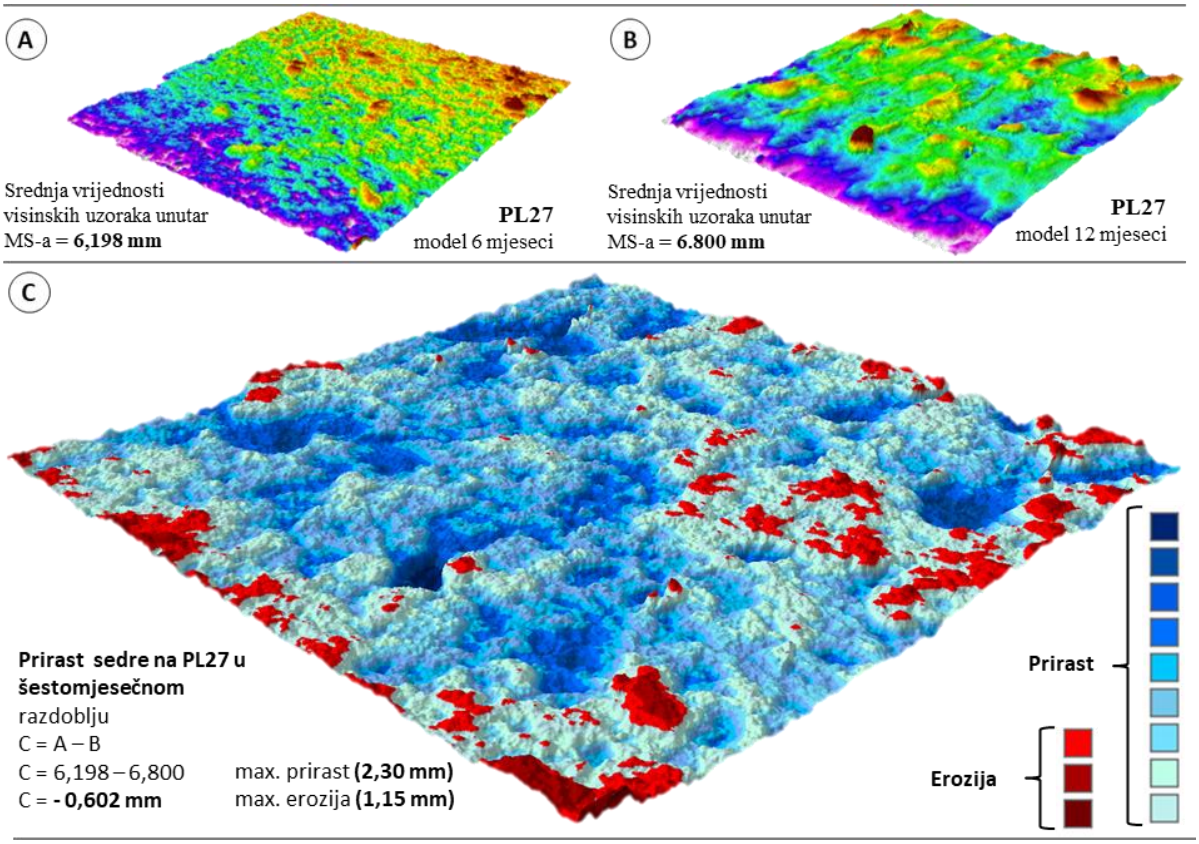

Slika 111. Shematski prikaz izračuna stope prirasta sedre

Volumetrijski prirast i erozija sedre izračunate su alatom *Cut Fill* koji utvrđuje promjene volumena između dvije ulazne površine. Prikazuje površinu i volumen koji su modificirani uklanjanjem ili dodavanjem površinskog materijala. Izračunati su za pločice koje su iz tokova vađene intervalno, svaka tri ili šest mjeseci. Detekcija erozije znači da u određenom intervalu mjerenja (tri ili šest mjeseci) nije došlo do dovoljno brze precipitacije kako bi se naknadnim taloženjem popunila mjesta u kojem je došlo do gubitka sedre.

Iz izvedenih podataka izračunat je intenzitet erozije i prirasta sedre po jedinici površine mm^2 koristeći formule a) i b). Intenzitet erozije ili prirasta je izražen kao prosječno smanjenje ili povećanje visine sedre na 1 mm^2 u prostoru detektirane promjene. Na slici 112 prikazan je primjer izračuna intenziteta erozije i prirasta sedre za PL13 u razdoblju od lipnja do rujna 2018. godine.

$$\text{a) } I_E = \frac{E_t}{P_e}, \quad \text{b) } I_P = \frac{P_t}{P_p} \tag{9}$$

gdje je:

I_E = intenzitet erozije sedre na pločici u specifičnom razdoblju

E_t = ukupni erodirani volumen (mm^3) na pločici u specifičnom razdoblju

P_e = površina pločice (mm^2) na kojoj je erodirani volumen (mm^3) detektiran

I_p = intenzitet prirasta sedre na pločici u specifičnom razdoblju

P_t = ukupni akumulirani volumen (mm^3) na pločici u specifičnom razdoblju

P_p = površina pločice (mm^2) na kojoj je akumulirani volumen (mm^3) detektiran

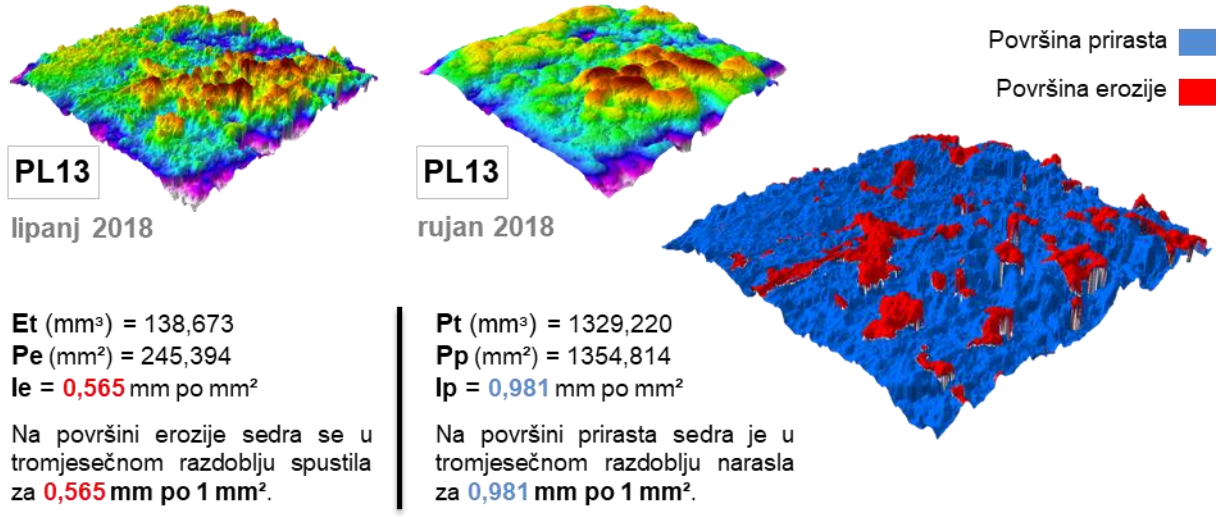

Slika 112. Primjer izračuna intenziteta erozije i prirasta sedre za PL13 (lipanj-rujan, 2018)

Primjer praćenja prirasta i erozije sedre prema specifičnim profilima izveden je alatima *Stack profile*. Vizualizacija 2.5D i 3D modela pločica izvedena je u programima *ArcScene* i *CloudCompare*. Generirani digitalni modeli submilimetarske rezolucije omogućuju izvođenje različitih morfometrijskih parametara na temelju kojih se pobliže može proučavati morfološka evolucija manjih uzoraka sedre.

4. REZULTATI ISTRAŽIVANJA

4.1 Makro razina

4.1.1 Terenska istraživanja šireg područja SB-a

Izvršeno je nekoliko terenskih obilazaka šireg područja SB-a uz stručno vodstvo Parka. Kroz nekoliko mjeseci, stalnim posjetima NPK, uočene su lokacije mogućeg prestanka sedrenja, isušeni tokovi te je inicijalno prepoznata najprimjerenija testna ploha za nastavak projektnih aktivnosti. Fotografirani su primjeri ugaslih tokova, stare sedre i lokacije na kojima je vidljivo da dolazi do usporavanja i izmjere smjera otjecanja sedrotvornih tokova uslijed nekontroliranog rasta invazivne vegetacije na rubnim dijelovima korita, antropogenog utjecaja itd (Slika 113). Uočeno je dosta potencijalnih lokacija koje mogu ukazivati na mogući proces prirodne eutrofikacije. Nadalje, detektiran je manji broj stabala koji su u sedrotvorne vodotokove pali uslijed vremenskih (ne)prilika te su djelomično blokirali protok vode.

Slika 113. Primjeri gašenja vodenih tokova uslijed nekontroliranog rasta vegetacije

Izvor: Terensko istraživanje, 12, svibanj, 2015

Na nekim lokacijama unutar šireg područja SB-a, izuzev nekontroliranog širenja invazivne vegetacije (Slika 114a-b), uočene su negativne hidrodinamične pojave koje su posljedica uslijed isključivo antropogenog utjecaja (izgradnja staze, odmarališta, utjecaj turista, akumulacija šljunka ispod mostova itd.) (Slika 114c-d, 115).

Slika 114. a) Invazivna vegetacija u blizini sedrotvornih tokova b) primjeri antropogenog utjecaja na hidrodinamiku sedrotvonih vodotokova

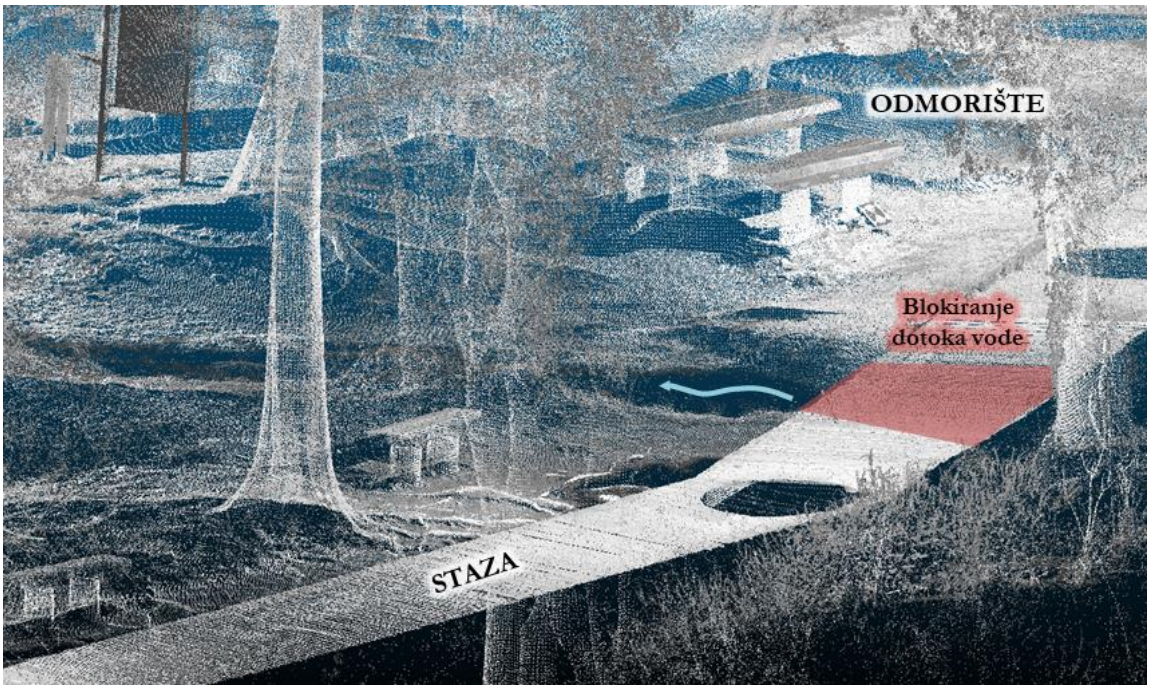

Slika 115. Blokiranje dotoka vode uslijed izgradnje staze

Ipak, uvidom u značajke šireg područja SB-a te distribucijom uočenih negativnih pojava zaključeno je da se treba odabrati manja testna ploha s dominantnim negativnim hidrodinamičkim pojavama (ugroženi održivi uvjeti sedrenja). Stoga je u nastavku istraživanja testna ploha odabrana primjenom GIS-MCDA na temelju definiranog skupa kriterija.

4.1.2 Digitalni model reljefa (DMR) šireg područja SB-a

Zračno skeniranje izvršeno je punovalnim laserskim mjernim sustavom Riegl LMS-Q780 s integriranom i GPS prijamnikom Novatel OEV/OEM4 internal. Rezolucija izvedenog modela iznosila je 0,3 m. Iz DMR-a cijelog NP „Krka“ izdvojen je DMR šireg područja SB-a oko 50 ha (Slika 116).

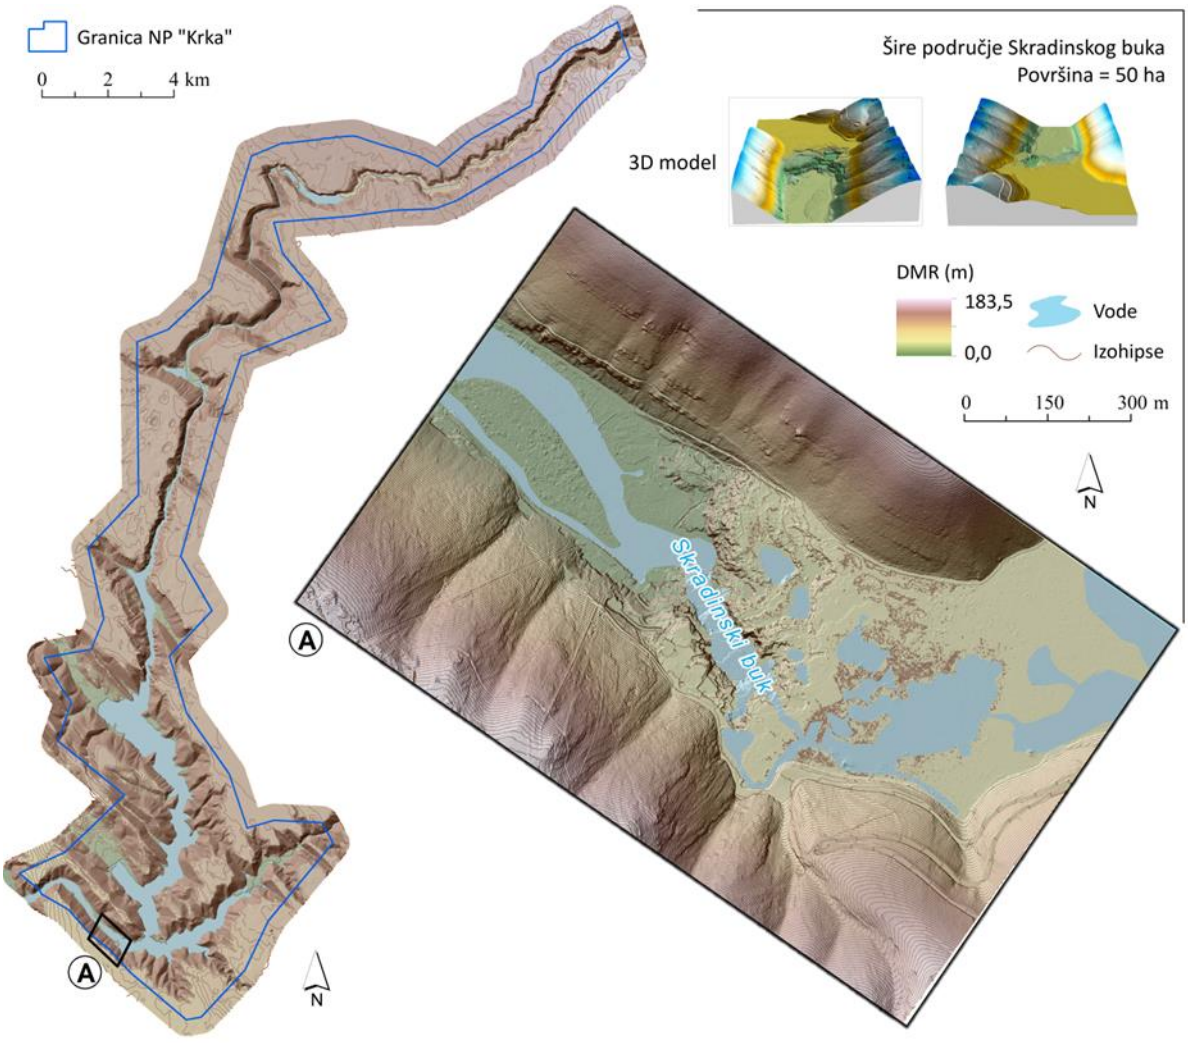

Slika 116. A) Izdvojeni dio DMR-a šireg područja SB-a

4.1.3 Georeferencirana A-U topografska karta šireg područja SB-a

Karta *Situations-plan des Krkafall-gebietes bei Scardona* georeferencirana je u poprečnoj Mercatorovoj projekciji. Prikazuje gotovo cijelo DMR područje šireg područja SB-a. Na temelju georeferencirane karte kartirani su vodeni tokovi koji su tad postojali na širem području SB-a. Na slici 117 prikazana je georeferencirana A-U karta s kartiranim vodenim površinama (tokovi i jezera) te akvaduktima. Prostor obilježava izrazito gusta mreža vodenih tokova koji povezuju veće aktivne akumulacije (Šupukovo jezero, Golubinka, Veliki vir, Veliko jezero, Draga, Dedinac itd.).

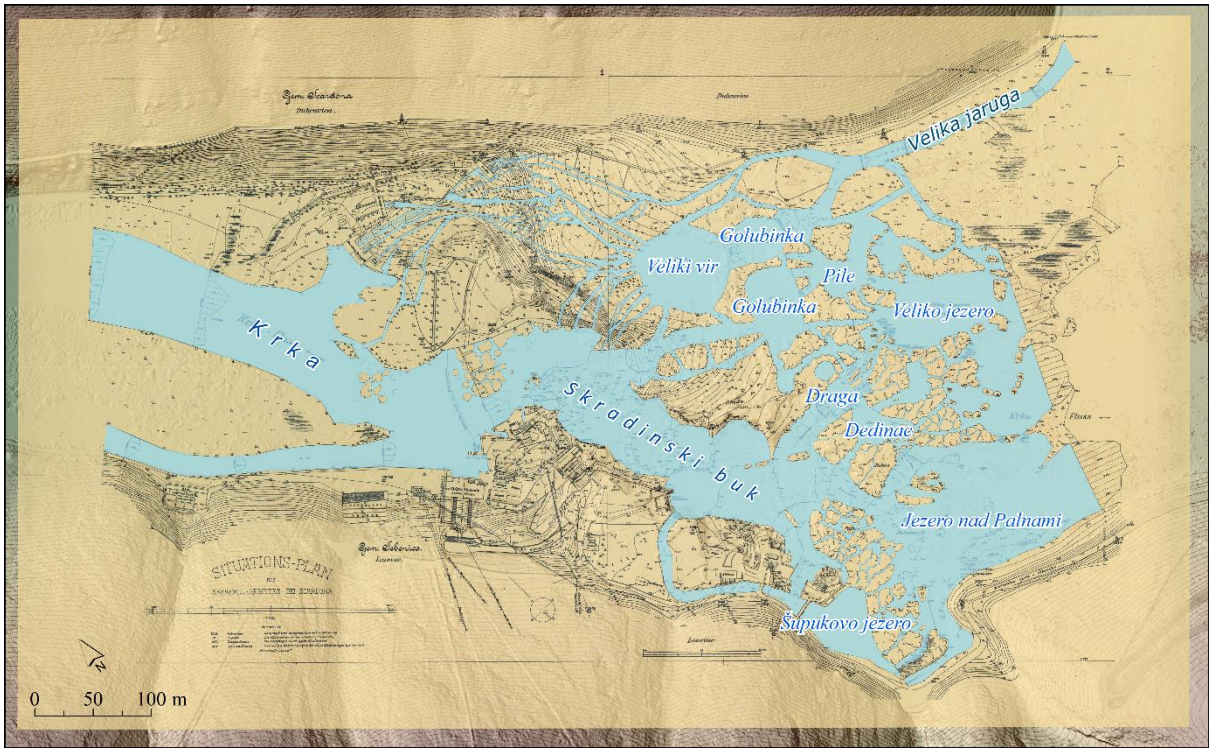

Slika 117. Georeferencirana A-U karta s kartiranim vodenim površinama

Izvor: Arhiv Nacionalnog parka „Krka“

4.1.4 Indeks pogodnosti testne plohe za šire područje SB-a

Finalni korak u GIS-MCDA je bio pretvaranje svih kriterija u rasterski tip podatka s jedinstvenom prostornom rezolucijom. Ona je u ovom slučaju iznosila 0,3 m. Razlog je prostorna rezolucija DMR-a koji je generiran na temelju podataka prikupljenih aero laserskim snimanjem. Višekriterijskom analizom generirana je karta (model) pogodnosti, odnosno definirane su zone koje su pogodne za praćenje promjena vegetacije, sedre i vodenih tokova. Model pogodnosti je generiran na temelju tri kriterija kojima su dodijeljeni različiti težinski koeficijenti. Najveći ponder pridodan je kriteriju pogodnost za snimanje (0,539), a najmanji nagibu (0,164). Raspon vrijednosti generalne pogodnosti za odabir mikrolokaliteta se kreće od

0 do 1. Vrijednosti su metodom jednakih intervala grupirane u 5 klasa. Svakoj klasi pridodani su opisni atributi: vrlo niska, niska, srednja, visoka i vrlo visoka (Slika 121). Indeks pogodnosti preklopljen je s podatkom o vodenim površinama vektoriziran na temelju A-U topografske karte te stazom koja se proteže kroz šire područje SB-a. Iz izvedenih podataka detektirana je potencijalna testna ploha za nastavak istraživanja (Slika 118).

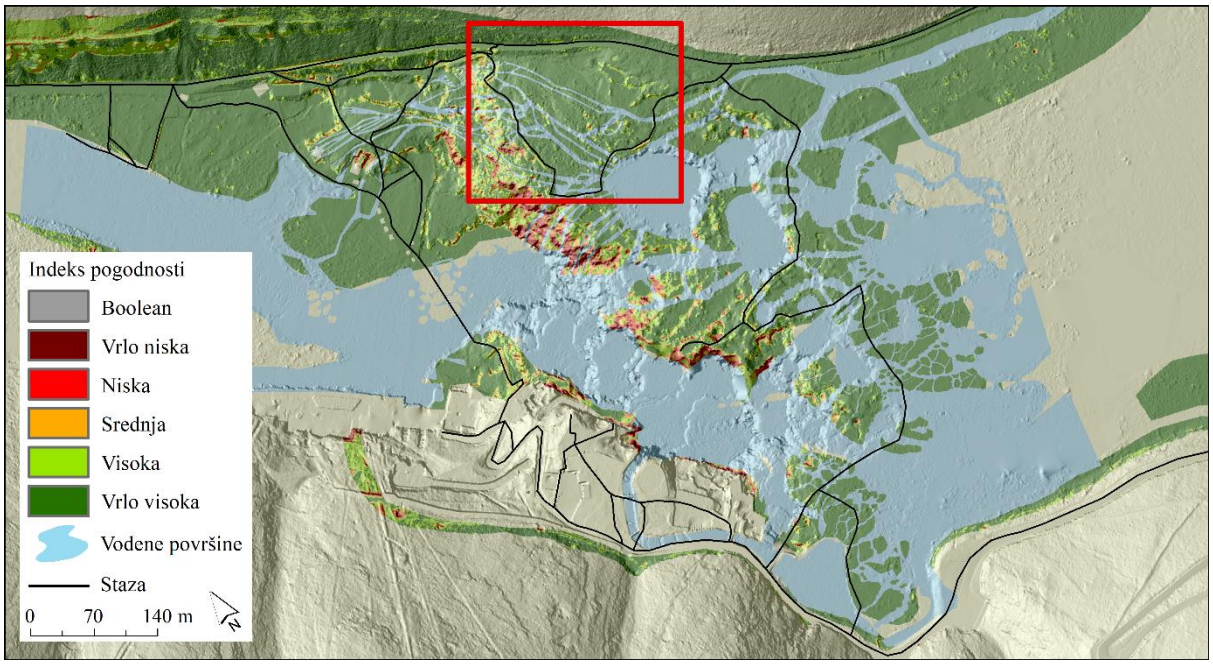

Slika 118. Indeks pogodnosti za odabir testne plohe na širem području SB-a

Testna ploha je predložena zbog sljedećih razloga: cijela je okružena sa stazom što omogućuje jednostavnije snimanje TLS-om, a površina od oko 0,8 ha spada u vrlo visoku ili visoku klasu pogodnosti. Nadalje, gotovo svi primjeri izmjene smjerova sedrotvornih vodotokova uslijed nekontroliranog rasta invazivne vegetacije te antropogenog utjecaja koji su navedeni u poglavlju *4.1.1 Terenska istraživanja šireg područja SB-a* nalaze se na odabranoj testnoj plohi.

Ipak, nakon inicijalnog odabira testne plohe primjenom GIS-MCDA izvršeno je još terenskih istraživanja na kojima su se pokušali detektirati tokovi koji prolaze kroz plohu, a vektorizirani su s A-U topografske karte. Na slici 119 crvenim poligonom označena je grupa tokova koji su detektirani na A-U topografskoj karti, ali su na testnoj plohi neaktivni uslijed gore navedenih razloga. Uzimajući u obzir brojna terenska istraživanja, GIS-MCDA analizu te tokove kartirane s A-U topografske karte, testna ploha površine od oko 0,8 ha sjeverno od Marasovića jezera, je odabrana kao najpogodnija za nastavak istraživanja.

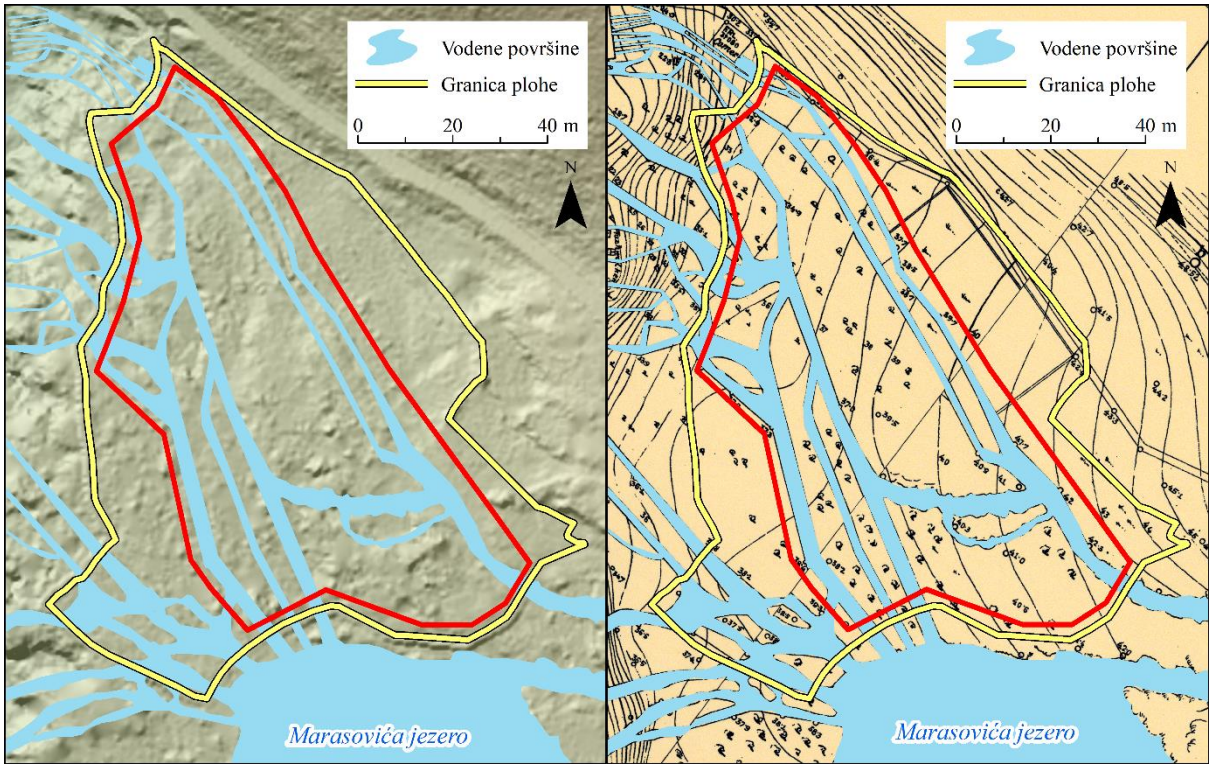

Slika 119. Presušeni tokovi kartirani s A-U karte na odabranoj testnoj plohi

4.2 Mezo razina

4.2.1 Model mreže površinskog otjecanja testne plohe

Model površinskog otjecanja testne plohe generiran je na temelju hibridnog modela (aeroLiDAR + TLS). Kao povremeni i stalni tokovi izdvojeni su oni elementi grida koji imaju vrijednost akumulacije veću od 600. Na slici 120a prikazana je mreža površinskog otjecanja izvedena iz hibridnog DMR-a. Mreža površinskog otjecanja je ispravljena i nadopunjena terenskim istraživanjem. Kartiranje (ispravljene) mreže otjecanja, odnosno korekcija, nadopunjavanje i klasificiranje tokova je izvedeno pomoć *RTK-GPS uređaja STONEX 10* i analogne karte s označenim tokovima. Na slici 120b prikazana je korigirana mreža površinskog otjecanja testne plohe koja predstavlja referentno stanje tokova prije intervencije. Mreža površinskog otjecanja je nadopunjena te je za svaki tok dodan atribut stanja (aktivno ili neaktivno). Aktivni tokovi se na testnoj plohi nalaze na južnoj i istočnoj strani. Detektirano je mnogo presušenih tokova i depresija koji su kao aktivne vodene površine označene na A-U topografskoj karti. U razgovoru sa stručnim osobljem Parka doznalo se da su neki tokovi na plohi te slap koji se nalazi ispod sjeverno-istočnog dijela presušili prije nekoliko godina.

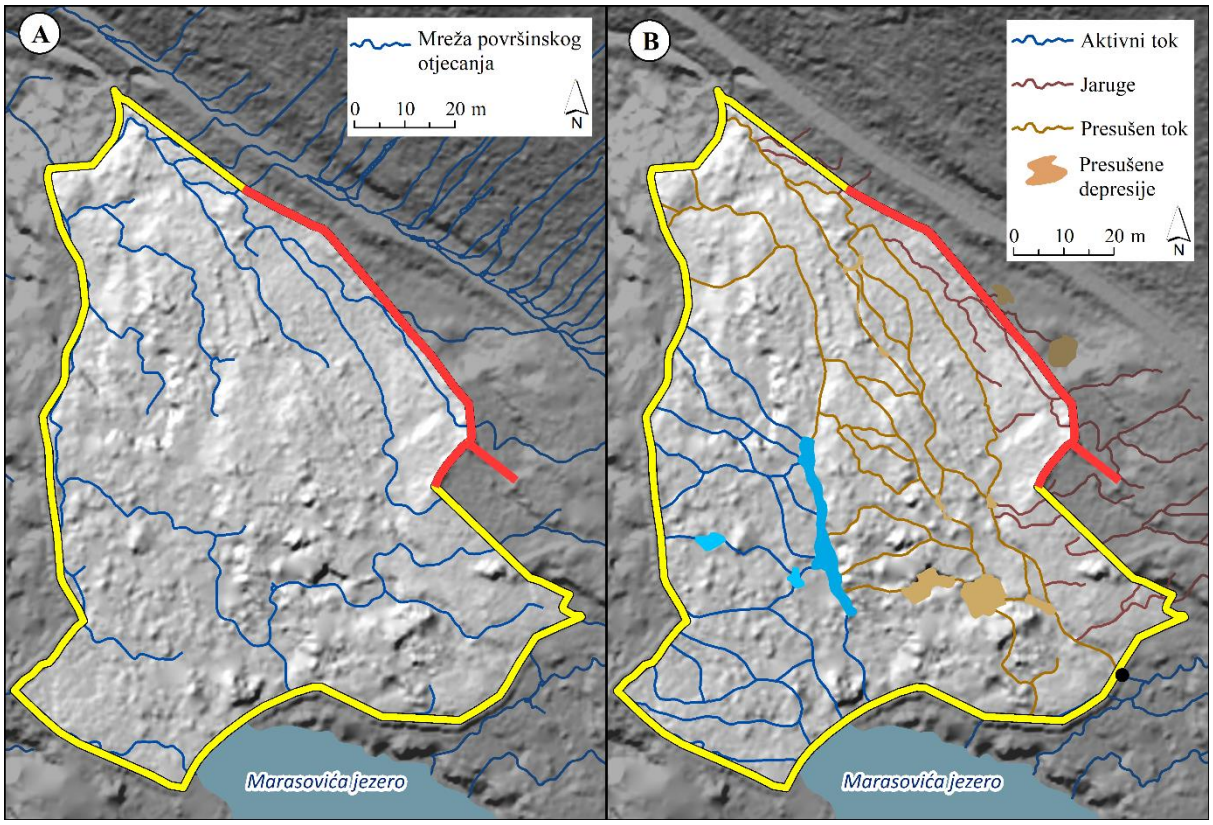

Slika 120. A) model mreže površinskog otjecanja testne plohe izveden iz hibridnog modela B) korigirana mreža površinskog otjecanja (referentno stanje tokova)

4.2.2 Katastar stabala nultog stanja testne plohe

Nakon odabira testne plohe, kartiranja referentnog stanja mreže površinskog otjecanja izvršeno je i kartiranje nultog stanja vegetacije. Ukupno je kartirano 358 stabala u 15 različitih vrsta (Tablica 26).

Tablica 25. Katastar stabala odabrane testne plohe

Vrsta drveća	Broj stabala	Postotak (%)
Javor (*Acer monspessulanum)*	1	0,28
Pajasen (*Ailanthus altissima*)	72	20,11
Crna joha (*Alnus glutinosa*)	1	0,28
Dudovac (*Broussonetia papyrifera*)	7	1,96
Crni koprivić (*Celtis australis*)	51	14,25
Smokva (*Ficus carica*)	31	8,66
Poljski jasen (*Fraxinus angustifolia*)	69	19,27
Crni jasen (*Fraxinus ornus*)	15	4,19
Bijela murva (*Morus alba*)	5	1,39
Mrtvo	15	4,19
Crni grab (*Ostrya carpinifolia)*	85	23,74
Alepski bor (*Pinus halepensis*)	1	0,28
Crna topola (*Populus nigra*)	3	0,84
Rašeljka (*Prunus mahaleb*)	1	0,28
Bijela vrba (*Salix alba*)	1	0,28
UKUPNO	**358**	**100**

Uz crni grab, pajasen je na testnoj plohi najzastupljenija vrsta s 20,11% (Tablica 26). Ako se u obzir uzmu sve kategorije pajasena prema starosti, on je najzastupljenija vegetacijska vrsta na testnoj plohi (Slika 121).

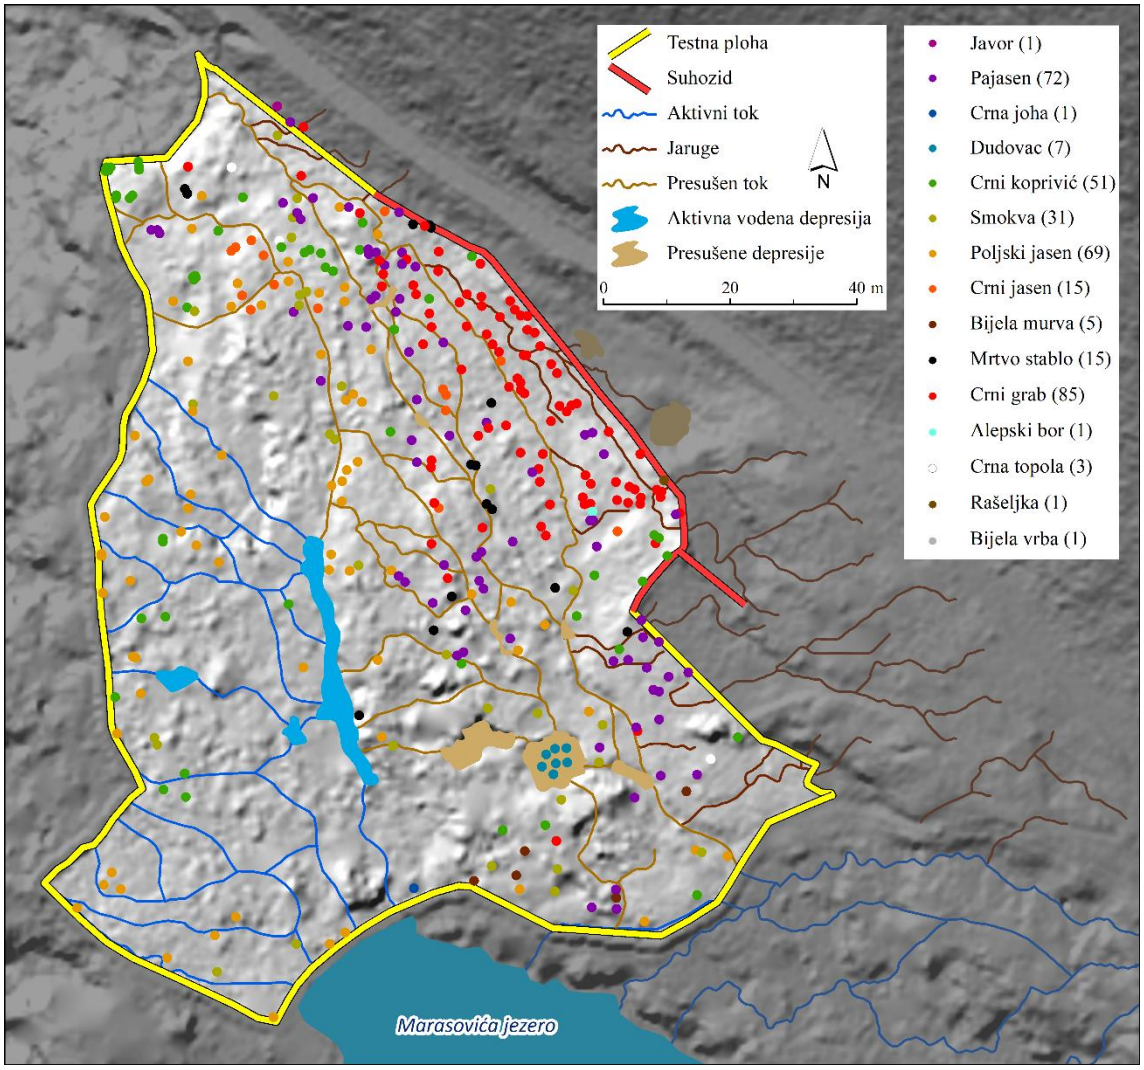

Slika 121. Katastar stabala nultog stanja testne plohe

Prema dominantnim vegetacijskim vrstama testna ploha je podijeljena u četiri zone (Slika 122). U prvoj zoni brojnošću dominira crni grab (*Ostrya carpinifolia Scop.*). U južnom dijelu zone čest je i pajasen (*Ailanthus altissima (Mill.) Swinge*). U sloju grmlja dolazi pajasen, crni grab *(Ostrya carpinifolia Scop.*), bršljan (*Hedera helix L.)* i kurika (*Euonymus europaeus L.).* Ova zona je prema mikroreljefu najviša i u njoj je najranije došlo do prestanka tijeka vode. U dijelu bližem odmorištu jači je antropogeni utjecaj, tj. rjeđi je sklop krošanja koji omogućava veću prisutnost invazivnog pajasena.

U drugoj zoni najbrojnija vrsta među dominantnim stablima je pajasen i poljski jasen (*Fraxinus angustifolia Vahl.)* te u jednom dijelu zone i smokva (*Ficus carica L.*). Ta zona je s povremenim tokom vode nešto vlažnija od prethodne i u njoj su jači antropogeni utjecaji pa je rjeđeg sklopa krošanja, što omogućava jače naseljavanje invazivne vrste pajasen. U trećoj zoni prevladava smokva (*Ficus carica L.),* a drugo drvo po brojnosti je koprivić (*Celtis australis L.*). Ovo je mješovita zona s promjenjivom vlažnosti. Također je mjestimično prorijeđenog

sklopa krošanja te ima i nekoliko stabala invazivnog pajasena. Posljednja, četvrta zona ima nekoliko stalnih tokova vode te je najvlažnija. Tu prevladavaju vrste drveća koje inače dolaze na povremeno (čak i dulje) poplavljivanim staništima. Najbrojniji je poljski jasen (*Fraxinus angustifolia Vahl.*). To je vrsta koja može podnijeti i višemjesečnu stagnaciju vode. Po brojnosti je iza njega smokva. U sloju niskog drveća i grmlja tu se u većem broju nalazi i dudovac (*Broussonetia papyrifera (L.) Vent.).* To je vrsta porijeklom iz Azije, koja se u nekim područjima smatra invazivnom vrstom.

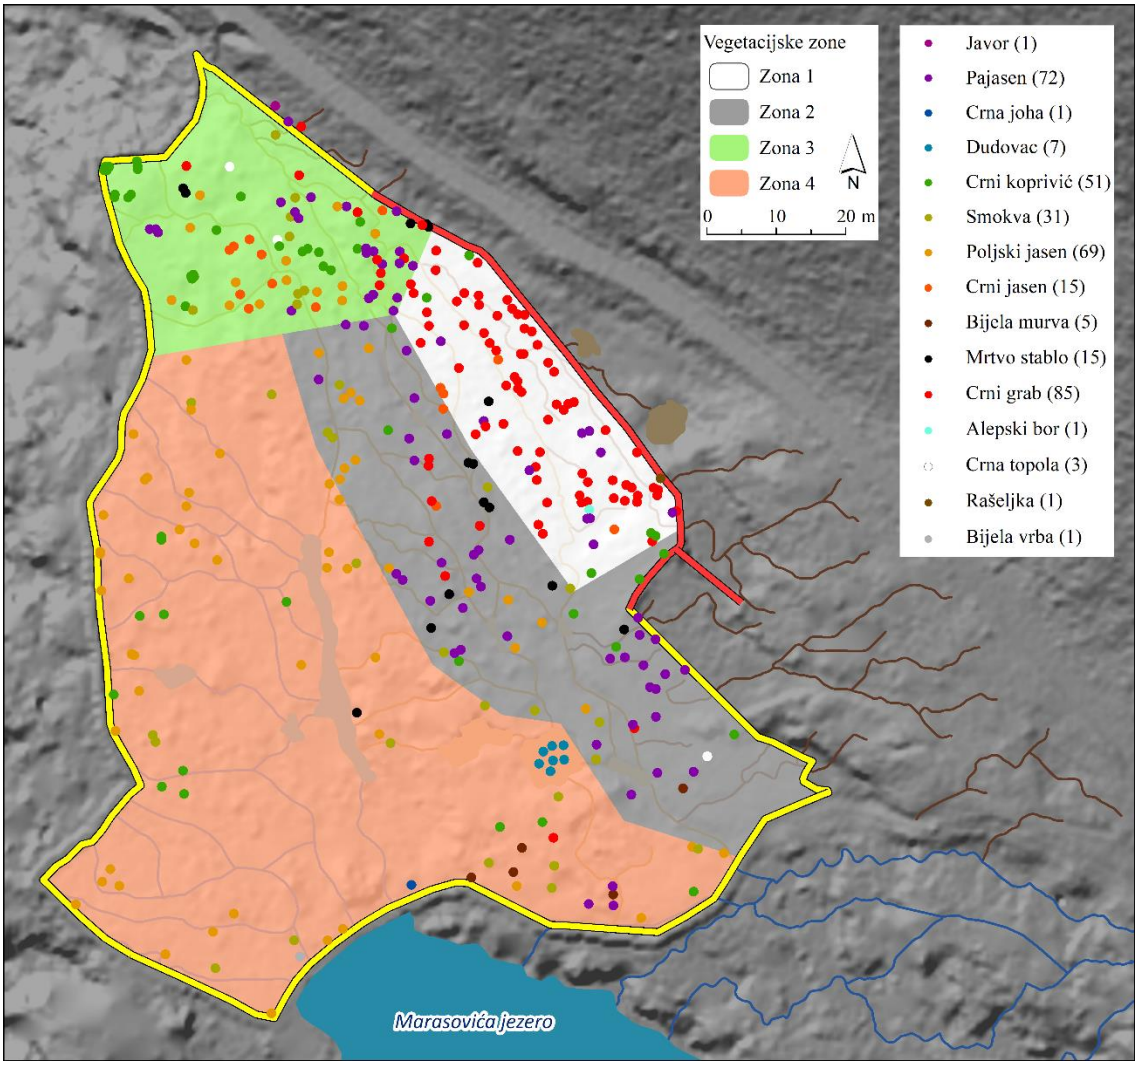

Slika 122. Vegetacijske zone testne plohe prema dominantnim vrstama

Vegetacija je na odabranoj plohi razvijena u obliku visoke šume - stabla su visine do oko 20 m, a mjestimično ima dijelova s mlađim i tanjim stablima. Sloj grmlja je intenzivno razvijen dok je sloj niskog rasta rijedak. U svrhu obnove uvjeta sedrenja u sedrotvornim tokovima u kojima voda ne teče već duže vrijeme ili samo povremeno uslijed visokih vodostaja potrebno je ukloniti i izvući palo, mrtvo drveće te sve vrste pajasena s testne plohe. Nakon

uklanjanja većih biljnih elemenata trebalo bi se ukloniti akumulirani biljni materijal koji je zatrpao suhe, ali recentno aktivne vodotoke. Nadalje, uklanjanje antropogeno akumuliranog šljunka ispod mostića kod odmorišta koji blokira glavni dotok prepoznat je kao zahvat koji je potrebno napraviti da bi se omogućilo ponovno protjecanje vode.

4.2.2 Promjene na plohi nakon selektivnog uklanjanja vegetacije

Selektivno uklanjanje vegetacije izvršeno je u lipnju, 2017, prema vegetacijskim zonama testne plohe. Uklanjanje je izvršila stručna služba NP „Krka“ nakon što je Uprava parka dobila dozvolu od *Ministarstva zaštite okoliša i energetike*. S testne plohe su uklonjene svi mladi sjemenjaci, stabalca i stabla pajasena. Koristila se ručna i mehanička metoda uklanjanja pajasena. S testne plohe je uklonjeno svih 72 pajasena koji su imali promjer veći od 15 cm te je iščupan velik broj mladica.

Selektivnim uklanjanjem vegetacije na testnoj plohi su se dogodile mikromorfološke promjene. S obzirom na izrazito slabu vertikalnu raščlanjenost terena (do 5 cm na 1 m^2), posebice na dijelovima koji su uvjetovali usmjeravanje tokova vode, uklanjanje pajasena te akumuliranog biljnog materijala koji je zatrpao suhe tokove, direktno je utjecalo na promjenu hidrološke mreže (Slika 123). Kombinacijom intenzivnijih oborina s pojačanim protokom vode (uklonjen šljunak ispod mosta kraj odmorišta u blizini Marasovića jezera) (Slika 124A) uslijedio je proces spiranja dijela materijala (prvenstveno lišća) i reaktiviranja presušenih tokova (Video1).

Slika 123. Isječci iz videa u kojem je snimljen proces reaktivacije tokova

Ti stari tokovi su najprije uočeni na georeferenciranoj A-U karti iz 1883. godine, a zatim su detaljno kartirani u ranijim fazama istraživanja (prije selektivne sječe vegetacije) na temelju podataka koji su prikupljeni aero i terestričkom laserskom izmjerom, geodetskim GPS uređajem i terenskim istraživanjem (Slika 124I). U drugoj polovici studenog 2017. godine, nakon što je voda svojim djelovanjem odnijela akumulirani materijal iz presušenih tokova, izvršeno je novo kartiranje vodenih tokova (Slika 124II) na testnoj plohi s ciljem utvrđivanja promjena koje su nastale nakon sustavnog uklanjanja vegetacije (Slika 124B-C). Kartiranje je izvršeno fuzijom podataka koji su prikupljeni terenskim istraživanjem (RTK-GPS, analogna karta) i aerosnimanjem (primjenom bespilotne letjelice).

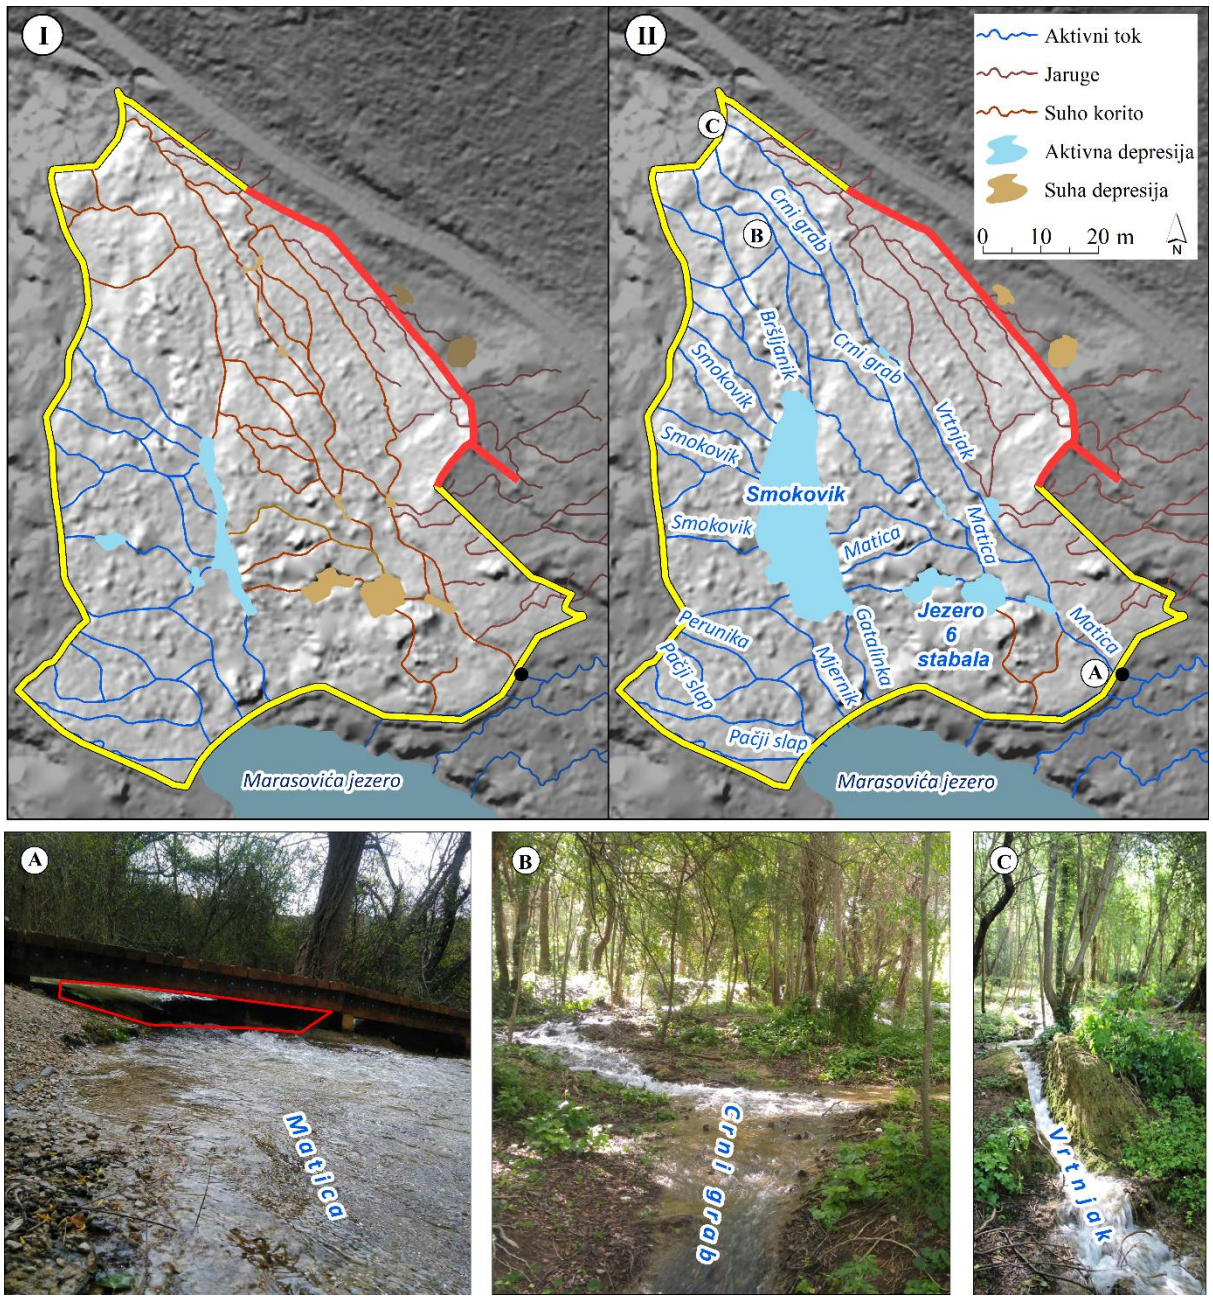

Slika 124. Primjeri promjena (A, B i C) hidrološke mreže na testnoj plohi

Na slici 125 na temelju intervalnih DOF-ova prikazan je primjer promjene izgleda testne plohe nakon uklanjanja pajasena (Slika 125A) i reaktivacija toka Matice-Vrtnjak (Slika 125B). Zbog velike gustoće vegetacije aerofotogrametrija se nije pokazala kao najbolje rješenje za praćenje vegetacijskih i hidroloških promjena. Od svih hidroloških promjena na drugom DOF-u mogu se uočiti samo promjene na navedenom toku te smanjena količina vegetacije na Pačjem slapu.

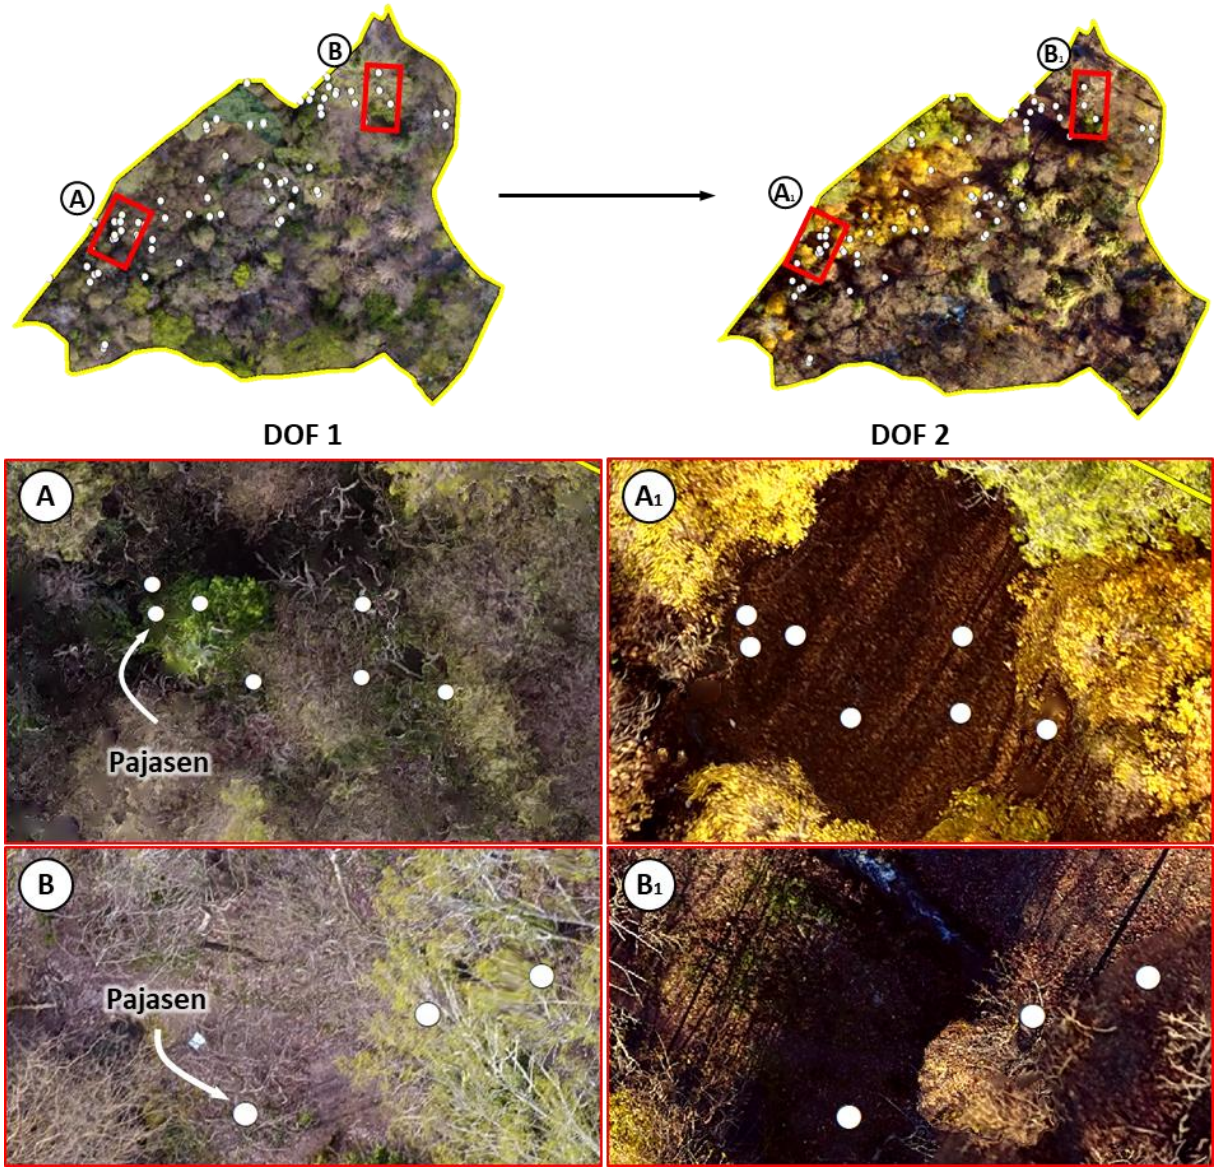

Slika 125. Primjeri promjena na testnoj plohi vidljivi iz zraka

Svim tokovima (starim aktivnim i novim reaktiviranim) su dana nova imena: *Vrtnjak, Crni grab, Bršljanik, Matica i Smokovik.* Na plohi su reaktivirana dvije jezerca: *Smokovik* i *Jezero 6 stabala.* U hladnijem dijelu godine zabilježeno je izlijevanje vode (Slika 126) iz oba

jezerca te spajanje s tokovima *Smokovika, Bršljanika* i *Matice* zbog čega točno kartiranje granica jezera i tokova nije bilo moguće.

Slika 126. Poplavljivanje vode iz akumulacije Smokovik sve do zapadne granice plohe

4.2.3 Rezultati cikličnog fotografiranja testne plohe

Na odabranu testnu plohu je nakon reaktiviranja tokova postavljena intervalna HD lovačka kamera. Cilj postavljanja kamere je bio pratiti rast i razvoj pajasena nakon njegovog uklanjanja kroz duže razdoblje, pomoću intervalnih snimaka. Kamera je za tu svrhu postavljena na dvije lokaciju u blizini *Kod mladog jasena* (Slika 127A) te u neposrednu blizinu odmarališta (Slika 127B), najbliže lokaciji *Bezimena*. Na obje lokacije ukupno je prikupljeno preko 6000 fotografija. Kamera je postupno pomicana na nekoliko lokacija na kojima su se prije selektivnog uklanjanja vegetacije nalazile velike količine pajasena. Međutim, iz intervalnih fotografija nije uočena značajnija regeneracija pajasena na testnoj plohi. Razlog tome je sljedeći. Uslijed reaktivacije tokova, pojačanog dotoka vode ispod mosta, došlo je do povremenog poplavljivanja većih površina na plohi (Slika 128). Zabilježena je reaktivacija nekih suhih tokova i jaruga iznad toka *Vrtnjak*. Takvo okruženje nije pogodovalo pajasenu s obzirom na to da on ne podnosi dugotrajno vlažna i poplavljena tla (Miller, 1990, Fryer, 2010, Wenning, 2014).

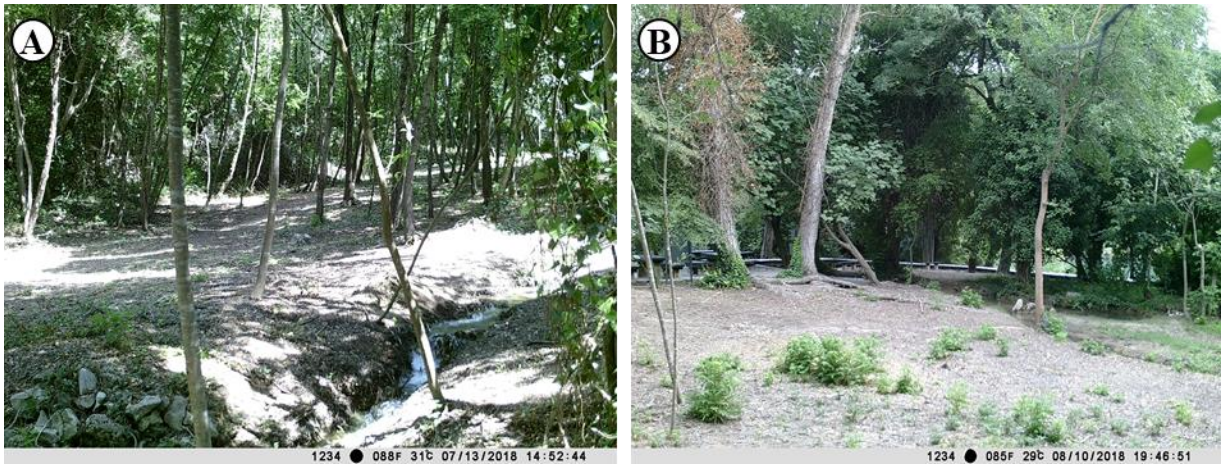

Slika 127. Primjeri intervalnih fotografija na kojima je praćena pojava pajasena

Slika 128. Primjer poplavljivanja testne plohe

Poslije šest mjeseci praćenja pojavnosti pajasena kamera je premještena na lokaciju izvan odabrane testne plohe (SZ dio), nedaleko od stare vodenice, blizu lokacije slapa koji je posljednjih godina bio presušen (Slika 129A). Time se htjelo utvrditi hoće li reaktivirani slap postati atraktivna lokacija za posjetitelje. Navedeno je iz intervalnih snimaka i utvrđeno (Slika 129B).

Slika 129. A) Reaktivirani slap izvan testne plohe B) posjetitelji slapa snimljeni intervalnom kamerom

4.2.4 Brzina protoka vode na testnoj plohi

Brzina protoka vode na testnoj plohi je praćena na sedam lokacija (P1-P7) (Tablica 27). Na lokacijama P2, P3 i P4 voda je tekla prije uklanjanja vegetacije. Na lokacijama P1, P5, P6 i P7 prije intervencije nije vodenog toka. Lokacije mjerenja protoka pokrivaju sve glavne dotoke vode na testnu plohu, ključne vodene tokove na plohi i otjecanje vode s plohe. U listopadu i prosincu brzina nije izmjerena zbog neispravnosti uređaja.

Tablica 26. Brzina protoka (m/s) prema lokacijama mjerenja

	03/18	**04/18**	**05/18**	**06/18**	**07/18**	**08/18**	**09/18**	**11/18**	**01/19**	**02/19**	**03/19**	**MEAN**	**SD**
P1	0,317	1,512	0,956	1,18	0,561	0,417	0,711	0,828	0,954	1,484	0,943	**0,897**	**0,391**
P2	0,782	0,386	0,211	0,28	0,320	0,123	0,073	0,577	0,129	0,456	0,216	0,323	0,215
P3	0,329	0,194	0,102	0,10	0,084	0,061	0,050	0,185	0,084	0,195	0,023	0,128	0,089
P4	0,353	0,111	0,046	0,04	0,031	0,038	0,039	0,107	0,039	0,273	0,053	**0,103**	**0,109**
P5	0,414	0,745	0,564	0,62	0,455	0,383	0,318	0,480	0,621	0,633	0,684	0,538	0,136
P6	0,295	0,856	0,881	0,80	0,527	0,567	0,707	0,446	0,516	0,705	0,442	0,613	0,190
P7	0,381	0,762	0,879	1,28	1,128	0,964	0,431	0,537	1,088	0,695	0,742	0,808	0,292

U jednogodišnjem razdoblju najbrži protok vode je u prosjeku bio na lokacijama P1 i P7. Potrebno je istaknuti da u navedenom razdoblju nije došlo do presušenja lokacija (P1, P5, P6 i P7) koje su prije uklanjanja vegetacije bile neaktivne. Na lokaciji P1 zabilježena je najveća vrijednost protoka vode (1,51 m/s), dok je na lokaciji P4 zabilježena najmanja (0,03 m/s). Na slici 13o. prikazan je godišnji hod brzine protoka prema odabranih lokacijama. Na svim lokacijama najmanje vrijednosti su izmjerene u srpnju i kolovozu. Lokacija P1, u blizini odmorišta, predstavlja glavni dotok vode na testnu plohu. Lokacija P7 je smještena iznad *Sedrenog kanjona* gdje je tok uži. Najmanja brzina protoka očekivano je zabilježena na lokacijama dotoka vode (P2, P3 i P4) iz *Marasović jezera.*

Kao jedan od osnovnih uvjeta nastanka sedre navedena je brzina protoka vode. Neki autori navode da brzina veća od 1,5 ili čak 0,8 m/s (donja granica) može erozivno utjecati na površinu sedre. Vrijednosti veće od 1,5 m/s zabilježene su samo u travnju, 2018. godine na lokaciji P1. Vrijednosti brzine protoka na lokacijama P1 i P7 ukazuju na to da tok *Vrtnjak* ima potencijalna erozivna svojstva. Naime, prosječna brzina protoka na navedenim lokacijama iznosila je 0,897 i 0,808 m/s.

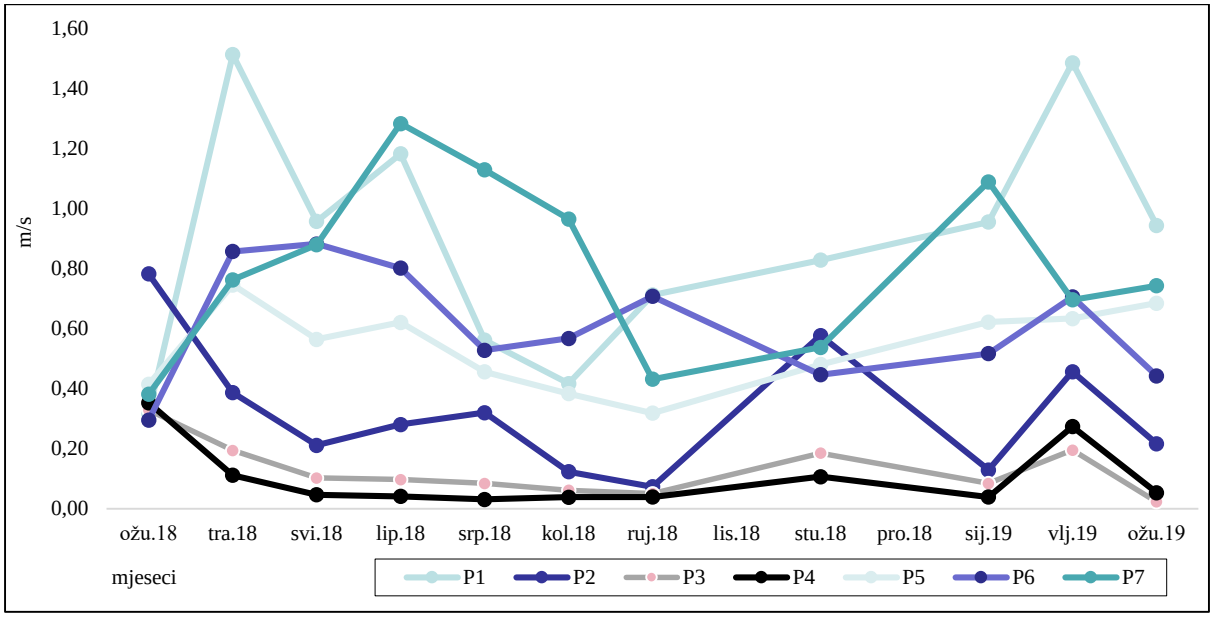

Slika 130. Kretanje brzine protoka prema odabranim lokacijama u razdoblju ožu.18-ožu.19

Podaci o brzini protoka korišteni su kao sekundarni kriterij u klasifikaciji fluvijalnih okruženja u koja su postavljene pločice. Prvi kriterij je bio vizualna interpretacija mikro lokacije. Primjerice, na lokacijama *Sedreni kanjon* i *Jezerski slapić* pločice nisu u potpunosti uronjene u vodu, već se nalaze u zoni prskanja. Stoga, brzinu protoka vode točno na toj lokaciji nije bilo moguće mjeriti. Njihovo fluvijalno okruženje stoga je klasificirano kao zona prskanja (SZ). Nadalje, pločice na lokacijama *Pačji slap*, *Nježna mahovina* i *Krivo stablo* su postavljene

na rub sedrene kaskade u blizini mahovina. Mjerenje brzine protoka na nekim od tih lokacija ljeti nije bilo moguće zbog dubine vode koja bi pala ispod 30 cm, a zimi bi bila ugrožena sigurnost operatora uslijed pojačanog protoka na kaskadi. Stoga je s obzirom na vizualnu sličnost njihovo fluvijalno okruženje klasificirano kao stepenasta kaskada (SC). Klasifikacija fluvijalnog okruženja *Jezera šest stabala* je bila najjednostavnija jer se radi od stagnantnoj vodi (SW). Preostale lokacije, koje ne spadaju u nijednu od spomenute tri kategorije su klasificirane u spori (0,102 - 0,322 m/s - SFW), srednji (0,323 - 0,612 m/s -MFW) i brzi protok vode (0,613 - 0,897 m/s - FFW). Granice klasa između kategorija su određene na temelju *Jenksove* metode klasifikacije.

4.2.5 Fizikalno-kemijska obilježja vode na testnoj plohi

U tablici 28 prikazani su grupirani podaci 14 parametara koji su u intervalu od 15 min prikupljani kroz jednogodišnje razdoblje (svibanj, 2018. - svibanj, 2019). U analizi fizikalno-kemijskih obilježja vode od svih raspoloživih podataka korištena su samo četiri parametara (ODO % sat, ODO mg/L, Temp °C, pH, ORP mV). Razlog tome je uočena pojava osedravanja sonde koja je rezultirala velikom varijacijom u prikupljenim podacima za sljedeće parametre: *SpCond µS/cm, Turbidity FNU, Chlorophyll RFU, Chlorophyll µg/L, BGA-PC RFU, BGA-PC µg/L, fDOM RFU te fDOM QSU.* Na godišnjoj razini neke su se vrijednosti razlikovale za faktor veći od 200 (Tablica 28).

Primjerice, specifičan konduktivitet za svibanj, 2018. godine iznosi 517,27 µS/cm. Nakon toga dolazi do naglog padanja vrijednosti sve do siječnja, 2019. kad je izmjerena vrijednost od 10,76 µS/cm. Smanjenje konduktiviteta vode može biti posljedica izrazite precipitacije $CaCO_3$, ali u ovom slučaju radi se o prevelikom faktoru promjene. Ako se izmjerene vrijednosti usporede s onima u drugim aktivnim sedrotvornim sustavima jasno je da su ovi rezultati posljedica neispravnosti senzora na sondi. Belančić i dr. (2009) unutar NP "Plitvička jezera" mjere vrijednosti od 362 do 363 µS/cm^{-1}. Arenas i dr. (2010) su za rijeku Piedru (Španjolska) izmjerili vrijednosti od 630 do 670 µS/cm^{-1} dok Auqué i dr. (2013) navode vrijednosti od 555 do 876 µS/cm^{-1}. Za rijeku Anamaza (Španjolska) Auqué i dr. (2014) bilježe konduktivitet od 694 µS/cm^{-1} do 866 µS/cm^{-1}. Ridl (2015) je maksimalne vrijednosti konduktiviteta na Skradinskom buku izmjerila u listopadu (524 µS/cm^{-1}), dok je minimum zabilježen u veljači (479 µS/cm^{-1}). S obzirom na sve navedeno odlučeno je da gore spomenuti parametri budu isključeni iz analize.

Tablica 27. Grupirani podaci izmjerenih parametara

M/G	ODO % sat	ODO mg/L	Temp °C	SpCond µS/cm	Sal ppt	Turbidity FNU	Chloro. RFU	Chloro. µg/L	BGA-PC RFU	BGA-PC µg/L	fDOM RFU	fDOM QSU	pH	ORP mV
05/18	**94,38**	8,80	18,68	517,27	0,25	0,76	0,25	1,01	0,44	0,55	1,36	4,09	**8,37**	**206,7**
06/18	90,08	8,10	20,50	459,50	0,22	2,15	0,38	1,53	-0,29	-0,29	1,70	5,11	8,38	345,1
07/18	86,68	7,34	23,69	376,06	0,18	4,31	0,56	2,23	-0,31	-0,31	1,65	4,95	8,42	357,3
08/18	82,44	6,73	**25,59**	253,15	0,12	8,84	0,72	2,86	-0,24	-0,24	1,52	4,56	8,40	368,0
09/18	74,68	**6,49**	22,30	165,56	0,08	6,98	0,60	2,41	-0,21	-0,21	1,77	5,30	8,51	374,3
10/18	**72,80**	6,96	17,52	88,03	0,04	7,24	0,86	3,43	-0,12	-0,12	2,34	7,01	8,57	390,5
11/18	72,86	7,44	14,42	43,38	0,02	6,37	1,16	4,64	-0,04	-0,04	2,53	7,60	8,65	414,2
12/18	73,08	8,23	10,13	10,39	0,00	5,23	0,38	1,51	-0,15	-0,15	3,28	9,85	8,65	438,7
01/19	76,00	9,21	**7,06**	10,76	0,00	183,73	4,11	16,44	1,07	1,07	8,05	24,14	8,77	**450,9**
02/19	91,57	**10,53**	9,17	288,94	0,14	53,21	1,91	7,66	0,24	0,24	4,86	14,59	8,79	363,3
03/19	92,16	10,28	10,45	349,98	0,17	3,16	0,69	2,76	-0,17	-0,17	2,15	6,46	8,80	349,4
04/19	93,31	9,75	13,36	400,54	0,19	2,71	0,61	2,42	-0,21	-0,21	1,50	4,50	8,79	325,0
05/19	94,24	9,40	15,46	482,70	0,23	1,46	0,31	1,25	-0,27	-0,27	1,54	4,62	**8,94**	322,4
MEAN	**84,04**	**8,34**	**16,32**	**278,34**	**0,13**	**20,61**	**0,93**	**3,72**	**-0,04**	**-0,03**	**2,60**	**7,79**	**8,65**	**360,6**
SD	**8,42**	**1,28**	**5,59**	**177,12**	**0,09**	**47,01**	**0,97**	**3,89**	**0,37**	**0,38**	**1,76**	**5,27**	**0,21**	**56,94**

U promatranom razdoblju % zasićenosti otopljenim kisikom (ODO % sat) prosječno je iznosio 84,04 %. Maksimalna vrijednost zabilježena je u svibnju, 2018 (94,38 %), a minimalna u listopadu (72,80 %). Generalno, postotni udio od 80 do 120 % se smatra veoma dobrim, dok veće (>125) i manje (<50) vrijednosti mogu ugroziti živi svijet u vodi. Ridl (2015) je na prostoru NP „Plitvička jezera“ zabilježila nešto veće maksimalne (ožujak 114%) i minimalne (rujan i listopad 92,8%) vrijednosti.

Temperatura vode

Od svibnja, 2018. do lipnja, 2019. prosječna godišnja temperatura vode na odabranoj lokaciji iznosila je 16,32 °C. Maksimalna temperatura vode izmjerena je u kolovozu, 2018. (25,59 °C), a minimalna u siječnju, 2019. godine (7,06 °C) (Slika 131).

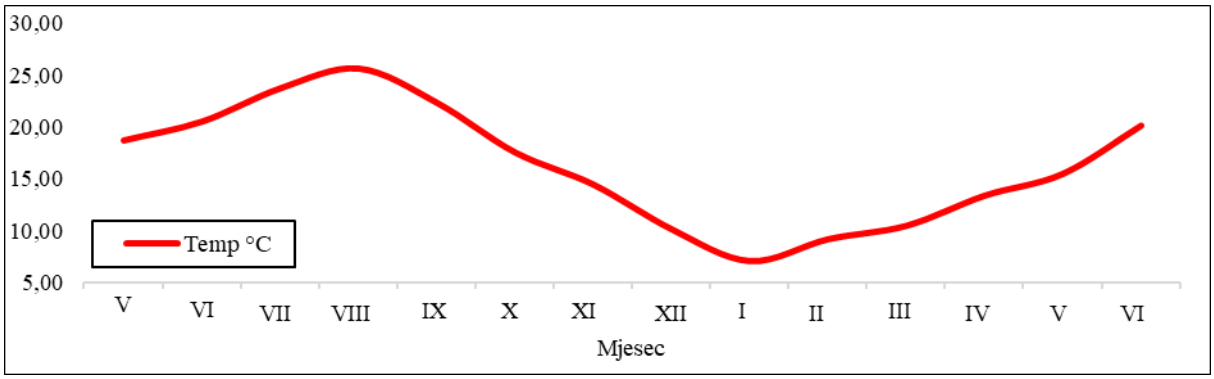

Slika 131. Godišnje kretanje temperature vode

Količina otopljenog kisika

Količina otopljenog kisika (ODO mg/L) u prosjeku je iznosila 8,34 mg/L, a mjerenja su zabilježila očekivane sezonske oscilacije (Slika 132). Najveća vrijednost (10,53 mg/L) zabilježena je u veljači, 2019., a najmanja u kolovozu (6,49 mg/L) i rujnu iste godine. Manje vrijednosti tijekom kolovoza i rujna mogu biti posljedica sporijeg protoka vode (nizak vodostaj uslijed smanjene količine oborina i povećanog isparavanja zbog viših temperatura zraka) te bržeg metabolizma i većeg broja organizama koji troše O_2. Slične vrijednosti otopljenog kisika dosad su zabilježene u drugim istraživanjima sedrotvornih sustava u RH. Prema Pearsonovom koeficijentu korelacije utvrđena je snažna negativna korelacija (-0,75) između temperature i količine otopljenog kisika.

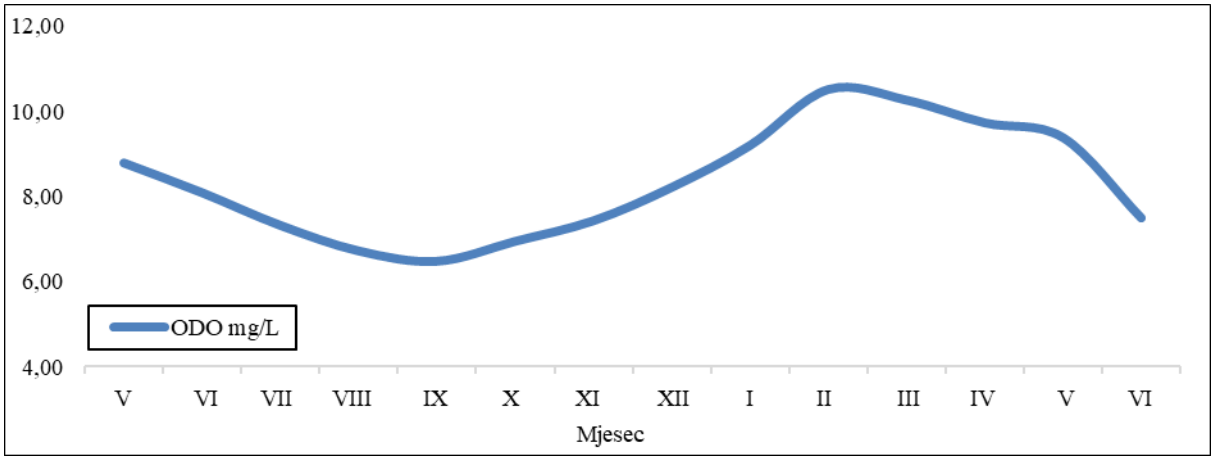

Slika 132. Godišnje kretanje količine otopljenog kisika na lokaciji Mjernik

Kiselost (pH) vode

Prosječna izmjerena vrijednost pH na odabranoj lokaciji iznosi 8,65. Time je zadovoljen jedan od osnovnih uvjeta nastanka sedre koji se odnosi na pH vrijednosti veće od 8. Najmanja izmjerena vrijednost zabilježena je u svibnju, 2018 (8,37), a najveća u svibnju 2019, (8,94). Nije uočeno značajno sezonsko ni dnevno osciliranje vrijednosti pH (Slika 133 i 134) iz čega se posredno može zaključiti da ne postoji značajnija uloga vodenih biljaka u uklanjanju CO_2 fotosintetskim procesima time utječući na stupanj prezasićenosti.

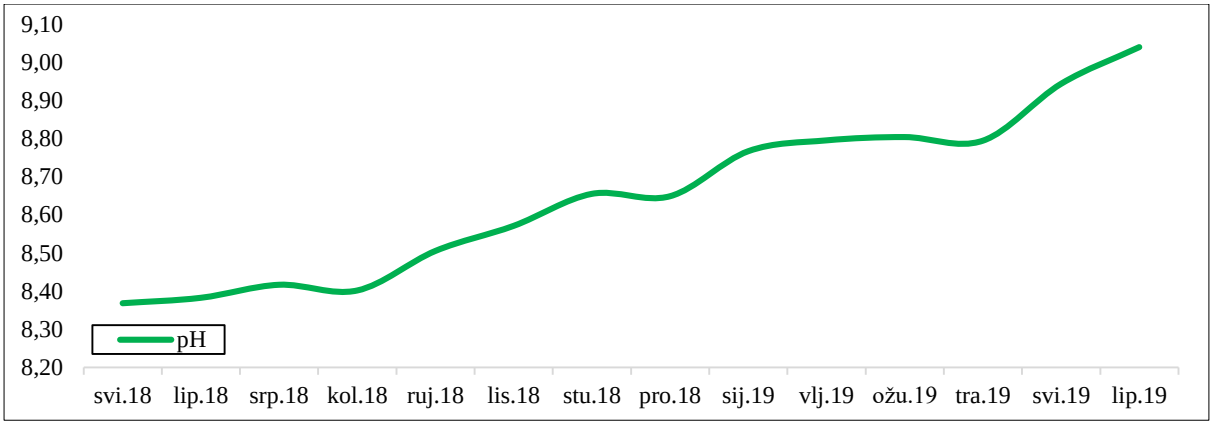

Slika 133. Godišnje kretanje pH vrijednosti

Nepostojanje jasnih dnevnih promjena pH (Slika 134) ukazuje na to da fotosintetski unos, za koje se očekuje da će pH povećati u podne (Merz-Preiß i Riding, 1999), ima malo utjecaja na precipitaciju u ovim tokovima, iako je lokacija postavljanja multiparametarske sonde bogata s vodenom vegetacijom. Dnevne varijacije u pH vrijednosti bi bile još manje da je sonda postavljena u fluvijalno okruženje u kojem je brži protok i izrazitija turbulencija vode.

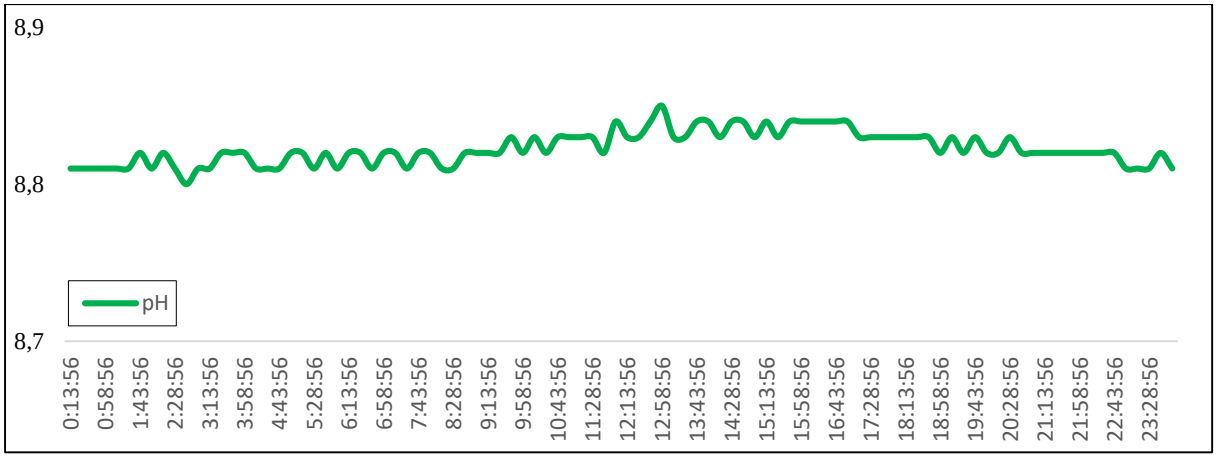

Slika 134. Primjer dnevnog kretanja pH vrijednosti (ožujak, 2019)

Izmjerene vrijednosti pH su u skladu s istraživanjima u drugim aktivnim sedrotvornim sustavima. Belančić i dr. (2009) su na dvije lokacije unutar NP "Plitvička jezera" izmjerili vrijednosti pH od 8,32 i 8,36. Cukrov i dr. (2008) su pH mjerili na 10 lokacija unutar NP "Krka". Također su utvrdili da ne postoje sezonske varijacije u pH, ali su uočili snažnu prostornu varijabilnost. Od izvora Krke pH se povećava s oko 7,5 na 8,3 uslijed otplinjavanja CO_2. Na karbonatnim podlogama (kao što je slučaj NPK) na područjima gdje se javlja unos podzemne vode dolazi do snižavanja pH vrijednosti. Vrijednosti pH utvrđene ovim istraživanjem u dobroj su podudarnosti s vrijednostima izmjerenim ranijim istraživanjima na postaji Skradinski buk gdje je Ridl (2015) minimalne pH vrijednost vode izmjerila u rujnu

(7,59), a maksimalne u ožujku (8,13) te ostalim sedrotvornim rijekama u Hrvatskoj, Španjolskoj i Japanu. Tako su Horvantinčić i dr. (2006) su na prostoru Plitvičkih jezera zabilježili pH vrijednosti od 7,51 do 8,45, a utvrdili su i konstantan porast pH vrijednosti u nizvodnom smjeru što je posljedica otpuštanja CO_2. Arenas i dr. (2010) te Auqué i dr., 2013 su utvrdili da rijeka Piedra ima vrijednosti pH koje variraju od 8 do 8,5. Auqué i dr. (2013) za istu rijeku navode vrijednosti od 7 do 8,7. Kawai i dr. (2009) su na četiri različite lokacije u Japanu izmjerili pH u rasponu od 8,14 do 8,55. Auqué i dr. (2014) su za vodu rijeke Anamaza izmjerili pH u rasponu od 7,16 do 8,69.

Oksidacijsko-redukcijski potencijal

Prosječna godišnja vrijednost oksidacijsko-redukcijskog potencijala (ORP mV) iznosila je 360,6. Najveća vrijednost zabilježena je u siječnju, 2019. (450,9), a najmanja u svibnju 2018. godine (206,7) (Slika 135). Izmjerene vrijednosti udovoljavaju kriteriju da se u zdravim vodama ORP kreće u vrijednostima od 300 do 500 mV (URL 49).

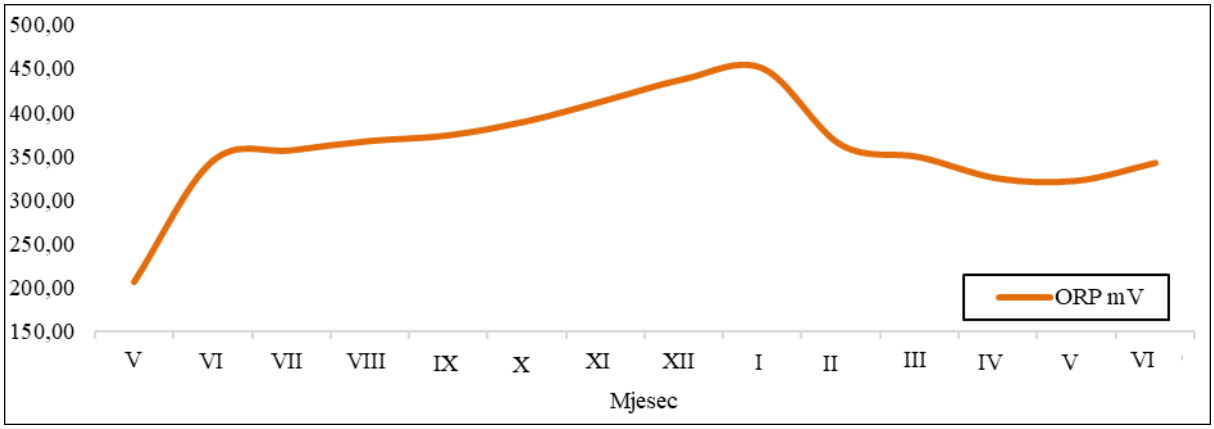

Slika 135. Godišnje kretanje ORP vrijednosti

4.3 Mikro razina

4.3.1 Kvaliteta mjerenja uređajem za koordinatnu mjernu makrofotogrametriju (CMD)

S ciljem utvrđivanja kvalitete mjerenja CMD-om provedeno je ispitivanje njegove točnosti i preciznosti. Točnost LCS-a je ispitana dodavanjem četiri kontrolne točke u *Metashape* projekt za pet različitih intervalnih modela pločice. U tablici 29 prikazane su pogreške po X, Y i Z koordinati za dodane kontrolne točke u pet različitih mjerenja. RMSE kontrolnih točaka za X i Y os je gotovo ista te iznosi 0,012 i 0,014 mm, dok je za Z os veća te iznosi 0,0988 mm. To je očekivano s obzirom na to da točnost koordinata (osobito X i Y) ovisi o: debljini tiskane linije LCS-a, točnosti pozicioniranja orijentacijske točke na sjecište linija LCS-a te veličini piksela na modelu koji je služio kao podloga za dodavanje točaka. Primjerice, pri odabranim korisničko-definiranim parametrima prostorna rezolucija modela na kojem su inicijalno dodane orijentacijske i kontrolne točke je iznosila 0,018 mm (Slika 136a).

Sjecište linija u LCS-u na koje su dodavane orijentacijske i kontrolne točke je prikazano s osam piksela, odnosno debljina linije iznosi 0,0944 mm (Slika 136b). Dodane orijentacijske i kontrolne točke moraju biti smještene točno na sjecište dviju linija koje „imitiraju“ meridijane i paralele u globalnom koordinatnom sustavu. Međutim, od idealnog sjecišta korisnik maksimalno može odstupiti četiri piksela po X i Y osi (Slika 136c). To znači da je prilikom dodavanja orijentacijskih i kontrolnih točaka maksimalna pogreška za X i Y koordinatu mogla iznositi 0,0473 mm (Slika 136c). Međutim, točnost pozicioniranja kontrolnih točaka je prema dobivenim rezultatima (Slika 136d) unutar jednog piksela za X i Y os što je očekivano s obzirom na mogućnosti *Metashapea* prilikom spajanja preklapajućih snimaka.

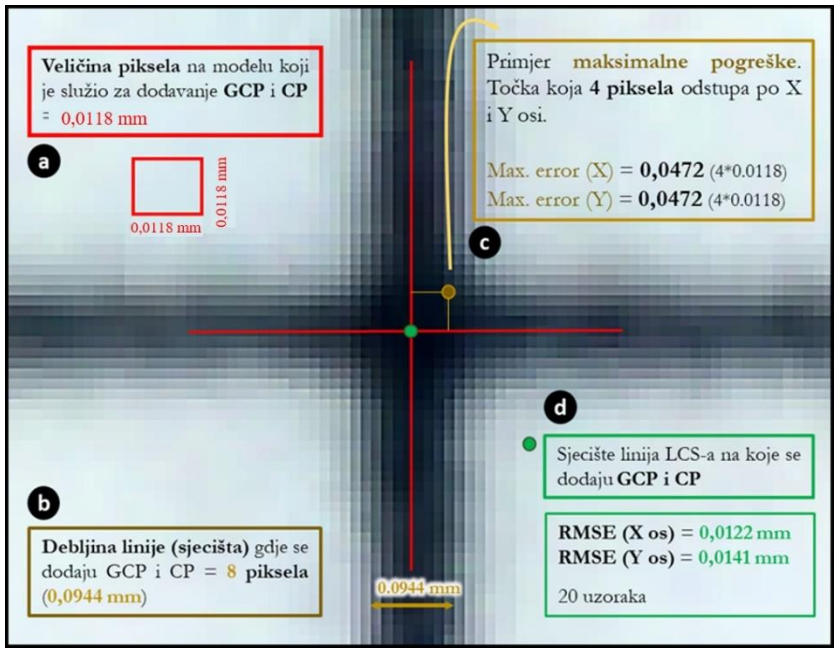

Slika 136. Shematski pristup izračuna kvalitete mjerenja CMD-om

RMSE kontrolnih točaka za Z os je veća te iznosi 0,097 mm. Veća pogreška za Z os je očekivana s obzirom na to da su sve kontrolne točke dodane na LCS te se pretpostavlja da se nalaze na istoj visini (0,00 mm). Međutim, LCS je tiskan i zalijepljen na ravnu metalnu ploču. Debljina ljepila te zakrivljenost metalne podloge u ovom slučaju utječe na visinu dodanih točaka. Nadalje, visina LCS-a u svakom intervalnom mjerenju mora biti ista, a provjera se pomoću digitalnog šublera. Dakle, postoje više korisničko-definiranih parametara koji potencijalno mogu povećati pogrešku na Z osi.

Provjerom na temelju 20 kontrolnih točaka utvrđeno je da je točnost Z koordinate manja od desetinke milimetra. Ukupna RMSE kontrolnih točaka u referentnom koordinatnom sustavu iznosi 0,0988 mm, a pogreška reprojekcije 0,246 piksela u koordinatnom sustavu slike (Tablica 29). Pogreška reprojekcije predstavlja srednju vrijednost pogreške korijena orijentacijske točke izračunatu na svim fotografijama na kojima je točka vidljiva. Vrijednosti manje od 1 piksela su prihvatljive. Veće vrijednosti su indikator pogrešne projekcije točke na jednoj ili više fotografija ili pogrešnog poravnavanja fotografija.

Tablica 28. Razlike između izmjerenih i procijenjenih vrijednosti kontrolnih točaka u pet različitih mjerenja

	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL03 (inicijalno stanje)	**P1**	0,001	-0,010	-0,125	0,126	0,133
	P2	-0,014	0,000	-0,144	0,145	0,141
	P3	-0,013	-0,007	-0,112	0,112	0,154
	P4	-0,007	-0,011	-0,135	0,136	0,122
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL15 (6 mjeseci)	**P1**	0,014	-0,017	-0,094	0,097	0,217
	P2	0,000	-0,003	-0,091	0,091	0,197
	P3	-0,013	-0,010	-0,079	0,080	0,177
	P4	-0,011	-0,019	-0,099	0,102	0,212
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL29 (godina dana)	**P1**	0,018	-0,018	-0,100	0,103	0,361
	P2	-0,013	-0,010	-0,095	0,097	0,518
	P3	-0,018	-0,005	-0,070	0,073	0,460
	P4	-0,009	-0,029	-0,003	0,031	0,445
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL25 (9 mjeseci)	**P1**	0,017	-0,019	-0,043	0,050	0,455
	P2	-0,014	-0,003	-0,087	0,088	0,479
	P3	-0,012	-0,010	-0,065	0,067	0,461
	P4	-0,011	-0,021	-0,069	0,073	0,376
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL13 (3 mjeseca)	**P1**	0,004	-0,019	-0,139	0,141	0,193
	P2	-0,015	-0,008	-0,131	0,132	0,152
	P3	-0,013	-0,008	-0,075	0,076	0,196
	P4	-0,003	-0,018	-0,057	0,059	0,160
RMSE		**0,012**	**0,014**	**0,097**	**0,0988**	**0,246**
MAE		**0,011**	**0,012**	**0,091**	**0,0939**	**0,215**

Ukupna RMSE orijentacijskih točaka u referentnom LCS-u bila je 0,014 mm, a u koordinatnom sustavu slike 0,218 pix. Ova metrika nije primjerena za determiniranje točnosti modela jer je izravno vezana uz korisničko-definiran parametar *Marker Accuracy* koji je prema uputama *Metashapea* postavljen na 0 cm (Tablica 30).

Tablica 29. Razlike između izmjerenih i procijenjenih vrijednosti GCP-a unutar pet različitih mjerenja

	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL03 (inicijalno stanje)	**P1**	0,000	0,000	0,004	0,004	0,118
	P2	0,000	0,000	-0,004	0,004	0,104
	P3	0,000	0,000	0,005	0,005	0,124
	P4	0,000	0,000	-0,003	0,003	0,120
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL15 (6 mjeseci)	**P1**	-0,001	0,000	0,003	0,003	0,182
	P2	0,000	0,001	-0,003	0,003	0,152
	P3	0,001	0,000	0,003	0,003	0,182
	P4	0,001	-0,001	0,000	0,001	0,186
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL29 (godina dana)	**P1**	-0,008	-0,003	0,024	0,025	0,362
	P2	-0,008	0,006	-0,015	0,018	0,500
	P3	0,012	0,011	-0,043	0,046	0,426
	P4	0,008	-0,019	0,071	0,074	0,444
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL25 (9 mjeseci)	**P1**	0,000	0,000	-0,002	0,002	0,174
	P2	0,000	0,000	0,001	0,001	0,113
	P3	0,000	0,000	-0,001	0,001	0,076
	P4	0,000	0,000	0,002	0,002	0,091
	Label	**X error (mm)**	**Y error (mm)**	**Z error (mm)**	**Total (mm)**	**Image (pix.)**
PL13 (3 mjeseca)	**P1**	-0,001	-0,001	0,003	0,003	0,209
	P2	-0,001	0,001	-0,002	0,003	0,163
	P3	0,001	0,000	0,002	0,002	0,169
	P4	0,000	-0,001	-0,001	0,001	0,151
RMSE		**0,003**	**0,004**	**0,014**	**0,014**	**0,218**

Usporedbom dobivenih vrijednosti s istraživanjima gdje je izvršen proces makrofotogrametrije (Marziali i Dionisio, 2017, Gajski i dr., 2016) i blizupredmetne fotografije (Barazzetti i dr., 2018) može se utvrditi da je ukupna pogreška pomaka prihvatljiva i da su kontrolne točke unutar DoF-a.

Rezultati kontrolnih točaka pokazuju da je točnost LCS-a, odnosno relativna točnost uređaja ispod desetinke milimetra. Apsolutna točnost je ispitana usporedbom volumena (mm^3) dijela pločice (Slika 137) generiranog CMD-om i uređajima (*Eva* i *Space Spider*) koji imaju službenu točnost 3D točaka 0,1 mm te 0,05 mm. U slučaju da je apsolutna točnost uređaja manja od desetinke milimetra CMD bi trebao generirati volumen pločice u rasponu vrijednosti

Artec Eve i *Space Spidera*. Rezultati provedenog testa to i potvrđuju. Naime, volumen odabrane testne pločice, 2 mm izdignut od referentne plohe u odnosu na LCS, generiran CMD-om iznosio je 14295,34 mm³. To je za 78,06 mm³ (AE), ili 0,55% (PE), veće od referentnog volumena (14217,28 mm³) generiranog 3D skenerom *Artec Space Spiderom*. Njegov model je uzet kao referentni jer ima bolju 3D točnost točaka (0,05 mm) od *Artec Eve* te je najtočniji uređaj koji je bio dostupan za korištenje prilikom istraživanja. Volumen iste pločice koji je generiran *Artec Evom* iznosio je 15257,86 mm³ što je za 1040,58 mm³ (AE) ili je 7,32% (PE) veće od referentnog volumena *Spidera*. To je za 6,77% lošiji rezultat od CMD-a. CMD je postigao rezultat bliži *Artec Spideru* u odnosu na *Artec Eva* koja ima službenu točnost 3D točaka od 0,1 mm.

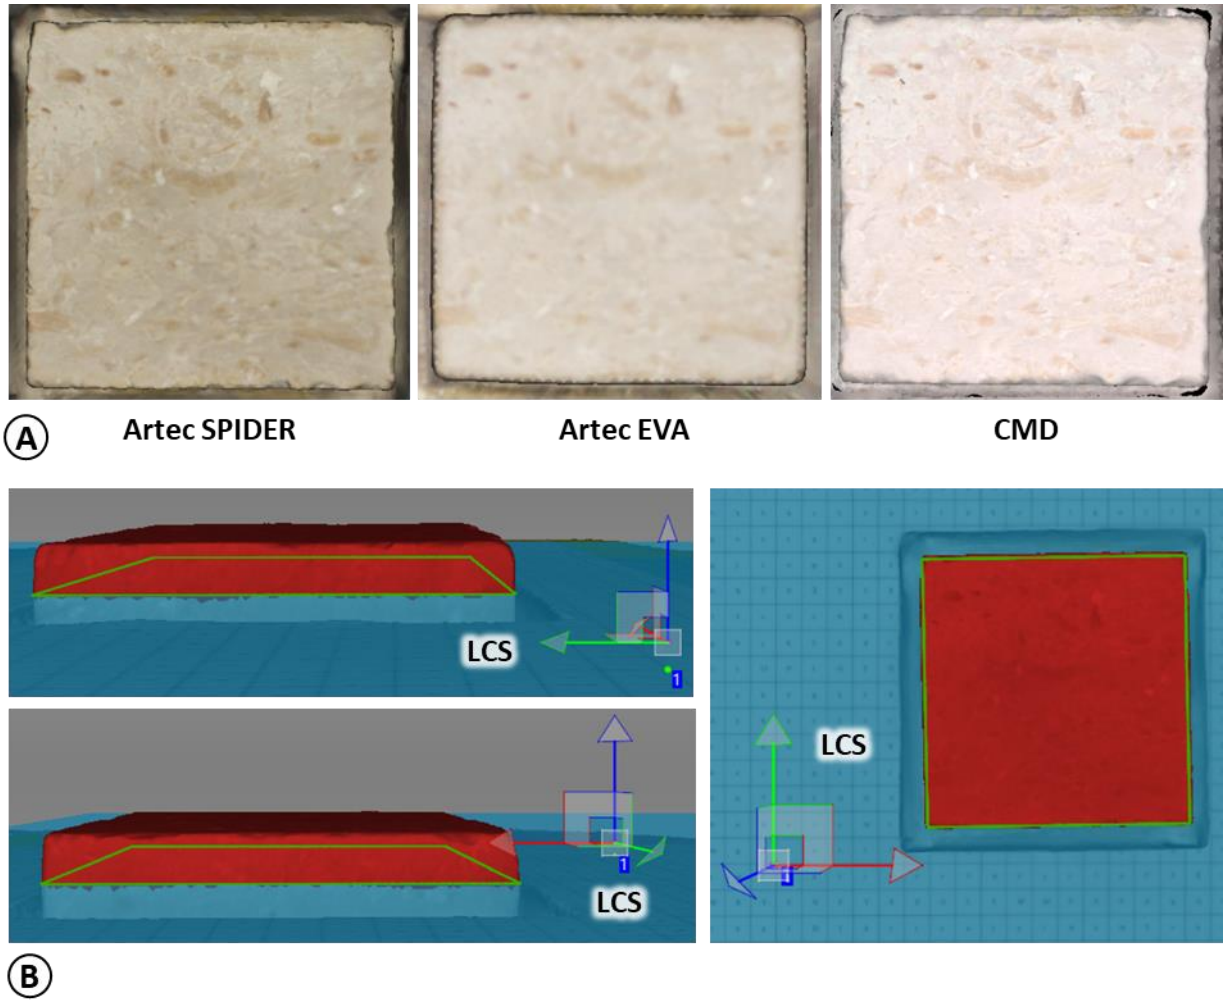

Slika 137. A) 3D modeli testne pločice te B) primjer izračuna volumena u *Artec Studiu*

Preciznost CMD-a je izračunata na temelju pet intervalnih mjerenja iste pločice provedenim na različite datume, ali pod istim uvjetima snimanja (postavke kamere, osvjetljenje, obrada fotografija itd.). Prije svakog snimanja, CMD je rastavljen, ponovno sastavljen te je pločica nanovo fiksirana unutar LCS-a. Izvedeno je pet DTHRM i DOF-a

sljedeći metodologiju obrade fotografija. Na DOF-ovima je označeno 70 uzoraka (piksela) koji bi se u svim mjerenjima trebali nalaziti na istim koordinatama (X, Y i Z) s obzirom na to da je visina LCS-a svaki put postavljena na istu visinu te je pločica fiksirana pomoću pomične metalne stope i fiksnih držača. Vrijednosti označenih uzoraka su izvučene za svako mjerenje te su iskazane u milimetrima. U tablici 31 vidljivi su primjeri izvedenih X, Y i Z vrijednosti za pojedini uzorak.

Tablica 30. X, Y i Z vrijednosti označenih uzoraka (n = 10/70) za pet mjerenja (1-5M)

ID	1M			2M			3M			4M			5M		
	X	Y	Z	X	Y	Z	X	Y	Z	X	Y	Z	X	Y	Z
0	36,86	41,58	7,36	36,90	41,58	7,33	37,12	41,57	7,45	36,99	41,53	7,49	36,94	41,55	7,48
1	23,90	18,62	7,43	23,94	18,61	7,38	24,22	18,51	7,48	24,09	18,52	7,51	24,09	18,51	7,51
2	59,69	57,31	7,47	59,73	57,31	7,45	59,89	57,34	7,59	59,77	57,31	7,63	59,72	57,32	7,64
3	33,76	51,94	7,41	33,81	51,93	7,39	33,96	51,88	7,51	33,86	51,88	7,56	33,79	51,87	7,59
4	33,19	60,35	7,43	33,23	60,35	7,40	33,36	60,30	7,54	33,27	60,28	7,59	33,22	60,28	7,60
5	38,59	60,94	7,40	38,63	60,93	7,35	38,76	60,89	7,48	38,69	60,86	7,54	38,61	60,89	7,56
6	45,84	59,14	7,46	45,88	59,13	7,43	46,03	59,12	7,56	45,93	59,11	7,61	45,88	59,12	7,63
7	20,19	61,74	7,42	20,21	61,72	7,40	20,36	61,62	7,54	20,27	61,63	7,59	20,22	61,61	7,63
8	27,15	60,50	7,41	27,17	60,49	7,36	27,34	60,39	7,51	27,23	60,41	7,57	27,17	60,44	7,55
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
69	45,48	32,91	7,37	45,53	32,90	7,37	45,76	32,90	7,46	45,65	32,88	7,48	45,62	32,89	7,50

Potom je na temelju generiranih X, Y i Z vrijednosti za pet mjerenja izračunata srednja vrijednost svakog uzorka za X, Y i Z koordinatu (Tablica 32).

Tablica 31. Primjer izračunatih srednjih vrijednosti uzoraka (n = 10/70) za x, y i z koordinate

ID	AVERAGE		
	X	Y	Z
0	36,96	41,56	7,42
1	24,05	18,55	7,46
2	59,76	57,32	7,56
3	33,84	51,90	7,49
4	33,26	60,31	7,51
5	38,66	60,90	7,47
6	45,91	59,12	7,54
7	20,25	61,66	7,52
8	27,21	60,45	7,48
...	...	...	...
69	45,61	32,90	7,44

Izvedeni rezultati su potom prikazani u dvije tablice. U prvoj (Tablica 33) je koristeći funkciju =*abs* za svako mjerenje izračunato apsolutno odstupanje (AD) pojedinog uzorka i njegove X, Y i Z koordinate od izračunatih srednjih vrijednosti u tablici 32. Time se eliminirao negativan predznak između odstupanja i omogućilo izvođenje MAD-a za X, Y i Z koordinatu svakog uzorka (n=70). U drugoj tablici (Tablica 34) generirane su vrijednosti SD-a za X, Y i Z koordinatu svakog uzorka (n=70).

Tablica 32. Izračun odstupanja svakog uzorka od srednje vrijednosti x, y i z koordinata u svakom mjerenju (n=5)

ID	1M_AD			2M_AD			3M_AD			4M_AD			5M_AD		
	X	Y	Z	X	Y	Z	X	Y	Z	X	Y	Z	X	Y	Z
0	0,133	0,012	0,047	0,094	0,012	0,074	0,131	0,006	0,047	0,004	0,040	0,088	0,055	0,022	0,075
1	0,189	0,055	0,014	0,153	0,049	0,066	0,132	0,047	0,032	0,007	0,041	0,065	0,001	0,052	0,064
2	0,087	0,032	0,067	0,048	0,035	0,093	0,106	0,006	0,053	0,016	0,032	0,086	0,061	0,022	0,103
3	0,101	0,031	0,068	0,051	0,021	0,083	0,101	0,026	0,037	0,003	0,034	0,092	0,067	0,036	0,116
4	0,084	0,029	0,068	0,043	0,027	0,096	0,088	0,025	0,044	0,002	0,038	0,094	0,056	0,041	0,104
5	0,082	0,023	0,048	0,043	0,013	0,105	0,086	0,018	0,032	0,016	0,052	0,092	0,063	0,026	0,110
6	0,089	0,000	0,064	0,050	0,007	0,087	0,097	0,018	0,042	0,002	0,031	0,090	0,055	0,013	0,111
7	0,077	0,073	0,086	0,054	0,055	0,098	0,090	0,044	0,036	0,007	0,039	0,089	0,046	0,055	0,130
8	0,083	0,045	0,060	0,057	0,040	0,110	0,113	0,056	0,045	0,002	0,041	0,103	0,060	0,015	0,082
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
69	0,158	0,003	0,052	0,113	0,009	0,053	0,119	0,016	0,043	0,003	0,029	0,063	0,025	0,024	0,083

U tablici 34 prikazan je dio vrijednosti SD-a i MAD-a za X, Y i Z koordinatu svakog uzorka (n=70). U konačnici je preciznost CMD-a izražena kao prosječna vrijednost SD-a i MAD-a X, Y i Z koordinate svakog uzorka.

Tablica 33. Izračunata srednja SD i MAD na temelju 70 uzoraka

ID	SD			MAD		
	X	Y	Z	X	Y	Z
1	0,102	0,023	0,074	0,075	0,018	0,063
2	0,131	0,054	0,056	0,104	0,047	0,045
3	0,076	0,012	0,090	0,053	0,009	0,077
4	0,078	0,032	0,090	0,058	0,028	0,075
5	0,067	0,035	0,093	0,050	0,030	0,078
6	0,068	0,030	0,091	0,054	0,024	0,074
7	0,072	0,012	0,090	0,054	0,009	0,075
8	0,067	0,061	0,102	0,052	0,053	0,085
9	…	…	…	…	…	…
69	0,108	0,011	0,065	0,081	0,008	0,056
SREDNJAK	**0,094**	**0,028**	**0,075**	**0,070**	**0,023**	**0,063**

Prema obje metrike vrijednosti za X, Y i Z koordinatu ne prelaze desetinku milimetra. Vrijednosti SD-a su sukladno pravilima nešto veće od MAD-a. Razlog tome je osjetljivost SD na veće greške (veću varijabilnost). Prema rezultatima MAD-a ispada da prosječna udaljenost svakog uzorka od izračunatog srednjaka prema X koordinati iznosi 0,070, prema Y 0,023, a prema Z koordinati 0,063 mm. Udaljenost specifičnog uzorka prema X i Y koordinati uvjetovana je ponajviše sposobnošću operatera, odnosno preciznošću fiksiranja pločice pomoću pomične metalne stope koje se nalazi na postolju. Ako pločica između intervalnih

mjerenja nije dobro fiksirana uzorak (piksel) se neće nalaziti na istoj X i Y lokaciji unutar LCS-a. Prema ovom testu nešto lošije fiksiranje pločice je napravljeno na X u odnosu na Y os. Odstupanje uzorka prema Z koordinati od srednjaka primarno je uvjetovana preciznošću postavljanja LCS-a. LCS se pomoću digitalnog šublera uvijek postavlja na istu visinu. Ako je u jednom mjerenju LCS-a postavljen na drugu visinu u odnosu na prethodna mjerenja vrijednosti Z koordinate na označenim uzorcima će se razlikovati te će se mjere SD-a i MAD-a povećati. Izvedene vrijednosti SD-a za X (0,094 mm), Y (0,028 mm) i Z (0,075 mm) koordinatu su nešto veće od MAD-a, ali također padaju ispod desetinke milimetra. Objašnjenje za ove vrijednosti je isto, samo što se SD povećava ako postoje uzorci koji više odstupaju od srednjaka. Dobivena metrika se može interpretirati na sljedeći način. Ako prosječna vrijednost X koordinate za *uzorak 13* iznosi 56,482 mm pretpostavlja se da će 68,2% uzoraka imati izmjerenu X koordinatu unutar vrijednosti od **56,388 do 56,572** mm (izmjerena vrijednost ±0,094). Ovakva interpretacija vrijedi pod pretpostavkom da uzorci imaju normalnu (Gaussovu) distribuciju.

Nadalje, preciznost CMD-a je izražena kao relativna nesigurnost X, Y i Z koordinate za svaki uzorak. Iz pet intervalnih mjerenja izračunati je raspon (RANGE) za X, Y i Z koordinatu svakog označenog uzorka (n=70) koji u ovom slučaju predstavlja najveću moguću pogrešku. U konačnici relativna nesigurnost za X, Y i Z koordinatu CMD-a je izračunata kao srednja vrijednosti nesigurnosti svakog uzorka (Tablica 35). Prema ovom pokazatelju relativna nesigurnost za X iznosi 0,7%, Y 0,2%, a za Z 2,2%. U odnosu na dva prethodna statistička pokazatelja, prema ovom najveću nesigurnost procjene vrijednosti pokazuje Z koordinata. Razlog tome je taj da se nesigurnost računa u odnosu na „količinu“ neke vrijednosti. Primjerice, ako raspon mjerenja (greška) za *uzorak14* X koordinate iznosi 1 mm, a izračunata mu je srednja vrijednost od 35,34 mm, onda mu je relativna nesigurnost (1 mm x 100 / 35,34) 2,83%. Ali, ako za Z koordinatu istog uzorka imamo isti raspon mjerenja (1 mm), a izračunata mu je srednja vrijednost od 7,26 mm (uvjetovano izdignućem pločice od LCS-a), onda mu je relativna nesigurnost (1 mm x 100 / 7,26) 13,77%. Dakle, iako je isti raspon mjerenja za X i Z koordinatu istog uzorka, relativna nesigurnost je veća za Z zato što ima manji srednjak (7,26 mm).

Testiranje preciznosti i točnosti uređaja je rađeno na nekorištenim vapnenačkim pločicama pločicama, kad je gornja ploha pločice u nultom stanju, odnosno minimalno izdignuta u odnosu LCS. Nakupljanjem precipitata na gornjoj pločici, povećat će se srednja vrijednost Z koordinate specifičnih uzoraka što znači da bi pod ovim postavkama, relativna nesigurnost za Z koordinatu trebala opadati.

Tablica 34. Relativna nesigurnost CMD-a za X, Y i Z koordinatu

ID	Raspon mjerenja (mm)			Relativna nesigurnost (%)		
	X	Y	Z	X	Y	Z
0	0,264	0,052	0,162	0,713	0,125	2,189
1	0,321	0,106	0,131	1,333	0,574	1,751
2	0,193	0,029	0,195	0,324	0,050	2,585
3	0,201	0,068	0,198	0,595	0,130	2,644
4	0,173	0,070	0,200	0,519	0,116	2,663
5	0,167	0,075	0,215	0,433	0,124	2,872
6	0,186	0,031	0,198	0,404	0,053	2,625
7	0,167	0,127	0,228	0,827	0,206	3,031
8	0,196	0,101	0,213	0,720	0,168	2,852
...	...	...	...	...	...	...
69	0,276	0,026	0,136	0,606	0,079	1,829
SREDNJAK				**0,664**	**0,162**	**2,198**

4.3.2 Digitalni modeli sedre visoke rezolucije (eng. DTHRM)

4.3.2.1 DTHRM – testna ploha Skradinski buk (SB)

Razvoj naprednih senzora za prikupljanje X, Y i Z podataka u lokalnom ili globalnom koordinatnom sustavu omogućava izradu visokorezolucijskih 2.5 i 3D modela iz kojih se izvode primarni i sekundarni morfometrijski parametri (npr. nagib, raščlanjenost, zakrivljenost, volumen) nekog objekta ili scene. Objekt ili scena su u tom slučaju prikazani pomoću gustih oblaka točaka čija gustoća ovisi o specifikacijama senzora i njegovoj udaljenosti od objekta snimanja. Modificirani mikro-erozijski metar (MEM), uređaj koji je danas najpopularniji u mjerenju dinamike formiranja sedre, takve mogućnosti nema.

Prema autorovom saznanju primjenom CMD-a prvi put je dinamika formiranja sedre praćena na temelju 2.5 i 3D digitalnih modela visoke rezolucije (eng. DTHRM). Digitalni modeli sedre visoke rezolucije se mogu definirati kao digitalni modeli složene površine sedre precipitirane na testnoj pločici sačinjene od ostataka sedrotvoraca prostorne rezolucije manje od 0,1 mm. Sljedeći plan snimanja ukupno je izvedeno 74 digitalna modela sedre visoke rezolucije. Među njima je izvedeno 28 modela referentnog stanja (R), 3 modela nakon 3 mjeseca mjerenja (3M), 12 nakon 6 mjeseci mjerenja (6M), 3 nakon 9 mjeseci mjerenja (9M) te 28 modela nakon godine dana mjerenja (12 M) (Slika 139 - 140).

Gustoća visinskih točaka iznosila je oko 1 785 točaka po mm². Prostorna rezolucija digitalnih modela sedre visoke rezolucije iznosila je 0,0236 mm, a digitalnog ortofota (DOF) 0,0118 mm. Bolja rezolucija DOF-a omogućila je detekciju i kartiranje različitih mikroorganizama koji su se nakupili na mjernoj površini pločice (Slika 138).

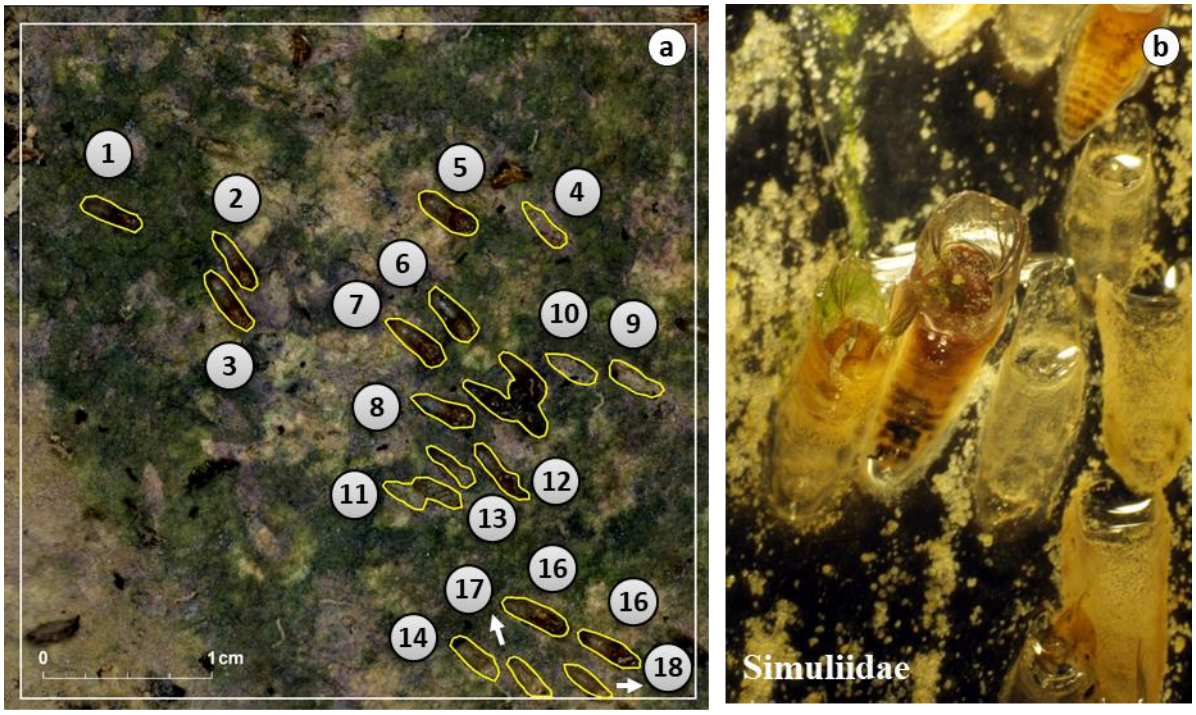

Slika 138. a) Primjer DOF-a (PL06) kao osnove za detekciju mikrorganizama na mjernoj površini b) Sedrotvorni mikroorganizam *Simulidae*

Izvor: b) slika Simulidae (Gulin i dr., 2019)

Gustoća visinskih točaka i prostorna rezolucija izvedenih modela rezultat je udaljenosti senzora od LCS-a i geometrijskih obilježja kamere (žarišna udaljenost, veličina senzora, rezolucija slike). U slučaju da je udaljenost senzora postavljena na manju udaljenost, odnosno bliže LCS-u, dobio bi se gušći oblak točaka i bolja prostorna rezolucija.

Srednja stopa prirasta sedre unutar MS (16 cm²) izračunata je kao srednja visinska vrijednost 2 856 100 uzoraka (piksela), odnosno 178 506 uzoraka po cm². Uspoređujući s MEM-om, koji ima gustoću prikupljanja podataka oko 0,13 točaka po cm² (Arenas i dr., 2014), CMD je prema odabranim postavkama snimanja generirao 1,3 milijuna puta više uzoraka na temelju kojih se prati dinamika formiranja sedre. Iz gustih oblaka točaka izvedenih u *Metashapeu* generirani su poligonski teksturirani 3D modeli intervalnih modela pločica u *obj*. formatu (Slika 144-145).

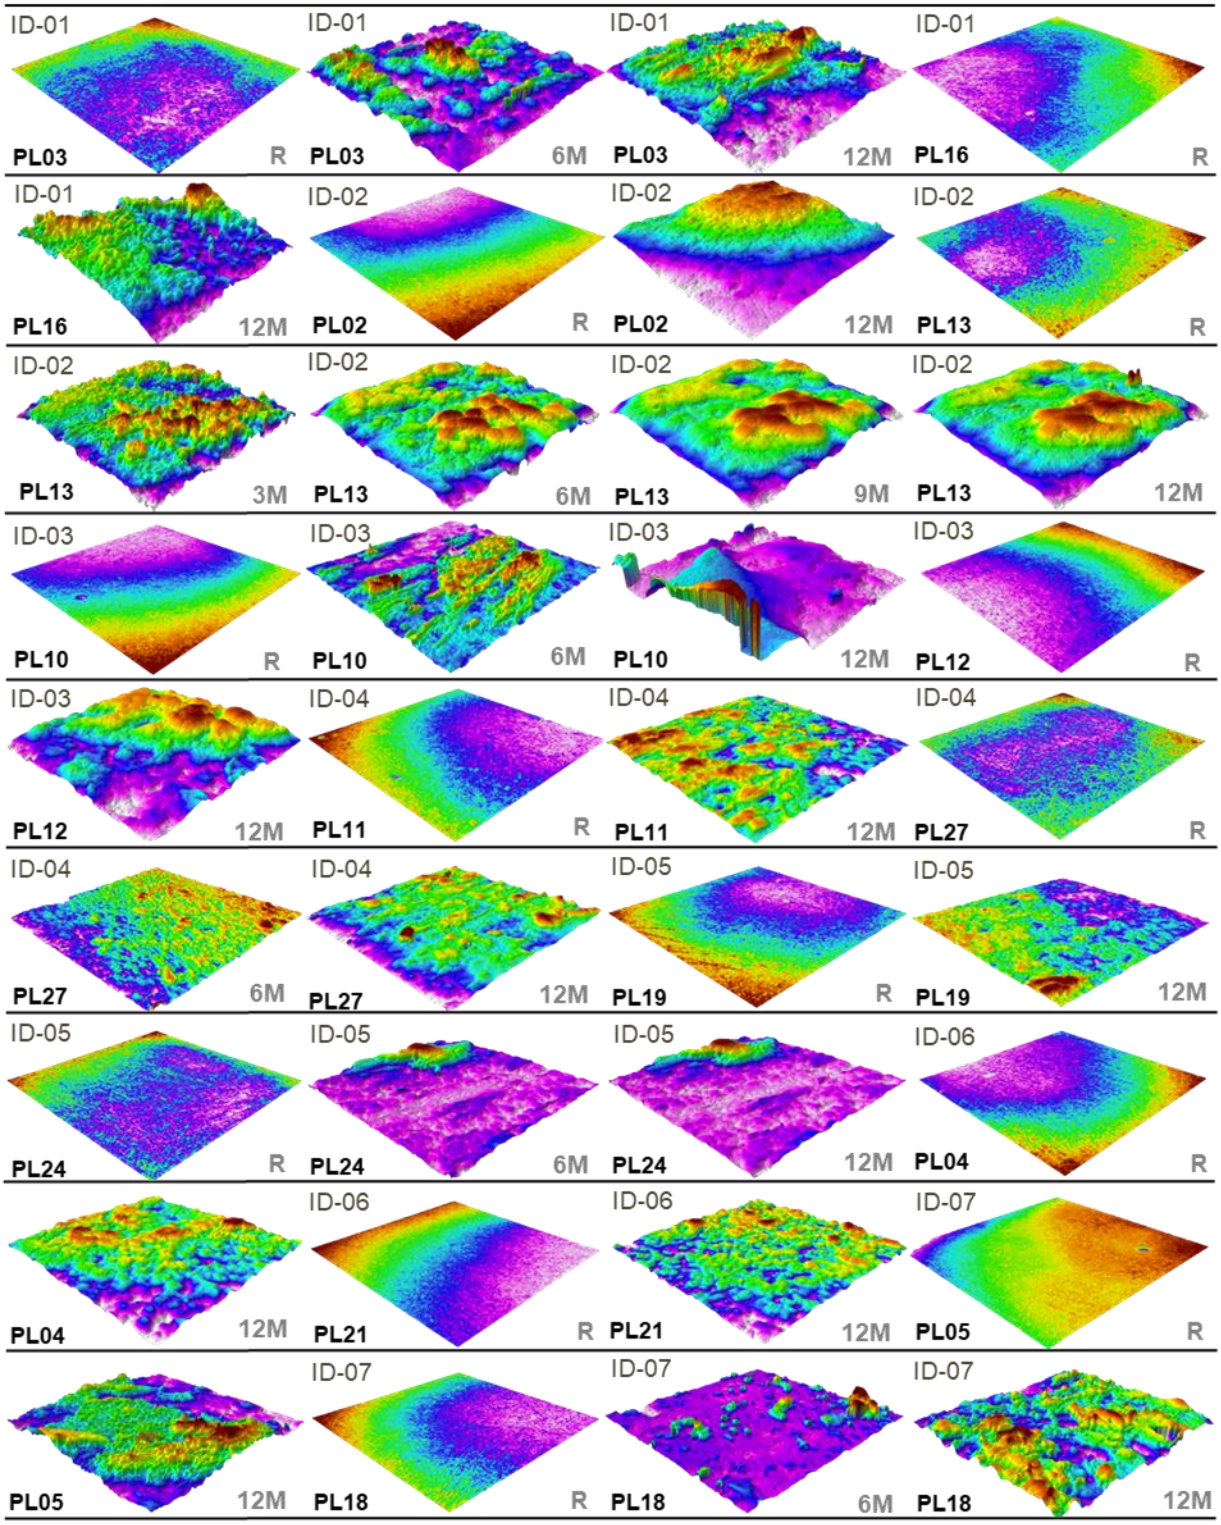

Slika 139. DTHRM za lokacije od ID01- do 07

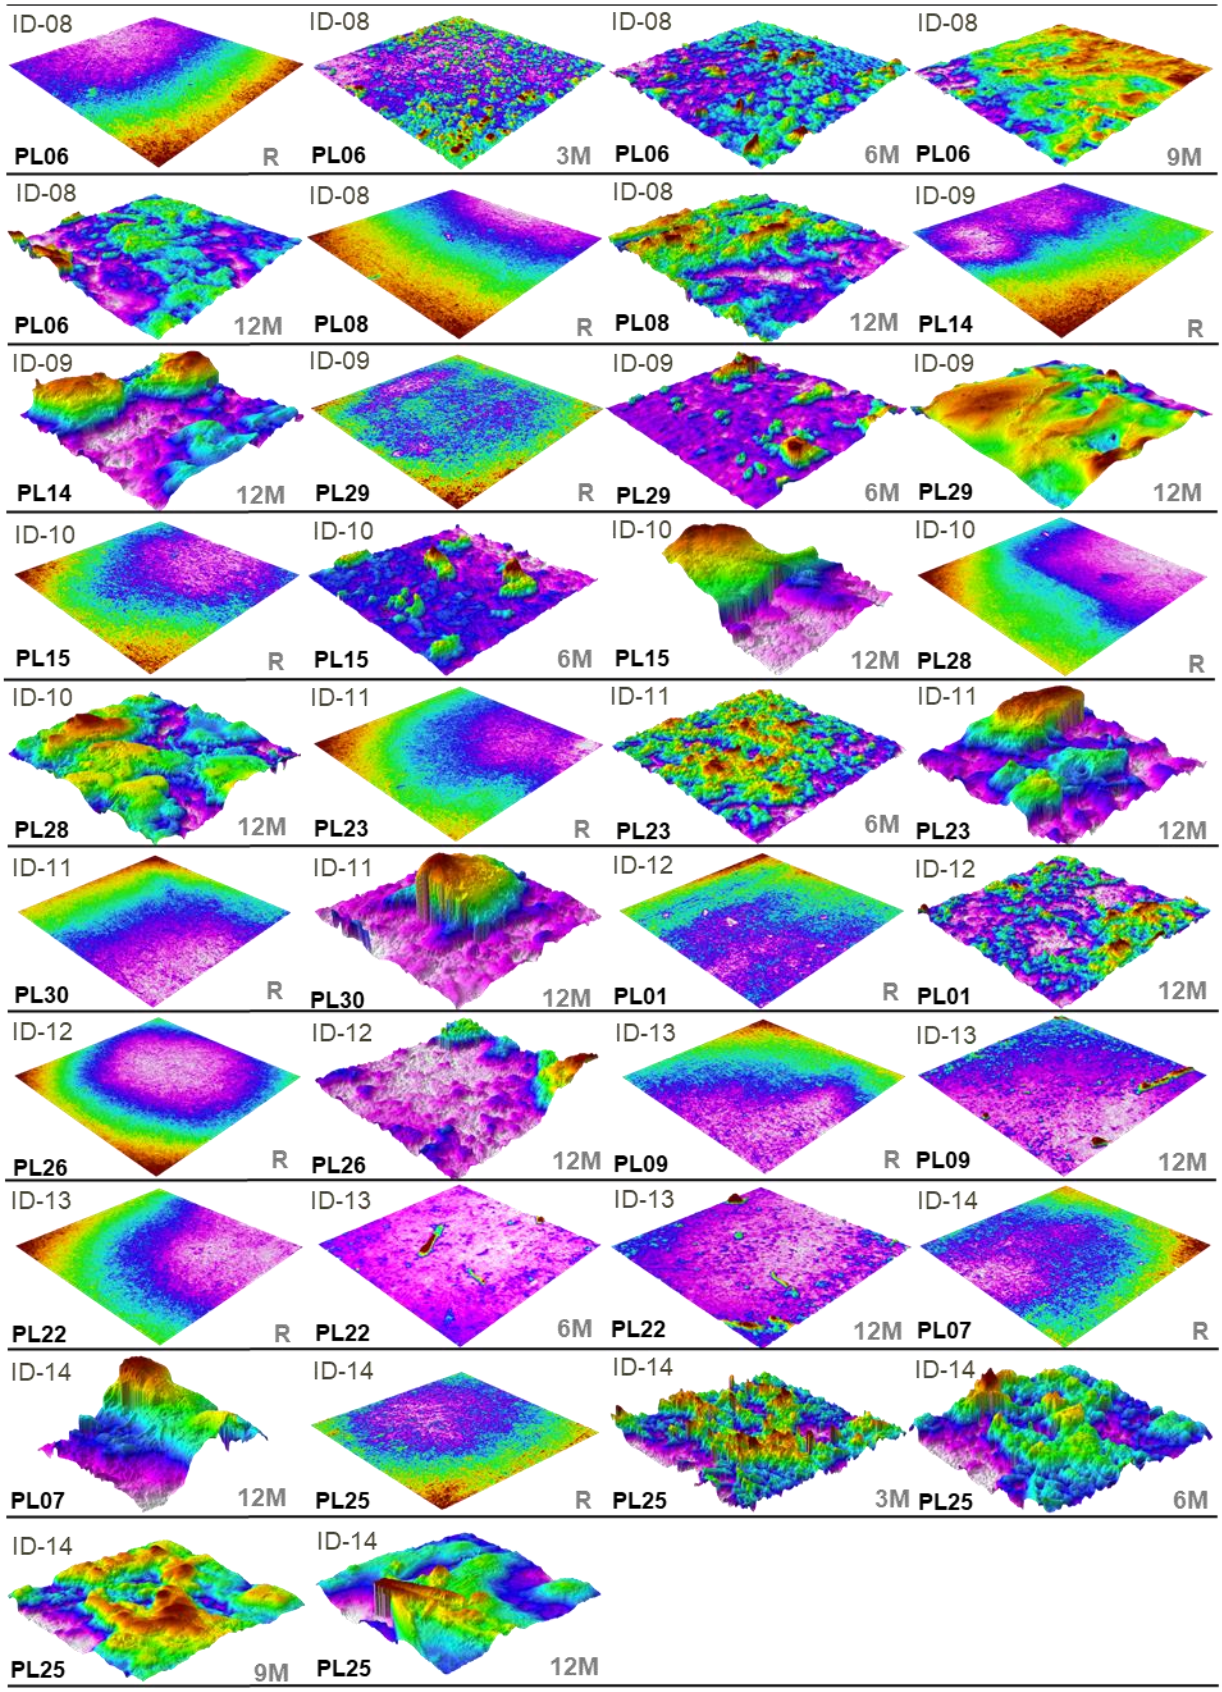

Slika 140. DTHRM za lokacije od ID08 do 14

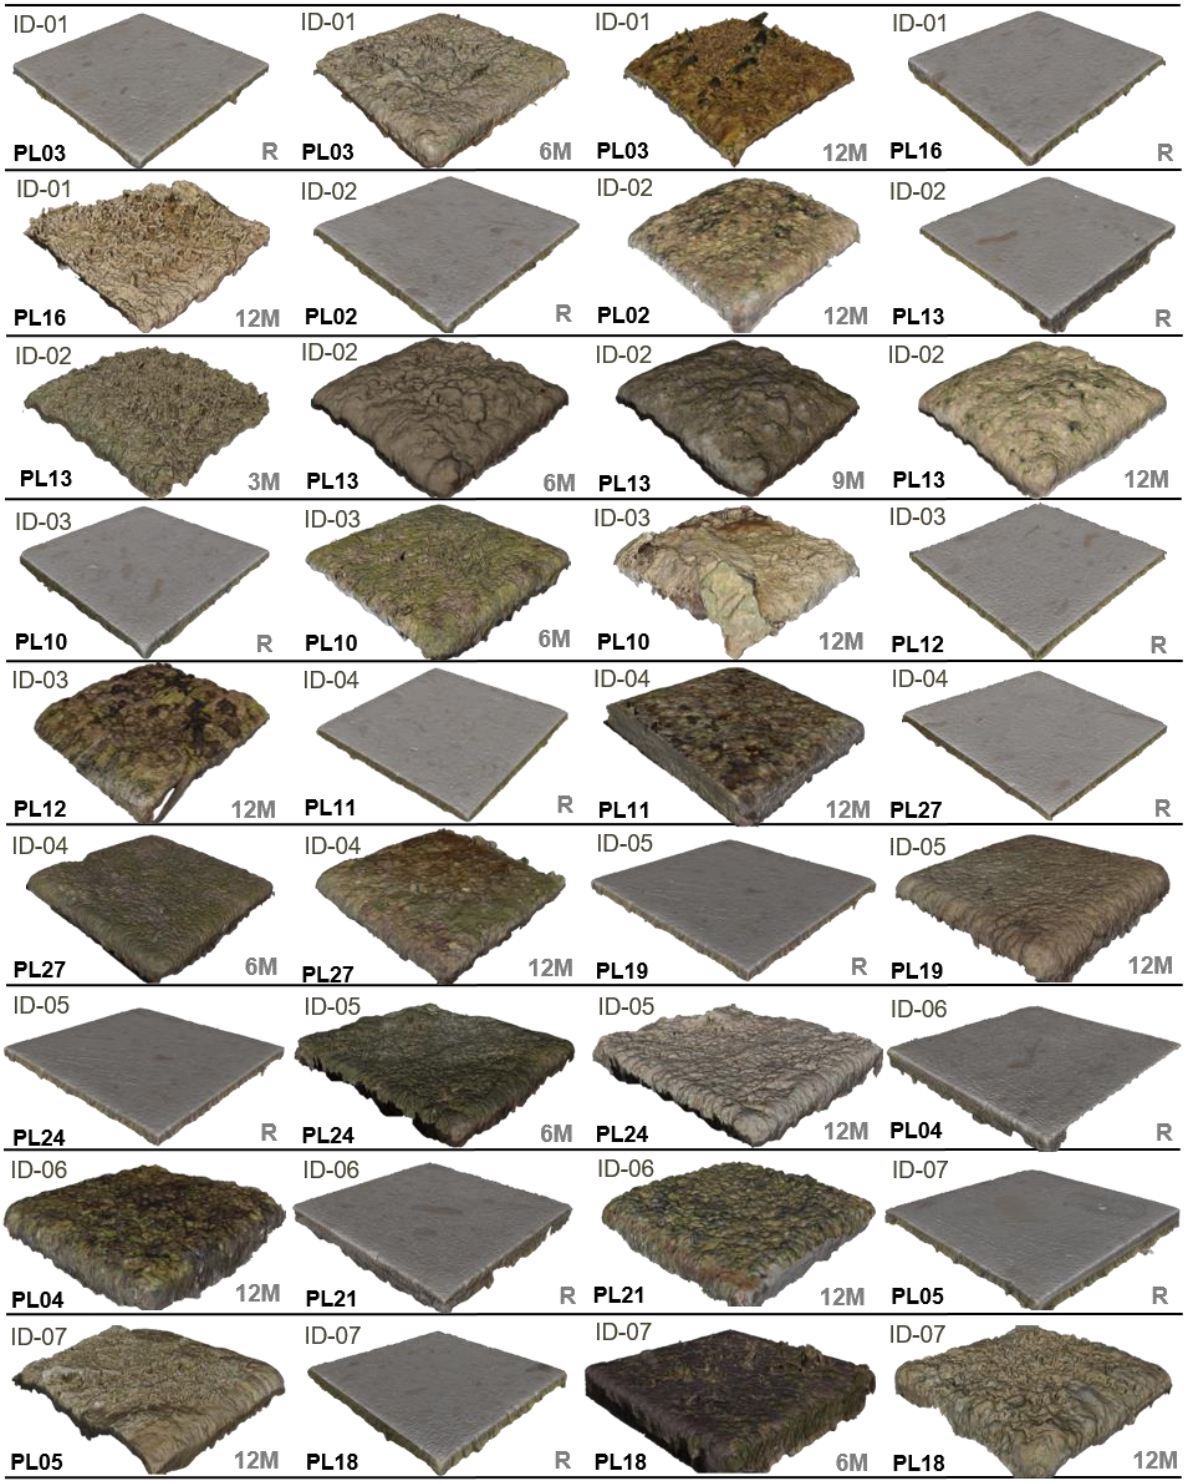

Slika 141. 3D modeli sedre od ID08 do 14

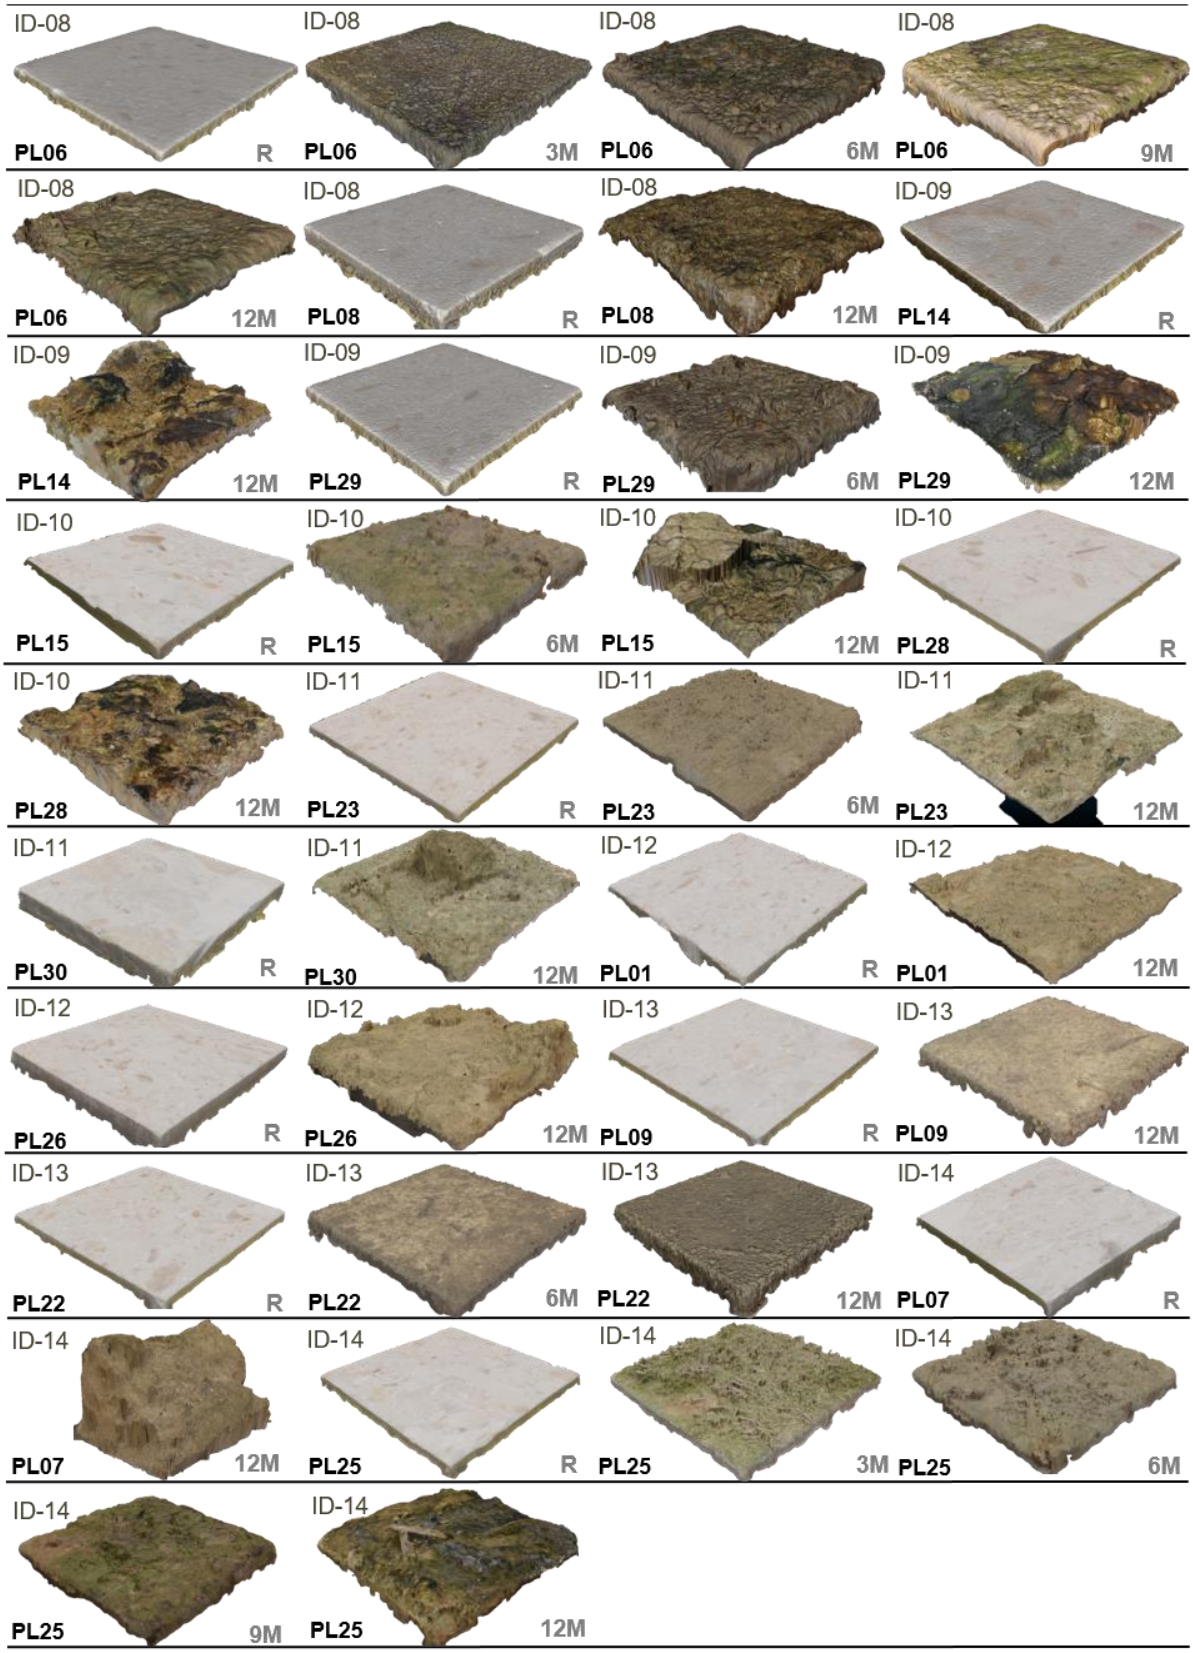

Slika 142. 3D modeli sedre od ID08 do 14

4.3.2.2 DTHRM – testna ploha Roški slap (RS)

Prateći modificirani plan snimanja (poglavlje *3.3.6 Postavljanje i snimanje testnih pločica RS*) za prostor testne plohe RS-a ukupno je izvedeno 11 DTHRM-a. Oni uključuju 8 modela referentnog stanja (R) te 3 modela nakon 6 mjeseci (6M) (Slika 143). S obzirom na to da su korištene iste postavke snimanja kao na testnoj plohi SB, generirana je ista gustoća visinskih točaka, prostorna rezolucija DTHRM-a te DOF-a (Slika 144).

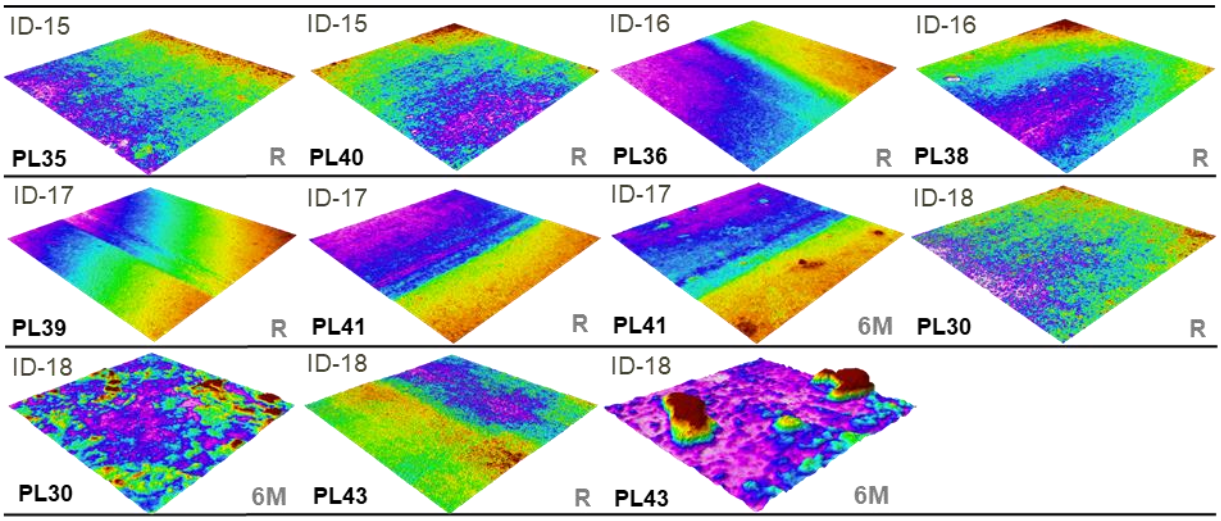

Slika 143. DTHRM za lokacije od ID15 do 18

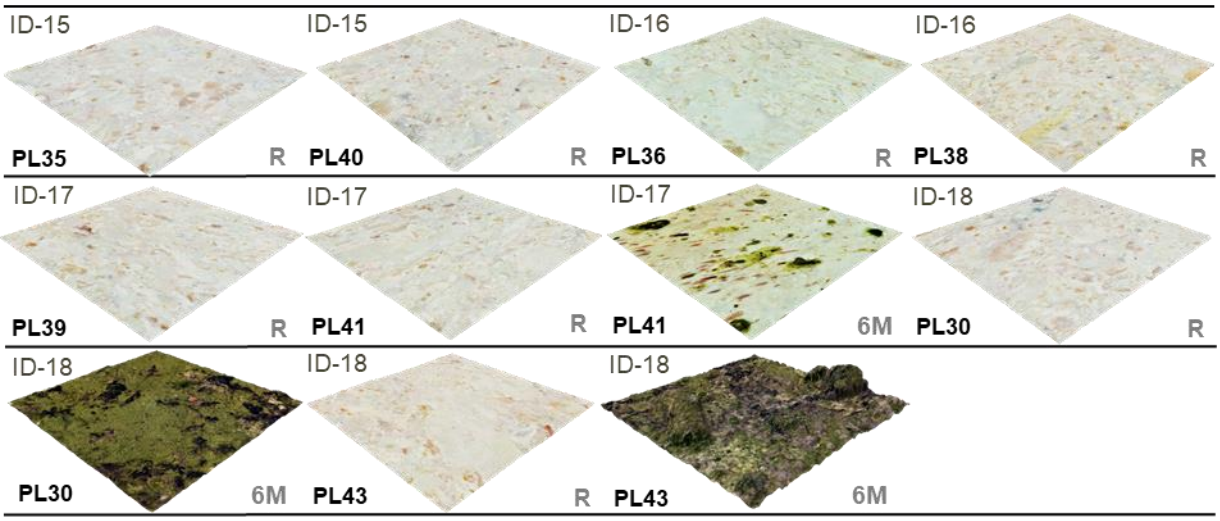

Slika 144. 3D modeli sedre od ID15 do 18

4.3.3 Stope prirasta sedre (mm a^{-1})

4.3.3.1 Stope prirasta sedre (mm a^{-1}) – testna ploha SB

Na svim pločicama postavljenim na odabranim lokacijama (ID 1-14) u toku rijeke Krke tijekom godine dana, zabilježena je pojava sedrenja. Na svakoj lokaciji dvije susjedne pločice su bile izložene djelovanju vode na udaljenosti ne većoj od 30 cm. Nekoliko tjedana nakon prvog postavljanja pločica na većini njih, izuzev PL09 i 22, uočeno je oblaganje površine s tankom karbonatnom ovojnicom, a negdje je primijećen početak kolonizacije ličinki vodenih insekata na mjernoj površini. Stope prirasta sedre se očekivano značajno razlikuju po lokacijama (Tablica 36) iako su pločice gotovo jednako vremena, na plohi površine od 0,8 ha, bile postavljene u sedrotvornim tokovima. Na temelju digitalnih modela sedre visoke rezolucije izračunat je prosječan prirast sedre po pločicama (n=28) te prema lokacijama (n=14) (Tablica 36).

Tablica 35. Stopa prirast sedre prema pojedinačnim pločicama i lokacijama

ID_ LOKACIJA	PL	STOPA PRIRASTA SEDRE (mm a^{-1})			
		Toplo razd. (ožu., 18 – ruj., 18)	**Hladno razd.** (ruj., 18 – ožuj., 19)	**Ukupno po PL** (ožu., 18 – ožu., 19)	**ID_LOKACIJA**
1	PL03	2,979	2,090	5,069	**5,145**
	PL16			5,221	
2	PL02			6,256	**6,659**
	PL13	5,741	1,321	7,062	
3	PL10	3,476	3,273	6,750	**6,770**
	PL12			6,790	
4	PL11			4,613	**4,629**
	PL27	4,042	0,603	4,645	
5	PL19			3,554	**3,298**
	PL24	2,833	0,209	3,042	
6	PL04			4,030	**3,818**
	PL21			3,605	
7	PL05			3,577	**3,488**
	PL18	1,734	1,665	3,399	
8	PL06	2,093	2,392	4,485	**4,376**
	PL08			4,266	
9	PL29	2,363	3,355	5,718	**5,933**
	PL14			6,147	
10	PL28			8,260	**9,081**
	PL15	7,003	2,899	9,902	
11	PL23	2,074	4,024	6,098	**6,075**
	PL30			6,052	
12	PL01			1,368	**1,474**
	PL26			1,580	
13	PL09			0,506	**0,327**
	PL22	0,095	0,053	0,148	
14	PL07			32,293	**19,302**
	PL25	3,646	2,666	6,312	
SREDNJAK		**3,173**	**2,046**	**5,741**	**5,771**

Velika varijabilnost u stopama prirasta sedre je očekivana. Gledajući pojedinačno po pločicama, zabilježene su vrijednosti prirasta od 0,15 (PL22) do 32,29 mm a^{-1} (PL07), a prema lokacijama od 0,327 (ID13) do 19,302 mm a^{-1} (ID14) (Slika 145).

Srednja stopa prirasta sedre po pločici (n=28) iznosi 5,741 mm a^{-1}, a prema lokaciji (n=14) 5,771 mm a^{-1}. Standardna devijacija od 5,66 mm a^{-1} prema pločicama te 4,319 mm a^{-1} prema lokacijama odražava znatnu raspršenost rezultata od srednjeg prirasta sedre. To je čimbenik koji se često zanemaruje kad se primjenjuje metoda masenog prirasta (Drysdale i Gillieson 1997). Uzimajući u obzir sve pločice te vrijeme izloženosti toku sedra je prosječno rasla 16,2 μm po danu. Ako bi se iz analize isključile ekstremno niske i visoke vrijednosti, odnosno ID13 gdje su pločice smještene u stagnantnoj vodi te ID14 gdje je došlo do potpunog obraštanja pločice mahovinom, prosječna stopa prirasta po lokacijama bi iznosila 5,062 mm a^{-1}. Ako bi se iz analize isključila samo PL07 (ID14) na kojoj je došlo do snažnog utjecaja mahovina, onda bi ta vrijednost iznosila 4,758 mm a^{-1}.

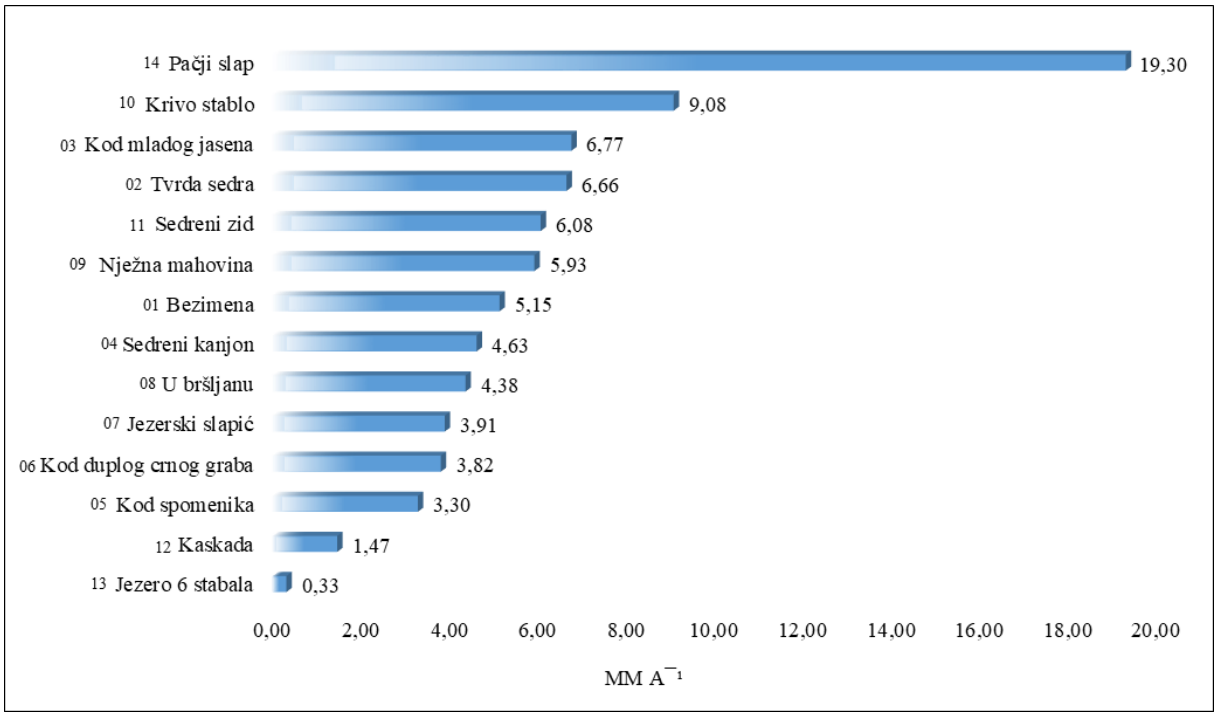

Slika 145. Prirast sedre (mm a^{-1}) prema lokacijama (ID)

Kroz cijelo razdoblje praćenja dinamike formiranja sedre (ožujak, 2018. – ožujak, 2019) najveća zabilježena stopa prirasta za bilo koju točku (uzorak) na mjernoj plohi između dva uzastopna mjerenja iznosila je 45,492 mm a^{-1} (PL07) (Slika 146). Ovako velika vrijednost stope prirasta gotovo je 8 puta veća od prosječne stopa prirasta prema lokacijama (5,771 mm a^{-1}) i posljedica je specifičnih mikro-lokacijskih uvjeta (blizina mahovine, velika količina makrozoobentosa) PL07 koji su detaljno objašnjeni u poglavlju *4.3.4.1.*

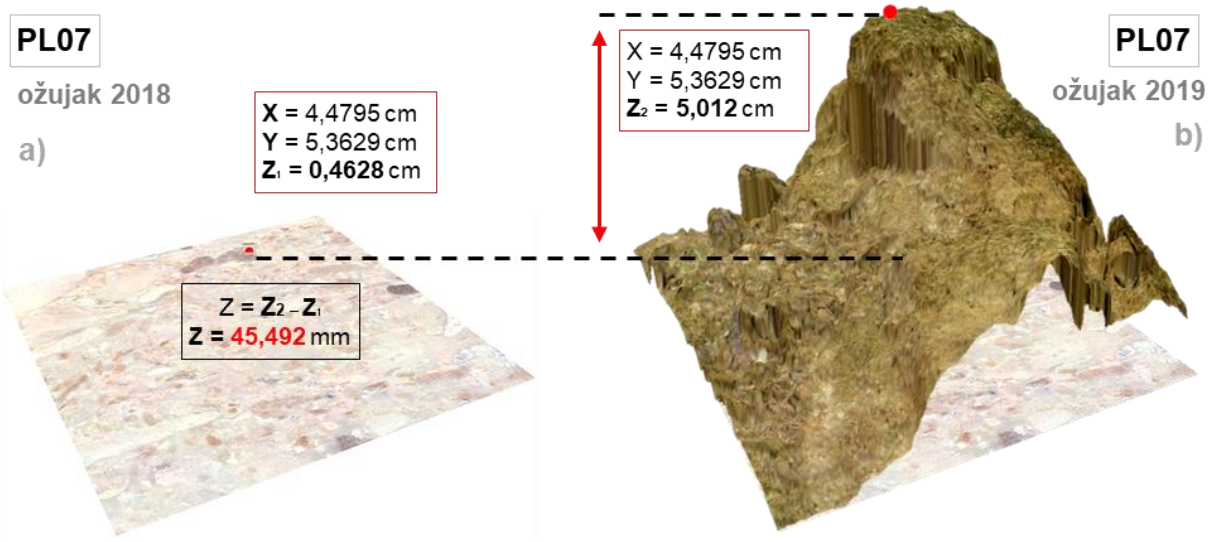

Slika 146. Uzorak s najvećom vrijednosti prirasta u jednogodišnjem praćenju

Nadalje, prosječan prirasta sedre od 5,771 mm a^{-1}, u usporedbi sa stopama prirasta sedre u svijetu (Tablica 6) spada u umjerenu do višu stopu prirasta. U kontekstu usporedbe aktivnih sedrotvornih sustava s obzirom na klimavegetacijska obilježja vrijednost srednje stope prirasta sedre je nešto niža od vrijednosti u području poluaridne mediteranske klime umjerenih visina u središnjoj Španjolskoj (Arenas i dr. 2014 = 7,86 mm a^{-1}, Vázquez-Urbez i dr. 2010 = 7,52 mm a^{-1}) te viša od vrijednosti u području vlažne tropske klime u sjeverozapadnoj Australiji (Drysdale i Gillieson, 1997 = 4,15 mm a^{-1}), snježno šumske klime u Huanglong Ravine, Kina (Liu i dr., 1995 = 1-5 mm a^{-1}, Yoshimura i dr., 2004 = 1 mm a^{-1}) te područja umjerene tople vlažne klime Bad Uracha, Njemačka (Merz-Preiβ i Riding 1999 = 2 mm a^{-1}).

Velika varijabilnost stopa prirasta je očekivana (Arenas i dr., 2010, Arenas i dr., 2014). Ona je posljedica širokog spektra čimbenika koji uključuju: različita mikro obilježja fluvijalnih okruženja u koje su pločice postavljenje (od „stajaće“ do izrazito brze, turbulentne vode) specifične, mikrolokacijske uvjete pojedinih pločica (npr. blizina mahovina, zadržavanje i inkrustacija lišća i grančica) te dinamike snimanja pločica (frekvencija vađenja pločica iz toka).

4.3.3.2 Stope prirasta sedre – testna ploha (RS)

Nakon šest mjeseci iz toka su izvađene dvije pločice s lokacije *Kod mlinice* te jedna s lokacije *Slomljeno svrdlo*. Sedra je istaložena samo na PL30 i 43 (*Kod mlinice*) koje su smještene u fluvijalnom okruženju koje je najsličnije lokacijama zone prskanja (SZ) na testnoj plohi SB-a (Tablica 37). Na PL41 (*Slomljeno svrdlo*) sedra nije detektirana. Rezultati izmjere na toj pločici spadaju u nesigurnost mjerenja, odnosno razinu pogreške koju CMD generira za

Z koordinatu (vidi poglavlje *4.3.1*). Za lokaciju *Kraj Mlinice* utvrđen je prosječan prirast sedre od 0,408 mm u šestomjesečnom razdoblju.

Tablica 36. Stope prirasta sedre za pločice na testnoj plohi RS

ID	Lokacija	Šifra pločice	Razdoblje od 1.7.2019 do 10.1.2020
15	*Konoplja među smokvama*	35	nije izvađena
	Konoplja među smokvama	40	nije izvađena
16	*Ćelava ogrlica*	36	nije izvađena
	Ćelava ogrlica	38	nije izvađena
17	*Slomljeno svrdlo*	39	nije izvađena
	Slomljeno svrdlo	41	**rezultati u razini pogreške CMD-a**
18	*Kraj mlinice*	30	**0,244**
	Kraj mlinice	43	**0,571**

Potrebno je istaknuti da je lokacija *Slomljeno svrdlo* prema fluvijalnim obilježjima slična ostalim lokacijama na RS-u (*Konoplja među smokvama* i *Ćelava ogrlica*) s kojih pločice nisu vađene te je reprezentativni primjer biohidroloških uvjeta na Roškom slapu. Na njoj nema sedre, tek se mogu uočiti manje zelenkaste nakupine algi (Slika 147). Za očekivati je stoga da u budućim mjerenjima sedra vjerovatno neće biti detektirana na pločicama *Konoplje među smokvama* i *Ćelavoj ogrlici*.

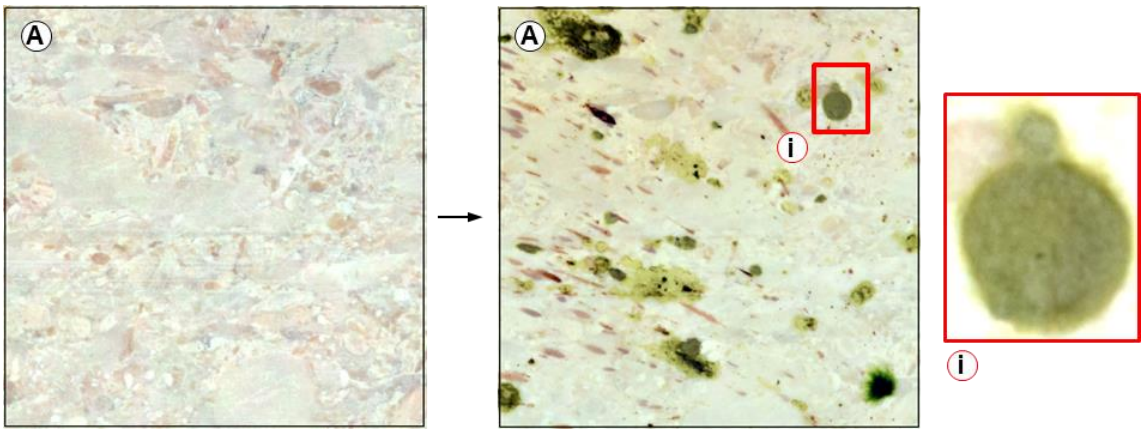

Slika 147. DOF A) inicijalnog i B) završnog stanja PL41 s i) nakupinama algi

4.3.3.3 Praćenje dinamike sedrenja po poprečnim profilima

S obzirom na činjenicu da se svaka pločica u LCS-u nalazi na istoj lokaciji (uvažavajući utvrđenu kvalitetu mjerenja) moguće je intervalno praćenje prirasta i/ili erozije sedre prema poprečnim presjecima. Naime, usporedbom uzastopnih visinskih vrijednosti unutar presjeka može se odrediti vertikalni pomak unutar svake točke. Na slikama 148 i 149 prikazan je primjer praćenja prirasta i erozije sedre prema poprečnom presjeku A-A' na PL25 (*Pačji slap*). Vertikalni pomak sedre je praćen kroz 1693 lomne točke odabranog poprečnog presjeka. U presjeku A-A' uočena su tri erozivna događaja (Slika 149).

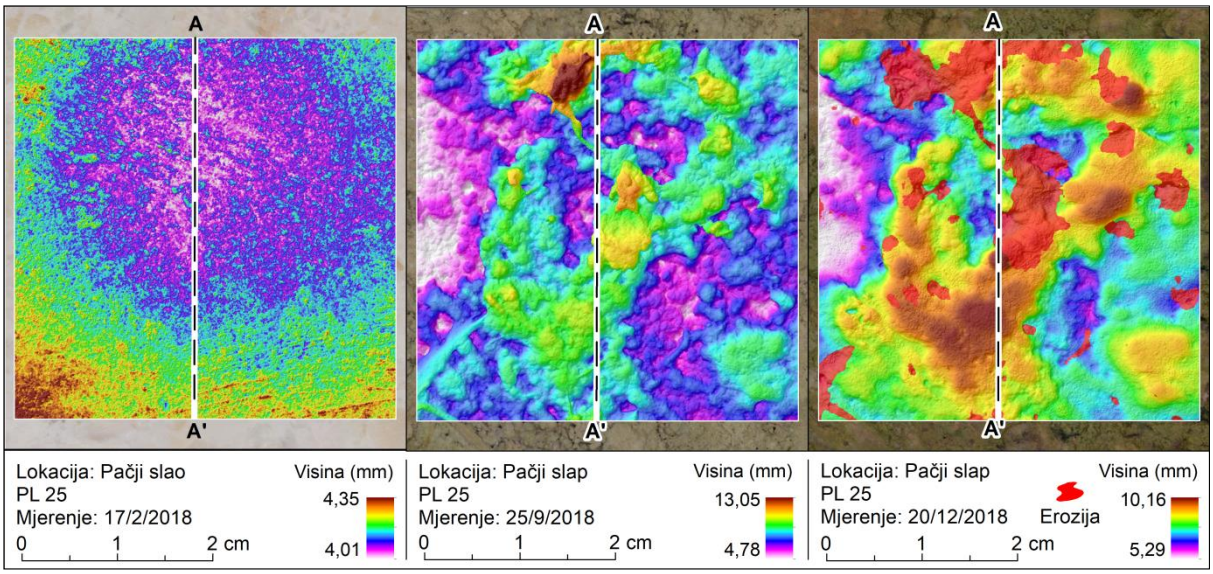

Slika 148. Primjer poprečnog presjeka A-A' na PL25

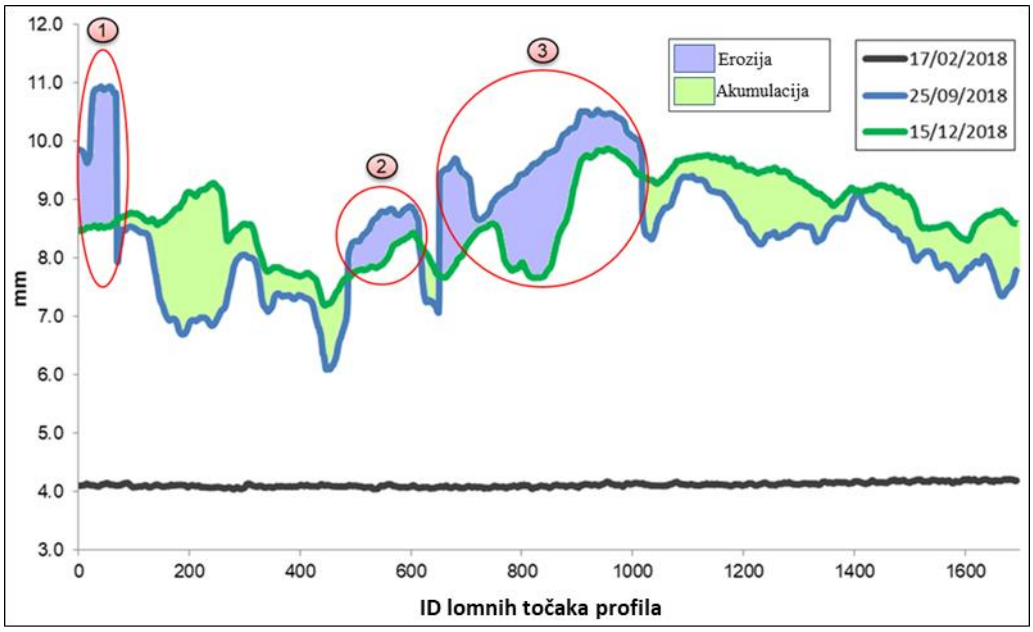

Slika 149. Vertikalni pomak sedre u presjeku A-A' te primjeri uočenih erozivnih događaja

Iz izvedenih visinskih uzoraka (n=1693) moguće je izračunati razliku visina preuzetih s intervalnih digitalnih modela sedre visoke rezolucije, pri čemu se rezultati mogu prikazati sumarno za sve točke. U tablici 38 dan je primjer za poprečni presjek A-A' na PL25 (*Pačji slap*).

Tablica 37. Statistički parametri izvedeni iz presjeka A-A'

	Vrijednosti (mm)
Count (pix.)	1693,000
Max.	2,437
Mean	0,170
Min.	-2,396
Range	4,833
SD	1,052

4.3.4 Stope prirasta sedre (mm a^{-1}) susjednih pločica

4.3.4.1 Stope prirasta sedre (mm a^{-1}) susjednih pločica - SB

Kako bi se ispitao utjecaj mikrolokacijskih čimbenika koji utječu na prirast sedre u istraživanju je provedeno postavljanje parova pločica u isto fluvijalno okruženje na gotovo istu X, Y i Z lokacije. Istraživanja gdje su dvije ili više pločica postavljenje u isto fluvijalno okruženje gotovo na istoj X, Y i Z lokaciji nema puno. Naime, u dosadašnjim istraživanjima dinamike sedrenje na odabrane lokacije je uglavnom postavljanja po jedna testna pločica te je rađena usporedba između različitih fluvijalnih okruženja (Arenas i dr., 2010, Auqué i dr., 2013, Auqué, i dr., 2014, Arenas i dr., 2014).

Iz izvedenih rezultata može se uočiti sljedeće. Usprkos činjenici da su parovi pločica bili postavljeni na gotovo istu X, Y i Z lokaciju, s razmakom ne većim od 30 cm, prosječna razlika u prirastu sedre između njih je iznosila 2,2165 mm a^{-1}. Na udaljenosti od 30 cm ne mogu se značajno razlikovati fluvijalno-kemijski parametri vode, stoga je ovako velika razlika u prirastu između susjednih pločica (gotovo godišnji prirast sedre u nekim sedrotvornim sustavima) posljedica drugih specifičnih mikrolokacijskih uvjeta koji su objašnjeni u nastavku tekstu. Na slici 150. može se uočiti da lokacija *Pačji slap* najviše utječe na razliku prirasta između susjednih pločica.

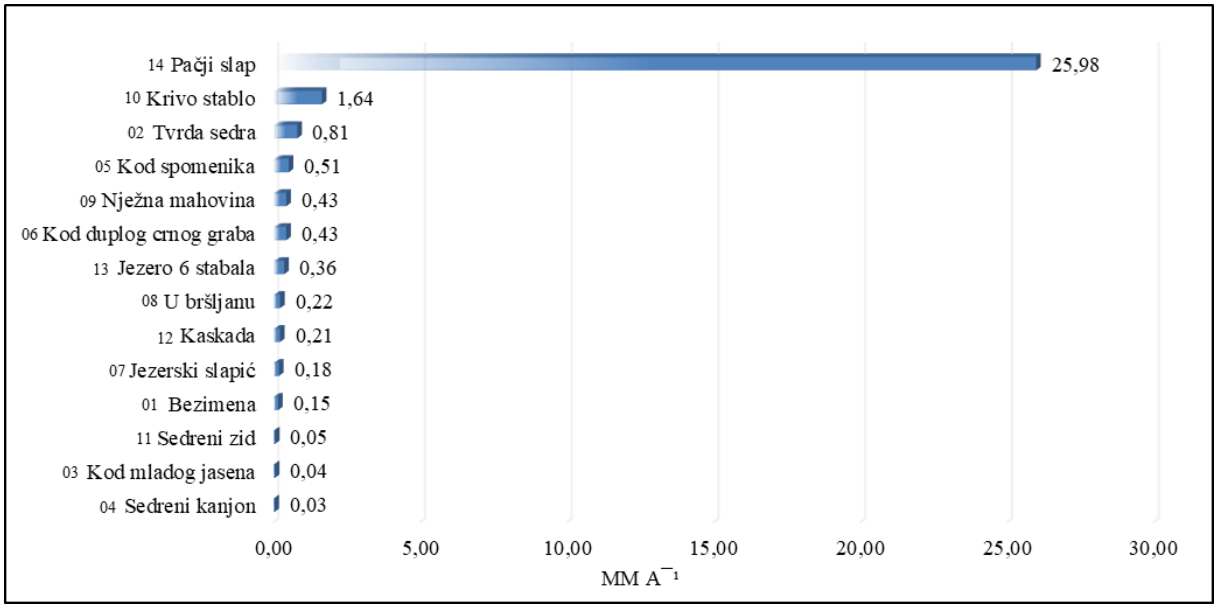

Slika 150. Razlika u prirastu sedre između susjednih pločica na svim lokacijama (ID)

Najmanja razlika između susjednih pločica je zabilježena na lokaciji *Sedreni kanjon* u iznosu od 0,033 mm a^{-1}, a najveća na lokaciji P*ačji slap* u iznosu od čak 25,981 mm a^{-1}. Standardna devijacija iznosi 6,852. Na svim lokacijama osim na *Pačjem slapu* i *Krivom stablu* je zabilježena razlika u visini sedre između susjednih pločica veća od 1 mm a^{-1}. Razlika od 1,642 mm a^{-1} na lokaciji *Krivo stablo* je posljedica zadržavanja i inkrustacije lista na površini mjerene plohe PL15 (Slika 151).

Slika 151. Zadržavanje i inkrustacija lista na PL15 (*Krivo stablo*)

Razlika u prirastu sedre od 25,981 mm a^{-1} na dvije susjedne pločice lokaciji *Pačji slap* posljedica je specifičnosti obilježja mikrolokaliteta PL07. Naime, na slici 152a se može vidjeti da je PL07 postavljena u neposrednoj blizini nakupine mahovina dok je susjedna PL25 nešto udaljenija. Također, PL25 je imala veću frekvenciju vađenja od PL07. Ona je iz toka vađena svaka tri mjeseca, dok je PL07 izvađena tek nakon godine dana. Vađenje i sušenje PL25 poremetilo je razvoj zajednice mahovina što je za posljedicu imalo usporavanje prirasta sedre. Vraćanjem u vodu ponovno je trebalo doći do rekolonizacije ove zajednice na mjernu plohu. Dakle, kod PL25 je stoga došlo do povremenih prekida procesa precipitacije sedre, a frekventnijim vađenjem onemogućeno je da mahovine u potpunosti prerastu mjernu površinu PL25. Rastom mahovina preko PL07 (Slika 152b-c) postupno se povećala nukleacijska površina, a time i prirast sedre na mjernoj površini.

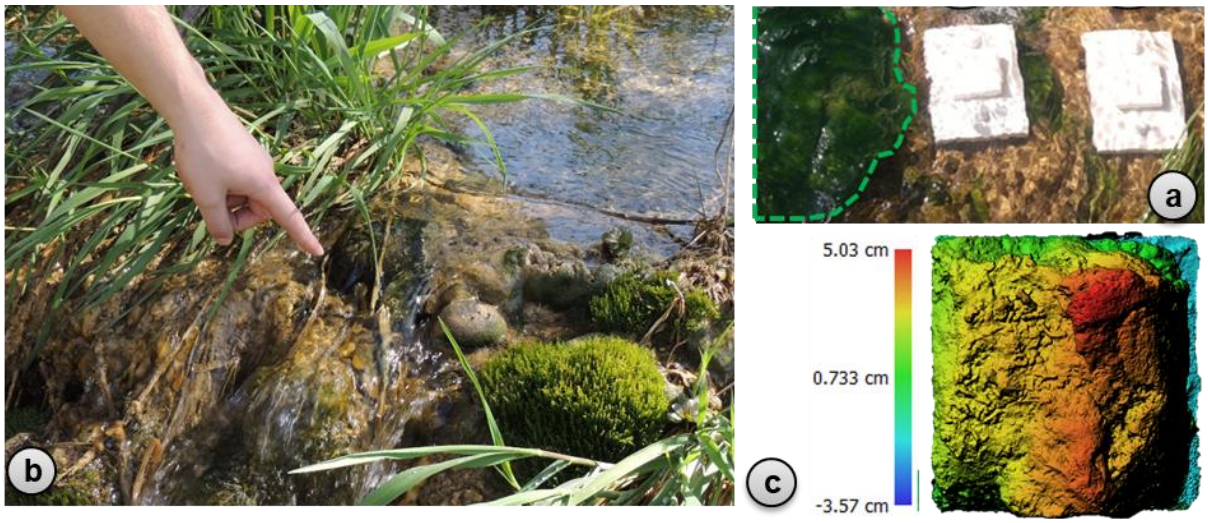

Slika 152. a) PL07 postavljena u neposrednoj blizni mahovina b) mahovine u potpunosti prerasle PL07 b) izvedeni DTHRM PL07

Slična situacija zabilježena je na lokaciji *Nježna mahovina* gdje je PL14 u odnosu na susjednu pločicu postavljena u neposrednoj blizini mahovine (Slika 153a). Razlika u stopi prirasta između njih iznosi samo 0,429 m a^{-1}. Razlog tome je taj da mahovina u godini dana nije stigla u potpunosti prerasti cijelu površinu pločice. Najvećim dijelom je zahvatila njen rub, tako da prostor mjerne površine (MS) nije bio u potpunosti zahvaćen (Slika 153b).

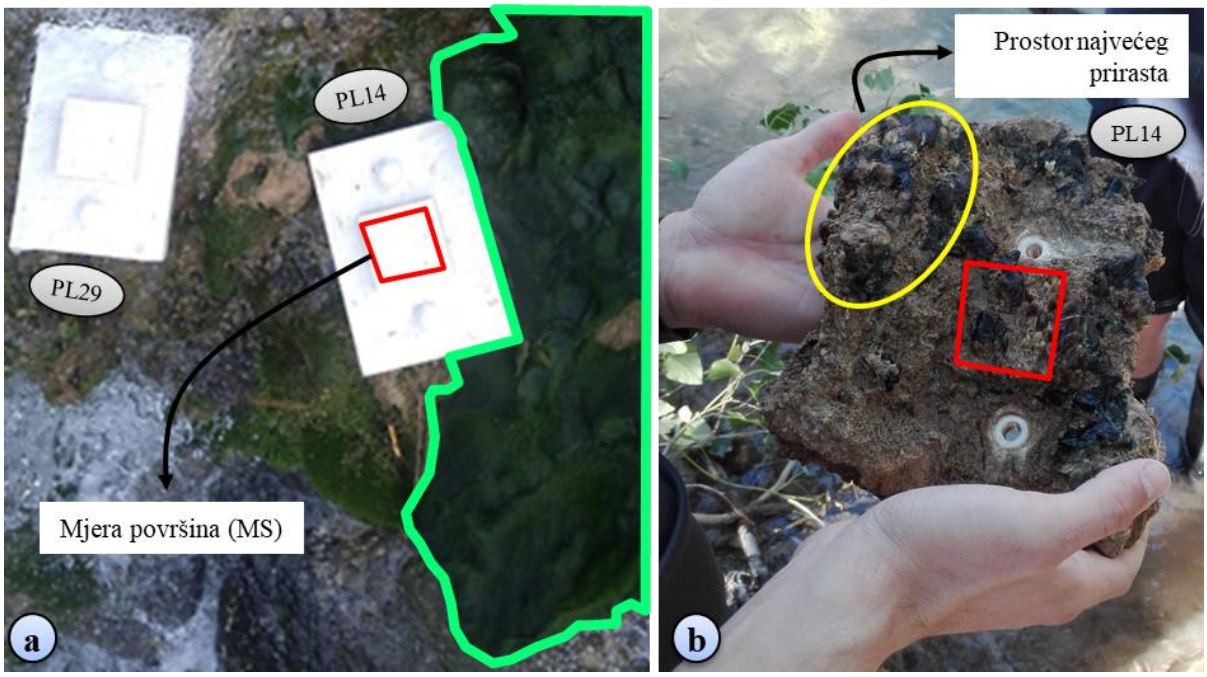

Slika 153. a) PL14 postavljena u neposrednoj blizni mahovine b) prostor najvećeg prirasta u odnosu na mjernu površinu pločice

Mogu se sagledati razlike u stopama prirasta sedre između susjednih pločica u kontekstu isključenja ovih lokacija iz analiza. Naime, ako bi se iz analize isključile navedene tri lokacije, u kojima je razlika u prirastu sedre bila posljedica neposredne blizine mahovina (*Pačji slap* i *Nježna mahovina*) te lista koji se inkrustrirao na mjernoj plohi PL15 *(Krivo stablo*), onda bi razlika prirasta sedre između pločica iznosila tek 0,2709 mm što je 8 puta manje od vrijednosti (2,2165 mm) ako se u obzir uzmu sve lokacije. SD za ovih 11 lokacija iznosi 0,238 mm a^{-1} što je za više od 28 puta manje ako se gleda svih 14 lokacija.

Ipak, uloga mahovina u prirastu sedre ne smije biti zanemarena. Primjerice, Wallner (1934) i Weijermars i dr. (1986) ističe da mahovine mogu biti iskorištene za potrebe stvaranja prirodnih obraštaja na umjetnim podlogama. Navode da mahovine *Cratoneuron commutatum* i *Bryum pseudotriquetrum* mogu oblikovati spužvaste slojeve sa stopom prirasta do čak 14 cm a^{-1}.

4.3.5 Stope prirasta (mm a^{-1}) sedre prema frekvenciji vađenja

Frekvencija vađenja te naknadni proces sušenja, snimanja i vraćanja pločice u tok nije jednako djelovao na dinamiku formiranja sedre. Za očekivati je bilo da će pločice (n=12) koje su vađene intervalno (3 i 6 mjeseci) imati manji prirast od susjednih pločica koje su izvađene nakon godine. Naime, veća frekvencija snimanja znači češće prekidanje procesa precipitacije, poremećaj razvoja, odnosno životnog ciklusa sedrotvornih organizma i mahovina te predisponiranje sedre za eroziju. Navedeno može za posljedicu imati usporavanje prirasta sedre. Od 12 lokacija, na kojem je jedna pločica vađena intervalno (3 i 6 mjeseci), na sedam njih (*Pačji slap, Kod spomenika, Nježna mahovina, Jezero 6 stabala, Jezerski slapić, Bezimena, Kod mladog jasena*) pločica koja ima veću frekvenciju vađenja ima manju stopu prirasta sedre. Na ovih sedam lokacija na pločicama koje su imale veću frekvenciju snimanja nastalo je u prosjeku 3,95 mm sedre manje u odnosu na susjednu pločicu. Na izvedene vrijednosti značajno utječe lokacija *Pačjeg slapa* (Slika 154).

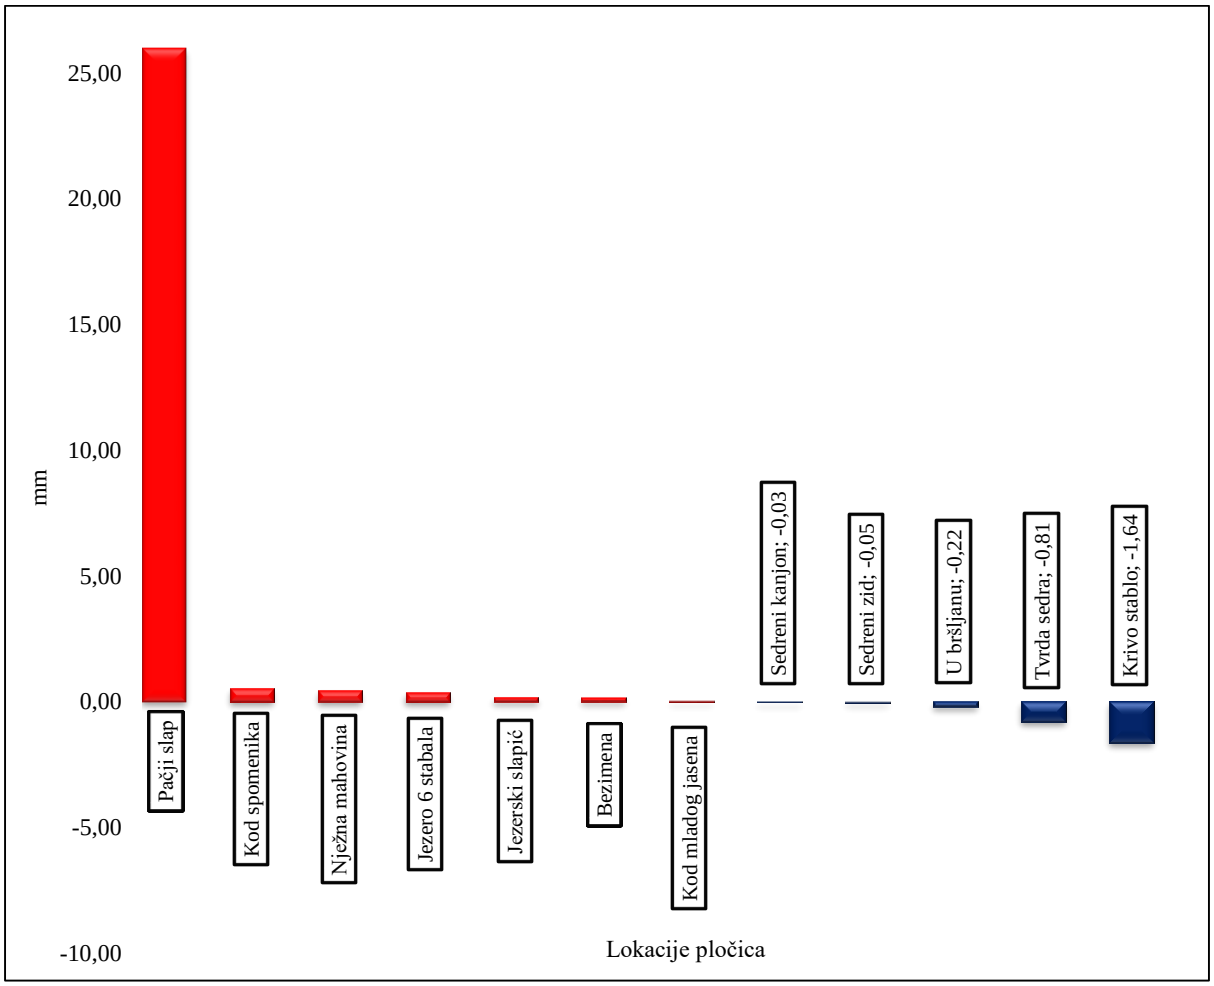

Slika 154. Razlike (mm) u prirastu sedre prema frekvenciji vađenja
(crvena - lokacije gdje su pločice s manjom frekvencijom vađenja imale veći prirast, plava - obrnuto)

Na ostalih pet lokacija (*Krivo stablo, Tvrda sedra, U bršljanu, Sedreni zid i Sedreni kanjon*) na pločicama koje su imale veću frekvenciju snimanja nastalo je u prosjeku 0,55 mm više sedre u odnosu na susjedne pločice koje su snimane nakon godine dana. Razlika od 1,64 mm za lokaciju *Krivu stablo* posljedica je zadržavanja i inkrustacije lista na mjernoj plohi PL15. Iako je PL15 snimana intervalno, na njenoj mjernoj plohi je tijekom vremena izloženosti toku došlo do zadržavanja i inkrustacije lista, što je povećalo stopu prirasta sedre. Gledajući sve lokacije na kojima je dinamika sedrenja praćena s većom frekvencijom (3 i 6 mjeseci) snimanja utvrđen je u prosjeku veći prirast sedre (2,08 mm) na pločicama koje su vađene s manjom frekvencijom snimanja (nakon godine dana). Iz navedenoga se može zaključiti da proces vađenja, sušenja, snimanja te ponovnog postavljanja pločica u tok potencijalno inhibira proces sedrenja. Ipak, specifičan splet mikrolokacijskih čimbenika (zadržavanje biljnih fragmenata) takav trend može preokrenuti (npr. *Krivo stablo*).

4.3.6 Stope prirasta (mm a^{-1}) sedre prema temperaturnom razdoblju (sezoni)

U nastavku su izvedene stope prirasta sedre prema temperaturnom razdoblju (sezoni). Iz izvedenih podataka mogu se uočiti sljedeće značajke reaktiviranog sedrotvornog sustava. U prosjeku je za svih 28 testnih pločica zabilježen 1,55 puta veći prirast sedre u toplijem (proljeće-ljeto) (3,173 mm a^{-1}) u odnosu na hladnije razdoblje (jesen-zima) (2,046 mm a^{-1}). Navedeno je značajka većine aktivnih sedrotvornih sustava u Hrvatskoj i svijetu (Matoničkin Kepčija i dr. 2017, Arenas i dr., 2014, Auqué i dr., 2014, Arenas i dr., 2010, Vazque-Urbez i dr., 2010, Kawai i dr., 2006, Kano i dr., 2003, Merz-Preiß i Riding, 1999) jer visoke temperature pogoduju otplinjavanju CO_2, što pogoduje taloženje kalcita (Špoljar i dr., 2011) te potiču razvoj mikroorganizama (Vazquez-Urbez i dr., 2010, Auqué i dr., 2014). Naime, od sredine proljeća do sredine ljeta se odvija najjače osedravanje talusa kao i najjača fotosintetska aktivnost (Sviben, 2012). Ipak, s obzirom na velik vodostaj, plavljenje tijekom zime te česte suše ljeti (Šandrić, 2016) pretpostavilo se da će brzina sedrenja biti veća u hladnijem razdoblju. Naime, zabilježeno je da su uzroci sedre koji su izloženi sušnim periodima u toplijim razdobljima podložniji eroziji te uslijed pojave ekstremnih kišnih događaja mogu bilježiti vrlo niske ili čak negativne stope sedimentacije (Auqué i dr., 2013).

Ne postoji univerzalni zajednički sezonski trend prirasta sedre za sve testne pločice te je varijabilnost rezultata izrazito velika. Tako PL06 (*U bršljanu*), PL23 (*Sedreni zid*) i PL29 (*Nježna mahovina*) bilježe prirast sedre u hladnom razdoblju veći za 0,294, 1,905 i 0,993 mm (Slika 155), odnosno stopa prirasta sedre na tim pločicama je za 1,14, 1,94 i 1,42 puta veća u hladnom u odnosu na toplo razdoblje.

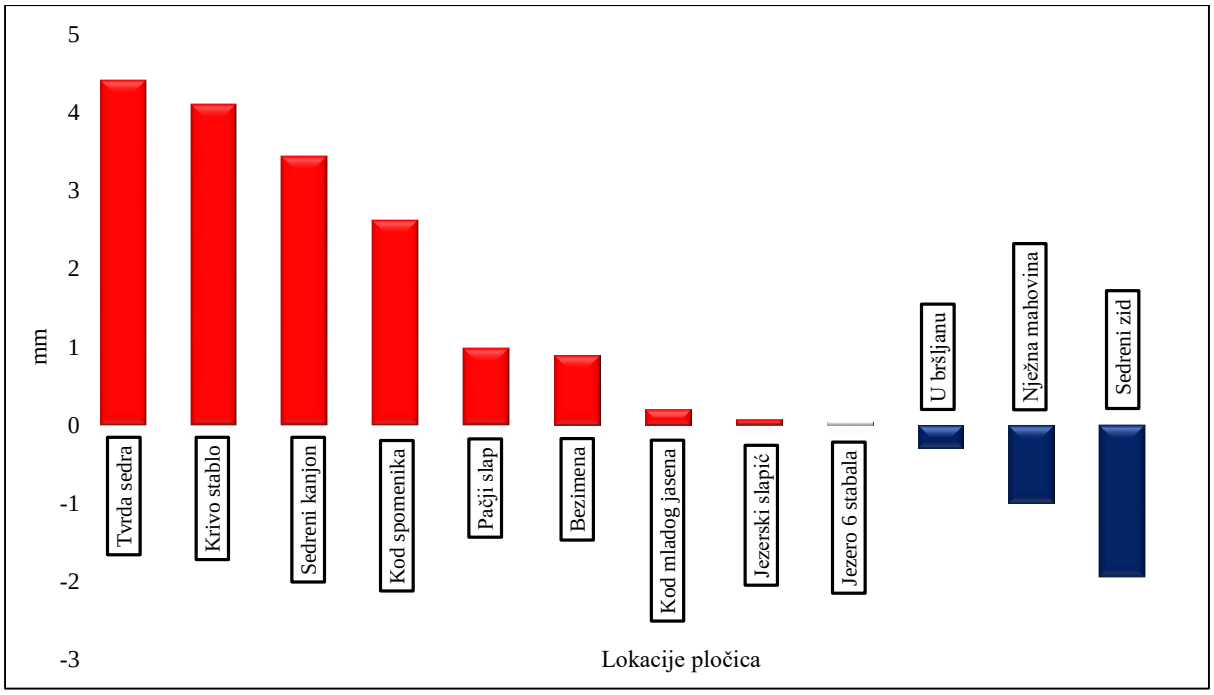

Slika 155. Razlike (mm) u prirastu sedre na u hladnom i toplom razdoblju

(pozitivne vrijednosti označavaju veći prirast u toplom, a negativne vrijednosti veći prirast u hladnom razdoblju

Međutim, iznimke (*U bršljanu, Nježna mahovina* i *Sedreni zid*) od sezonskih uzoraka (pravila) sedrenja nisu iznenađujuće s obzirom na važnost mikrolokacijskih uvjeta u kojima se pločice nalaze (Arenas i dr., 2014, Gradziński, 2010). Na ostalim pločicama veći prirast sedre u toplijem u odnosu na hladno razdoblje varira od 13,54 (PL24) do 1,04 (PL18) puta. Razlog zabilježenom ekstremu na PL24 je presušenje toka koje se dogodilo u hladnom razdoblju zbog čega je proces precipitacije, odnosno izloženost pločice vodi bio prekinut (*vidi poglavlje 4.3.1*).

Dakle, nije utvrđen univerzalni zajednički sezonski trend prirasta sedre za sve testne pločice. Devet od dvanaest pločica ima veći prirast u toplom u odnosu na hladno razdoblje. To potvrđuje važnost lokalnih čimbenika mikro-okoliša (npr. protok vode, blizina mahovine, osvjetljenje) koji su specifični za svaku lokaciju (Gradziński, 2010) te u konačnici određuju stopu prirasta sedre. Nadalje, nije zabilježen slučaj, kao u drugim istraživanjima (Arenas i dr., 2014), da je u hladnom razdoblju došlo do opadanja srednje visine sedre u odnosu na toplo razdoblje unutar mjerne površine pločice.

4.3.7 Stope prirasta (mm a^{-1}) sedre prema tipu fluvijalnog okruženja na SB

Stope prirasta sedre u različitim fluvijalnim okruženjima znatno su se razlikovale. Prema definiranoj klasifikaciji (vidi *poglavlje 3.3.5)* raspon između stopa sedrenja u različitim fluvijalnim okruženjima je iznosio 11,112 mm a^{-1} (Tablica 39).

Tablica 38. Stope sedrenja (mm a^{-1}) u različitim fluvijalnim okruženjima

Fluvijalno okruženje	ID_lokacije	Prosječna stopa sedrenja (mm a^{-1})
(SC) stepenaste kaskade	09, 10, 14	11,439
(FFW) brzo protočna voda	02, 03, 06	5,749
(MFW) umjereno protočna voda	01, 05, 08	4,273
(SZ) zona prskanja	04, 07	4,268
(SZ) sporo protočna voda	11, 12	3,775
(SW) stajaća voda	13	0,327

U reaktiviranom sedrotvornom sustavu odabrane testne plohe utvrđen je prirast sedre od 11,44 mm a-^{1} na lokacijama kaskadnih slapova u blizini mahovina te 5,75 mm a^{-1} na lokacijama s najbržim protokom vode. Najniža stopa prirasta sedre (0,33 mm a^{-1}) zabilježena je na lokacijama "stajaće" vode pri dubini većoj od pola metra i sporijim, manje turbulentnim tokovima (3,78 mm a^{-1}). Navedena pojava se može objasniti: manjom debljinom graničnog sloja difuzije koji olakšava migraciju iona prema rastućim kristalima (Gradziński, 2010, Liu i dr., 1995), fizičkim djelovanjem sedrotvoraca (Matoničkin Kepčija i dr., 2006, Horner i dr., 1990) kroz osiguravanje mjesta nukleacije i/ili hvatanja kalcita (Plant, 2019) te činjenicom da su brzina i turbulencija važan faktor koji kontrolira precipitaciju $CaCO_3$ kroz mehaničko gubljenje CO^2 (Arenas i dr., 2010, Vazquez-Urbez i dr., 2010).

Prirast sedre veći je lokacijama kaskadnih slapova, u blizini algi i mahovina nego u fluvijalnom okruženju brzo protočne vode (FFW). Izuzev Izuzev fluvijalnih uvjeta, razlog tomu je fizička aktivnost mikro-organizama (PL14, PL07) koja može značajno utjecati na rast sedre u umjerenim i visokoenergetskim uvjetima. Naime, visokoenergetski protok može uzrokovati "stres" te čak spriječiti kolonizaciju mikro-organizmima na površinu testnih pločica (Gradziński, 2010). Horner i dr. (1990) čak ističu da brzina strujanja veća od 80 cm/s može uzrokovati uklanjanje algalnog perifitona. Povišena brzina, iznad one na koju su alge navikle, može dovesti do povećanja gubitaka i privremeno smanjene biomase (Horner i dr., 1990).

Prirast sedre na odabranoj testnoj plohi odgovara karakteristikama aktivnih sedrotvornih sustava gdje je utvrđeno da postoji tendencija većeg prirasta na lokacijama bržeg

protoka vode (Slika 156) i kaskadnim slapovima, u odnosu na lokacije stagnantne vode i sporiji protok (Arenas i dr., 2010, Gradziński, 2010, Arenas i dr., 2014, Auqué i dr., 2014, Auqué i dr., 2013, Drysdale i Gillieson, 1997, Bono i dr., 2000, Lu i dr., 2000, Liu, 2017, Liu i dr., 1995, Vazque-Urbez i dr., 2010, Zhang i dr., 2012) (Tablica 5).

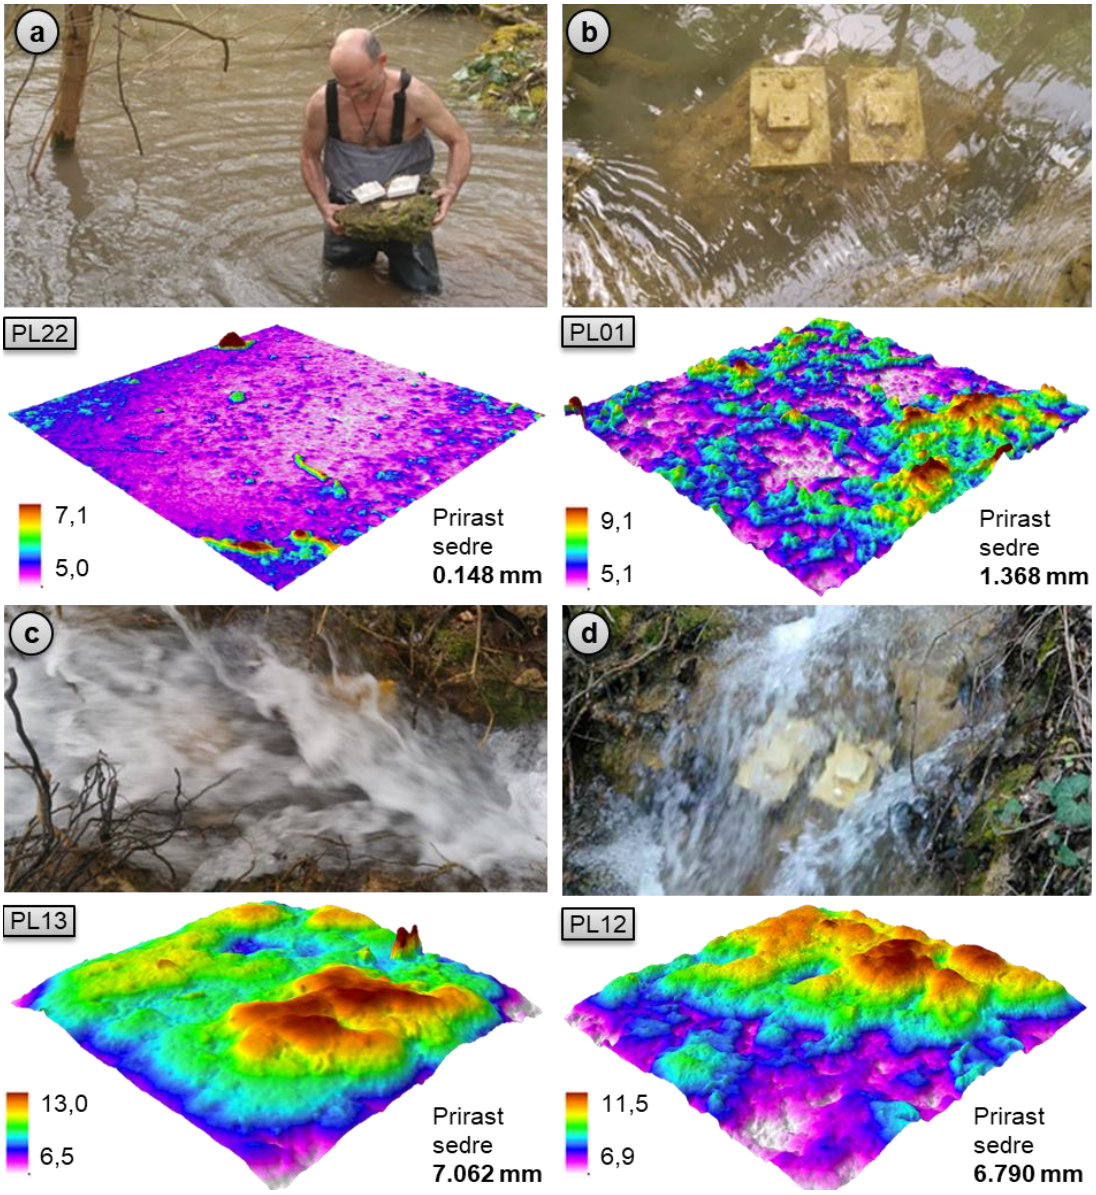

Slika 156. Usporedba visoko-rezolucijskih modela sedre iz fluvijalnog okruženja a) SW i b) SFW u odnosu na c-d) FFW

4.3.8 Volumetrijska analiza testnih pločica – utvrđivanje pojave prirasta i erozije

Vrijednosti erozije i volumetrijskog prirasta (mm^3) su izvedene iz digitalnih modela sedre visoke rezolucije (Tablica 40 i 41). Erozija i volumetrijski prirast su analizirani na 12 pločica koje su iz protoka vađene intervalno, svaka tri (PL13, 25 i 06) ili šest (PL03, 10, 27,

24, 29, 15, 23, 18 i 22) mjeseci. Način izvođenja intenziteta erozije i prirasta sedra je objašnjen u poglavlju *3.3.8 Morfometrijske analize DTHRM-a*.

Tablica 39. Volumetrijski prirast sedre (mm³) za intervalno snimane pločice

Lokacija ID	PL šifra	lipanj – rujan, 2018	rujan – prosinac, 2018	prosinac 2018 – ožujak 2019	rujan 2018 – ožujak 2019	lipanj 2018 – ožujak 2019
		Prirast (+)	Prirast (+)	Prirast (+)	Prirast (+)	Prirast (+)
01	03	nije mjereno	nije mjereno	nije mjereno	**3349,46**	nije mjereno
03	10	nije mjereno	nije mjereno	nije mjereno	**5237,34**	nije mjereno
04	27	nije mjereno	nije mjereno	nije mjereno	**966,48**	nije mjereno
05	24	nije mjereno	nije mjereno	nije mjereno	**343,25**	nije mjereno
09	29	nije mjereno	nije mjereno	nije mjereno	**5369,11**	nije mjereno
10	15	nije mjereno	nije mjereno	nije mjereno	**11305,99**	nije mjereno
11	23	nije mjereno	nije mjereno	nije mjereno	**6442,41**	nije mjereno
07	18	nije mjereno	nije mjereno	nije mjereno	**2682,27**	nije mjereno
13	22	nije mjereno	nije mjereno	nije mjereno	**102,77**	nije mjereno
02	13	**1329,22**	**1090,56**	**1023,70**	**2114,64**	**3305,60**
14	25	**1804,42**	**917,40**	**3651,65**	**4294,23**	**5975,87**
08	06	**2217,81**	**967,93**	**706,42**	**1647,93**	**3858,02**

CMD ima visoku sposobnost otkrivanja erozivnih događaja i volumetrijskog prirasta. U nastavku su detaljnije analizirani odabrani erozivni događaji. Tijekom istraživanjima, na spomenutim pločica (PL 03, PL27, PL24, PL29, PL23, PL18, PL22, PL25 i PL06) zabilježen je proces erozije novonastale sedre koja ovisno o pločici iznosi od 0,003 mm³ do 305,539 mm³. Samo na dvije (PL10 i PL15) od 12 pločica erozivni događaji nisu detektirani. Ove pločice su iz tokova vađene svakih 6 mjeseci.

Tablica 40. Erozija (mm³) sedre izvedena za intervalno snimane pločice

Lokacija_ID	PL_ šifra	lipanj – rujan, 2018	rujan – prosinac, 2018	prosinac 2018 – ožujak 2019	rujan 2018 – ožujak 2019	lipanj 2018 – ožujak 2019
		Erozija (-)	Erozija (-)	Erozija (-)	Erozija (-)	Erozija (-)
01	03	nije mjereno	nije mjereno	nije mjereno	**7,330**	nije mjereno
03	10	nije mjereno	nije mjereno	nije mjereno	**Nema**	nije mjereno
04	27	nije mjereno	nije mjereno	nije mjereno	**3,004**	nije mjereno
05	24	nije mjereno	nije mjereno	nije mjereno	**8,695499**	nije mjereno
09	29	nije mjereno	nije mjereno	nije mjereno	**0,365841**	nije mjereno
10	15	nije mjereno	nije mjereno	nije mjereno	**Nema**	nije mjereno
11	23	nije mjereno	nije mjereno	nije mjereno	**0,041488**	nije mjereno
07	18	nije mjereno	nije mjereno	nije mjereno	**18,376956**	nije mjereno
13	22	nije mjereno	nije mjereno	nije mjereno	**18,316643**	nije mjereno
02	13	**138,673**	**0,308**	**0,003**	**Nema**	**1,515**
14	25	**90,663**	**305,539**	**Nema**	**30,092512**	**0,083932**
08	06	**Nema**	**20,453**	**12,417346**	**7,17147**	**Nema**

Na pločicama (PL10 i 15) nije došlo do erozije vjerovatno zbog zadržavanja i inkrustacije lista na mjernoj površini (MS) pločica. To je utjecalo na povećanje nukleacijske površine za precipitaciju sedre (Slika 157). Zbog toga je volumetrijski prirast sedre na navedenim pločicama značajno veći u odnosu na ostale. PL10 u šestomjesečnom razdoblju bilježi prirast od 5237,338 mm^3, a PL15 od čak 11305,995 mm^3 (Tablica 40).

Takav slučaj nije neuobičajen, poznato je da više i niže vodene biljke mogu odigrati važnu ulogu u razvoju sedre kroz pružanje materijala za formiranje novih sedrenih depozita. Mogu se ugraditi u naslage sedre dok su živi ili mogu pružiti drvenaste ostatke koji se kasnije integriraju u sedreni depozit. Materijal u tim ostatcima varira od malih listova i grančica do velikih stabala drveća, a formira fitoklastičnu sedru kada se dogodi proces kalcificiranja (Carthew i dr., 2003).

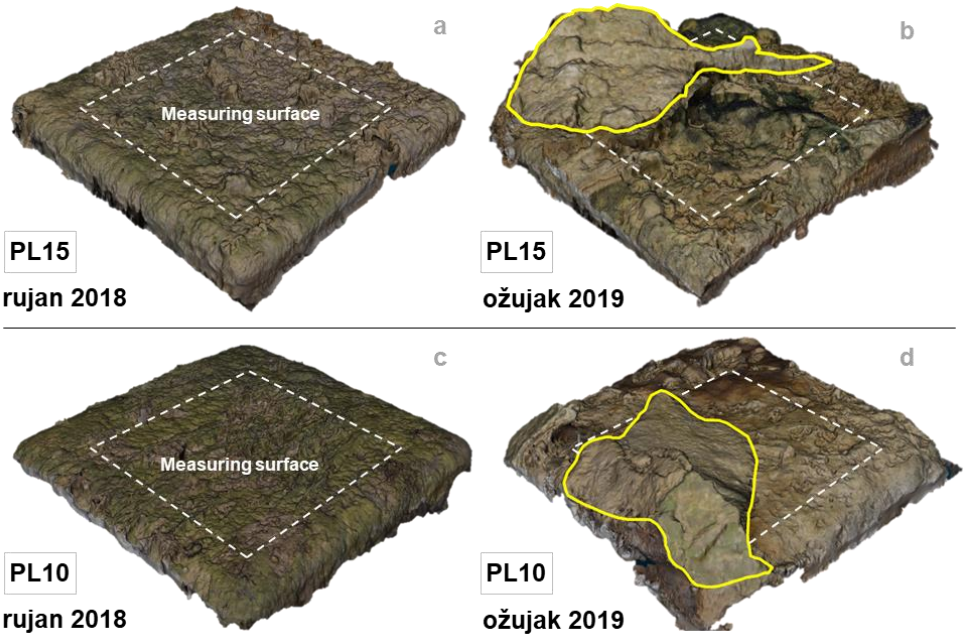

Slika 157. Primjer zadržavanja i inkrustacije lista na mjernoj površini (MS) PL15 i PL10

Najveća količina erozija zabilježena je na PL25 (interval vađenja tri mjeseca) gdje je volumen erodiranog materijala (305,539 mm^3) u razdoblju od rujna 2018. do prosinca 2018. iznosio 33,305% volumetrijskog prirasta (917,397 mm^3) sedre u tom razdoblju (Slika 158). Na istoj pločici zabilježen je najveći intenzitet erozije u tromjesečnim razdobljima u iznosu od 1,270 mm po mm^2. Erozivni događaji su detektirani na gotovo šest puta manjoj površini (240,652 mm^2) od površine prirasta (1358,611 mm^2). Zabilježen je najveći intenzitet erozije zbog specifičnosti površine supstrata, na kojoj su u rujnu, 2018. dominirale veće količine suhih biljnih fragmenata koje nisu u potpunosti učvršćene u podlogu. Prema prosincu, odnosno sljedećem datumu intervalnog snimanja, brzina protoka vode na toj lokaciji je jačala. U jednom trenutku, s obzirom na to da suhi biljni fragmenti nisu bili u potpunosti integrirani u sedrenu podlogu došlo je do odnošenja materijala.

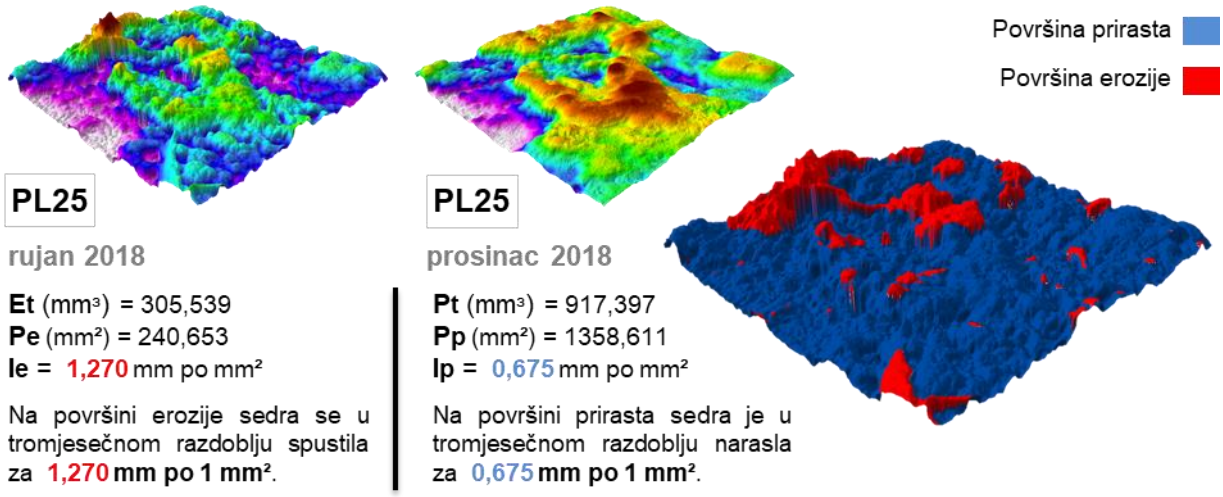

Slika 158. Erozija zabilježena u razdoblju rujan-prosinac, 2018 (PL25)

Na PL13 u razdoblju od lipnja, 2018. do rujna, 2018. erozija je zabilježena na najvećoj površini (245,394) unutar mjerne plohe (Slika 159). Erodirani materijal u tom razdoblju iznosi 138,673 mm³ što 2,2 puta manje od najveće erozije (305,539 mm³) zabilježene na PL25 (Tablica 41). Razlog većoj površini erozije, ali 2,2 puta manjem intenzitetu u odnosu na PL25 (Slika 158) je snaga protoka (>0,8 m/s) te vrste supstrata koji se na površini mjerne plohe uhvatio.

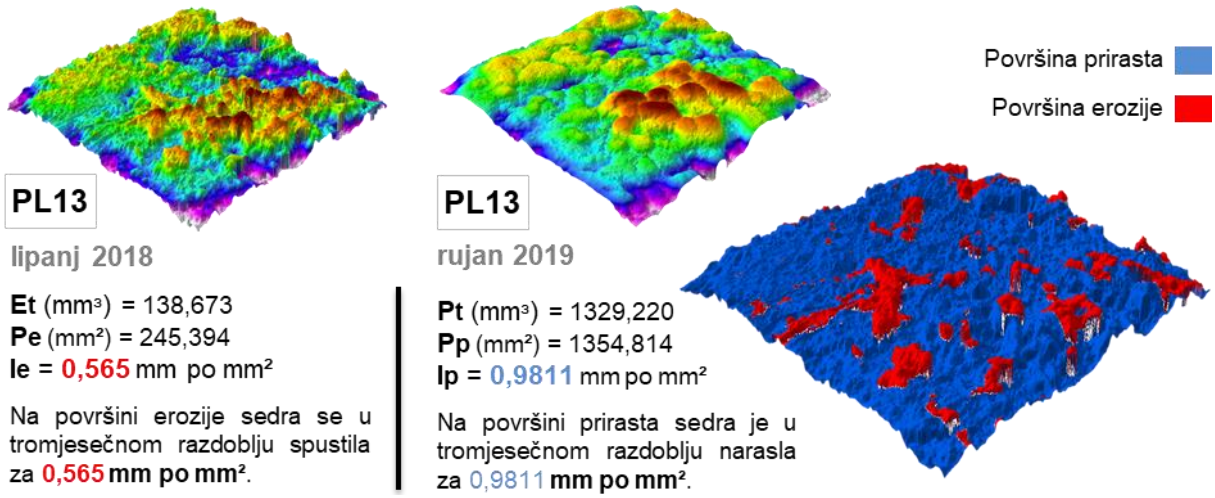

Slika 159. Najveća površina erozivnog događaja zabilježena u razdoblju lipanj-rujan, 2018. (PL25)

Naime, iz visoko-rezolucijskog DOF-a PL13 može se uočiti da je u kolonizacijskoj fazi došlo do naseljavanja mikroorganizama koji izgledaju kao uspravna, cjevasta (eng. *tub-like*) kalcitna tijela (Slika 160). Kolonizacijska faza predstavlja vremenski interval između postavljanja pločice u tok te prvog post instalacijskog mjerenja. U tom razdoblju dolazi do akumulacije karbonata, a mjerna ploha se inicijalno kolonizira s ličinkama vodenih insekata i

mikroflorom. U pravilu stopa prirasta sedre je niža za vrijeme kolonizacijskog u odnosu na druga razdoblja mjerenja. Slične organizme u fluvijalnom okruženju brzo protočnih voda zabilježili su Plant (2019) te Vázquez-Urbez i dr. (2010). Promatrane cjevaste strukture predstavljaju kalcificirane cijanobakterijske ovojnice te skeletne ostatke bivših mikroba (Andreeva, 2007). Nakon vađenja iz toka supstrat je osušen, snimljen te ponovno vraćen u tok. Na pojedinim lokacijama PL13 gdje nakupine mikroorganizama nisu bile dobro učvršćene za supstrat došlo je do erozije (Slika 159) uslijed djelovanja toka. To je uzrokovalo pojavu najveće erozijske površine koja se nije uspjela u potpunosti zapuniti do ožujka 2019. Detaljan pregled erozijskih događaja kroz proučavana razdoblja PL13 prikazan je na slici 167.

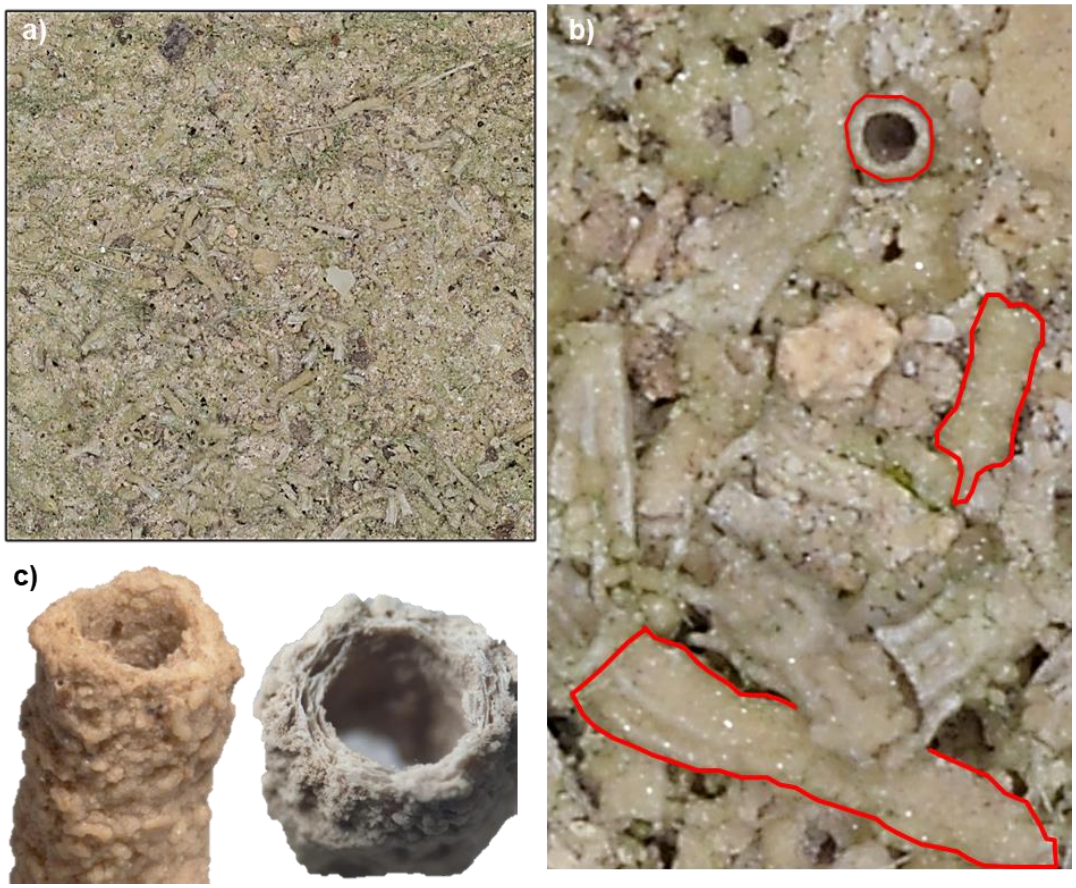

Slika 160. Primjer uspravnih, cjevastih kalcitna tijela na PL13 a-b) te slični oblici c) navedeni u Plant (2019).

Kroz cijelo razdoblje praćenja dinamike formiranja sedre (ožujak, 2018. – ožujak, 2019) najveća zabilježena erozija za bilo koju točku (uzorak) na mjernoj plohi između dva uzastopna mjerenja iznosila je -4,753 mm a^{-1} (PL25) (Slika 161) u tromjesečnom razdoblju (rujan 2018, - prosinac, 2019).

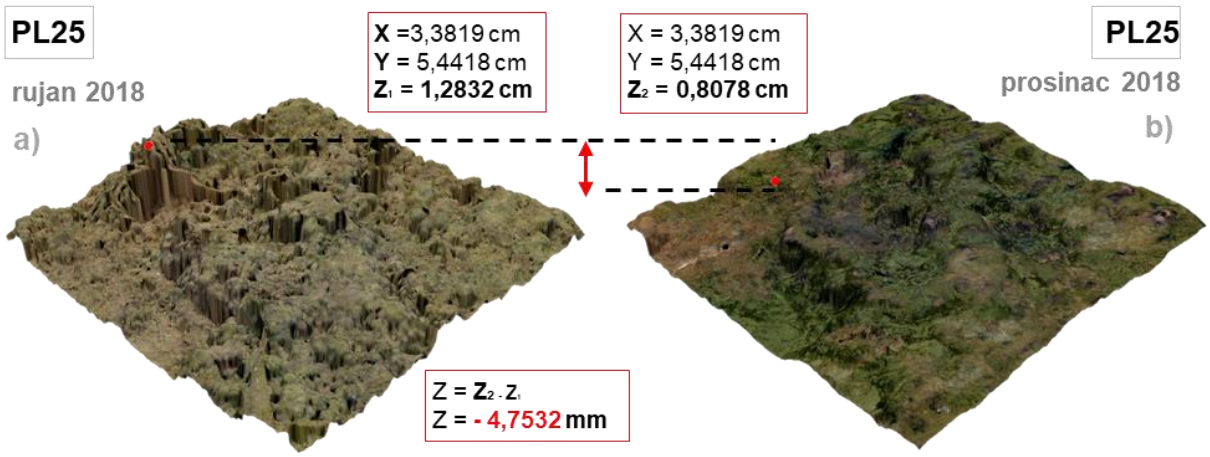

Slika 161. Uzorak s najvećom vrijednosti (-4,753 mm a^{-1}) erozije

Na PL25 zabilježena je veća stopa prirasta sedre u toplijem u odnosu na hladnije razdoblje u iznosu od 0,992 mm a^{-1}. Razlog tome može biti značajan erozivni događaj u hladnom razdoblju (rujan, 2018. - prosinac, 2018.) koji je prema intenzitetu erozije među pločicama najveći (Slika 162). Međutim, malo je vjerojatno da je on glavni razlog veće dinamike sedrenja u toplijem periodu. Naime, na istoj pločici je i u tromjesečnom razdoblju toplog perioda (lipanj, 2018. - rujan, 2018.) također zabilježen erozivni događaji u ukupnom iznosu od 90,663 mm^3 (Slika 162). Razlog eroziji je specifičnost strukture precipitata. Naime, na lokaciji *Pačji slap* gdje je postavljena PL25 prevladava porozna sedra s naslagama mahovina. Arenas i dr. (2014) navode da sedra poroznih naslaga s mahovinama i algama podložnija eroziji od stromatolitne sedre (izražena laminacija).

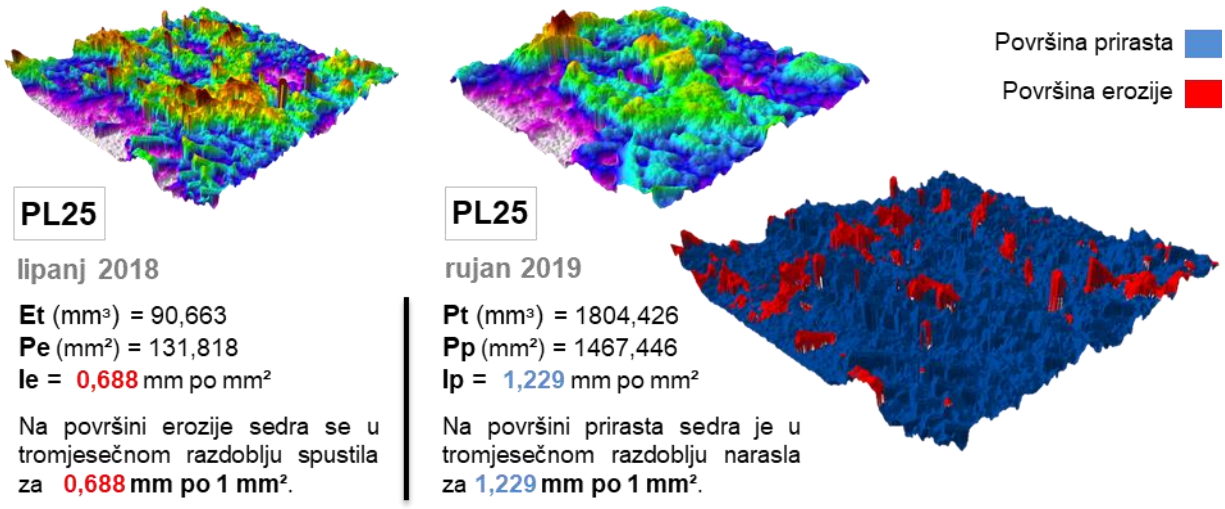

Slika 162. Erozija zabilježena u razdoblju lipanj-rujan, 2018 (PL25)

Nadalje, po količini erodiranog materijala ističe se PL22 gdje je erodiralo 18,317 mm^3 u razdoblju od rujna 2018. do ožujka 2019. To je iznosilo 17,823% volumetrijskog prirasta

sedre u tom razdoblju (102,767 mm³). PL22 je smještena u stajaćoj vodi (*Jezero 6 stabala*) i imala je najnižu stopu prirasta (0,148 mm a^{-1}). Međutim, prilikom vađenja pločice iz jezera izvođeno je lagano ispiranja pločice u jezeru kako bi se s vrha mjerene površine uklonio sedreni mulj koje ne predstavlja formirani precipitat (sedru), a nataložio se dok je pločica bila u jezeru. Vrlo je vjerojatno da je zabilježena erozija dijelom rezultat procesa ispiranja s obzirom na distribuciju erozivnih lokacija na mjernoj površini (Slika 163). Erozivni događaji su detektirani na gotovo sedam puta manjoj površini od površine prirasta (1395,904 mm²). Ipak, specifičnost fluvijalnog mikrookruženja (stagnantna voda, dubina jednog metra, nedostatak svjetla) ove pločice rezultiralo je najnižim intenzitetom prirasta sedre (0,074 mm) u šestomjesečnom razdoblju (rujan, 2018. – ožujak, 2019.) od svih mjerenih pločica.

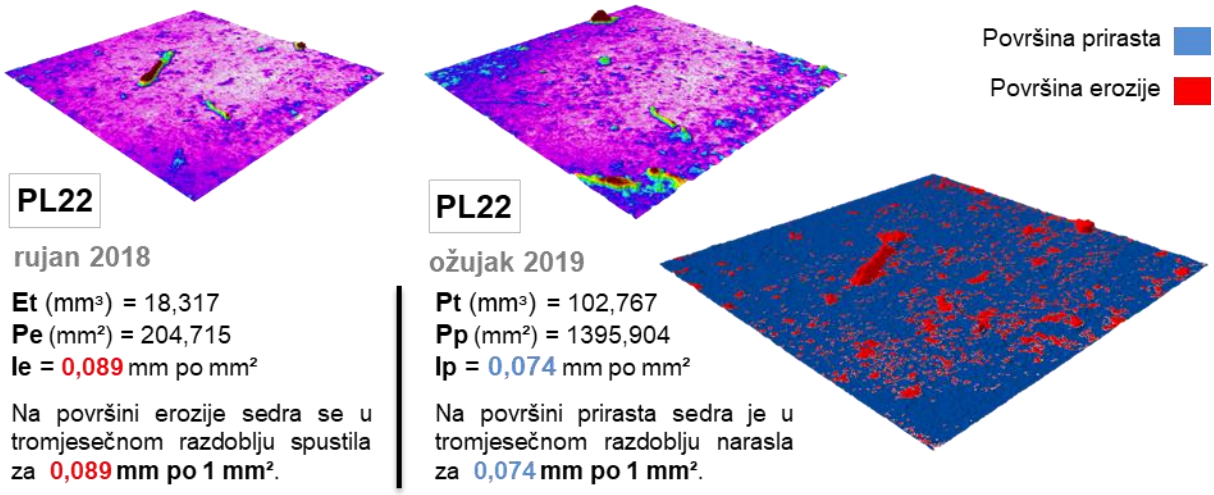

Slika 163. Primjer erozivnog događaja u razdoblju rujan-prosinac, 2018 (PL22)

Na PL06, 23 i 29 je zabilježen veći prirast sedre u hladnijem u odnosu na toplije razdoblje. Arenas i dr. (2014) navode da značajniji erozivni događaji mogu biti posljedica preokreta sezonskog uzorka stopi taloženja, odnosno da prosječni prirast bude veći u hladnom u odnosu na topliji periodu. Iz toga proizlazi da bi značajni erozivni događaji trebali biti uočeni na spomenutim pločicama u toplom, šestomjesečnom (ožujak, 2018. – rujan, 2018.), ili bar tromjesečnom periodu (lipanj, 2018. – rujan, 2018.). S obzirom na to da su pločice za potrebe doktorske disertacije mjerene u razdoblju od godine dana ne postoji dovoljan kontinuitet snimanja kako bi se navedena teza mogla ispitati. Ipak, djelomično se može provjeriti za PL06 koja je intervalno vađena svaka tri mjeseca. Na njoj u tromjesečnom razdoblju toplijeg perioda (lipanj, 2018 – rujan, 2018) nije zabilježena erozija (Slika 164a), dok je u tromjesečnom razdoblju hladnijeg perioda (rujan, 2018. - prosinac, 2018.) zabilježena u iznosu od 20,453 mm³, odnosno intenziteta od 0,377 mm po mm² (Slika 164b).

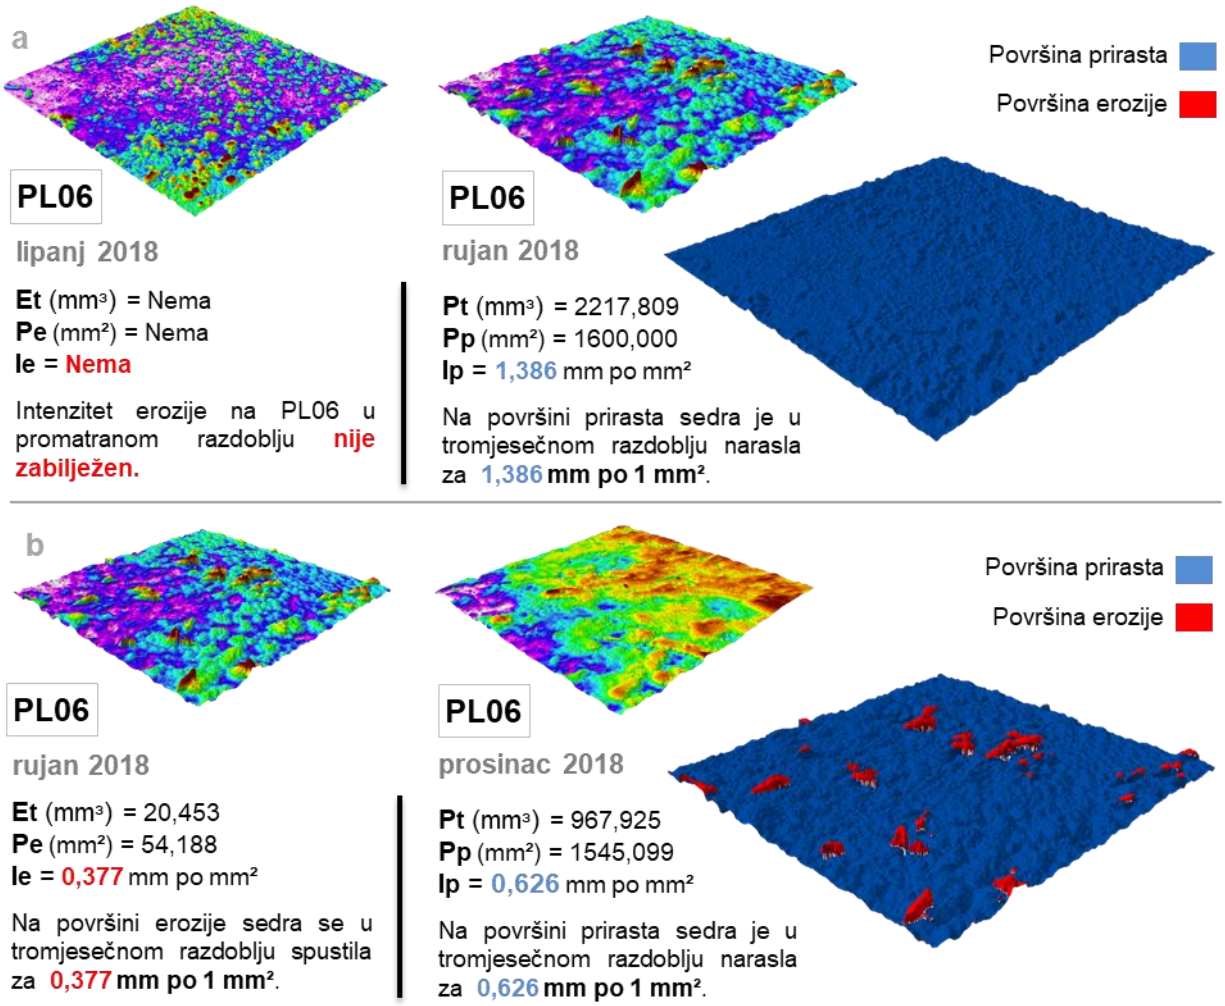

Slika 164. a) Nedostatak erozivnih događaja za PL06 u razdoblju (lipanj, 2018 – rujan, 2018) te b) detektirani erozijski događaji u razdoblju (rujan, 2018. – prosinac, 2018.)

Dakle, usprkos činjenici da u toplijem razdoblju erozije nije bilo, a u hladnijem je ona detektirana, prosječni prirast sedre na PL06 je bio veći u hladnijem razdoblju za 0,299 mm a^{-1}. Stoga u ovom slučaju značajniji erozivni događaji u hladnijem razdoblju nisu mogli utjecati na promjene sezonskog uzorka stopa prirasta.

Iz distribucije i relativno pravilnih oblika zabilježenih erozivnih događaja može se uočiti zanimljiv slučaj erozije makrozoobentosa u razdoblju rujan, 2018. – prosinac, 2018. za PL06 i PL25 koje su imale interval vađenja od tri mjeseca. Naime, na PL06 otkrivena je erozija ličinki iz porodice *Simuliidae (*red: *Diptera)*[98]. Erozija ličinki nije detektirana samo u tromjesečnom razdoblju rujan, 2018. – prosinac, 2018 (Slika 165d), već i na pojedinim lokacijama u šestomjesečnom razdoblju rujan, 2018. – ožujak, 2019 (Slika 165e). Takva višektrana pojava erozije ukazuje da na PL06 nije došlo do dovoljno brzog precipitiranja sedre

[98] Determinaciju je napravila izv. prof. dr. sc. Renata Matoničkin Kepčija (2019).

koje bi moglo zapuniti (nadomijestitit) erozijske događaje, odnosno nestanak ličinki *Simuliidae (*red: *Diptera)*.

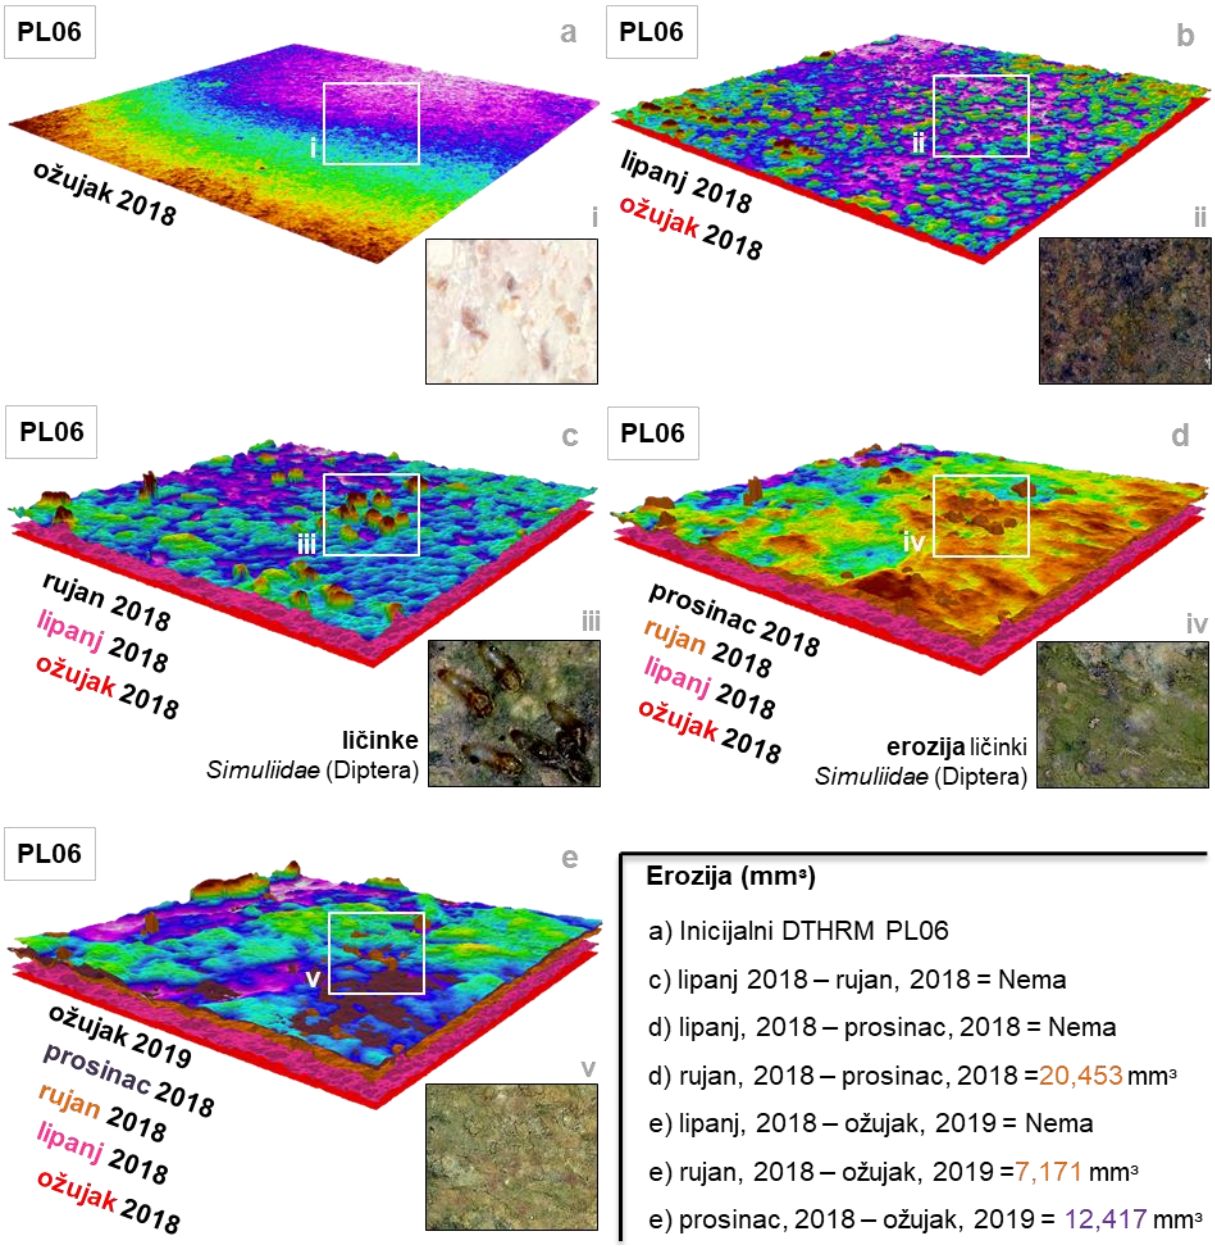

Slika 165. Primjer c, d, e) erozije ličinki iz porodice *Simuliidae (*red: *Diptera)* na PL06

Nadalje, uočen je primjer erozije ličinki vodenih kukaca iz porodice trzalaca *Chironomidae (Diptera)* na PL25 (lokacija: *Pačji slap*) u razdoblju lipanj, 2018. – prosinac, 2018 (Slika 166).

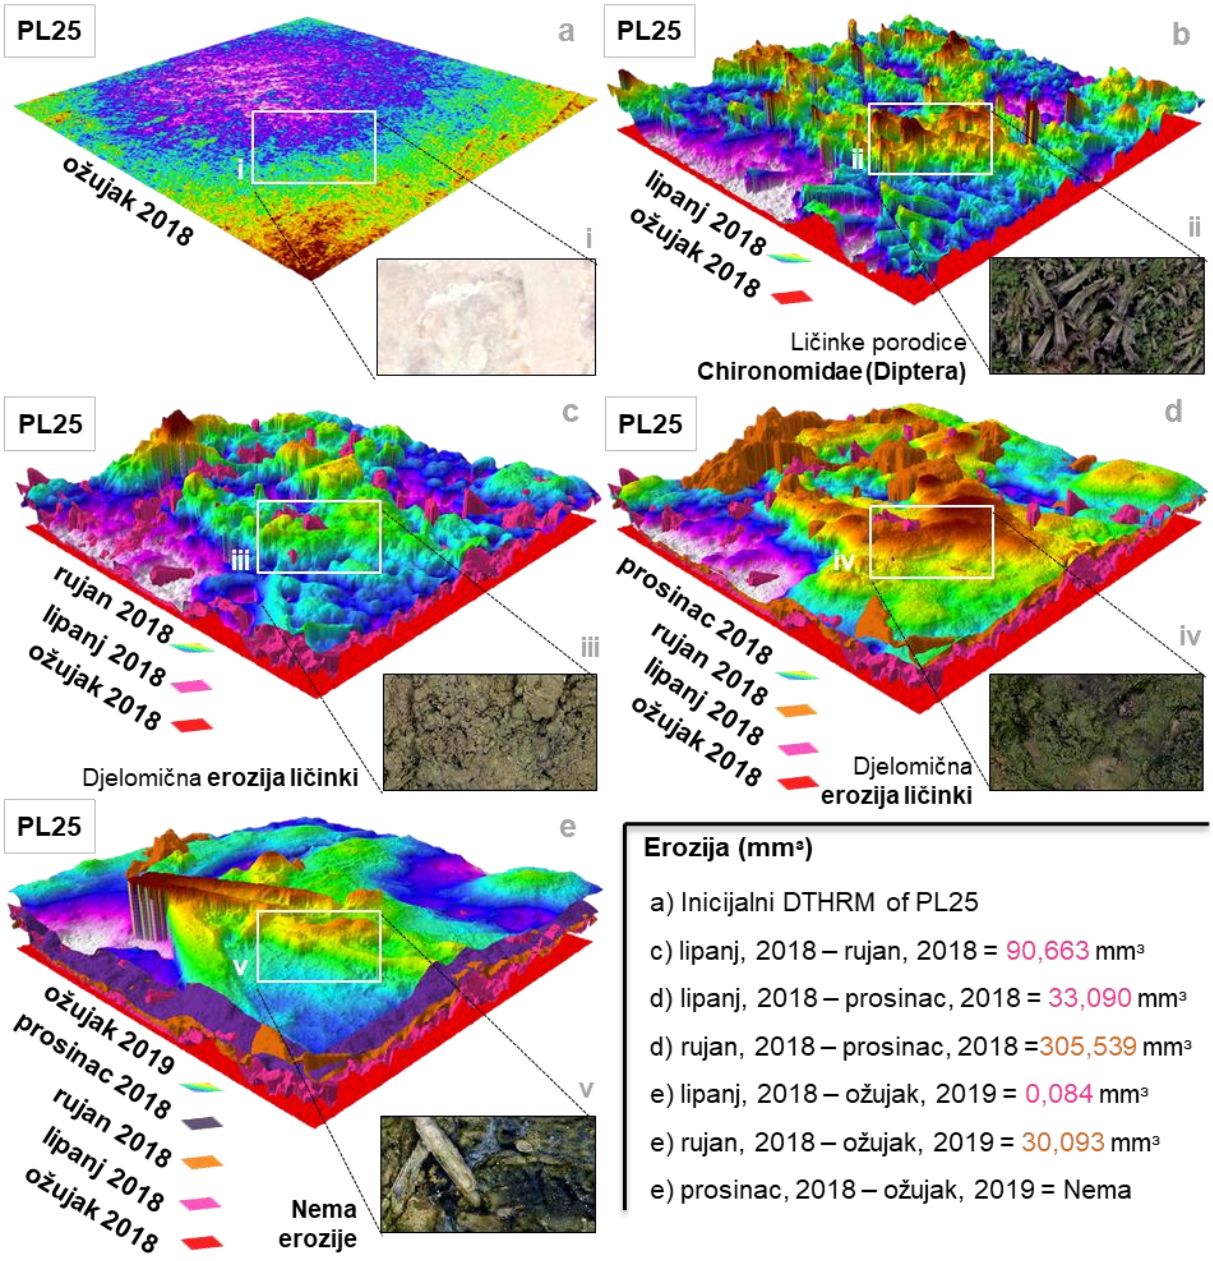

Slika 166. Primjer c-d) erozije ličinki iz porodice *Chironomidae (Diptera)* na PL25

Potrebno je istaknuti i primjer erozije na PL13 (Slika 167) (*Tvrda sedra*) gdje sedra nije stigla precipitirati dovoljno brzo, točnije u intervalu od 9 mjeseci (lipanj, 2018. - ožujak, 2019.) kako bi popunila mjesta erozije naknadnim taloženjem. Razlog tome može biti brzina toka (>0,8 m/s) na navedenoj lokaciji i veća frekvencija snimanja pločice (3 mjeseca). Naime, *Tvrda sedra* je prema specifičnostima fluvijalnog okruženja klasificirana kao brzo protočna voda (eng. FFW). Visokoenergetski protok može uzrokovati stres pa čak i spriječiti mikroorganizme da koloniziraju površinu pločica (Gradziński, 2010). Najveći intenzitet erozije na PL13 zabilježen je u razdoblju lipanj, 2018. – rujan, 2018. (Slika 167c) u iznosu od 0,565 mm po

mm², a odnosi se na ličinke vodenih kukaca koji obiluju na ovoj lokaciji (poglavlje *4.3.9 Detekcija makrozoobentosa*). Usporedbom DTHRM devetomjesečnog razdoblja (lipanj, 2018. - ožujak, 2019) (Slika 167e) erozija je detektirana na 7,049 mm² u iznosu od 1,515 mm³ što daje intenzitet erozije za to razdoblje od 0,215 mm po mm².

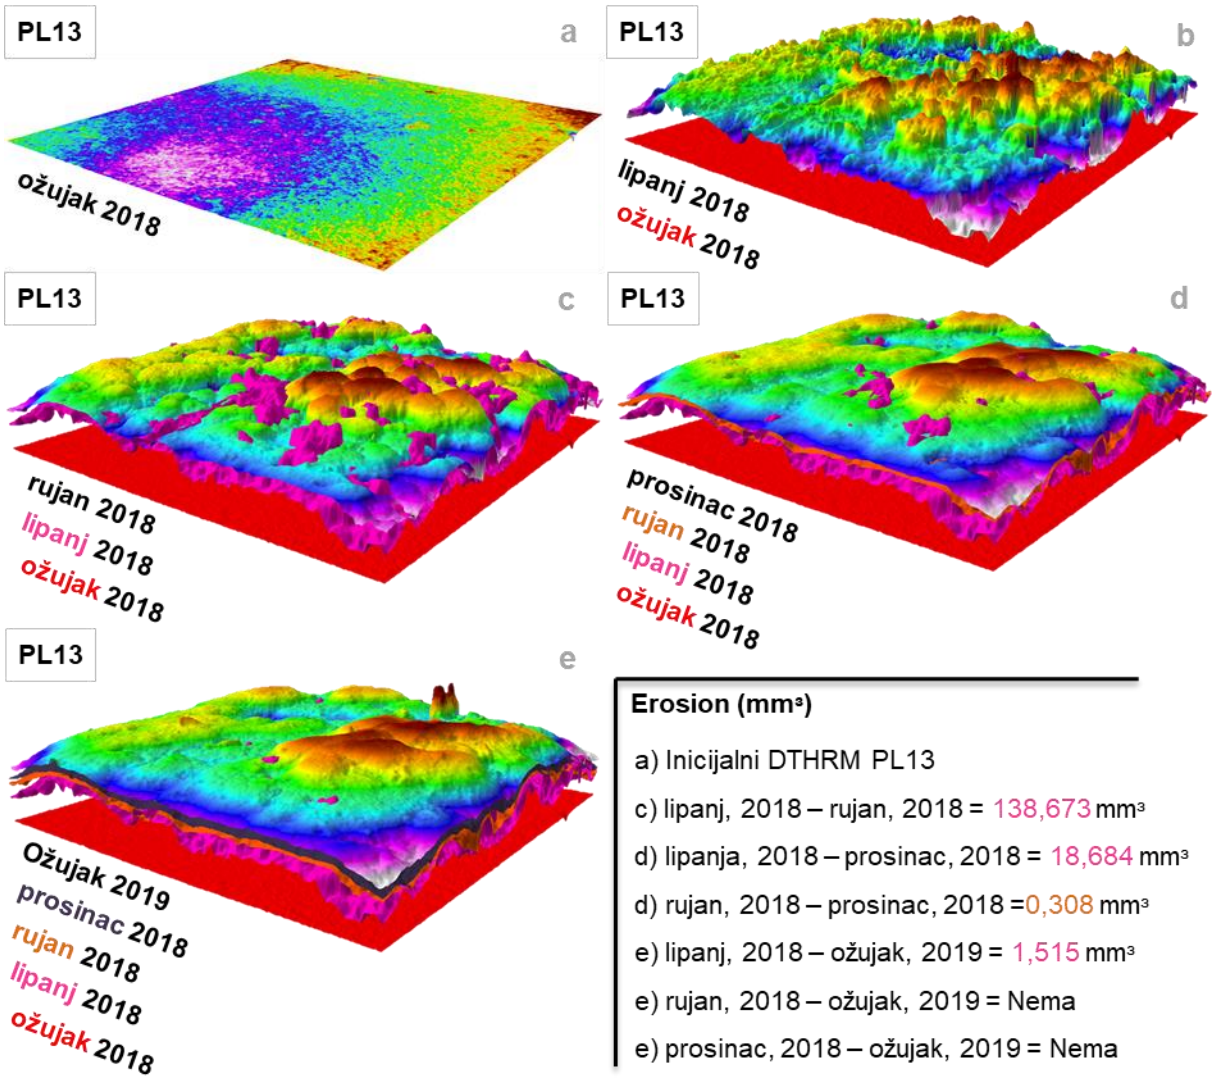

Slika 167. Erozijski događaji na PL13

Slična je situacija utvrđena na PL03, 18, 22, 23, 24, 27 i 29. Navedene pločice su vađene iz tokova u šestomjesečnom intervalu (rujan, 2018. - ožujak, 2019). Na svim pločicama nije došlo do „nadoknađivanja“ erodiranog supstrata erodiranog supsrata, točnije u intervalu od šest mjeseci mjesta erozije nisu „popunjena“ naknadnim taloženjem (Tablica 41). Ipak, izuzev PL22 čiji je erozivni događaj objašnjen u tekstu iznad, postotak erodiranog materijala ostalih pločica (PL03, 18, 23, 24, 27 i 29) u spomenutom razdoblju nije značajan, odnosno ne prelazi 2,533 % (PL24) volumetrijskog prirasta u tom razdoblju. Za PL03 iznosi (0,219), PL18 (0,685) (Slika 172a), PL23 (0,001), PL27 (0,311) (Slika 168b) te za PL29 0,007%.

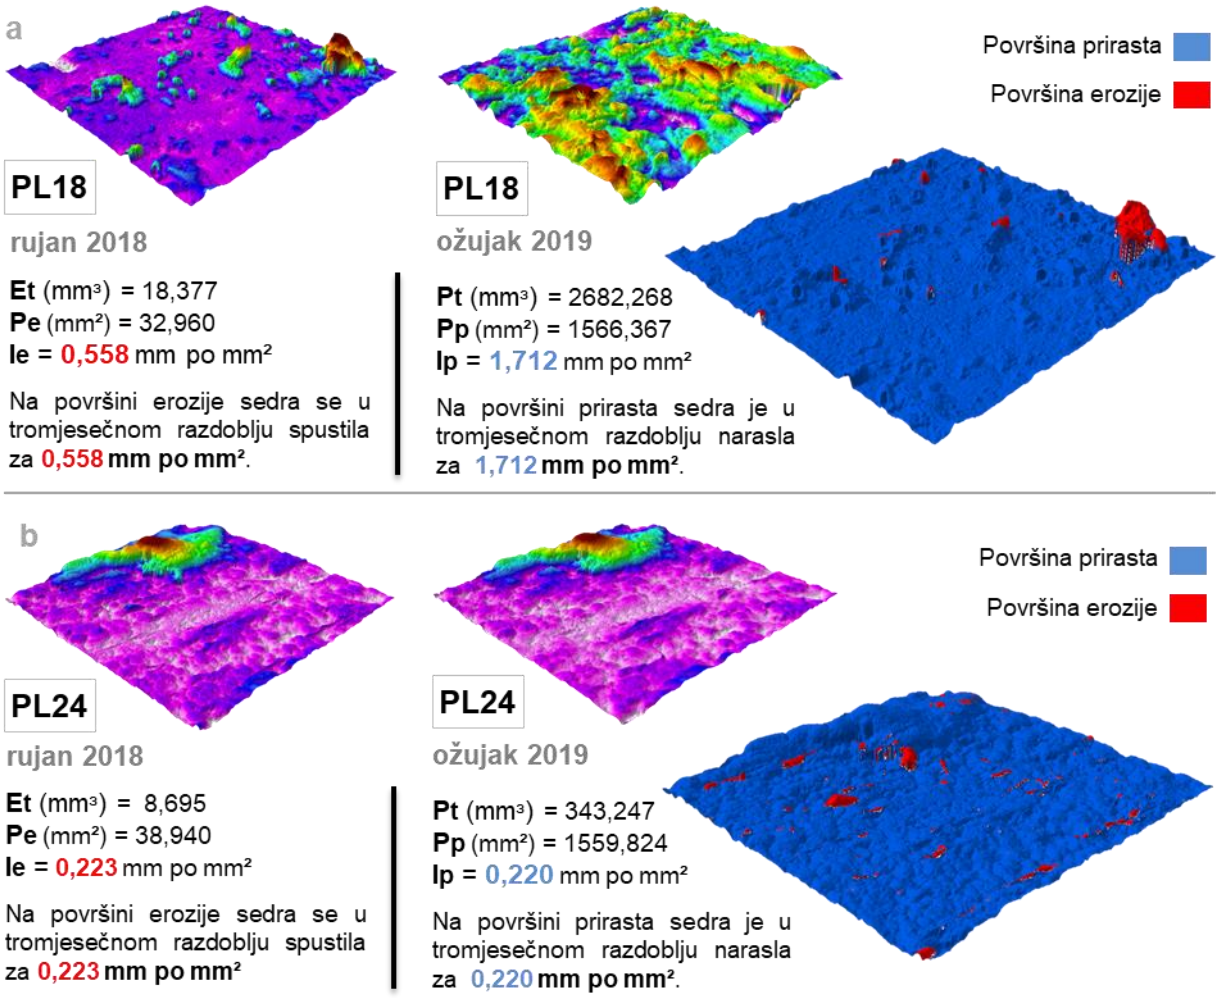

Slika 168. Primjer erozije PL18 i PL24 u šestomjesečnom razdoblju (srpanj, 2018. – ožujak, 2019)

Najniži intenzitet prirasta od svih intervalno vađenih pločica u šestomjesečnom razdoblju rujan, 2018. – ožujak, 2019 bilježi, uz PL22 koja je smještena u fluvijalnom okruženju klasificiranom kao SW, PL24 (*Kod spomenika*). Naime, PL24 je za razliku od PL22 smještena u fluvijalnom okruženju umjereno protočne vode (MFW). U isto fluvijalno okruženje su postavljene PL03 i 16 (*Bezimena*) te PL06 i 08 (*U bršljanu*). Ipak prosječna stopa prirasta na lokaciji *Bezimena* iznosi 5,145 mm a^{-1}, na *U bršljanu* je 4,376 mm a^{-1}, dok je *Kod spomenika* tek 3,298 mm a^{-1}, odnosno 1,847 mm a^{-1} manje od prve (*Bezimena*) te 1,078 mm a^{-1} od druge (*U bršljanu*) lokacije.

Razlog manjih stopa prirasta na lokaciji *Kod spomenika* u odnosu na druge lokacije (*U bršljanu* i *Bezimena*) istog tipa fluvijalnog okruženja te nižeg intenziteta prirasta u odnosu na prvo šestomjesečno razdoblje je presušenje toka koje je uočeno prilikom posljednjeg, četvrtog vađenja pločica (Slika 169a). Dolaskom na teren, desetak metara uzvodno od lokacije *Kod*

spomenika (Slika 169c) uočeno je srušeno stablo smokve koje je prekrilo dio toka. Na toj lokaciji je došlo do značajne akumulacije materijala (grančice, lišće) nošenog tokom što je u konačnici stvorilo prirodnu branu, preusmjerilo protok vode te u konačnici presušilo tok u kojem su se nalazile PL24 i PL19 (Slika 170a-c).

Slika 169. a) PL24 unutar presušenog toka b) skidanje PL24 i PL19 te c) uklanjanje akumuliranog biljnog materijala

Nakon vađenja PL24 i PL19 iz presušenog toka, uslijedilo je uklanjanje akumuliranog materijala, odnosno rušenja prirodno nastale brane (Slika 169c). Uklanjanjem materijala na kritičnoj točki došlo je neposrednog reaktiviranja prethodnog toka. Snaga protoka je potom pročistila zapunjeno korito. Na slici 170 prikazani su isječci iz filmskog materijala snimljenog na terenu prilikom reaktiviranja presušenog toka. Presušivanje toka uslijed akumulacije materijala, glavni je uzrok manjem intezitetu sedrenja na lokaciji *Kod spomenika* te objašnjava veliku razliku (naročito u hladnom razdolbju) između stopama prirasta sedre između lokacija (*U bršljanu* i *Bezimena*) koje se nalaze u istom fluvijalnom okruženju. Ovim primjerom prikazano je kako povećana koncentracija biljnog materijala, odnosno neodržavanje tokova, izraženo u nedovoljno čestom uklanjanju akumulirane vegetacije, može ugroziti održive uvjete sedre na nekim mikrolokacijama.

Slika 170. Isječak iz videa u kojem je vidljiva reaktivacija presušenog toka

4.3.9 Utjecaj frekvencije snimanja pločica na količinu i intenzitet erozije

U svrhu utvrđivanja utjecaja frekvencije snimanja pločica na količinu i intenzitet erozije i prirasta analizirane su pločice s manjom (šest mjeseci) te većom frekvencijom (tri mjeseca). Uspoređene su samo pločice koje su se nalazile u istim fluvijalnim okruženjima prema definiranoj klasifikaciji. Razlog tome je činjenica da tip okruženja može značajno utjecati na pojavu erozivnih događaja. Od pločica s većom frekvencijom snimanja tu spadaju PL06, 13 i 25 koje su prema tipu fluvijalnog okruženja smještene u MFW, FFW i SC. Uspoređene su s P03, 10, 15, 24 i 29 koje su smještene u isti tip fluvijalnog okruženja. Prosječna erozija na pločicama koje su imale veću frekvenciju snimanja u razdoblju od rujna, 2018. do ožujka 2019. bila je 32,483 mm^3, a prosječni intenzitet erozije je iznosio 0,784 mm po mm^2. Na pločicama s manjom frekvencijom snimanja u istom razdoblju zabilježena je erozija od prosječno 16,391 mm^3, što je gotovo dva puta manje. Prosječni intenzitet erozije je iznosio 0,821 mm po mm^2. Ako se usporede vrijednosti prirasta na pločicama s manjom frekvencijom snimanja, u navedenom razdoblju u prosjeku su zabilježile 16560,3 mm^3, dok za one s većom frekvencijom snimanja taj broj iznosi 6958,2 mm^3. Veća frekvencija snimanja pločica iz toka može inhibirati rast sedre, odnosno povećati podložnost eroziji. Vađenjem pločica iz toka, njihovim sušenjem i snimanjem dolazi do prekidanja ciklusa naseljavanja pločica od strane sedrotvoraca (primjer PL06), prekida se proces precipitacije, sedra postaje krhka te prilikom vraćanju u tok podložnija eroziji.

4.3.9 Utvrđivanje makrozoobentosa u rekativiranom sedrotvornom sustavu

Makrozoobnetos se odnosi na faunu vodenih beskralježnjaka sveprisutnu u potocima i rijekama svijeta. Pojam „makro“ označava organizme veće od 500 mikrona koje zaustavlja sito ili mreža (Hauer i Resh, 2017). O ulozi organizama u procesu sedrenja se dosta debatira. Ona prije svega ovisi o biotičkim i abiotičkim obilježjima promatranog sedrotvornog sustava (Plant, 2019). Staništa na sedrenim slapovima zbog svojih jedinstvenih ekoloških uvjeta predstavljaju jedinstven biotop na kojeg se mogu naseliti samo one biljne i životinjske vrste koje su prilagođene tim posebnim uvjetima (Slika 171) (Matoničkin i Pavletić, 1960).

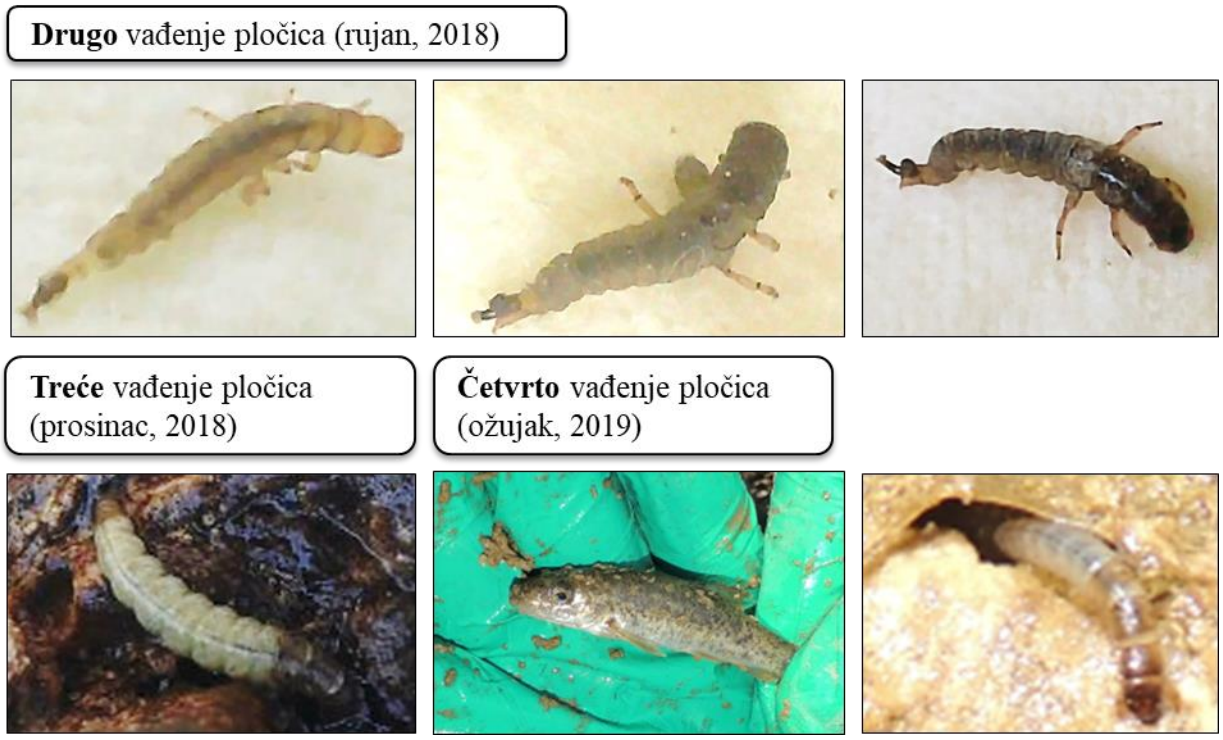

Slika 171. Primjeri organizama koji su uočeni prilikom vađenja pločica iz protoka

Određene vrste makrozoobentosa mogu odigrati značajnu ulogu u procesu formiranja sedre. Tako su fosilni ostatci pleistocenske i eocenske sedre bogati kalcificiranim ostatcima raznih ličinki vodenih kukaca (Carthew i dr., 2002). Ličinke vodenih kukaca mogu imati izrazito bitnu ulogu u procesu sedrenja. Navedeno je posebno utvrđeno za područja s obilježjima tropske klime: *Louie Creek* (sjeverozapadni Queensland), *Riversleigh* (Australija) te *Madang Province* (Papua Nova Gvineja). Na onim lokacijama gdje je aktivnost ličinki ograničena na razdoblje proljeće-ljeto njihova ulogu u procesu sedrenja je smanjena (Carthew i dr., 2002). One ne samo da povećavaju stopu prirasta sedre već mogu inicirati prirast na njenim starijim površinama. Tip porodice ličinki vodenih kukaca koji se javlja na nekoj lokaciji posljedica je specifičnih obilježja mikrolokaliteta (Ridl, 2015) te položaja sedrenih barijera

unutar proučavanog sustava (Šemnički i dr., 2012). Vodeni kukci mogu preferirati različite vrste mikrostaništa, ali generalno najveća brojnost njihovih ličinki je na supstratima makrovegetacije, mahovina te lokacija gdje ima organskih ostataka (hrana) (Orlović, 2015).

Slične strukture ponekad se mogu uočiti u suvremenim sedrotvornim okruženjima, ali su samo povremeno vidljive kada njihove "građevne" strukture postoje u izobilju (Plant, 2019). U brzim tokovima koji u pravilu imaju najveće stopa prirasta sedre pločice su u pravilu kolonizirane s mikroorganizmima koji imaju upravna, cijevima slična kalcitna tijela. Suprotno, područja sa sporim i stojećim vodama imaju manje količine uspravnih kalcitnih tijela.

U disertaciji je kroz utvrđivanje makrozoobentosa na testnim pločicama demonstrirana još jedna prednost CMD uređaja u odnosu na MEM koji ima isključivu funkciju mjerenja prirasta i erozije sedre. Detaljna determinacija makrozoobentosa te vrsta algi i mahovina na mjernoj plohi pločice nije rađena jer nije relevantna za ciljeve ovog istraživanja. Osim toga takva analiza vrlo je opsežna u domeni za to specijaliziranih biologa. Determinirane su dvije najzastupljenije vrste organizama.

Zbog svoje veličine (jedinke > 300 mikrona) makrozoobentos je moguće detektirati izravno iz DOF-ova pločica. Pojava makrozoobentosa u pravilu pozitivno korelira s količinom makrofita (vodenih biljaka) na određenoj lokaciji jer su makrofiti važan izvor hrane i vrijedno stanište makrozoobentosa (Šemnički i dr., 2012). Među njima se ističu mahovine koje zbog povoljnih uvjeta nastaju na barijerama, a podržavaju izuzetnu brojnost i bioraznolikost različitih svojti makrozoobentosa. Mahovinski pokrov zadržava usitnjenu organsku tvar, usporava brzinu strujanja vode, osigurava zaštitu nepredatorskoj fauni te omogućava naseljavanje obraštajne zajednice čime pozitivno utječe na funkcionalni ustroj makrozoobentosa (Tetkov, 2016).

S obzirom na to da je određeni broj testnih pločica postavljen na prostore prirodnih barijera u blizini mahovina za očekivati je bilo da će se na površini sedre uočiti određene vrste makrozoobentosa. Na visokorezolucijskom DOF-u pločice (PL13, 25, 06), koje su intervalno vađene svaka tri mjeseca, detektirana je uloga makrozoobentosa u procesu formiranja sedre. Točnije, identificirane su ličinke vodenih insekata, trzalaca iz porodice dvokrilaca *Simuliidae* i *Chironomidae* (red: *Diptera*) (Slika 172a-c).

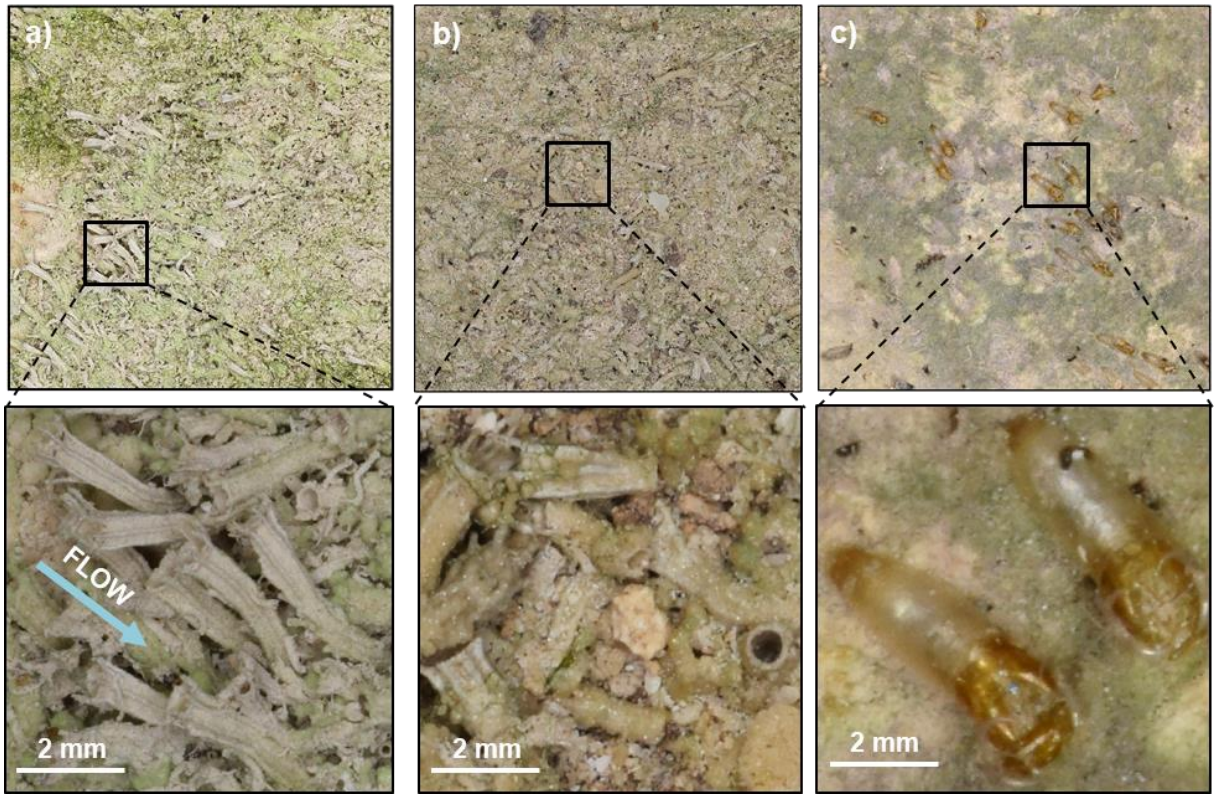

Slika 172. Detektirane ličinke vodenih kukaca *Chironomidae* a-b) i *Simuliidae* c) u procesu formiranja sedre na a) PL25, b) PL13 i c) PL06

Pojava organizama u lipnju (22,4°C) nije iznenađujuća s obzirom na to da se sedrotvorni organizmi najbolje razvijaju na temperaturama oko 20ºC te da se su najpovoljnije temperatura za sedrotvorne vegetaciju između 15 do 20ºC (Matoničkin i Pavletić, 1960).

Kukci iz porodice *Simuliidae* i *Chironomidae* najčešće se koriste kao bioindikatori (Slika 173). Obje porodice su karakteristične za vode bogate organskim. Oni su također biomedijatori u procesu nastanka sedre jer proizvode cjevaste oblike (eng. *dwelling tube*) te metaboličke izlučevine; svilene mreže (eng. *silk nets*) koje im primarno služe u korist hranjenja, ali u konačnici postaju lokacije precipitacije kalcita (Matoničkin Kepčija i dr., 2005). Svilene mreže po sastavu sliče na svilu te se za njihove izlučevine love i zadržavaju kristalići kalcita što može dovesti do mozaičnog rasporeda sedre, a da se na fotografijama ne vidi zašto je do tog došlo (Matoničkin Kepčija, 2019). Te strukture se u konačnici ugrađuju u precipitat što rezultira specifičnom sedrenom strukturom ili fabrikom (Carthew i dr., 2002). Ličinke iz porodice *Chironomidae* su uobičajene za lokacije plitke tekuće vode na prednjim stranama (vijencu) brane gdje izgrađuju malene cilindrične "stambene" cijevi sačinjene od svilenih sekreta (Carthew i dr., 2003).

Slika 173. Primjeri ličinki vodenih kukaca *Simuliidae c)* i *Chironomidae* (red: *Diptera*) a-b)

Otkriveni cjevasti oblici su građeni paralelno sa smjerom toka dok su im "ručice" okrenute prema struji samog toka. One su se postupno ugrađivale u precipitat sedre što je povećalo stope prirasta (stope prirasta za PL13 i PL25 su više od prosječne stopa za sve pločice), ali je istovremeno povećana i poroznost (najveća erozija je otkrivena na PL13 i PL25). U konačnici to rezultira specifičnom sedrenom strukturom (Carthew i dr., 2002). Te mikro konstrukcije hvataju male fitoklaste (biljne fragmente - lišće i grančice) koji se također ugrađuju u sedru povećavajući joj poroznost (Carthew i dr., 2003). Nadalje, konstrukcije ličinki na mikro razini remete protok vode, pojačavaju lokalnu turbulenciju te time povećavaju mehaničko otpuštanje CO_2, što povećava zasićenost kalcita i ubrzava stvaranje sedre. Prirastom sedre turbulencija vode postaje sve izraženija te se cijeli proces ponavlja (Carthew i dr., 2002).

U nastavku su analizirani DOF snimci svih pločica te su istaknuti primjeri makrozoobentosa koji je sudjelovao u procesu formiranja sedre. Ukratko su opisane strukturne i teksturalne značajke precipitata na svakoj pločici (lokaciji) te je dana međusobna usporedba. Prvo su analizirane lokacije s intervalom snimanja od tri i šest mjeseci, a potom one od godine dana.

Lokacija ***Tvrda sedra*** **(PL13 i 02); N=3 mjeseca i 12 mjeseci**

Na PL13 u mjerenju provedenom u lipnju, 2018 godine, zabilježen je velik broj ličinki vodenih kukaca iz porodice *Chironomidae* (red: *Diptera*). To ne iznenađuje s obzirom na to da je interval snimanja bio tri mjeseca, tako da se snimanje (lipanj, 2018) poklopilo s vremenom kad je u pravilu najveća abundancija ličinki vodenih kukaca. Uz ličinke vodenih kukaca na precipitatu se mogu uočiti fragmenti biljaka, tijela ili tkiva životinja, odnosno sitni (FPOM[99]) i krupni (CPOM[100]) detritus autohtonog ili alohtonog podrijetla. Dakle, na površini PL13 nakon tri mjeseca izloženosti toku dominiraju cjevasti oblici ličinki, sitni biljni i životinjski ostatci te čestice (uočeno je preko 600 različitih mikrooblika) (Slika 174). Nije uočen obrazac pravca pružanja ličinki u odnosu na tok, ličinke ne izgledaju dobro učvršćene za supstrat (potvrdili

[99] Fine Particulate Organic Matter
[100] Coarse Particulate Organic Matter

rezultati erozije), manjih su dimenzija od ličinki na PL25. Značajan broj kalcitnih cjevastih tijela je položen uspravno. Tekstura precipitata je raznolika.

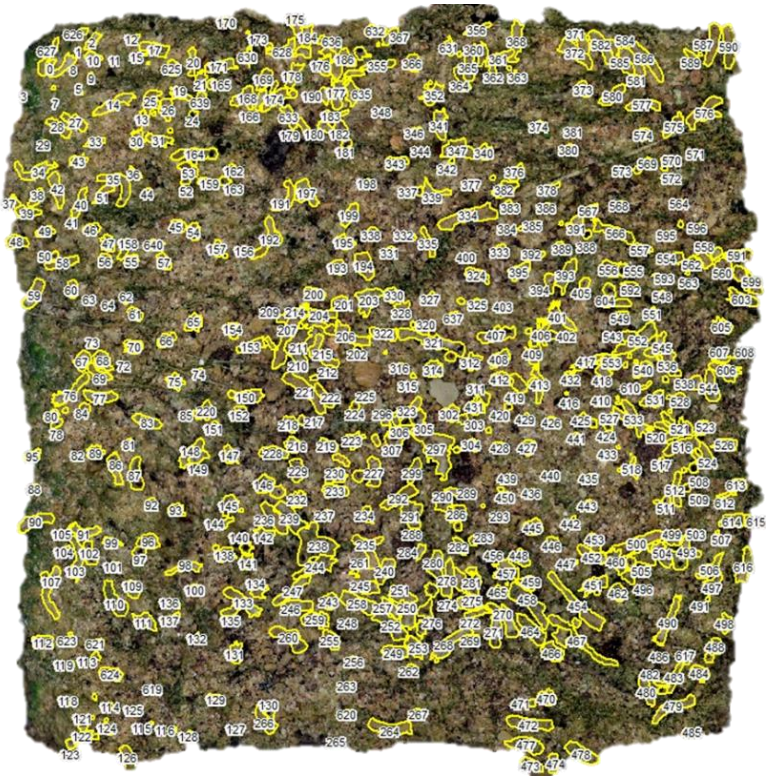

Slika 174. Detektirani mikroorganizmi na površini PL25 (lipanj, 2018)

Nakon šest mjeseci izloženosti (rujan, 2018) površina depozita se u potpunosti promijenila. Površina precipitata je zaglađenija te teksturalno ujednačenija (Slika 175). Precipitat je izrazito čvrst. Na površini sedre nema uočljivih cjevastih oblika ličinki vodenih kukaca te veće količine detritusa autohtonog ili alohtonog podrijetla. Na rubu pločice može se uočiti jedan jasan obris ličinki. Razlog tome može biti vrijeme snimanja (kraj rujna) kad je aktivnost makrozoobentosa smanjena, snažniji protok u odnosu na lipanj koji ne pogoduje naseljavanju makrozoobentosa te pojava erozivnih događaja neposredno nakon vraćanja pločice u tok nakon snimanja. Naime, prilikom prvog vađenja PL13 precipitat je osušen, snimljen i vraćen nazad, ali na onim mikro lokacijama na mjernoj plohi gdje ličinke nisu bile dobro učvršćene za supstrat te su „stršile“ u odnosu na okolnu površinu došlo je do značajnije pojave erozije (poglavlje *4.3.8 Detekcija erozije*). Nakon devet mjeseci izloženosti toku (prosinac, 2018) površina depozita se nije značajnije promijenila u odnosu na snimanje krajem rujna, 2018 (Slika 175). Na površini nema uočljivih cjevastih oblika ličinki, sitnih biljnih i životinjskih ostataka te različitih čestica. Površina precipitata je zaglađena, teksturalno je nešto

različitija u odnosu na rujan, 2018. s pojavom malih *zelenih krpica* (alge ili mahovine) na precipitatu. Precipitat je izrazito čvrst.

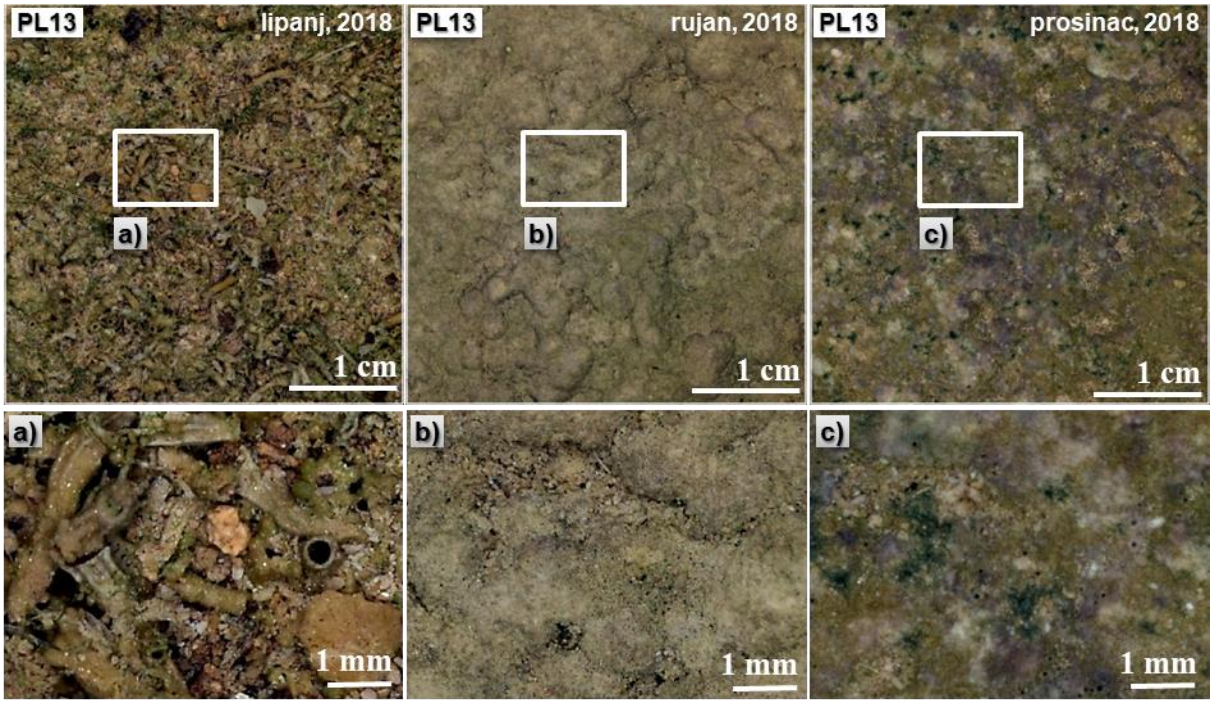

Slika 175. Precipitat na PL13 a) lipanj, 2018, b) rujan, 2018 i c) prosinac, 2018.

Međutim, iako nema puno jasnih cjevastih oblika ličinki (prosinac, 2018), tek nekoliko njih je detektirano na površini sedre, ipak se mogu uočiti brojne mikro rupice na precipitatu (rupičasta struktura sedre) koje su zapravo ostatci ličinki cjevastih oblika koje su u prethodnom snimanju (lipanj, 2018) na površini sedre bile položene uspravno. Detektirano je preko 600 manjih mikroudubljenja (Slika 176).

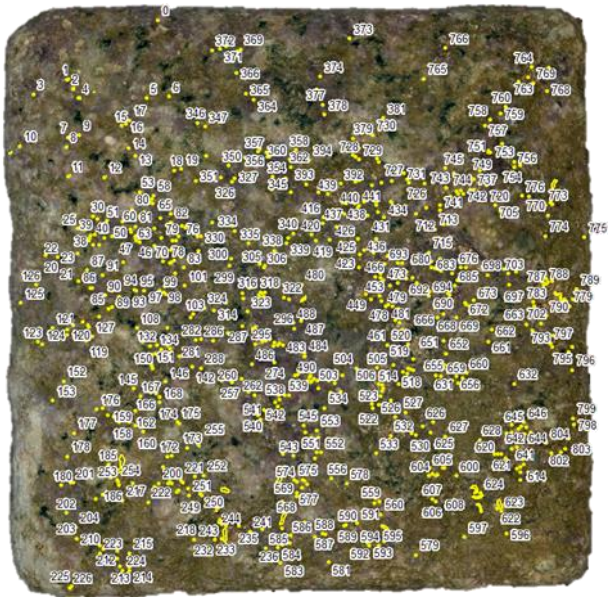

Slika 176. Detektirane mikro rupice na površini sedre PL25 (prosinac, 2018)

Navedeni opis vrijedi za precipitat snimljen u ožujku, 2019. I dalje na površini nema naznaka cjevastim oblicima ličinki, sitnim biljnim i životinjskim ostatcima te različitim česticama. Uočena je tek jedna manja ličinka koja nije povezana s precipitatom. Susjedna PL02 koja je izvađena nakon godine dana (ožujak, 2018) ima ista strukturna i teksturalna obilježja kao PL13. Na njoj je nešto izraženija zelenkasto-smeđa površina koja je sačinjena od različitih algi i biljaka (Slika 177).

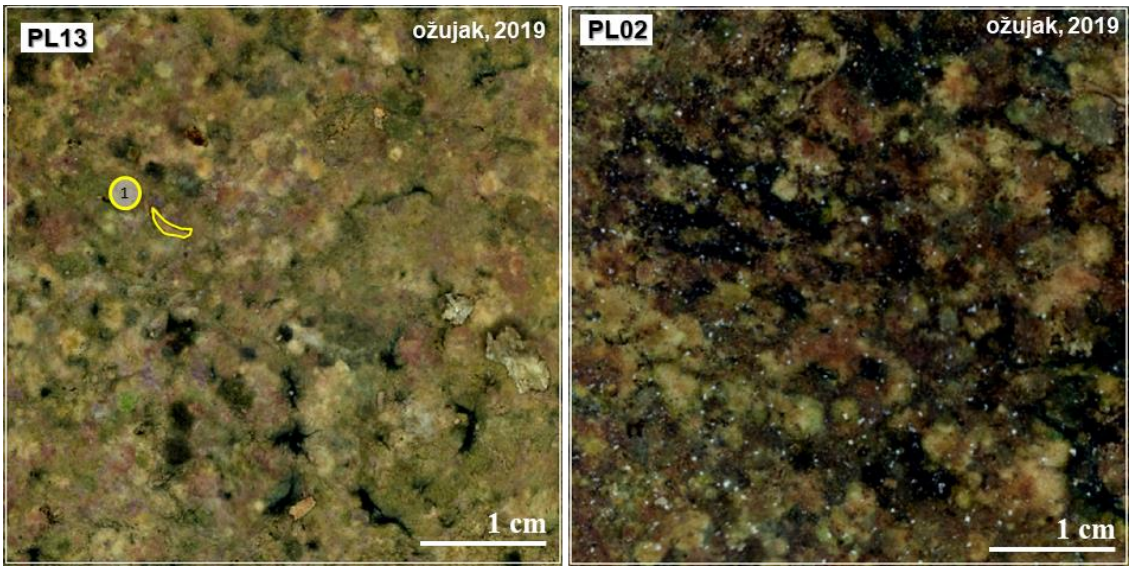

Slika 177. Precipitat nakon godine dana izloženosti a) PL13 i b) PL02

Slična tekstura površine precipitata je uočena na lokacijama *Kod duplog crnog graba* te *Kod mladog jasena*, odnosno u onim fluvijalnim okruženjima gdje je brzina protoka te turbulencija vode nešto izraženija (FFW). Na ovoj lokaciji nastao je facijes sedre koji je tipičan za lokacije brzog protoka vode u kojem ima značajne turbulencije vode. Time je osiguran jedan od glavnih uvjeta za naseljavanje makrozoobentosa - dobro prozračivanje. Najveća količina jedinki makrozoobentosa očekivano je detektirana u fazi kolonizacije, odnosno u prvom intervalnom razdoblju snimanja (ožujak, 2018. – lipanj, 2018). Sediment je izrazito čvrsto povezan, nije porozan, izuzev kratkog kolonizacijskog razdoblja prva tri mjeseca. Laminacija je izražena. Tekstura i struktura površine sedimenta je gotovo u potpunosti ista kao na lokaciji *Kod duplog crnog graba*.

Lokacija ***Pačji slap*** **(PL25 i 07); N=3 mjeseca i N=12 mjeseci**

Na PL25 (lokacija *Pačji slap*) u mjerenju u lipanju, 2018., zabilježen je najveći broj jedinki ličinki vodenih kukaca iz porodice *Chironomidae* (red: *Diptera*). To ne iznenađuje s obzirom na to da je interval snimanja svaka tri mjeseca, tako da se vrijeme snimanja (lipanj, 2018) poklopilo s vremenom kad je najveća abundancija ličinki. Nadalje, PL25 je smještena

na prirodnoj barijeri u blizini mahovina. Lokacija je dobro osunčana te pogodna kao mikrostanište za različite vrste makrozoobentosa. S obzirom na takva obilježja staništa i veliku frekvenciju snimanja ne iznenađuje toliki broj uočenih organizama na površini sedre. U odnosu na PL13 (*Tvrda sedra*) na ovoj lokaciji ličinke iz porodice *Chironomidae* su duže, polegnute, te se pružaju u pravcu toka s ispruženim mikro konstrukcijama za hranjenje (Slika 178).

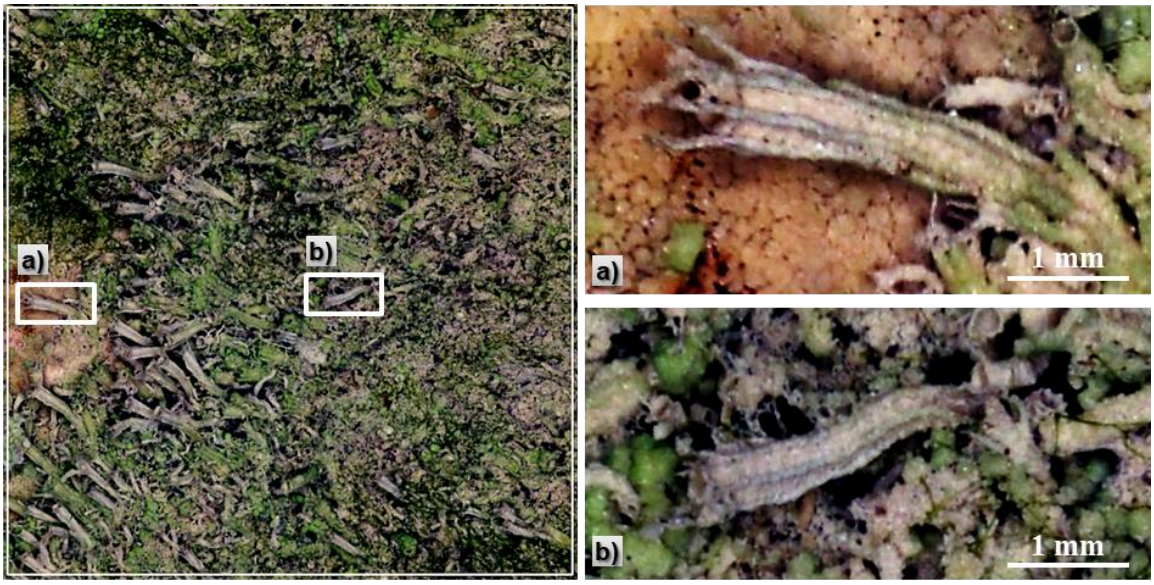

Slika 178. PL25 (lipanj, 2018) *Chironomidae* (red: *Diptera*)

Na PL25 (lipanj, 2018) koristeći visoko-rezolucijski DOF detektirani su različiti oblici makrozoobentosa. Najprepoznatljivije su duguljaste velike ličinke *Chironomidae* koje na svojim otvorima imaju prepoznatljive ručice, a po sredini tijela grebene (Slika 180). Cijelo tijelo im je sivkaste, svijetlo-smeđe boje. Malo teže je uočiti te ličinke nakon duže izloženosti toku te su se već integrirale u samu površinu substrata. Njihovo tijelo sad je prekriveno zelenkastom ovojnicom, dok su prepoznatljive ručice izgubile svoj oblik, kojeg su zamijenile zelenkaste okrugle nakupine (Slika 180). Uz duguljaste velike ličinke *Chironomidae* detektirani su i mali cjevasti oblici ličinki položeni uspravno i bočno (Slika 180). Na PL25 (lipanj, 2018) detektirano je preko 700 različitih mikro oblika (Slika 179).

Slika 179. Detektirani mikroorganizmi na površini PL25 (lipanj, 2018)

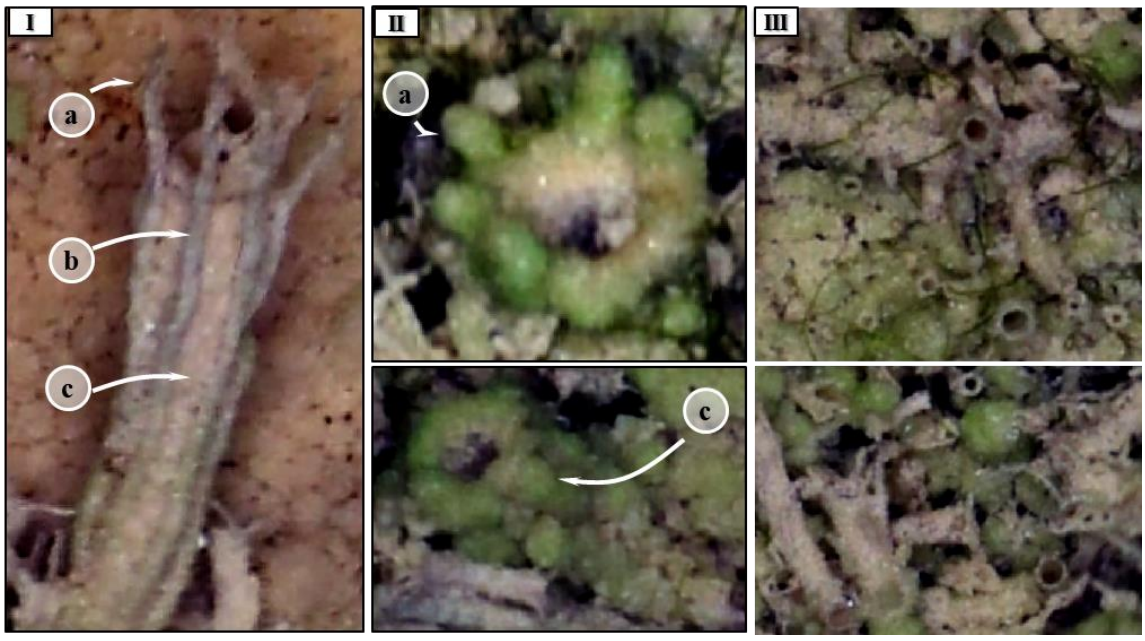

Slika 180. Primjeri detektiranih mikroorganizama za površini PL25 (ožujak, 2018)

Kroz intervalna snimanja (rujan, prosinac 2018. i ožujak, 2019) došlo je do gotovo potpune inkrustacije detektiranih organizama. Na površini intervalnih modela nije uočen velik broj jasnih obrisa mikroorganizama (Slika 181).

Slika 181. PL25 a) rujan, 2018 b) prosinac, 2018 te c) ožujak, 2019

Specifični cjevasti oblici mikroorganizama su najuočljiviji na PL25 u lipnju, 2018. Nakon tri mjeseci (rujan, 2018) već su toliko inkrustirani u površinu sedre da bi ih bilo gotovo nemoguće detektirati da LCS nije fiksan, odnosno da se ne nalaze na gotovo istoj X, Y i Z lokaciji. Na modelima nakon devet mjeseci i godine dana (prosinac, 2018. i ožujak, 2019) mikroorganizama na površini sedre nema. U potpunosti su prekriveni nastalim precipitatom. Razlog tome može biti: generalno je u ljetnim mjesecima precipitiranje sedre intenzivnije zbog čega dolazi do izrazitijeg kalcificiranja biljki. To može biti problem, osobito za životinjske vrste koje ne mogu podnositi intenzivnije taloženje sedre te otežano naseljavaju kalcificirano bilje (Matoničkin i Pavletić, 1960). Naime, na površini modela za rujan i prosinac, 2018 te ožujak, 2019 uočena je veća količina nakupina većih biljnih fragmenata (listovi, takne grančice) (Slika 181a-c).

Nadalje, na modelu rujan, 2018. može se uočiti da sedrena površina izgleda suše (Slika 186) u odnosu na površine snimljene u prosincu 2018 i ožujku, 2019 (Slika 182). Zbog velikih količina inkrustiranih biljnih fragmenata (listovi i tanke graničice) otežano je detektiranje cjevastih oblika mikroorganizama. Razlog sušoj površini i većoj količini biljnih fragmenata može biti slabiji protok na toj lokaciji za vrijeme topolog razdoblja. Na posljednjem modelu došlo je do nakupljanja većih biljnih segmenata na površini pločice (Slika 182) te polaganog početka inkrustacije.

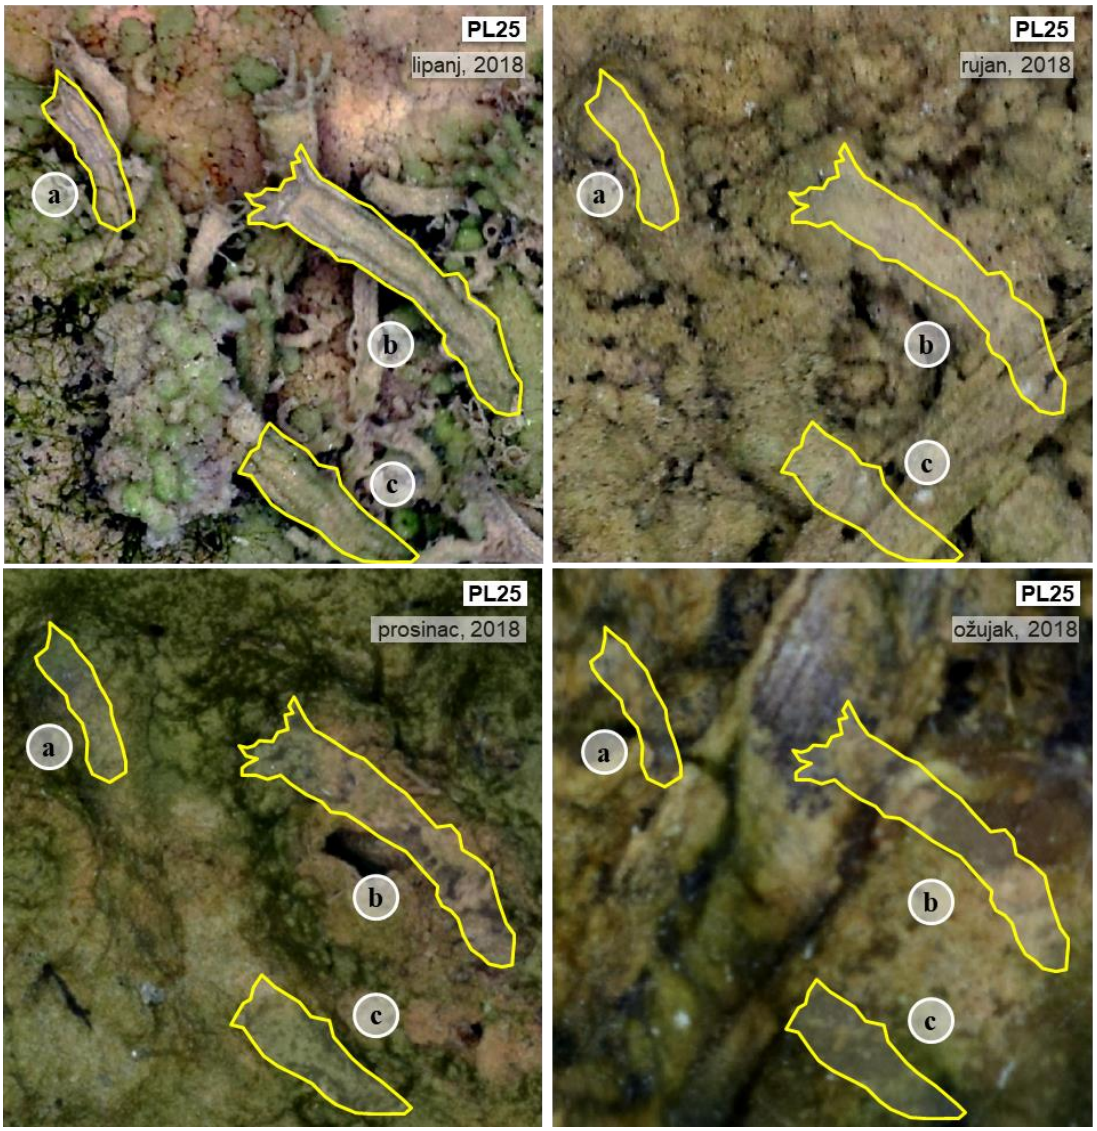

Slika 182. Promjene površine sedre na PL25

Na njenoj susjednoj pločici (PL07) izvađenoj nakon godine dana prirast sedre je veći za 3,2 puta veći u odnosu na PL15 koja je na testnoj plohi imala drugi najveći prirast. Nekoliko čimbenika je doprinijelo tome. PL07 je kroz prva tri mjeseca izloženosti toku vjerojatno na svojoj površini imala veliku količinu ličinki vodenih kukaca te biljnih fragmenata, slično kao njena susjedna pločica. Međutim, ona nije intervalno snimana. Činjenica da se nije vadila iz toka omogućila joj je da se proces sedrenja ne prekida, da se istaloženi precipitat, sačinjen od ličinki vodenih kukaca, mahovine i biljnih fragmenata ne suši time čime postaje podložniji na erozivno djelovanje. Interval snimanja od godine dana, blizina mahovina koje su izvrstan habitat za makrozoobentos te povoljni mikrolokacijski uvjeti (dovoljna količina svjetlosti i protok vode koji nije previše brz - SC) uvjetovali su tako velik prirast (najveći). Naime, u

slabijem protoku vode manji je pomak koji nema izraziti utjecaj na odnošenje organskog materijala (hrana makrozoobentosa) i ličinki kukaca (Orlović, 2015).

Teksturalne i strukturne karakteristike sedimenta se razlikuju od lokacije *Tvrda sedra*. Na ovoj lokaciji je nastala porozna, spužvasta, gruba, a ponegdje i nelaminirana sedra s obilnim inkrustiranim mahovinama. Cjevasta tijela mikroorganizama u prvom kolonizacijskom razdoblju su dugačka do 5 mm, a široka oko 0,7 mm. Ovakav izgled (lice) sedre je tipičan za stepenaste slapove (SC), male padove i baraže, lokacije prskanja vode – dobro prozračivanje, u čijoj je blizini zabilježen izražen rast mahovina ili drugih makrofita koji pružaju izvrsno stanište za makrozoobentos.

Lokacija ***U bršljanu*** **(PL06 i 08); N=3 mjeseca i N=12 mjeseci**

Na lokaciji *U bršljanu* postavljene su dvije pločice (PL06 i PL08). Na PL06 u prvom mjerenju u lipnju, 2018. uočena je ličinka iz porodice *Simuliidae* (izvan mjerne plohe) te dvije ličinke iz porodice *Chironomidae* (red: *Diptera*) unutar mjerne plohe. Ličinke su spljoštene te djelomično prekrivene tankom kalcitnom ovojnicom. Precipitat je izrazito čvrst s raznolikom teksturom. Na istoj pločici je nakon 6 mjeseci izloženosti (rujan, 2018) zabilježeno preko 20 kukuljica iz porodice *Simuliidae* (red: *Diptera*), dok su ličinke detektirane u prethodnom mjerenju u potpunosti prekrivene s precipitatom (Slika 183). Neke od uočenih kukuljica su prazne.

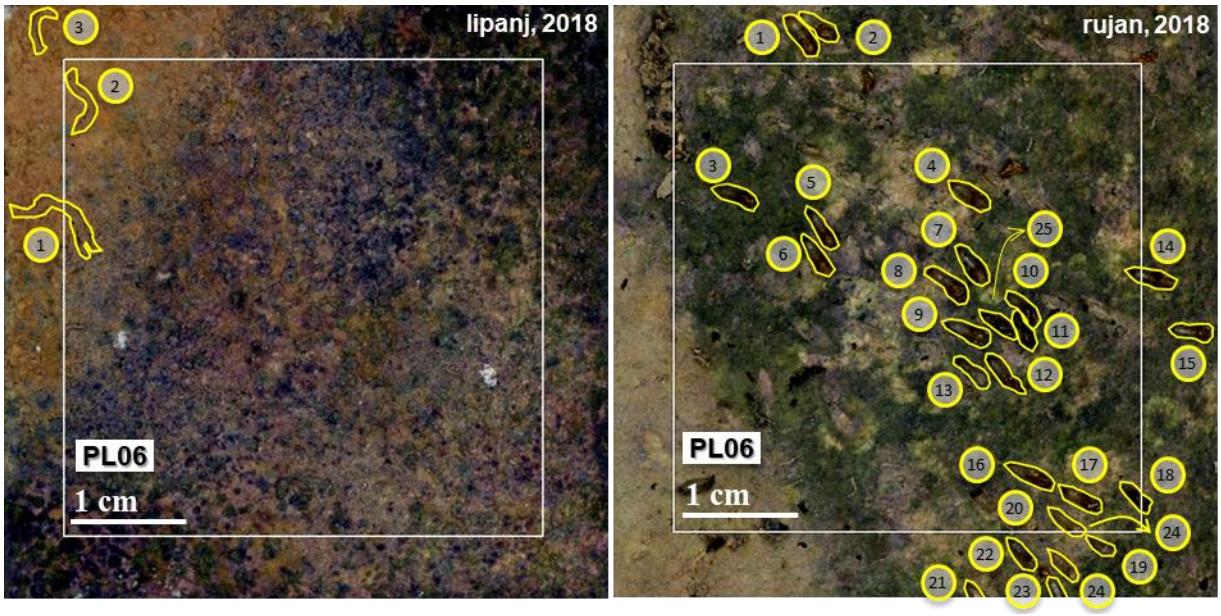

Slika 183. Površina sedre na PL06 (lipanj, 2018 i rujan, 2018)

Na modelima generiranima nakon 9 (prosinac, 2018) i 12 mjeseci (ožujak, 2019) izloženosti PL06 toku nije uočena značajnija pojava ličinki ili kukuljica. Na modelu PL06 snimljenom u ožujku, 2019. detektirana je samo jedna ličinka koja spada porodici

Chironomidae. Na susjednoj pločici, PL08, također nije uočena značajnija pojava makrozoobentosa, iako se na površini mogu nazrijeti inkrustirani oblici mikroorganizama. Na površini sedre je detektiran neklasificirani organizam.

Teksturalne i strukturne karakteristike sedre spadaju u prijelazni oblik između *Tvrde sedre* i *Pačjeg slapa*. Sediment je ipak sličniji onom nastalom na lokaciji *Tvrde sedre* što je očekivano s obzirom na obilježja fluvijalnog okruženja (MFW). Tekstura PL08 je nešto tamnija od PL06 na kojoj ima prostora s rozim pigmentom (Slika 184). To može biti posljedica većeg intervala snimanja PL06 ili nakupljanja specifičnih vrsta algi. Na ovoj lokaciji nastala je umjereno čvrsta sedra, relativno porozna s manjom količinom inkrustiranih makrofita. Ovakav facijes sedre je tipičan za lokacije umjerenog protoka i turbulencije vode u čijoj blizini nema velike količine mahovina ili drugih makrofita.

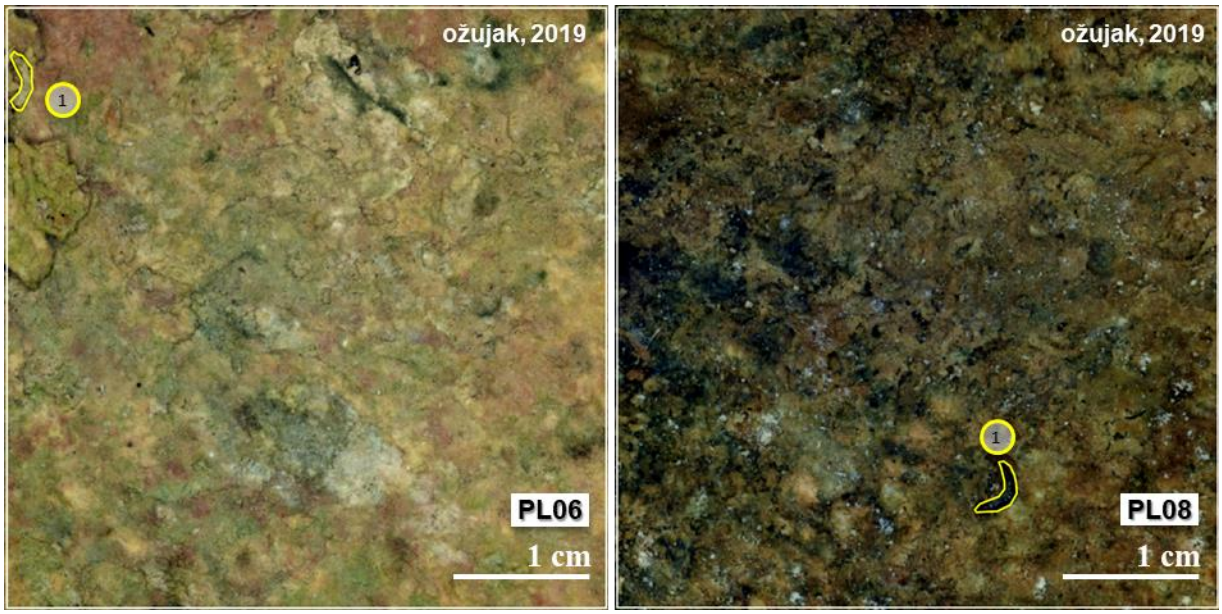

Slika 184. Površina sedre PL06 i 08 nakon godine dana izloženosti toku

Od svih pločica koje su vađene u intervalu od 3 mjeseca (PL06, PL13 i PL25) na ovoj lokaciji je detektirano najmanje mikroorganizama. Na PL13 i PL25 dominiraju ličinke iz porodice *Chironomidae* koje imaju specifična cjevasta tijela s mikro konstrukcijama za hranjenje. Na PL13 i PL25 ti oblici nisu u potpunosti povezani i inkrustirani s okolnim supstratom (osobito kod PL13) koji se sastoji od nakupina nepovezanih fragmenata biljaka, tijela ili tkiva životinja, odnosno sitnog i krupnog detritusa autohtonog ili alohtonog podrijetla. Na površini sedre PL06, u drugom mjerenju (rujan, 2018), zabilježena je dominacija kukuljica iz porodice *Simuliidae* (red: *Diptera*). U odnosu na PL13 i PL25, supstrat oko ovih ličinki je kompaktniji i tvrđi s manjim udjelom nepovezanih fragmenata biljaka, tijela ili tkiva životinja.

Lokacija ***Bezimena*** **(PL03 i 16); N=6 mjeseci i N=12 mjeseci**

Na površini PL03 u prvom snimanju (rujan, 2019) nije zabilježena veća količina vidljivog makrozoobentosa. Na površini sedre mogu se nazrijeti oblici koji su potpuno inkrustirani u supstrat. Od vidljivih oblika detektiran je (nedeterminirani) slatkovodni račić koji je tek počeo inkrustirati u površinu sedre, dug oko 7,2 mm. Na prostoru izvan mjerne površine (MS) uočene su dvije ličinke iz porodice dvokrilaca *Simuliidae (Diptera)* duge oko 2,8 mm (Slika 185). Na površini pločice uočeno je dosta inkrustiranih biljnih fragmenata.

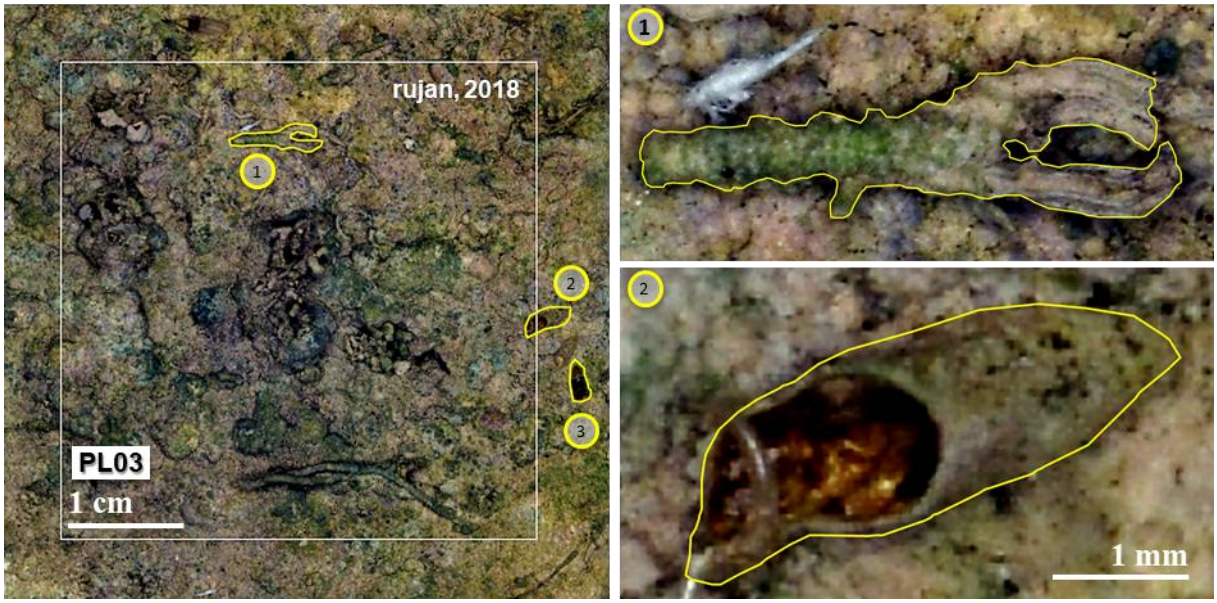

Slika 185. PL03 (rujan, 2018) slatkovodni račić te ličinka *Simuliidae (Diptera)*

Nakon godine dana mjerenja (ožujak, 2019) na površini sedre je uz malene nakupine mahovina detektirano mnoštvo cjevastih oblika (Slika 186) koji su vjerojatno izgrađeni od strane dvokrilaca iz porodice *Chironomidae* (Slika 191). Detaljnim pregledom cjevastih oblika nije uočena zakonitost pružanja mikro konstrukcija u odnosu na smjer toka. Ipak, dosta oblika je položeno uspravno u odnosu na podlogu.

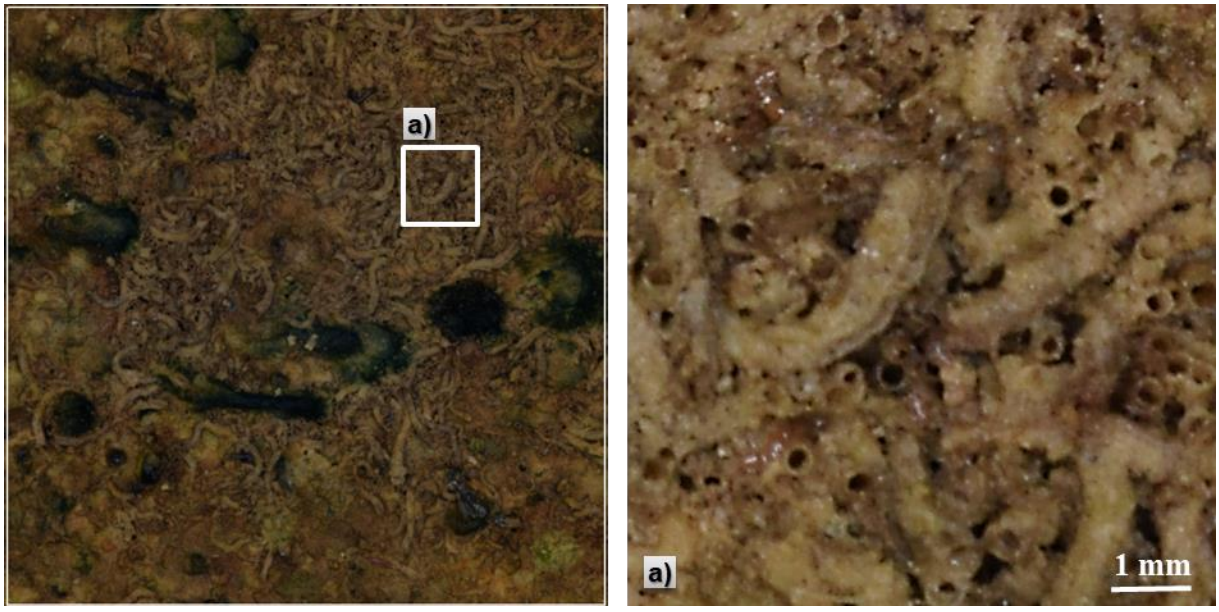

Slika 186. PL03 (ožujak, 2019) cilindrične "stambene" cijevi

Na njenoj susjednoj pločici PL16 koja je izvađena nakon godine dana (ožujak, 2019) također je uočeno obilje cjevastih oblika (Slika 188) koji su već, u odnosu na PL03, intenzivnije započeli proces inkrustacije (Slika 189). Razlika u stopi prirasta sedre između ove dvije lokacije iznosi tek 0,1519 mm. Posljedica je nešto veće količine biljnih fragmenata koji su se nakupili na PL16 te činjenice da PL03 ima veću frekvenciju vađenja iz toka.

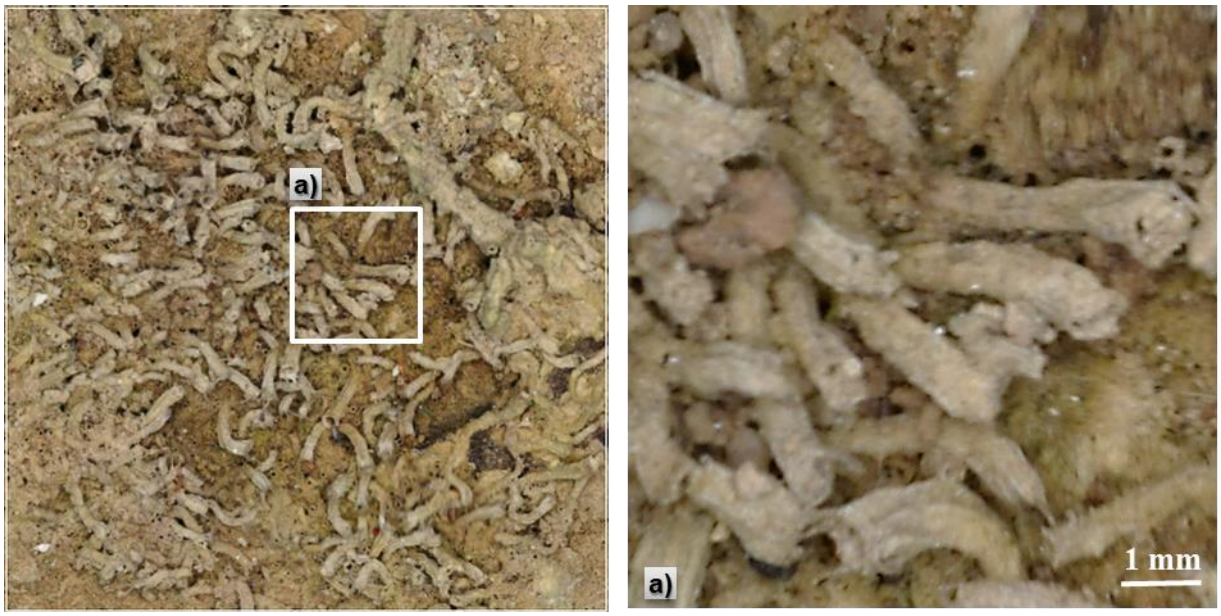

Slika 187. PL16 (ožujak, 2019) inkrustacija cilindričnih cijevi

Na površini PL16 detektirani su zanimljivi događaji. Na slici 188a-c mogu se uočiti nedeterminirane crvenkasti crvići koji izlaze iz ličinki vodenih kukaca iz porodice *Chironomidae*, dok se na slici 188b može vidjeti nedeterminirani tip dvokrilca koji je upravo izašao iz ličinke.

Slika 188. Detektirani nedeterminirani organizmi na PL16 (ožujak, 2019).

Slika 189. Detektirani mikroorganizmi na površini PL16 (ožujak, 2019)

Teksturalna i strukturna obilježja sedre se mogu opisati kao sljedeća. Na ovoj lokaciji je nastala čvršća sedra s izraženijom laminacijom od lokacije *Pačji slap*. Zbog izrazito velike količine mikroorganizama sedra je poroznija od lokacije *U bršljanu*. Ova vrsta izgleda sedre odgovara lokacijama nešto bržeg, ali ne izrazito jakog protoka (klasifikacija MFW) u kojem nema izrazitijeg rasta mahovina ili drugih makrofita kao što je uočeno na lokaciji *Pačji slap,* ali ih opet ima nešto više nego na lokaciji *U bršljanu.*

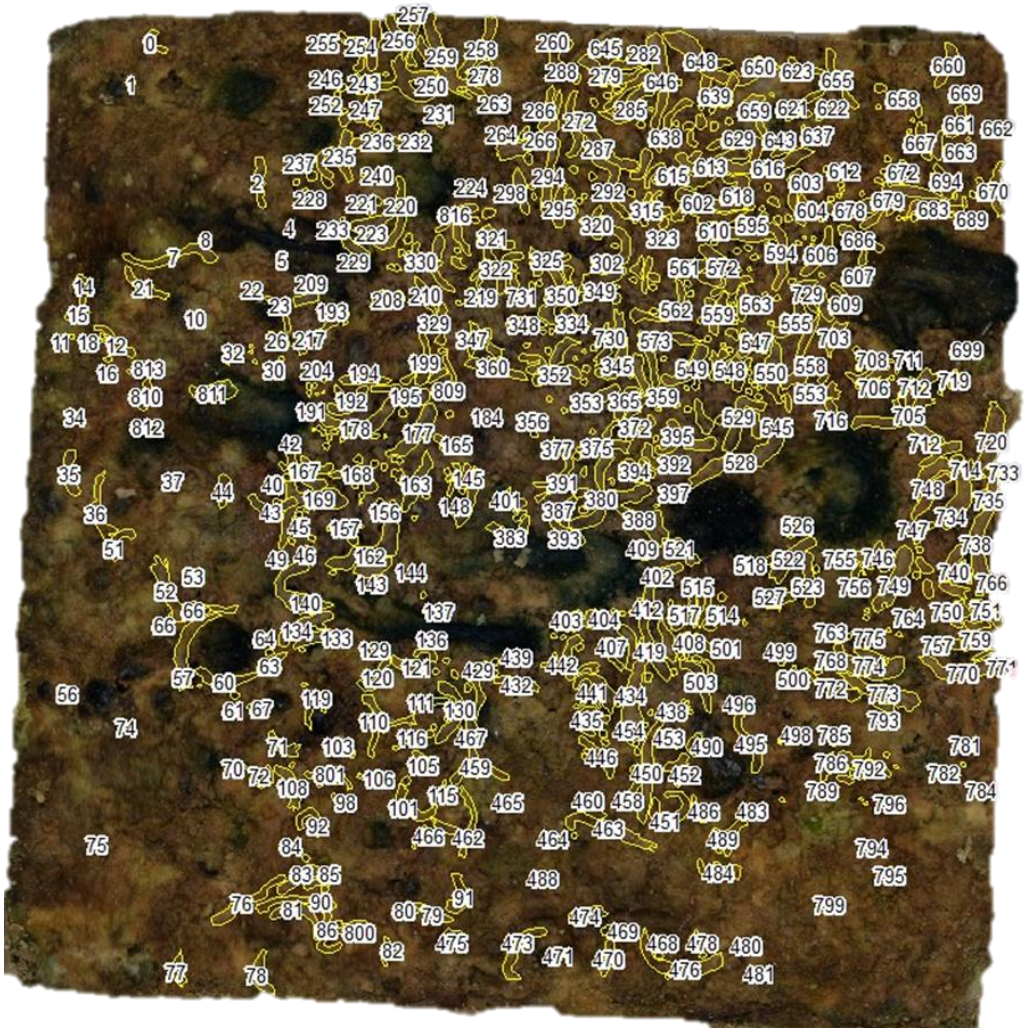

Slika 190. Detektirani mikroorganizmi na površini PL03 (ožujak, 2019)

Lokacija ***Jezero 6 stabala*** **(PL22 i 09); N=6 mjeseci i N=12 mjeseci**

Na PL09 i 22 nisu uočeni jasni obrisi makrozoobentosa (Slika 191). Uzrok tome su obilježja njihovog fluvijalnog okruženja. Pločice su bile smještene u stagnantnoj vodi na dubini većoj od 1 m u gotovo središnjem dijelu reaktiviranog jezera. Pločice nisu izravno položene na muljevito dno već su ubušene u ostatke mrtve sedre koje su pronađene u blizini. Na udaljenosti od oko 2 m oko njih je smješteno nekoliko stabala, dok u blizini pločica nema mahovine. Lokacija se nalazi u dubokoj sjeni, nema turbulencije i protoka vode. Sediment (kalcitni

premaz) na obje pločice je nakon intervalnih mjerenja bio izuzetno tanak (<0,5 mm). Njihov izostanak ne iznenađuje s obzirom na to da muljevite stagnantne, vodene prostore ne preferiraju jer nema strujanja vode, a time ni mogućnosti vršenja filtracije uz pomoć koje se hrane. Mulj im kao supstrat nije stabilno stanište jer se kao ličinke ne mogu za njega prihvatiti (Orlović, 2015). Nadalje, opisani fluvijalni uvjeti uvjetuju okolinu u kojoj nema dovoljnog prozračivanja. Ono je izuzetno bitno iz dva aspekta. Na tim lokacijama sedrenje je u pravilu najintenzivnije te glavni sedrotvorci se uspijevaju naseliti samo u uvjetima jakog prozračivanja. Na lokacijama gdje je brzina vode niža od 0,5 m/sek nije moguće naseljavanje glavnih sedrotvoraca zbog toga što uslijed slabijeg prozračivanja nema dovoljno kisika (Matoničkin, Pavletić, 1960).

Teksturalna i strukturna obilježja precipitirane sedre se mogu opisati kao sljedeća. Na ovoj lokaciji precipitat je izuzetno tanak, uočljiv je nedostatak laminacije (nema dovoljne količine sedre), sedra je rastresita, nastala je uglavnom taloženjem sedrenog mulja s podloge jezera. Sediment se sastoji od blata te rijetkih jako malenih biljnih ostataka koji nisu u potpunosti kalcificirani. Teško je uočiti teksturalne i strukturalne razlike između sedimenata s obzirom na gotovo nulti kontrast između njih. Ovakva vrsta sedimenta specifična je samo za ovu lokaciju (duboke, stagnantne vode bez turbulencije).

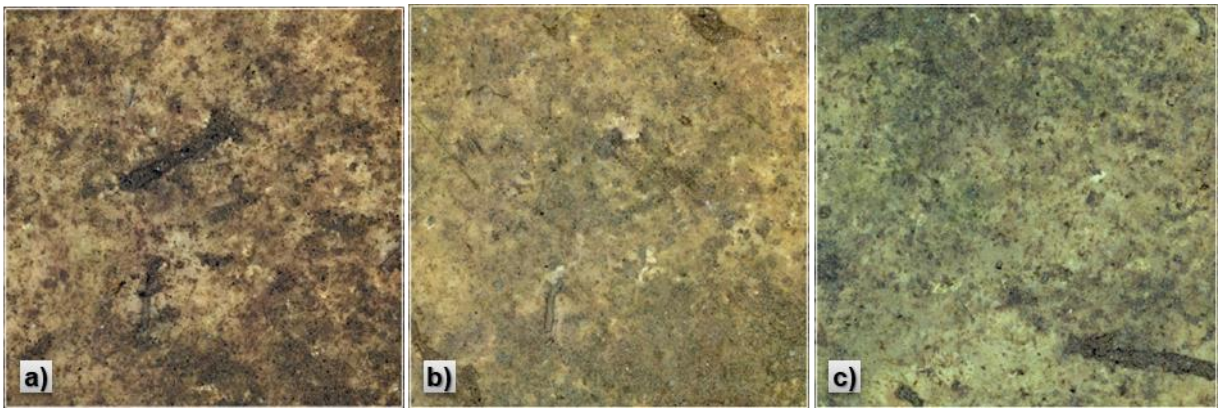

Slika 191. a) PL22 (rujan, 2018) b) PL 22 (ožujak, 2019) i c) PL09 (ožujak, 2019)

Lokacija ***Jezerski slapić*** **(PL18 i 05); N=6 mjeseci i N=12 mjeseci**

Iznad *Jezera 6 stabala*, u zoni prskanja, postavljene su PL18 i 05. Na modelu koji je intervalno vađen PL18 (rujan, 2018) zabilježeno je preko desetak ličinki vodenih kukaca *Simuliidae* (red: *Diptera*) (Slika 192).

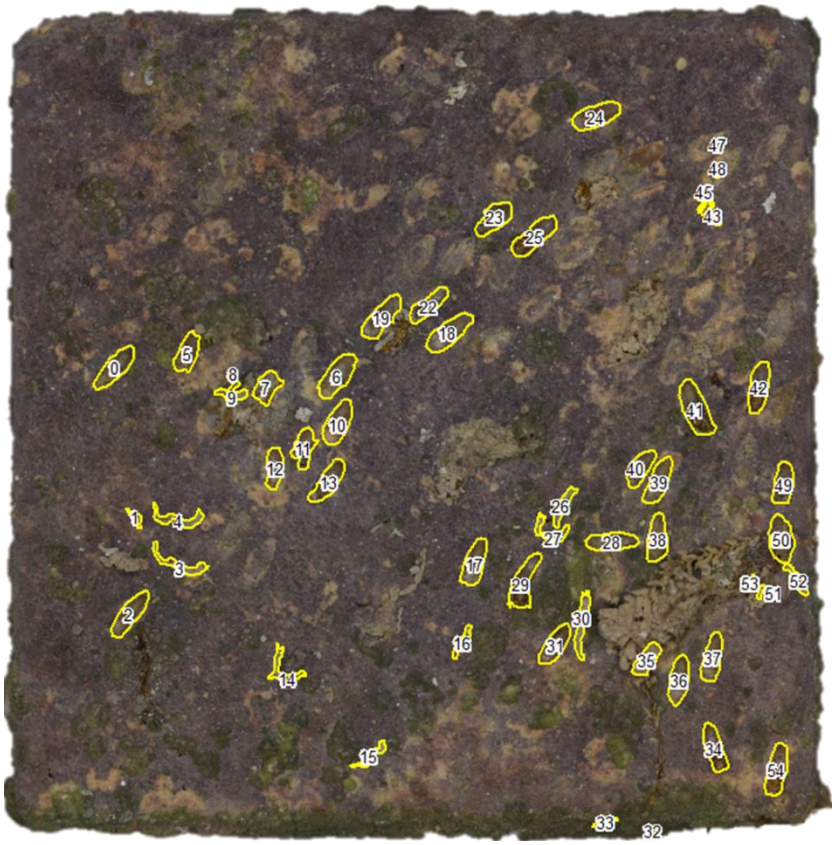

Slika 192. Detektirani mikroorganizmi na površini PL03 (ožujak, 2019)

Neke od njih su prazne, dok se u nekima još uvijek mogu vidjeti organizmi. Na temelju razlike u teksturi mogu se uočiti i lokacije gdje su ličinke ostavile otisak, odnosno nalazile se prije nego što su nestale uslijed emergencije te erozivnog djelovanja toka (Slika 193b).

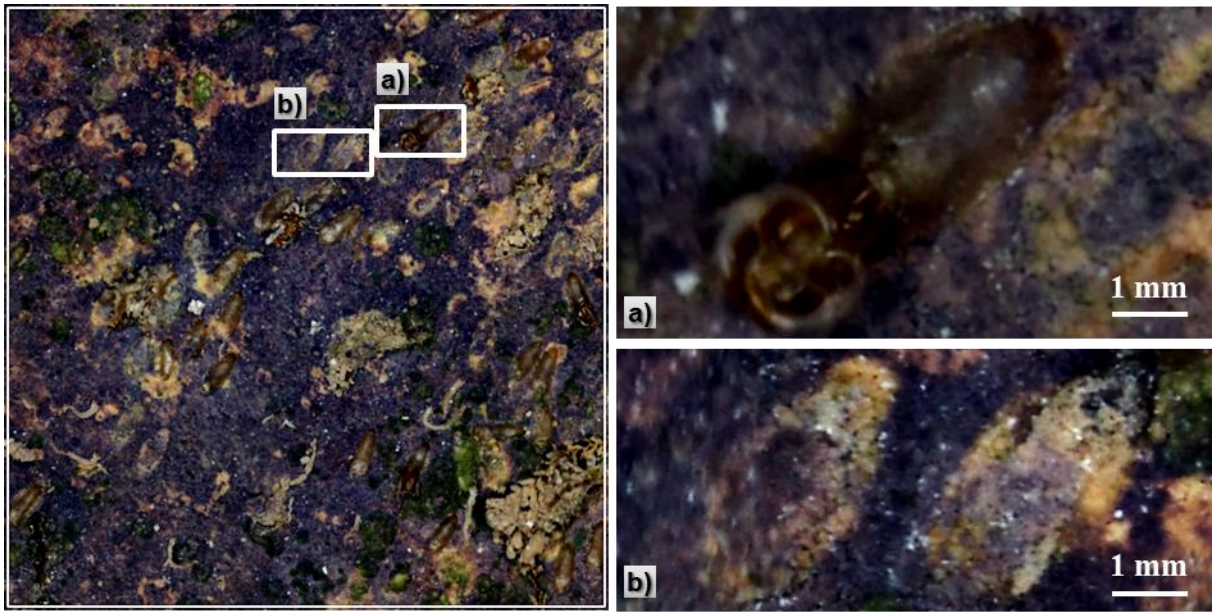

Slika 193. PL18 (rujan, 2018) a) ličinka vodenih kukaca *Simuliidae* te b) otisak ličinke na supstratu

Na istoj pločici nakon godine dana (ožujak, 2019) nisu zabilježene spomenute ličinke. Ipak na površini supstrata uočen je znatan broj cjevastih oblika koji su vjerojatno izgrađeni od strane dvokrilaca iz porodice *Chironomidae* (Slika 194). Precipitat na toj površini nije pretjerano čvrst (rupičast struktura sedre), mogu se uočiti nakupine manjih biljnih fragmenata, nema izražene laminacije. Tekstura je raznolika: zelenkasto - smeđe - ljubičaste nijanse (Slika 195).

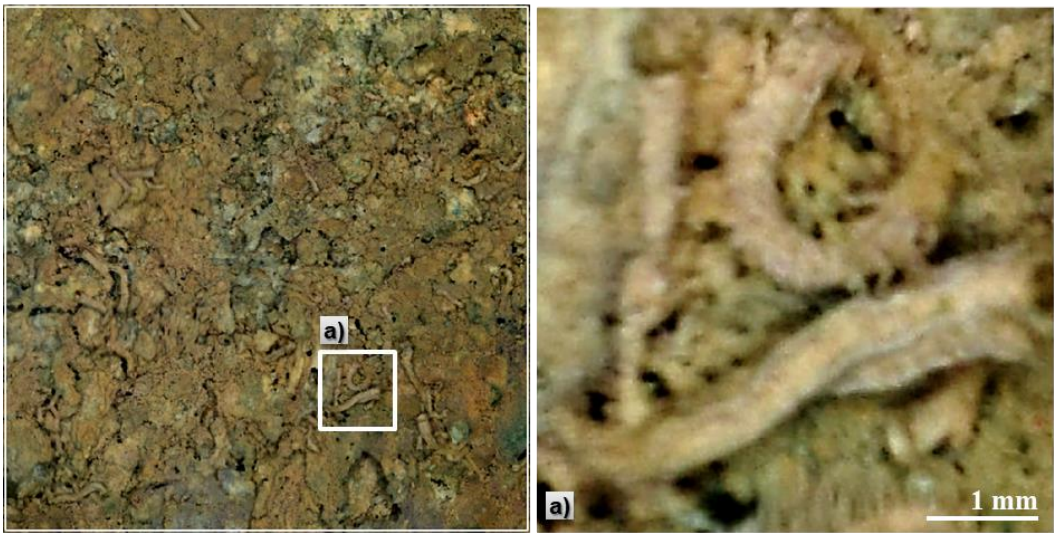

Slika 194. PL18 (ožujak, 2019) a) ličinka cjevčastog oblika porodica *Chironomidae*

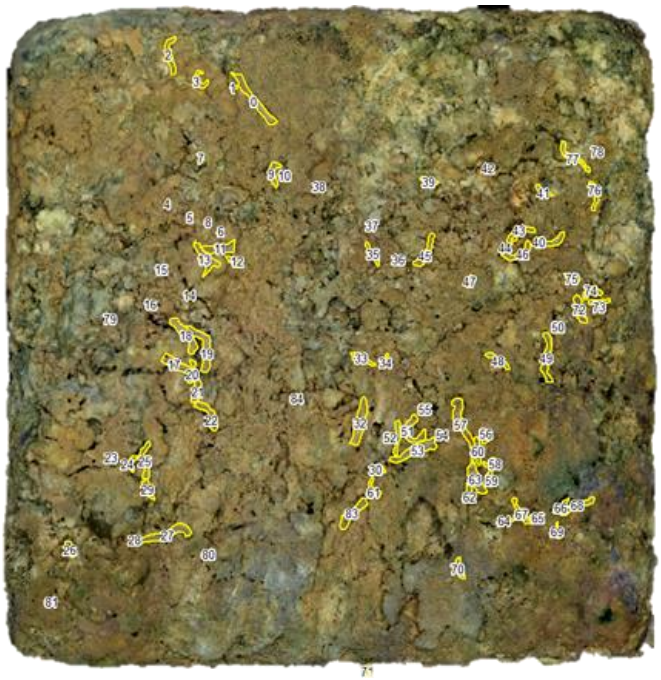

Slika 195. Detektirani mikroorganizmi na površini PL18 (ožujak, 2019)

Na susjednoj PL05 koja je izvađena nakon godine dana (ožujak, 2019) uočen je manji broj cjevastih ličinki vodenih kukaca (Slika 197). U odnosu na PL18 na velikom dijelu mjerne

površine došlo je do inkrustacija algi ili mahovina koje izgledaju kao nepravilno isprepletene niti koje su presvučene kalcitnom ovojnicom (Slika 196b). Međutim, teško je razlikovati inkrustirane ovojnice algi ili mahovina od cjevastih oblika ličinki zbog čega njihov broj može biti i veći. Na površini precipitata uočen je jedan veći biljni fragment. Tekstura susjednih pločica izgleda dosta slično (Slika 195 i 196). Precipitat izgleda nešto čvršće u odnosu na susjednu pločicu, ipak površinom dominira rupičasta struktura.

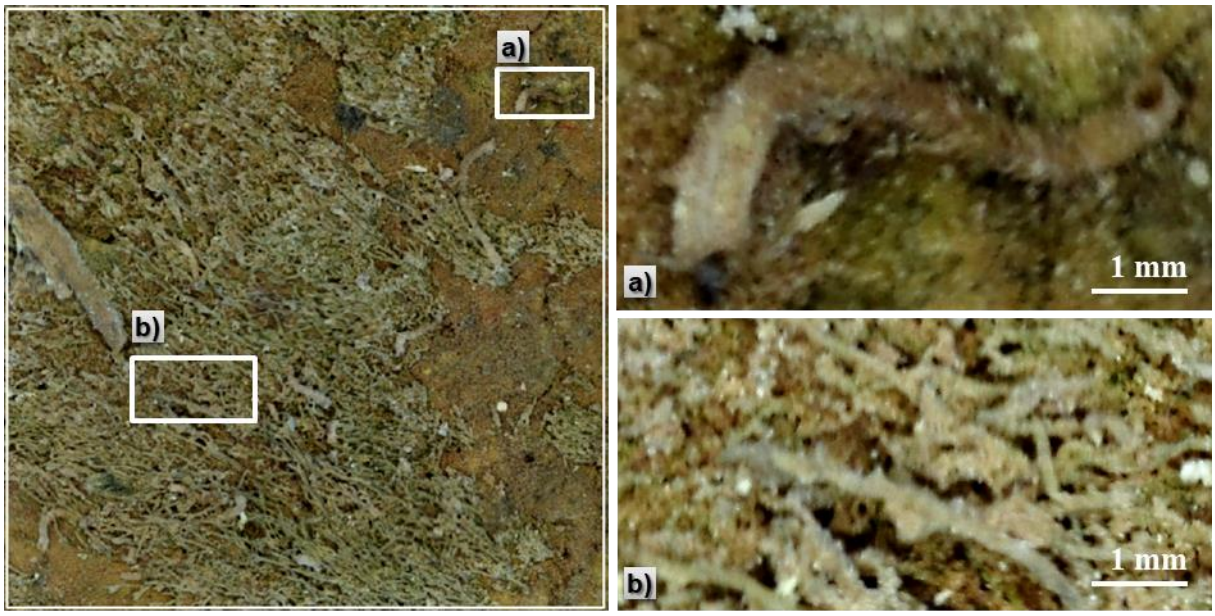

Slika 196. PL05 (ožujak, 2019) a) ličinka cjevastog oblika b) inkrustacija algi

Slika 197. Detektirani mikroorganizmi na površini PL05 (ožujak, 2019)

Lokacija ***Kod mladog jasena*** **(PL10 i 12); N=6 mjeseci i N=12 mjeseci**

Na pločicama (PL10 i 12) na lokaciji *Kod mladog jasena* nisu uočene značajnije količine ličinki makrozoobentosa. Lokaciju obilježava velika brzina protoka te turbulencija vode. Nešto je bolja osvijetljenost u odnosu na lokaciju *Kod duplog crnog graba* te se pločice nalaze na manjoj dubini, gotovo na samoj površini vode. Na PL10 (rujan, 2018) uočena je pojava inkrustacije nepravilno isprepletenih niti algi u smjeru toka vode koje su prevučene kalcitnom ovojnicom (Slika 198). Nakon godine dana (ožujak, 2018) na površini je detektiran gotovo u potpunosti inkrustiran list u površinu sedre (Slika 2199).

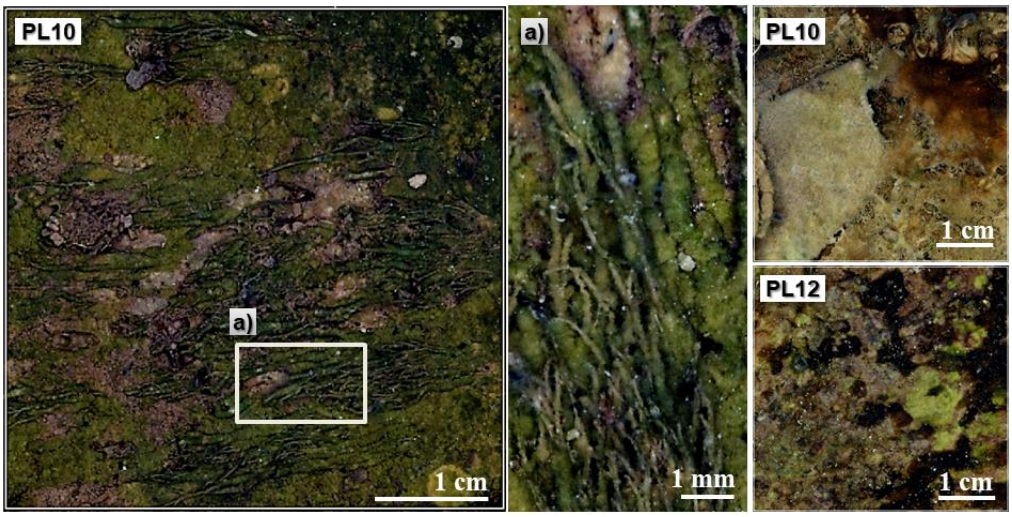

Slika 198. a) Inskrustacija algalnih niti PL10 te površina PL10 i 12 nakon godine dana

U odnosu na susjednu PL12, na PL10 je nakon dvanaest mjeseci izloženosti toku uočena nešto veća količina izrazito sitnih, uglavnom uspravnih ličinki makrozoobentosa.

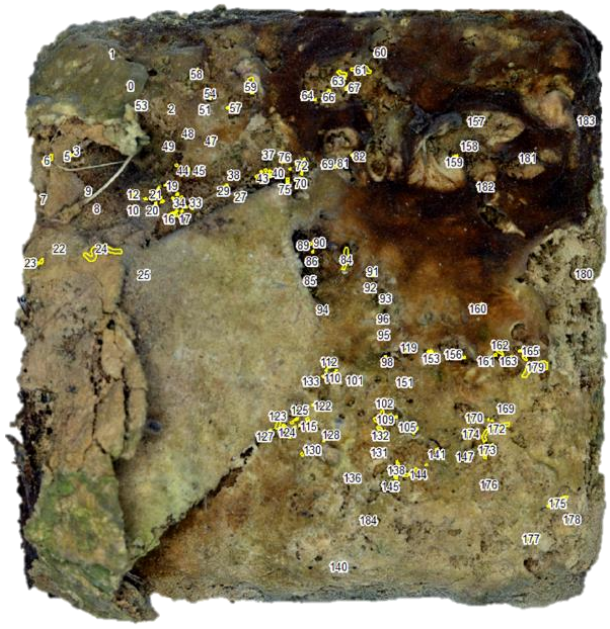

Slika 199. Detektirani mikroorganizmi na površini PL10 (ožujak, 2019)

Susjedna PL12 ima nešto drugačiju teksturu od PL10 (Slika 199), najsličniju *maskirnoj* zeleno-smeđoj podlozi koju su imale PL04 i PL21 (*Kod duplog crnog graba*). Na ovoj lokaciji je nastala čvršća, slabo porozna sedra s izrazitom laminacijom kod PL12. Veća količina inkrustiranih biljnih fragmenata te ličinki makrozoobentosa učinile su PL10 nešto poroznijom. Ipak, ova vrsta facijesa odgovara brzo tekućem okruženju u kojem nema izrazitog rasta mahovina ili drugih makrofita u neposrednoj blizini pločice. Veća količina ličinki makrozoobentosa na PL10 vjerovatno je posljedica dobrih uvjeta prozračivanja fluvijalnog okruženja. Prema teksturi i strukturi najsličnije su pločicama na lokaciji *Kod duplog crnog graba* (FFW). PL10 i 12 se razlikuju prema teksturalnim i strukturnim obilježjima. PL10 ima nešto porozniji, nepovezaniji sediment od PL12 te nešto svjetliju teksturu.

Lokacija ***Kod spomenika*** **(PL24 i 19); N=6 mjeseci i N=12 mjeseci**

Na modelu PL24 snimljenom u rujnu, 2018 zabilježeno je tek par ličinki vodenih kukaca *Simuliidae* (red: *Diptera*) i to izvan mjerne plohe, na samom rubu pločice (Slika 200a). Navedeno ne iznenađuje s obzirom na to da je snimanje izvršeno krajem rujna kad aktivnost makrozoobentosa znatno opada u odnosu na ljetne mjesece. Ipak, na površini su još vidljivi otisci ličinki, odnosno lokacije gdje su se nalazile prije nego što su nestale uslijed emergencije te erozivnog djelovanja toka (Slika 200b). Nadalje, uočena je manja pojava inkrustacije nepravilno isprepletenih niti algi u smjeru toka vode koje su presvučene tankom kalcitnom ovojnicom (Slika 200c).

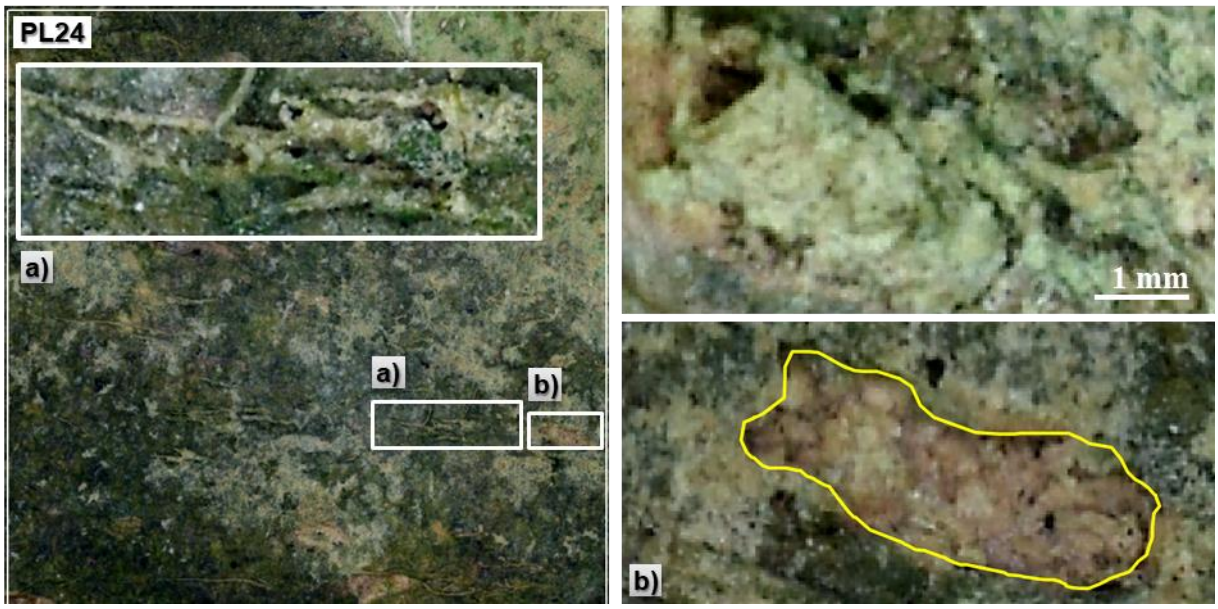

Slika 200. PL24 (rujan, 2018) a) inskrustacija algalnih niti te b) te otisak ličinke cjevčastog oblika porodice *Chironomidae*

Na istoj pločici (ožujak, 2019) sedreni depozit je uslijed presušenja toka (objašnjeno u prethodnim poglavljima) dobio specifičnu bijelu teksturu. Struktura sedimenta je nakon presušenja postala izrazito krhka i porozna. Na površini nema vidljivog makrozoobentosa, već se samo mogu nazrijeti niti isprepletenih algi sad s dominantnom bijelom teksturom. Presušenje toka utjecalo je na strukturu sedrenog depozita koji je sad postao podložniji mrvljenju, prhkiji. Na obje pločice (PL19 i 24) nisu uočeni jasni obrisi makrozoobentosa. Susjedne pločice su slične prema strukturnim, dok se nešto više razlikuju prema teksturalnim obilježjima. Razlog tome je razlika u mikro orijentaciji pločica unutar toka. PL19 je u toku bila nešto izdignutija od PL24 zbog čega je uslijed slabljenja i u konačnici presušenja toka duže vremena bila izvan vode (Slika 201). Prema teksturi i strukturi precipitirana sedre na ovoj lokaciji trebala je biti najsličnija sedri na lokaciji *Kod duplog crnog graba* (FFW) međutim uslijed presušenja toka došlo je modifikacije obilježja sedrenog depozita.

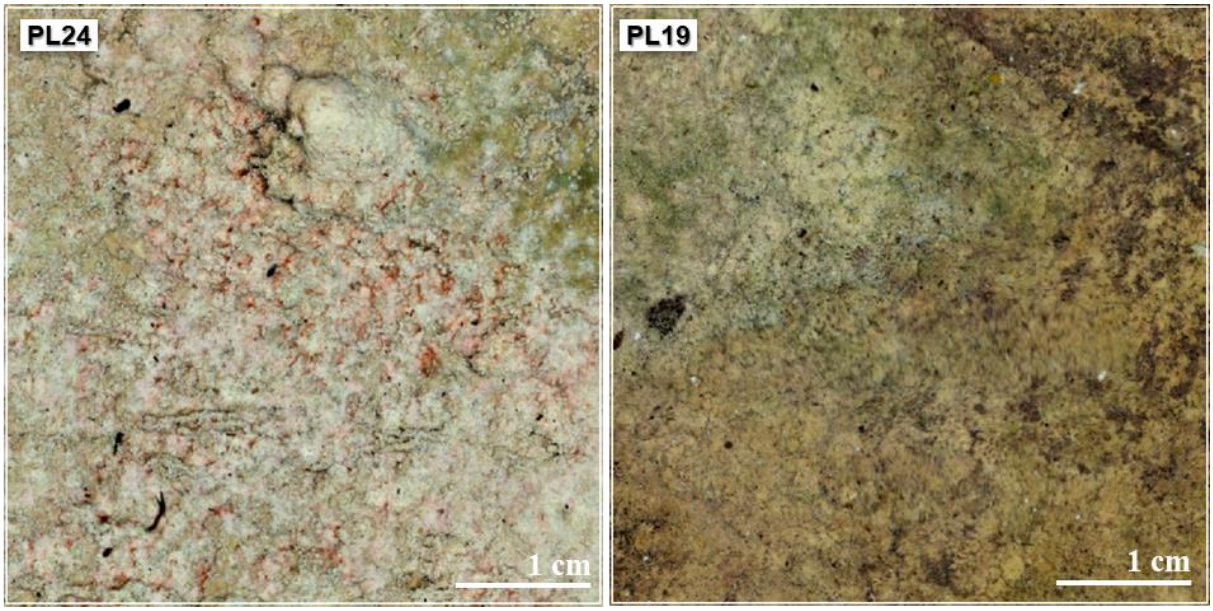

Slika 201. a) Bijela tekstura PL24 te b) PL19 (ožujak, 2019)

Lokacija ***Krivo stablo*** **(PL15 i 28); N=6 mjeseci i N=12 mjeseci**

Na modelu PL15 snimljenom u rujnu, 2018. zabilježeno je tek nekoliko ličinki vodenih kukaca *Simuliidae* (red: *Diptera*) i to izvan mjerne plohe, na samom rubu pločice (Slika 202a) te jedna ličinka iz porodice *Chironomidae*. Manji broj ličinki posljedica je vremena snimanja koje je izvršeno krajem rujna, kad aktivnost makrozoobentosa znatno opada u odnosu na ljetne mjesece. Nadalje, uočena je pojava nakupljanja i inkrustacije manjih biljnih fragmenata koji su presvučeni tankom kalcitnom ovojnicom (Slika 202b). S obzirom na blizinu makrofita ovoj lokaciji pojava biljnih fragmenata te makrozoobentosa ne iznenađuje.

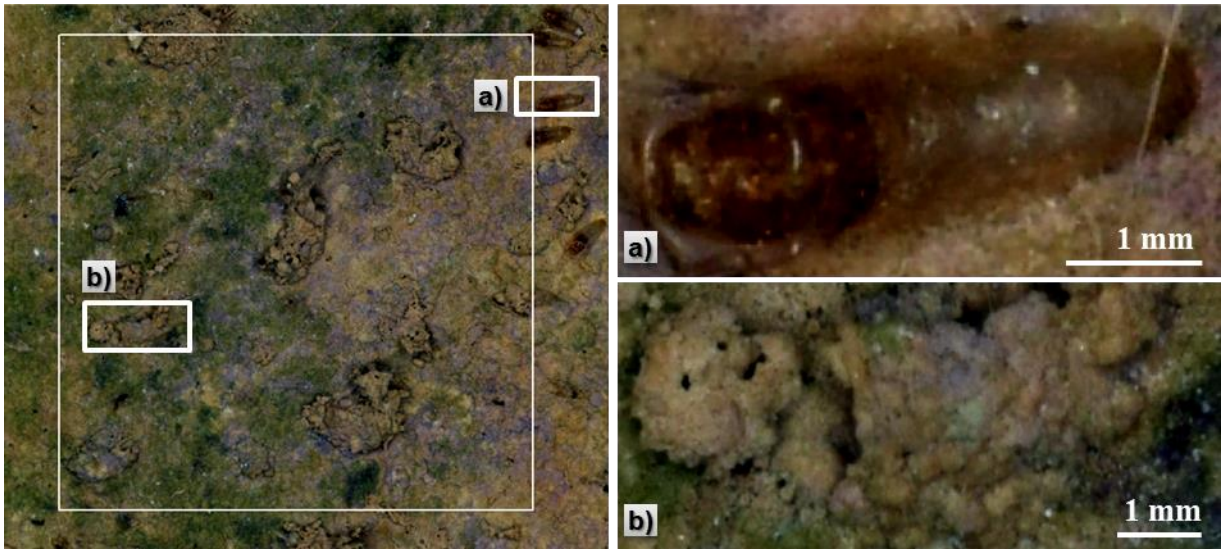

Slika 202. Sedrena površina PL15 a) ličinka vodenog kukca b) inkrustacija ličinke

Nakon godine dana (ožujak, 2019) na površini P15 je uočen gotovo u potpunosti inkrustiran list. Ispod njega se donekle nazire *maskirna* zeleno-smeđa podloga slična lokaciji *Kod mladog jasena*. Nadalje, na površini se može uočiti i manji broj ličinki vodenih kukaca koji još nisu u potpunosti pričvršćeni za supstrat. Ako se izuzme inkrustirani list na površini PL15 te ličinke koje još nisu u potpunosti povezane za supstrat, na ovoj lokaciji je nastala relativno čvrsta, ali ipak porozna sedra. To je još uočljivije na PL28 gdje nije došlo do značajnijeg nakupljanja biljnih fragmenata, ali se mogu primijetiti mali otočići mahovine integrirani unutar supstrata (Slika 203c) te veća količina cjevastih oblika raznih ličinki vodenih kukaca koja je već inkrustirana u depozit (Slika 203b).

Ovakva struktura i tekstura precipitirane sedre na PL15 i PL28 odgovara bržem, turbulentnijem (uvjeti prozračivanja) fluvijalnom okruženju u kojem ipak ima znatnijeg rasta mahovina ili drugih makrofita u neposrednoj blizini pločica. Navedeno su značajke lokacije *Krivo stablo* (SC). Prema istaknutim obilježjima precipitirana sedre ove lokacije je slična sedri nastaloj na lokacijama *Kod mladog jasena* (FFW) i *Pačji slap* (SC).

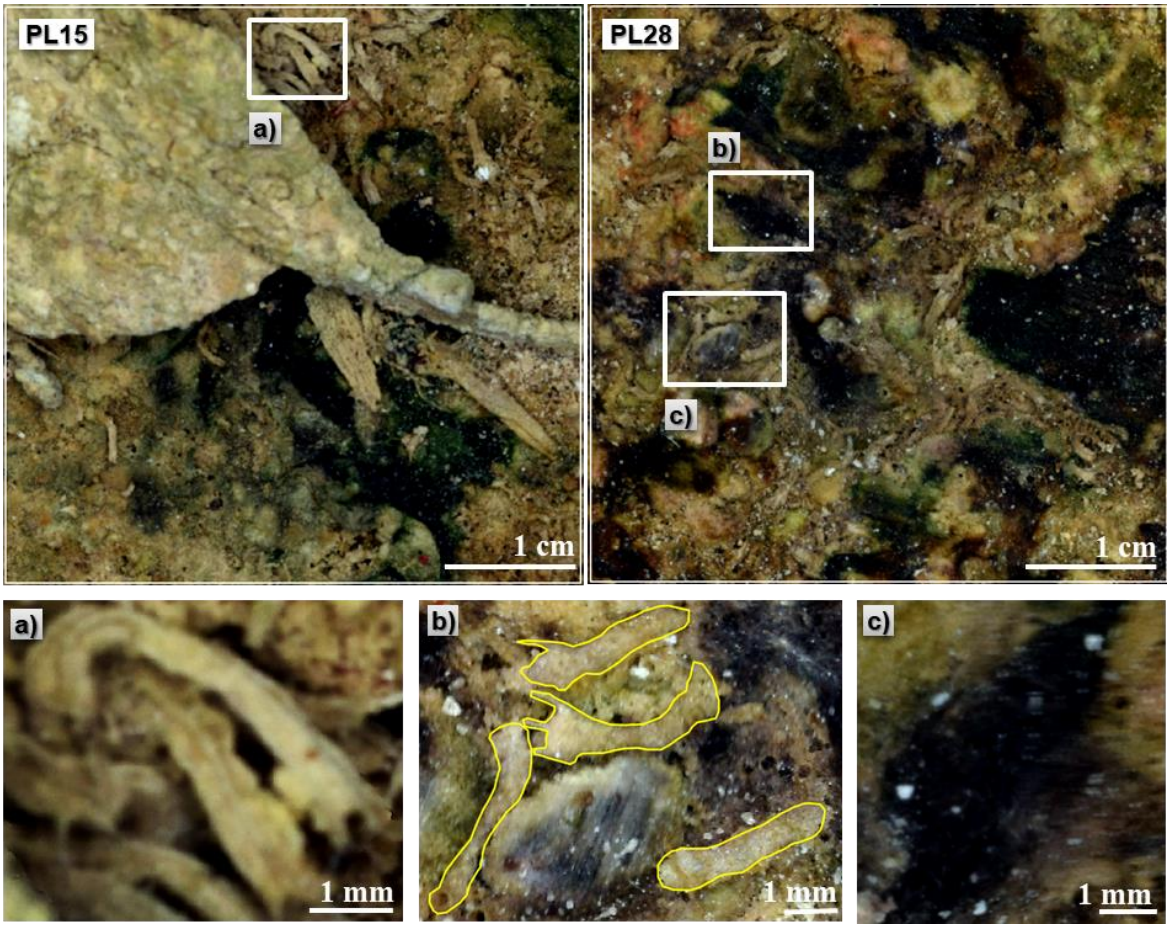

Slika 203. Površina sedre PL15 i PL28 a-b) ličinke vodenih kukaca c) otočići mahovine

Lokacija ***Nježna mahovina*** **(PL14 i 29); N=6 mjeseci i N=12 mjeseci**

Na modelu PL29 snimljenom u rujnu, 2018. zabilježen je isti slučaj kao na PL15 (*Krivo stablo*). Na površini se može uočiti nešto veći broj (devet) ličinki vodenih kukaca *Simuliidae* (red: *Diptera*) unutar mjerne plohe (Slika 204a) te nakupljanje i inkrustacija manjih biljnih fragmenata koji su presvučeni tankom kalcitnom ovojnicom (Slika 204b). S obzirom na blizinu makrofita pojava biljnih fragmenata i značajnije količine makrozoobentosa je očekivana.

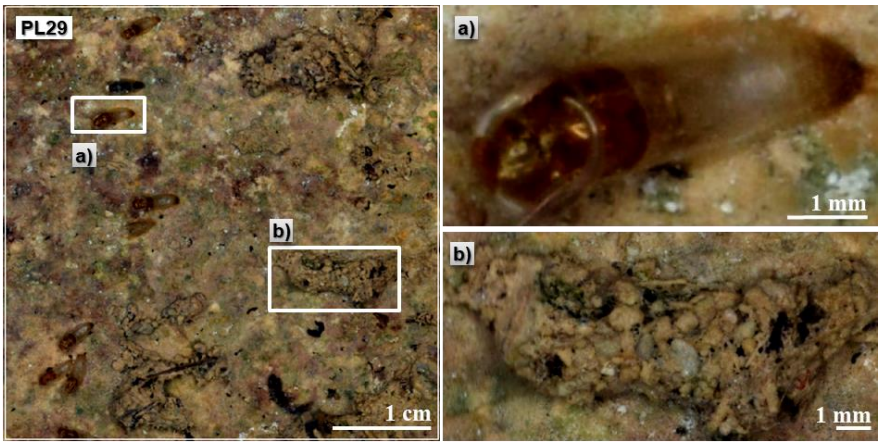

Slika 204. Površina sedre PL29 a) ličinka vodenog kukca te b) inkrustacije ličinke

Nakon godine dana (ožujak, 2019.) površina PL29 je u potpunosti prekrivena tamno-zelenim smeđim „tepihom“, kojeg čine alge i mahovine, na kojem nisu vidljivi ostatci makrozoobentosa (Slika 205a). Na susjednoj pločici (PL14) koja je izvađena nakon godine dana nije došlo do potpunog prekrivanja mjerne površine sa zelenim tepihom već se mogu primijetiti mali otočići algi unutar mjerne plohe (Slika 205b). U odnosu na PL29, na PL14 se može uočiti veća količina cjevastih oblika raznih ličinki vodenih kukaca koje na nekim lokacijama još uvijek nisu u potpunosti inkrustirane u depozit (Slika 205c).

Susjedne pločice se prema teksturnim i strukturnim obilježjima donekle razlikuju. PL29 ima specifičnu teksturu što je izravna posljedica njezine mikro lokacije (blizina mahovina). PL14 ima nešto porozniju strukturu s obzirom na veću količinu makrozoobentosa. Ipak, ovakva vrsta strukture i teksture precipitirane sedre odgovara bržem, turbulentnijem fluvijalnom okruženju u kojem ima znatnijeg rasta mahovina i drugih makrofita u blizini pločica. Prema teksturnim i strukturnim obilježjima precipitirana sedre na lokaciji *Nježna mahovina* (SC) je najsličnija sedri nastaloj na lokaciji *Krivo stablo* (SC).

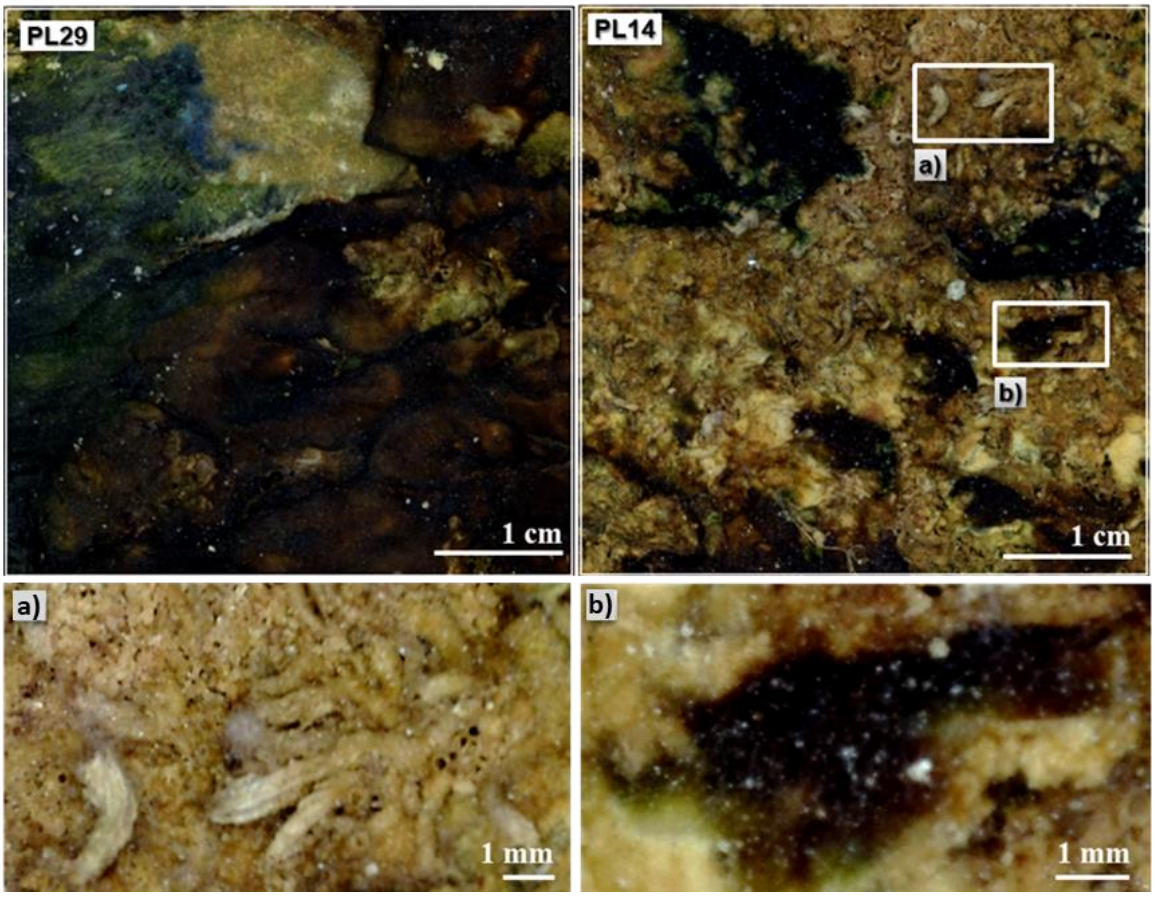

Slika 205. Površina sedre PL29 i PL14 a) ličinke vodenih kukaca i b) nakupine algi

Lokacija ***Sedreni zid*** **(PL23 i 30); N=6 mjeseci i N=12 mjeseci**

Na modelu PL23 snimljenom u rujnu, 2018. zabilježen je mozaičan raspored sedre koji može biti posljedica metaboličkih izlučevina kukaca iz porodice *Chironomidae* (Matoničkin Kepčija, 2019) (Slika 206). Sediment na ovom modelu nije čvrst, nema jasne laminacije, izrazito je porozan te se na površini precipitata može uočiti mali broj ličinki kukaca iz porodice *Chironomidae* koje su u potpunosti inkrustirane u površinu sedre (Slika 206a). Teško je jasno utvrditi njihov točan broj s obzirom na to da je došlo do gotovo gotovo potpune inkrustacije u supstrat (Slika 206). Može se pretpostaviti da bi većim intervalom vađenja (3 mjeseca) broj uočenih ličinki bio veći te da bi bilo jednostavnije utvrđivanje njihovih oblika.

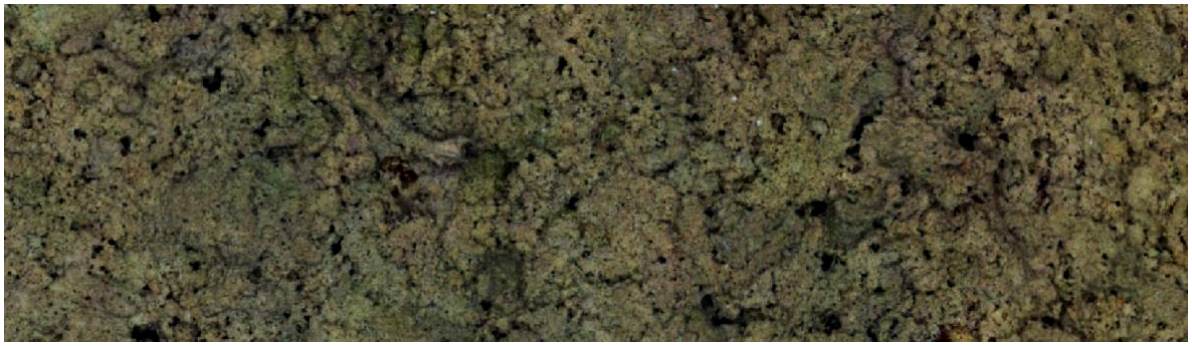

Slika 206. Mozaična struktura supstrata na PL23 (rujan, 2018)

Nakon godine dana (ožujak, 2019.) na istoj pločici su uočene veće nakupine biljnih fragmenata uz povremene ličinke kukaca iz porodice *Chironomidae*. Zbog velike količine biljnih fragmenata koji još uvijek nisu u potpunosti inkrustirani sedra nije čvrsta, izrazito je porozna te nema jasnu laminaciju (Slika 207b). Susjedna PL30 je prema teksturalnim i strukturnim obilježjima u potpunosti ista kao PL23. Precipitat je rastresit, labav, bez jasne laminacije s rupičastom strukturom (Slika 207b-c). Tekstura ovih pločica se u potpunosti razlikuje od zeleno-smeđe maskirne teksture pločica smještenih u fluvijalna okruženja koja obilježavaju brži protok te izrazitija turbulencija vode. Iako je fluvijalno okruženje ove lokacije klasificirano kao SFW, kao lokacija *Kaskada*, na ovim pločicama je zabilježena puno veća količina precipitata. To je posljedica većih količina nanesenog biljnog materijala te većeg broja jedinki makrozoobentosa. Naime, zanimljivo je da se na mjernoj plohi obje pločice (PL23 i 30), izvađene nakon godine dana, nalazi po jedan izrazito velik biljni fragment koji utječe na „lažno“ povećanje prosječne stope sedrenja ove lokacije. Točnije, lokacija *Kaskada* u fluvijalnom okruženju iste klasifikacije (SFW) ima prosječnu stopu sedrenju od 1,474 mm a^{-1}, dok je na ovoj lokaciji prosječna stopa sedrenja iznosila čak 6,075 mm a^{-1}. U odnosu na lokaciju *Kaskada* (SC), *Sedreni zid* (SFW) se nalazi ispod toka koji izlazi iz *Jezera 6 stabala*, pritom

prolazeći kroz guste makrofite donoseći velike količine biljnih fragmenata. Također, lokacija je nešto osunčanija. Ipak, izuzev količine nastalog precipitata teksturna i strukturna (porozna sedre, bez izrazite laminacije) obilježja sedre su najsličnija lokaciji *Kaskada*.

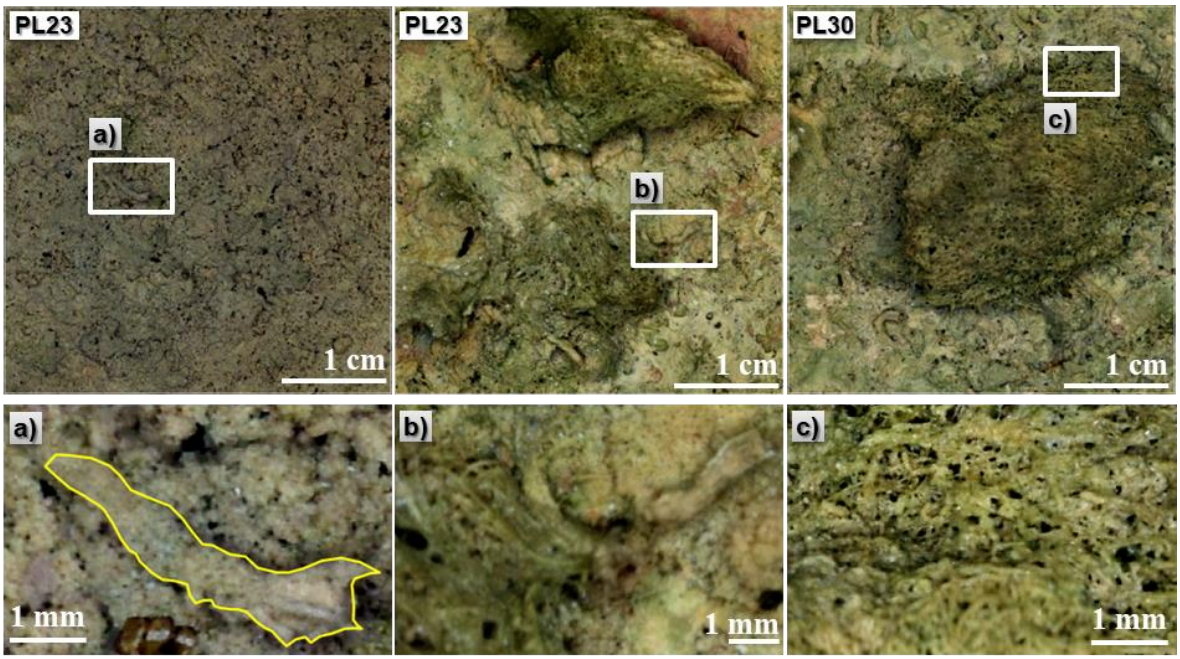

Slika 207. Površina sedre PL23 i PL30 a) ličinka vodenih kukaca b-c) veliki biljni fragmenti

Lokacija ***Sedreni kanjon*** **(PL27 i 11); N=6 mjeseci i N=12 mjeseci**

Na modelu PL27 snimljenom u rujnu, 2018. nisu zabilježene jedinke makrozoobentosa. Tekstura površine ima jedinstven izgled koji se sastoji od ljubičaste podloge (vjerojatno *cyanobacteria-Red slime algae*), okruglih zelenkastih nakupina te žuto-smeđih okruglih nedeterminiranih nakupina (Slika 208a-b-c).

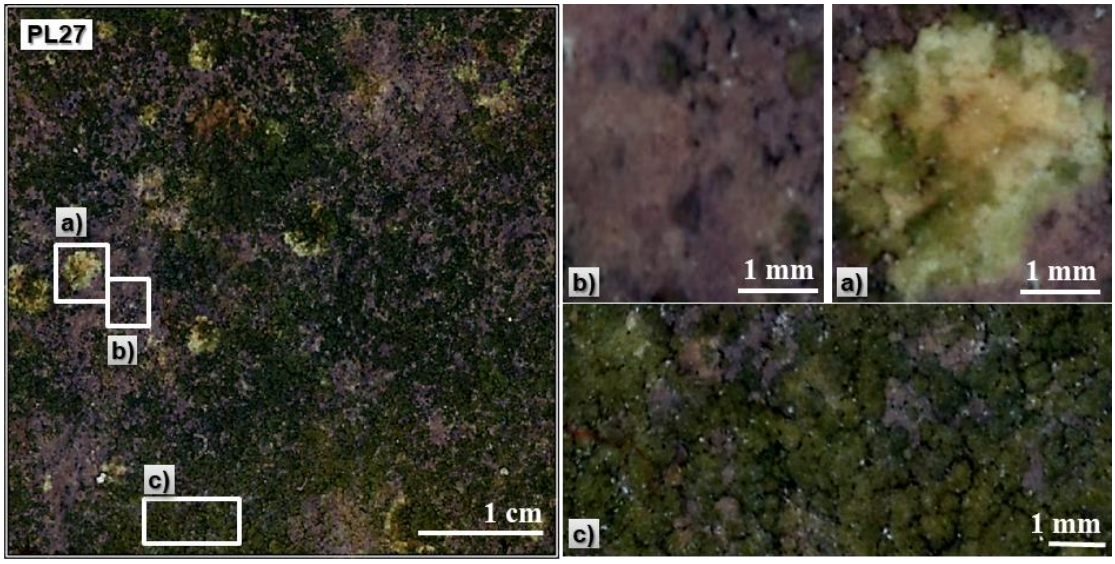

Slika 208. Površina sedre PL27 sa specifičnom teksturom

Nakon godine dana izloženosti toku (ožujak, 2018.) nestala je prepoznatljiva ljubičasto-zelena tekstura. Površina je u potpunosti prekrivena tamnim zelenkasto-smeđim tepihom na kojem nisu vidljivi ostatci makrozoobentosa (Slika 209). Na manjim dijelovima još se mogu uočiti ljubičaste krpice podloge od prije šest mjeseci. Na susjednoj pločici (PL11) tekstura maskirne zeleno-smeđe podloge je nešto izraženija. Na pločici nije uočen makrozoobentos, ali se također mogu primijetiti ljubičaste krpice podloge koje su detektirane na PL27.

Na ovoj lokaciji je nastala čvrsta, neporozna sedra s izrazitom laminacijom. Ova vrsta strukture i teksture odgovara SFW okruženju u kojem nema izrazitog rasta makrofita u neposrednoj blizini pločice. Usprkos izrazitoj turbulenciji vode, koje omogućuje jako prozračivanje, na depozitu nije uočen makrozoobentos. Razlog tome može biti interval snimanja (hladno razdoblje), nedostatak makrofita u blizini koji im služe kao mikrostanište te vrlo jaki protok koji sprječava hvatanje i naseljavanje organizama. PL11 i 27 su iste prema strukturnim i teksturalnim obilježjima. Prema teksturnim i strukturnim obilježjima precipitirana sedre na ovoj lokaciji (SZ) je slična sedri nastaloj na lokaciji *Kod mladog jasena* (FFW) i *Kod duplog crnog graba* (FFW).

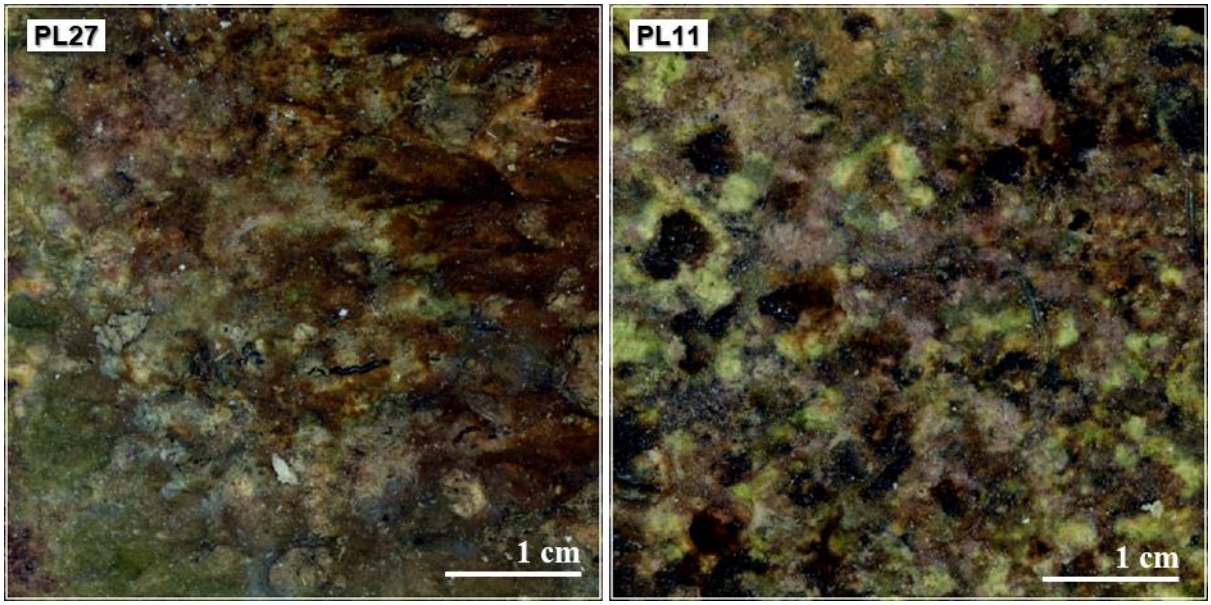

Slika 209. Površina sedre PL27 i 11

Lokacija ***Kaskada*** **(PL01 i 26); N=12 mjeseci**

Na ovoj lokaciji pločice su vađene nakon godine dana izloženosti toku (ožujak, 2019.). Nalaze su fluvijalnom okruženju SFW u kojoj nema značajnije turbulencije (slabi uvjeti prozračivanja) te je osunčanost slaba. Zbog navedenih razloga na površini precipitata se nije očekivao veći broj ličinki vodenih kukaca što je na modelima potvrđeno (Slika 210). U konačnici je na obje pločice (PL01, 26) detektirano tek po nekoliko ličinki. Na površini se

uglavnom nalaze kalcificirani ostaci mahovina, nitastih algi i manjih biljnih fragmenata. Njih je nešto veći broj u odnosu na lokaciju *Jezero 6 stabala* koja je *Kaskadi* slična po fluvijalnim obilježjima. Razlog tome je ipak nešto brži protok vode. Na obje pločice je nastao facijes sedre koji je tipičan za uvjete sporog protoka vode u kojem nema turbulencije vode te u blizini nema veće količine makrofita.

Sediment nije čvrsto povezan, rastresit je, uglavnom je izgrađen od vapnenačkog blata, nema laminacije. Tekstura i struktura površine je najsličnija lokaciji *Kaskada*. Na ovoj lokaciji je zabilježena manja količina depozita što je posljedica izostanka biljnih fragmenata te veće količine makrozoobentosa na mjernoj plohi. PL01 i 26 su u potpunosti iste prema strukturnim i teksturalnim obilježjima precipitirane sedre (Slika 210).

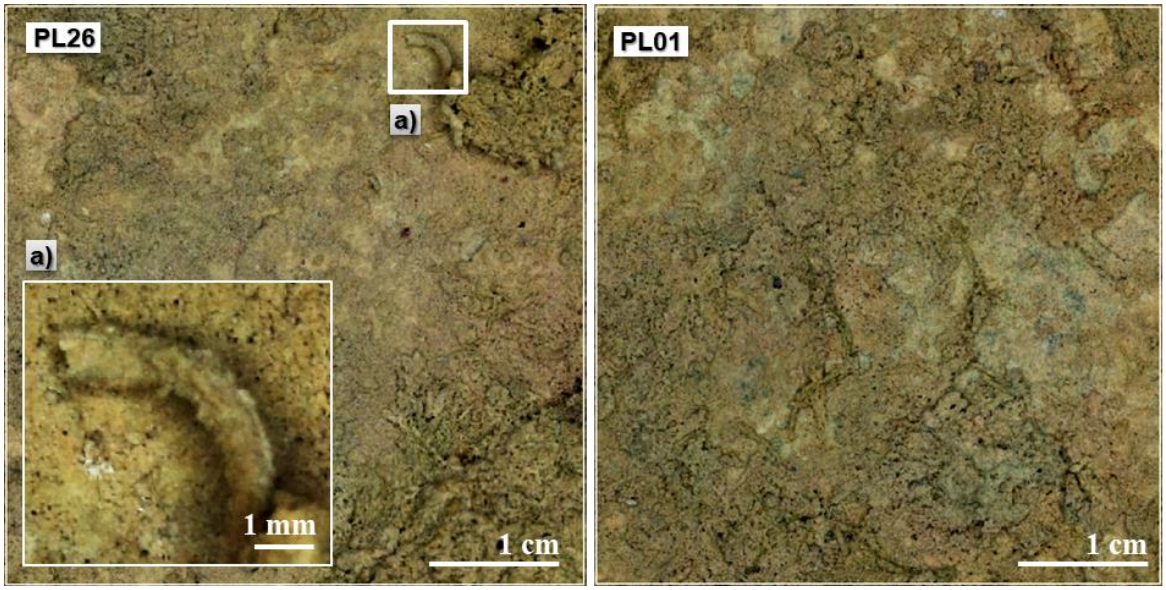

Slika 210. PL26 (ožujak, 2019) a) ličinka cjevastog oblika porodica *i b)* PL01

Lokacija ***Kod duplog crnog graba*** **(PL04 i 21); N=12 mjeseci**

Na pločicama (PL04, 21) koje su snimane u intervalu od godine dana nisu uočene ličinke makrozoobentosa na površini sedre. To ne iznenađuje s obzirom na interval snimanja te mikro obilježja lokacije. Da su pločice snimane u razmaku od tri mjeseca na njenim prvim modelima vjerojatno bi bila uočena pojava makrozoobentosa kao što je bio slučaj s *Tvrdom sedrom* koja ima slična fluvijalna obilježja (FFW). U odnosu na *Tvrdu sedru* ova lokacija je slabije osvjetljenja jer se pločice nalaze u usječenom toku smještenom između dva graba. Uz to pločice se nalaze na većoj dubini, nego kod *Tvrde sedre* i *Kod mladog jasena*, a osobito *Sedrenog kanjona,* gdje gotovo da i nisu uronjene, nalazeći se u zoni prskanja. Činjenica da je stopa sedrenja na ovoj lokaciji 2,841 mm a^{-1} manja od lokacije *Tvrda sedre*, a nalaze se u sličnom fluvijalnom okruženju, ukazuje na to da je ovdje izostala značajnija uloga

makrozoobentosa u procesu formiranja sedre. Površina sedimenta na obje pločice izgleda kao maskirna zelenkasto-smeđa podloga koja je sačinjena od različitih algi i biljaka (Slika 211). Slična tekstura je uočena na lokaciji *Tvrda sedra* i *Kod mladog jasena*.

Na lokaciji je nastala najčvršća, neporozna sedra s izrazitom laminacijom. Ova vrsta facijesa odgovara brzo protočnom okruženju u kojem nema izrazitog rasta mahovina ili drugih makrofita u neposrednoj blizini pločice. PL04 i 21 su u potpunosti iste prema strukturnim i teksturalnim obilježjima.

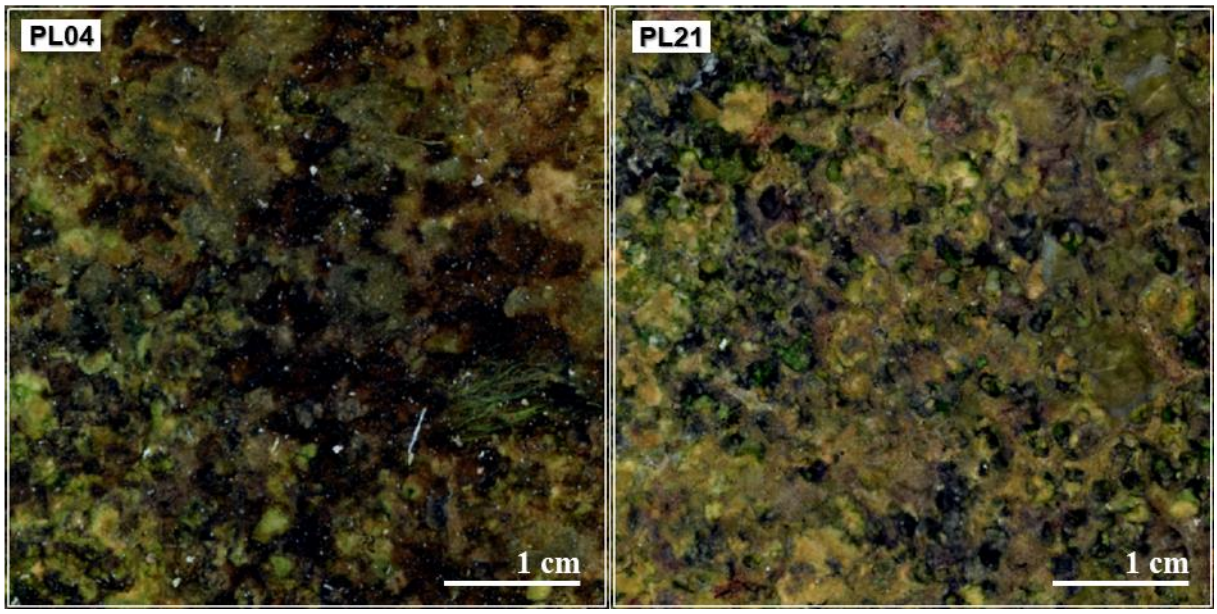

Slika 211. Zeleno-smeđa tekstura PL04 i 21 (ožujak, 2019)

4.4.0 Dinamika formiranja sedre na pločicama mjerenim u tromjesečnim intervalima

U istraživanjima dinamike sedrotvornih sustava očekivano je da prirast sedre bude veći u razdobljima nakon prve kolonizacije umjetnih podloga, odnosno nakon što je stvoren veći supstrat za nukleaciju kalcita. Dakle, u pravilu za vrijeme kolonizacijskog razdoblja prirast sedre bi trebao biti niži u odnosu na druga razdoblja mjerenja. Međutim, taj trend od tri pločice (PL06, PL13 i PL25) koje su mjerene u tromjesečnim intervalima ima samo PL06 (Slika 212).

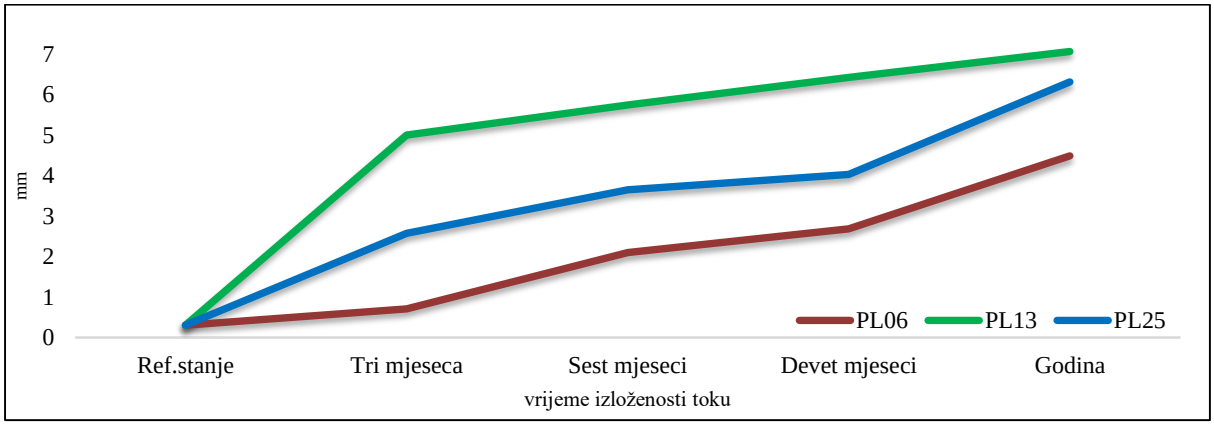

Slika 212. Dinamika formiranja sedre na pločicama vađenima u tromjesečnim intervalima

U prvom kolonizacijskom razdoblju PL06 (ožujak, 2018. – lipanj, 2018) prirast sedre je iznosio 0,706 mm, dok je u drugom (lipanj, 2018. – rujan, 2018) bio 1,386 mm, odnosno 0,680 mm veći. Suprotno, u prvom kolonizacijskom razdoblju PL13 prirast je iznosio 4,997 mm, dok je u razdoblju nakon iznosio tek 0,744 mm, odnosno za 4,253 mm manje. Isti slučaj je zabilježen na PL25 gdje je u prvom kolonizacijskom razdoblju prirast iznosio 2,574 mm, u razdoblju nakon 1,072 mm, odnosno 1,502 mm manje. Odstupanje od očekivane dinamike sedrenja nešto je manje za PL25, dok ja za PL13 osobito izražena. Ono se može objasniti kroz navedene postavke. Povoljni lokacijski uvjeti pločica, reprezentirani u izrazitom prozračivanju (PL13), osunčanosti (PL25) te blizini makrofita (PL25) uvjetovali su doseljavanje veće količine makrozoobentosa u prvom kolonizacijskom razdoblju (ožujak, 2018. – lipanj, 2018) koji je utjecao na lažno povećanje stopa prirasta sedre istovremeno čineći supstrat poroznijim i podložnijim erozivnim događajima. To se može utvrditi iz podataka o erozivnim događajima. Naime, količina erodiranog materijala je bila puno veća na PL13 i PL25 u drugom razdoblju, odnosno od prve detekcije makrozoobentosa (lipanj, 2018) do drugog vađenja (rujan, 2018) u odnosu na PL06. U tom razdoblju na PL13 i 25 je zabilježena ukupna erozija od 138,673 mm^3 te 90,663 mm^3, dok je intenzitet erozije iznosio 0,565 mm po mm^2 i 0,688 mm po mm^2. U istom razdoblju na PL06 nije došlo do erozije. Na PL06 erozija je zabilježena tek u trećem razdoblju (rujan, 2018, - prosinac, 2018), odnosno u razdoblju gdje su detektirane kukuljice iz porodice

Simuliidae (rujan, 2018) do sljedećeg snimanja (prosinac, 2018). Ukupno je erodiralo 20,453 mm^3 materijala, a intenzitet erozije je iznosio 1,270 mm po mm^2. Intenzitet erozije na PL06 u odnosu na PL13 i 25 je veći zato što je prostor erozije bio ograničen na manja području (54,18 mm^2), odnosno na pojedinačne kukuljice *Simuliidae,* dok su u drugom razdoblju kod PL13 i 25 erodirali veći dijelovi nepovezanog supstrata (245,39 i 240,65 mm^2) s dominantnim ličinkama.

PL13 izrazitije odstupa od očekivane dinamike prirasta sedre. Naime, u njezina tri intervalna razdoblja snimanja (od rujna i prosinca, 2018, do ožujka, 2019) zabilježen je prirast sedre od ukupno 2,065 mm, dok je samo u prvom kolonizacijskom razdoblju zabilježen prirast od 4,997. Dakle, u tri puta dužem razdoblju došlo je do gotovo 2,5 puta slabijeg prirasta. Kod PL25 nije toliko izraženo odstupanje. U ista tri razdoblja zabilježen je prirast od 3,738 mm, dok je u prvom kolonizacijskom razdoblju prirast iznosio 2,574 mm. PL13 izrazitije odstupa od očekivane dinamike sedrenja zbog obilježja svog fluvijalnog okruženja. Naime, lokacija *Tvrde sedre* uz *Kod duplog crnog graba* te *Sedreni kanjon* ima najveću brzinu protoka vode na testnoj plohi. Međutim, poznato je da visoko-energetski protok može uzrokovati "stres" pa čak i spriječiti kolonizaciju mikroorganizama na plohu pločice (Gradziński, 2010). Dovoljna je brzina protoka veća od 80 cm/s da dođe do uklanjanja perifitona s pločice i privremenog gubljenja biomase, što je uočeno na PL13. Do snažnijeg oporavka izgubljene biomase u sljedećim razdobljima snimanja (rujan, 2018. – ožujak, 2019) nije došlo zbog pojačanog protoka vode koji je u hladnijem dijelu godine jačao.

5. RASPRAVA

- **H1 (Razvijen sustav izravnog, beskontaktnog, intervalnog praćenja dinamike sedrenja postići će točnost od ±0,1 mm).**

Navedena hipoteza je **potvrđena**. U procesu određivanja kvalitete mjerenja ispitana je relativna i apsolutna točnost uređaja. Rezultati apsolutne i relativne točnosti su uvjetovani širokim spektrom parametara koji uključuju: proces prikupljanja podataka (postavke kamere, udaljenost senzora od objekta), karakteristike GCP-a, postavke kamere (ISO, žarišna udaljenost, brzina zatvarača, veličina senzora), kalibraciju kamere te proces obrade snimaka (tip algoritma, korisničko-definirani parametri). Apsolutna točnost se odnosi na to koliko je izmjerena vrijednost (u ovom slučaju izmjerena CMD-om) blizu apsolutnoj stvarnoj vrijednosti koja je izmjerena s drugim, referentnim uređajem (*Artec Spider*). Relativna točnost LCS-a, koji predstavlja integralan dio razvijenog sustava za praćenje dinamike sedrenja, je ispitana dodavanjem četiri kontrolne točke u pet različitih projekata. Koordinate kontrolnih točaka nisu mogle biti utvrđene drugom metodom prikupljanja podataka već su izračunate u programu u kojem je kreiran LCS. Stoga je ovim procesom primarno testirana relativna točnost primijenjenog LCS-a.

Na temelju razlike izmjerenih i procijenjenih vrijednosti izvedene su dvije statističke metrike (RMSE i MAE) za X, Y i Z koordinate. Ukupna relativna točnost LCS-a je manja od desetinke milimetra. RMSE kontrolnih točaka za X i Y koordinatu je gotovo jednaka (0,012 i 0,014 mm) te manja od z (0,0988 mm) koordinate. Bolja točnost X i Y koordinate ne iznenađuje s obzirom na: debljinu tiskane linije (visoko kvalitetna tehnika tiskanja), činjenicu da je orijentacija kontrolnih točaka vršena na kvalitetnim fotografijama (unutar DoF) te mogućnosti *Metashapea* prilikom poravnavanja fotografija i pozicioniranja GCP-a. Za X i Y koordinatu točnost pozicioniranja orijentacijskih točaka je prema dobivenim rezultatima unutar jednog piksela. Za Z koordinatu je pogreška veća, ali je unutar desetinke milimetra. Veća pogreška nije začuđujuća s obzirom na to da su sve točke dodane na LCS te da postoji više korisničko-definiranih parametara koji na nju mogu utjecati. Ukupna RMSE kontrolnih točaka u referentnom koordinatnom sustavu iznosi 0,0988 mm. Pogreška reprojekcije iznosi 0,246 piksela u koordinatnom sustavu slike što znači da se kontrolne točke nalaze unutar DoF-a. S obzirom na to da prosječni prirast sedre po lokaciji iznosi 5,771 mm a^{-1}, a pogreška po z koordinati iznosi 0,0988 mm proizlazi da CMD prema odabranim postavkama snimanja precjenjuje i/ili podcjenjuje prirast sedre za 1,71%. Drysdale i Gillieson (1997), koji su prvi

primijenili MEM u mjerenju dinamike formiranja sedre, navode da je pogreška od 5 do 10% godišnje akumulacije prirasta unutar prihvatljivih granica.

Apsolutna točnost je ispitana usporedbom volumena (mm^3) dijela pločice generiranog CMD-om te uređajima koji imaju službenu submilimetarsku točnost 3D točaka. Rezultati potvrđuju apsolutnu točnost CMD-a manju od desetinke milimetra. Naime, volumen testne pločice generiran CMD-om je bliži referentnoj vrijednosti koja je utvrđena *Artec Space Spiderom* u odnosu na *Artec Eva* koja ima točnost 3D točaka od 0,1 mm.

- **H2 (Razvijen sustav izravnog, beskontaktnog, intervalnog praćenja dinamike sedrenja postići će vertikalnu i horizontalnu preciznost od ±0,1 mm).**

Navedena hipoteza je **potvrđena.** Preciznost CMD-a je izračunata na temelju pet intervalnih mjerenja iste pločice provedenim na različite datume, pod istim uvjetima snimanja. Prije svakog snimanja, CMD je rastavljen, ponovno sastavljen te je pločica nanovo fiksirana unutar LCS-a. Izvedeno je pet visoko-rezolucijskih DOF-ova sljedeći definiranu metodologiju obrade fotografija. Na DOF-ovima je označeno 70 uzoraka (piksela) koji bi se na svim modelima n=5 trebali nalaziti na istim koordinatama. Osnovna pretpostavka je bila da je visina LCS-a pomoću digitalnog šublera svaki put postavljena na istu visinu te da se pločica u svakom mjerenju nalazi na istim koordinata s obzirom na to da je fiksirana pomoću pomične metalne stope i fiksnih držača. Aktivnosti obavlja operator stoga određeno odstupanje u oba slučaja mora postojati. Vrijednosti označenih uzoraka su za svako mjerenje izvučene te su iskazane u milimetrima. Iz njih su izračunati rasponi i odstupanja mjerenja od srednjaka za X, Y i Z koordinatu svih uzorka (n=70). Preciznost je potom reprezentirana kroz SD, MAE i relativnu nesigurnost. Prema SD-u i MAE-u vrijednosti za X, Y i Z koordinatu ne prelaze desetinku milimetra. Udaljenost uzorka prema X i Y koordinati uvjetovana je ponajviše sposobnošću operatera, odnosno preciznošću fiksiranja pločice pomoću pomične metalne stope koja se nalazi na postolju. Ako pločica između intervalnih mjerenja nije dobro fiksirana, uzorak (piksel) na njoj se neće nalaziti na istoj X i Y lokaciji unutar LCS-a. Utvrđeno je nešto lošije fiksiranje pločice prema X (0,070) u odnosu na Y koordinatu (0,023). Odstupanje uzorka od srednjaka prema Z koordinati primarno je uvjetovana preciznošću postavljanja LCS-a koji se pomoću digitalnog šublera uvijek postavlja na istu visinu. Ako je u jednom mjerenju LCS-a postavljen na različitu visinu u odnosu na prethodna, vrijednosti Z koordinate na označenim uzorcima će se razlikovati, te će se mjere SD-a i MAE-a povećati. Vrijednosti SD-a su sukladno pravilima veće od MAE vrijednosti, ali također padaju ispod desetinke milimetra. Za X, Y i Z koordinatu iznose 0,094, 0,028 i 0,075 mm. Parametar relativne nesigurnosti na X, Y i Z iznosi

0,664, 0,162 te 2,198%. Za razliku od dvije prethodne metrike, relativna nesigurnost je najveća za Z koordinatu. Razlog tome je specifičnost procesa izračuna relativne nesigurnosti. Iako uzorak može imati jednak raspon mjerenja (npr. 0,124 mm) za X i Z koordinatu, relativna nesigurnost će biti veća za Z koordinatu zato što ona ima manju vrijednost srednjaka (npr. visina uzorka iznosi 7,26 mm) u odnosu na X koordinatu (npr. uzorak se nalazi 35,23 mm sjeverno od ishodišne točke LCS-a). Potrebno je istaknuti da je testiranje kvalitete mjerenja izvršeno na praznim pločicama, kad je gornja ploha pločice minimalno izdignuta u odnosu LCS (na njoj nema formiranog precipitata). Nakupljanjem precipitata na gornjoj pločici, povećat će se srednja vrijednost Z koordinate specifičnih uzoraka što znači da bi relativna nesigurnost za Z koordinatu trebala opadati. Primjerice, ako na uzorku precipitira sedra te njena visina bude 13,24 mm iznad LCS-a, onda će, uzimajući u obzir raspon mjerenja od 0,124 mm, relativna nesigurnost za Z koordinatu iznositi 0,94%.

CMD je riješio sve probleme koji nastaju primjenom MEM-a u praćenju dinamike formiranja sedre. Omogućio je izvođenje visoko-rezolucijskih 2.5 i 3D modela površine sedre iz kojih se mogu generirati specifični morfometrijski parametri. Uzimajući u obzir odabrane postavke snimanja, koje se mogu prilagoditi potrebama korisnika, gustoća uzorkovanja CMD-a je bila preko 1,3 milijuna puta veća od gustoće uzorkovanja. Ovisno o potrebama korisnika gustoća uzorkovanja može biti manja ili veća. Nadalje, CMD ne dodiruje površinu sedre, što eliminira problem zbijanja i pojavu lažne erozije. Točnost i preciznost CMD-a je submilimetarska čime se eliminira problem velikih mjernih pogrešaka (0,53 mm) koje proizvodi MEM. Kvaliteta mjerenja CMD-om nije uvjetovana čvrstoćom precipitata kao kod MEM-a čija točnost mjerenja za različite (tvrđe ili mekše) tipove supstrata nije ispitana. Nadalje, CMD nije ograničen u mjerenju velikih ili manjih, tanjih ili debljih uzoraka sedre, potrebna je samo korekcija LCS-a te odabir novih parametara snimanja.

- **H3 (Selektivno uklanjanje vegetacije reaktivirat će sedrotvorne vodotokove)**.

Navedena hipoteza je **potvrđena**. Nekontrolirani rast invazivnih vegetacijskih oblika i antropogeni utjecati (izgradnja mostića, akumulacija šljunka) su prepoznati kao ključni problem koji je uzrokovao negativne hidrološke promjene i time ugrozio održive uvjete sedrenja na širem području Skradinskog buka. Bujan razvoj invazivne vegetacije uz neuklanjanje palih ostataka velikih biljnih fragmenata može u konačnici dovesti do zaraštanja sedrotvornih tokova i ugrožavanja statike sedrenih barijera. *Uprava Parka* je prepoznala navedene prijetnje je uz dozvolu *Ministarstva zaštite okoliša i energetike* pokusno dozvolila da se na odabranoj testnoj plohi ukloni invazivna vegetacija koja je agresivnošću smanjila

biološku raznolikost staništa te ublaže detektirani antropogeni utjecaji (uklanjanje šljunka). Uz invazivnu vegetaciju izvršeno je čišćenje drugih palih nezaštićenih oblika vegetacije koji su uzrokovali presušenje sedrotvornih tokova na odabranoj testnoj plohi. Tokovi su detektirani iz stare A-U karte, terenskim istraživanjem (ostatci mrtve sedre) te hidrološkim analizama iz visoko-rezolucijskog hibridnog LiDAR modela. Selektivno uklanjanje vegetacije na testnoj plohi je izvršeno u lipnju, 2017. Korištena je ručna i mehanička metoda uklanjanja vegetacije. S obzirom na slabu vertikalnu raščlanjenost plohe uklanjanje pajasena i manjih vegetacijskih oblika iz zaraštenih sedrotvornih tokova uzrokovalo je manje mikromorfološke promjene. Sve mikromorfološke i hidrološke promjene na plohi su kartirane. Pojačan protok vode uzrokovao je spiranje akumuliranog biljnog materijala što je za posljedicu imalo reaktivaciju starih presušenih tokova i manjih vodenih akumulacija. Jezera i novi tokovi su potom kartirani te su im dodani hidronimi.

Reaktivaciju sedrotvornih tokova potvrđuje nekoliko dokaza. Prvi je video snimljen nakon selektivnog uklanjanja vegetacije, uklanjanja nanesenog šljunka ispod mosta te puštanja vode prema testnoj plohi. Na njemu se jasno vidi kako voda protječe neaktivnim sedrotvornim tokovima u kojima se nalazi velika količina biljnih fragmenata koji se polagano ispiru. Nadalje, reaktivaciju dokazuju podaci o brzini protoka. Naime, na lokacijama mjerenja P1, P5, P6 i P7 prije selektivnog uklanjanja vegetacije nije bilo vode. Nakon reaktivacije tokova i postavljanja testnih pločica za praćenje dinamike sedrenja počela se pratiti brzina protoka vode. Rezultati su navedeni u poglavlju 4.*2.4 Brzina protoka vode na testnoj plohi*. Reaktivaciju sedrotvornih tokova dokazuju i rezultati stopa prirasta sedre. Naime, na svim pločicama koje su inicijalno postavljene u neaktivne tokove zabilježena je pojava precipitata u rasponu od (0,148-32,293 mm a^{-1}). Potrebno je istaknuti primjer kako neuklanjanje prirodno pale vegetacije može utjecati na promjenu hidrološke mreže. Naime, prilikom četvrtog skidanja pločica uočena je promjena smjera otjecanja voda u toku *Crni grab* koja je bila posljedica palog stabla smokve i akumuliranog biljnog materijala kojeg je nanio tok. Dio toka nizvodno od palog stabla je presušio te su pločice na lokaciji *Kod spomenika* ostale bez vode. To je rezultiralo manjim stopama prirasta sedre u odnosu na druge lokacije istog fluvijalnog okruženja te gotovo 13 puta većim prirastom u toplom u odnosu na hladno (bez vode) razdoblje. Ovaj primjer jasno prikazuje kako povećana koncentracija biljnog materijala, odnosno neodržavanje tokova (uklanjanje akumulirane vegetacije) može ugroziti održive uvjete sedrenja na nekim mikrolokacijama.

Gulin i dr. (2019) su utvrdili da u reaktiviranim kanalima zajednica perifitona ima veću raznolikost zbog niže konkurentnosti i grabežljivih stopa. Zaključeno je da reaktivirani kanali na odabranoj testnoj plohi predstavljaju povoljna staništa za kolonizaciju mikrofaune.

- **H4 (U razdoblju od godine dana na postavljenim pločicama zabilježit će se maksimalna stopa prirasta sedre veća od 15 mm).**

Navedena hipoteza je **potvrđena**. U radu je, uvažavajući vrijednosti maksimalnog prirasta na sedrotvornim područjima koja se nalaze u sličnim klimatskim područjima NP Krka, odlučeno da kao pretpostavka maksimalnog prirasta bude vrijednost od 1,5 cm a^{-1}. Na prostoru središnje Španjolske Arenas i dr. (2014) utvrđuju maksimalnu stopu prirasta od 1,653 cm a^{-1}, a Vazquez-Urbez i dr. (2010) bilježe 1,745 cm/god a^{-1}. U rezultatima stopa prirasta sedre prema specifičnostima fluvijalnog okruženja postoji značajna varijabilnost. U RH neki autori spominju slične vrijednosti. Tako, Srdoč i dr. (1985) navode da prirast sedre na Kozjaku iznosi oko 1,5 cm a^{-1}, Rubinić i dr. (2017) ističu da sedra u rijeci Krki raste od 1 do 3 cm a^{-1}, dok Zwicker i Rubinić (2004) spominju vrijednosti od 1,35 cm a^{-1} za Prošćansko jezero. S druge strane Bonacci i dr. (2017) ističu mogućnosti porasta sedrenih barijera na Skradinskom buku u prosjeku od tek 1,6 mm a^{-1}. Zwicker i Rubinić (2004) utvrđuju da je prirast sedre na jezeru Kozjak 0,56 cm a^{-1}.

Stope prirasta sedre na postavljenim pločicama se značajno razlikuju. Prosječan prirast sedre po pločici iznosi (5,741 mm a^{-1}), a prema lokaciji (5,771 mm a-^{1}). Raspon stopa prirasta u reaktiviranom sedrotvornom sustavu prema lokacijama iznosi 18,97 mm a^{-1}, a prema pločicama 32,145 mm a^{-1}. Na svim pločicama izuzev PL07 koja se nalazi na lokaciji *Pačji slap* izmjerena je manja stopa prirasta sedre od 15 mm a^{-1}. Dakle, samo na jednoj od 28 postavljenih pločica je zabilježena stopa prirasta sedra veća od 15 mm a^{-1}. Maksimalna stopa prirasta sedre izmjerena na PL07 iznosi čak 32,293 mm a^{-1}, dok prosječna stopa prirasta na lokaciji *Pačji slap* iznosi 19,302 mm a^{-1}. Kroz jednogodišnje razdoblje praćenja dinamike formiranja sedre najveća zabilježena stopa prirasta za bilo koji uzorak na mjernoj plohi neke pločice između dva uzastopna mjerenja iznosi 45,492 mm a^{-1} (PL07). Veliko odstupanje u odnosu na prosječan prirast sedre po pločicama nije iznenađujući te je posljedica specifičnih mikro-lokacijskih uvjeta PL07 koji su detaljno objašnjeni u poglavlju *4.3.4.1.*

Velika promjenjivost stopa prirasta sedre po pločicama je očekivana, a posljedica je različitih obilježja fluvijalnih okruženja u koje su pločice postavljenje, specifičnih mikrolokacijskih uvjeta pojedinih pločica (npr. blizina mahovina, zadržavanje i inkrustacija lišća i grančica) te plana snimanja pločica (frekvencija vađenja pločica iz toka). Važnost specifičnih mikrolokacijskih uvjeta može se uočiti ako se usporede stope prirasta sedre između

susjednih pločica na istim lokacijama. Prosječna apsolutna razlika u stopi prirasta sedre između susjednih pločica iznosi čak 2,217 mm a^{-1}, dok je relativna razlika 17,09%. Najmanja relativna razlika zabilježena je na lokaciji *Kod mladog jasena* (0,594%), dok je najveća na lokaciji *Pačji slap* (80,454 %). Međutim, sve lokacije, izuzev *Pačjeg slapa* i *Krivog stabla*, imaju apsolutnu razliku <1 mm a^{-1}. Razlika od 1,642 mm a^{-1} kod *Krivog stabla* nastala je zbog zadržavanja i inkrustacije lista na mjernoj površini PL15. Razlika od čak od 25,981 mm a^{-1} na lokaciji *Pačji slap* je uvjetovana obilježjima mikrolokacije pločice, točnije, blizine mahovine koja je u potpunosti prerasla mjernu površinu PL07.

U usporedbi sa stopama prirasta sedre u svijetu rezultati u NP Krka su najsličniji autorima Arenas i dr. (2014), Arenas i dr. (2010), Auqué i dr. (2013), Auqué i dr. (2014) te Vázquez-Urbez i dr. (2010), Drysdale i Gillieson, (1997). To ne čudi s obzirom na to da je praćena dinamika formiranja iste vrsta precipitata (sedra), na većem broju površinski sličnih uzoraka (vapnenačke testne pločice) u različitim fluvijalnim okruženjima te u klimatski sličnom području svijeta. U kontekstu globalnih aktivnih sedrotvornih sustava vrijednost srednje stope prirasta sedre je niža od prostora središnje Španjolske (Arenas i dr., 2010, Arenas i dr., 2014, Vázquez-Urbez i dr., 2010) te viša od prostora sjeverozapadne Australije (Drysdale i Gillieson, 1997).

- **H5 (Stopa prirasta sedre bit će veća u hladnijem u odnosu na toplije razdoblje)**

Navedena hipoteza je **odbačena**. Postavljena hipoteza je suprotna onome što se smatra kao dominantan trend i što je uočeno u većini fluvijalnih sedrotvornih sustava. Generalno gledano precipitacija sedre je izraženija u toplijim klimatskim uvjetima (Drysdale i Gillieson 1997, Kano i dr., 2007). Snažan sezonski uzorak sedrenja izrazitiji u toplijim razdobljima navodi velik broj autora (Arenas i dr., 2014, Auqué i dr., 2014, Arenas i dr., 2010, Kano i dr., 2003, Kawai i dr., 2006, Merz-Preiß i Riding, 1999, Vázquez-Urbez i dr., 2010). U recentnom istraživanju na prostoru Skradinskog buka i Roškog slapa Matoničkin Kepčija i dr. (2017) navode da su tijekom ljeta na prostoru Skradinskog buka i Roškog slapa zabilježeno do pet puta veće količine sedre u ostalu na ostala godišnja doba. Ipak, gore navedena hipoteza je postavljena zbog dva razloga. Usprkos spomenutom trendu, u nekim sedrotvornim sustavima precipitacija je ipak veća u hladnijim nego toplijim razdobljima (Auqué i dr., 2013) zbog izrazito slabijeg protoka voda ljeti (presušivanje tokova, slabo mehaničko otpuštanje CO_2). S obzirom na to da područje rijeke Krke obilježava velika vlažnost i plavljenje tijekom zime, a česta oskudica vode ljeti (Šandrić, 2016) pretpostavilo se da će brzina sedrenja biti veća u hladnijem razdoblju. Naime, zabilježeno je da uzorci sedre koji su podvrgnuti sušnim

periodima u toplijim razdobljima bilježe vrlo niske ili čak negativne stope sedimentacije (Auqué i dr., 2013) te su podložnije eroziji.

Nadalje, dinamika sedrenja je proučavana u jednogodišnjem razdoblju u intervalnim mjerenjima u razmaku od tri i šest mjeseci. Većina pločica je vađena i snimana s intervalom od šest mjeseci. Prvi period vađenja koji se naziva *kolonizacijska faza* odnosio se na toplo razdoblje odnosno razdoblje od ožujka do rujna 2018. U tom razdoblju dolazi do inicijalne kolonizacije površine pločice s ličinkama vodenih insekata i mikroflorom. U pravilu stopa prirasta sedre bi trebala biti niža za vrijeme kolonizacijskog, u ovom slučaju toplog (ožujak-rujan, 2018), u odnosu na druga razdoblja mjerenja (rujan, 2018 - ožujak, 2019). S obzirom na to da se u ovom slučaju kolonizacijska faza podudara s toplim razdobljem pretpostavilo se da će stope sedrenja biti veće u drugoj fazi koja odgovara hladnom razdoblju.

U prosjeku je na svih 28 pločica zabilježen 1,55 puta veći prirast sedre u toplijem (ožujak, 2018 - rujan, 2018) (3,173 mm a^{-1}) u odnosu na hladnije razdoblje (rujan, 2018. - ožujak, 2019) (2,046 mm a^{-1}). Navedeno je značajka većine aktivnih sedrotvornih sustava s obzirom na to da visoke temperature pogoduju otplinjavanju CO_2, čime se povećava zasićenost vode otopljenim $CaCO_3$ (Špoljar i dr., 2011) te potiče razvoj i ubrzava metabolizam sedrotvornih mikroorganizama (Vazquez-Urbez i dr., 2010, Auqué i dr., 2014). Potrebno je istaknuti da ne postoji univerzalni zajednički sezonski trend prirasta sedre za sve testne pločice te je varijabilnost rezultata izrazito velika. Na pločicama PL06 (*U bršljanu*), PL29 (*Nježna mahovina*) i PL23 *(Sedreni zid*) zabilježen je veći prirast sedre u hladnom razdoblju za 0,299, 0,992 i 1,95 mm a^{-1}. Navedene PLs bilježe veću stopu sedrenja u hladnom razdoblju za 1,14, 1,94 i 1,42 puta u odnosu na toplo razdoblje. To ukazuje na važnost obilježja mikro-lokacije (npr. protok i dubina vode, blizina mahovine ili algi, osvjetljenje, nagib pločice u odnosu na tok) koji su specifični za svaku pločicu (Gradziński, 2010) i u konačnici određuju stopu prirasta sedre. Iznimke od sezonskih uzoraka nisu iznenađujuće (Arenas i dr., 2014, Gradziński, 2010).

Na ostalim pločicama stopa prirasta sedre u toplijem u odnosu na hladno razdoblje je veća od 1,04 (PL18) do čak 13,54 (PL24). Zabilježen ekstrem na PL24 je rezultat presušenja toka koje se dogodilo u hladnom razdoblju zbog čega je proces precipitacije prestao, odnosno izloženost pločice toku bio prekinut (vidi *poglavlje 4.3.1*). Ova pojava ukazuje kako mikrolokacijski uvjeti (presušivanje toka, zadržavanje i inkrustacija biljnih fragmenata), koji ne moraju uvijek biti uočeni, mogu utjecati na dinamiku formiranja sedrenja, a time i na interpretaciju samih rezultata. Nadalje, nije detektiran slučaj, kao u drugim istraživanjima (Arenas i dr., 2014), da je u hladnom razdoblju došlo do opadanja srednje visine sedre unutar mjerne površine pločice.

- **H6 (Učinak erozije bit će zabilježen na pločicama snimljenim u intervalnim razmacima).**

Navedena hipoteza je **potvrđena**. Erozivne pojave na površini sedre uočene su u većini istraživanja dinamike formiranja sedre. Razlozi tome mogu biti intenzivan protok uslijed pojačanih oborina, sušna razdoblja za vrijeme ljeta, ljudski čimbenik, interval snimanja umjetnih podloga koji se poklapa s fazom gubitka perifitona uslijed emigracija ili intenzivnije ispaše itd. Erozija je analizirana na svim pločicama koje su iz svojih protoka vađene i snimane intervalno u razmaku od tri ili šest mjeseci.

Količina erodiranog materijala u tromjesečnom i šestomjesečnom razdoblju varira od 0,003 mm^3 do 305,539 mm^3. Na samo dvije (interval vađenja 6 mjeseci) od dvanaest pločica erozivni događaji nisu detektirani. Na njima nije došlo do erozije zbog zadržavanja i inkrustacije lista na mjernoj površini pločica, što je utjecalo na povećanje nukleacijske površine za precipitaciju te izrazitog volumetrijskog prirasta sedre. Na pločicama koje su mjerene u tromjesečnim intervalima očekivano je zabilježena veća količina erodiranog materijala i veći intenzitet erozije. Naime, veći interval snimanja (3 mjeseca) znači da postoji manje vremena da se erozivni događaji naknadnim taloženjem popune. Usprkos činjenici da su na 10 od 12 pločica detektirani erozivni događaji ipak se može zaključiti da precipitirana sedra nije pokazala izrazitu sklonost eroziji u promatranim razdobljima. Međutim, potrebno je istaknuti da su se u slučaju pojave erozivnog događaja tromjesečni i šestomjesečni intervali pokazali kao prekratka razdoblja za potpuno popunjavanje mjesta erozije naknadnim taloženjem sedre.

Nadalje, utvrđeno je da podložnost eroziji ovisi o vrsti fluvijalnog okruženja kojem je pločica izložena, strukturnim obilježjima precipitirane sedre te intervalu snimanja. Primjerice, najveća količina erodiranog materijala zabilježena je na lokaciji *Pačji slap* (PL25) gdje je volumen erodiranog materijala u razdoblju rujan 2018. - prosinac 2018. iznosio 33,305% volumetrijskog prirasta sedre u istom razdoblju. Na njoj je zabilježen najveći intenzitet erozije što je posljedica specifičnosti površine supstrata, na kojoj su u rujnu, 2018. dominirale veće količine suhih biljnih fragmenata te ličinki makrozoobentosa koje nisu u potpunosti učvršćene u podlogu. Prema prosincu, odnosno sljedećem datumu intervalnog snimanja, brzina protoka vode na toj lokaciji je jačala. U jednom trenutku, s obzirom na to da suhi biljni fragmenti nisu bili u potpunosti pričvršćeni za podlogu došlo je do odnošenja materijala. Upravo je na PL25 izmjerena najveća zabilježena erozija za bilo koji uzorak na mjernoj plohi. Iznosila je 4,753 mm a^{-1} (PL25) u razdoblju rujan 2018, - prosinac, 2019. Razlog tome je specifičnost strukture precipitata. Arenas i dr. (2014) navode da je porozna sedra s velikim udjelom biljnih fragmenata te algi i mahovina podložnija eroziji od stromatolitne sedre (izražena laminacija)

koja nastaje u fluvijalnom okruženju brzog protoka. Nadalje, značajniji erozivni događaji izmjereni su na lokaciji *Tvrda sedra* (PL13) u razdoblju lipnja - rujan, 2018. gdje je volumen erodiranog materijala iznosio 10,43% volumetrijskog prirasta sedre u istom razdoblju. Naime, na inicijalnom modelu (lipanj, 2018) je uočeno preko 600 različito položenih, cjevastih kalcitnih tijela koja nisu dobro pričvršćena za supstrat. Dakle, na onim lokacijama gdje nakupine mikroorganizama nisu bile dobro učvršćene erozivni događaj je detektiran zbog djelovanja toka (FFW). To je za posljedicu imalo generiranje najveće erozijske površine koja se nije uspjela popuniti sve do ožujka 2019 godine. Slična pojava je utvrđena na PL03, 18, 22, 23, 24, 27 i 29 koje su vađene iz svojih tokova u šestomjesečnom razmaku (rujan, 2018. - ožujak, 2019). Na navedenim pločicama sedra nije stigla precipitirati dovoljno brzo, točnije u intervalu od šest mjeseci nije u potpunosti popunila mjesta erozije naknadnim taloženjem. Ipak, izuzev PL22, čiji je erozivni događaj objašnjen u nastavku teksta, postotak erodiranog materijala na ostalim pločicama ne prelazi 2,533% (PL24) volumetrijskog prirasta u tom razdoblju.

Nadalje, potrebno je istaknuti potencijalni ljudski čimbenik koji može utjecati na pojavu erozivnih događaja. Na lokaciji *Jezero 6 stabala* (PL22) u šestomjesečnom razdoblju je erodiralo 18,317 mm^3, odnosno 17,823% volumetrijskog prirasta sedre u tom razdoblju. Međutim, to nije bila posljedica obilježja fluvijalnog okruženja (SW) već laganog ispiranja pločice provođenog sa svrhom uklanjanja površinskog blata koje ne predstavlja formirani precipitat (sedru), a nataložilo se za vrijeme izloženosti. S obzirom na to da sediment na mjernoj površini nije bio učvršćen vrlo je vjerojatno da je erozija dijelom rezultat procesa ispiranja na što ukazuje raspršenost erozivnih lokacija. Usprkos relativno velikom postotku erodiranog materijala u odnosu na druge pločice na ovoj pločici je zabilježen jedan od najnižih intenziteta erozije sedre.

U prethodnom poglavlju je navedeno da je u prosjeku za sve pločice stopa prirasta sedre u toplom razdoblju bila veća za 1,55 puta u odnosu na hladno razdoblje. Međutim, od tog sezonskog uzorka odstupaju PL06, 23 i 09. Arenas i dr. (2014) navode da značajniji erozivni događaji mogu biti uzrok preokreta sezonskog uzorka stopa prirasta. Odnosno u ovom slučaju, da su značajniji erozivni događaji u toplom razdoblju mogli biti uzrok preokreta sezonskog uzorka stopa taloženja. Zbog jednogodišnjeg razdoblja promatranja navedena hipoteza se mogla provjeriti samo za slučaj PL06. Utvrđeno je da u ovom slučaju značajniji erozivni događaji u toplom razdoblju nisu bili uzrok preokreta sezonskog uzorka stopa taloženja. Naime, na njoj u tromjesečnom razdoblju toplijeg perioda (lipanj - rujan, 2018) nije zabilježena erozija, dok je u tromjesečnom razdoblju hladnijeg perioda (rujan - prosinac, 2018) zabilježena

(20,453 mm^3). Dakle, usprkos činjenici da u toplom razdoblju erozija nije detektirana, a u hladnom jest, prirast sedre je ipak bio veći u hladnom razdoblju. Stoga, zabilježeni erozivni događaji na PL06 nisu mogli utjecati na preokret sezonskog uzorka stopa taloženja. Nadalje, potrebno je istaknuti zanimljiv slučaj erozije zajednica makrozoobentosa (*Simuliidae* i *Chironomidae* red: Diptera) detektiran na PL06 i 25 u razdoblju rujan, - prosinac 2018).

Prosječna erozija na pločicama koje su imale veću frekvenciju snimanja u razdoblju od rujna, 2018. do ožujka 2019. bila je 32,483 mm^3. Na pločicama s manjom frekvencijom snimanja u istom razdoblju zabilježena je erozija od prosječno 16,391 mm^3. Pločice s manjom frekvencijom snimanja u navedenom razdoblju su u prosjeku imale 16560,3 mm^3 volumetrijskog prirasta, dok su one s većom frekvencijom imale 6958,2 mm^3. Veća frekvencija vađenja i snimanja pločica može inhibirati rast sedre, odnosno povećati podložnost eroziji. Vađenjem pločica iz toka, njihovim sušenjem i snimanjem dolazi do prekidanja ciklusa naseljavanja pločica od strane sedrotvoraca (primjer PL06), prekida se proces precipitacije, sedra postaje krhka te prilikom vraćanju u tok podložnija eroziji.

- **H7 (Stopa prirasta sedre bit će veća u fluvijalnim okruženjima bržeg protoka i turbulencije vode)**

Navedena hipoteza je **potvrđena**. Usporedba stopa prirasta sedre između različitih fluvijalnih okruženja je moguća jer je terenskim obilascima te intervalnim mjerenjima brzine protoka za sedam odabranih lokacija utvrđeno da su pločice u proučavanom razdoblju, izuzev lokacije *Kod spomenika*, bile izložene relativno stabilnim hidrauličnim uvjetima. Dakle, fluvijalna obilježja lokacija nisu se značajnije mijenjala nakon inicijalnog postavljanja pločica. Stopa prirasta sedre u klasificiranim fluvijalnim okruženjima znatno varira.

Prema definiranoj klasifikaciji fluvijalnog okruženja raspon stopa prirasta sedre je iznosio čak 11,112 mm a^{-1}. Najveća stopa je izmjerena u brzoj i turbulentnoj vodi blizu mahovina (značajnije mehaničko otpuštanje CO_2) kaskadnih slapova, dok je najnižu stopu prirasta imalo fluvijalno okruženje spore i stagnantne vode. Inače, ovo je karakteristika većine aktivnih sedrotvornih sustava (Arenas i dr., 2014, Arenas i dr., 2010; Auqué i dr., 2014, Auqué i dr., 2013, Bono i dr., 2001, Drysdale i Gillieson 1997; Gradziński, 2010, Lu, i dr., 2000, Liu, 2017, Liu i dr., 1995, Vázquez-Urbez i dr., 2010; Zhang i dr., 2012). To se može objasniti manjom debljinom granice sloja difuzije koji olakšava migraciju iona prema rastućim kristalima (Gradziński, 2010, Liu i idr., 1995) te većom površinom granice zrak-voda (Chen i dr., 2004). Činjenica da je stopa prirasta sedre bila veća na lokacijama kaskadnih slapova u blizini mahovine (SC) nego na lokaciji brzo protočne i turbulentne vode (FFW) može se

objasniti kroz sljedeće postavke. Visoko-energetski protok može uzrokovati stres pa čak i spriječiti mikroorganizme od koloniziranja površine testnih ploča (Gradziński, 2010). Naime, brzina protoka veća od 80 cm/s može uzrokovati uklanjanje algijskog perifitona i privremeno smanjenu biomasu (Horner i dr., 1990). Ova pojava je uočena i izmjerena na PL26, 13 i 06. Nadalje, PL07 i 14 koji su postavljene u blizini mahovine zabilježile su veće stope prirasta sedre od njihovih susjednih pločica (PL25 i 29) za 25,98 i 0,43 mm a^{-1}. Mjerne plohe PL07 i 14 su potpuno prerasle s mahovinama koje su povećale efektivnu nukleacijsku površinu precipitacije (Gradziński, 2010). Utjecaj mahovina u procesu precipitacije ističu Weijermars i dr. (1986) navodeći da one mogu formirati spužvaste slojeve s maksimalnom stopom prirasta od 11 do 14 cm a^{-1}. S obzirom na sve navedeno najviša stopa prirasta sedre na lokacijama kaskadnih slapova u blizini mahovine nije iznenađujuća. Osim fluvijalnih uvjeta (turbulencija i brzina protoka) i fizikalno-kemijskih parametara vode, fizički učinci mahovina i drugih mikroorganizama mogu također značajno utjecati na stopu prirasta sedre.

Precipitacija sedre u reaktiviranom sedrotvornom sustavu posljedica je primarno anorganskog otpuštanja CO_2, odnosno njegovog mehaničkog otpuštanja uslijed zagrijavanja i povećane turbulencije vode. Nije uočeno značajno sezonsko ni dnevno osciliranje vrijednosti pH iz čega se posredno može zaključiti da ne postoji izraženija kemijska uloga vodenih biljaka u uklanjanju CO_2 fotosintetskim procesima. Nepostojanje jasnih dnevnih promjena pH ukazuje na to da fotosintetski unos, za koje se očekuje da će pH povećati u podne (Merz-Preiß i Riding, 1999) ima malo utjecaja na precipitaciju u ovim tokovima iako je lokacija multiparametarske sonde bogata s vodenom vegetacijom.

- **H8 (Stopa prirasta sedre će biti veća na lokacijama šireg prostora Skradinskog buka u odnosu na lokacije na Roškom slapu).**

Navedena hipoteza je **potvrđena**. Prema planu vađenja i snimanja desne pločice na svakoj lokaciji RS-a (n=4) je trebalo izvaditi nakon šest mjeseci izloženosti toku. Navedenu aktivnost nije bilo moguće provesti uslijed iznimno velikog vodostaja i brzine protoka što je moglo ugroziti sigurnost osobe koja bi pločice vadila. S ciljem okvirne usporedbe stopa prirasta sedre između testne plohe RS-a i SB-a izvađene su samo one pločice (PL30, 31 i 43) kojima se moglo pristupiti bez ugrožavanja sigurnosti operatora. Od tri izvađene pločice sedra je detektirana samo na PL30 i 43 (*Kod mlinice*) koje su smještene u fluvijalnom okruženju koje je najsličnije lokacijama zone prskanja (SZ) na testnoj plohi SB-a. Na PL41 postavljenoj na lokaciji *Slomljeno svrdlo*, koja je najsličnija fluvijalnom okruženju FFW, sedra nije

detektirana. Rezultati izmjere na njoj spadaju u nesigurnost mjerenja. Na njenoj mjernoj plohi detektirane su male nakupine modrozelenih algi. Ova lokacija je prema fluvijalnim obilježjima slična ostalim lokacijama na RS-u (*Konoplja među smokvama* i *Ćelava ogrlica*) s kojih pločice nisu vađene te je reprezentativni primjer biohidroloških uvjeta na Roškom slapu. Karakterizira ih velika brzina protoka, nema značajnije turbulencije na pločicama, a dubina na kojoj se nalaze izrazito varira ovisno o vodostaju. U njihovoj neposrednoj blizini nalaze se različite vrste mahovina i algi čija se dominacija mijenja ovisno o temperaturi vode i brzini strujanja. Za očekivati je stoga da u budućim mjerenjima sedra neće biti detektirana na lokacijama *Konoplje među smokvama* i *Ćelavoj ogrlici*.

Ipak, na lokaciji *Kraj Mlinice,* klasificiranoj kao SZ, utvrđen je prosječan prirast sedre od 0,408 mm u šestomjesečnom razdoblju. Na PL43, koja je izloženija prskanju vode, stopa prirasta je iznosila 0,571 mm, a na PL30 tek 0,244 mm. S druge strane, na testnoj plohi SB-a, prosječna stopa prirasta (lokacije *Sedreni kanjon* i *Jezerski slapić*), za isti tip fluvijalnog okruženja, iznosila je 4,268 mm u jednogodišnjem razdoblju promatranja. Na navedenim lokacijama PL27 (*Sedreni kanjon*) i PL18 (*Jezerski slapić*) su vađene i snimane u intervalu od šest mjeseci. Na njima je u šestomjesečnom razdoblju izloženosti toku zabilježena stopa prirasta od 4,042 mm te 1,734 mm. U oba slučaja stope prirasta sedre su očekivano nekoliko puta veće u odnosu na prostor RS-a.

Postavljena hipoteza se podudara s obilježjima većine aktivnih sedrotvornih sustava (Drysdale i dr., 2002, Auqué i dr., 2013). Očekivani tip razvoja sedrotvornog sustava je onaj u kojem se intenzivnije sedrenje bilježi u nizvodnom dijelu vodenog sustava uslijed većeg oslobađanja CO_2, viših vrijednosti pH-a, povišenih temperatura, bržeg metabolizma organizama itd. Ovi rezultati odstupaju od recentnog istraživanja Matoničkin Kepčija i dr. (2017) gdje je primijenjena metoda masenog prirasta te izmjerena 10 puta veća količine sedre na lokaciji RS-a u odnosu na lokaciju SB-a. Usprkos činjenici da zbog propisanog radnog plana projektom GAL te vremenskih (ne)prilika vrijeme postavljanja i mjerenja između lokacija RS-a i SB-a nije bilo usklađeno izmjerene stope prirasta sedre su pružile generalnu sliku dinamike sedrenja s obzirom na lokaciju (uzvodno, nizvodno) pločica u vodenom sustavu.

6. ZAKLJUČAK

U disertaciji je predložena višerezolucijska struktura metoda i alata za upravljanje osjetljivim i zaštićenim sedrotvornim sustavima s osnovnim ciljem postizanja i očuvanja održivih uvjeta sedrenja. Poseban naglasak u predloženom modelu je stavljen na novi metodološki pristup beskontaktnog intervalnog praćenja dinamike sedrenja utemeljenog na metodi makrofotogrametrije. Izrada višekriterijskog modela održivog upravljanja sedrotvornih vodotokova podrazumijevala je provođenje širokog spektra aktivnosti ovisno o razini istraživanja. S obzirom na to da se radi o pokusnim mjerama zaštite temeljnog fenomena Parka, koji dosad nisu primijenjeni u drugim zaštićenim područjima, njihova učinkovitost je ispitana na manjoj testnoj plohi. Manja testna ploha (0,8 ha) unutar šireg područja SB-a detektirana ja na makro razini istraživanja primjenom GIS-MCDA, terenskim istraživanjima te na temelju podataka izvedenih iz starog kartografskog izvornika.

Na mezo razini istraživanja izvršeno je kartiranje vegetacije i mreže površinskog otjecanja, odnosno aktivnih i presušenih sedrotvornih vodotokova. Provedeno je selektivno uklanjanje invazivne vegetacije koje je rezultiralo mikromorfološkim i hidrološkim promjenama. Kombinacija intenzivnih oborina i pojačanog protoka vode dovela je do ispiranja biljnog materijala i aktiviranja presušenih tokova vidljivih na starim kartografskim izvornicima. Hidrološke promjene (reaktivacija presušenih tokova i jezera) su nanovo kartirane. U nastavku istraživanja uspostavljen je sustav praćenja stanja sedrotvornog okoliša koji se sastojao od četiri sastavnice. Prva se odnosi na praćenje dinamike formiranja sedre na vapnenačkim pločicama. Ona obuhvaća morfometrijske parametre koji se odnose na linearni ($mm\ a^{-1}$) i volumetrijski (mm^3) prirast te eroziju sedre. Druga sastavnica (hidrološki parametar) obuhvaća sustavno praćenje brzine protoka (m/s) vode u aktivnim i reaktiviranim sedrotvornim tokovima. Treća se odnosi na intervalno mjerenje ključnih fizikalno-kemijskih parametara vode (temperatura vode, DO, pH, itd.). Posljednja, četvrta sastavnica (vegetacijski parametar) obuhvaća praćenje bioraznolikosti na testnoj plohi, odnosno pojavu i razvoj invazivne vegetacije metodom cikličnog fotografiranja. Nakon ručnog i mehaničkog uklanjanja pajasen se nije obnovio na testnoj plohi. Razlog tome je povremeno poplavljivanja većih površina uslijed pojačanog dotoka vode. Takvo okruženje ne pogoduje pajasenu te učinkovito sprječava njegovu obnovu.

Poželjno je da cjelovit sustav praćenja sedrotvornog okoliša uključuje još tri sastavnice. Peta sastavnica (biološki parametar) bi uključivala praćenje dinamike kolonizacije mikrofaune, odnosno analizu zajednice perifitona. Šesta (klimatološki kriterij) bi se odnosila na mjerenje

intenziteta osunčanosti svake lokacije na kojoj se prati dinamika formiranja sedre, dok bi sedma sastavnica uključivala izotopne analize novoformiranih sedrenih uzoraka. U ovom potpunom sustavu praćenja stanja sedrotvornog okoliša poželjno bi bilo da se mjerenje svih parametara vrši na istim X, Y i Z lokacijama. Drugim riječima, svaka lokacija (n=14) na kojoj se prati dinamika formiranja sedre trebala bi imati zasebne podatke o brzini protoka voda, fizikalno-kemijskim parametrima, osunčanosti, perifitona itd. Navedeno bi omogućilo razvoj točnih predikcijskih modela dinamike formiranja sedre te identificiralo ključne kriterije koji utječu na taj proces.

Na mikro razini istraživanja praćena je dinamika formiranja sedre na testnim pločicama postavljenima u različita fluvijalna okruženja. Stope prirasta i erozije sedre su po prvi put mjerene pomoću uređaja (CMD) koji se temelji na metodi makrofotogrametrije. Primjenom CMD-a eliminirani su svi nedostatci modificiranog mikro-erozijskog metra (MEM) te su uklonjeni problemi karakteristični za proces blizupredmetne fotogrametrije. CMD omogućuje izradu DTHRM-a na temelju kojih se submilimetarski točno i precizno mogu mjeriti stope prirasta i erozije sedre ili nekog drugog precipitata. CMD je precizna, točna i beskontaktna metoda koja ne proizvodi problem kompakcije, odnosno pojavu lažne erozije te ne generira velike pogreške pri mjerenju supstrata mekših površina. Primjenom CMD-a uklonila se mogućnosti oštećenja površinskog sloja sedre. Uređaj nema logističkih ograničenja kao MEM. Prilagodbom LCS-a te postavki snimanja mogu se mjeriti uzorci sedre različitih veličina. Uređaj proizvodi izrazito gusti oblak točaka na temelju kojih se mogu generirati različitih morfometrijski parametri. Gustoća uzoraka i prostorna rezolucija modela se prilagođava potrebama operatora. Na mehanički okvir uređaja mogu se instalirati multispektralne i hiperspektralne kamere s ciljem proučavanja sadržaja klorofila na površini sedre. Njihova primjena može pomoći u razlikovanju površina kalcita i mahovina s ciljem kvantificiranja nesigurnosti prilikom mjerenja stopa prirasta sedre. Nadalje, za razliku od MEM-a, CMD omogućava izvođenje visoko-rezolucijskih DOF-ova na temelju kojih je moguće identificirati i klasificirati jedinke makrozoobentosa. CMD se može primjenjivati u svim istraživanjima koja zahtijevaju submilimetarsku točnost i preciznost, intervalno mjerenje i usporedbu modela te izvođenje specifičnih morfometrijskih parametara manjih objekata.

Mjerenja dinamike formiranja sedre na 14 lokacija unutar odabrane testne plohe rezultirala su prosječnom stopom prirasta od 5,771 mm a^{-1}. Sedra je u prosjeku rasla 16,2 μm dnevno. Utvrđena je velika varijabilnost stopa prirasta sedre, što je posljedica različitih obilježja fluvijalnih okruženja, specifičnih mikrolokacijskih uvjeta te frekvencije snimanja pločica. Dinamika formiranja sedre odgovara karakteristikama većine aktivnih sedrotvornih

sustava. Stope prirasta sedre su veće na kaskadnim slapovima u blizini mahovina te u plitkoj, brzo protočnoj, turbulentnoj vodi. Najmanje stope prirasta sedre su u stagnantnoj i sporo protočnoj vodi. Više stope prirasta sedre su zabilježene u toplijem razdoblju, iako ne postoji jasni sezonski uzorak za sve pločice što naglašava važnost ostalih mikrolokacijskih parametara koji u konačnici reguliraju rast sedre. Utvrđeno je da biološka sastavnica (flora i fauna) kroz fizičku ulogu ima važnu ulogu u procesu formiranja sedre u reaktiviranom sedrotvornom sustavu. Naime, iz izvedenih visoko-rezolucijskih DOF-ova može se zaključiti da konstrukcije ličinki vodenih insekata, mikrofiti i makrofiti doprinose hvatanju minerala kalcita. Biološki materijal ima značajnu ulogu u inicijalizaciji novih sedrenih depozita, povećava akumulacijsku stopu te lokalnu mikro turbulenciju toka i gubitak CO_2. Međutim, time se istovremeno povećava primarna poroznost precipitata. Prepoznatljiva struktura novoformirane (na pločicama) i mrtve sedre (ostatci u suhozidima) na širem području Skradinskog buka mogu se povezati s kalcificiranom biološkom tvari. S druge strane, nepostojanje jasnih dnevnih i sezonskih promjena u pH vrijednostima ukazuje na to da fotosintetski unos, odnosno biološka uloga organizama, ima malo utjecaja na precipitaciju u reaktiviranim sedrotvornim tokovima. Nadalje, utvrđeno je da podložnost eroziji ovisi o vrsti fluvijalnog okruženja kojem je pločica izložena, strukturnim obilježjima precipitirane sedre te intervalu snimanja.

Provođenjem predloženog višekriterijskog modela održivog upravljanja ostvareni su ključni ciljevi iz akcijskih planova 7 i 8 sadržani u službenom dokumentu *Plana upravljanja NP „Krka“*. Na odabranoj testnoj plohi šireg područja SB-a spriječena je sukcesija invazivne makrovegetacije, reaktivirani su ugasli sedrotvorni tokovi te su u njima postignuti održivi uvjeti sedrenja. Očuvanje temeljnog fenoman Parka te postizanje održivih uvjeti sedrenja na odabranoj testnoj plohi potvrđeno je kroz: izmjerene stope prirasta sedre, brzinu protoka vode, fizikalno-kemijske parametre, pojavu sedrotvornih organizama te kroz izostanak obnove invazivne vegetacije nakon selektivnog uklanjanja vegetacije

Korisnici predloženog metodološkog okvira ove disertacije mogu biti nacionalne, regionalne i lokalne vlasti, kao i upravni odbori zaštićenih i ugroženih prirodnih područja. Rezultati dobiveni u ovom istraživanju mogu biti korisni znanstvenicima koji se bave proučavanjem dinamike formiranja sedre kroz različite aspekte. Izvedeni podaci poslužit će kao referentno stanje prilikom provođenja prostorno-vremenskih analiza u varijacijama stopa prirasta sedre.

SAŽETAK

Nacionalni park „Krka“ (NPK) je osjetljiv sustav podložan različitim vrstama vanjskih poremećaja. Na širem području Skradinskog buka (SB) uočene su negativne hidrološke promjene te prestanak procesa sedrenja na nekim lokacijama. Glavni uzroci prepoznati su u nekontroliranom rastu i širenju invazivne vegetacije, pojačanom antropogenom utjecaju te neuklanjanju nanesenih biljnih fragmenata na mjestima prirodnih prepreka. S ciljem rješavanja problema Uprava Parka je pokrenula projekt pod nazivom *Upravljanje i održavanje makrovegetacije na Skradinskom buku – izrada višekriterijskog modela održivog upravljanja*. Glavni cilj projekta je reaktivacija ugaslih sedrotvornih tokova, uklanjanje invazivne vegetacije te postizanje održivih uvjeta sedrenja na odabranoj testnoj plohi. Ostvaranje tog cilja uvjetovalo je provođene su brojnih aktivnosti i istraživanja među kojima su i ona dana u okviru ove doktorske disertacije.

Metodološki okvir istraživanja je podijeljen u tri razine. Makro razina istraživanja obuhvaća skup aktivnosti usmjerenih prema odabiru testne plohe unutar šireg područja SB-a. Mezo razina uključuje postavljanje sustava za praćenje stanja sedrotvornog okoliša te kartiranje referentnog i završnog stanja vegetacije i hidrološke mreže na testnoj plohi nakon uklanjanja invazivne vegetacije. Na mikro razini istraživanja proučavana je dinamika formiranja sedre primjenom novog metodološkog pristupa temeljnog na metodi makrofotogrametrije.

Provođenje predloženog višekriterijskog modela održivog upravljanja rezultiralo je ostvarenim ključnim ciljevima projekta. Na odabranoj testnoj plohi spriječena je sukcesija invazivne makrovegetacije, reaktivirani su ugasli sedrotvorni tokovi te su u njima postignuti održivi uvjeti sedrenja. Rezultati su potvrđeni kroz: izmjerene stope prirasta sedre, brzinu protoka vode, fizikalno-kemijske parametre, pojavu sedrotvornih organizama te izostanak obnove invazivne vegetacije.

Mjerenja dinamike formiranja sedre rezultirala su prosječnom stopom prirasta od 5,771 mm a^{-1}. Utvrđena je velika varijabilnost u stopama prirasta sedre, a dinamika formiranja sedre odgovara karakteristikama većine aktivnih sedrotvornih sustava. Novi metodološki pristup (CMD) omogućuje intervalno praćenje dinamike formiranja sedre te generiranje modela submilimetarske rezolucije i visokokvalitetne teksture.

CMD može biti primijenjen u svim istraživanjima koja zahtijevaju submilimetarsku kvalitetu podataka, usporedbu intervalnih 3D modela te izvođenje različitih morfometrijskih parametara manjeg objekta. Potencijalni korisnici izvedenog višekriterijskog modela održivog upravljanja mogu biti nacionalne, regionalne i lokalne vlasti te upravni odbori zaštićenih i ugroženih sedrotvornih područja.

Ključne riječi: dinamika formiranja sedre, održivo upravljanje, uređaj za koordinatnu mjernu makrofotogrametriju (CMD), modificirani mikro-erozijski metar (MEM), NP „Krka“

SUMMARY

The Krka National Park is a sensible system exposed to different sorts of external disorders. In the wider Skradinski buk area (SB) negative hydrological changes were noticed which lead to a reduction of tufa formation intensity. Major reasons were recognized in uncontrolled growth and the spreading of invasive vegetation, strengthened by anthropogenic impact and the lack of removal of deposited plant fragments in places of natural obstacles. With the aim of solving the problem, the administarion board has initiated the project entitled *Management and maintenance of macro-vegetation in Skradinski buk – making of a multi-criteria model of sustainable management*. The main goal of the project is a reactivation of extinct tufa formation flows, removal of invasive vegetation and achieving sustainable conditions of tufa formation at the selected test surface. Achieving this goal has led to the implementation of numerous activities and research, including those given in this doctoral dissertation.

The methodological framework of the research was divided into three levels. Macro level of the research encompasses a set of activities directed towards the selection of test surface within the wider SB area. Mezo level includes the installation of the system for tracking the condition of tufa-forming environment and mapping the referent and final condition of the vegetation and hydrological network on the test surface after the removal of invasive vegetation. At the micro level of the research, dynamics of tufa formation was studied by applying a new methodological approach based on the macro photogrammetry method.

Implementation of the proposed multi-criteria model of sustainable management resulted in the achievement of key goals of the project. At the selected test surface, the succession of invasive macro vegetation was prevented, extinct tufa formation flows were reactivated and sustainable conditions of tufa formation were achieved within them. Results were confirmed by measured tufa growth rates, speed of water flow, physical-chemical parameters, the emergence of tufa-forming organisms, lack of invasive vegetation renewal and the dynamics of microfauna colonization.

Measurements of the tufa formation dynamics resulted in an average growth rate of 5,771 mm a^{-1}. Large variability in tufa growth rates was determined and the dynamics of tufa formation matches characteristics of most of the active tufa-forming systems. The new methodological approach (CMD) enables interval tracking of tufa-forming dynamics and generation of the model of submillimeter resolution and high-quality texture.

CMD can be applied in all studies which requires submillimeter data quality, comparison of interval 3D models and implementation of different morphometric parameters of a smaller object. Potential users of implemented multi-criteria model of sustainable management can be national, regional and local authorities and boards of directors of protected and endangered tufa-forming areas.

Keywords: dynamics of tufa formation, sustainable managment, coordinate measuring macrophotogrammetry device (CMD), modified micro-erosion meter (MEM), Krka National Park, Croatia.

LITERATURA

Agisoft PhotoScan, (2019): Agisoft PhotoScan - Tips and Tricks, dostupno na: http://www.agisoft.ru/w/index.php?title=PhotoScan/Tips_and_Tricks, srpanj, 2019.

Aguilar, F, J., Agüera, F., Aguilar, M. A., Carvajal, F. (2005): Effects of terrain morphology, sampling density, and interpolation methods on grid DEM accuracy, *Photogrammetric Engineering & Remote Sensing, 71(7)*, 805-816.

Alexandrowicz, W. P. (2004): Protection of calcareous tufa sites in Southern Poland, *Polish Geological Institute Special Papers*, 13(11).

Al-Kheder, S., Al-Shawabkeh, Y., Haala, N. (2009): Developing a documentation system for desert palaces in Jordan using 3D laser scanning and digital photogrammetry, *Journal of Archaeological Science*, 36(2), 537-546.

Allen, T. F., Hoekstra, T. W. (1991): Role of heterogeneity in scaling of ecological systems under analysis, u: *Ecological heterogeneity* (pp. 47-68), Springer, New York, NY.

Alonso, J. A., Lamata, M. T. (2006): Consistency in the analytic hierarchy process: a new approach, *International journal of uncertainty, fuzziness and knowledge-based systems*, 14(04), 445-459.

Ananda, J., Herath, G. (2009): A critical review of multi-criteria decision making methods with special reference to forest management and planning, *Ecological economics*, 68(10), 2535-2548.

Andreeva, P. (2007): Givetian microbial carbonates from the carbonate-sulphate suite in well R-119 Kardam (North-eastern Bulgaria), *COMPTES RENDUS-ACADEMIE BULGARE DES SCIENCES*, 60(2), 179.

Andrews, J. E., Pedley, M., & Dennis, P. F. (2000): Palaeoenvironmental records in Holocene Spanish tufas: a stable isotope approach in search of reliable climatic archives, *Sedimentology*, 47(5), 961-978.

Ansari, H., Gondaliya, P. (2013): Effective 3D visualisation from close range photogrametry surface measurment, University of Pune, Department of geography, dostupno na: https://www.slideshare.net/PARTHGONDALIYA1/iirscrp-report-by-parth-gondaliya-and-huzaifa-ansari, travanj, 2019.

Arenas, C., Osácar, C., Sancho, C., Vázquez-Urbez, M., Auqué, L., Pardo, G. (2010): Seasonal record from recent fluvial tufa deposits (Monasterio de Piedra, NE Spain): sedimentological and stable isotope data, *Geological Society*, London, Special Publications, 336(1), 119-142.

Arenas, C., Vázquez-Urbez, M., Auqué, L., Sancho, C., Osácar, C.,Pardo, G. (2014): Intrinsic and extrinsic controls of spatial and temporal variations in modern fluvial tufa sedimentation: A thirteen-year record from a semi-arid environment, *Sedimentology*, 61(1), 90-132.

Arp, G., Bissett, A., Brinkmann, N., Cousin, S., De Beer, D., Friedl, T., Mohr, K. I., Neu, T. R., Reimer, A., Shiraishi, F., Stackebrandt, E. Zippel, B. (2010): Tufa-forming biofilms of German karstwater streams: microorganisms, exopolymers, hydrochemistry and calcification, *Geological Society*, London, Special Publications, 336(1), 83-118.

Arp, G., Wedemeyer, N., Reitner, J., (2001): Fluvial Tufa Formation in a Hard-Water Creek (Deinschwanger Bach, Franconian Alb, Germany), *Facies*, 44, 1-22.

Artec 3D, (2019): Professional 3D scanning solutions, dostupno na: https://www.artec3d.com/files/pdf/ArtecScanners-Booklet-EURO.pdf, listopad, 2019.

Artec Group, (2016): Artec™Eva 3D Scanner - Scan easier. Scan more, dostupno na: http://www.dirdim.com/pdfs/EVA_Brochure_DDI.pdf, rujan, 2018.

Asner, G. P., Knapp, D. E., Kennedy-Bowdoin, T., Jones, M. O., Martin, R. E., Boardman, J., Hughes, R. F. (2008): Invasive species detection in Hawaiian rainforests using airborne imaging spectroscopy and LiDAR, *Remote Sensing of Environment*, 112(5), 1942-1955.

Auqué Sanz, L. F., Arenas Abad, M. C., Osácar Soriano, M. C., Pardo Tirapu, G. M., Sancho Marcén, C., Vázquez-Urbez, M. (2013): Tufa sedimentation in changing hydrological conditions: the River Mesa (Spain), *Geologica Acta*, 11(1), 0085-102.

Auqué, L., Arenas, C., Osácar, C., Pardo, G., Sancho, C., Vázquez-Urbez, M. (2014): Current tufa sedimentation in a changing-slope valley: the River Añamaza (Iberian Range, NE Spain), *Sedimentary Geology*, *303*, 26-48.

Badalamenti, F., Ramos, A. A., Voultsiadou, E., Lizaso, J. S., D'anna, G., Pipitone, C., Mas, J., Ruiz Fernandez, J.A., Whitemarsh, D., Riggio, S. (2000): Cultural and socio-economic impacts of Mediterranean marine protected areas, *Environmental conservation*, 27(2), 110-125.

Baker A, Smart PL. (1995) Recent flowstone growth rates: Field measurements in comparison to theoretical predictions, *Chemical Geology*, 122(1-4): 121-128.

Balletti, C., Beltrame, C., Costa, E., Guerra, F., Vernier, P. (2015): *Underwater Photogrammetry and 3D Reconstruction of Marble Cargos Shipwreck*, International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, Volume XL-5/W5, 2015

Underwater 3D Recording and Modeling, 16–17 April 2015, Piano di Sorrento, Italy

Barada, M. (2017): *Utjecaj korisničko-definiranih parametara na točnost digitalnog modela reljefa*, Sveučilište u Zadru, Odjel za geografiju, Zadar.

Barazzetti, L., Previtali, M., Roncoroni, F. (2018): *Can we use low-cost 360 degree cameras to create accurate 3D models?*. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 42(2).

Barilar, M., Todić, F., Krste, I. (2015): Korištenje fotogrametrijskog materijala u izradi 3D modela i fototeksture, *Ekscentar*, (18), 50-56.

Barrios, V., Carrizosa, S., Darwall, W. R. T., Freyhof, J., Numa, C., Smith, K. (2014): Freshwater key biodiversity areas in the Mediterranean basin hotspot: Informing species conservation and development planning in freshwater ecosystems (Vol. 52). IUCN.

Belančić, A., Kepčija, R. M., Miliša, M., Moraj, A. P., Habdija, I. (2009): Flow velocity effect on leaf litter breakdown in tufa depositing system (Plitvice Lakes, Croatia). *International Review of Hydrobiology*, 94(4), 391-398.

Belić, J. (2005): *Model of sediments on Prošćansko Lake*, Diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Inženjerska geodezija i upravljanje prostornim podatcima, Zagreb.

Benac, Č., (2013): *Riječnik pojmova u primijenjenoj geologiji i ekološkom inženjerstvu*, Sveučilište u Rijeci, Rijeka.

Beraldi-Campesi, H., Arenas-Abad, C., Garcia-Pichel, F., Arellano-Aguilar, O., Auqué, L., Vazquez-Urbez, M., Ruiz-Velasco, S. (2012): Benthic bacterial diversity from freshwater tufas of the Iberian Range (Spain), *FEMS microbiology ecology*, 80(2), 363-379.

Bertin, S., Friedrich, H. (2016): Field application of close-range digital photogrammetry (CRDP) for grain-scale fluvial morphology studies, *Earth Surface Processes and Landforms*, 41(10), 1358-1369.

Bezerra, U.T, Vasconcelos, K.K.F., Wegner, R.R. (2010): *New Hardness Scale*, dostupno na: https://www.researchgate.net/publication/311011462_New_Hardness_Scale, lipanj, 2020.

Blaschke, T., Hay, G. J. (2001): Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure, *International Archives of Photogrammetry and Remote Sensing*, 34(4), 22-29.

Bočić, N., Lukić, A., Opačić, V. T. (2007): Management models and development of show caves as tourist destinations in Croatia, *Acta Carsologica*, 35(2-3).

Bodrožić, A., Adžić, Đ., Milec, K. (2015). Priprema za fotogrametrijsko snimanje i fotogrametrijsko snimanja artefekata, *Ekscentar*, (18), 47-49.

Bolan, N. S., Baskaran, S., Thiagarajan, S. (1999): Methods of measurement of dissolved organic carbon of plant origin in soils, manures, sludges and stream water, u: *Analysis of Plant Waste Materials* (pp. 1-19). Springer, Berlin, Heidelberg.

Bonacci, O. (2016): *Hidrološka analiza pojave mutnoće na izvorima u kršu: interpretacija podataka mjerenih na izvoru Omble*, Hrvatske vode, 24(95), 47-57.

Bonacci, O., Roje-Bonacci, R., Andrić, I. (2017): Prilog izučavanju hidrologije Skradinskog buka na rijeci Krki, *Hrvatske vode*, 25(99), 27-36.

Bono, P., Dreybrodt, W., Ercole, S., Percopo, C., Vosbeck, K. (2001): Inorganic calcite precipitation in Tartare karstic spring (Lazio, central Italy): field measurements and theoretical prediction on depositional rates. *Environmental Geology*. 41(3-4), 305-313.

Botić, J. (2010): Rijeka Krka i Nacionalni park Krka u funkciji zavičajne nastave, *Godišnjak Titius: godišnjak za interdisciplinarna istraživanja porječja Krke*, 2(2), 239-251.

Brady A. L., Slater G., Laval B., Lim, D. S. (2009): Constraining carbon sources and growth rates of freshwater microbialites in Pavilion Lake using ^{14}C analysis, *Geobiology*. 7(5): 544-555.

Brady, S. (2009): Revisiting a Honduran landscape described by Robert West: An experiment in repeat geography, *Journal of Latin American Geography*, 7-27.

Brajković, I. (2016): Primjena rezultata ankete posjetitelja u javnoj ustanovi „Nacionalni park Krka“, Specijalistički diplomski stručni, Veleučilište u Šibeniku, Odjel menadžment, Šibenik.

Brock, J. C., Wright, C. W., Clayton, T. D., Nayegandhi, A. (2004): LIDAR optical rugosity of coral reefs in Biscayne National Park, Florida, *Coral Reefs*, 23(1), 48-59.

Bronić, I. K. (2009): ^{14}C method of dating archaeological artifacts, *Godišnjak Gradskog muzeja Sisak*, 9, 81-92.

Brown, D. C. (1971). Close-Range Camera Calibration, *Photogrammetric Engineering* 37(8): 855–866.

Brown, D. S., Kelley, J. F., Moore, K. S., Seager, T. P. (2015): U.S. Patent No. 9,196,027. Washington, DC: U.S. Patent and Trademark Office.

Brutto, M. L., Dardanelli, G. (2017): Vision metrology and Structure from Motion for archaeological heritage 3D reconstruction: a Case Study of various Roman mosaics. ACTA IMEKO, 6(3), 35-44.

Bućan, D. (2016): *Naseljavanje makrozoobentosa na umjetne podloge na izvoru potoka Jankovac (Park prirode Papuk)*, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

Bulat, Ž. (2010): Buk – Glasnik Javne ustanove „Nacionalni park „Krka“, Javna ustanova „Nacionalni park Krka“, Šibenik, dostupno na: http://npkrka.hr.win9.mojsite.com/buk/buk1/files/assets/downloads/publication.pdf, ožujak, 2019.

Bulat, Ž. (2011): Plan upravljanja - Nacionalni park „Krka“, Javna ustanova „Nacionalni park Krka“, dostupno na: http://www.npkrka.hr/stranice/plan-upravljanja-nacionalnog-parka-krka/6.html, ožujak, 2019.

Bulat, Ž. (2012): Institucionalni okvir zaštite prirode u Republici Hrvatskoj, *Pravni vjesnik: časopis za pravne i društvene znanosti Pravnog fakulteta Sveučilišta JJ Strossmayera u Osijeku*, 28(2), 95-128.

Burnett, C., Blaschke, T. (2003): A multi-scale segmentation/object relationship modelling methodology for landscape analysis, *Ecological modelling*, 168(3), 233-249.

Byers, A. (1987): An assessment of landscape change in the Khumbu region of Nepal using repeat photography, *Mountain Research and Development*, 77-81.

Byers, A. C. (2007): An assessment of contemporary glacier fluctuations in Nepal's Khumbu Himal using repeat photography, *Himalayan Journal of Sciences*, 4(6), 21-26.

Capezzuoli, E., Gandin, A., Pedley, M. (2014): Decoding tufa and travertine (fresh water carbonates) in the sedimentary record: the state of the art, *Sedimentology*, 61(1), 1-21.

Carthew, K. D., Drysdale, R. N., Taylor, M. P. (2003): Tufa deposits and biological activity, Riversleigh, northwestern Queensland, u: *Advances in Regolith: Proceedings of the CRC LEME Regional Regolith Symposia*. CRC LEME, Bentley, Australia (pp. 55-59).

Carthew, K. D., Taylor, M. P., Drysdale, R. N. (2002): Aquatic insect larval constructions in tropical freshwater limestone deposits (tufa): preservation of depositional environments. General and Applied Entomology: the Jour*nal of the Entomological Society of New South Wales*, 31, 35.

Chafetz, H. S., Folk, R. L. (1984): Travertines; depositional morphology and the bacterially constructed constituents, *Journal of Sedimentary Research*, 54(1), 289-316.

Chafetz, H., Srdoc, D., Horvatincic, N. (1994): Early diagenesis of Plitvice lakes Waterfall and barrier treavertine deposits, *Geographie physique et Quaternaire*, 48(3), 247-255.

Chankong, V., Haimes, Y. Y. (2008): *Multiobjective decision making: theory and methodology*, Courier Dover Publications.

Chapman, D. V. (Ed.). (1996): *Water quality assessments: a guide to the use of biota, sediments and water in environmental monitoring*. CRC Press.

Chen, J., Zhang, D. D., Wang, S., Xiao, T., Huang, R. (2004): Factors controlling tufa deposition in natural waters at waterfall sites. *Sedimentary Geology*, 166(3-4), 353-366.

Ciceli, T. (2007): Kalibracija digitalne kamere FUJI FinePIX S2 Pro, *Geodetski list*, 61(1), 41-59.

Clarke, T. A., Fryer, J. G. (1998): The development of camera calibration methods and models. *The Photogrammetric Record*, 16(91), 51-66.

Collen, B., Whitton, F., Dyer, E. E., Baillie, J. E., Cumberlidge, N., Darwall, W. R., Pollock, C., Richman, I. N., Soulsby, A-M, Böhm, M. (2014): Global patterns of freshwater species diversity, threat and endemism, *Global ecology and Biogeography*, 23(1), 40-51.

Collins, B. D., Brown, K. M., Fairley, H. C. (2008): *Evaluation of terrestrial LIDAR for monitoring geomorphic change at archeological sites in Grand Canyon National Park*, Arizona (No. 2008-1384), US Geological Survey.

Constán-Nava, S., Bonet, A., Pastor, E., Lledó, M. J. (2010): Long-term control of the invasive tree Ailanthus altissima: Insights from Mediterranean protected forests, *Forest Ecology and Management*, 260(6), 1058-1064.

Cowie, I. D., Werner, P. A. (1993): Alien plant species invasive in Kakadu National Park, tropical northern Australia, *Biological Conservation*, 63(2), 127-135.

Cox, R. L., Underwood, E. C. (2011): The importance of conserving biodiversity outside of protected areas in Mediterranean ecosystems, *PLoS One*, 6(1), e14508.

Cukrov N., Lojen, S. (2010): Tufa as environmental proxy in the karst river systems, 4th Croatian Geological Congress with international participation: Abstract book / Horvat, M. (ed.). Zagreb, Croatian Geological Survey; pp. 312-313.

Cukrov, N., Cmuk, P., Mlakar, M., Omanović, D. (2008): Spatial distribution of trace metals in the Krka River, Croatia: an example of the self-purification, *Chemosphere*, 72(10), 1559-1566.

Cukrov, N., Surić, M., Fuček, L., Ćosović, V., Korbar, T., Juračić, M. (2010): Geology of Krka River estuary, u: Vodič ekskurzija–Excursion Guide-book (4. hrvatski geološki kongres), Hrvatski geološki institut.

Dadić, Ž. (2012): Pregled kvalitete pitke vode u Hrvatskoj. Literatura: Priručnik o temeljnoj kakvoći vode u Hrvatskoj, dostupno na: http://www.waterline.hr/Prirucnik_za_vodu.pdf, rujan, 2019.

Davis, J. S., Rands, D. G., Hein, M. K. (1989): Biota of the Tuta Deposit of Falling Springs, Illinois, USA. *Transactions of the American Microscopical Society*, 403-409.

Dawson, F. H. E. M. F. Clinton, M. Ladle, (1991): Invertebrates on cut weed removed during weed-cutting operations along an English river, the River Frome, Dorset. *Aquaculture and Fisheries Management*, 22: 113–121.

De Waele, J., Gutiérrez, F., Parise, M., Plan, L. (2011): Geomorphology and natural hazards in karst areas: a review, *Geomorphology*, 134(1-2), 1-8.

Deluka-Tibljaš, A., Karleuša, B., Dragičević, N. (2013): Pregled primjene metoda višekriterijske analize pri donošenju odluka o prometnoj infrastrukturi, *Građevinar*, 65(07.), 619-631.

Demott, LM, Scholz, CA, Junium, CK. (2019): 8200-year growth history of a Lahontan-age lacustrine tufa deposit, *Sedimentology*. 66, 2169–2190. doi: 10.1111/sed.12579

Domazetović, F. (2018): *Kvantitativna analiza jaruga na prostoru otoka Paga korištenjem modela visoke rezolucije*, Diplomski rad, Sveučilište u Zadru, Odjel za geografiju, Zadar.

Dreybrodt, W., Buhmann, D., Michaelis, J., Usdowski, E. (1992): Geochemically controlled calcite precipitation by CO2 outgassing: Field measurements of precipitation rates in comparison to theoretical predictions, *Chemical Geology*, 97(3-4), 285-294.

Dreybrodt, W., Eisenlohr, L., Madry, B., Ringer, S. (1997): Precipitation kinetics of calcite in the system $CaCO_3$-H_2O-$C0_2$: The conversion to CO_2 by the slow process $H^+ + HCO_3^- \rightarrow CO_2 + H_2O$ as a rate limiting step, *Geochimica et Cosmochimica Acta*, 61(18), 3897-3904.

Drysdale, R., Gillieson, D. (1997): Micro-erosion meter measurements of travertine deposition rates: a case study from Louie Creek, Northwest Queensland, Australia. *Earth Surface Processes and Landforms: The Journal of the British Geomorphological Group*, 22(11), 1037-1051.

Drysdale, R.N., Taylor, M.P., Ihlenfeld, C., (2002): Factors controlling the chemical evolution of travertine-depositing rivers of the Barkly karst, northern Australia, *Hydrological Processes*, 16, 2941-2962.

Dudley, N. (2008): *Guidelines for applying protected area management categories*, IUCN, Gland, Švicarska.

Dumitraşcu, M., Grigorescu, I., Kuscicsa, G., Doroftei, M., Năstase, M., Dragotă, C. S. (2014): Invasive terrestrial plant species in the Romanian protected areas. A geographical approach, *Révue Roumanine de Géografie/Romomanian Journal of Geography*, 58(2), 145-160.

Dundović, M. (2013): *Fauna vodenih beskralježnjaka perifitona prirodnih podloga Sakadaškog jezera s posebnim osvrtom na maločetinaše*, Diplomski rad, Sveučilište Josipa Jurja Strossmayera, Odjel za biologiju, Osijek.

Eagles, P. F., McCool, S. F., Haynes, C. D., Phillips, A. (2002): Sustainable tourism in protected areas: Guidelines for planning and management (Vol. 8). Gland: IUCN.

Eltner, A., Kaiser, A., Castillo, C., Rock, G., Neugirg, F., Abellán, A. (2016): Image-based surface reconstruction in geomorphometry–merits, limits and developments. *Earth Surface Dynamics*, 4(2), 359-389.

Emeis, K. C., Richnow, H. H., Kempe, S. (1987): Travertine formation in Plitvice National Park, Yugoslavia: chemical versus biological control, *Sedimentology*, *34*(4), 595-609.

Ergun, B., Baz, I. (2006). Design of an expert measurement system for close-range photogrammetric applications, *Optical Engineering*, 45(5), 053604.

Espinola, B. (2017): *Statistical analysis of water data from an online EXO2 monitoring sonde: Modelling Chlorophyll-a using an EXO2 sonde*, Thesis, Helsinki Metropolia University of Applied Sciences, Environmental Engineering, Water Resource Management, Helsinki.

Everitt, J. H., Anderson, G. L., Escobar, D. E., Davis, M. R., Spencer, N. R., Andrascik, R. J. (1995): Use of remote sensing for detecting and mapping leafy spurge (Euphorbia esula), *Weed Technology*, 9(3), 599-609.

Evin, A., Souter, T., Hulme-Beaman, A., Ameen, C., Allen, R., Viacava, P, Larson, G, Cucchi, T, Dobney, K. (2016): The use of close-range photogrammetry in zooarchaeology: Creating accurate 3D models of wolf crania to study dog domestication, *Journal of Archaeological Science*: Reports, 9, 87-93.

Farina, A., (1998): *Principles and Methods in Landscape Ecology*, Chapman & Hall, London.

Farr, G., Graham, J., Stratford S., (2017): Survey, characterisation and condition assessment of Palustriella dominated springs' H7220 Petrifying springs with tufa formation (Cratoneurion)'in Gloucestershire, England.

Forbes, M., Vogwill, R., Onton, K. (2010): A characterisation of the coastal tufa deposits of south–west Western Australia, *Sedimentary Geology*, 232(1-2), 52-65.

Ford, D., Williams, P. (2007): *Introduction to Karst*, u: Karst Hydrogeology and Geomorphology, ur. P. W. Williams, John Wiley & Sons Ltd., 1-8.

Ford, T. D., Pedley, H. M. (1996): A review of tufa and travertine deposits of the world, *Earth-Science Reviews*, 41(3-4), 117-175.

Foxcroft, L. C., Richardson, D. M. (2007): Ornamental plants as invasive aliens: Problems and solutions in the Kruger National Park, South Africa.

Frankl, A., Nyssen, J., De Dapper, M., Haile, M., Billi, P., Munro, R. N., Deckers, J., Fraser, C. (2015): Advances in close-range photogrammetry, in: *Photogrammetric week* (Vol. 2015, pp. 257-268).

French, J. R. (2003): Airborne LiDAR in support of geomorphological and hydraulic modelling, *Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group*, 28(3), 321-335.

Frey J, Kovach K, Stemmler S, Koch B. (2018): UAV Photogrammetry of Forests as a Vulnerable Process. A Sensitivity Analysis for a Structure from Motion RGB-Image Pipeline, *Remote Sensing*, 10(6): 912.

Frey, J. (2019): Is auto-focus leading to worse results in photogrammetry?, *Research gate*, dostupno na: https://www.researchgate.net/post/Is_auto-focus_leading_to_worse_results_in_photogrammetry, siječanj, 2020.

Frohn, R. C., Lopez, R. D. (2017): Remote sensing for landscape ecology: new metric indicators: monitoring, modeling, and assessment of ecosystems, CRC Press, Lewis Publisher, New York.

Fryer, J. L. (2010): Ailanthus altissama. u: Fire Effects Information System, [Online]. U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, Fire Sciences Laboratory (Producer).

Gajski, D., Gašparović, M. (2015): Ispitivanje utjecaja distorzije objektiva nemjernih digitalnih kamera na točnost fotogrametrijske izmjere, *Geodetski list*, 69(1), 27-40.

Gajski, D., Solter, A., Gašparović, M. (2016): Applications of macro photogrammetry in archaeology, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B5, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic.

Gallagher, J. M., Josephs, R. L. (2008): Using LiDAR to detect cultural resources in a forested environment: an example from Isle Royale National Park, Michigan, USA. *Archaeological Prospection*, 15(3), 187-206.

Gallo, A., Muzzupappa, M., Bruno, F. (2014): 3D reconstruction of small sized objects from a sequence of multi-focused images, *Journal of Cultural Heritage*, 15(2), 173-182.

García Del Cura, M. A., Martín, J. G., Ordóñez, S. (1999): Conservation of an active fluvial tufa barrage system: Ruidera lakes natural park (Castilla-la Mancha, Spain), Towards the balanced management and conservation of the geological heritage in the new millenium. Madrid, 275-281.

Garcia-Moreno, J., Harrison, I., Dudgeon, D., Clausnitzer V., Darwall W., Farrell, T., Savy, C., Tockner, K. (2014): Sustaining freshwater biodiversity in the Anthropocene. In The global water system in the Anthropocene (pp. 247-270). Springer, Cham.

Garrard, R., Kohler, T., Wiesmann, U. M., Price, M. F., Byers, A. C., Sherpa, A. R. (2012): Depicting community perspectives: repeat photography and participatory research as tools for assessing environmental services in Sagarmatha National Park, Nepal, *Eco. mont-journal on protected mountain areas research*, 4(2), 21-31.

Gašparović, M., Gajski, D. (2016): Algoritam za preciznu eliminaciju utjecaja distorzije objektiva digitalnih kamera, *Geodetski list*, 70(1), 25-38.

Glišić, M., Lakušić, D., Šinžar-Sekulić, J., Jovanović, S. (2014): GIS analysis of spatial distribution of invasive tree species in the protected natural area of Mt Avala (Serbia), *Botanica Serbica*, 38(1), 131-138.

Goldscheider, N., Ravbar, N. (2010): Research frontiers and practical challenges in karst hydrogeology, *Acta carsologica*, 39(2).

Golubić, S., (1969): Cyclic and noncyclic mechanisms in the formation of travertine. *Verhandlungen der Internationalen Vereinigung fu¨r Theoretische und Angewandte Limnologie* 17: 956–961

Golubić, S., Violante, C., Plenković-Moraj, A., Grgasović, T. (2008): Travertines and calcareous tufa deposits: an insight into diagenesis, *Geologia Croatica*, 61(2-3), 363-378.

González, M. Á. M., Yravedra, J., González-Aguilera, D., Palomeque-González, J. F., Domínguez-Rodrigo, M. (2015): Micro-photogrammetric characterization of cut marks on bones, *Journal of Archaeological Science*, 62, 128-142.

González, M., Rubio, F. (2000): Man's alterations of fluvial-tufa systems landscape in central Spain. *Boletín de la Real Sociedad Española de Historia Natural, Sección Geológica*, 96(1/2), 155-186.

Goodchild, M. F. (1993): The state of GIS for environmental problem-solving, *Environmental modeling with GIS*, 8-15.

Goudie, A. S., Viles, H. A., Pentecost, A. (1993): The late-Holocene tufa decline in Europe. *The Holocene*, 3(2), 181-186.

Gradziński, M. (2010): Factors controlling growth of modern tufa: results of a field experiment, *Geological Society, London, Special Publications*, 336(1), 143-191.

Grbavac, F. (2015): *Makrozoobentos stalnih i povremenih krških izvora*, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno – matematički fakultet, Biološki odsjek, Zagreb.

Greene, R., Devillers, R., Luther, J. E., Eddy, B. G. (2011): GIS-based multiple-criteria decision analysis, *Geography Compass*, 5(6), 412-432.

Grgić, I., Redžović, Z. (2016): Procjena antropogenih utjecaja na rijeku Krku i potencijalne opasnosti za Nacionalni park Krka, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

Gross, J. E., Goetz, S. J., Cihlar, J. (2009): Application of remote sensing to parks and protected area monitoring: Introduction to the special issue, *Remote Sensing of Environment*, 113(7), 1343-1345.

Gu, Y., Du, J., Tang, Y., Qiao, X., Bossard, C.,Deng, G. (2013): Challenges for sustainable tourism at the Jiuzhaigou World Natural Heritage site in western China, In Natural Resources Forum (Vol. 37, No. 2, pp. 103-112).

Gulić, S. (2017): Turizam u brojkama, Ministarstvo turizma Republike Hrvatske, dostupno na:https://www.htz.hr/sites/default/files/201808/HTZ%20TUB%20HR_%202017%20FINAL.pdf, ožujak, 2019.

Gulin, V., Kepčija, R. M., Perić, M. S. (2018): Spatio-temporal patterns of tufa deposition and periphyton community dynamics along the newly formed water pathways in National Park Krka, Croatia. u: 13. Hrvatski biološki kongres s međunarodnim sudjelovanjem.

Gulin, V., Matoničkin Kepčija, R., Sertić Perić, M. (2019): Reactivated Channels Along Tufa Barrier as Favorable Habitat for Colonization of Microfauna, VIII European Congress of Protistology (ECOP) - ISOP Joint Meeting, Abstract book_talks_ECOP 2019 / Angelici, Maria Cristina - Rim, 2019, 99-99 Rim, Italija.

Habdija, I., Perić, M. S. (2012): The influence of experimental removal of macrophytes on physico-chemical water parameters at the Novakovića Brod tufa-barrier, 119-0000000-1205 - Implementacija funkcionalnog ustroja akvatičkih zajednica u valorizaciji okoliša, Prirodoslovno-matematički fakultet, Zagreb.

Habdija, I., Primc-Habdija, B., (2006): Ekološka obilježja biocenoza na travertinskim barijerama u rijeci Krki. Nacionalni park „Krka“: prirodoslovni vodič, Šibenik.

Haimes, Y.Y., Hall, W.A., (1974): Multi-objectives in water resource systems analysis: the surrogate worth trade off method. *Water Resources Research* 10, 615–624.

Hantson, W., Kooistra, L., Slim, P. A. (2012): Mapping invasive woody species in coastal dunes in the N etherlands: a remote sensing approach using LIDAR and high-resolution aerial photographs, *Applied vegetation science*, 15(4), 536-547.

Harker, P. T., Vargas, L. G. (1987): The theory of ratio scale estimation: Saaty's analytic hierarchy process. *Management science*, 33(11), 1383-1403.

Hauer, F. R., Resh, V. H. (2017): Macroinvertebrates. In *Methods in Stream Ecology*, Volume 1 (pp. 297-319). Academic Press.

Heery, S. (2007): A survey of tufa-forming (petrifying) springs in the Slieve Bloom, Ireland. A Report for Offaly & Laois County Councils Part, 1.

Heimann, A., Sass, E. (1989): Travertines in the northern Hula Valley, Israel. *Sedimentology,* 36(1), 95-108.

Herath, G., (2004): Incorporating community objectives in improved wetland management: the use of the analytic hierarchy process, *Journal of Environmental Management* 70 (263), 273.

Herman, J. S., Lorah, M. M. (1988): Calcite precipitation rates in the field: measurement and prediction for a travertine-depositing stream, *Geochimica et Cosmochimica Acta*, 52(10), 2347-2355.

Herrero, H. V., Southworth, J., Bunting, E., Child, B. (2017): Using repeat photography to observe vegetation change over time in Gorongosa National Park, *African Studies Quarterly*, 17(2), 65-82.

Hlongwa, P., Sander, F. G., Geiger, M. (2007). Digital macro-photogrammetry in orthodontic tooth movement: case report: case study, *South African Dental Journal*, 62(10), 446-450.

Hoalst-Pullen, N., Patterson, M. W. (2010): Geospatial technologies in environmental management (Vol. 3), Springer Science & Business Media.

Hoiberg, C. (2018). The Best Aperture for Landscape Photography, dostupno na: https://petapixel.com/2018/06/15/the-best-aperture-for-landscape-photography/, siječanj, 2020

Holjevac, N., Kuzle, I., Zidar, M., Modrovčić, M. (2014): Razvoj modela analitičkog hijerarhijskog procesa i njegovo korištenje pri donošenju odluke o prelasku na 20 KV pogonski napon, *Hrvatski ogranak međunarodne elektrodistribucijske konferencije*–HO CIRED.

Hori, M., Kawai, T., Matsuoka, J., Kano, A. (2009): Intra-annual perturbations of stable isotopes in tufas: effects of hydrological processes, *Geochimica et Cosmochimica Acta*, 73(6), 1684-1695.

Horner, R. R., Welch, E. B., Seeley, M. R., Jacoby, J. M. (1990): Responses of periphyton to changes in current velocity, suspended sediment and phosphorus concentration. *Freshwater biology,* 24(2):215-232.

Horvatinčić, N., Barešić, J., Čalić, R., Obelić, B., Bronić, I. K. (2005): Study of eutrophication process by physico-chemical measurements of water. U: *XIX. hrvatski skup kemičara i kemijskih inženjera.*

Horvatinčić, N., Briansó, J. L., Obelić, B., Barešić, J., Bronić, I. K. (2006): Study of pollution of the Plitvice Lakes by water and sediment analyses, u: *The Interactions Between Sediments and Water*, ur. J. Faganeli, N. Ogrinc, Springer, Dordrecht, 111-121.

Horvatinčić, N., Obelica, B., Baresica, J., Calicb, R., Babinkac, S., Suckowd, A., Bronica, I. K. (2004): A geochemical and isotope hydrological study of eutrophication processes in the Plitvice Lakes, Croatia, u: Isotopes in Environmental Studies Aquatic Forum 2004, International Atomic Energy Agency, 158-159.

Hršak, V., Marguš, D., Šegota, V., Sedlar, Z., Alegro, A. (2017): Revitalizacija kamenjarskih travnjaka u Nacionalnom parku „Krka" kontroliranim paljenjem, Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka", 44 - 52, Šibenik, 2017.

Hruševar, F. D., & Posavec-Vukelić, V. (2008). Ailanthus altissima (Mill.) Swingle, Hrvatska agencija za okoliš i prirodu, Zagreb, dostupno na: http://www.haop.hr/sites/default/files/uploads/publications/Prirucnici/Flora/Flora_svojte_II.pdf, listopad, 2019.

Huang, C. Y., Asner, G. (2009): Applications of remote sensing to alien invasive plant studies, *Sensors*, 9(6), 4869-4889.

Huang, I. B., Keisler, J., Linkov, I. (2011): Multi-criteria decision analysis in environmental sciences: Ten years of applications and trends, *Science of the total environment*, 409(19), 3578-3594.

Hulme, P. E. (2003): Biological invasions: winning the science battles but losing the conservation war?. *Oryx*, 37(2), 178-193.

Irion, G., Müller, G. (1968): Mineralogy, petrology and chemical composition of some calcareous tufa from the Schwäbische Alb, Germany, u: Recent developments in carbonate sedimentology in Central Europe (pp. 157-171). Springer, Berlin, Heidelberg.

Jaafari, S., Shabani, A. A., Danehkar, A., Nazarisamani, A: (2014): Application of landuse change modeling for protected area monitornig, *The holistic approach to environment*, 4(1), 31-40.

Jacobson, R.L. Usdowski, E., (1975): Geochemical controls on a calcite precipitating spring. *Contrib. Mineral. Petrol*., 51: 65-74.

James M. R., Chandler J. H., Eltner A., Fraser C., Miller P. E., Mills, J. P., Noble T., Robson, S., Lane S. N. (2019). Guidelines on the use of structure-from-motion photogrammetry in geomorphic research, *Earth Surface Processes and Landforms*, 44(10), 2081-2084.

James, M.R., Robson, S., (2012): Straightforward reconstruction of 3D surfaces and topography with a camera: accuracy and geoscience application: *Journal of Geophysical Research*, v. 117, 17 p.

James, N. C., Copeland, C. C., Lytle, A. D., (2004): Relationship between Oxidation-Reduction potential, Oxidant, pH, in Drinking water, American Water Works Association, dostupno na: https://pdfs.semanticscholar.org/81f8/4a82fb386e8d03057e6df7f107e9e86b983d.pdf, rujan, 2019

Janssen, R. (2012): Multiobjective decision support for environmental management (Vol. 2). Springer Science & Business Media.

Ji, P., Jiang, R. (2003). Scale transitivity in the AHP. *Journal of the Operational Research Society*, 54(8), 896-905.

Johnson, G. D., Patil, G. P. (1998): Quantitative multiresolution characterization of landscape patterns for assessing the status of ecosystem health in watershed management areas, *Ecosystem Health*, 4(3), 177-187.

Jones, D. A., Hansen, A. J., Bly, K., Doherty, K., Verschuyl, J. P., Paugh, J. I., Carle, P., Story, S. J. (2009): Monitoring land use and cover around parks: A conceptual approach, *Remote Sensing of Environment*, 113(7), 1346-1356.

Jovičić, D., Ivanović, V. (2004): Menadžment turizma u nacionalnim parkovima, *Tourism and hospitality management*, 10(3-4), 93-105.

Jun T. (2012) 3D modelling of small object based on the projector-camera system, *Kybernetes* 41(9): 1269-1276.

Jurjević, L. (2017). *Kalibracija kamere bespilotne letjelice*, Diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb.

Kaenel, B. R. C. D. Matthaei, U. Uehlinger, (1998): Disturbance by aquatic plant management in streams: effects on benthic invertebrates, *Regulated Rivers: Reserach & Management*, 14: 341–356

Kaenel, B. R. H. Buehrer, U. Uehlinger, (2000): The effects of aquatic plant management on stream metabolism and the oxygen balance in streams, *Freshwater Biology*, 45: 85–95.

Kalla, S. (2009): Measurement Of Uncertainty: Standard Deviation, dostupno na: https://explorable.com/measurement-of-uncertainty-standard-deviation, prosinac, 2019.

Kano, A., Hagiwara, R., Kawai, T., Hori, M., Matsuoka, J. (2007): Climatic conditions and hydrological change recorded in a high-resolution stable-isotope profile of a recent laminated tufa on a subtropical island, southern Japan, *Journal of Sedimentary Research*. 77(1):59-67.

Kano, A., Kawai, T., Matsuoka, J., Ihara, T. (2004): High-resolution records of rainfall events from clay bands in tufa, *Geology*, 32(9):793-796.

Kano, A., Matsuoka, J., Kojo, T., Fujii, H. (2003): Origin of annual laminations in tufa deposits, southwest Japan, *Palaeogeography, Palaeoclimatology, Palaeoecology*, 191(2), 243-262.

Kawai, T., Kano, A., Hori, M. (2009): Geochemical and hydrological controls on biannual lamination of tufa deposits, *Sedimentary Geology*, 213(1-2), 41-50.

Kawai, T., Kano, A., Matsuoka, J., Ihara, T. (2006): Seasonal variation in water chemistry and depositional processes in a tufa-bearing stream in SW-Japan, based on 5 years of monthly observations, *Chemical Geology*, 232(1-2), 33-53.

Keeney, R.L., McDaniels, T.L., Ridge-Cooney, V.L., (1996): Using values in planning wastewater facilities for metropolitan Seattle, *Water Resources Bulletin* 32, 293–303.

Kelleher, G. Kenchington, R. (1991): *Guidelines for Establishing Marine Protected Areas*, IUCN, Gland, Switzerland and Cambridge, UK

Kempe, S., Emeis, K. (1985): *Carbonate chemistry and the formation of Plitvice Lakes*, Transport of carbon and minerals in major world rivers, Part, 3, 351-383.

Kennedy, R. E., Townsend, P. A., Gross, J. E., Cohen, W. B., Bolstad, P., Wang, Y. Q., Adams, P. (2009): Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects, *Remote sensing of environment*, 113(7), 1382-1396.

Kerney MP, Preece RC, Turner, C. (1980) Molluscan and plant biostratigraphy of some Late Devensian and Flandrian deposits in Kent. Philosophical Transactions of the Royal Society of London. B, Biological Sciences 291(1044): 1-43.

Khalili, N. R., Duecker, S. (2013): Application of multi-criteria decision analysis in design of sustainable environmental management system framework, *Journal of Cleaner Production*, 47, 188-198.

Kiker, G. A., Bridges, T. S., Varghese, A., Seager, T. P., Linkov, I. (2005): Application of multicriteria decision analysis in environmental decision making, *Integrated environmental assessment and management*, 1(2), 95-108.

Kincey, M., Challis, K. (2009): Monitoring fragile upland landscapes: The application of airborne lidar, *Journal for Nature Conservation*, 18(2), 126-134.

Klanjšček, T., Legović, T., Klanjšček, J., Geček, S., Marguš, D., (2017): Prihvatni kapacitet Nacionalnog parka „Krka“ za posjetitelje, Zbornik radova: Vizija i izazovi upravljanja

zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 378-422, Šibenik.

Klasner, F. L., Fagre, D. B. (2002): A half century of change in alpine treeline patterns at Glacier National Park, Montana, USA, *Arctic, Antarctic, and Alpine Research*, 34(1), 49-56.

Koch, M., Kaehler, M. (2009): Combining 3D laser-Scanning and close-range Photogrammetry-An approach to Exploit the Strength of Both methods, u: *Making History Interactive, Computer Applications and Quantitative Methods in Archeology Conference* (pp. 22-26).

Kolasa, J., S. T. A. Pickett, (1991): *Ecological Heterogeneity*, Springer-Verlag, New York.

Kosanović, M. (2010): *Metode kalibracije kamere*, Diplomski rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računalstva, Zagreb.

Kriticos, D. J., Brunel, S. (2016): Assessing and managing the current and future pest risk from water hyacinth,(Eichhornia crassipes), an invasive aquatic plant threatening the environment and water security, *PloS one*, 11(8), e0120054.

Kučinić, M., Previšić, A., Vajdić, M., Tunjić, M., Mihoci, I., Žalac, S., Sviben, S., Vučković, I., Trupković, M., Habdija, I. (2017): First systematic investigation of adults and second checklist of caddisflies of the Plitvice Lakes National Park with notes on research history, biodiversity, distribution and ecology, *Natura Croatica*, 26(2), 225.

Kudrnovsky, H., Lazowski, L. (2017): Fluvial landscapes – an important ecological dimension within European protected areas, 6th Symposium for Research in Protected Areas 2 to 3 November 2017, Salzburg, 349 – 352.

Kull, C. A. (2005): Historical landscape repeat photography as a tool for land use change research, *Norsk Geografisk Tidsskrift-Norwegian Journal of Geography*, *59*(4), 253-268.

Laval, B., Cady, S. L., Pollack, J. C., McKay, C. P., Bird, J. S., Grotzinger, J. P., Bohm, H. R. (2000). Modern freshwater microbialite analogues for ancient dendritic reef structures. *Nature*, 407(6804), 626.

Lavy, A., Eyal, G., Neal, B., Keren, R., Loya, Y., Ilan, M. (2015): A quick, easy and non-intrusive method for underwater volume and surface area evaluation of benthic organisms by 3D computer modelling, *Methods in Ecology and Evolution*, 6(5), 521-531.

Lee, S. A., Kim, G. (2018): Sources, fluxes, and behaviors of fluorescent dissolved organic matter (FDOM) in the Nakdong River Estuary, Korea, *Biogeosciences*, 15(4), 1115-1122.

Levin, S.A., (1992): The problem of pattern and scale in ecology, *Ecology* 73 (6), 1943–1967.

Lewin, J., Woodward, J. C. (2009): Karst geomorphology and environmental change, u: *The Physical Geography of the Mediterranean*, ur: C. Woodward, Oxford University Press, Oxford, 287–317.

Limondin-Lozouet, N., & Preece, R. C. (2004). Molluscan successions from the Holocene tufa of St Germain-le-Vasson, Normandy (France) and their biogeographical significance. *Journal of Quaternary Science: Published for the Quaternary Research Association*. 19(1):55-71.

Linardić, J. (1949): Studije o jadranskom fukusu (Fucus virsoides), *Acta Botanica Croatica*, 12(1), 7-131.

Linkov, I., Satterstrom, F. K., Kiker, G., Batchelor, C., Bridges, T., Ferguson, E. (2006): From comparative risk assessment to multi-criteria decision analysis and adaptive management: Recent developments and applications, *Environment International*, 32(8), 1072-1093

Liović, B., Županić, M. (2005): Štetočinje šuma nacionalnih parkova Hrvatske i ekološki prihvatljive mjere zaštite, *Radovi*, 40(1), 101-112.

Liu, L. (2017): Factors Affecting Tufa Degradation in Jiuzhaigou National Nature Reserve, Sichuan, China, *Water*, 9(9), 702.

Liu, Z., Sun, H., Baoying, L., Xiangling, L., Wenbing, Y., Cheng, Z. (2010): Wet-dry seasonal variations of hydrochemistry and carbonate precipitation rates in a travertine-depositing canal at Baishuitai, Yunnan, SW China: implications for the formation of biannual laminae in travertine and for climatic reconstruction, *Chemical Geology*, 273(3-4), 258-266.

Liu, Z., Sun, H., Li, H., Wan, N. (2011): $\delta^{13}C$, $\delta^{18}O$ and deposition rate of tufa in Xiangshui River, SW China: implications for land-cover change caused by climate and human impact during the late Holocene, *Geological Society, London, Special Publications*, 352(1), 85-96.

Liu, Z., Svensson, U., Dreybrodt, W., Daoxian, Y., Buhmann, D. (1995): Hydrodynamic control of inorganic calcite precipitation in Huanglong Ravine, China: Field measurements and theoretical prediction of deposition rates, *Geochimica et Cosmochimica Acta*, *59*(15), 3087-3097.

Lluis, J., Josep, J., Costa, A., Coll, S. (2014): Close Range Photogrammetry and Constructive Characterization of Masonry Gothic Vaults. Revista de la Construcción, *Journal of Construction*, 13(1).

Lodeta, V., Novak, N., Kravarščan, M. (2010). Tree of heaven (Ailanthus altissima (Mill.) Swingle) – Colonization in Croatia, Complete Programme oft he 2nd International Workshop

on Invasive Plants int he Mediterranean Type Regions of the World, 87, 2010-08-02/06, Trabzon, Turska

Lojen, S., Dolenec, T., Vokal, B., Cukrov, N., Mihelčić, G., Papesch, W. (2004): C and O stable isotope variability in recent freshwater carbonates (River Krka, Croatia), *Sedimentology*, 51(2), 361-375.

Løken, E. (2007): Use of multicriteria decision analysis methods for energy planning problems, *Renewable and Sustainable Energy Reviews*, 11(7), 1584-1595.

Lorah, M. M., Herman, J. S. (1988): The chemical evolution of a travertine-depositing stream: Geochemical processes and mass transfer reactions, *Water Resources Research*, 24(9), 1541-1552.

Lorah, M. M., Herman, J. S. (1990): Geochemical evolution and calcite precipitation rates in Falling Spring Creek, Virginia, u: Herman, J. S. and Hubbard, D. A. (Eds), Travertine-Marl: Stream Deposits in Virginia, Virginia Division of Mineral Resources, Publication 101, 17–32.

Lowe, D. G. (1999). Object recognition from local scale-invariant features. u: *iccv* (Vol. 99, No. 2, pp. 1150-1157).

Lu, G., Li, X., (1992): A study on the cold-water travertine surface depositional landform in Huanglong scenic spot, Sichuan. J. Chengdu College of Geology. 19(56): 55–63.

Lu, G., Zheng, C., Donahoe, R. J., Lyons, W. B. (2000): Controlling processes in a CaCO3 precipitating stream in Huanglong Natural Scenic District, Sichuan, China, *Journal of Hydrology*: 230(1-2): 34-54.

Lugli, S., Wright, W., Tang, Y., Jie, D., Qiao, X., Fisher, S. (2016): Conquests of the Jiuzhaigou National Nature Reserve, A World Heritage Site at the edge of the Qinghai-Tibetan Plateau (China).

Luhmann, T., Robson, S., Kyle, S., Harley, I. (2007): *Close range photogrammetry*, Wiley.

Lyons, M. D., Kelly, D. L. (2016): Monitoring guidelines for the assessment of petrifying springs in Ireland. Irish Wildlife Manuals, No. 94. National Parks and Wildlife Service, Department of Arts, Heritage, Regional, Rural and Gaeltacht Affairs, Ireland.

Mägdefrau, K. (1956): Paläobiologie der Pflanzen. Dritte Aufl., 443 S. Fischer Verlag, Jena.

Makarewicz, A., Kowalczuk, P., Sagan, S., Granskog, M. A., Pavlov, A. K., Zdun, A., Zabłocka, M. (2018): Characteristics of chromophoric and fluorescent dissolved organic matter in the Nordic Seas, *Ocean Science*, 14(3), 543-562.

Malczewski, J. (1999): *GIS and multicriteria decision analysis*, John Wiley & Sons.

Malczewski, J. (2006): GIS-based multicriteria decision analysis: a survey of the literature. *International journal of geographical information science*, 20(7), 703-726.

Malczewski, J., Rinner, C. (2015): Introduction to GIS-MCDA. In *Multicriteria Decision Analysis in Geographic Information Science* (pp. 23-54). Springer, Berlin, Heidelberg.

Manzo, E., Perri, E., Tucker, M. E. (2012): Carbonate deposition in a fluvial tufa system: processes and products (Corvino Valley–southern Italy). *Sedimentology*, 59(2), 553-577.

Marceau, D. J., Hay, G. J. (1999): Remote sensing contributions to the scale issue. *Canadian journal of remote sensing*, 25(4), 357-366.

Marguš, D. (2017): Plan upravljanja Nacionalnog parka Krka, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 353 - 362, Šibenik, 2017.

Marguš, D. (2018): BUK – Glasnik Javne ustanove “Nacionalni park Krka”, godište IX. | broj 18, Javna ustanova “Nacionalni park Krka”, Šibenik.

Marguš, D. i Martinić, I. (2017): Razvojni izazovi u upravljanju Nacionalnim parkom „Krka“ - prema vrhu izvrsnosti, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 33-39, Šibenik, 2017.

Marguš, D., Babačić Ajduk, A., Zekanović, H., Dragutin Burić, T. (2017): Zaštićene prirodne vrijednosti na području Šibensko-kninske županije, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 423 - 453, Šibenik, 2017.

Martinić, I. (2017): Vizija razvoja sustava zaštićenih područja Republike Hrvatske - Nacionalni park „Krka“ kao predvodnik trendova, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 342 - 352, Šibenik, 2017.

Marziali, S., Dionisio, G. (2017): Photogrammetry and macro photography, The experience of the MUSINT II Project in the 3D digitizing process of small size archaeological artifacts. Studies in Digital Heritage, 1(2), 298-309.

Matoničkin Kepčija, R. (2014): Istraživanje vode, Program Globe - priručnik za mjerenja, dostupno na: http://globe.pomsk.hr/prirucnik/voda.PDF, kolovoz, 2019

Matoničkin Kepčija, R., Gulin, V., Sertić Perić, M (2018): Utjecaj uklanjanja pajasena na osedravanje prirodnih podloga i dinamiku perifitona i makrozoobentosa, 13. HRVATSKI BIOLOŠKI KONGRES s međunarodnim sudjelovanjem, Poreč, 19 - 23. 09. 2018 (67), Hrvatsko biološko društvo SOCIETAS BIOLOGORUM CROATICA, Zagreb, 2018.

Matoničkin Kepčija, R. Habdija, I., Primc-Habdija, B., Miliša, M. (2005): The role of simuliid and trichopteran silk in tufa formation during the Holocene of the Plitvice Lakes (Croatia), *1st International Symposium on Travertine*, Pamukkale University, Denizli, Turkey.

Matoničkin Kepčija, R., Habdija, I., Primc-Habdija, B., Miliša, M. (2006): Simuliid silk pads enhance tufa deposition, *Archiv für Hydrobiologie*, 166(3), 387-409.

Matoničkin Kepčija, R., Milišal, M., Ivković, M., Mihaljević, Z. (2017): Sezonska dinamika perifitiona na sedrenim barijerama NP „Krka“, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 789-902, Šibenik.

Matoničkin, I., Pavletić, Z. (1960): Biološke karakteristike sedrenih slapova u našim krškim rijekama, *Hrvatski geografski glasnik*, 22(1.), 43-55.

Matsuoka, J., Kano, A., Oba, T., Watanabe, T., Sakai, S., & Seto, K. (2001): Seasonal variation of stable isotopic compositions recorded in a laminated tufa, SW Japan. *Earth and Planetary Science Letters*. 192(1): 31-44.

Matthews, N. A. (2008): Aerial and close-range photogrammetric technology: providing resource documentation, interpretation, and preservation. US Department of the Interior, Bureau of Land Management, National Operations Center.

McGarigal, K., Marks, B. J. (1995): FRAGSTATS: spatial pattern analysis program for quantifying landscape structure. Gen. Tech. Rep. PNW-GTR-351. Portland, OR: US Department of Agriculture, Forest Service, Pacific Northwest Research Station. 122 p, 351.

McMinn, S. (1997): The challenge of sustainable tourism, *Environmentalist*, 17(2), 135-141.

Medić, T. (2015). Izmjera nepristupačnih područja pomoću bespilotnih letjelica, Diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb.

Medunić, G., Cindrić, I. J., Pivčević, N., Kampić, Š., Prohić, E., Goreta, G., Čobić, A. (2013): Chemical and textural composition of the Krka River tufa deposits from the Dinaric Karst region of Croatia, u: *Protected karst territories-monitoring and management*, 16-20 rujan 2012, Shumen, Bulgaria.

Megerle, H., (2012): Limited visibility and protection as well as insufficient recognition of geomorphosites: Background and challenges identified in South-West Germany, dostupno na: https://www.researchgate.net/profile/Heidi_Megerle/publication/270111703_Les_geomorphosites_du_Sud-Ouest_de_l'Allemagne_un_patrimoine_naturel_et_culturel_de_grande_valeur_mais_neglige/links/56bb1fd708ae3ace992e1b32.pdf, siječanj, 2019.

Mellenbergh, G. J. (2019): Random and Systematic Errors in Context. In *Counteracting Methodological Errors in Behavioral Research* (pp. 1-12). Springer, Cham.

Meloche, C., Murphy, S. D. (2006): Managing tree-of-heaven (Ailanthus altissima) in parks and protected areas: a case study of Rondeau Provincial Park (Ontario, Canada), *Environmental management*, 37(6), 764-772.

Merz-Preiß, M., Riding, R. (1999): Cyanobacterial tufa calcification in two freshwater streams: ambient environment, chemical thresholds and biological processes, *Sedimentary Geology*, 126(1-4), 103-124.

Meštrov, M., Ilijanić, L., Tavčar, V., Koprek, J. (1973): Utjecaj populacije bijelog amura (Ctenopharyngodon idella Val.) na vegetaciju i ekosistem Trakošćanskog jezera, *Acta Botanica Croatica*, 32(1), 125-134.

Meyrick RA, Preece RC. (2001) Molluscan successions from two Holocene tufas near Northampton, English Midlands, *Journal of biogeography* 28(1): 77-93

Micheletti, N., Chandler, J.H., and Lane, S.N., (2015): Structure from Motion (SfM) Photogrammetry: *British Society of Geomorphology, Geomorphological Techniques*, ch. 2, sec. 2.2, 12 p.

Mikac, I., Fiket, Ž., Terzić, S., Barešić, J., Mikac, N., Ahel, M. (2011): Chemical indicators of anthropogenic impacts in sediments of the pristine karst lakes, *Chemosphere*, 84(8), 1140-1149.

Miler, M., Đapo, A., Kordić, B., Medved, I. (2007): Terestrički laserski skeneri, *Ekscentar*, (10), 35-38.

Miliša, M., Kepčija, R. M., Radanović, I., Ostojić, A., Habdija, I. (2006): The impact of aquatic macrophyte (Salix sp. and Cladium mariscus (L.) Pohl.) removal on habitat conditions and macroinvertebrates of tufa barriers (Plitvice Lakes, Croatia). *Hydrobiologia*, 573(1), 183-197.

Miller, J. H. 1990. Pp. 101 105 in Burns, R. M. and Honkala, B. H. (Eds.), Silvics of North America, Vol. 2: Hardwoods. USDA Agricultural Handbook No. 654.

Ministarstvo zaštite okoliša i energetike i Hrvatska agencija za okoliš i prirodu (2018): Smjernice za planiranje upravljanja zaštićenim područjima i/ili područjima ekološke mreže, UNDP, Hrvatska, dostupno na: http://www.haop.hr/sites/default/files/uploads/dokumenti/04_zasticena/smjernice/Smjernice_za_planiranje_upravljanja_MZOE_HAOP_2018.pdf, siječanj, 2019.

Modabber, A., Peters, F., Kniha, K., Goloborodko, E., Ghassemi, A., Lethaus, B., Möhlhenrich, S. C. (2016): Evaluation of the accuracy of a mobile and a stationary system for three-dimensional facial scanning. *Journal of Cranio-Maxillofacial Surgery*, 44(10), 1719-1724

Moschini-Carlos, V., Henry, R., Pompêo, M. L. (2000): Seasonal variation of biomass and productivity of the periphytic community on artificial substrata in the Jurumirim Reservoir [2pt](São Paulo, Brazil), *Hydrobiologia*, 434(1-3), 35-40.

Müllerová, J., Pyšek, P., Jarošík, V., Pergl, J. A. N. (2005): Aerial photographs as a tool for assessing the regional dynamics of the invasive plant species Heracleum mantegazzianum, *Journal of Applied Ecology*, 42(6), 1042-1053.

Nagendra, H., Lucas, R., Honrado, J. P., Jongman, R. H., Tarantino, C., Adamo, M., Mairota, P. (2013): Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats, *Ecological Indicators*, 33, 45-59.

Nekić, B., Krajnović, A. (2015): Politika zaštite okoliša u RH nakon pristupanja Europskoj uniji, *Tranzicija*, 16(34), 39-58.

Newsome, D., Moore, S. A., Dowling, R. K. (2012): Natural area tourism: Ecology, impacts and management (Vol. 58), UK: Channel View Publications.

Nicolae, C., Nocerino, E., Menna, F., Remondino, F. (2014): Photogrammetry applied to problematic artefacts. The International Archives of Photogrammetry, *Remote Sensing and Spatial Information Sciences*, 40(5), 451.

Nordström, E. M., Holmström, H., Öhman, K. (2013): Evaluating continuous cover forestry based on the forest owner's objectives by combining scenario analysis and multiple criteria decision analysis, Silva Fenn, 47(4).

Novak, N., Kravarščan, M. (2014): Pajasen [Ailanthus altissima (Mill.) Swingle]-strana invazivna biljna vrsta u hrvatskoj, *Glasilo biljne zaštite*, 14(3), 254-261.

Novak, Z. (2007): Optech LiDAR, *Ekscentar,* (10), 24-30.

NSW, (2014): Landholder Guide: Guidelines for Thinning of Native Vegetation under the NSW Native Vegetation Regulation 2013, Office of Environment and Heritage for the NSW Government, Sydney, dostupno na: https://www.environment.nsw.gov.au/resources/vegetation/140273DraftThinningGde.pdf, kolovoz, 2019.

Nyssen, J., Poesen, J., Descheemaeker, K., Nigussie Haregeweyn, Mitiku Haile, Moeyersons, J., Frankl, A., Govers, G., Munro, R.N., Deckers, J., (2008): Effects of region-wide soil and water conservation in semi-arid areas: the case of northern Ethiopia. *Zeitschrift für Geomorphologie*, 52(3), 291-315.

Ohsawa, T., Jones, T. E. (2017): How Can Protected Area Managers Deal with Nonnative Species in an Era of Climate Change?. *Natural areas journal*, 37(2), 240-254.

Okumura, T., Takashima, C., Shiraishi, F., Nishida, S., Kano, A. (2013): Processes forming daily lamination in a microbe-rich travertine under low flow condition at the Nagano-yu hot spring, southwestern Japan, *Geomicrobiology Journal*, 30(10): 910-927.

Okumura, T., Takashima, C., Shiraishi, F., Nishida, S., Yukimura, K., Naganuma, T., Koike, H., Gernot, A., Kano, A. (2011): Microbial processes forming daily lamination in an aragonite travertine, Nagano-yu Hot Spring, Southwest Japan, *Geomicrobiology Journal*, 28(2): 135-148.

Oliveira, G., Bertone, E., Stewart, R., O'Halloran, K. (2017): Understanding and modelling fluorescent dissolved organic matter probe readings for improved coagulation performance in water treatment plants. u: *Proceedings of the 22nd International Congress on Modelling and Simulation*, Hobart, Australia (pp. 3-8).

Olson, D. M., Dinerstein, E. (2002): The Global 200: Priority ecoregions for global conservation, *Annals of the Missouri Botanical garden*, 199-224.

Orlović, A. (2015). Višegodišnje fenološke i ekološke značajke tulara (Trichoptera, Insecta) i mušica svrbljivica (Simuliidae, Diptera, Insecta) na sedrenoj barijeri, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

Ozsoy, U., Sekerci, R., Ogut, E. (2015): Effect of sitting, standing, and supine body positions on facial soft tissue: detailed 3D analysis, *International journal of oral and maxillofacial surgery*, 44(10), 1309-1316.

Palčić, I. (2016): Tourism in figures 2016, Ministarstvo turizma RH, Zagreb, dostupno na: https://www.htz.hr/sites/default/files/2017-06/Tourism_in_figures_ENG_2016.pdf, siječanj, 2019.

Pate, K., Haneberg, W. C. (2011): Photogrammetric and LiDAR 3-D rock slope discontinuity mapping and interpretation surveys to improve baseline information for supporting design and construction of capital improvement projects at hydroelectric facilities, u: *45th US Rock Mechanics/Geomechanics Symposium*, American Rock Mechanics Association.

Patil, P. N., Sawant, D. V., Deshmukh, R. N. (2012): Physico-chemical parameters for testing of water-A review. *International Journal of Environmental Sciences*, 3(3), 1194.

Pazdur A, Pazdur MF, Szulc, J. (1988) Radiocarbon dating of Holocene calcareous tufa in southern Poland, *Radiocarbon*, 30(2): 133-152.

Pedley, M., Andrews, J., Ordonez S., del Cura, M. A. G., Martin, J. A. G., Taylor, D. (1996): Does climate control the morphological fabric of freshwater carbonates? A comparative study of Holocene barrage tufas from Spain and Britain, *Palaeogeography, Palaeoclimatology, Palaeoecology*, 121(3-4): 239-257.

Pedley, H. M., (1994): Prokaryote-microphyte biofilms and tufas: a Sedimentological Perspective. Kaupia (Darmstadter Beitr. Naturgesch.) 4: 45–60.

Pedley, H. M., Rogerson, M. (2010). In vitro investigations of the impact of different temperature and flow velocity conditions on tufa microfabric, *Geological Society, London, Special Publications*, 336(1), 193-210.

Pedley, M. (2000): Ambient temperature freshwater microbial tufas, in: *Microbial sediments, Springer*, 179-186, Berlin, Heidelberg.

Pedley, M., Rogerson, M., Middleton, R. (2009): Freshwater calcite precipitates from in vitro mesocosm flume experiments: a case for biomediation of tufas, *Sedimentology*, 56(2), 511-527.

Pellitero, R., González-Amuchastegui, M. J., Ruiz-Flaño, P., Serrano, E. (2011): Geodiversity and geomorphosite assessment applied to a natural protected area: the Ebro and Rudron Gorges Natural Park (Spain), *Geoheritage*, 3(3), 163-174.

Peña, J. L., Sancho, C., Lozano, M. V. (2000): Climatic and tectonic significance of Late Pleistocene and Holocene tufa deposits in the Mijares River canyon, eastern Iberian Range, northeast Spain, *Earth Surface Processes and Landforms*, 25(13), 1403-1417.

Pentecost, A. (1978): Blue–green algae and freshwater carbonate deposits, Proc. R. Soc. Lond. B, 200(1138), 43-61.

Pentecost, A. (1981): The tufa deposits of the Maliam district, North Yorkshire, Field Studies, 5, 365-387.

Pentecost, A. (2005). *Travertine*, Springer-Verlag, Berlin, 445 pp.

Pentecost, A., Coletta, P. (2007): The role of photosynthesis and CO2 evasion in travertine formation: a quantitative investigation at an important travertine-depositing hot spring, Le Zitelle, Lazio, Italy, *Journal of the Geological Society*. 164(4):843-853.

Pentecost, A., Viles, H. (1994): A review and reassessment of travertine classification, *Géographie physique et Quaternaire*, 48(3), 305-314.

Percoco, G., Guerra, M. G., Salmeron, A. J. S.,Galantucci, L. M. (2017): Experimental investigation on camera calibration for 3D photogrammetric scanning of micro-features for micrometric resolution, *The International Journal of Advanced Manufacturing Technology*, 91(9-12), 2935-2947.

Percoco, G., Lavecchia, F., Salmerón, A. J. S. (2015): Preliminary study on the 3D digitization of millimeter scale products by means of photogrammetry, *Procedia CIRP*, 33, 257-262.

Perica, D., Orešić, D., Trajbar, S. (2005): Geomorfološka obilježja doline i poriječja rijeke Krke s osvrtom na dio od Knina do Bilušića buka, *Geoadria*, 10(2), 131-156.

Petryshyn, V. A., Corsetti, F. A., Berelson, W. M., Beaumont, W., Lund, S. P. (2010). Stromatolite lamination frequency, Walker Lake, Nevada: implications for stromatolites as biosignatures. *Geology*, 40(6): 499-502

Pevalek, I. (1956): Slap Plive u Jajcu na samrti. *Naše starine* III, 269-273.

Phillips, A., World Conservation Union. (2002): Management guidelines for IUCN category V protected areas: Protected landscapes/seascapes (Vol. 9), IUCN--the World Conservation Union.

Phua, M. H., Minowa, M. (2005): A GIS-based multi-criteria decision making approach to forest conservation planning at a landscape scale: a case study in the Kinabalu Area, Sabah, Malaysia, *Landscape and Urban Planning*, 71(2-4), 207-222.

Plant, R. A. (2019): Biomediation of tufa formation by silk capture nets of larval philopotamidae (insecta: trichoptera), Chulalongkorn University, Tropical Natural History 19(2):113-119.

Plummer, L. N., Wigley, T. M. L., Parkhurst, D. L. (1978): The kinetics of calcite dissolution in CO 2-water systems at 5 degrees to 60 degrees C and 0.0 to 1.0 atm CO 2. *American journal of science*, 278(2), 179-216.

Pohekar, S. D., Ramachandran, M. (2004): Application of multi-criteria decision making to sustainable energy planning—a review, *Renewable and sustainable energy reviews*, 8(4), 365-381.

Porter, S. T., Roussel, M., Soressi, M. (2016): A simple photogrammetry rig for the reliable creation of 3D artifact models in the field: lithic examples from the Early Upper Paleolithic sequence of Les Cottés (France), *Advances in Archaeological Practice*, 4(1), 71-86.

Poslončec-Petrić, V. (2010). Distribucija prostornih podataka za potrebe službene kartografije Republike Hrvatske, Doktorska disertacija, Geodetski fakultet, Sveučilište u Zagrebu.

Prato, T., (2006): *Adaptive management of national parks*, George Wright Society 23, 72–86.

Preece, R. C., Day, S. P. (1994): Special Paper: comparison of post-glacial molluscan and vegetational successions from a radiocarbon-dated tufa sequence in Oxfordshire, *Journal of Biogeography*, 463-478.

Pribičević, B., Medak, D., Đapo, A. (2010): Integracija suvremenih geodetsko-hidrografskih mjernih metoda u krškim područjima Republike Hrvatske, *Ekscentar*, (12), 58-63.

Primc-Habdija, B., Habdija, I., Plenković-Moraj, A. (2001): Tufa deposition and periphyton overgrowth as factors affecting the ciliate community on travertine barriers in different current velocity conditions, *Hydrobiologia*, 457(1-3), 87-96.

Prohić, E., Juračić, M. (1989): Heavy metals in sediments—problems concerning determination of the anthropogenic influence Study in the Krka River estuary, eastern Adriatic coast, Yugoslavia, *Environmental Geology and Water Sciences*, 13(2), 145-151.

Radeljak, P., Pejnović, D. (2009): Utjecaj turizma na održivi razvoj funkcionalne regije Nacionalnog parka Krka, *Godišnjak Titius: godišnjak za interdisciplinarna istraživanja porječja Krke*, 1(1), 329-361.

Rahnama, A., Mojtabai, N., Fakhimi, A. (2012): Numerical analysis of room closure rate in an underground potash mine, u: *46th US Rock Mechanics/Geomechanics Symposium*. American Rock Mechanics Association.

Ramos, A. P., Prieto, G. R. (2015): 3D virtualization by close range photogrammetry indoor gothic church apses, The case study of church of San Francisco in Betanzos (La Coruna, Spain), The International Archives of Photogrammetry, *Remote Sensing and Spatial Information Sciences*, 40(5), 201.

Rannow, S., Neubert, M. (2014): *Managing protected areas in central and eastern Europe under climate change*, Springer.

Remondino F, El-Hakim S. (2006): Image-based 3D Modelling: A Review, *The Photogrammetric Record*, 21(115): 269 – 291.

Richardson, D.M. Van Wilgen, B.W. (2004): Invasive alien plants in South Africa: how well do we understand the ecological impacts? *South African Journal of Science*, 100: 45–52.

Ridl, A. (2015): Vodeni kukci mediteranskih sedrenih barijera: specifične zajednice jedinstvenih staništa, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

RIEGL, (2015): Full Waveform Digitizing Airborne Laser Scanner for Wide Area Mapping, dostupno na: http://www.riegl.com/uploads/tx_pxpriegldownloads/DataSheet_LMS-Q780_2015-03-24.pdf, siječanj, 2020

Rodríguez-Martín, M., Lagüela, S., González-Aguilera, D., Rodríguez-Gonzálvez, P. (2015): Procedure for quality inspection of welds based on macro-photogrammetric three-dimensional reconstruction, *Optics & Laser Technology*, 73, 54-62.

Rodríguez-Martín, M., Rodríguez-Gonzálvez, P., Lagüela, S., González-Aguilera, D. (2016): Macro-photogrammetry as a tool for the accurate measurement of three-dimensional misalignment in welding, *Automation in Construction*, 71, 189-197.

Roglić, J. (1967). Prilog poznavanju reljefa jadranskog priobalskog dna. Rad JAZU, 345, 39-54.

Rosen, M. R., Arehart, G. B., Lico, M. S. (2004): Exceptionally fast growth rate of< 100-yr-old tufa, Big Soda Lake, Nevada: Implications for using tufa as a paleoclimate proxy, *Geology*, 32(5), 409-412.

Roush, W., Munroe, J. S., Fagre, D. B. (2007): Development of a spatial analysis method using ground-based repeat photography to detect changes in the alpine treeline ecotone, Glacier National Park, Montana, USA, *Arctic, Antarctic, and Alpine Research*, 39(2), 297-308.

Rubinić, J., Goreta, G., Giljušić, M., Marguš, D., Radišić, M., Zwicker Kompar, G., Kompar, D., (2017): Hidrologija Krke – utjecaji i promjene, Zbornik radova: Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj, Javna ustanova „Nacionalni park Krka“, 705 - 720, Šibenik, 2017.

Ruwanza, S., Gaertner, M., Esler, K. J., Richardson, D. M. (2013): Both complete clearing and thinning of invasive trees lead to short-term recovery of native riparian vegetation in the W estern C ape, S outh A frica. *Applied Vegetation Science*, 16(2), 193-204.

Saaty, T. L. (2008): Decision making with the analytic hierarchy process, *International journal of services sciences*, 1(1), 83-98.

Šakić, K. (2017): Buk – Glasnik Javne ustanove „Nacionalni park „Krka“, Javna ustanova „Nacionalni park Krka“, Šibenik, dostupno na: http://np-krka.hr/upload/clanci/2018/12/2018-12-19/497/buk16katia.pdf, oužujak, 2019.

Salmon, J. (2014): State of: Close-Range Photogrammetry, dostupno na: http://www.xyht.com/lidarimaging/state-of-close-range-photogrammetry/, travanj, 2019.

Samaan, M., Héno, R., Pierrot-Deseilligny, M. (2013): Close-range photogrammetric tools for small 3D archeological objects, ISPRS-International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences*, 1(2), 549-553.

Sand-Jensen, K., J. R. Mebus, (1996): Fine-scale patterns of water velocity within macrophyte patches in streams. *Oikos,* 76: 169–180.

Šandrić, S. (2016): *Usporedba kakvoće vode rijeke Krke na mjernim postajama unutar NP u 2014. godini*, Završni rad, Međimursko veleučilište u Čakovcu, Čakovec.

Santoši, Ž., Šokac, M., Korolija-Crkvenjakov, D., Kosec, B., Soković, M., Budak, I. (2015): Reconstruction of 3D models of cast sculptures using close-range photogrammetry. *Metalurgija*, 54(4), 695-698.

Schenk, T. (2005): *Introduction to photogrammetry*, The Ohio State University, Columbus, 106.

Schneider, D. C. (1994): *Quantitative ecology: spatial and temporal scaling*, Elsevier.

Schnitzer, W. A. (1974): Kalkinkrustation und Kalksinterknollen in Lias-Quellwässern bei Elsenberg (Bl. Erlangen-Nord). *Geologische Blatter für Nordost Bayern und Angrenzende Gebiete*, 24:188-191.

Seminati, E., Talamas, D. C., Young, M., Twiste, M., Dhokia, V., Bilzon, J. L. (2017): Validity and reliability of a novel 3D scanner for assessment of the shape and volume of amputees' residual limb models. PloS one, 12(9), e0184498.

Shah, P. B., Luximon, Y. (2017): Review on 3D scanners for head and face modeling. In *International Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management* (pp. 47-56). Springer, Cham.

Shiraishi, F., Okumura, T., Takahashi, Y., Kano, A. (2010): Influence of microbial photosynthesis on tufa stromatolite formation and ambient water chemistry, SW Japan. *Geochimica et Cosmochimica Acta* 74, no. 18 (2010): 5289-5304.

Šargač, J. (2010): *Planktonske zajednice u umjetnim ujezerenjima potoka Jankovac (Papuk)*, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

Šemnički, P., Previšić, A., Ivković, M., Čmrlec, K., Mihaljević, Z. (2012): Tufa barriers from a caddisfly's point of view: Streams or lake outlets?. *International Review of Hydrobiology*, 97(6), 465-484.

Šikić Z., (2007): *Plan upravljanja Nacionalnim parkom Plitvička jezera*, Ministarstvo kulture Republike Hrvatske, Zagreb.

Šiljeg, A, Barada, M, Marić, I, Roland, V. (2018): The effect of user-defined parameters on DTM accuracy—development of a hybrid model. *Applied Geomatics*. 11(1), 81-96. doi:10.1007/s12518-018-0243-1

Šiljeg, A. (2013): *Digital terrain model in the analysis of geomorphometrical parameters–the example of nature park lake Vrana*, Doktorska disertacija, Prirodoslovno-matematički fakultet, Geografski odsjek, Sveučilište u Zagrebu.

Šiljeg, A., Lozić, S., Marić, I. (2017). Kvantitativna analiza horizontalne strukture krajobraza PP Vransko jezero, *Annales-Anali za Istrske in Mediteranske Studije-Series Historia et Sociologia*, 27(3), 563.

Simard, M., Zhang, K., Rivera-Monroy, V. H., Ross, M. S., Ruiz, P. L., Castañeda-Moya, E., Twilley, R.R., Rodriguez, E. (2006): Mapping height and biomass of mangrove forests in Everglades National Park with SRTM elevation data, *Photogrammetric Engineering & Remote Sensing*, 72(3), 299-311.

Skarlatos, D., Menna, F., Nocerino, E., Agrafiotis, P. (2019): Precision Potential of Underwater Networks for Archaeological Excavation Through Trilateration and Photogrammetry. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(2/W10), 175-180.

Sladonja, B., Poljuha, D., Sušek, M., Dudaš, S. (2014): Herbicidal effect of Ailanthus altissima leaves water extracts on Medicago sativa seeds germination. In *3rd Conference with International Participation: Conference VIVUS on Agriculture, Environmentalism, Horticulture, Floristics, Food Production and Processing.*

Sladonja, B., Sušek, M., Guillermic, J. (2015): Review on invasive tree of heaven (Ailanthus altissima (Mill.) Swingle) conflicting values: assessment of its ecosystem services and potential biological threat, *Environmental management*, 56(4), 1009-1034.

Slukan Altić, M. (2007): Instrukcija za arhivare mapa-prva arhivistička uputa za specijalizirane arhive, *Vjesnik Istarskog arhiva*, 8(2001.-2003.)), 81-103.

Smith, M. W., Carrivick, J. L., Quincey, D. J. (2016): Structure from motion photogrammetry in physical geography. *Progress in Physical Geography*, 40(2), 247-275.

Smith, M. W., Vericat, D. (2015). From experimental plots to experimental landscapes: topography, erosion and deposition in sub-humid badlands from structure-from-motion photogrammetry, *Earth Surface Processes and Landforms*, 40(12), 1656-1671.

Soles S, Brady AL, Southam G, Lim DS, Slater GF. (2012): Isotopic signatures and growth rates of freshwater microbialites in Kelly Lake, A*merican Geophysical Union Fall Meeting*, Abstract B13A-0459.

Soloviy, K., Malovanyy, M. (2019): Freshwater ecosystem macrophytes and microphytes: development, environmental problems, usage as raw material. Review. *Environmental Problems, 3 (4), 2019*, (3), 115-124.

Spate, A. P., Jennings, J. N., Smith, D. I., Greenaway, M. A. (1985): The micro-erosion meter: use and limitations, *Earth Surface Processes and Landforms*, 10(5), 427-440.

Špoljar, M., Štafa, D., Ostojić, A., Dražina, T., Matoničkin Kepčija, R., Kralj Borojević, K., Primc, B. (2011): Tufa deposition in a karst stream as an indicator of water quality (Papuk Nature Park, Croatia). *Croatian Journal of Fisheries*, 69(4), 137-151.

Špoljarić, D., Kranjec, M., Medak, F., Šoštar, K. (2010): Modern Topographic Survey and Geovisualisation of Palagruža Archipelago Needed in Interdisciplinary Research. *Geodetski list*, 64(2), 87-106.

Srdoč, D., Horvatinčić, N., Ahel, M., Giger, W., Schaffner, C., Bronić, I. K., Petricioli, D., Pezdič, J., Marčenko, E., Plenković-Moraj, A. (1992): Anthropogenic influence on the ^{14}C

activity and other constituents of recent lake sediments: a case study, *Radiocarbon*, 34(3), 585-592.

Srdoč, D., Horvatinčić, N., Obelić, B., Bronić, I. K., Sliepčević, A. (1985): Procesi taloženja kalcita u krškim vodama s posebnim osvrtom na Plitvička jezera, Jugoslavenska akademija znanosti i umjetnosti, Zagreb.

Stephenson, W. J., Finlayson, B. L. (2009): Measuring erosion with the micro-erosion meter—contributions to understanding landform evolution, *Earth-Science Reviews*, 95(1-2), 53-62.

Stockdon, H. F., Doran, K. S., Sallenger Jr, A. H. (2009): Extraction of lidar-based dune-crest elevations for use in examining the vulnerability of beaches to inundation during hurricanes, *Journal of Coastal Research*, 59-65.

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.

Stylianidis, E., Patias, P., Tsioukas, V., Sechidis, L., Georgiadis, C. (2003): A digital close-range photogrammetric technique for monitoring slope displacements, In *11th International Symposium on Deformation Measurements*.

Suarez, D. L. (1983): Calcite supersaturation and precipitation kinetics in the Lower Colorado River, All-American Canal and East Highline Canal, *Water Resources Research*, 19(3), 653-661.

Sumner, T. A., Riddle, A. T. (2008): A virtual paleolithic: assays in photogrammetric three-dimensional artifact modelling, *PaleoAnthropology*, 2008, 158-169.

Sviben, S. (2012): Utjecaj osedravanja na makroalge i epifitsku faunu u Prošćanskom jezeru, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

Swetnam, T. W., Allen, C. D., Betancourt, J. L. (1999): Applied historical ecology: using the past to manage for the future, *Ecological applications*, 9(4), 1189-1206.

Takekawa, J. Y., Woo, I., Athearn, N. D., Demers, S., Gardiner, R. J., Perry, W. M., Neil K. G., Shellenbarger G. G., Schoellhamer, D. H. (2010): Measuring sediment accretion in early tidal marsh restoration, *Wetlands ecology and management*, 18(3), 297-305.

Ternjej, I. Plenković-Moraj, A., Mihaljević, Z., Kerovec, M. (2010): Spatial and temporal variation of plankton in a mediterranean karstic lake, *Ekológia* (Bratislava), 29(1), 65-86.

Tetkov, M. (2016): Naseljavanje makrozoobentosa u mahovinama sedrenih barijera, Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, Zagreb.

Thomas, L., Middleton, J. (2003): *Guidelines for management planning of protected areas* (Vol. 10). GlandCambridge: Iucn.

Thorpe, P. M. (1981) Isotope studies of UK tufa deposits and associated source waters, DPhil thesis, University of Oxford, 302 pp

Tran, H., Rott, E., Sanders, D. (2019). Exploring the niche of a highly effective biocalcifier: calcification of the eukaryotic microalga Oocardium stratum Nägeli 1849 in a spring stream of the Eastern Alps. *Facies*. 65(3), 37.

Trentini, C. P., Campanello, P. I., Villagra, M., Ritter, L., Ares, A., Goldstein, G. (2017): Thinning of loblolly pine plantations in subtropical Argentina: Impact on microclimate and understory vegetation. *Forest Ecology and Management*, 384, 236-247.

Trifilo, P., Raimondo, F., Nardini, A., Lo Gullo, M. A., Salleo, S. (2004): Drought resistance of Ailanthus altissima: root hydraulics and water relations, *Tree Physiology*, 24(1), 107-114.

Trpčić. M. (2016): Sedra i slapovi krških rijeka u slijevu Korane, u: *Prirodoslovlje, Hrvatski prirodoslovci 25, Znanstveni skup Odjela za prirodoslovlje i matematiku Matice hrvatske*, Karlovac, 303-317.

Turner, M.G., Gardner, R.H. (Eds.), (1991): *Quantitative Methods in Landscape Ecology*, Springer, New York.

Tushev, S., Sukhovilov, B., Sartasov, E. (2017, October): Architecture of industrial close-range photogrammetric system with multi-functional coded targets. In *2017 2nd International Ural Conference on Measurements (UralCon)* (pp. 435-442). IEEE

Uhde, B., Hahn, W. A., Griess, V. C., Knoke, T. (2015): Hybrid MCDA methods to integrate multiple ecosystem services in forest management planning: a critical review. *Environmental management*, 56(2), 373-388.

UNEP-WCMC, IUCN and NGS (2018): Protected Planet Report 2018. UNEP-WCMC, IUCN and NGS: Cambridge UK; Gland, Switzerland; and Washington, D.C., USA, dostupno na: https://livereport.protectedplanet.net/pdf/Protected_Planet_Report_2018.pdf, ožujak, 2019.

Uredba o standardu kakvoće voda (NN 89/2010), dostupno na: http://zakon.poslovna.hr/public/uredba-o-standardu-kakvoce-voda/525995/zakoni.aspx, lipanj, 2019

van Wilgen, B. W. (2012): Evidence, perceptions, and trade-offs associated with invasive alien plant control in the Table Mountain National Park, South Africa. *Ecology and Society*, 17(2).

Vatavuk, A. (2018): Uloga JU NP Krka u poticanju turističkog razvoja Šibensko-kninske županije, Diplomski rad, Veleučilište u Šibeniku, Šibenik.

Vázquez-Urbez, M., Arenas, C., Sancho, C., Osácar, C., Auqué, L., Pardo, G. (2010): Factors controlling present-day tufa dynamics in the Monasterio de Piedra Natural Park (Iberian Range, Spain): depositional environmental settings, sedimentation rates and hydrochemistry, *International Journal of Earth Sciences*, 99(5), 1027-1049.

Verhoeven, G., Sevara, C., Karel, W., Ressl, C., Doneus, M., Briese, C. (2013): Undistorting the past: New techniques for orthorectification of archaeological aerial frame imagery, In *Good Practice in Archaeological Diagnostics* (pp. 31-67). Springer, Cham.

Verma, A. K., Bourke, M. C. (2019): A method based on structure-from-motion photogrammetry to generate sub-millimetre-resolution digital elevation models for investigating rock breakdown features, *Earth Surface Dynamics,* 7(1), 45-66.

Vilà, M., Tessier, M., Suehs, C. M., Brundu, G., Carta, L., Galanidis, A., Lambdon, P., Manca, M., Medail, F., Moragues, E., Traveset, A., Troumbis, Y.A., Hulme, E.P (2006): Local and regional assessments of the impacts of plant invaders on vegetation structure and soil properties of Mediterranean islands, *Journal of Biogeography,* 33(5), 853-861.

Viles, H. A., Goudie, A. S. (1990): Tufas, travertines and allied carbonate deposits, *Progress in Physical Geography*, 14(1), 19-41.

Viles, H., Pentecost, A. (2007): Tufa and travertine, in: *Geochemical Sediments and Landscapes,* eds. D. J. Nash, S. J. McLaren, Blackwell Publishing Ltd., 173-199

Vurnek, M., Brozinčević, A., Čulinović, K., Novosel, A. (2018): Challenges in the Management of Plitvice Lakes National Park, Republic of Croatia, in*: National Parks-Management and Conservation, IntechOpen.*

Wackrow, R., Chandler, J. H., Bryan, P. (2007): Geometric consistency and stability of consumer-grade digital cameras for accurate spatial measurement, *The Photogrammetric Record,* 22(118), 121-134.

Wallner, J. (1934). Über die Bedeutung der sog. Chironomidentuffe für die Messung der järlichen Kalkproduktion durch Algen, *Hedwigia*: 74, 176-180.

Walpersdorf, E., Neumann, T., Stüben, D. (2004): Efficiency of natural calcite precipitation compared to lake marl application used for water quality improvement in an eutrophic lake, *Applied geochemistry*, 19(11), 1687-1698.

Webb R.H., Leake S.A., Turner R.M. (2007): The ribbon of green: change in riparian vegetation in the southwestern United States, The University of Arizona Press, Tucson, AZ

Wedding, L. M., Friedlander, A. M., McGranaghan, M., Yost, R. S., Monaco, M. E. (2008): Using bathymetric lidar to define nearshore benthic habitat complexity: Implications for management of reef fish assemblages in Hawaii, *Remote Sensing of Environment*, 112(11), 4159-4165.

Weijermars, R., Mulder-Blanken, C. W., Wiegers, J. (1986): Growth rate observation from the moss-built Checa travertine terrace, central Spain, *Geological Magazine*, 123(3), 279-286.

Wenning, B. (2014): Tree of Heaven: An Exotic Invasive Plant Fact Sheet, Invasive Plants, dostupno na: https://www.ecolandscaping.org/05/landscape-challenges/invasive-plants/tree-of-heaven-an-exotic-invasive-plant-fact-sheet/, siječanj, 2020.

Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., Reynolds, J. M. (2012): 'Structure-from-Motion'photogrammetry: A low-cost, effective tool for geoscience applications, *Geomorphology*, 179, 300-314.

Wilcock, R. J. P. D. Champion J. W. Nagels, G. F. Croker, (1999). The influence of aquatic macrophytes on the hydraulic and physico-chemical properties of a New Zealand lowland stream. *Hydrobiologia* 416: 203–214.

Williams, B. K. (2011): Adaptive management of natural resources—framework and issues, *Journal of environmental management*, 92(5), 1346-1353.

Willis, K. S. (2015): Remote sensing change detection for ecological monitoring in United States protected areas, *Biological Conservation*, 182, 233-242.

Wolfslehner, B., Vacik, H., Lexer, M. J. (2005): Application of the analytic network process in multi-criteria analysis of sustainable forest management, *Forest ecology and management*, 207(1-2), 157-170.

Wróblewski, W., Gradziński, M., Motyka, J., Stankovič, J. (2017): Recently growing subaqueous flowstones: Occurrence, petrography, and growth conditions, *Quaternary International*, 437, 84-97.

Wu, J., (1999): Hierarchy and scaling: extrapolating information along a scaling ladder, Can. J. *Remote Sensing*, 25, 367–380.

Wu, J., Jelinski, D. E., Luck, M., Tueller, P. T. (2000): Multiscale analysis of landscape heterogeneity: scale variance and pattern metrics, *Geographic information sciences*, 6(1), 6-19.

Wu, J., Loucks, O. L. (1995): From balance of nature to hierarchical patch dynamics: a paradigm shift in ecology, *The Quarterly review of biology*, 70(4), 439-466.

Wu, J., Marceau, D., (2002): Modeling complex ecological systems: an introduction, Ecol. Model. 153, 1–6.

Yakar, M., Yilmaz, H. M. (2008): Using in volume computing of digital close range photogrammetry, The International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences*, Vol. XXXVII. Part B3b.

Yamafune, K. (2016): Using Computer Vision Photogrammetry (Agisoft PhotoScan) to Record and Analyze Underwater Shipwreck Sites, Doctoral dissertation, Texas A&M University.

Yanagi, H., Chikatsu, H. (2010): 3D Modeling of Small Objects Using Macrolens in *Digital Very Close Range Photogrammetry. ISPRS Arch*, 38, 617-22.

Yastikli, N. (2007): Documentation of cultural heritage using digital photogrammetry and laser scanning, *Journal of Cultural Heritage*, 8(4), 423-427.

Yoshimura, K., Liu, Z., Cao, J., Yuan, D., Inokura, Y., Noto, M. (2004): Deep source CO2 in natural waters and its role in extensive tufa deposition in the Huanglong Ravines, Sichuan, China. *Chemical Geology*, 205(1-2), 141-153.

Young, G. C., Dey, S., Rogers, A. D., Exton, D. (2017): Cost and time-effective method for multi-scale measures of rugosity, fractal dimension, and vector dispersion from coral reef 3D models, *PloS one*, 12(4), e0175341.

Yu, C. S. (2002). A GP-AHP method for solving group decision-making fuzzy AHP problems. *Computers & Operations Research*, 29(14), 1969-2001.

Yuan, D. (1997): Sensitivity of karst process to environmental change along the PEP II transect, *Quaternary International*, 37, 105-113.

Zavaleta, E. S., Hobbs, R. J., Mooney, H. A. (2001): Viewing invasive species removal in a whole-ecosystem context. *Trends in Ecology & Evolution*, 16(8), 454-459.

Zelić, M. (2017): Upravljanje zaštićenim područjima, aktrakcijska osnova i marketinška strategija NP Krka, Završni rad, Veleučilište u Šibeniku, Odjel menadžmenta, Šibenik.

Zhang, D. D., Zhang, Y., Zhu, A., Cheng, X. (2001): Physical mechanisms of river waterfall tufa (travertine) formation, *Journal of Sedimentary Research*, 71(1), 205-216.

Zhang, J., Boutin, M., Aliaga, D. G. (2006): Robust bundle adjustment for structure from motion. In *2006 International Conference on Image Processing* (pp. 2185-2188). IEEE.

Zhang, J., Wang, H., Liu, Z., An, D., Dreybrodt, W. (2012): Spatial–temporal variations of travertine deposition rates and their controlling factors in Huanglong Ravine, China–A world's heritage site, *Applied geochemistry*, 27(1), 211-222.

Zhang, K., Simard, M., Ross, M., Rivera-Monroy, V., Houle, P., Ruiz, P., Twilley, R, R., Whelan, K. (2008): Airborne laser scanning quantification of disturbances from hurricanes and lightning strikes to mangrove forests in Everglades National Park, USA, *Sensors*, 8(4), 2262-2292.

Zmijanović, L. (2015): Održivi razvoj i upravljanje baštinom zaštićenih područja na primjeru Pokrčja, Godišnjak Titius: godišnjak za interdisciplinarna istraživanja porječja Krke, 6(6-7), 71-90.

Zwicker, G., Rubinić, J. (2004): Water level fluctuations as an indicator of tufa barrier growth dynamics in the Plitvice Lakes, *RMZ-Materials and geoenvironment*, 52(1), 161-163.

IZVORI

Zakon o zaštiti prirode, NN 80/2013, (1658), 28.6.2013., dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2013_06_80_1658.html, siječanj, 2019.

Pravilnik o jedinstvenom vizualnom identitetu sustava upravljanja zaštićenim područjima u Republici Hrvatskoj, NN 108/2014, (2096), 10.9.2014., dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2014_09_108_2096.html, siječanj, 2019.

Pravilnik o topografskoj izmjeri i izradi državnih karata, NN 65/2016 , (1618), 15.7.2016, dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2016_07_65_1618.html, travanj, 2019.

URL 1 http://www.npkrka.hr/stranice/nacionalni-park-krka/2.html, siječanj, 2019.

URL 2 http://www.npkrka.hr/stranice/skradinski-buk/78.html, siječanj, 2019.

URL 3 https://np-plitvicka-jezera.hr/prirodna-i-kulturna-bastina/prirodna-bastina/sedra/, siječanj, 2019.

URL 4 https://www.projectsmart.co.uk/smart-goals.php, siječanj, 2019.

URL 5 http://www.npkrka.hr/stranice/nacionalni-park-krka/2.html, siječanj, 2019.

URL 6 Temeljni strateški dokumenti na kojima se temelji zaštita prirode u RH, https://www.pmf.unizg.hr/_download/repository/HrsakText[2].pdf , siječanj, 2019.

URL 7 Kovač, K. (2020): Sedra - e_skola_kemija - PMF-a, dostupno na: http://eskola.chem.pmf.hr/udzbenik/sedra/sedra_01.php3, veljača, 2019.

URL 8 Karbonatne mineralne sirovine https://rudar.rgn.hr/~mklanfar/nids_mklanfar/TEHNOLOGIJA%20NEMETALA/Karbonati.pdf, veljača, 2019.

URL 9 Kako nastaje sedra? Nacionalni park „Krka“

http://www.npkrka.hr/stranice/kako-nastaje-sedra/51.html, veljača, 2019
URL 10 What Is the Hardness of Limestone?
https://www.hunker.com/12573362/what-is-the-hardness-of-limestone, veljača, 2019.
URL 11 Nacionalni park Plitvička jezera
https://np-plitvicka-jezera.hr/prirodna-i-kulturna-bastina/prirodna-bastina/sedra/, veljača, 2019.
URL 12 https://www.picturesboss.com/pictures/travertine-quarry-26.html, veljača, 2019 **(12)**
URL 13 http://profharwood.x10host.com/GEOL101/Labs/AtlasSedimentary/index.htm, veljača, 2019
URL 14 Parkovi Hrvatske, Ministarstvo zaštite okoliša i prirode i Slobodna Dalmacija d.d
https://www.parkovihrvatske.hr/documents/20181/311591/Bro%C5%A1ura+Parkovi+Hrvatske/2473adc8-579a-478c-a29e-5a47ccc82792, ožujak, 2019. (14)
URL 15 Statut javne ustanove „Nacionalni park Krka“
http://www.npkrka.hr/upload/stranice/2015/02/2015-02-03/136/statutjunpkrka22092014.pdf, ožujak, 2019
URL 16 HAOP, (2015): Mapping and assessment of ecosystem and their services in Croatia, Zagreb, 2015, dostupno na:
http://www.haop.hr/sites/default/files/uploads/dokumenti/03_prirodne/studije/ekosustav/Kartiranje_i_procijena_ekosustava_ENG.pdf, ožujak 2019.
URL 17 http://www.npkrka.hr/stranice/np-krka-suncani-sati/290.html, ožujak, 2019.
URL 18 Državni hidrometeorološki zavod, dostupno na:
https://meteo.hr/klima.php?section=klima_podaci&param=k1&Grad=sibenik, ožujak, 2019.
URL 19 http://biologija.com.hr/modules/AMS/article.php?storyid=9546, ožujak, 2019.
URL 20 http://biologija.com.hr/modules/AMS/article.php?storyid=9422, travanj, 2019
URL 21 https://www.prweb.com/releases/tree/herbicides/prweb9524136.htm, travanj, 2019.
URL 22 https://extension.psu.edu/tree-of-heaven, travanj, 2019
URL 23 https://www.fs.fed.us/database/feis/plants/tree/ailalt/all.html#108, travanj, 2019.
URL 24 https://castateparks.wordpress.com/2018/08/31/a-plea-to-preserve-the-tufa/, travanj, 2019
URL 25 https://www.aaas.org/programs/scientific-responsibility-human-rights-law/overview-geospatial-project, travanj, 2019
URL 26 http://www.ctt.bg.ac.rs/blog/sta-cini-dobar-projekat-indikatori-i-sredstva-verifikacije-i-kako-ih-definisati/, travanj, 2019.
URL 27 http://www.fao.org/3/y5558e/y5558e03.htm, travanj, 2019

URL 28 http://www.gisresources.com/wp-content/uploads/2015/10/geospatial-technology.jpg, travanj 2019
URL 29 https://support.pix4d.com/hc/en-us/articles/202559809-Ground-sampling-distance-GSD-, travanj, 2019.
URL 30 http://www.klubputnika.org/servis/foto-uputstva/88-osnove-fotografije/3584-blenda-zatvarac-ekspozicija-iso, travanj, 2019.
URL 31 https://fotografija.hr/dof-dubinska-ostrina/, travanj, 2019.
URL 32 https://sketchfab.com/blogs/community/focus-stacked-reverse-lens-macro-photogrammetry/, travanj, 2019
URL 33 https://photographylife.com/how-to-focus-in-macro-photography, travanj, 2019.
URL 34 https://digital-photography-school.com/5-situations-when-manual-focus-is-better-than-auto-focus/, travanj, 2019.
URL 35 Section VII - Photogrammetric Surveys, dostupno na: http://www.dot.state.wy.us/files/live/sites/wydot/files/shared/Highway_Development/Surveys/Survey%20Manual/Section%20VII%20-%20Photogrammetric%20Surveys.pdf, travanj, 2019.
URL 36 https://3dscanexpert.com/artec-eva-3d-scanner-review/, travanj, 2019.
URL 37 Artec Eva, dostupno na: https://www.artec3d.com/portable-3d-scanners/artec-eva#specifications, travanj, 2019.
URL 38 https://gomeasure3d.com/blog/how-structured-light-3d-scanners-work-video/, travanj, 2019
URL 39 https://expertphotography.com/difference-between-macro-micro-and-close-up-photography/, travanj, 2019
URL 40 http://wiki.agisoft.com/wiki/Photogrammetry#Absolute_orientation, travanj, 2019.
URL 41 https://www.mathworks.com/help/vision/ug/camera-calibration.html, travanj, 2019.
URL 42 https://www.fondriest.com/environmental-measurements/parameters/water-quality/dissolved-oxygen/, rujan, 2019.
URL 43 https://www.des.nh.gov/organization/divisions/water/wmb/vrap/documents/wq-resultsinfo.pdf, rujan, 2019.
URL 44 http://www.np-krka.hr/clanci/water-quality-Krka-NP/584/en.html, rujan, 2019
URL 45 http://www.jpbuoy.com/key-to-live-data, rujan, 2019.
URL 46 http://jadran.izor.hr/azo/pokazatelj.html?4K03, rujan, 2019
URL 47 https://www.aquaread.com/need-help/what-are-you-measuring/cdom-fdom/, rujan, 2019.

URL 48 http://www.shep.uga.edu/docs/reports/2014-06%20Savannah%20Water%20Quality%20Study%20Final%20Report%20June%202014%20rev%207-15_Part2.pdf, rujan, 2019.

URL 49 https://www.enr.gov.nt.ca/sites/enr/files/oxidation-reduction_potential.pdf, rujan, 2019.

URL 50 http://www.npkrka.hr/stranice/stare-razglednice-newsletter/400.html, studeni, 2019.

URL 51 https://www.zf-laser.com/fileadmin/editor/Datenblaetter/Z_F_IMAGER_5010C_Datasheet_E.pdf, siječanj, 2020

URL 52 https://www.ysi.com/exo2, kolovoz, 2019

URL 53 http://sprega-kamen.com/kamen-u-ponudi/plano-kamen/kamen-plano/, siječanj, 2020

Arhiv Nacionalnog parka "Krka"

Matoničkin Kepčija, R. (2019): Priopćenje putem e-maila

Previšić, A. (2019): Priopćenje putem e-maila

ŽIVOTOPIS

Ivan Marić, mag. geogr.
Sveučilište u Zadru
Odjel za geografiju
Trg kneza Višeslava 9
imaric1@unizd.hr
023/300-814

Matični broj znanstvenika: 357431
orcid.org/0000-0002-9723-6778

Rođen je 28. lipnja 1991. godine u Zadru, Hrvatska. Na Sveučilištu u Zadru 2010. upisao je preddiplomski studij primijenjene geografije, kojeg je završio 2013. Iste godine upisuje diplomski studij primijenjene geografije. Diplomski rad pod naslovom *Primjena GIS-a u analizi tržišta za potrebe trgovačkih centara* obranio je 14. listopada 2015. i stekao akademski stupanj magistra geografije (mag. geogr.).

Kao student je obnašao funkciju demonstratora iz kolegija: *Digitalna kartografija*, *GIScience o geoprostornim informacijama*, *Primjena GIS-a u prostornom planiranju* i *Daljinska istraživanja*. Dvostruki je dobitnik nagrade *Frederic Grisogono* na Odjelu za geografiju (2013/2014. i 2014/2015.) te *Pohvalnice* udruge Hrvatskog geografskog društva-Zadar za odličan uspjeh postignut u akademskoj godini 2012/2013. Od 01. listopada 2016. godine zaposlen je kao asistent na Odjelu za geografiju Sveučilišta u Zadru. Iste godine upisao je poslijediplomski doktorski studij *Jadran – poveznica među kontinentima*, Sveučilišta u Zadru.

Sudjelovao je na desetke stručnih projekata: *HOLISTIC IPA program Jadranske prekogranične suradnje*, *Dikgathlong Dam Tourism Master Plan-Botswana*, *Urban Green Belts Project*, *GIS baza sustava za navodnjavanje Baštica*, *Upravljanje i održavanje makrovegetacije na Skradinskom buku*, *GIS evidencija nekretnina (ENA)*, *Kvantitativna analiza jaruga otoka Paga primjenom modela visoke rezolucije* (Natura Jadera). Od ožujka 2018 suradnik je na uspostavnom istraživačkom projektu Hrvatske zaklade za znanost pod nazivom GAL (*Geospatial Analysis Laboratory*) te projektu *(Re)constructing religioscapes as markers of competing territorial claims in Bosnia and Herzegovina since 1995* u suradnji Sveučilišta u Zadru te Sveučilišta u Pittsburghu.

Napredno koristi GIS i tehnologiju daljinskih istraživanja. Do kolovoza 2019. objavio je 1 knjigu, 15 znanstvenih i 2 stručna rada. Govori, čita i piše engleski te poznaje osnove talijanskog jezika.

POPIS RADOVA

- **Knjiga:**

1) Šiljeg, A., Barada, M., Marić, I. 2018: Digitalno modeliranje reljefa, Alfa i Sveučilište u Zadru, Zagreb.

- **Znanstveni i stručni radovi:**

1) **Marić, I.** Šiljeg, A., Domazetović, F. (2019). Geoprostorne tehnologije u 3D dokumentaciji i promociji kulturne baštine – primjer utvrde Fortica na otoku Pagu // Geodetski glasnik, 1 (2019), 50; 19-44
2) Domazetović, F., Šiljeg, A., Lončar, N., **Marić, I.** (2019): GIS automated multicriteria analysis (GAMA) method for susceptibility modelling. *MethodsX*, doi: 10.1016/j.mex.2019.10.031
3) Domazetović, F., Šiljeg, A., Lončar, N., **Marić, I.** (2019): Development of automated multicriteria GIS analysis of gully erosion susceptibility. *Applied Geography*, 112, 102083.
4) Šiljeg, A., Cavrić, B., **Marić, I.,** Barada, M. (2019): GIS modelling of bathymetric data in the construction of port terminals–An example of Vlaška channel in the Port of Ploče, Croatia. *International Journal for Engineering Modelling*, 32(1 Regular Issue), 17-37.
5) Šiljeg, A., Cavrić, B., Šiljeg, S. **Marić, I.,** Barada, M., (2019): Land Suitability Zoning for Ecotourism Planning and Development of Dikgatlhong Dam, Botswana. *Geographica Pannonica*. 23 (2019) , 2; 76-86
6) Mrđen, S. **Marić, I.** (2018): Demografski depresivna područja u Hrvatskoj: kakva treba biti populacijska politika? *Zbornik Matice srpske za društvene nauke* (167). 687-69.
7) Šiljeg, S., **Marić, I.,** Nikolić, G., Šiljeg, A. (2018): Analiza dostupnosti urbanih zelenih površina u naselju Zadar, Hrvatska. *Šumarski list*, 142(9-10), 487-496.
8) Šiljeg, A. Barada, M. **Marić, I.,** Roland, V. (2018): The effect of user-defined parameters on DTM accuracy—development of a hybrid model. *Applied Geomatics*, 10 (2018), 7; 1-16
9) Šiljeg, S., **Marić, I.,** Cavrić, B. (2018): Pregled razvoja teorija u proučavanju zadovoljstva stanovanjem, *Geoadria*, 23/1, 51-84.
10) **Marić, I.,** Šiljeg, A., Sabolović, M. (2018): Military-Geographic Analysis of Tactical Task Jaguar 1992., *Časopis za suvremenu povijest*, 50/1, 87-11.
11) Marić, I., Šiljeg, A. Cavrić, B. Barada M., Šiljeg, S. (2018): Application of integrated geo-technologies in agricultural land plannning and management - a caste study of agro estate „Baštica“, *Izgradnja,* 72, 576-586.
12) Šiljeg, A., Lozić, S., **Marić, I.** (2017): Kvantitativna analiza horizontalne strukture krajobraza - PP Vransko jezero, *Annales-Anali za Istrske in Mediteranske Studije-Series Historia et Sociologia*, 27/3; 563-580.
13) Šiljeg, A., Roland, V., **Marić, I.** (2017): Izrada tematskih karata na temelju podataka prikupljenih batimetrijskom izmjerom, *Zbornik radova Vizija i izazovi upravljanja zaštićenim područjima prirode u Republici Hrvatskoj - Aktivna zaštita i održivo upravljanje u Nacionalnom parku "Krka", Javna ustanova „Nacionalni park Krka*“, 994-1014.
14) Šiljeg, A., **Marić, I.,** Jurišič, M., Plaščak, I. (2017): Model vidljivosti kao strategija za prevenciju šumskih požara - primjer Zadarske županije, *Šumarski list*, 141/7-8, 339-349.
15) **Marić, I.,** Šiljeg, A. (2017): Analiza tržišnog natjecanja primjenom Huffova modela – primjer trgovačkih centara u naselju Zadru, *Geoadria*, 22/1, 41-64.
16) Šiljeg, A., Jurišić, M., **Marić, I.** (2016): Batimetrijska izmjera jezera Skradinskog buka, *Geodetski list*, V/3, 231-252.
17) Marić, I., Roland, V., i Milošević, R. (2015): Primjena GIS tehnologije u vatrogastvu, *Vatrogastvo i upravljanje požarima*, (1.), 57-71.

POPIS OZNAKA I KRATICA

AD - Apsolute Deviation
AHP - Analytical Hierarchy Process
ALS - Airborne Laser Scanning
ASPRS - American Society for Photogrammetry and Remote Sensing
A-U - Austro-Ugarska
BA - Bundle Adjustment
CDOM - Chromophoric/Colored Dissolved Organic Matter
CI - Consistency Index
CLSM - Confocal Laser Scanning Microscopy
CMD - Current Meter Digitizer
CMD - Coordinate Measuring Macrophotogrammetry Device
CMM - Coordinate Measuring Machine
CMOS - Complementary Metal Oxide Semiconductor
CP - Check Point
CPOM - Coarse Particulate Organic Matter
CR - Consistency Ratio
CRP - Close Range Photogrammetry
CoC - Circle of Confusion
DG - Direct Georeferencing
DMR – Digitalni model reljefa
DO - Dissolved Oxygen
DOC - Dissolved Organic Carbon
DOM - Dissolved Organic Matter
DoF - Depth of Field
DSLR - Digital Single-Lens Reflex
DSM - Digital Surface Model
DSM - Direct Survey Method
DTHRM - Digital Tufa High Resolution Model
DZZP - Državni zavod za zaštitu prirode
EC - Electrical Conductivity
EO - Exterior Orientation
EPPO - European and Mediterenean Plant Protection Organization
EPS - Extracellular Polymeric Substance
FAU - Formazine Attenuation Units
FDOM - Fluorescent Dissolved Organic Matter
FFA - Federal Aviation Administration
FFW - Fast Flow Water
FNU - Formazine Nephlometric Unit
FOV - Field of View
FPOM - Fine Particulate Organic Matter
FTU - Formazine Turbidity Units
GAL - Geospatial Analysis Laboratory
GCP - Ground Control Point
GIS - Geographic Information System
GNSS - Global Navigation Satellite System
GPS - Global Positioning System
GSD - Ground Sampling Distance
GST - Geospatial Technologies
HA - Hydrological Approach

HE - Hidroelektrana
HPD - Hierarchical Patch Dynamics
IMU - Inertial Measurement Unit
IO - Interior Orientation
IUCN - International Union for Conservation of Nature
LAS - LIDAR Data Exchange File
LCS - Local Coordinate System
LiDAR - Light Detection and Ranging
MAE - Mean Absolute Error
MAD - Mean Absolute Deviation
MADM - Multi-Attribute Decision Making
MCDA - Multiple-Criteria Decision Analysis
MCDM - Multiple-Criteria Decision Making
MEM - Modified Micro-Erosion Meter
MFW - Medium Flow Water
MI - Mass Increment
MI – Metoda interpolacija
MODM - Multi-Objective Decision Making
MS - Measuring Surface
MT - Mass Transfer
NaN – Natural Neighbour
NIS - Non-indigenous Species
NP - Nacionalni park
NPK - Nacionalni park „Krka“
NPPJ - Nacionalni park „Plitvička jezera“
NTU - Nephelometric Turbidity Unit
OC – Organic Carbon
ODO - Optical Dissolved Oxygen
OECD - Organisation for Economic Cooperation and Development
ORP - Oxidation–Reduction Potential
pH - Power of Hydrogen
PP - Park prirode
PPB - Parts-per-billion
PPT – Parts-per-thousand
POS - Position Orientation System
PPR - Pulse Repetition Rate
PWP - Plummer-Wigley-Parkhurst
QSU - Quinine Sulfate Units
RH - Republika Hrvatska
RGB - Red Green Blue
RFU - Relative Fluorescence Unit
RI - Random Indeks
RMSE - Root Mean Square Error
RS - Roški slap
RTK - Real Time Kinematic
SB - Skradinski buk
SC - Stepped Cascade
SEM - Scanning Electron Microscope
S_{Ic} - Calcite Saturation Indeks
SIFT - Scale-Invariant Feature Transform

SEM - Scanning Electron Microscope
SfM - Structure from Motion
SfM-MVS - Structure from Motion-Multi View Stereo
SFW - Slow Flowing Water
SD - Standard Deviation
SR - Socijalistička Republika
SW - Stagnant Water
SZ - Spray Zone
TDS - Total Dissolved Solid
TLS - Terrestrial Laser Scanning
TFD - Tufa Formation Dynamics
TGR - Tufa Growth Rate
TER - Tufa Erosion Rate
TOF - Time of Flight
TSS – Total Suspended Solid
UNESCO - The United Nations Educational, Scientific and Cultural Organisation
UAV - Unmanned Aerial Vehicle
UV – Ultraviolet
WHO - World Health Organization

POPIS SLIKA

Slika 1. Izgled Skradinskog buka u A) toplom u odnosu na B) hladno razdoblje 21
Slika 2. Geografski smještaj a) NPK-a u RH-a te b) Šibensko-kninskoj županiji 24
Slika 3. Geografski položaj SB-a u NPK 27
Slika 4. Geografski smještaj testne plohe SB 29
Slika 5. Geografski položaj RS u NPK 30
Slika 6. Shematski prikaz višerezolucijskog (hijerarhijskog) modeliranja 40
Slika 7. GIS-MCDA u paradigmi adaptivnog upravljanja 42
Slika 8. EZ-Ject sustav unošenja herbicida 62
Slika 9. a) Pajsen zaklanja pogled prema Skradinskom buku, b) pajasen raste iz kamena 64
Slika 10. Naslage travertina (Tivoli, Italija) 66
Slika 11. Šupljikava struktura sedre 67
Slika 12. Primjer krivog navođenja sedre kao travertina na službenoj 68
Slika 13. Fotografije skenirajućeg elektronskog mikroskopa (SEM) različitih morfologija sedre 72
Slika 14. Morfološka klasifikacija autohtonih sedrenih naslaga 74
Slika 15. Primjer poprečnog presjeka stromatolitne sedre 75
Slika 16. Kristali kalcita na ljepljivim površinama mahovina i cijanobakterija 76
Slika 17. Izgled Skradinskog buka kroz povijest 82
Slika 18. Odlomljen dio sedrene barijere Ciginovac/Okrugljak (NPPJ) 83
Slika 19. Primjer cvjetanja algi na Roškom slapu 84
Slika 20. Utjecaj mahovina iz roda *Cratoneuron* u formiranju sedre RH (NPPJ) 91
Slika 21. Faze inkrustacije mahovina organskim i anorganskim procesima 92
Slika 22. Izgled testne pločice prije postavljanja (lijevo) i nakon vađenja iz toka (desno) 99
Slika 23. Modificirani mikro-erozijski metar za praćenje dinamike sedrenja 100
Slika 24. Shematski prikaz primjena problema zbijanja (0,53 mm) izvedenog MEM-om 101
Slika 25. Primjer površina na kojima MEM generira velike mjerne pogreške 102

Slika 26. Shematski primjer ograničenja MEM-a u mjerenju jako malih uzoraka sedre 103
Slika 27. Usporedba gustoće uzorkovanja a) MEM-a i b) gustog oblaka točaka 104
Slika 28. Izlazni rezultatu primjenom a) MEM-a te b) trokoordinatnih mjernih uređaja 105
Slika 29. Primjer jednostavnih fotogrametrijskih mjernih sustava u CRP-u 116
Slika 30. Vrsta TLS-a prema načinu skeniranja 123
Slika 31. Sastavnice 3D skenera strukturiranog svjetla 124
Slika 32. Shema metodološkog okvira istraživanja 127
Slika 33. Snimljeno područje NPK – uz označena šira područje A) SB-a i B) RS-a 130
Slika 34. Oblaci točaka (.las format) unutar softvera *Cloud Compare* 131
Slika 35. Shematski prikaz izvođenja DMR iz *LAS Dataseta* 132
Slika 36. Zadane postavke unutar alata *LAS Dataset to Raster* 133
Slika 37. a-b) Isječci Austro-ugarske topografske karte korištene za potrebe analiza c) oznake tokova na širem području SB-a 134
Slika 38. Površina na širem području SB-a koja je primjenom *boolean pristupa* isključena iz odabira najpogodnije testne plohe 136
Slika 39. Standardiziran kriterij nagiba u procesu GIS-MCDA 137
Slika 40. Standardiziran kriterij vertikalne raščlanjenosti u procesu GIS-MCDA 138
Slika 41. Standardiziran kriterij vidljivosti u procesu GIS-MCDA 138
Slika 42. *Z+F Imager5600i* na odabranoj testnoj plohi 142
Slika 43. Gusti oblak točaka testne plohe te isječak a) manjeg dijela iznad vidikovca 143
Slika 44. a) *LAS Dataset* gustog oblaka točaka te b) raspored stajališta TLS-a 143
Slika 45. Oblak točaka s markicama za orijentaciju i georeferenciranje oblaka točaka 144
Slika 46. Točke izdvojene iz gustog oblaka za potrebe izrade hibridnog modela 145
Slika 47. Gusti oblak točaka TLS-a preklopljen s oblakom točaka šireg područja SB-a (aeroLiDAR) 145
Slika 48. Shema ispravka lažnog sinka i lažnog vrha 146
Slika 49. Shema klasificiranja smjera modela površinskog otjecanja vode 147
Slika 50. Pravilna mreža poligona koja je služila za orijentaciju na testnoj plohi 148
Slika 51. Mreža površinskog otjecanja na a) hibridnom modelu te b) A-U karti 149
Slika 52. Prikupljanje točaka lokalne geodetske osnove, ožujak 2017. godine 150
Slika 53. Prikupljanje točaka lokalne geodetske osnove, ožujak 2018. godine 151
Slika 54. Kalibriranje sustava senzora Phantoma 4, ožujak, 2018 151
Slika 55. Screen shotovi najvažnijih koraka u SfM fotogrametriji 153
Slika 56. Stajališta TLS-a korištena u procesu kartiranja vegetacije 154
Slika 57. a) Kartiranje vrste stabala na isječku oblaka točaka između stajališta 13 i 14 155
Slika 58. Primjer ručnog čupanja mladih izdanaka pajasena 156
Slika 59. Lokacije mjerenja protoka vode na testnoj plohi 158
Slika 60. Mjerenje brzine protoka vode na lokaciji P1 (tok Matica kod odmorišta) 159
Slika 61. Mjerenje brzine protoka vode na lokacijama P2-P4 (kod Marasovića jezera) 159
Slika 62. Mjerenje brzine protoka vode na lokacijama P5 (ulaz u tok Vrtnjak) P6 (ulaz u Pačji slap) 159
Slika 63. Mjerenje brzine protoka vode na lokaciji P7 (najnizvodnija točka toka Vrtnjak na testnoj plohi) 160
Slika 64. Postavljanje multiparametnae sonde YSI EXO2 na odabranu lokaciju 160
Slika 65. Lokacija postavljanja multiparametarske sonde na testnoj plohi 161

Slika 66. Osedreni kavez i sonda nakon dvadesetak dana izloženosti toku 161
Slika 67. Screen shot izmjerenih parametara s EXO2 monitora 164
Slika 68. Primjer dnevnih varijacija pH vrijednosti 168
Slika 69. Kretanja vrijednosti temperature vode kroz 2. svibanj, 2019. 169
Slika 70. Kretanja vrijednosti temperature vode i otopljenog kisika kroz srpanj, 2018 171
Slika 71. a) Izgled trokoordinatnog mjernog stroja (CMM) te b) konceptualni model CMD-a 172
Slika 72. Proces izrade mehaničkog okvira CMD-a 173
Slika 73. a) CMD sa svim sastavnicama b) pomična metalna stopa i držači koji fiksiraju pločicu te c) sastavnice LCS-a 174
Slika 74. A) Konceptualni model i B) fizički model LCS-a te C) simuliranje prirasta sedre 175
Slika 75. Snimanje pločice s a) *Spiderom*, b) *Evom* i c) CMD-om 180
Slika 76. Shematski prikaz izračuna preciznosti mjerenja CMD-om 181
Slika 77. Testirane vrste pločica za potrebe praćenja TFD-a 185
Slika 78. Pločice plano postavljene na odabranu testnu plohu 185
Slika 79. Dizajn vapnenačke pločice za praćenje TFD-a 186
Slika 80. Zaštitni plastični omotač koji sprječava nastanak sedre na podnožju bazne pločice 186
Slika 81. Prikupljanje lokacija pločica RTK-GPS-om 187
Slika 82. Lokacije postavljanja pločica na testnoj plohi SB 188
Slika 83. A) Nedostatci na testnoj pločici Kupid B) novi dizajn pločice s kapicama te C) sedre nastala na kapicama tijekom intervalnih vađenja 189
Slika 84. PL 03 i 16 na lokaciji *Bezimena* 190
Slika 85. PL02 i 13 pločice na lokaciji *Tvrda sedra* 191
Slika 86. PL11 i 27 na lokaciji *Sedreni kanjon* 191
Slika 87. PL 10 i 12 na lokaciji *Kod mladog Jasena* 192
Slika 88. PL 19 i 24 na na lokaciji *Kod spomenika* 193
Slika 89. PL04 i 21 na lokaciji *Kod duplog Crnog graba* 194
Slika 90. PL 05 i 18 na lokaciji *Jezerski slapić* 194
Slika 91. PL 06 i 08 na lokaciji *U bršljanu* 195
Slika 92. PL 21 i 26 na lokaciji *Kaskada* 196
Slika 93. PL15 i 28 na lokaciji *Krivo stablo* 196
Slika 94. PL 14 i 29 na lokaciji *Nježna mahovina* 197
Slika 95. PL07 i 25 na lokaciji *Pačji slap* 198
Slika 96. PL23 i 30 na lokaciji *Sedreni zid* 198
Slika 97. PL 09 i PL22 na lokaciji *Jezero šest stabala* 199
Slika 98. Primjeri postavljanja pločica u različita fluvijalna okruženja 200
Slika 99. Pločice nakon vađenja iz vode a) 21/6/18 b) 19/9/18 c) 15/12/18 d) 15/3/19 202
Slika 100. Lokacije postavljanja pločica na testnoj plohi RS 202
Slika 101. PL35 i 40 na lokaciji *Konoplja među smokvama* 203
Slika 102. PL39 i PL41 na lokaciji *Slomljeno svrdlo* 203
Slika 103. PL30 i PL43 na lokaciji *Kod mlinice* 204
Slika 104. Veliki vodostaj na testnoj plohi RS koji je onemogućio vađenje pločica 204
Slika 105. A) PL30, B) PL43 i C) PL41 nakon vađenja iz vode (10. siječanj, 2020). 205
Slika 106. Testiranje *Artec Eve* za potrebe snimanja pločica A) snimanje PL07 (*Pačji slap*) B) obrada skenova u *Artec Studiu* C) teksturirani 3D model pločice 207

Slika 107. Primjer procesa obrade skenova PL30 (završno stanje) A) brisanje nepotrebnih dijelova B) optimizacija položaja C) eliminacija šumova D) oštro spajanje E) dodavanje teksture 208
Slika 108. Primjer prednjeg i bočnog preklapanje susjednih fotografija 210
Slika 109. Primjer procjene pogrešaka na orijentacijskim i kontrolonim točkama (PL_{25}) 211
Slika 110. Proces obrade fotografija u *Agisoft Metashapeu 1.5.1* 212
Slika 111. Shematski prikaz izračuna stope prirasta sedre 213
Slika 112. Primjer izračuna intenziteta erozije i prirasta sedre za PL13 (lipanj-rujan, 2018) 214
Slika 113. Primjeri gašenja vodenih tokova uslijed nekontroliranog rasta vegetacije 215
Slika 114. a) Invazivna vegetacija u blizini sedrotvornih tokova b) primjeri antropogenog utjecaja na hidrodinamiku sedrotvonih vodotokova 216
Slika 115. Blokiranje dotoka vode uslijed izgradnje staze 216
Slika 116. A) Izdvojeni dio DMR-a šireg područja SB-a 217
Slika 117. Georeferencirana A-U karta s kartiranim vodenim površinama 218
Slika 118. Indeks pogodnosti za odabir testne plohe na širem području SB-a 219
Slika 119. Presušeni tokovi kartirani s A-U karte na odabranoj testnoj plohi 220
Slika 120. A) model mreže površinskog otjecanja testne plohe izveden iz hibridnog modela B) korigirana mreža površinskog otjecanja (referentno stanje tokova) 221
Slika 121. Katastar stabala nultog stanja testne plohe 223
Slika 122. Vegetacijske zone testne plohe prema dominantnim vrstama 224
Slika 123. Isječci iz videa u kojem je snimljen proces reaktivacije tokova 225
Slika 124. Primjeri promjena (A, B i C) hidrološke mreže na testnoj plohi 226
Slika 125. Primjeri promjena na testnoj plohi vidljivi iz zraka 227
Slika 126. Poplavljivanje vode iz akumulacije Smokovik sve do zapadne granice plohe 228
Slika 127. Primjeri intervalnih fotografija na kojima je praćena pojava pajasena 229
Slika 128. Primjer poplavljivanja testne plohe 229
Slika 129. A) Reaktivirani slap izvan testne plohe B) posjetitelji slapa snimljeni intervalnom kamerom 230
Slika 130. Kretanje brzine protoka prema odabranim lokacijama u razdoblju ožu.18-ožu.19 231
Slika 131. Godišnje kretanje temperature vode 233
Slika 132. Godišnje kretanje količine otopljenog kisika na lokaciji Mjernik 234
Slika 133. Godišnje kretanje pH vrijednosti 235
Slika 134. Primjer dnevnog kretanja pH vrijednosti (ožujak, 2019) 235
Slika 135. Godišnje kretanje ORP vrijednosti 236
Slika 136. Shematski pristup izračuna kvalitete mjerenja CMD-om 237
Slika 137. A) 3D modeli testne pločice te B) primjer izračuna volumena u *Artec Studiu* 240
Slika 138. a) Primjer DOF-a (PL06) kao osnove za detekciju mikrorganizama na mjernoj površini b) Sedrotvorni mikroorganizam *Simulidae* 245
Slika 139. DTHRM za lokacije od ID01- do 07 246
Slika 140. DTHRM za lokacije od ID08 do 14 247
Slika 141. 3D modeli sedre od ID08 do 14 248
Slika 142. 3D modeli sedre od ID08 do 14 249
Slika 143. DTHRM za lokacije od ID15 do 18 250
Slika 144. 3D modeli sedre od ID15 do 18 250
Slika 145. Prirast sedre (mm a^{-1}) prema lokacijama (ID) 252
Slika 146. Uzorak s najvećom vrijednosti prirasta u jednogodišnjem praćenju 253

Slika 147. DOF A) inicijalnog i B) završnog stanja PL41 s i) nakupinama algi 254
Slika 148. Primjer poprečnog presjeka A-A' na PL25 255
Slika 149. Vertikalni pomak sedre u presjeku A-A' te primjeri uočenih erozivnih događaja 255
Slika 150. Razlika u prirastu sedre između susjednih pločica na svim lokacijama (ID) 257
Slika 151. Zadržavanje i inkrustacija lista na PL15 (*Krivo stablo*) 257
Slika 152. a) PL07 postavljena u neposrednoj blizni mahovina b) mahovine u potpunosti prerasle PL07 b) izvedeni DTHRM PL07 258
Slika 153. a) PL14 postavljena u neposrednoj blizni mahovine b) prostor najvećeg prirasta 259
Slika 154. Razlike (mm) u prirastu sedre prema frekvenciji vađenja 260
Slika 155. Razlike (mm) u prirastu sedre na u hladnom i toplom razdoblju 262
Slika 156. Usporedba visoko-rezolucijskih modela sedre iz fluvijalnog okruženja a) SW i b) SFW u odnosu na c-d) FFW 264
Slika 157. Primjer zadržavanja i inkrustacije lista na mjernoj površini (MS) PL15 i PL10 266
Slika 158. Erozija zabilježena u razdoblju rujan-prosinac, 2018 (PL25) 267
Slika 159. Najveća površina erozivnog događaja zabilježena u razdoblju 267
Slika 160. Primjer uspravnih, cjevastih kalcitna tijela na PL13 a-b) te slični oblici c) navedeni u Plant (2019). 268
Slika 161. Uzorak s najvećom vrijednosti (-4,753 mm a^{-1}) erozije 269
Slika 162. Erozija zabilježena u razdoblju lipanj-rujan, 2018 (PL25) 269
Slika 163. Primjer erozivnog događaja u razdoblju rujan-prosinac, 2018 (PL22) 270
Slika 164. a) Nedostatak erozivnih događaja za PL06 u razdoblju (lipanj, 2018 – rujan, 2018) te b) detektirani erozijski događaji u razdoblju (rujan, 2018. – prosinac, 2018.) 271
Slika 165. Primjer c, d, e) erozije ličinki iz porodice *Simuliidae (*red: *Diptera)* na PL06 272
Slika 166. Primjer c-d) erozije ličinki iz porodice *Chironomidae (Diptera)* na PL25 273
Slika 167. Erozijski događaji na PL13 274
Slika 168. Primjer erozije PL18 i PL24 u šestomjesečnom razdoblju 275
Slika 169. a) PL24 unutar presušenog toka b) skidanje PL24 i PL19 te c) uklanjanje akumuliranog biljnog materijala 276
Slika 170. Isječak iz videa u kojem je vidljiva reaktivacija presušenog toka 277
Slika 171. Primjeri organizama koji su uočeni prilikom vađenja pločica iz protoka 278
Slika 172. Detektirane ličinke vodenih kukaca *Chironomidae* a-b) i *Simuliidae* c) u procesu formiranja sedre na a) PL25, b) PL13 i c) PL06 280
Slika 173. Primjeri ličinki vodenih kukaca *Simuliidae c)* i *Chironomidae* (red: *Diptera*) a-b) 281
Slika 174. Detektirani mikroorganizmi na površini PL25 (lipanj, 2018) 282
Slika 175. Precipitat na PL13 a) lipanj, 2018, b) rujan, 2018 i c) prosinac, 2018. 283
Slika 176. Detektirane mikro rupice na površini sedre PL25 (prosinac, 2018) 283
Slika 177. Precipitat nakon godine dana izloženosti a) PL13 i b) PL02 284
Slika 178. PL25 (lipanj, 2018) *Chironomidae* (red: *Diptera*) 285
Slika 179. Detektirani mikroorganizmi na površini PL25 (lipanj, 2018) 286
Slika 180. Primjeri detektiranih mikroorganizama za površini PL25 (ožujak, 2018) 286
Slika 181. PL25 a) rujan, 2018 b) prosinac, 2018 te c) ožujak, 2019 287
Slika 182. Promjene površine sedre na PL25 288
Slika 183. Površina sedre na PL06 (lipanj, 2018 i rujan, 2018) 289
Slika 184. Površina sedre PL06 i 08 nakon godine dana izloženosti toku 290
Slika 185. PL03 (rujan, 2018) slatkovodni račić te ličinka *Simuliidae (Diptera)* 291

Slika 186. PL03 (ožujak, 2019) cilindrične "stambene" cijevi 292
Slika 187. PL16 (ožujak, 2019) inkrustacija cilindričnih cijevi 292
Slika 188. Detektirani nedeterminirani organizmi na PL16 (ožujak, 2019). 293
Slika 189. Detektirani mikroorganizmi na površini PL16 (ožujak, 2019) 293
Slika 190. Detektirani mikroorganizmi na površini PL03 (ožujak, 2019) 294
Slika 191. a) PL22 (rujan, 2018) b) PL 22 (ožujak, 2019) i c) PL09 (ožujak, 2019) 295
Slika 192. Detektirani mikroorganizmi na površini PL03 (ožujak, 2019) 296
Slika 193. PL18 (rujan, 2018) a) ličinka vodenih kukaca *Simuliidae* te b) otisak ličinke na supstratu 296
Slika 194. PL18 (ožujak, 2019) a) ličinka cjevčastog oblika porodica *Chironomidae* 297
Slika 195. Detektirani mikroorganizmi na površini PL18 (ožujak, 2019) 297
Slika 196. PL05 (ožujak, 2019) a) ličinka cjevastog oblika b) inkrustacija algi 298
Slika 197. Detektirani mikroorganizmi na površini PL05 (ožujak, 2019) 298
Slika 198. a) Inskrustacija algalnih niti PL10 te površina PL10 i 12 nakon godine dana 299
Slika 199. Detektirani mikroorganizmi na površini PL10 (ožujak, 2019) 299
Slika 200. PL24 (rujan, 2018) a) inskrustacija algalnih niti te b) te otisak ličinke cjevčastog oblika porodice *Chironomidae* 300
Slika 201. a) Bijela tekstura PL24 te b) PL19 (ožujak, 2019) 301
Slika 202. Sedrena površina PL15 a) ličinka vodenog kukca b) inkrustacija ličinke 302
Slika 203. Površina sedre PL15 i PL28 a-b) ličinke vodenih kukaca c) otočići mahovine 303
Slika 204. Površina sedre PL29 a) ličinka vodenog kukca te b) inkrustacije ličinke 303
Slika 205. Površina sedre PL29 i PL14 a) ličinke vodenih kukaca i b) nakupine algi 304
Slika 206. Mozaična struktura supstrata na PL23 (rujan, 2018) 305
Slika 207. Površina sedre PL23 i PL30 a) ličinka vodenih kukaca b-c) veliki biljni fragmenti 306
Slika 208. Površina sedre PL27 sa specifičnom teksturom 306
Slika 209. Površina sedre PL27 i 11 307
Slika 210. PL26 (ožujak, 2019) a) ličinka cjevastog oblika porodica *i b)* PL01 308
Slika 211. Zeleno-smeđa tekstura PL04 i 21 (ožujak, 2019) 309
Slika 212. Dinamika formiranja sedre na pločicama vađenima u tromjesečnim intervalima 310

POPIS TABLICA

Tablica 1. Kategorije zaštićenih područja u RH 47
Tablica 2. Broj posjetitelja u nacionalnim parkovima RH 50
Tablica 3. Izdvojeni akcijski planovi iz Plana upravljanja NPK 52
Tablica 4. Glavne razlike u značajkama travertina i sedre 65
Tablica 5. Pregled obilježja nekih aktivnih sedrotvornih sustava 77
Tablica 6. Pregled stopa prirasta sedre (mm a^{-1}) u svijetu 95
Tablica 7. Semantika Saatyeve skale 139
Tablica 8. Matrica usporedbe stupnja utjecaja između kriterija 139
Tablica 9. Izvedeni težinski koeficijenti odabranih kriterija 140
Tablica 10. Osnovne specifikacije *Z+F Imager5600i* 142
Tablica 11. Specifikacije STONEX-a S10 148
Tablica 12. Specifikacija UAV Phantom 4 150
Tablica 13. Specifikacije uređaja za mjerenje brzine protoka vode 158

Tablica 14. Specifikacije sonde YSI EXO2 162
Tablica 15. Parametri mjerenja sonde YSI EXO2 162
Tablica 16. Razina eutrofikacije prema koncentraciji klorofila a 166
Tablica 18. Primjer fizikalno-kemijskih podataka grupiranih po danima (1. srpanj, 2018) 169
Tablica 19. Primjer fizikalno-kemijskih podataka grupiranih po mjesecima (srpanj, 2018). 170
Tablica 20. Specifikacije *DSLR NIKON D5300* 176
Tablica 21. Specifikacije makro objektiva *Venus LAOWA 60mm* 177
Tablica 22. Unutarnji orijentacijski parametri kamere 178
Tablica 23. Plan usporedbe modela te vađenje i snimanje pločica na testnoj plohi SB 200
Tablica 24. Klasifikacija i opis fluvijalnih okruženja postavljanja pločica 201
Tablica 25. Pločice postavljene na testnoj plohi RS 205
Tablica 26. Katastar stabala odabrane testne plohe 222
Tablica 27. Brzina protoka (m/s) prema lokacijama mjerenja 230
Tablica 28. Grupirani podaci izmjerenih parametara 233
Tablica 29. Razlike između izmjerenih i procijenjenih vrijednosti kontrolnih točaka u pet različitih mjerenja 238
Tablica 30. Razlike između izmjerenih i procijenjenih vrijednosti GCP-a unutar pet različitih mjerenja 239
Tablica 31. X, Y i Z vrijednosti označenih uzoraka (n = 10/70) za pet mjerenja (1-5M) 241
Tablica 32. Primjer izračunatih srednjih vrijednosti uzoraka (n = 10/70) za x, y i z koordinate 241
Tablica 33. Izračun odstupanja svakog uzorka od srednje vrijednosti x, y i z koordinata u svakom mjerenju (n=5) 242
Tablica 34. Izračunata srednja SD i MAD na temelju 70 uzoraka 242
Tablica 35. Relativna nesigurnost CMD-a za X, Y i Z koordinatu 244
Tablica 36. Stopa prirast sedre prema pojedinačnim pločicama i lokacijama 251
Tablica 37. Stope prirasta sedre za pločice na testnoj plohi RS 254
Tablica 38. Statistički parametri izvedeni iz presjeka A-A' 256
Tablica 39. Stope sedrenja (mm a^{-1}) u različitim fluvijalnim okruženjima 263
Tablica 40. Volumetrijski prirast sedre (mm^3) za intervalno snimane pločice 265
Tablica 41. Erozija (mm^3) sedre izvedena za intervalno snimane pločice 265