Geoprostorne tehnologije u modeliranju i promociji zaštićenih područja na primjeru jezera Zmajevo oko

Panđa, Lovre

Master's thesis / Diplomski rad

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:162:596899

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Sveučilište u Zadru
Universitas Studiorum
Jadertina | 1396 | 2002 |

Repository / Repozitorij:

University of Zadar Institutional Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zadru

Odjel za geografiju
Diplomski jednopredmetni sveučilišni studij primijenjene geografije

Lovre Panđa

Geoprostorne tehnologije u modeliranju i promociji zaštićenih područja na primjeru jezera Zmajevo oko

Diplomski rad

Zadar, 2020.

Sveučilište u Zadru

Odjel za geografiju

Diplomski jednopredmetni sveučilišni studij primijenjene geografije

Geoprostorne tehnologije u modeliranju i promociji zaštićenih područja na primjeru jezera Zmajevo oko

Diplomski rad

Student/ica: Lovre Panđa

Mentor/ica: izv. prof. dr. sc. Ante Šiljeg

Zadar,2020.

Izjava o akademskoj čestitosti

Ja, **Lovre Panđa,** ovime izjavljujem da je moj **diplomski** rad pod naslovom **Geoprostorne tehnologije u modeliranju i promociji zaštićenih područja na primjeru jezera Zmajevo oko** 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, 17. srpanj 2020.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zadru

Odjel za geografiju Diplomski rad

GEOPROSTORNE TEHNOLOGIJE U MODELIRANJU I PROMOCIJI ZAŠTIĆENIH PODRUČJA NA PRIMJERU JEZERA ZMAJEVO OKO

Lovre Panđa

Izvadak

Posljednjih desetljeća geoprostorne tehnologije je zahvatio proces ubrzanog razvoja. Uz ostalo, one su omogućile dokumentaciju trenutnog stanja i izradu modela visoke kvalitete u svrhu očuvanja i promocije zaštićenih područja. Područje istraživanja ovoga diplomskog rada je jezero Zmajevo oko kod Rogoznice. Aerofotogrametrijom za koju je korištena bespilotna letjelica *Phantom 4 Pro*, opremljena fotoaparatom visoke razlučivosti, obuhvaćeno je vodno lice jezera i šire obalno područje u tampon zoni od 100 m. Batimetrijskom izmjerom, za koju se po prvi put u RH koristio integralni mjerni sustav kombinacija višesnopnog dubinomjera *WASSP S3* i *Hemisphere V320 GNSS* pametne antene, obuhvaćeno je dno jezera. Podaci prikupljeni objema metodama spojeni su te je izrađen integralni model jezera visoke kvalitete. Uspješno je detektirano deset podvodnih tunela (pukotina) na bočnim stranama jezera. Na temelju 2.5D i 3D modela izračunati su volumen, površina i duljina obalne linije jezera. Točnost modela dobivenog aerofotogrametrijom iznosi < 5 cm. Vertikalna preciznost, nefiltriranih podataka, integralnog mjernog sustava iznosi 6,8 cm, a horizontalna 11,8 cm. U programu *Lumion* izrađena je virtualna šetnja jezerom u svrhu promocije, a pomoću 3D printera *Prusa i3 MK3* ispisan je i fizički model jezera koji može poslužiti kao suvenir. Prikupljeni podaci visoke kvalitete predstavljaju temelj za buduća istraživanja na ovom zaštićenom području.

Ključne riječi: Zmajevo oko; Hrvatska; geoprostorne tehnologije; aerofotogrametrija; batimetrija; WASSP S3; modeli visoke rezolucije; virtualna šetnja; 3D printer

Voditelj: izv. prof. dr. sc. Ante Šiljeg

Povjerenstvo: prof. dr. sc. Josip Faričić; izv. prof. dr. sc. Ante Šiljeg; doc.dr.sc. Denis Radoš

BASIC DOCUMENTATION CARD

University of Zadar

Department of Geography Graduation thesis

GEOSPATIAL TECHNOLOGIES IN MODELING AND PROMOTION OF PROTECTED AREAS ON THE EXAMPLE OF LAKE ZMAJEVO OKO

Lovre Panđa

Abstract

In recent decades, geospatial technologies have been affected by a process of rapid development. Among other things, they enabled the documentation of the current situation and the development of high quality models for the purpose of preserving and promoting protected areas. The research area of this graduation thesis is Lake Zmajevo oko near Rogoznica. Aerial photogrammetry, for which a *Phantom 4 Pro* UAV equipped with a high-resolution camera was used, covered the water face of the lake and the wider coastal area in the buffer zone of 100 m. The bathymetric survey, for which, for the first time in the Republic of Croatia, an integrated measuring system of combinations of the *WASSP S3* multi-beam depth sounder and the *Hemisphere V320 GNSS smart antenna* was used, covered the bottom of the lake. The data collected by both methods were combined and an integrated model of a high quality lake was developed. Ten underwater tunnels (cracks) on the sides of the lake were successfully detected. Based on the 2.5D and 3D models, the volume, area, and length of the lake shoreline were calculated. The accuracy of the model obtained by aerial photogrammetry is < 5 cm. The vertical precision of unfiltered data of the integral measuring system is 6.8 cm, and the horizontal is 11.8 cm. In the *Lumion* software, a virtual walk through the lake was made for the purpose of promoting. A physical model of the lake, which can serve as a souvenir, was printed by the help of the 3D printer *Prusa i3 MK3*. The collected high quality data are the basis for future research in this protected area.

Keywords: Zmajevo oko; Croatia; geospatial technologies; aerial photogrammetry; bathymetry; WASSP S3; high resolution models; virtual walk; 3D printer

Supervisor: Associate Professor Ante Šiljeg, PhD

Reviewers: Professor Josip Faričić, PhD; Associate Professor Ante Šiljeg, PhD; Assistant Professor Denis Radoš, PhD

Sadržaj

Predgovor 6

1. Uvod 7

1.1. Objekt i cilj istraživanja 8

1.2. Svrha istraživanja 9

1.3. Hipoteze 9

1.4. Pregled dosadašnjih istraživanja 10

2. Područje istraživanja 13

3. Teorijska osnova 14

3.1. Geoprostorne tehnologije 14

3.1.1. Aerofotogrametrija 15

3.1.2. Batimetrijska izmjera 16

3.1.2.1. Metode i tehnike batimetrijske izmjere 16

3.1.2.1.1. Jednosnopni dubinomjeri 17

3.1.2.1.2. Višesnopni dubinomjeri 18

3.1.3. Virtualna stvarnost 19

3.1.4. 3D printer 20

3.2. Primjena geoprostornih tehnologija u promociji zaštićenih područja 20

4. Metodologija istraživanja 21

4.1. Aerofotogrametrija jezera Zmajevo oko 21

4.1.1. Označavanje i prikupljanje točaka lokalne geodetske osnove 23

4.1.2. Izrada plana zračnog snimanja jezera Zmajevo oko 26

4.1.3. Kalibracija bespilotne letjelice *Phantom 4 Pro* 27

4.1.4. Proces obrade zračnih snimaka 28

4.1.5. Ispitivanje točnosti modela izvedenih procesom aerofotogrametrije 31

4.1.6. Generiranje gustog oblaka točaka u *Agisoft Metashape Professional 1.5.1* 31

4.2. Batimetrijska izmjera jezera Zmajevo oko 32
4.2.1. Plan batimetrijske izmjere 32
4.2.2. Integralni mjerni sustav kombinacija RTK GPS i višesnopnog dubinomjera 32
4.2.2.1. Višesnopni dubinomjer *WASSP S3 Multibeam* 33
4.2.2.1.1. Softveri *CDX* i *Data Manager* 35
4.2.2.1.2. Sonda 38
4.2.2.1.3. Inercijalni mjerni sustav 39
4.2.2.2. *Hemisphere V320 GNSS Smart Antenna* 40
4.2.3. Sekundarni podaci i kalibracija sustava za prikupljanje podataka 41
4.2.4. Prikupljanje i obrada batimetrijskih podataka 43
4.2.5. Ispitivanje vertikalne i horizontalne preciznosti integralnog mjernog sustava 46
4.2.6. Uređivanje podataka 50
4.2.7. Filtracija podataka primjenom *SOR filter-a* 52
4.2.8. Interpolacija podataka prikupljenih batimetrijskom izmjerom 52
4.2.9. Prostorna rezolucija 53
4.3. Izračun volumena, površine i duljine obalne linije jezera Zmajevo oko 53
4.4. Izvođenje virtualne šetnje jezerom Zmajevo oko 55
4.5. 3D ispis jezera Zmajevo oko 56
5. Rezultati 58
5.1. Točnost modela izrađenih procesom aerofotogrametrije 58
5.2. Gusti oblak točaka 59
5.3. 2.5D i 3D modeli jezera Zmajevo oko 60
5.4. Vertikalna i horizontalna preciznost integralnog mjernog sustava 63
5.5. Podvodni tuneli (pukotine) 70
5.6. Integralni modeli jezera Zmajevo oko 71
5.7. Volumen, površina i duljina obalne linije jezera Zmajevo oko 73

5.8. Virtualna šetnja jezerom Zmajevo oko 73
5.9. Suvenir jezera Zmajevo oko 75
6. Rasprava i zaključak 76
Literatura 79
Izvori 87
Popis grafičkih priloga 88
Popis tabličnih priloga 91
Sažetak 93
Summary 94

Predgovor

Kvantitativna revolucija u geografiji ponudila je nova, moderna i nikad preciznija metodološka rješenja u modeliranju fizičko-geografskih stanja, pojava i procesa. Geoprostorne tehnologije iz dana u dan postaju sve kvalitetnije i dostupnije, a modeli sve realističniji. Iza toga velikog napretka stoji cijela 'vojska' znanstvenika koji su svoj život posvetili izradi brojnih patenata i algoritama koje danas koristimo 'zdravo za gotovo'. Današnji komercijalni projekti su nezamislivi bez kvalitetnih digitalnih modela. Što su kvalitetniji modeli to su kvalitetnija i predviđanja kako u geografskom tako i u financijskom ili bilo kojem drugom pogledu. Stoga, nije samo ljudska znatiželja, želja za stalnim napredovanjem i usavršavanjem te ispitivanjem granica mogućnosti ono što gura znanost prema naprijed već i sve zahtjevnije tržište. Zadatak nas geografa kao interdisciplinarnih znanstvenika je povezati više znanosti te oformiti multidisciplinarne timove ljudi koji će zajedničkim snagama usavršavati stare i stvarati nove prostorne koncepte.

Ovaj diplomski rad je napravljen u sklopu projekta *Batimetrijska i geodetska izmjera jezera Zmajevo oko* pod vodstvom izv. prof. dr. sc. Ante Šiljega, a rezultat je gospodarske suradnje Sveučilišta u Zadru i Javne ustanove za upravljanje zaštićenim područjima i drugim zaštićenim dijelovima prirode Šibensko-kninske županije.

Ovim putem želio bih zahvaliti svom mentoru izv.prof.dr.sc. Anti Šiljegu koji je svojim znanjem i iskustvom, ali i velikom strašću za geoprostornim tehnologijama uvelike pridonio mojoj odluci da se želim baviti GIS-om. Hvala i dr. sc. Nevenu Cukrovu i Marinu Lovriću s Instituta Ruđer Bošković na pomoći pri prikupljanju terenskih podataka. Hvala i tvrtci Prehnit d.o.o. koja je ustupila 3D printer *Prusa i3 MK3* za potrebe izrade fizičkog modela. Veliko hvala i kolegama dr. sc. Ivanu Mariću te mag. geogr. Franu Domazetoviću na brojnim savjetima pri pisanju ovoga diplomskog rada. Hvala i svim profesorima Odjela za geografiju koji su mi kroz ove godine prenijeli brojna nova znanja koja će mi poslužiti u daljnjem radu u ovoj struci. Veliko hvala i članovima povjerenstva za obranu i ocjenu ovoga diplomskog rada: prof.dr.sc. Josipu Faričiću i doc.dr.sc. Denisu Radošu na komentarima, konstruktivnim kritikama i savjetima. Posebne zahvale mojoj obitelji, sestri Valentini, djedu Slovenu, baki Mariji i djevojci Dajani koji su cijelo vrijeme bili uz mene i pružali mi podršku na mom putu prema diplomi. Na posljetku, najveće hvala mojim roditeljima Ivici i Sendi koji su se najviše žrtvovali kako bi mi omogućili visoko obrazovanje i najbolje uvjete tijekom cijelog studiranja. Njihova ljubav i potpora su ono što me najviše inspiriralo svih ovih godina.

1. Uvod

Modeliranje ima važnu ulogu u razumijevanju prirodnih procesa na Zemljinoj površini (Blaszczynski, 1997; Bishop i dr., 2012). U početcima terenskih istraživanja, modeliranje Zemljine površine vršilo se na licu mjesta (Blaszczynski, 1997; Shroder i Bishop, 2003), no razvojem geoprostornih tehnologija (geografski informacijski sustav (GIS), globalni položajni sustav (GPS) i daljinska istraživanja (RS – *remote sensing*)) za prikupljanje i obradu podataka (Bodzin i Cirucci, 2009; Mareddy i dr., 2017; Šiljeg i dr., 2018), u posljednjih dvadesetak godina (Bodzin i Cirucci, 2009; Jackson i dr., 2009; Bishop i dr., 2012; Šiljeg i dr., 2018), došlo je do revolucije u geomorfometriji (Pike, 2000; Gessler i dr. 2009; Guth, 2013). Proces izrade digitalnog modela reljefa i izvođenja analiza na temelju njega naziva se digitalno modeliranje reljefa (Šiljeg i dr, 2018). Model je objekt ili koncept koji se koristi za predstavljanje nečega drugog, odnosno pojednostavljena stvarnost pretvorena u oblik koji možemo razumjeti (Meyer, 1995; Wu i Marceau, 2002). Prema tome, modeliranje je proces kojim se uspostavlja veza između oblika i procesa na Zemljinoj površini i modela. Ovisno o svrsi istraživanja, geoprostorne tehnologije u modeliranju kompleksnih procesa i oblika omogućuju različite razine detaljnosti (Šiljeg, 2019). U svrhu poboljšanja kvalitete modela, s ciljem analize, vizualizacije i interpretacije, izrađuju se integralni modeli. To su modeli izrađeni od podataka prikupljenih različitim metodama i tehnikama (Fabris i dr., 2010; Abdalla, 2016). Ovisno o objektu, cilju i svrsi istraživanja primjenjuju se različite vrste geoprostornih tehnologija. Batimetrija, kao znanost o mjerenju i kartiranju dubina, izuzetno je bitna pri izradi modela koji uključuju vodene površine (Kearns i Breman, 2010), dok primjerice aerofotogrametrija i laserska (LiDAR) tehnologija imaju veoma važnu ulogu pri stvaranju kvalitetnih digitalnih modela kopnenih područja (Fabris i dr. 2010). Velik napredak i sve veća dostupnost moderne tehnologije, omogućili su 3D dokumentaciju, konzervaciju i digitalnu promociju zaštićenih područja i objekata (Remondino i Rizzi, 2010; Cipolla-Ficarra, 2012). 3D dokumentacija podrazumijeva prikupljanje, obradu, reproduciranje i prezentiranje geoprostornih podataka kroz određivanje položaja, oblika i dimenzija nekog objekta ili područja u trodimenzionalnom prostoru u svrhu očuvanja trenutnog stanja (Marić i dr., 2019) kulturne (Manić i dr., 2013; Marić i dr., 2019) i prirodne baštine (Leonov i dr., 2011; Bishop i dr., 2012). UNESCO (1972) koristi termin "prirodna baština" za fizičke, biološke i geološke značajke, formacije i mjesta iznimne vrijednosti s estetskog ili znanstvenog stajališta (Boehler i dr., 2001). Proučavanje prirodne baštine uvelike ovisi o očuvanosti jer globalne klimatske promjene, prirodne katastrofe, masovni turizam, terorizam te ljudski nemar uvelike utječu na

promjene u krajoliku, a samim time i na zaštićena područja (Marić i dr., 2019). Brz razvoj tehnologije virtualne stvarnosti (VR – *virtual reality*) nudi mogućnost upotrebe modernih tehnologija u svrhu turizma (Bruno i dr., 2010; Leonov i dr., 2011; Tussyadiah i dr., 2018). One mogu pružiti značajne informacije o odredištu potencijalnim putnicima te biti pripremni korak u fazi namjere putovanja (Manić i dr., 2013; Huang i dr., 2015). Također, upotrebom suvremenih 3D printera omogućuje se nov i kreativan pristup izradi suvenira. To podrazumjeva personalizaciju, a s time i unikatnost, jer turist može sam sudjelovati u procesu izrade vlastitog suvenira (Anastasiadou i Vettese, 2019). Stoga je promocija zaštićenih prirodnih i kulturnih područja, pomoću modernih geoprostornih tehnologija neophodna želi li se ostati u korak sa suvremenim zahtjevima turizma.

1.1. Objekt i cilj istraživanja

Objekt istraživanja je modeliranje jezera Zmajevo oko kod Rogoznice (Slika 1) primjenom geoprostornih tehnologija. Aerofotogrametrija je korištena za snimanje vodnog lica i širega obalnog područja jezera s ciljem dobivanja podatka o površini jezera i duljini obalne linije kao i zbog izrade modela visoke rezolucije u svrhu bolje vizualizacije područja istraživanja. Batimetrijsko istraživanje, kao primarni cilj ovoga diplomskog rada je izvršeno pomoću višesnopnog dubinomjera kako bi se dobili podaci o dubini i volumenu jezera te podvodnim tunelima kojima je jezero povezano s morem. Virtualnom šetnjom je cilj približiti područje istraživanja krajnjem korisniku, koji će moći na temelju integriranih podataka prikupljenih batimetrijom i aerofotogrametrijom prošetati oko jezera. Također, pomoću istih podataka kao i za virtualnu šetnju ispisat će se jezero na 3D printeru te će se dobiti model jezera koji je moguće dalje koristiti kao suvenir.

Cilj istraživanja je utvrditi vertikalnu i horizontalnu preciznost integralnoga mjernog sustava kombinacija RTK GPS i višesnopnog dubinomjera s obzirom na to da je isti prvi put korišten u Republici Hrvatskoj te dobiti informacije o osnovnim karakteristikama jezera (površina, volumen, dubina, duljina obalne linije).

Slika 1. Geografski položaj A) Republike Hrvatske, B) Rogoznice i C) jezera Zmajevo oko (prema: DGU, 2020 (DOF))

1.2. Svrha istraživanja

Istraživanje jezera Zmajevo oko provedeno je iz više razloga: izrade batimetrijske karte (modela visoke rezolucije), kartiranja tunela (pukotina), dokumentacije trenutnog stanja jezera, vizualizacije jezera (virtualna šetnja jezerom), izrade suvenira i promocije kulturne baštine. Primarna svrha istraživanja je izrada detaljne batimetrijske karte upotrebom *WASSP S3 Multibeam* višesnopnog dubinomjera. Dobiveni model visoke rezolucije će osim u znanstvene svrhe poslužiti i u promociji ovoga specifičnog područja kroz izradu suvenira i 3D vizualizaciju. Dokumentacija trenutnog stanja jezera omogućit će praćenje promjena u morfologiji dna kao i tunela (pukotina) kojima je povezano s morem.

1.3. Hipoteze

Polazne hipoteze ovoga diplomskog rada utemeljene su na pretpostavkama da će korištene geoprostorne tehnologije omogućiti prikupljanje podataka, detekciju specifičnih reljefnih oblika i generiranje visoko-kvalitetnih modela. One glase:

- Korištena operativna frekvencija (160 kHz) omogućit će kartiranje stvarnog dna jezera.
- Točnost izrađenog modela procesom aerofotogrametrije bit će manja od 5 cm.
- Preciznost integralnog mjernog sustava (kombinacija višesnopnog dubinomjera *WASSP S3* i *Hemisphere V320 GNSS* pametne antene) bit će manja od 5 cm.
- Integralni mjerni sustav omogućit će detekciju podvodnih tunela (pukotina).

1.4. Pregled dosadašnjih istraživanja

S obzirom na to da je u ovom diplomskom radu korišteno nekoliko različitih metoda prikupljanja podataka, u procesu proučavanja literature fokus je stavljen na svaku metodu posebno i na radove koji su svojom metodologijom relevantni za ovaj diplomski rad. Također su proučeni geografski i geološki radovi o Zmajevom oku, radovi kojima je ono jedini predmet istraživanja kao i oni u kojima se o njemu piše u kontekstu njegove morfogeneze, hidroloških specifičnosti s naglaskom na utjecaj promjene razine mora.

Anastasiadou i Vettese (2019) u svom radu istražuju mišljenje turista o 3D ispisu suvenira. Zaključuju kako su mišljenja pozitivna, osobito kad se radi o uključenosti turista u izradu vlastitog suvenira. Svatko može više ili manje sudjelovati u personalizaciji i sa svojim doprinosom učiniti suvenir unikatnim što ga čini trajnom uspomenom na posjećeno područje. Stoga je izrada fizičkog modela pomoću 3D printera svakako potrebna u promociji zaštićenih područja.

Bakran-Petricioli i dr. (1998) pišu o jezeru Zmajevo oko u kontekstu utjecaja izolacije i jedinstvenih ekoloških značajki na bioraznolikost. Spominju kako je geološko podrijetlo jezera povezano s urušavanjem krova kaverne uzrokovanog postglacijalnim izdizanjem razine mora. Povezanost jezera podvodnim tunelima i pukotinama s okolnim morem argumentiraju prisutnošću utjecaja morskih mijena. Pišu i o gotovo stalnoj stratifikaciji vodenog stupca u jezeru (temperatura, salinitet, koncentracija kisika, prisustvo H_2S) te anoksičnim uvjetima u pridnenom sloju vode.

Bishop i dr. (2012) u svom radu ističu kako modeliranje reljefa ima važnu ulogu u razumijevanju procesa na Zemljinoj površini, upravljanju prirodnim resursima, upravljanju rizicima od katastrofa, praćenju promjena u krajoliku, ali i razumijevanju geološke kronologije nastanka određenih reljefnih oblika. Naglašavaju kako je relativno novi napredak geoprostornih tehnologija pokrenuo revoluciju u modeliranju reljefa.

Bura-Nakić i dr. (2012) pišu o Zmajevom oku kao jedinstvenom primjeru anoksičnog sustava ne samo na obali Jadrana već i cijelog Mediterana. Proučavaju sezonsku stratifikaciju u vodenom stupcu i utjecaj meteoroloških uvjeta na miješanje vode. Zaključuju kako prebrzo izdizanje sulfata s dna može uzrokovati anoksične uvjete u cijelom jezeru.

Cipolla-Ficarra (2012) naglašava da dobar upravitelj zajednice za lokalnu baštinu mora brinuti o promociji iste upotrebom suvremenih tehnologija koje su se dokazale kao efikasan alat u očuvanju i promociji kulturne i prirodne baštine. U radu se nalaze sveukupne smjernice dvaju projekata koji pokušavaju postići najvišu kvalitetu sa smanjenim troškovima. Zaključuje da lokalna i globalna promocija kulturnih i prirodnih dobara uz pomoć novih tehnologija može biti izrazito uspješna ako je stvorena sinergija između lokalnih vlasti, stanovnika tog područja i programera multimedijalnih sadržaja.

Fabris i dr. (2010) navode u svom radu kako uz lasersku, odnosno LiDAR (*Light Detection and Ranging*) tehnologiju, aerofotogrametrija i batimetrija uz pomoć višesnopnog dubinomjera imaju veoma važnu ulogu u stvaranju digitalnih modela terena (DTM) kopnenih i podmorskih područja. Ističu da je integriranje spomenutih istraživačkih tehnika presudno za pružanje točnih i homogenih DTM-ova duž uskih obalnih područja koji se često ne mogu adekvatno ispitati zbog logističkih ograničenja prikupljanja batimetrijskih podataka u plitkoj vodi.

Kearns i Breman (2010) pišu o važnosti batimetrije, odnosno o njenoj primjeni u sigurnoj plovidbi, vojsci, industriji itd. Opisuju razne metode i tehnike batimetrijske izmjere. Objašnjavaju kako su podaci prikupljeni, prikazani i primijenjeni. Između ostalog opisuju i princip rada te prednosti i nedostatke višesnopnog dubinomjera koji je korišten u istraživanju vezanom uz ovaj diplomski rad.

Lenov i dr. (2011) u svom radu prezentiraju projekt razvoja 3D dokumentacije Doline gejzira na Kamčatki koja je pod zaštitom UNESCO-a. Autori pišu o tome kako reljef može biti digitalno rekonstruiran pomoću raznih izvora podataka kao na primjer povijesnih topografskih karata, satelitskih podataka te podataka prikupljenih aerofotogrametrijom ili laserskim snimanjem. Ističu kako je precizna i vizualno realna rekonstrukcija krajolika nužna za postizanje kvalitetnog VR efekta i kako veća razlučivost znači i veću količinu podataka, a samim time teži *web* pristup. Zaključuju kako odabir izvora podataka prvenstveno ovisi o tehničkim i financijskim mogućnostima.

Manić i dr. (2013) ističu kako je napredak informatičko-komunikacijske tehnologije pružio mogućnost novim načinima primjene tehnologije u svrhu promocije kulturne baštine te naglašavaju važnost očuvanja kulturne baštine kroz njenu digitalizaciju. Napominju kako *web* stranice, društvene mreže i različite aplikacije mogu pridonijeti promociji kulturne baštine, posebno među mladima koji uglavnom koriste te tehnologije za informiranje, zabavu i obrazovanje. Iste metode se mogu primijeniti i za promociju prirodnih dobara.

Marić i dr. (2019) u svom radu koristili su geoprostorne tehnologije u svrhu 3D dokumentacije i promocije kulturne baštine. Korištena je aero i bliskopredmetna fotogrametrija kako bi se dobili model visoke rezolucije utvrde Fortica na Pagu. Izrađena je i virtualna šetnja korištenjem moderne vizualizacijske tehnike (VR), dok je 3D printerom za potrebe promocije, kao suvenir, izrađen fizički model utvrde. Upravo je metodologija ovoga originalnog znanstvenog rada imala važnu ulogu u ostvarenju teme diplomskog rada.

Remondino i Rizzi (2010) raspravljaju o tehnikama, problemima i primjerima 3D dokumentacije prirodne i kulturne baštine. Navode da razvojem novih tehnologija raste i pritisak za dokumentacijom u svrhu očuvanja kulturne i prirodne baštine. Ističu da je za izradu 3D modela velikih zaštićenih područja izrazito bitno zadovoljiti određene kriterije. To su: točnost i preciznost modela (osim ako nije riječ o brzoj i jednostavnoj vizualizaciji), pokretnost (mogućnost pristupa nepristupačnim lokacijama, dostupnost električne energije i razna druga ograničenja), niska cijena (većina istraživanja ima ograničen budžet kojim ne može financirati skupu opremu), brza realizacija (većina zaštićenih područja ima određeno vrijeme pogodno za dokumentaciju kako se ne bi ometalo radnike ili turiste) i fleksibilnost (mogućnost primjene tehnike u različitim mjerilima u bilo kojim uvjetima). Naglašavaju da nije uvijek moguće napraviti dokumentaciju određenog područja samo jednom tehnikom te da se u većini slučajeva izrađuju integralni modeli iz podataka prikupljenih raznim metodama i tehnikama.

Surić (2005) piše kako je Zmajevo oko morsko jezero nastalo urušavanjem krova kaverne izazvanog gubitkom plutajuće potpore, koju je pružala morska voda, nakon kasne pleistocensko-holocenske transgresije. Cirkulacijom morske vode, koja se vrši kroz okršeno podzemlje i pukotine u jezero, dospijevaju razni morski organizmi koji omogućavaju bioerozijske procese i iza obalne crte mora. Zaključuje kako je svaka krška značajka rezultat gotovo jedinstvene kombinacije geoloških, geomorfoloških i hidroloških postavki i da se niti

jedan od tih procesa, generiranih interakcijom krša i morske vode, ne smije shvaćati općenito već da pri istraživanju treba imati poseban pristup prema svakom takvom lokalitetu.

Šiljeg i dr. (2016) poseban naglasak stavljaju na važnost odabira odgovarajućeg programskog paketa, metode interpolacije i prostorne rezolucije potrebnih za izradu kvalitetnih modela te važnost vizualizacije podataka u svrhu promocije jezera, educiranju i podizanju svijesti o zaštiti prirodnih fenomena.

2. Područje istraživanja

Batimetrijskom izmjerom bilo je obuhvaćeno područje jezera Zmajevo oko (Slika 2), dok je aerofotogrametrijskim snimanjem, s ciljem izrade integralnog modela, bilo obuhvaćeno šire obalno područje jezera u tampon zoni od 100 metara.

Područje Zmajevog oka je specifična cjelina koju karakterizira velika vertikalna raščlanjenost na malom području (gotovo 50 metra). Smješteno je na poluotoku Gradina koji je tankom prevlakom spojen s kopnom te okružen uvalama Soline i Koprišće. Jezero površinski nije spojeno s morem, ali je podzemnim tunelima (pukotinama) u kršu. Na to ukazuju slanost vode, prisutnost mediolitoralne stepenice i izmjena morskih mijena (Bakran-Petricioli i dr., 1998; Surić, 2005).

Također, specifična su i fizikalno-kemijska svojstva. Jezero obilježavaju nagle promjene u temperaturi, salinitetu i gustoći uzrokovane slabim miješanjem vode, geomorfološkim obilježjima i meteorološkim uvjetima. Naime, jezero je prirodno zaklonjeno od vjetra s obzirom na to da je smješteno u kotlini. Upravo je to jedan od glavnih razloga stalne kemijske stratifikacije jezera (Ciglenečki i dr., 1996; Bakran-Petricioli i dr., 1998; Bura-Nakić i dr., 2012). Pridneni sloj karakterizira debeli sloj sumporovodika zbog kojeg je voda mutna i bijela u tom dijelu. Prisutna je i anoksija, odnosno odsustvo kisika uzrokovano meromiksijom tj. slabim miješanjem vode u vodenom stupcu (Bakran-Petricioli i dr., 1998; Bura-Nakić i dr., 2007; Bura-Nakić i dr., 2012).

Sve navedene specifičnosti utjecale su na izbor metoda batimetrijske izmjere te izbor misija u aerofotogrametrijskom snimanju. Za batimetrijsku izmjeru korištena je najmodernija tehnika – integralni mjerni sustav, kombinacija višesnopnoga ultrazvučnog dubinomjera i RTK-GPS-a. Tehnologija je za razliku od jednosnopnoga ultrazvučnog dubinomjera omogućila arealno snimanje dna jezera pod kutem u rasponu od 4 do 120 stupnjeva.

Slika 2. Područje izmjere – Zmajevo oko

3. Teorijska osnova

3.1. Geoprostorne tehnologije

Modeliranje ima važnu ulogu u razumijevanju svih procesa na Zemljinoj površini (Bishop i dr., 2012). Pojavom geoprostornih tehnologija, odnosno GIS-a, GPS-a i RS-a, ostvaren je brz napredak u kvaliteti modeliranja (Bodzin i Cirucci, 2009; Jackson i dr., 2009; Bishop i dr., 2012; Šiljeg i dr., 2018). Geoprostorni podaci dostupni su na internetu te im je moguće pristupiti sa svih platformi koje imaju mogućnost povezivanja na internetsku mrežu.

Geoprostorne tehnologije omogućuju vizualizaciju, kartiranje i analizu više slojeva georeferenciranih podataka te su se dokazale kao vrijedan alat u procesu razumijevanja okoliša i donošenja odluka. Sposobnost korištenja, analize te tumačenja slika i karata postaje sve važnije u mnogim znanstvenim i ekonomskim područjima. Prostorno razmišljanje obuhvaća znanje i vještine korištenja prostornih koncepata, karata i grafova te procesa zaključivanja u svrhu organiziranja i rješavanja problema (Bodzin i Cirucci, 2009).

3.1.1. Aerofotogrametrija

Fotogrametrija je znanstvena disciplina i tehnologija dobivanja pouzdanih kvantitativnih informacija o objektima na Zemlji, procesom snimanja, označavanja, mjerenja, analiziranja i interpretacije fotografskih snimaka i prikaza elektromagnetskog zračenja dobivenih senzorskim sustavima (Matthews, 2008; Ahmad i Samad, 2010; Barilar i dr., 2015). Najširu primjenu ima aerofotogrametrija, metoda u kojoj su kamere pričvršćene na posebna žiroskopski stabilizirana postolja iznad otvora na podu zrakoplova (Wawro, 2013). Obilježava je velika gustoća prikupljanja podataka koja se prilagođava konkretnom projektu i morfološkim osobinama terena. Zahtijeva manje terenskog rada, pokriva velika područja, pogodna je za mjerenja u opasnim i nepristupačnim područjima i primjenjuje se u različitim oblastima. Najveći problem kod ove metode predstavlja vegetacija i optička vidljivost terena sa snimališta. Kao jedno od glavnih i trenutno najpopularnijih tehnoloških dostignuća fotogrametrije uključuje razvoj bespilotnih zrakoplovnih sustava (UAV) i njima pripadajućih algoritama za obradu fotogrametrijskih podataka. Oni imaju mogućnost snimanja opasnih i nepristupačnih terena bez ugroze ljudskih života, ali i snimanje iz mnogo veće blizine nego što je to moguće nekom drugom vrstom letjelice (Eisenbeiß, 2009). Bespilotne letjelice imaju mogućnost manualnog, poluautonomnog i autonomnog upravljanja, što omogućuje planiranje misija leta u svrhu pravilne i potpune pokrivenosti terena zračnim snimkama. Kamere mogu biti mjerne (poznati elementi unutarnje orijentacije) i nemjerne (nema točno određene elemente unutarnje orijentacije). Pri izvođenju aerofotogrametrijskih i bliskopredmetnih mjerenja (ako se upotrebljava nemjerna kamera) nužno je precizno odrediti parametre unutarnje kalibracije (žarišna daljina i koordinata glavne točke snimke po osima X i Y, zakošenost piksela, radijalna i tangencijalna distorzija), tj. kameru je potrebno kalibrirati (Remondino i Fraser, 2006). Važni su i vanjski parametri orijentacije (*Jaw, Pitch i Roll*) koji se odnose na položaj kamere u prostoru u odnosu na objekt snimanja. Također, potrebno je kalibrirati i bespilotnu letjelicu te u softveru izraditi prikladan plan snimanja. Ovisno o planu

snimanja te specifikacijama i kalibracijskim parametrima kamere i bespilotne letjelice varirat će i kvaliteta izlaznih rezultata.

3.1.2. Batimetrijska izmjera

Kartiranje dna oceana, mora, rijeka i jezera jedna je od najstarijih aktivnosti čiji je cilj izrada karata i kartama srodnih prikaza. Pomorci već tisućama godina mjere dubine kako bi omogućili sigurnu plovidbu (Kearns i Breman, 2010). U današnje vrijeme, nacionalne vlade, vojska, telekomunikacijske kompanije, naftne korporacije i akademske institucije kartiraju dno s ciljem dobivanja egzaktnih podataka koji imaju višestruku primjenu u brojnim granama gospodarstva (IHO, 2005; Kearns i Breman, 2010) poput turizma (Ferreira i dr., 2009), eksploatacije prirodnih resursa (Medved i dr., 2010), proširenja lučkih terminala (Šiljeg i dr., 2019), gradnje mostova (Kuspilić i dr., 2010), podzemnih tunela (Aykut i Akpınar, 2013) ili pak komunalne infrastrukture (Snellen i dr., 2011; Nonnis i dr., 2016) te zaštite prirodnih dobara (Wilson i dr., 2007; Medak i dr., 2008; Letessier i dr., 2016).

Hidrografija je grana fizičke oceanografije koja se bavi mjerenjima i definiranjem konfiguracije dna oceana, mora, jezera, rijeka i drugih oblika vodenih površina na Zemlji (NOAA, 1976; IHO, 2005; Šiljeg, 2013). Batimetrija je grana hidrografije koja se odnosi na mjerenje i kartiranje dubina za određivanje topografskih obilježja dna vodenih površina. Svi podaci o dubinama trebaju imati koordinate u nekom od koordinatnih sustava, u pravokutnom koordinatnom sustavu to su X i Y koordinate (predstavljaju položaj mjerenja ili horizontalnu poziciju) i Z koordinate (predstavljaju dubinu ili vertikalnu poziciju) koji vrijede za ravninu u odgovarajućoj kartografskoj projekciji, a u geografskom koordinatnom sustavu to su geografska širina (φ) , geografska dužina (λ) i dubina (h). Batimetrija se može vršiti pomoću raznih sredstava poput satelita, zrakoplova, brodova, podmornica i podmorskih platformi korištenjem raznih metoda i tehnika (Kearns i Breman, 2010).

3.1.2.1. Metode i tehnike batimetrijske izmjere

Ovisno o kompleksnosti projektnog zadatka (krajnja upotreba i veličina istraživanog područja), postoje različite metode i tehnike batimetrijske izmjere koje se razlikuju prema standardu točnosti. Najveći standard točnosti je na komercijalnim projektima. Srednji standard točnosti je na projektima stanja, dok je najniži na projektima generalnog poznavanja (IHO, 2005; Sciortino, 2010).

Batimetrija se može obaviti pomoću dubinomjernog viska, dubinomjerne motke, jednostavnoga inženjerskog dubinomjera (zapis dubina na papiru) i naprednoga inženjerskog dubinomjera (u potpunosti automatizirano). Ovisno o korištenju instrumenata, mjerenje se definira kao direktno i indirektno (IHO, 2005; Šiljeg, 2013). Posljednjih nekoliko desetljeća batimetrijsko istraživanje je napredovalo pojavom jednosnopnih (*singlebeam*) i višesnopnih dubinomjera (*multibeam*) te zračnih laserskih sustava (*airborne laser sounding*) koji imaju mogućnost prikupljanja podataka velike gustoće i omogućuju realističan prikaz dna (Šiljeg i dr., 2018). Jednosnopni i višesnopni ultrazvučni dubinomjeri funkcioniraju na principu mjerenja vremenskog zaostatka zvučnog signala odaslanog iz sonde, dok zračni laserski sustavi funkcioniraju na principu mjerenja vremena potrebnog laserskim zrakama (infracrvenim i zelenim) da se vrate u laserski altimetar (Whiteway, 2009; Kearns i Breman, 2010; Aykut i Akpınar, 2013; Šiljeg, 2013). Ultrazvučni dubinomjeri su najčešće korištene metode batimetrijske izmjere jer imaju najbolji omjer cijene i kvalitete prikupljenih podataka (Šiljeg, 2013).

3.1.2.1.1. Jednosnopni dubinomjeri

Ultrazvučna tehnologija je široko primijenjena metoda prikupljanja podataka o dnu vodenih površina koja na temelju vremenskog zaostatka i intenziteta zvuka daje korisne podatke o izgledu i sastavu dna (Amiri-Simkooei i dr., 2011; Ferretti i dr., 2015). Jednosnopni dubinomjer je ultrazvučni dubinomjer koji na temelju vremenskog zaostatka zvučnih impulsa odaslanih sa sonde uronjene u vodu računa dubinu. (Whiteway, 2009; Kearns i Breman, 2010; Aykut i Akpınar, 2013; Šiljeg, 2013). Vremenski zaostatak se računa na temelju brzine zvuka u vodi koja ovisi o salinitetu, temperaturi i tlaku (dubini) (Kearns i Breman, 2010; Šiljeg, 2013). Osim za trup broda (Kearns i Breman, 2010), sonda (*transducer*) može biti montirana i na šipku ili može biti vučena za brodom (Letessier i dr., 2016). Jednosnopni dubinomjeri prikladni su za generiranje profila dna i najčešće su korišteni za mjerenje dubina neposredno ispod plovila, odnosno za snimanje manjih dijelova uskih ponora s ciljem utvrđivanja njihove dubine (Kearns i Breman, 2010). S obzirom na to da kut snimanja iznosi manje od 3°, potrebno je jako puno vremena kako bi se snimilo dno određene vodene površine pa se preporučuje snimanje po unaprijed isplaniranim i jednako udaljenim profilima kako bi prostor koji nije obuhvaćen snimanjem mogao biti interpoliran prikladnom metodom interpolacije (Medak i dr., 2008; Kearns i Breman, 2010; Šiljeg, 2013; Šiljeg i dr. 2019). Kvaliteta podataka prikupljenih jednosnopnim dubinomjerom ovisi o karakteristikama senzora, dubini vode i definiranom planu snimanja (Kearns i Breman, 2010; Šiljeg, 2013;

Šiljeg i dr. 2019). Važno je istaknuti kako se kod jednosnopnih dubinomjera upotrebom metoda interpolacije, pri određivanju vrijednosti između dva profila, vertikalna i horizontalna greška povećavaju (Šiljeg, 2013). Snimanje je moguće u rasponu frekvencija između 12 i 710 kHz (Šiljeg i dr., 2018), ovisno o tome što se točno želi detektirati: morfologija dna, olupine brodova, riba itd. (Biffard, 2011).

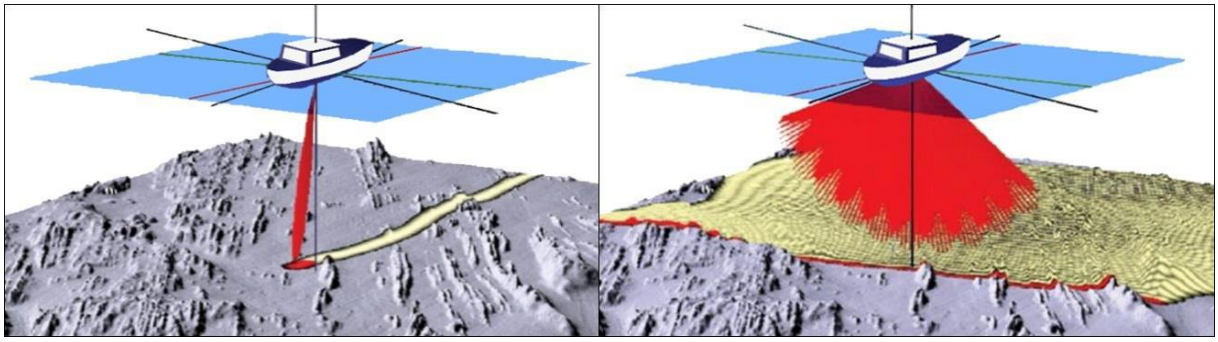

Slika 3. Princip rada jednosnopnog i višesnopnog dubinomjera (Kearns i Breman, 2010:10;13)

3.1.2.1.2. Višesnopni dubinomjeri

Mjerenja dubina vode, posebice u dubokim oceanima, bila su gotovo nemoguća prije razvoja tehnologije ultrazvučnih dubinomjera. To se posebno odnosi na višesnopni dubinomjer koji je omogućio snimanje velikih vodenih površina u relativno kratkom vremenskom roku (Whiteway, 2009). U usporedbi s jednosnopnim, prednost višesnopnog dubinomjera je mjerenje veće površine dna u isto vrijeme koja omogućava veliku pokrivenost dna (Slika 3). No postoje i nedostatci poput veće cijene opreme te više vremena potrebnog za obradu prikupljenih podataka (Biffard, 2011; Šiljeg i dr., 2019). Tehnologija višesnopnih dubinomjera ima višestruku primjenu poput batimetrije, nadzora i održavanja okoliša, ribarstva, istraživanja ugljikovodika, upravljanja obalnim područjima ili podvodne arheologije (Lurton, 2016). Da bi rezultati mjerenja bili reprezentativni, potrebnno je prikupiti podatke potebne za kalibraciju dubinomjera (salinitet, temperatura) na referentnom području (Kearns i Breman, 2010; Šiljeg, 2013; Eleftherakis i dr., 2018).

Korištenjem RTK-GPS-a horizontalna točnost jednosnopnih i višesnopnih dubinomjera iznosi ±20 i ±30 centimetara, dok vertikalna iznosi između ±2 i ±8 centimetara. Točnost ponajviše ovisi o radnoj frekvenciji dubinomjera, kao i o širini i obliku snopa (Šiljeg, 2013). Veliku ulogu u točnosti podataka ima i dubina jer s njom raste i *footprint* (okvir snimka), a prostorna rezolucija snimljenog područja opada (Slika 4). Sustavi poput zračnog

laserskog skenera ili višesnopnog dubinomjera upotrebljavaju čimbenik preklapanja kako bi osigurali potpunu i kontinuiranu pokrivenost dna. (Kearns i Breman, 2010).

Osim prema broju snopova, dubinomjeri se dijele i prema broju frekvencija (jednofrekventni i višefrekventni) (Lurton, 2016; Eleftherakis i dr., 2018; Janowski i dr., 2018), zatim prema obliku snopa (uskosnopni i širokosnopni) te prema broju kanala (jednokanalni i višekanalni) (Lurton, 2016; Clarke, 2006).

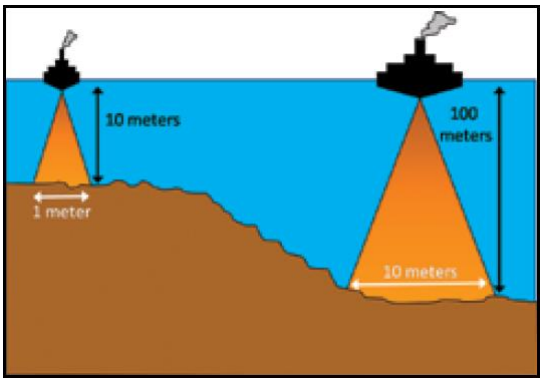

Slika 4. Veza dubine i *footprint*-a snimka (Kearns i Breman, 2010:9)

3.1.3. Virtualna stvarnost

Virtualni model je kognitivno sredstvo i osnovni medij putem kojeg korisnik može imati interakciju s 3D modelima u virtualnom okruženju (Bruno i dr., 2010). Da bi virtualna stvarnost bila kvalitetna, treba zadovoljiti određene kriterije. To su: potpuno okruženje (korisnik mora moći vidjeti sve okolo, te iznad i ispod sebe), percepcija dubine i paralakse kretanja (mora postojati dojam dubine prostora i osjećaj približavanja i udaljavanja od objekata), prostorni zvuk (zvuk uvijek mora dolaziti s pravog mjesta i s prave udaljenosti od korisnika, neovisno o njegovom položaju), prilagodbe za praćenje korisnikovog kretanja razlikuju se od smjera pogleda (u ranim sustavima oni su bili povezani, smanjujući tjelesnu slobodu pokreta), jedina kamera je smjer pogleda korisnika (VR je medij za doživljaj iz prvog lica), prirodni pokreti (što su prirodniji pokreti to je veći osjećaj prisutnosti), prilagodbe za izgradnju narativa (autor(i) trebaju dizajnirati zanimljivu priču koja će zainteresirati korisnika) te načelo djelovanja (korisnika mora imati priliku kretati se i djelovati u prostoru te uočiti posljedice) (Laurel, 2016). Tehnologija virtualne stvarnosti svakim danom postaje sve kvalitetnija i povoljnija (Anthes i dr., 2016) te se primjenjuje u brojnim djelatnostima poput psihologije (Wilson i Soranzo, 2015), vojske (Bhagat i dr., 2016), industrije video igara (Bergmann i dr., 2017), ali i u turizmu s ciljem očuvanja i promocije kulturnih i prirodnih

dobara (Bruno i dr., 2010; Leonov i dr., 2011; Huang i dr., 2015; Tussyadiah i dr., 2018; Marić i dr., 2019). VR se može promatrati kao: medij preko kojeg korisnik može „komunicirati“ s 3D modelima doživljavajući prirodnu i kulturnu baštinu u izvornom okruženju, pomoćni alat rekonstrukcije umjetničkih djela ili čak kao pomoćno sredstvo u izvođenju virtualne obnove bez utjecaja na izvornik. VR se danas sve više koristi u promociji i obrazovanju budući da se informacije prenose senzorskim kanalima (slika, zvukovi) time postajući lako razumljivi nespecijaliziranim korisnicima (Marić i dr., 2019).

3.1.4. 3D printer

Replikacija ili izrada točnih kopija koristi se u masovnoj proizvodnji svih vrsta predmeta, od prehrambenih proizvoda do automobila, od kuća do knjiga (Klein i dr., 2014) ili pak za izradu prototipa, rezervnih dijelova, prilagođenih proteza transformacijom digitalnih u fizičke modele (Lee i dr. 2015; Jordan, 2019). Koristi se i za reprodukciju već postojećih objekata (Klein i dr., 2014) na trodimenzionalnoj razini upotrebom raznih materijala ovisno o korištenom 3D printeru. To mogu biti: plastika, glinamol, silikon, gips, metal ili na primjer čokolada s obzirom na primjenu 3D printera u gastronomiji (Jung i tom Dieck, 2017). Cijela ideja 3D printanja leži u Kartezijanskom robotu. To je stroj koji se može kretati u tri linearna smjera po X, Y i Z koordinati Kartezijeva, tj. pravokutnoga koordinatnog sustava. Da bi to bilo izvedivo, 3D printeri koriste male koračne (*stepper*) motore koji se pomiču s milimetarskom preciznošću i točnošću što rezultira generiranjem fizičkih modela visoke kvalitete (Evans, 2012). Komercijalno dostupni 3D printeri proizvode fizičke modele visoke rezolucije s velikom preciznošću i brzinom te su sve povoljniji na tržištu (Lee i dr. 2015; Jung i tom Dieck, 2017).

3.2. Primjena geoprostornih tehnologija u promociji zaštićenih područja

Geoprostorne tehnologije, osim što su olakšale prikupljanje geografskih podataka te utjecale na poboljšanje kvalitete modela, pružile su i nove mogućnosti primjene istih. Visoko kvalitetni, oku ugodni modeli kod korisnika pobuđuju znatiželju i interes pa tako i želju za posjetom određenoj turističkoj destinaciji. 3D dokumentacija je sve popularnija metoda očuvanja i promocije kulturne i prirodne baštine koja omogućuje izradu kvalitetnih modela u svrhu promocije (Marić i dr., 2019). Podatke o određenom objektu ili lokaciji moguće je prikupiti s mnogo različitih metoda i tehnika, a najčešće se pribjegava izradi integralnih modela (Fabris i dr., 2010; Abdalla, 2016). Te modele je moguće transformirati u različite

podatkovne formate te iz njih izraditi fizičke i digitalne modele. Fizički mogu poslužiti kao primjer za izradu suvenira (Anastasiadou i Vettese, 2019) dok digitalni mogu poslužiti za izradu virtualnih šetnji (Marić i dr., 2019). Virtualni svijet pruža mogućnosti odredišnim marketinškim organizacijama komunikaciju s ciljanim tržištima na potpuno nov način koji pobuđuje zanimanje kod potencijalnih posjetitelja (Huang i dr., 2015).

4. Metodologija istraživanja

4.1. Aerofotogrametrija jezera Zmajevo oko

Aerofotogrametrijsko snimanje Zmajevog oka izvršeno je 19. srpnja 2019., a izmjerom je obuhvaćeno vodno lice jezera te širi obalni pojas u tampon zoni od 100 metara. U procesu prikupljanja podataka korištena je bespilotna letjelica *Phantom 4 Pro* (Slika 5a) (Tablica 1) i RTK-GPS *Stonex S10* (Slika 5b) (Tablica 2). *Phantom 4 Pro* je manja bespilotna letjelica kineske tvrtke *Dà-Jiāng Innovations Science and Technology Co.* (DJI) sa sjedištem u Shenzhen, Guangdongu. Opremljen je fotoaparatom visoke razlučivosti (20 Mpx) s veličinom piksela na senzoru od 0,0024 mm, žarišne daljine 8,8 mm. Letjelica je opremljena autopilotom koji neprekidno analizira podatke inercijalne mjerne jedinice (*Inertial Measurement Unit*), uključujući podatke integriranog GPS-a. GPS i inercijalni sustavi određuju trenutačni geografski položaj i kutne momente uređaja. Dobivena razlučivost terena rezultat je odabira visine leta (npr. visina 100 m = 2,5 cm PS). Snimke se ne prenose u realnom vremenu, već se pohranjuju na SD memorijsku karticu (URL2).

Stonex S10 je GNSS prijemnik nove generacije (SMART ROVER) s 394 kanala i s mogućnošću primanja ATLAS korekcijskog signala (L-band) za postizanje RTK točnosti i bez CROPOS signala ili u uvjetima bez GSM signala (aRTK). Inovacije poput IMU žiroskopa za naginjanje i digitalne libele značajno olakšavaju rad na terenu (URL15). U istraživanju je korišten za određivanje orijentacijskih i kontrolnih točaka te praćenja vodostaja za vrijeme snimanja.

Slika 5. a) *Phantom 4 Pro* i b) *Stonex S10* (prema:URL4 i URL16)

Tablica 1. *Specifikacije Phantom 4 Pro*

SPECIFIKACIJE	PHANTOM 4 PRO
Težina	1388 g
Raspon točnosti lebdenja	Vertikalno: ±0,1 m (with Vision Positioning) ±0,5 m (with GPS Positioning) Horizontalno: ±0,3 m (with Vision Positioning) ±1,5 m (with GPS Positioning)
Satelitski pozicijski sustav	GPS/GLONASS
Polje pogleda	Naprijed: 60°(Horizontal), ±27°(Vertical) Nazad: 60°(Horizontal), ±27°(Vertical) Ispod: 70°(Front and Rear), 50°(Left and Right)
Senzor	1'' CMOS Effective pixels: 20M
Objektiv	FOV 84° 8.8 mm/24 mm (35 mm format equivalent) f/2,8 - f/11 auto focus at 1 m - ∞
ISO raspon	Fotografije: 100 - 3200 (Auto) 100- 12800 (Manual)

Izvor: URL2

Tablica 2. *Specifikacije Stonex S10*

SPECIFIKACIJE	STONEX S10 PRIJAMNIK
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

Izvor: URL15

4.1.1. Označavanje i prikupljanje točaka lokalne geodetske osnove

Aerofotogrametrijsko snimanje i obrada podataka izvršena je u nekoliko koraka (Slika 6). Prvi korak se odnosio na označavanje i prikupljanje točaka lokalne geodetske osnove. Orijentacijske točke (OT) su prikupljene s ciljem postizanja bolje apsolutne orijentacije modela. OT se mogu identificirati na snimkama ili rekonstruiranom modelu, a imaju poznate (X, Y i Z) koordinate u specifičnom koordinatnom sustavu. Koriste se za povezivanje bloka s referentnim koordinatnim sustavom i izjednačenje bloka aerotriangulacije.

Označeno je i prikupljeno ukupno 9 točaka lokalne geodetske osnove (Slika 8). Točke su prikupljene na različitim nadmorskim visinama uvažavajući pravila prostornog rasporeda postavljanja točaka u fotogrametriji. Plan postavljanja točaka je napravljen u softveru *ArcMap 10.1*. Na istočnoj strani jezera Zmajevo oko nije bilo moguće prikupiti točke zbog toga što je taj prostor bio ograđen (privatan posjed).

Ukupno je prikupljeno 6 orijentacijskih točaka (OT1, 2, 4, 7, 8, 9) koje će poslužiti za postizanje bolje apsolutne orijentacije modela (Slika 8). Prikupljene 3 kontrolne točke (OT3, 5 i 6) nisu upotrebljene za orijentaciju modela već su korištene za utvrđivanje točnosti generiranog modela. Iz razlike (reziduala) izmjerenih X, Y i Z vrijednosti (koje su prikupljene na terenu s GPS-om *Stonex S10*) te procijenjenih X, Y i Z vrijednosti (3D model) izračunata je srednja kvadratna pogreška (RMSE) i srednja apsolutna pogreška (MAE) za X, Y i Z koordinatu te za ukupan (total) model.

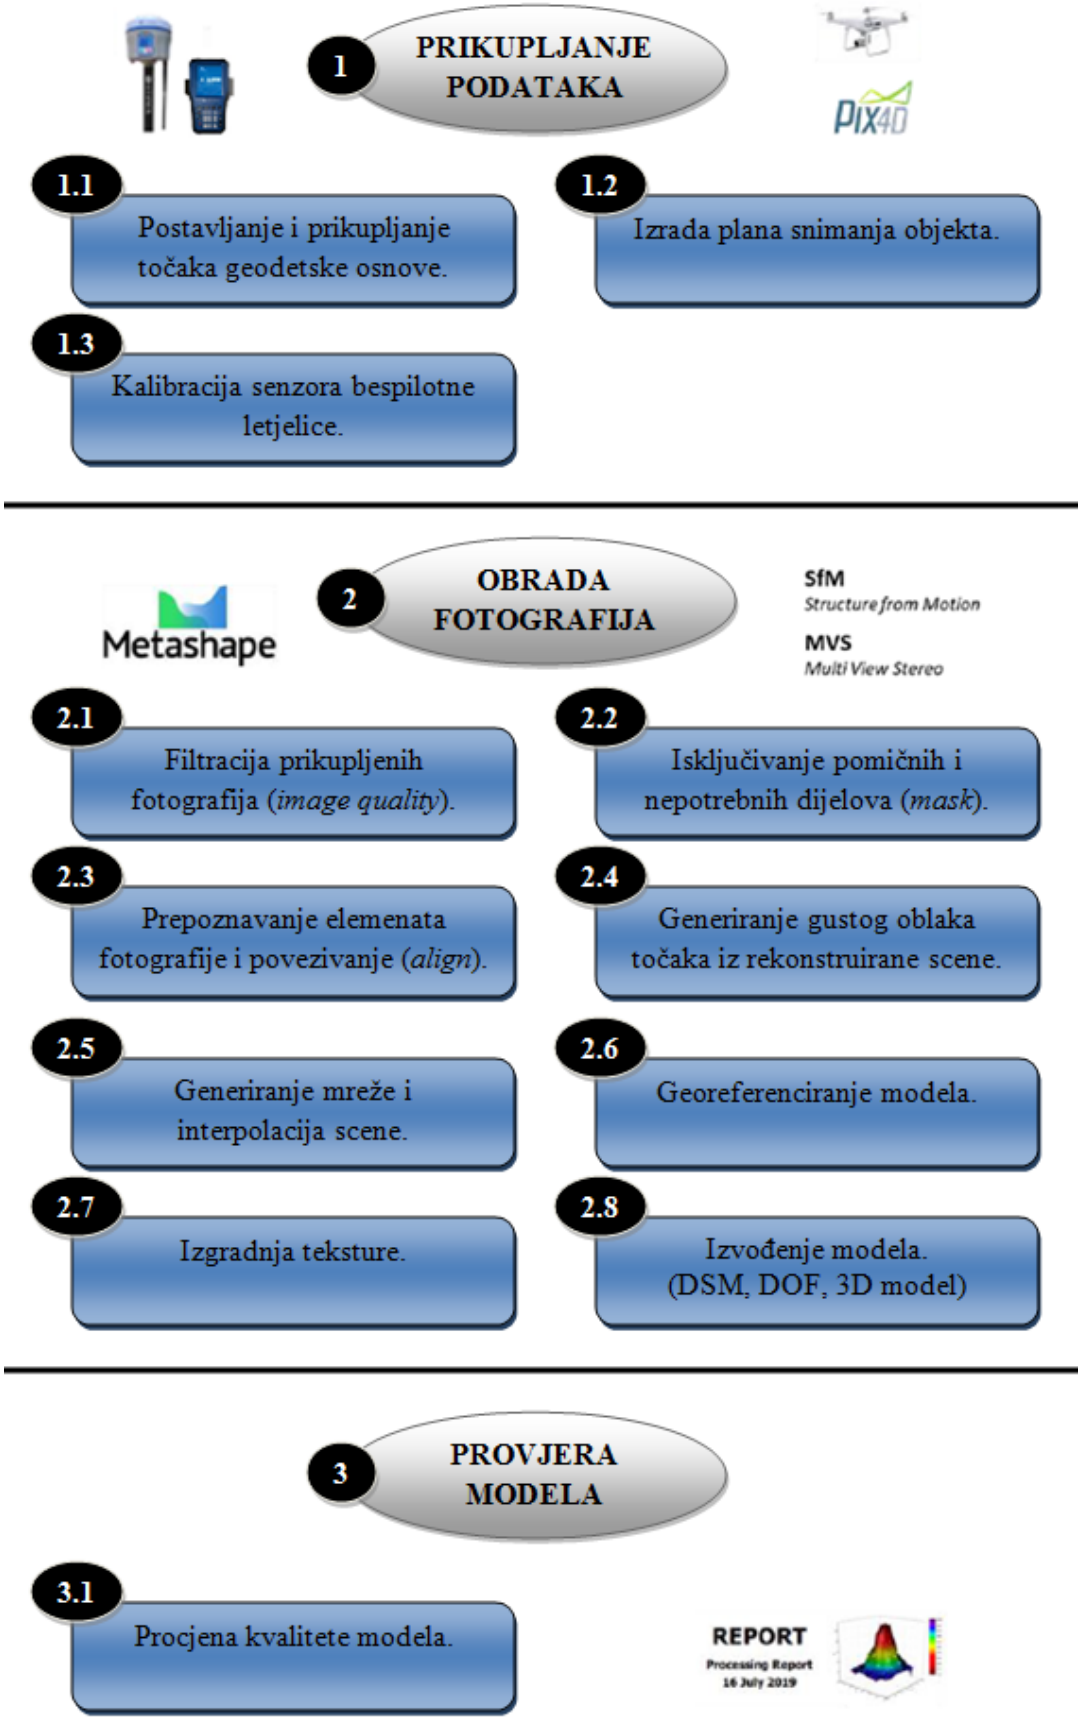

Slika 6. Shema aerofotogrametrijskog procesa Zmajevog oka

Slika 7. Primjer označene orijentacijske točke OT1

Prilikom označavanja OT-a vođeno je računa da su oznake dovoljno velike, korištena je kontrastna (plava) boja u odnosu na lokalni teren te se pazilo na otvorenost horizonta iznad oznaka kako bi se olakšalo dodavanje markera (Slika 7). Označene geodetske točke su prikupljene koristeći GNSS RTK *Stonex S10*. Točke su prikupljanje u službenom projekcijskom koordinatnom referentnom sustavu poprečne Mercatorove projekcije (HTRS96/TM) (Tablica 3).

Tablica 3. *Točke lokalne geodetske osnove prikupljene na terenu*

FID	Label	X	Y	Z	TIP TOČKE
1	OT1	456248,8	4821457	4,121	Orijentacijska
2	OT2	456211,9	4821406	6,9357	Orijentacijska
3	OT3	456188,4	4821383	9,4637	Kontrolna
4	OT4	456172,5	4821360	10,9875	Orijentacijska
5	OT5	456167,5	4821308	16,5376	Kontrolna
6	OT6	456214,9	4821299	17,4789	Kontrolna
7	OT7	456235,4	4821287	18,9237	Orijentacijska
8	OT8	456274,9	4821282	21,833	Orijentacijska
9	OT9	456305,9	4821285	23,7003	Orijentacijska

Slika 8. Distribucija orijentacijskih i kontrolnih točaka oko jezera Zmajevo oko

4.1.2. Izrada plana zračnog snimanja jezera Zmajevo oko

Izrada optimalnog plana snimanja uključivala je odabir vrsta misija s obzirom na morfologiju terena, objekt istraživanja te distribuciju OT-a. Izrada misija UAV-om je izvršena u softveru *Pix4D*. Širi prostor jezera Zmajevo oko je snimljen koristeći četiri vrste misija: *Grid Mission*, *Double Grid Mission*, *Circular Mission* te *Free Flight Mission* (Slika 9). Na slici 10. pružen je primjer prikupljenih fotografija unutar svakog tipa izvedene misije leta.

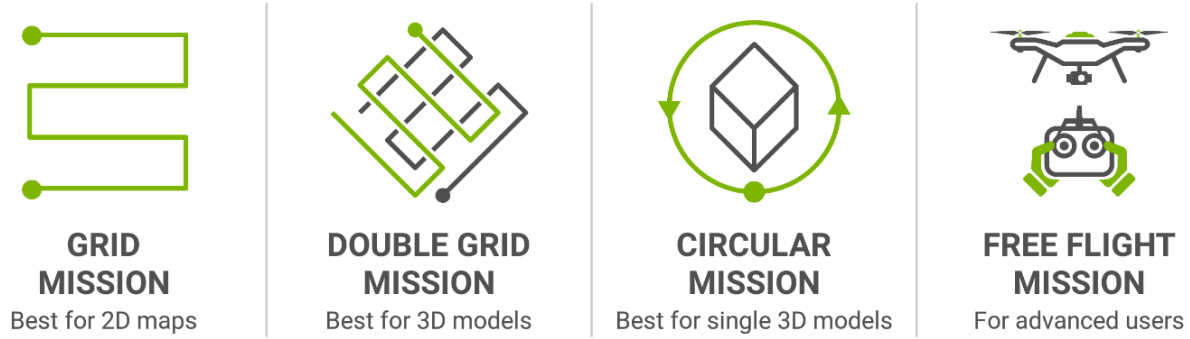

Slika 9. Vrste misija korištene prilikom snimanja jezera Zmajevo oko (URL17)

Slika 10. Primjer snimljenih zračnih snimaka Zmajevog oka a) *Grid Mission*, b) *Double Grid Mission*, c) *Circular Mission* i d) *Free Flight Mission*

Double Grid Mission je prema uputama *Pix4D*-a preporučena ako se želi dobiti potpuni 3D model odabranog prostora. Izvedeno je sedam *Double Grid* misija na visinama leta od 70 m s kutom kamere od 90°. Postotak prednjeg i bočnog preklapanja je postavljen na 80%. Takav tip misije osigurava gusto preklapanje snimki pogodno za optimalnu obradu. Ukupno je prikupljeno više od 3876 fotografija (Slika 11a-b) na prostoru od oko 0,12 km². Prosječna visina leta je iznosila je 71,7 m iznad razine kopna.

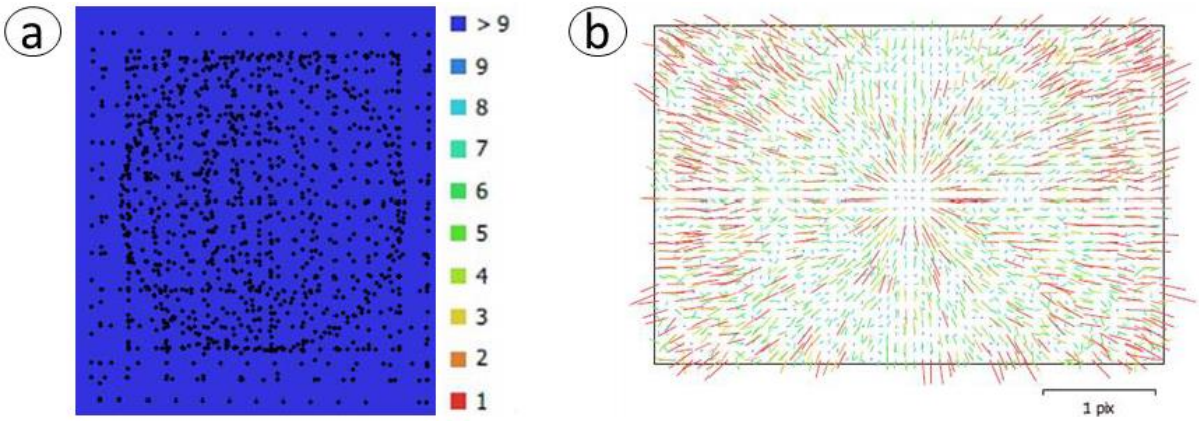

Slika 11. a) Lokacije fotografija te broj preklapanja b) *Image residuals* (8.8 mm)

4.1.3. Kalibracija bespilotne letjelice *Phantom 4 Pro*

Prije snimanja izvršeno je kalibriranje *vision* sustava pozicioniranja, IMU sustava i kompasa *Phantom 4 Pro* te resetiranje postavki kamere u aplikaciji *DJI GO*. Prilikom izvođenja procesa kalibracije *Phantom 4 Pro* je postavljen u različite položaje u skladu sa zadanim uputama na ekranu tableta (Slika 12).

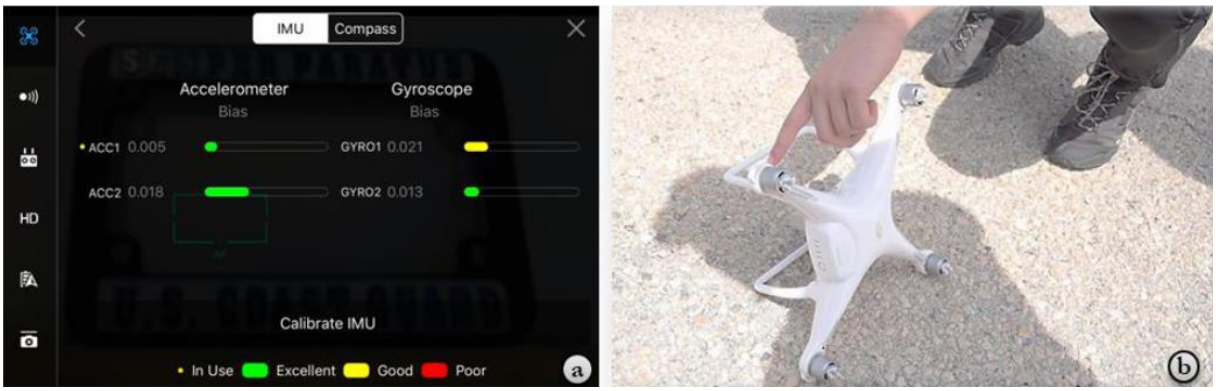

Slika 12. a) Kalibracijsko sučelje aplikacije *DJI GO* te b) kalibracija IMU sustava na terenu

4.1.4. Proces obrade zračnih snimaka

U procesu obrade snimki korišten je računalni program *Agisoft Metashape Professional 1.5.1* specijaliziran SfM-MVS (*Structure from Motion – MultiView Stereo*) za fotogrametriju. To je napredni softver za 3D modeliranje koji kroz obradu digitalnih fotografija stvara visokokvalitetne 3D prostorne podatke. Primjenjuje metodu SfM koja omogućuje da se tehnikom prilagođavanja snopova (BA) istodobno odredi orijentacija i položaj kamere u prostoru (vanjski orijentacijski parametri) kao i 3D koordinate točaka objekata za veliki broj snimki. Uz vanjske, istodobno se određuju i unutarnji orijentacijski parametri kamere. Povezivanje snimki i rekonstrukcija 3D modela u programu su potpuno automatizirani. Proces obrade snimki i generiranja izlaznih modela (digitalnog modela površina (DSM), digitalnog ortofota (DOF), oblaka točaka i 3D modela) izvršen je u nekoliko koraka (Slika 15).

Prvi korak odnosio se na filtraciju prikupljenih snimki kroz automatsku procjenu kvalitete *Image quality*. Zamućene i loše fokusirane snimke mogu negativno utjecati na rezultate povezivanja stoga su uklonjene sve snimke s vrijednošću manjom od 0,5. Potom su isključeni (maskirani) pomični i nepotrebni dijelovi (npr. nebo, brod na jezeru, turisti u pokretu) na snimkama koje prilikom izvođenja rijetkog i gustog oblaka točaka mogu otežati povezivanje snimki. Maskirana područja algoritam ne koristi prilikom procesa fototriangulacije. Prije inicijalne izrade modela izvršena je orijentacija i spajanje snimki. Softver je automatski prepoznao i očitao unutarnje kalibracijske parametre kamere te ih nakon svake optimizacije ažurirao. Očitani parametri kalibracije su u softveru uzeti kao početni elementi za izračun elemenata orijentacije u procesu fototriangulacije. Nakon orijentacije snimki prikazane su izračunate pozicije kamere i rijetki oblak točaka (Slika 13).

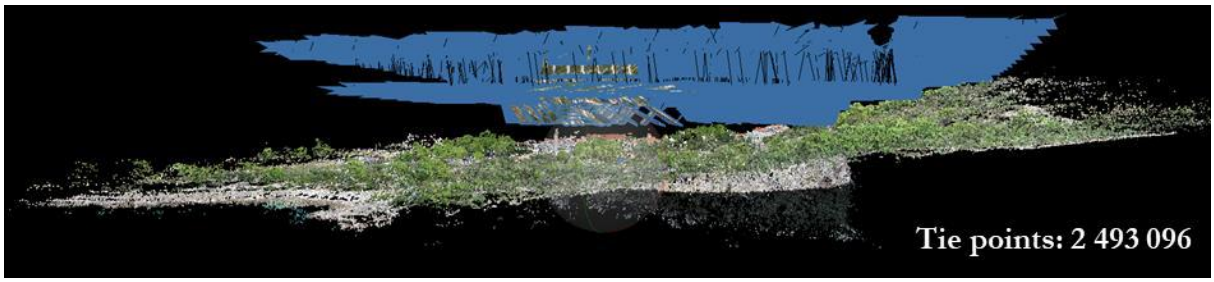

Slika 13. Rijetki oblak točaka te izračunate lokacije kamere

Sljedeći korak odnosio se na izvođenje i vizualizaciju modela gustog oblaka točaka. Na osnovi procijenjenih lokacija kamera izračunava se dubina za svaku kameru. Tim procesom izvodi se oblak točaka koji može biti jednake gustoće ili čak gušći od oblaka točaka dobivenog LiDAR-om. Na primjeru Zmajevog oka izvedeno je ukupno oko 12 453 234 mil. točaka pod parametrom *Quality Low*. Spomenuti model je poslužio za stvaranje inicijalnoga gustog oblaka točaka, koji je kasnije poslužio kao osnova za generiranje mreže poligona te dodavanje prikupljenih orijentacijskih točaka. Iz izvedenog oblaka točaka potom je rekonstruirana 3D mreža poligona kao prikaz površine objekta. Ona je izvedena primjenom algoritamske metode *Height field*. Rezultat rekonstrukcije geometrije, odnosno izrade mreže poligona u daljnjem procesu je teksturiran. Teksturirana mreža poligona poslužila je kao osnova za dodavanje orijentacijskih i kontrolnih točaka prikupljenih na terenu s RTK GNSS *Stonex S10* (Slika 14).

Slika 14. Označene orijentacijske i kontrolne točke na gustom oblaku točaka

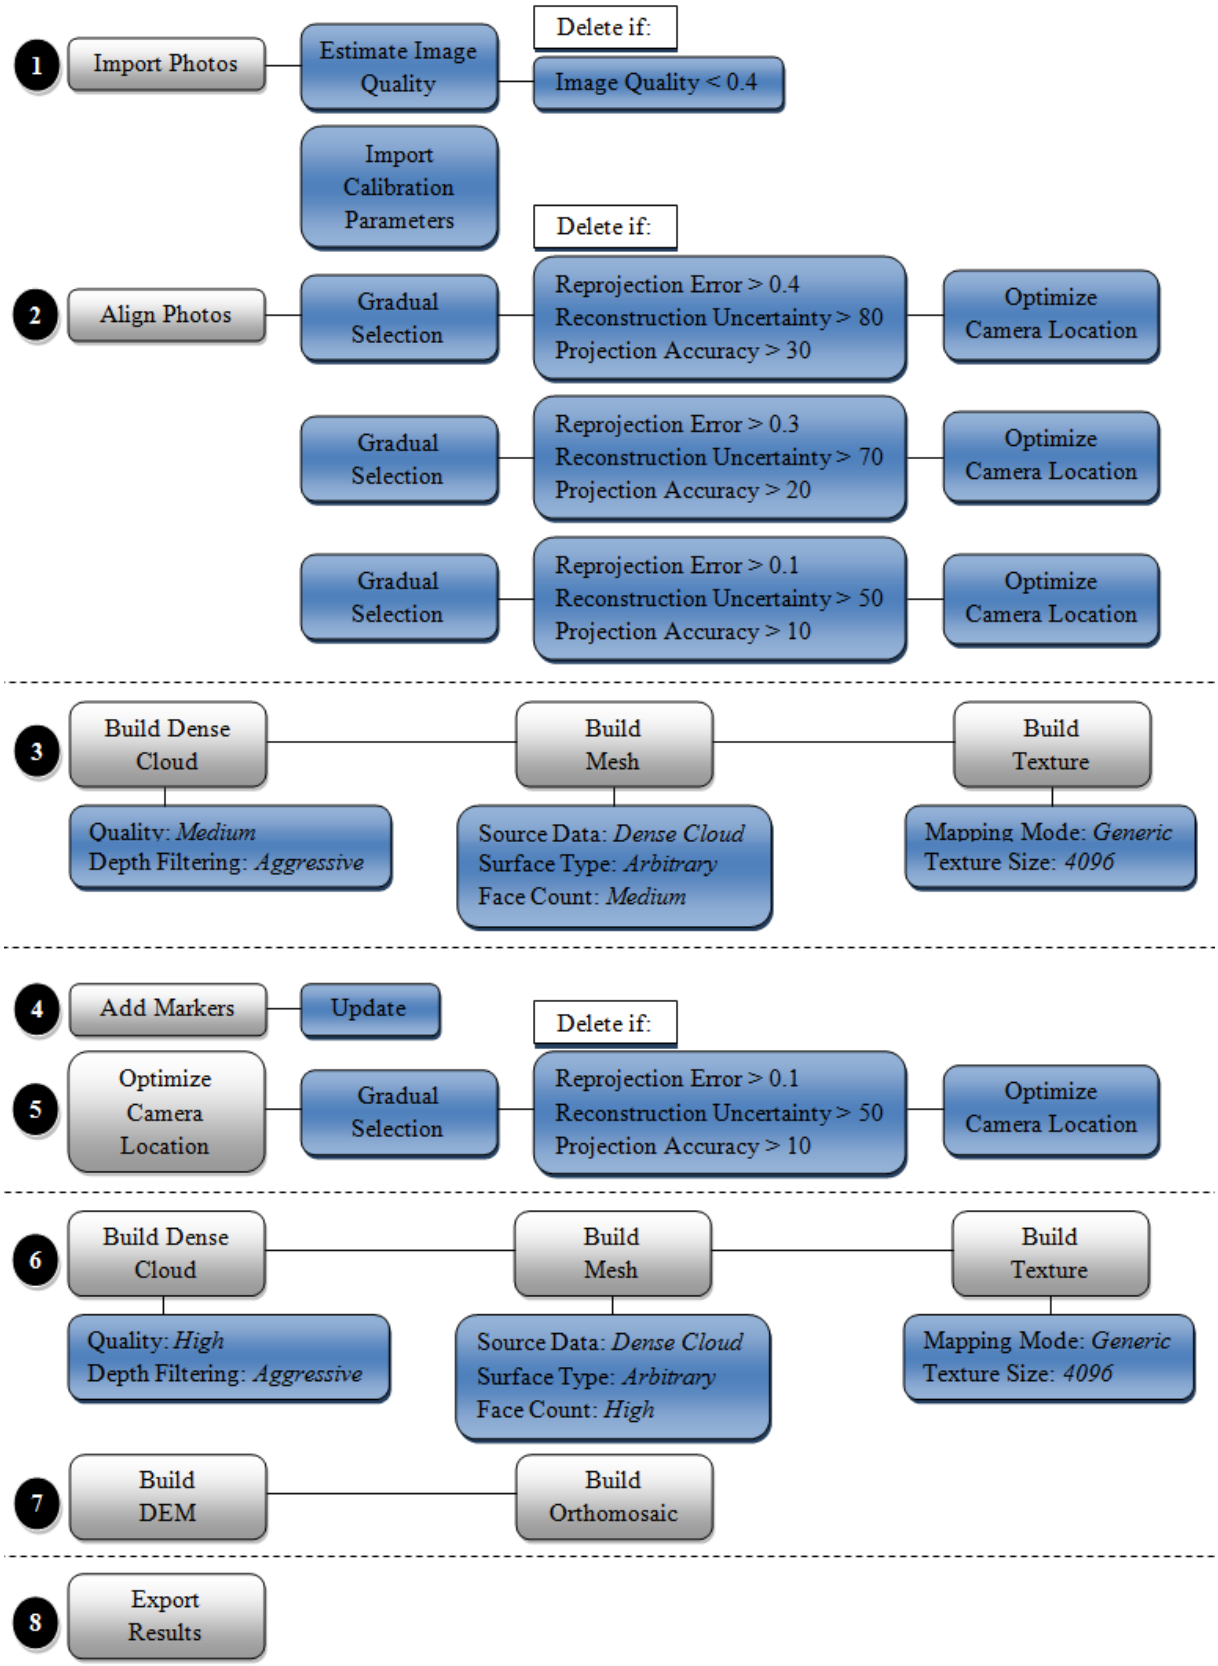

Slika 15. Proces obrade zračnih snimaka u *Agisoft Metashape 1.5.1*

4.1.5. Ispitivanje točnosti modela izvedenih procesom aerofotogrametrije

Nakon dodavanja orijentacijskih i kontrolnih točaka izračunata je točnost izvedenih modela. Za izračun su korištena dva statistička pokazatelja.

Prva korištena metoda je srednja apsolutna pogreška (*mean absolute error* – MAE) koja pruža prirodnu i usporedivu mjeru performansi modela i indikaciju neusmjerenih visinskih pogrešaka (Smith i Vericat, 2015). Izračunava se po formuli:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|e_i|$$

Druga korištena metoda je srednja kvadratna pogreška (*root mean square error* – RMSE). Ona se uobičajeno navodi i koristi se kao metrika provjere kvalitete površine modela (Smith i Vericat, 2015), a izračunava se po formuli:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}e_i^2}$$

Za obe formule vrijedi da je *n* broj točaka, dok *e* predstavlja pogreške dobivene kao razlika reziduala (Chai i Draxler, 2014).

Kvaliteta modela (točnost i preciznost) uvjetovana je širokim spektrom čimbenika koji uključuju: odabrane postavke snimanje, površinu snimanog područja, kalibraciju kamere, performanse podudaranja fotografija, teksturu površine snimanog objekta, uvjete osvjetljenja te najvažnijih obilježja korištenih orijentacijskih točaka (ovisno o RTK GPS-u) (Smith i Vericat, 2015).

4.1.6. Generiranje gustog oblaka točaka u *Agisoft Metashape Professional 1.5.1*

Nakon preciznijega apsolutnog orijentiranja modela te optimizacije veznih točaka generiran je gusti oblak točaka (*dense cloud*). Odabrani su sljedeći parametri: *Quality:High* i *Depth filtering:Aggressive*.

Iz gustog oblaka točaka generiran je poligonski model jezera Zmajevo oko. Odabrane su sljedeće postavke: *Source data* (Dense cloud), *Surface type* (*Arbitrary*), *Face count* (*Medium*). Generirani poligonski model jezera je u konačnici teksturiran.

4.2. Batimetrijska izmjera jezera Zmajevo oko

Batimetrijskom izmjerom obuhvaćeno je područje jezera Zmajevo oko, odnosno njegovo dno. Za batimetrijsku izmjeru korišten je gumenjak *Luna* duljine oko 2,5 m, koji se zbog manjih dimenzija i gaza te lake mogućnosti ugrađivanja komponenti mjernog sustava pokazao kao optimalno rješenje (Slika 16).

Slika 16. Gumenjak *Luna* na kojem je instaliran integralni mjerni sustav

4.2.1. Plan batimetrijske izmjere

Tijekom batimetrijske izmjere iznimno je važno detaljno planiranje koje omogućava praćenje razvoja i organizaciju izmjere od početka do kraja (IHO, 2005). Plan izmjere obuhvaćao je širok spektar aktivnosti koje su se sastojale od nekoliko faza:

1) određivanje točnog područja izmjere;

2) utvrđivanje svrhe batimetrijske izmjere;

3) primjena metode izmjere (tehnika, točnost, horizontalni i vertikalni referentni geodetski sustav, oprema itd.);

4) vremenski rok (duži ili kraći);

5) prikupljanje sekundarnih podataka (aero snimke, salinitet, temperatura itd.);

6) uzimanje u obzir ograničavajućih čimbenika (proračun, logistika itd.).

4.2.2. Integralni mjerni sustav kombinacija RTK GPS i višesnopnog dubinomjera

Batimetrijska mjerenja izvršena su integriranim mjernim sustavom (Slika 17) koji je uključivao šest glavnih sastavnica:

a) *WASSP S3 Multibeam Wideband Sounder c/w DRX* (Slika 18);

b) *WASSP Sensor Box* s integriranim *Spatial IMU* (Slika 26);

c) *Hemisphere V320 GNSS Smart Antenna* (mFreq, mGNSS, RTK, SBAS) (Slika 27);

d) akumulator i kabel za napajanje;

e) konfiguracijsko računalo i kabel;

f) softveri za konfiguraciju (*PoketMax*, *NtripClient*, *DRX Setup Webpages*);

g) softveri za navođenje (*CDX*) i eksportiranje podataka (*Data Manager*).

Sve komponente su povezane i konfigurirane prema uputama proizvođača i međunarodnih standarda s obzirom na obilježja korištenog broda s ciljem minimaliziranja korisničko definiranih parametara koji mogu utjecati na izlazne rezultate. Uz navedenu konfiguraciju sustava prilikom izmjere bitno je kalibrirati sondu, pri čemu na izlazne rezultate mjerenja dubine i tvrdoće dna treba izračunati optimalnu brzinu zvuka u vodi (ENL Group, 2016).

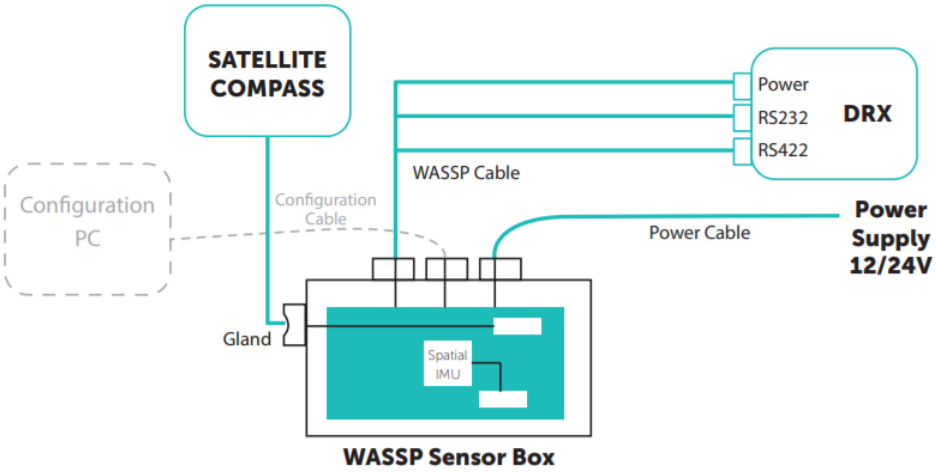

Slika 17. Komponente integralnog mjernog sustava (ENL Group, 2016)

4.2.2.1. Višesnopni dubinomjer *WASSP S3 Multibeam*

WASSP (*Wide Angle Sonar Seafloor Profiler*) je višenamjenski ultrazvučni dubinomjer koji omogućava istraživanje, generiranje modela visoke rezolucije i detaljno kartiranje dna mora, jezera, rijeka itd. Verzija S3 (*Survey*) treća je i najnovija generacija višesnopnih dubinomjera koja koristi širokopojasnu tehnologiju. Ocijenjen je certifikatom

IP53 koji je potvrda da je kućište novog *DRX-32* primopredajnika (Slika 18) djelomično zaštićeno od prašine i otporno na prskanje vode (URL5). To ga uz njegovu kompaktnost i ekonomičnost nameće kao prvi izbor pri izvođenju batimetrije na teže dostupnim mjestima pomoću manjih plovila gdje oprema ne može biti u potpunosti zaštićena od vanjskih utjecaja. Maksimalna vertikalna rezolucija mu iznosi 2 centimetra što ga čini idealnim rješenjem za istraživanje podvodnih područja s izrazitom vertikalnom raščlanjenosti terena do 400 m dubine. *WASSP S3* karakterizira frekvencija od 160 kHz i 224 snopa, a mogući raspon snopova je od 4 do 120 stupnjeva (Tablica 4) (URL6).

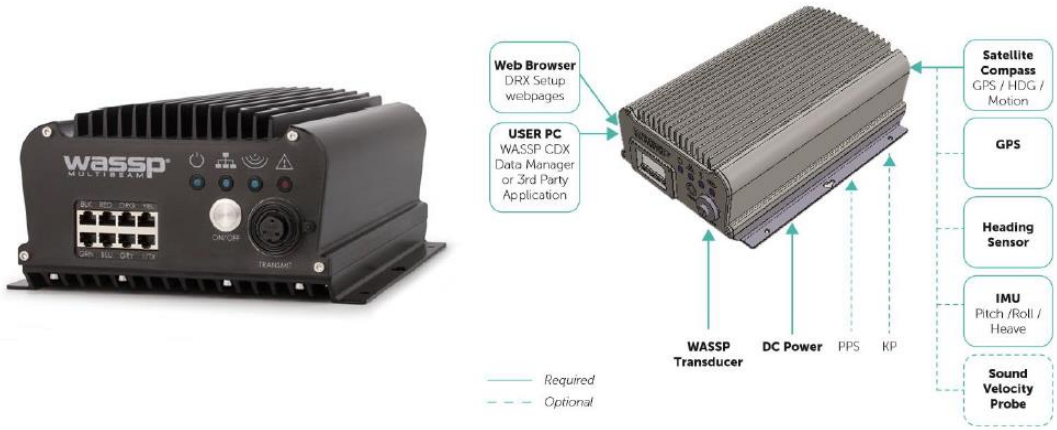

Slika 18. Višesnopni dubinomjer *WASSP S3* (prema: URL3 i URL6)

Tablica 4. *Osnovna specifikacija višesnopnog dubinomjera WASSP S3*

MODEL	**S3**
Frequency	160 kHz (WideBand Variable)
Transceiver type	DRX-32
Transducers supported	WMB - 160
IMU supported	External
Depth - swath	200 m
Depth - max	400 m
Effective beamwidth (athwartships x fore-aft)	120° x 4°
Beam width PS (deg)	4.4
Beam width FA (deg)	3.2
Beam spacing (nominal)	0.54^o over 120° (224 beams)
Max vertical resolution (cm)	2
Sensor connectivity	DRX
PSU	9-32VDC (30W)
Bottom detections	Amplitude & Phase
Interface	RS232/422/NMEAO183
Tide correction	Fully Geo Referenced
Bathymetry 2D / 3D	Yes
Sonar polar view	Yes
Sounder (quint beam)	No

Izvor: URL6

4.2.2.1.1. Softveri *CDX* i *Data Manager*

CDX je *WASSP*-ov operativni sustav koji služi za kontrolu, vizualizaciju i upravljanje prikupljenim podacima. On omogućava kartiranje dna u visokoj rezoluciji te prikaz snimanog područja u realnom vremenu na pojednostavljenom korisničkom sučelju. Pametni algoritam uzima najbolje podatke sa starih i novih snimaka generirajući tako visoko kvalitetne batimetrijske karte bez grubih granica između snimljenih profila. Baza podataka je višerezolucijska i organizirana tako da se s približavanjem prema karti prostorna rezolucija povećava (URL6). Aplikacija *CDX* sastoji se od 6 sastavnica (Slika 19):

1) *Home* pristup – pruža mogućnosti konfiguracije zaslona, ploče, izgleda, alata, postavljanje sustava i korisničkih postavki;

2) Okviri zaslona – zasloni su povezani su s određenim tipovima podataka za vizualizacija i kontrola;

3) *CS* (*context sensitive*) meni – omogućuje postavljanje i konfiguraciju specifičnih ploča za prikaz kojima se pristupa desnim klikom na bilo kojoj ploči;

4) Zaslon s informacijama – mogućnost preklapanja informacija na ploči zaslona s *CS* izbornikom;

5) Alati za kontrolu – omogućuju kontrolu preklapanja upravljačke ploče na zaslonu;

6) Opcijski alati – služe za prikaz općih podataka.

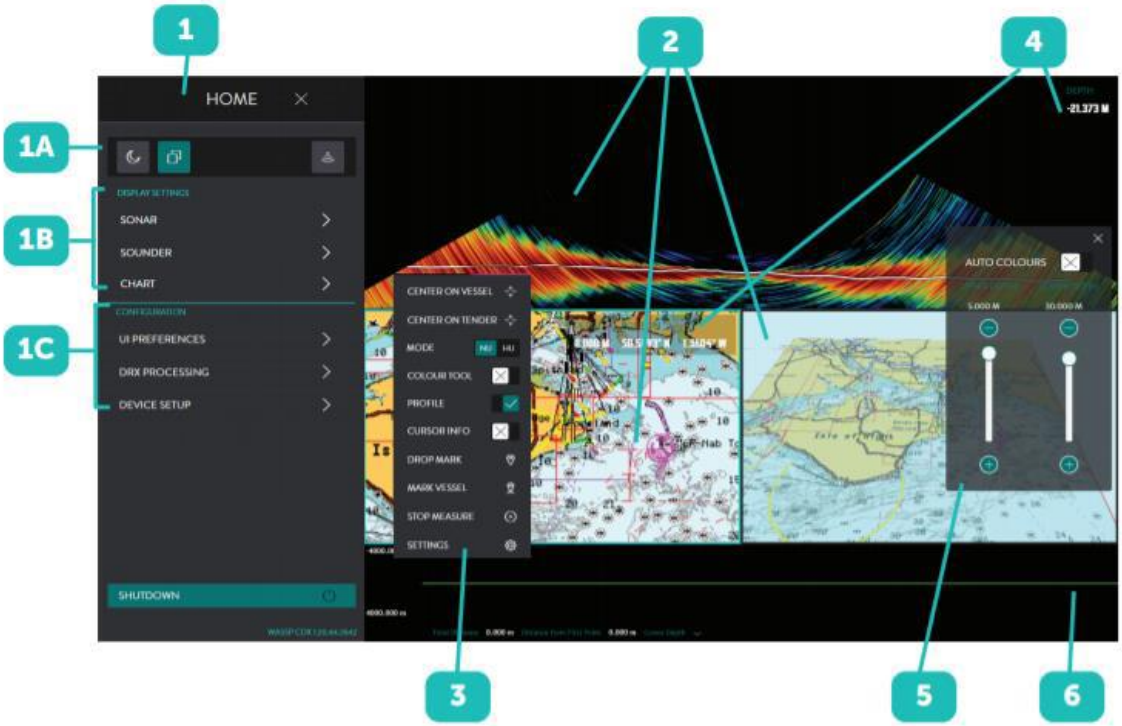

Slika 19. Sastavnice aplikacije *CDX*

Sučelje aplikacije *CDX* sadrži osnovne podatke o značajkama specifičnog položaja broda i okvire za prikaz jezera. Sustav je opremljen naprednim sastavnicama koje omogućuju uvid u realnom vremenu u vizualnu kvalitetu modela kroz čak 5 prikaza jezera: a) dvodimenzionalni, b) perspektivni (3D), c) sonarno polje, d) bočno skeniranje i e) profil (Slika 20).

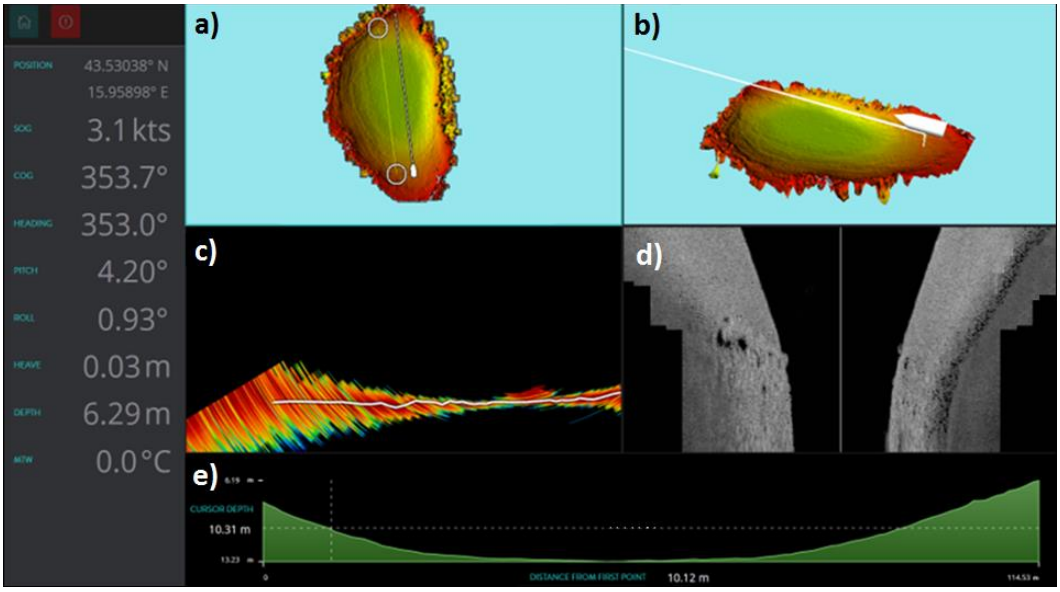

Slika 20. Prikazi jezera: a) dvodimenzionalni; b) perspektivni (3D); c) sonarno polje; d) bočno skeniranje; e) profilni

Na slici 21. je primjer snimljenog dna (dubina) Zmajevog oka (3D, profil) s višesnopnim dubinomjerom *WASSP S3*, dok je na slici 22. prikazano kako uređaj kartira tvrdoću dna jezera.

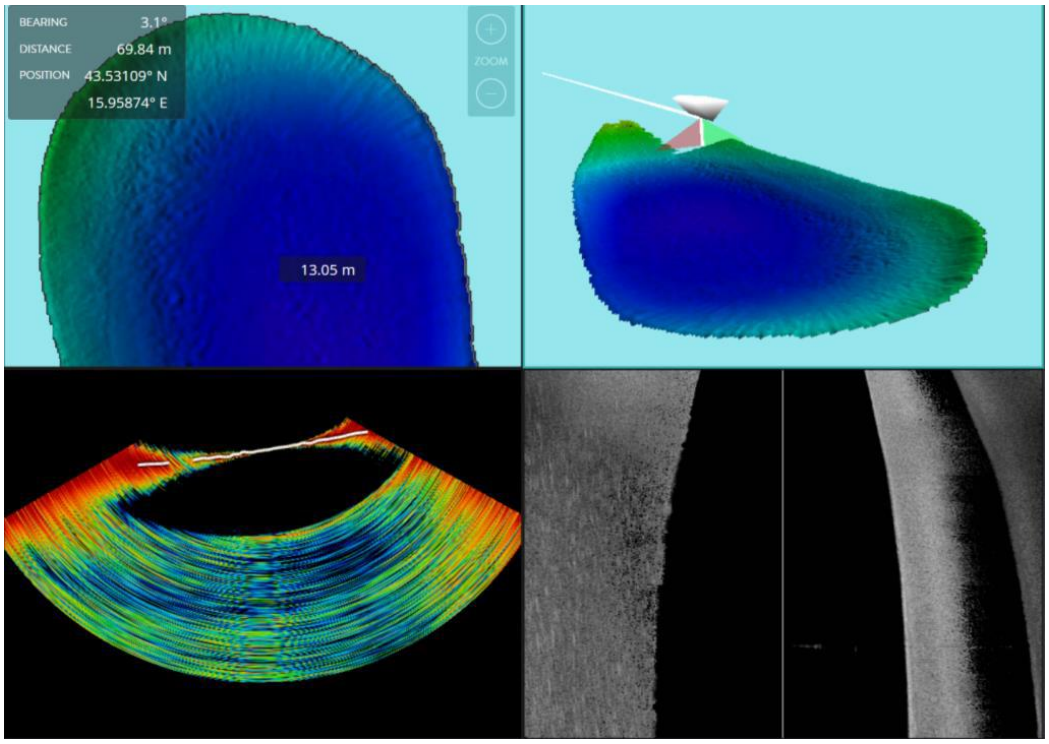

Slika 21. Primjer snimljenog dna (dubina) Zmajevog oka s višesnopnim dubinomjerom *WASSP S3*

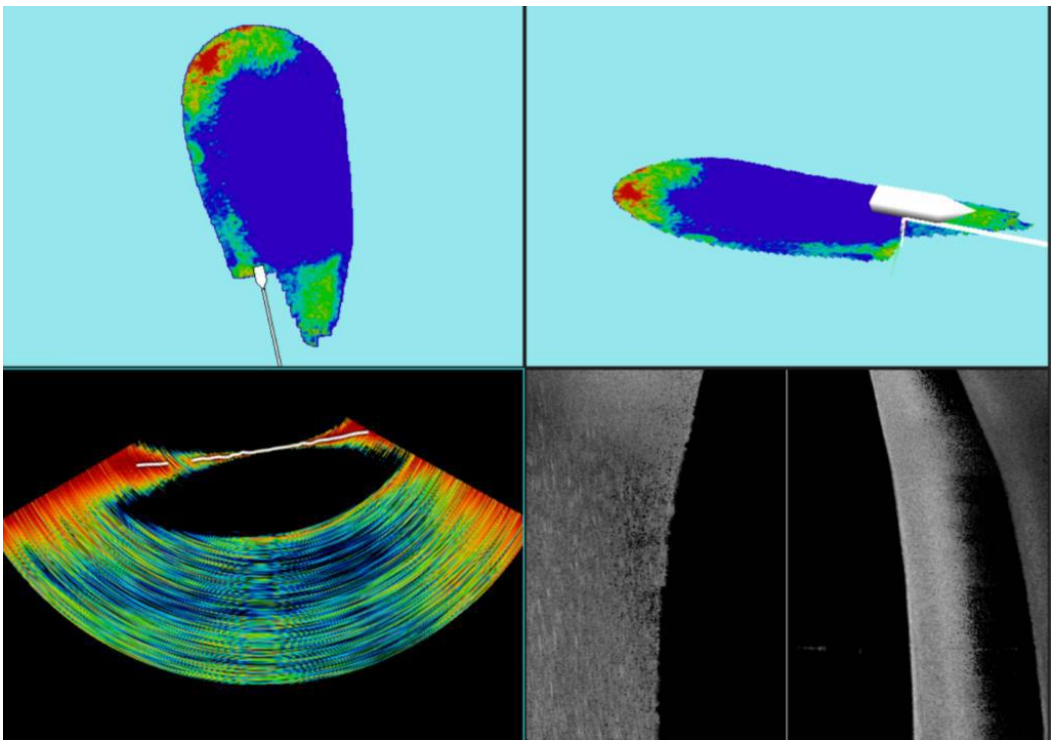

Slika 22. Primjer snimljenog dna (tvrdoća) Zmajevog oka s višesnopnim dubinomjerom *WASSP S3*

Data Manager je programski paket za upravljanje podacima. On se generalno sastoji od tri komponente (Slika 23):

1) Snimanje podataka;

2) Ponovni prikaz;

3) Izvoz podataka

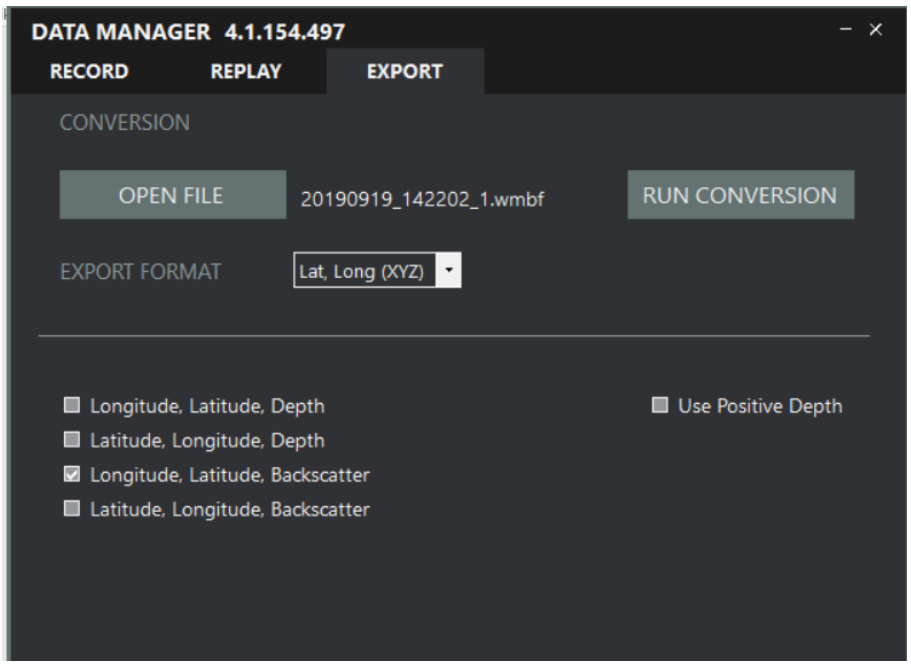

Slika 23. Sučelje softvera *Data Manager*

4.2.2.1.2. Sonda

Sonda ili *transducer* je uređaj koji pretvara energiju iz jednog oblika u drugi (Song i Lee, 2008). U slučaju batimetrije to se odnosi na pretvaranje elektronskog signala u ultrazvučni i obrnuto. Na temelju vremenske razlike između odaslanog i primljenog zvučnog signala bilježi se vertikalna udaljenost od dna do sonde.

Pri batimetriji jezera Zmajevo oko korištena je sonda *WMB-160* čija je operativna frekvencija 160 kHz (Slika 24). Ona je čvrsto pričvršćena za čeličnu motku kako se prilikom izmjere ne bi pomicala i samim time utjecala na izlazne rezultate. Uronjena je na dubinu od 60 cm te je razlika udaljenosti između nje i vodene površine uračunata u izmjeru. Orijentirana je pod kutem od 90° kako bi zvučni signal putovao najkraćim mogućim putem i bio pravilno georeferenciran. Također je veoma važna i pozicija sonde s obzirom na turbulencije uzrokovane radom propelera koje mogu utjecati na kvalitetu prikupljenih podataka. Stoga je

cijeli sustav pozicioniran što je dalje bilo moguće od pente. Kako bi prikupljeni podaci bili na točnoj X,Y koordinati, odnosno kako bi horizontalna točnost bila kvalitetna, antena je montirana točno iznad sonde (Slika 24).

Slika 24. Sonda *WMB-160* (URL9) i njezina pozicija u integralnom mjernom sustavu

4.2.2.1.3. Inercijalni mjerni sustav

Kvaliteta prikupljenih podataka oscilira s obzirom na to da je pri batimetrijskoj izmjeri prisutan utjecaj prednjih i bočnih valova zbog kretanja plovila po vodenoj površini (Slika 25) (Šiljeg, 2013). Stoga veliku važnost pri prikupljanju podataka, korištenjem integralnog mjernog sustava - kombinacije RTK GPS-a i višesnopnog dubinomjera, ima integrirani inercijalni mjerni sustav (IMU) koji omogućuje registraciju podataka po X, Y i Z osi.

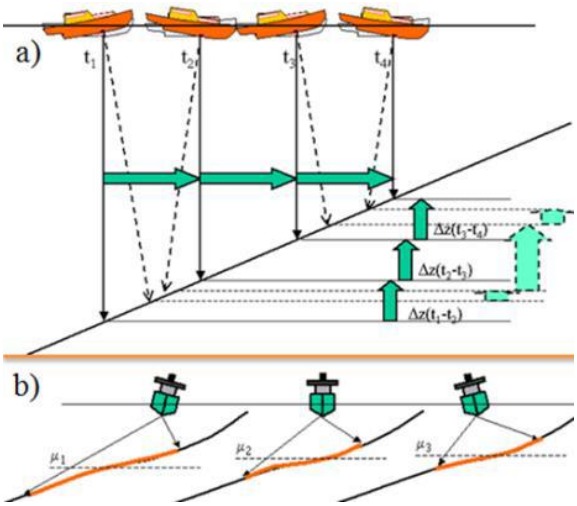

Slika 25. Utjecaj a) prednjih i b) bočnih valova na registraciju podataka (Šiljeg, 2013:58)

Advanced Navigation Spatial IMU WSP002-INU smješten u senzornoj kutiji (Slika 26) je minijaturni navigacijski sustav s inertnim navigacijskim sustavom GPS-a i AHRS (*attitude and heading reference system*). On osigurava točnu poziciju, brzinu, ubrzanje i orijentaciju u najzahtjevnijim uvjetima te je zbog svoje visoke preciznosti u kombinaciji s *Hemisphere V320 GNSS* pametnom antenom (Slika 27) idealan za sustave na malim plovilima koji su pod velikim utjecajem prednjih i bočnih valova (URL10). Kombinira temperaturno kalibrirane, akcelerometre, žiroskope, magnetometre i senzor tlaka s naprednim GNSS prijemnikom. Oni su spojeni u sofisticiranom fuzijskom algoritmu kako bi pružili točnu i pouzdanu navigaciju i orijentaciju (Pao, 2018).

Slika 26. *WASSP Sensor Box* s integriranim *Advanced Navigation Spatial IMU WSP002-INU* (prema: ENL Group, 2016; URL10)

4.2.2.2. *Hemisphere V320 GNSS Smart Antenna*

Hemisphere V320 (Slika 27) prva je višenamjenska GNSS pametna antena, koja omogućava RTK precizno usmjeravanje. Dizajnirana je tako da i u različitim vremenskim uvjetima omogućava kvalitetno dinamičko pozicioniranje pri profesionalnom istraživanju dubina. S postavljenim odvajanjem, *V320* pruža konzistentnu i pouzdanu točnost položaja i smjera. *Vector 320* može koristiti Atlas L-opseg i SBAS (WAAS, EGNOS, MSAS, itd.) za korekciju GNSS signala (URL11).

Slika 27. *Hemisphere V320 GNSS Smart Antenna* (URL11)

Tablica 5. *Specifikacija GNSS senzora*

MODEL	V320
Receiver type	Vector GNSS L1 Compass
Signals received	GPS and GLONASS
Channels	540
GPS sensitivity	-142 dBm
SBAS tracking	2-channel, parallel tracking
Update rate	20 Hz standard
Position accuracy: RMS	Horizontal Vertical
Position accuracy: Single point	1.2 m 2.5 m
Position accuracy: SBAS (WAAS)	0.3 m 0.6 m
Position accuracy: Code differential GPS	0.3 m 0.6 m
Heading accuracy	0.30˚
Pitch/Roll accuracy	1˚
Heave accuracy	30 cm 3
Timing (1 PPS) accuracy	20 ns
Rate of turn	90˚/s maximum
Compass safe distance	75 cm (with enclosure)
Cold start	60 s (no almanac or RTC)
Warm start	20 s typical (almanac and RTC)
Hot start	1 s typical (almanac, RTC and
Heading fix	10 s typical (valid position)
Maximum speed	1,850 mph (999 kts)
Maximum altitude	18,288 m (60,000 ft)
Differential options	SBAS Beacon, External RTCM

Izvor: URL11

4.2.3. Sekundarni podaci i kalibracija sustava za prikupljanje podataka

Dobivanje sekundarnih podataka predstavljalo je proces koji je uključivao prikupljanje svih podataka koji su neophodni za optimalno planiranje batimetrijske izmjere. DOF i HOK korišteni su kao podloge za iscrtavanje granice obale i profila. Podatci o temperaturi su bitni zbog izračuna brzine zvuka u vodi. Dobivena vrijednost brzine zvuka važan je parametar prilikom kalibracije dubinomjera. Unos brzine zvuka potreban je za kompenzaciju netočnosti raspona uzrokovanih zvukom varijacije u brzini. Te se promjene mogu dogoditi, sezonski i s geografskim područjima, posebno u obalnim područjima gdje će na brzinu zvuka utjecati

temperatura vode i zraka te razlike u slanosti vode. Na brzinu zvuka u vodi dakle utječu i temperatura i slanost. Ovu vrijednost treba redovito prilagoditi ovisno o radnom okruženju, jer će imati izravan utjecaj na točnost kartiranja. Što je brzina zvuka preciznija, to je preciznije kartiranje dna. Vizualni učinak neispravne brzine zvuka očituje se tako da će se prikaz ravnog morskog dna konkavno ili konveksno zakriviti (Dong i dr., 2007; Dong i dr., 2011) (Slika 28).

Slika 28. Netočnosti prikaza morskog dna zbog pogrešne brzine zvuka

Stoga je uređaj kalibriran na zaravnjenom dijelu jezera s ciljem minimaliziranja grešaka prilikom izmjere (Slika 29). S obzirom na karakteristike temperature i saliniteta na dan izmjere brzina zvuka iznosila je 1531,58 m/s (Slika 30).

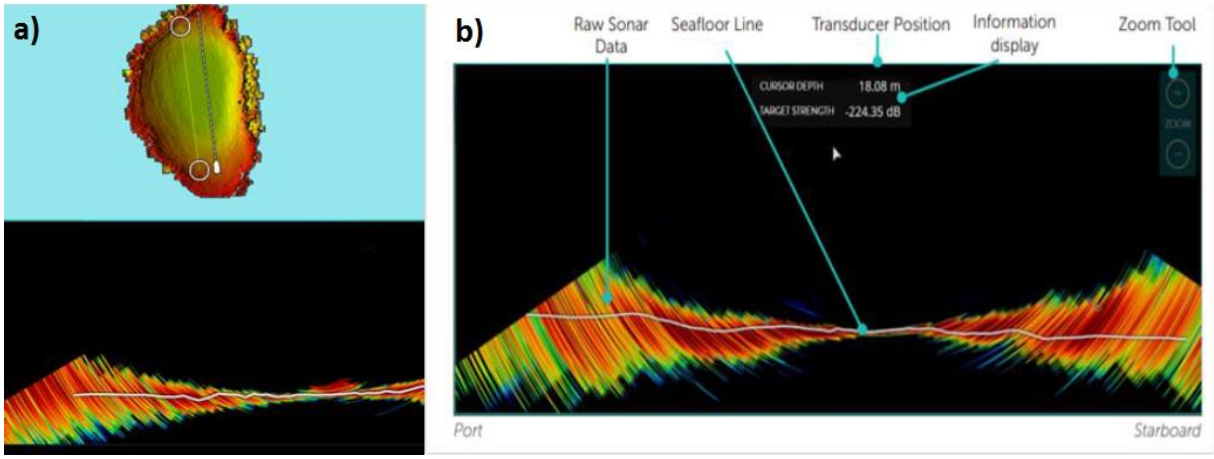

Slika 29. Prikaz Sonarne ploče koja prikazuje vodeni stup i profil morskog dna ispod sonde a) primjer jezera Zmajevo oko; b) generalan primjer sa sastavnicama

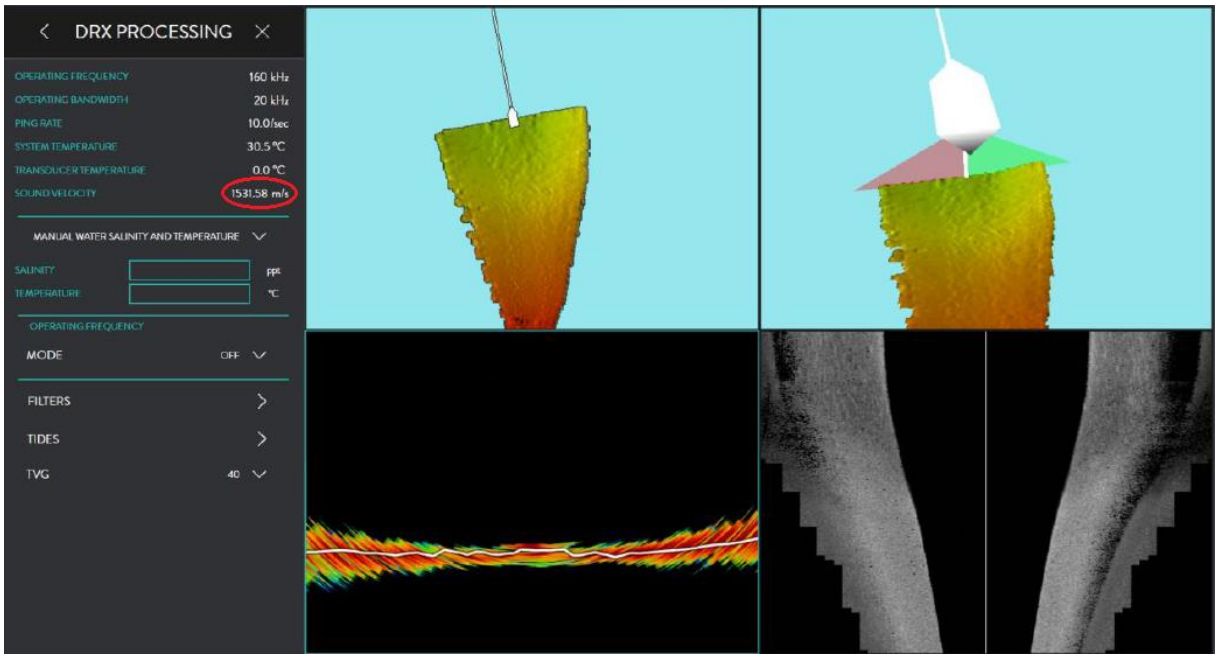

Slika 30. Sučelje softvera *CDX* s podatkom o brzini zvuka

4.2.4. Prikupljanje i obrada batimetrijskih podataka

Prilikom prikupljanja podataka postotak preklapanja snimaka iznosio je 50% jer je relativno mala površina područja istraživanja to dozvolila. Operativna frekvencija iznosila je 160 kHz, dok je operativna širina snopa bila 20º. Stopa pinga varirala je od 10 do 14/sek. Također, uređaj je u realnom vremenu prikupljao i prikazivao podatke o položaju broda, brzini, azimutu, odstupanju od ravnine i dubini na temelju unaprijed definiranih korisničko definiranih postavki sustava. Prilikom prikupljanja podataka GPS antena je preko GSM mreže spojena na CROPOS sustav. To je omogućilo vrlo visoku preciznost prikupljenih podataka. Sustav je prikupljao podatke u WGS84_UTM_N33 projekciji. U procesu obrade s ciljem standardizacije svi podatci transformirani su u HTRS96 projekciju.

Mjerenje jezera Zmajevo oko izvršeno je četiri puta (Tablica 8) (Slika 31-32). Ukupno je prikupljeno 4 674 864 točaka. Minimalna prikupljena vrijednost dubine iznosila je u -0,73 m, a maksimalna dubina -20,37 m (Tablica 6). Maksimalne vrijednosti se odnose na potencijalne vertikalne tunele (pukotine) ili greške koje su uvjetovane mjernim sustavom. Raspon vodostaja na dan snimanja praćen je s uređajem *Stonex S10*. Kao srednja vrijednost uzet je vodostaj od 0,21 m.

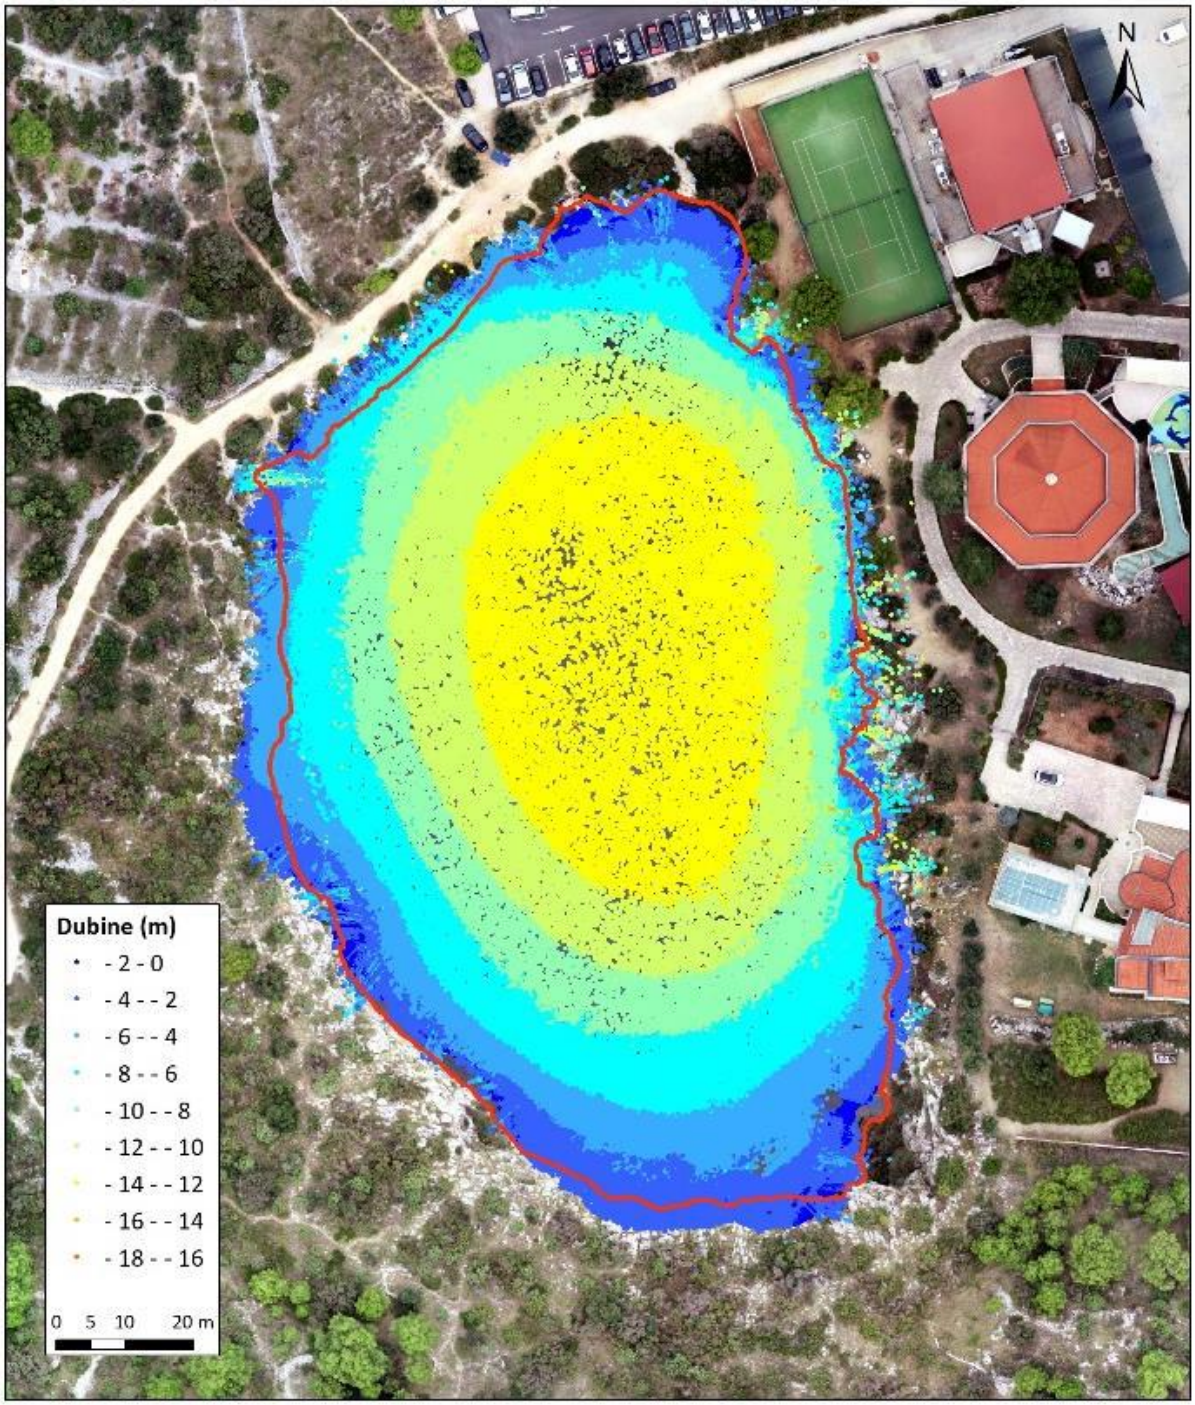

Slika 31. Izmjerene dubine jezera Zmajevo oko

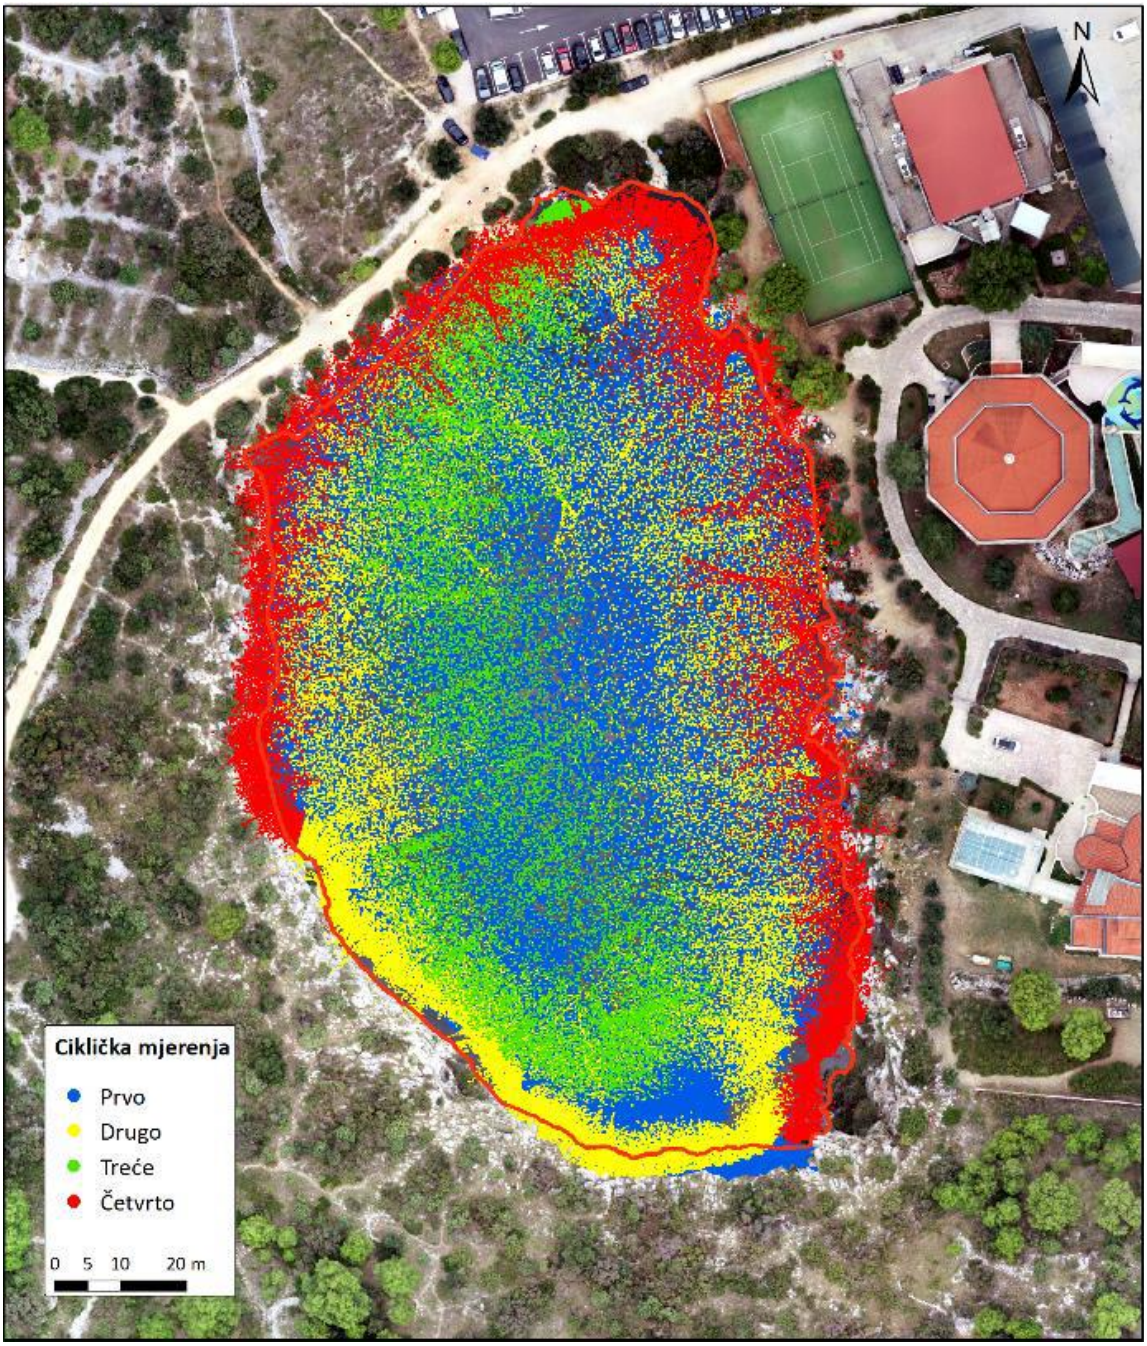

Slika 32. Gusti oblak neobrađenih prikupljenih točaka cikličnih mjerenja

Tablica 6. *Karakteristike prikupljenih neobrađenih točka*

Izmjera	LAS Dataset	Min Z	Max Z	Z Range	LAS Files	Broj točaka
1.	LAS_0.lasd	-0,91	-18,54	-17,63	1	1 397 243
2.	LAS_1.lasd	-0,73	-19,82	-19,09	1	1 267 833
3.	LAS_2.lasd	-1,07	-20,37	-19,3	1	1 487 819
4.	LAS_3.lasd	-1,25	-16,91	-15,66	1	521 969
Ukupno						4 674 864

Izmjereni podatci su preko programskih paketa (aplikacija) za navođenje *CDX* (Slika 22) i upravljanje podatcima *Data Manager* (Slika 26) prebačeni na stolno računalo na daljnju obradu i interpretaciju. Korišteni programski paketi tijekom mjerenja kreiraju zasebnu datoteku s informacijama o položaju točke, vremenu u kojem je točka registrirana, dubini i atributima o tvrdoći u svakoj točki. Programski paketi imaju samo mogućnost eksportiranja točaka u *.xyz* formatu. S obzirom na raspored, gustoću i brojnost uzoraka navedeni format nije prikladan za daljnju obradu, analizu, vizualizaciju i interpretaciju podataka. Stoga su sve točke pomoću alata, unutar softverskog paketa *ArcMap 10.1.*, konvertirane u *.las* format (preporuka američkog društva za fotogrametriju i daljinska istraživanja).

4.2.5. Ispitivanje vertikalne i horizontalne preciznosti integralnog mjernog sustava

Za ispitivanje vertikalne i horizontalne preciznosti integralnog mjernog sustava bilo je potrebno usporediti vertikalne i horizontalne vrijednosti minimalno dva nefiltrirana gusta oblaka točaka koji pokrivaju isto područje. U alatu *C2C* (*Cloud to Cloud*) unutar programa *CloudCompare* uspoređeni su gusti oblaci točaka prvog (OP_0) i trećeg (OP_2) cikličnog snimanja (Slika 33).

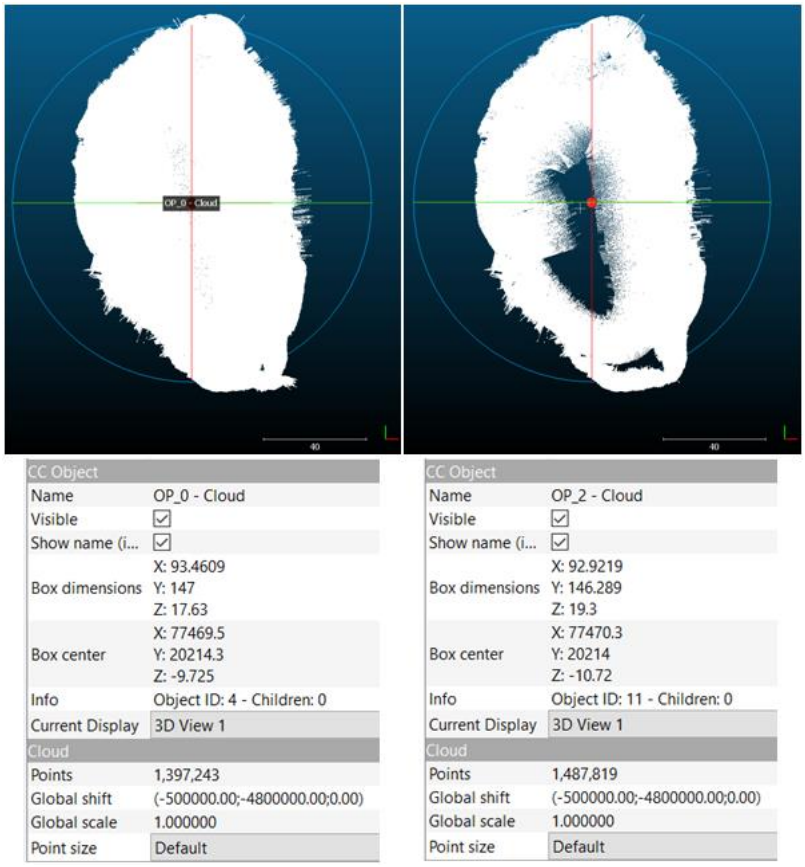

Slika 33. Uspoređeni gusti oblaci točaka s karakteristikama

U opciji *Choose role* kao referentni oblak točaka postavljen je OP_0 (1 397 243 točke) jer najbolje reprezentira cijelo jezero, dok je OP_2 (1 487 819 točaka) postavljen kao uspoređeni oblak. Iako OP_2 ne obuhvaća cijelo područje, on ima više točaka od OP_0 (Slika 34).

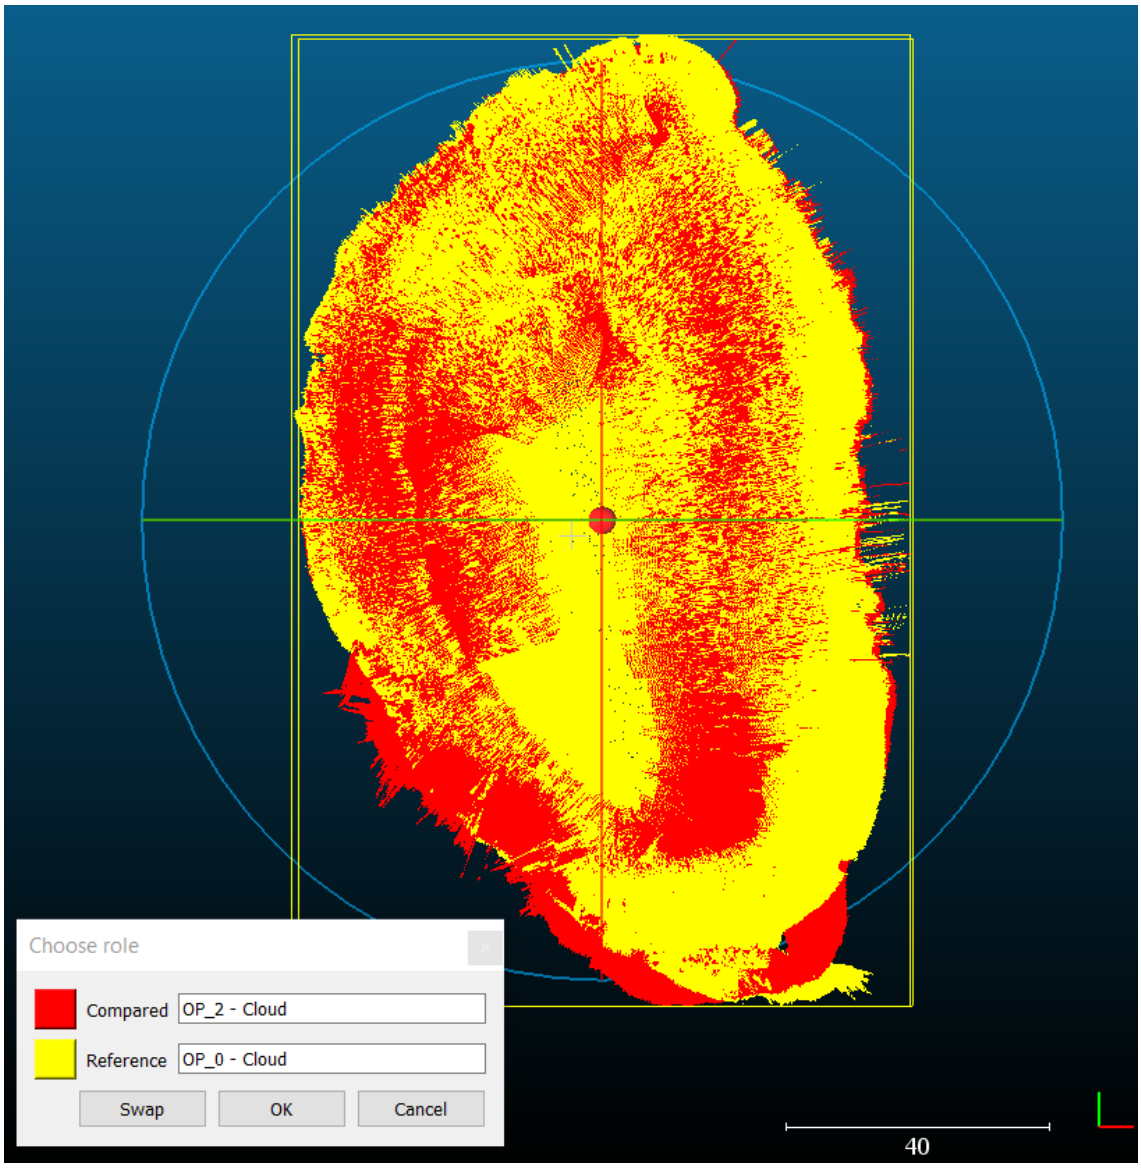

Slika 34. Odabir referentnog i uspoređenog oblaka točaka u opciji *Choose role* unutar programa *CloudCompare*

U opciji *Distance computation* unutar alata *C2C* podešeni su parametri za izradu modela apsolutnih udaljenosti uspoređenih oblaka. Za izračun udaljenosti u opciji *General parameters* razina ekstrahiranja (*Octree level*) je postavljena na automatsko, dok je maksimalna udaljenost postavljena na 1 m jer se preko 90% točaka nalazi unutar udaljenosti od 1 m, a maksimalna greška, provjerena u opciji *Approximate distances* iznosi 0,579 m (Tablica 7).

Tablica 7. *Prosječne udaljenosti točaka uspoređenih oblaka OP_0 i OP_2*

	Vrijednosti udaljenosti (m)
Min dist.	0
Max dist.	8,52358
Avg dist.	0,360326
Sigma	0,78311
Max error	0,579956

Alat *M3C2* unutar *CloudCompare*-a omogućava generiranje pozitivnih i negativnih vrijednosti udaljenosti na temelju čega se izračunava standardna devijacija (SD), koja je korištena kao glavna statistička metoda za provjeru vertikalne i horizontalne preciznosti integralnog mjernog sustava. To je zapravo najčešća mjera odstupanja vrijednosti od aritmetičke sredine, a izračunava se po formuli:

$$SD = \sqrt{\frac{\sum(x_i - M)^2}{N - 1}}$$

U formuli x_i predstavlja sve vrijednosti točaka, M je aritmetička sredina, a N ukupan broj točaka (Streiner, 1996).

Najvažniji parametar unutar *M3C2* je *subsample cloud #1* u kojem je određeno da minimalna udaljenost između točaka bude 0,1 m. Upravo ovaj parametar utječe na konačan broj uzoraka na temelju kojih će se ispitati vertikalna preciznost. *Max depth* je postavljen na 1 m iz istih razloga kao i u opciji *General parameters* unutar alata *C2C*. Vertikalna i horizontalna preciznost su u konačnici ispitane na temelju 669 723 uzorka.

Standardna devijacija za vertikalnu preciznost integralnog mjernog sustava je računata i na manjem testnom području koje je obuhvaćeno s cikličnim snimcima (OP_0, OP_2 i OP_3) (Slika 35). Sva tri uspoređena uzorka su postavljena u uloge referentnog i uspoređenog oblaka. U alatu *M3C2* ponovno su postavljeni isti parametri kao i prvi put, osim što je *Max depth* postavljen na 0,2 m. SD je izračunata za svih šest mogućih kombinacija, a konačna vrijednost SD je srednja vrijednost svih SD-a.

Standardna devijacija za horizontalnu preciznost integralnog mjernog sustava također je ispitana na odabranom testnom području i to na temelju odnosa snimaka OP_2 i OP_3, odnosno OP_3 i OP_2, koji je najreprezentativniji (Slika 36). Konačna vrijednost SD je srednjak dobivene dvije vrijednosti.

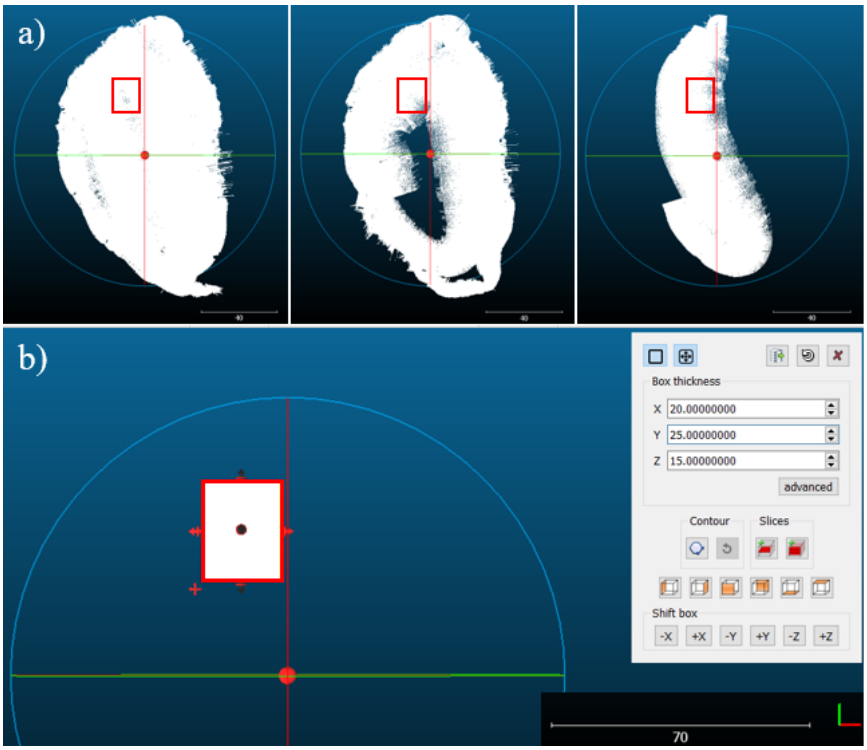

Slika 35. a) Ciklični snimci (OP_0, OP_2 i OP_3) i b) područje preklapanja snimaka korišteno za procjenu vertikalne preciznosti integralnog mjernog sustava

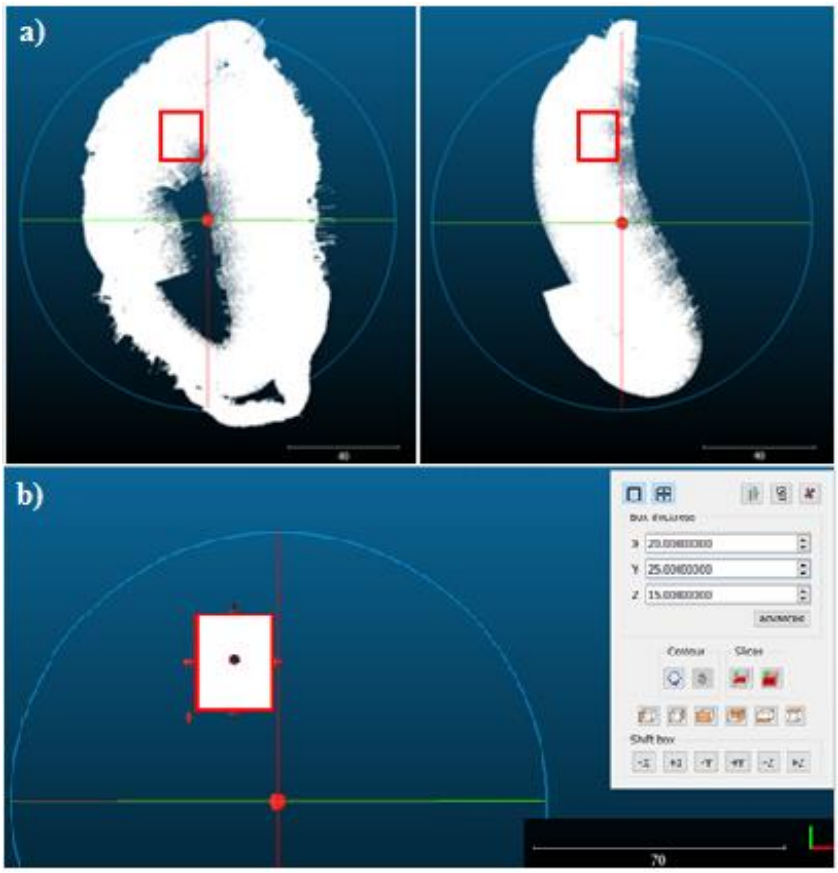

Slika 36. a) Ciklični snimci (OP_2 i OP_3) i b) područje preklapanja snimaka korišteno za procjenu horizontalne preciznosti integralnog mjernog sustava

4.2.6. Uređivanje podataka

S ciljem izrade kvalitetnog modela, prema standardima Međunarodne hidrografske organizacije, jedan od najzahtjevnijih zadataka u procesu modeliranja jezera je filtracija podataka. Naime, sustav prikupi mnoštvo visinskih podataka koji ne reprezentiraju morfologiju dna jezera, već mogu biti različiti šumovi i greške koje je potrebno pročistiti.

S obzirom na specifičnosti jezera teško je iz gustog oblaka točaka uočiti i zaključiti jesu li značajnija odstupanja od prosječnih vrijednosti za pojedina područja greške ili pak tuneli (pukotine). Jedna od budućih aktivnosti zasigurno može biti provjera specifičnih odstupanja metodom mjerenja dubina viskom na točno određenim koordinatama. U procesu filtracije podataka korištene su dvije metode u softveru *CloudCompare*: ručna metoda (iz 3D prikaza i profila) (Slika 37-38) i metoda segmentacije (Slika 39). Ručna metoda uklanjanja grešaka je izrazito dugotrajan i zahtjevan proces u kojem istraživač na temelju iskustva iz 3D prikaza i uzdužnih i poprečnih profila uklanja greške, prateći pritom konfiguraciju dominantnog terena..

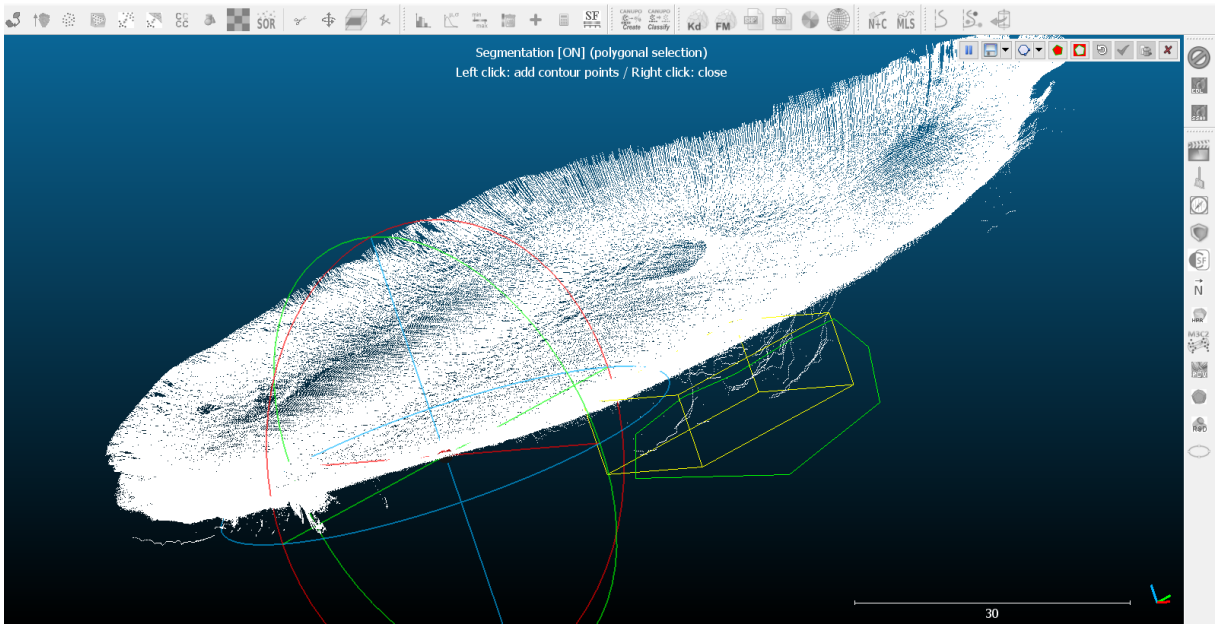

Slika 37. Primjer ručnog uklanjanja grešaka iz 3D prikaza u softveru *CloudCompare*

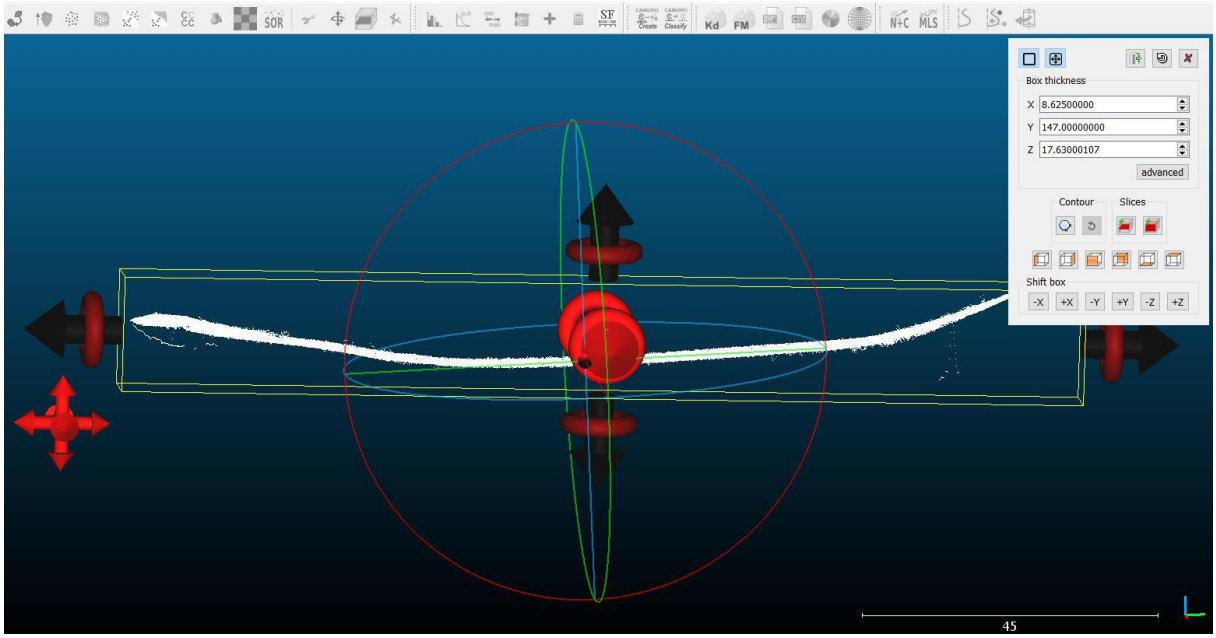

Slika 38. Primjer ručnog uklanjanja grešaka iz profila u softveru *CloudCompare*

Automatsko uklanjanje grešaka obavljeno je pomoću alata *LabelConnected Components* u *CloudCompare*-u koji koristi 3D rešetku za ekstrahiranje povezanih komponenti. Ovaj alat segmentira odabrane oblake u manje dijelove odvojene minimalnom udaljenošću, pri čemu je svaki dio povezana komponenta (tj. skup 'spojenih' točaka). Alat zahtjeva poznavanje nekoliko važnih parametara. Prvi je Razina ekstrahiranja (*Octree level*) kojim se definira minimalni razmak između dvije komponente. Što je razina viša to je razmak između komponenti manji što rezultira gušćom ćelijom, odnosno dobiva se više oblaka točaka koji su podskupine izvornog oblaka. Razina ovisi o ukupnom broju i gustoći prikupljenih točaka te je s obzirom na to postavljena razina 10. Sljedeći parametar je Minimalan broj točaka po komponenti (*Minimum points per component*). On je također uvjetovan brojem i gustoćom prikupljenih točaka te je definirano da se sve komponente koje imaju manje od 10 točaka zanemare. Na posljetku je označena i opcija Slučajne boje (*Random colors*) kojom je svakoj komponenti dodijeljena slučajna boja kako bi se lakše uočile razlike među komponentama. Po završetku *CloudCompare* je stvorio više oblaka kao komponenti koji su zapravo odgovarajuća podskupina izvornog oblaka s istim značajkama(skalarna polja, normale, boje itd.). Označeni su oblaci koji predstavljaju šumove i greške nastale u procesu prikupljanja podataka te opcijom Izbriši (*Delete*) uklonjeni iz skupa točaka koji ide u daljnji proces obrade.

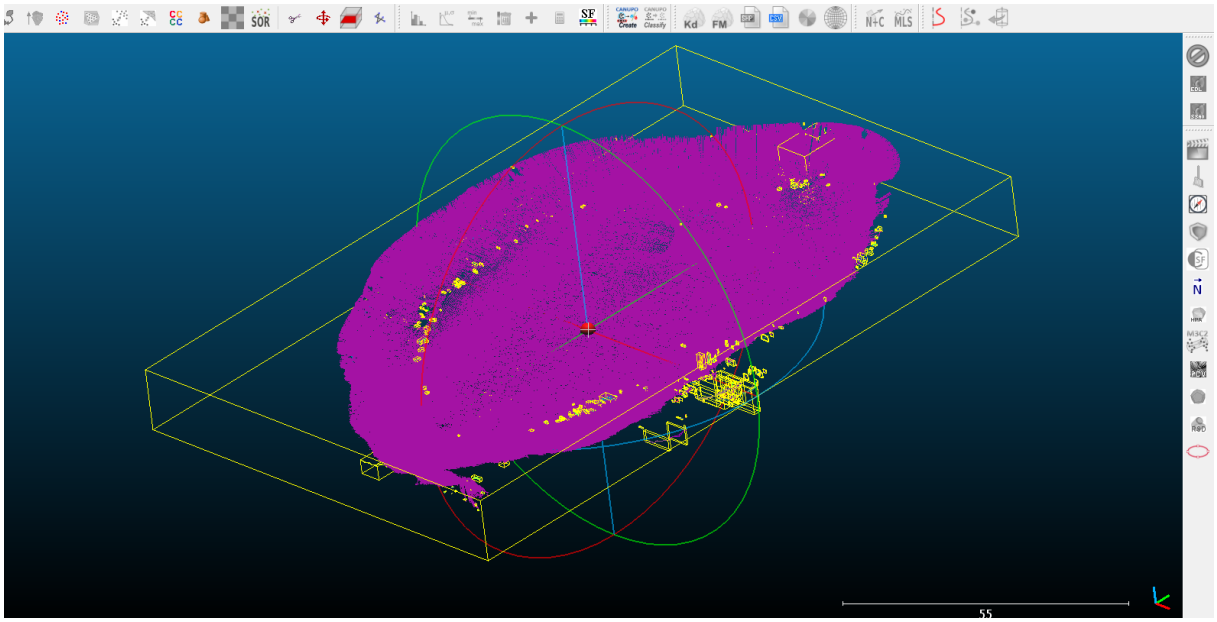

Slika 39. Primjer automatskog filtriranja gustog oblaka točaka procesom segmentacije u softveru *CloudCompare*

4.2.7. Filtracija podataka primjenom *SOR filter-a*

Za uspješnije filtriranje točaka korišten je napredni *SOR filter* (*Statistical Outlier Removal*) unutar *CloudCompare-a*. On filtraciju podataka vrši na sljedeći način. Za početak izračunava prosječnu udaljenost svake točke do svojih susjeda. Potom odbacuje, odnosno briše sve točke čija je udaljenost od susjednih točaka izvan intervala definiranog prosječnom udaljenosti i standardnim odstupanjem. *SOR filter*ima dva parametra. U prvom (*Number of points to use for mean distance*) se definira broj susjednih točaka koji će se koristiti za izračun 'udaljenosti do susjeda' za svaku točku. Prema zadanim postavkama određeno je da je to broj 6. Drugi parametar (*Standard deviation multiplier threshold (nSigma)*) odnosi se na množitelja standardnog odstupanja koji može biti bilo koji realni broj između 0 i 10 uključujući i njih. *SOR filter* je veoma osjetljiv te se za ovaj parametar predlaže odabir veće vrijednosti od broja točaka unutar klastera (Shen i dr., 2011). Stoga je određeno da sve točke čije je standardno odstupanje veće od onog pomnoženog s brojem 8 bude označeno te na posljetku filtrirano. Dobiven je u potpunosti 'čist' oblak točaka bez šumova i pogrešnih očitanja koji je spreman za interpolaciju.

4.2.8. Interpolacija podataka prikupljenih batimetrijskom izmjerom

Da bi se dobile kontinuirane površine (visoko rezolucijski modeli) koje su neophodne za proučavanje, a time i poznavanje dna Zmajevog oka bilo je potrebno procijeniti vrijednosti

na neuzorkovanim područjima koristeći pritom optimalnu interpolacijsku metodu i prostornu rezoluciju. Interpolacija je proces računanja vrijednosti za određenu točku uz pomoć dviju ili više susjednih točaka s poznatim vrijednostima. Nova vrijednost u točki nikad ne prelazi interval određen susjednim točkama, a procijenjena vrijednost se svrstava u područje mogućega (Šiljeg i dr, 2018). Slijedeći primjere dobre prakse unutar digitalnog modeliranja reljefa odabrana je metoda interpolacije prirodni susjed (*natural neighbor*).

„Prirodni susjed je jedna od najpopularnijih metoda interpolacija, sa širokom primjenom u geografskom i geofizičkom modeliranju, mehanici itd. Ona kombinira najbolje značajke metoda najbližih susjeda i triangulacijske nepravilne mreže. To je metoda ponderiranog prosjeka koja procjenjuje vrijednost pomoću lokalnih koordinata prirodnog susjeda na temelju Voronoijeve teselacije (proces stvaranja dvodimenzionalne ravnine ponavljanjem geometrijskih oblika bez preklapanja i praznina)" (Šiljeg i dr., 2018:45).

4.2.9. Prostorna rezolucija

Nakon procesa usporedbe metoda interpolacije, sljedeći korak je proces odabira pravilne prostorne mreže ili *grid-a*. Najveći problem za većinu znanstvenika, pri izradi digitalnih modela, predstavlja odabir prostorne rezolucije ili veličine piksela. Ona je izračunata pomoću *Grid calculator-a* i metode analize uzoraka točaka (Hengl, 2006). Prilikom izrade integralnog modela (digitalni model dubina + digitalni model površina) odabrana je optimalna prostorna rezolucija od 5 cm (*point pattern analysis*). Ona predstavlja kompromis između gustoće uzorkovanja visinskih i dubinskih točaka te površine područja snimanja. Za potrebe vizualizacije rezolucija modela je smanjena na vrijednost od 10 cm.

4.3. Izračun volumena, površine i duljine obalne linije jezera Zmajevo oko

Iz generiranih 2.5D i 3D modela jezera Zmajevo oko moguće je izvoditi različite primarne i sekundarne parametre (morfometrijske, hidrološke itd). Tako je primjerice na slici 40 prikazana izmjera specifičnih profila unutar jezera kroz odabrane poprečne presjeke. Naime, da bi se što bolje razumjela prostorno-vremenska evolucija pojedinih dijelova dna jezera potrebno je provesti detaljnu morfometrijsku i tipološku klasifikaciju određenih promatranih profila i to kroz kvantitativno opisivanje recentnih promjena u širini i dubini promatranih poprečnih presjeka jezera.

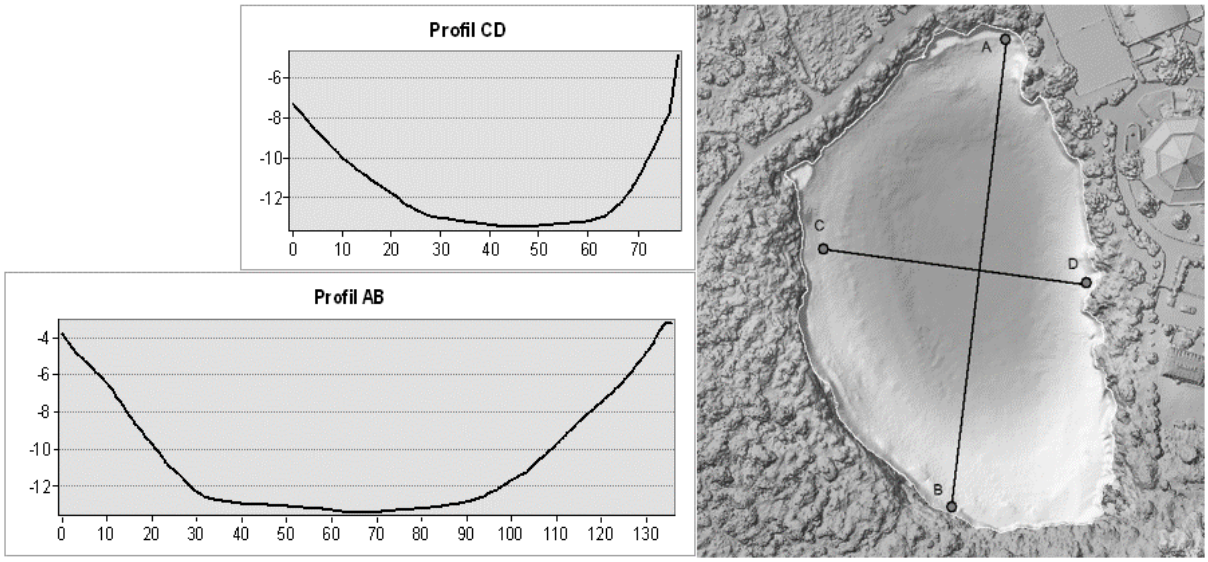

Slika 40. Uzdužni AB i poprečni CD profili jezera Zmajevo oko

U završnoj fazi batimetrijskog istraživanja izračunati su površina i volumen te duljina obalne linije jezera Zmajevo oko. „Volumen se može definirati kao količina vode koja zauzima određeni prostor između površine i dna jezera izražen u kubičnim jedinicama" (Šiljeg i dr., 2016:248).

Na izlazne rezultate mogu utjecati brojni čimbenici. To su ponajprije raščlanjenost dna, zatim odabrana metoda prikupljanja podataka, gustoća i raspored prikupljenih točaka te prostorna rezolucija (veličini piksela). No izlazni rezultati ovise i o korištenom softveru i algoritmima te metodama interpolacije koji omogućuju prikaz rezultata te njihovu usporedbu (Šiljeg i dr., 2016).

Volumen jezera Zmajevo oko izračunat je iz pravilne mreže dobivene interpolacijom. Korištene su tri *Newton-Cotesove* formule integrirane unutar softvera *Surfer* koje služe za izračun površine i volumena različitih oblika: produljeno trapezoidno pravilo, produljeno Simpsonovo 1/3 pravilo te produljeno Simpsonovo 3/8 pravilo (Šiljeg i dr., 2016).

Ukupna površina jezera i duljina obalne linije izračunate su u softveru *ArcMap 10.1.* iz DEM-a usklađenog s DOF-om dobivenim obradom aerofotogrametrijskih snimaka. Osnova za izdvajanje obalne linije jezera je izohipsa 0,21 m (vrijednosti izmjerene geodetskim GPS-om *Stonex S10*). Međutim, s obzirom na gustu vegetaciju u određenim rubnim dijelovima jezera, obalna linija je ručno vektorizirana na temelju DOF-a i 3D gustog oblaka točaka. Potom je izdvojena alatom *Contour*, a opcijom *Calculate Geometry* izračunata je njezina

duljina. Alatom *Feature To Polygon* pomoću sloja obalne linije izrađen je poligon jezera iz kojeg je opcijom *Calculate Geometry* izračunata površina Zmajevog oka.

4.4. Izvođenje virtualne šetnje jezerom Zmajevo oko

Lumion 10.0.1. je softver namijenjen za izradu 3D virtualnog okruženja. Uz brojne mogućnosti dorađivanja uvezenih 3D modela, pruža mogućnosti kreiranja video te panoramskih 360° i običnih snimaka (URL13). Za potrebe promocije Zmajevog oka izrađeno je šest panoramskih 360° snimaka postavljenih na pravilno raspoređenih šest lokacija oko jezera te kratki promotivni video. Prvi korak u fazi izrade virtualnog okruženja bio je uvoženje 3D modela iz *Agisoft Metashape Professional 1.5.1.* u *.obj* formatu. Zatim je izvršena orijentacija modela u prostoru te postavljanje mjerila. Sljedeći korak je bio odabir šest lokacija na području jezera koje će najbolje reprezentirati model (Slika 41). Odabrano je pet lokacija uz obalu jezera te jedna na sredini jezera. Završni korak za izradu panoramskih 360° snimki bio je postavljanje parametara u opciji *Render all 360 Panoramas* (Slika 42a). Kvaliteta snimki (*Output quality*) je postavljena na 4/5, uključen je stereoskopski pogled (*Stereoscopic*) i postavljen razmak između dva oka na 64,0 mm (*Eye to Eye distance*) kako bi se dobio privid dubine prostora. Snimke su izrađene za mogućnost otvaranja i pregledavanja na platformama poput računala ili mobilnih uređaja (*Generic device*) iako se može namjestiti opcija i za VR naočale (*GearVR/Oculus*). Panorame su izvezene u prostornoj rezoluciji 4096x4096 (*Medium*). Za izradu promotivnog videa izvršeno je renderiranje 50 odabranih stajališta. Parametri za izvoz videa postavljeni su u opciji *Render Clip*. Kvaliteta videa (*Output quality*) je postavljena na 5/5, a broj sličica u sekundi (*Frames per second*) na 200. Renderiranje slijeda slika iz cijelog videa (*Render image sequence from entire movie*) je postavljeno na *Full HD*, odnosno prostorna rezolucija videa postavljena je na 1920x1080 (Slika 42b)

Slika 41. Lokacije panoramskih 360º snimaka

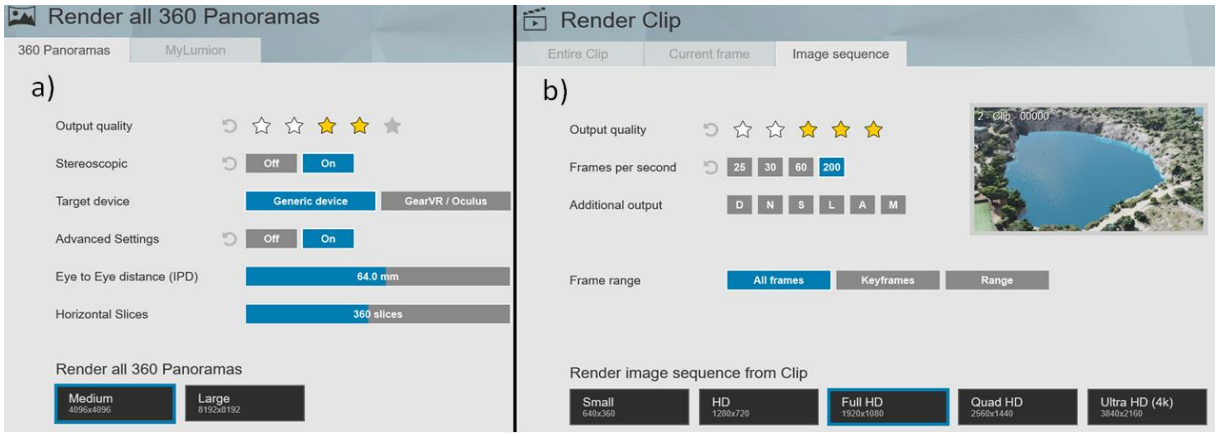

Slika 42. Postavljeni parametri za a) panoramske 360º snimke u opciji *Render all 360 Panoramas* i za b) promotivni video u opciji *Render Clip* u softveru *Lumion 10.0.1*.

4.5. 3D ispis jezera Zmajevo oko

3D ispis jezera Zmajevo oko izvršen je pomoću 3D printera *Prusa i3 MK3*. To je napredni *low cost open source* 3D printer koji je zapravo nasljednik originalnog *Prusa i3 MK2S*-a s brojnim nadogradnjama hardvera i softvera koje čine ovaj 3D printer pouzdanijim, bržim i jednostavnijim za upotrebu od prethodnih verzija (Prusa, 2019). Izrada 3D fizičkog modela sastojala se od nekoliko koraka (Slika 43). Prvo je napravljena konverzija podataka u

.stl format (*Standard Tessellation Language*) pomoću računalnog programa *Agisoft Metashape Professional 1.5.1*. To je format koji geometriju trodimenzionalnih površina prikazuje u obliku mreže trokuta (*mesh*). Ta mreža mora biti dovoljno gusta kako bi kvaliteta fizičkog modela bila visoka, ali također ne smije biti ni prekompleksna kako se ne bi preopteretio i usporio rad računala (Marić i dr., 2019). Zatim su podaci ubačeni u *Prusa i3 Control* softver kako bi se odabrali parametri 3D ispisa. Podešena je orijentacija modela te vrsta filamenta. PLA (*polylactide*) plastika pokazala se kao najbolji izbor zbog svoje kompaktnosti, čvrstoće te mogućnosti bojanja i daljnje obrade, ali i zbog biorazgradivosti s obzirom na to da je ekološki materijal koji se pravi od kukuruza (Raquez i dr., 2013). Visina sloja filamenta je prema preporukama proizvođača postavljena na 0,15 mm. Model je potom eksportiran u *G-code* format koji je standardan za većinu 3D printera i industrijskih strojeva. U završnoj fazi model je USB memorijom prebačen na prethodno kalibrirani 3D printer i izvršen je 3D ispis modela jezera.

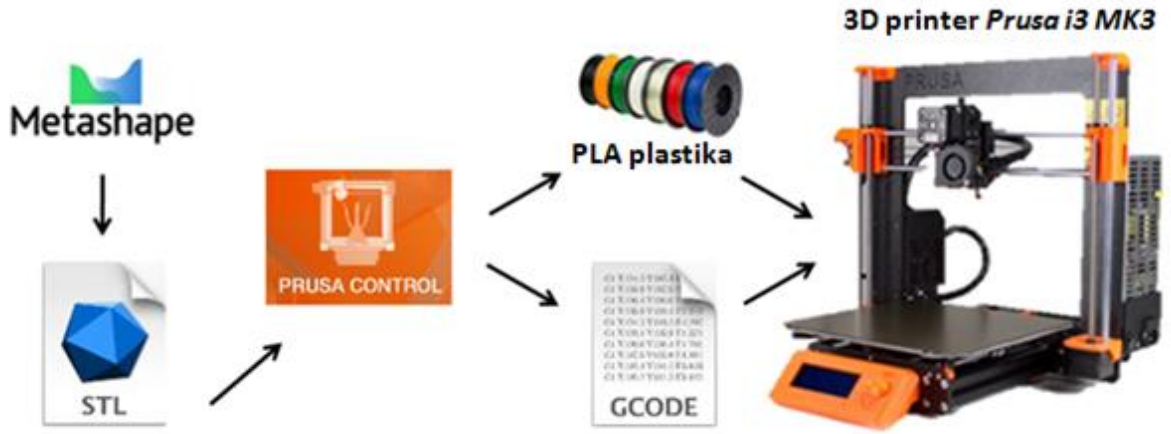

Slika 43. Shematski prikaz procesa 3D ispisa jezera Zmajevo oko (prema: URL7; URL8; URL12; URL14; URL18)

5. Rezultati

5.1. Točnost modela izrađenih procesom aerofotogrametrije

Tablica 8. *Točnost orijentacijskih točaka preuzeta iz Agisoft izvješća*

Label	X error (cm)	Y error (cm)	Z error (cm)	Total error (cm)	Image (pix.)
OT1	0,2969	-1,6864	1,4370	2,2354	0,2910
OT2	0,0016	2,4146	-0,9491	2,5945	0,3350
OT4	-0,0548	-0,5395	-1,6983	1,7828	0,2260
OT7	-0,4444	-1,1989	2,8345	3,1095	0,3150
OT8	-0,6817	-0,7466	1,1504	1,5315	0,4350
OT9	0,8825	1,7566	-2,7753	3,4010	0,4770
MAE	**0,3936**	**1,3904**	**1,8074**	**2,4424**	**0,3465**
RMSE	**0,5053**	**1,5300**	**1,9541**	**2,5327**	**0,3568**

Tablica 9. *Točnost kontrolnih točaka preuzeta iz Agisoft izvješća*

Label	X error (cm)	Y error (cm)	Z error (cm)	Total error (cm)	Image (pix.)
OT3	2,4512	-2,6298	-1,7342	3,9914	0,2970
OT5	1,6740	-2,1828	-0,1587	2,7554	0,1570
OT7	-0,3151	-4,9591	1,5946	5,2187	0,0820
MAE	**1,4801**	**3,2572**	**1,1625**	**3,9885**	**0,1787**
RMSE	**1,7234**	**3,4772**	**1,3632**	**4,133**	**0,1997**

Vrijednosti RMSE-a i MAE-a se gotovo u potpunosti podudaraju (Tablica 8-9). U rezultatima je očekivano točnost orijentacijskih točaka nešto bolja od kontrolnih (Slika 44). RMSE orijentacijskih točaka za X os iznosi 0,0553, za Y 1,5300, za Z os 1.9541 cm. Ukupna RMSE orijentacijskih točaka iznosi 2,5327 cm. RMSE u koordinatnom sustavu slike iznosi 0,3568 pix. RMSE kontrolnih točaka je nešto lošija, za X os iznosi 1,7234, za Y 3,4772 dok za Z os 1,3632 cm. Ukupna RMSE kontrolnih točaka iznosi 4,1133 cm. RMSE u koordinatnom sustavu slike iznosi 0,200 pix. Ukupna pogreška pomaka odgovara

vrijednostima koje su postignute u sličnim studijama i radovima, a orijentacijske točke se nalaze unutar oštrog prostora slike (DOF).

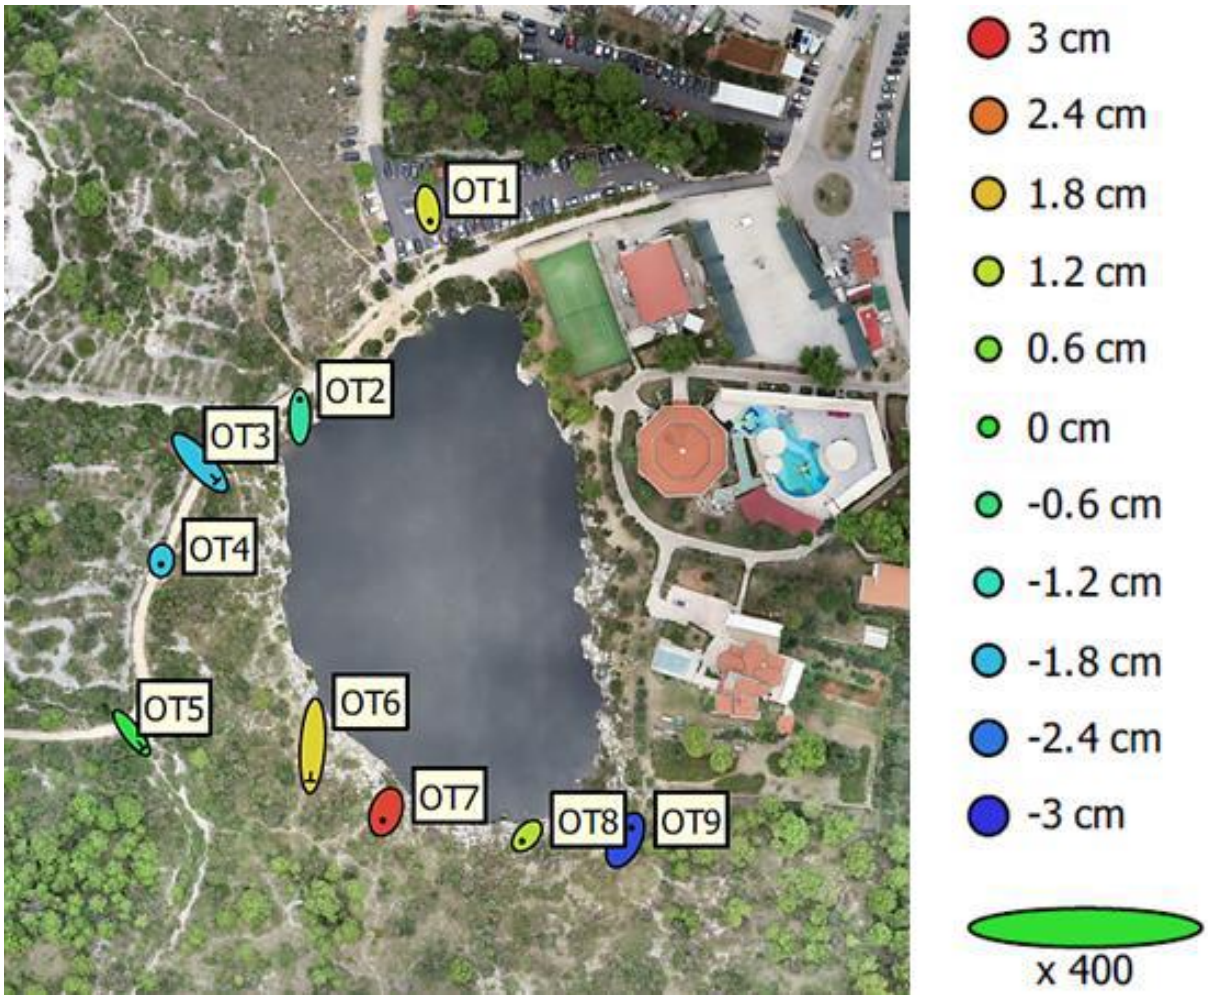

Slika 44. Procjena pogreške za orijentacijske i kontrolne točke (X, Y pogreške su predstavljene oblikom elipse, Z pogreška je predstavljena bojom elipse)

5.2. Gusti oblak točaka

Generirani oblak točaka se sastoji od 105 484 025 točaka (Slika 45).

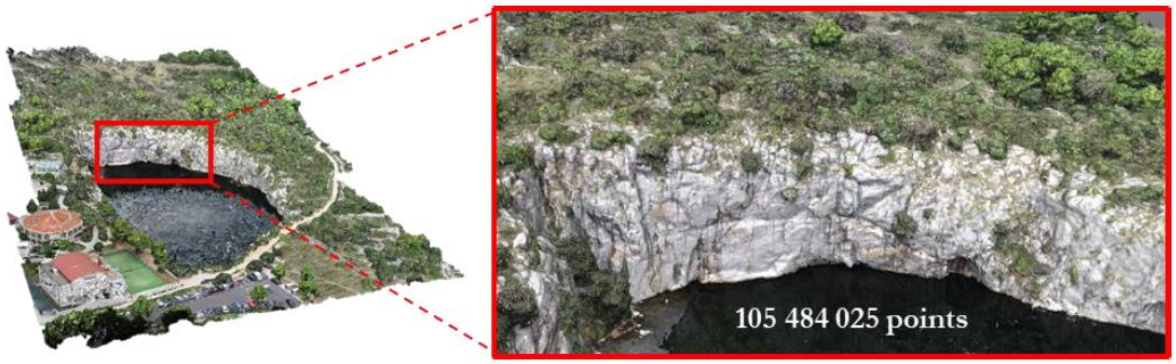

Slika 45. Generirani gusti oblak točaka užeg područja jezera Zmajevo oko

Iz gustog oblaka točaka generiran je poligonski model jezera Zmajevo oko. Ukupno je generirano preko 2 mil. poligona za uži prostor Zmajevog oka. Generirani poligonski model jezera je u konačnici teksturiran (Slika 46).

Slika 46. Poligonski model jezera Zmajevo oko

5.3. 2.5D i 3D modeli jezera Zmajevo oko

Iz aerofotogrametrijskog snimanja provedenog 19. studenog 2019. Izvedeni su sljedeći modeli jezera Zmajevo oko:

1) Visoko-rezolucijski digitalni ortofoto snimak (DOF) (Slika 47)

2) Visoko-rezolucijski digitalni model površina (DSM) (Slika 48)

3) 3D model jezera (.*obj* format) (Slika 49)

Nova 1) visoko-rezolucijska digitalna ortofoto (DOF) karta jezera Zmajevo oko je izvedena u prostornoj rezoluciji 1,56 cm (Slika 47). Ortofoto karta je planimetrijski ispravna snimka iz zraka, koja po metričkim svojstvima, u potpunosti odgovara karti istog mjerila (URL1). Izrada ortofoto karte temelji se na orijentiranom digitalnom fotogrametrijskom snimku i digitalnom modelu reljefa.

Slika 47. Visoko-rezolucijski DOF snimak jezera Zmajevo oko

Iz gustog oblaka točaka generiran je 2) digitalni model površina (DSM) užeg područja jezera Zmajevo oko. Prostorna rezolucija modela posljedica je postavki parametra *Quality* koja je postavljena na *High*. U konačnici je generiran model prostorne rezolucije 3,115 cm (Slika 48).

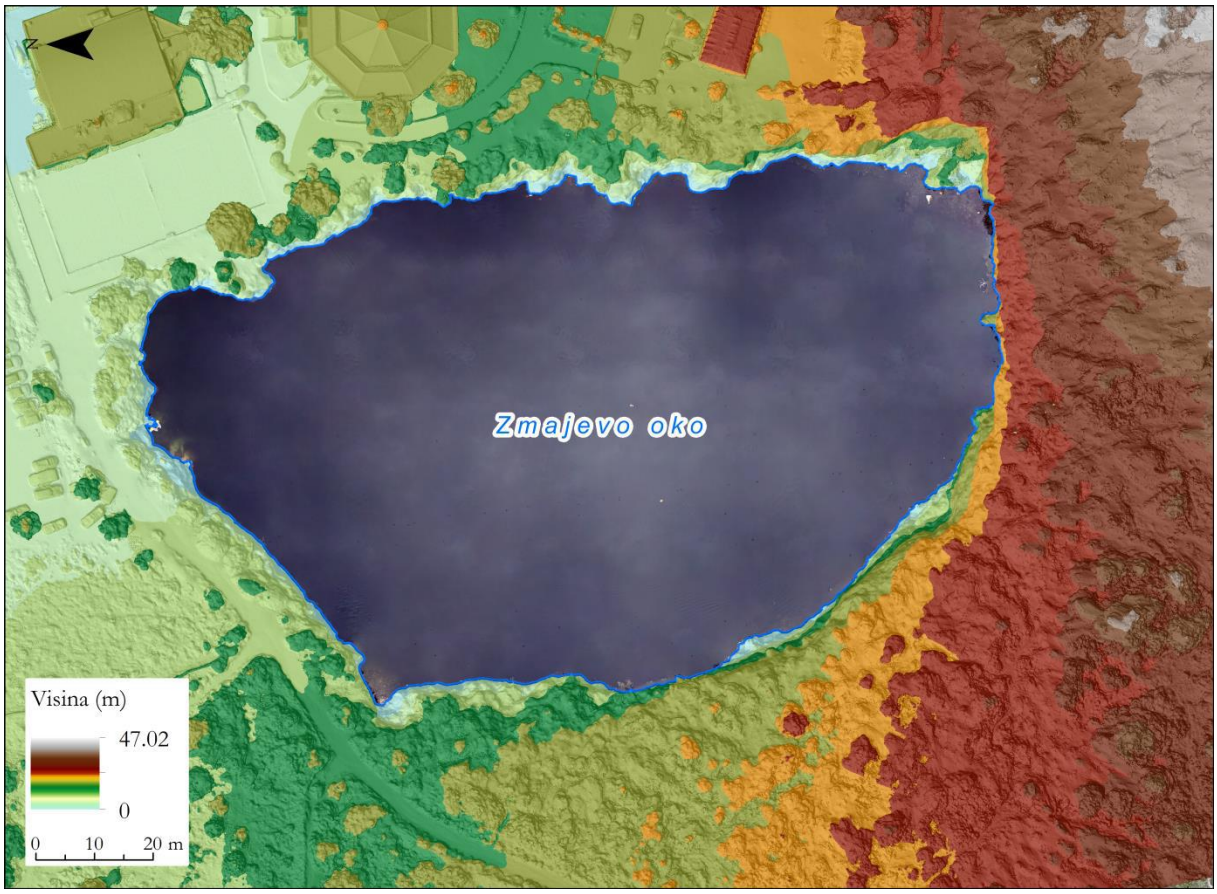

Slika 48. Digitalni model površina (DSM) užeg područja jezera Zmajevo oko

Na poslijetku je generiran 3) 3D model šireg područja Zmajevo oko u formatu *.obj* (Slika 49). Izvedeni model može poslužiti za promotivne svrhe. Naime, njegovom primjenom moguće je kreirati virtualnu šetnju prostorom oko jezera. Da bi to bilo moguće potrebno je napraviti renderiranje odabranih stajališta oko jezera. No moguće je izraditi i snimku virtualne šetnje u kojoj korisnik nije u mogućnosti sam upravljati i donositi odluke već je cijela šetnja unaprijed isprogramirana. Na temelju ovog modela izrađene su panoramske 360° snimke i kratki promotivni video.

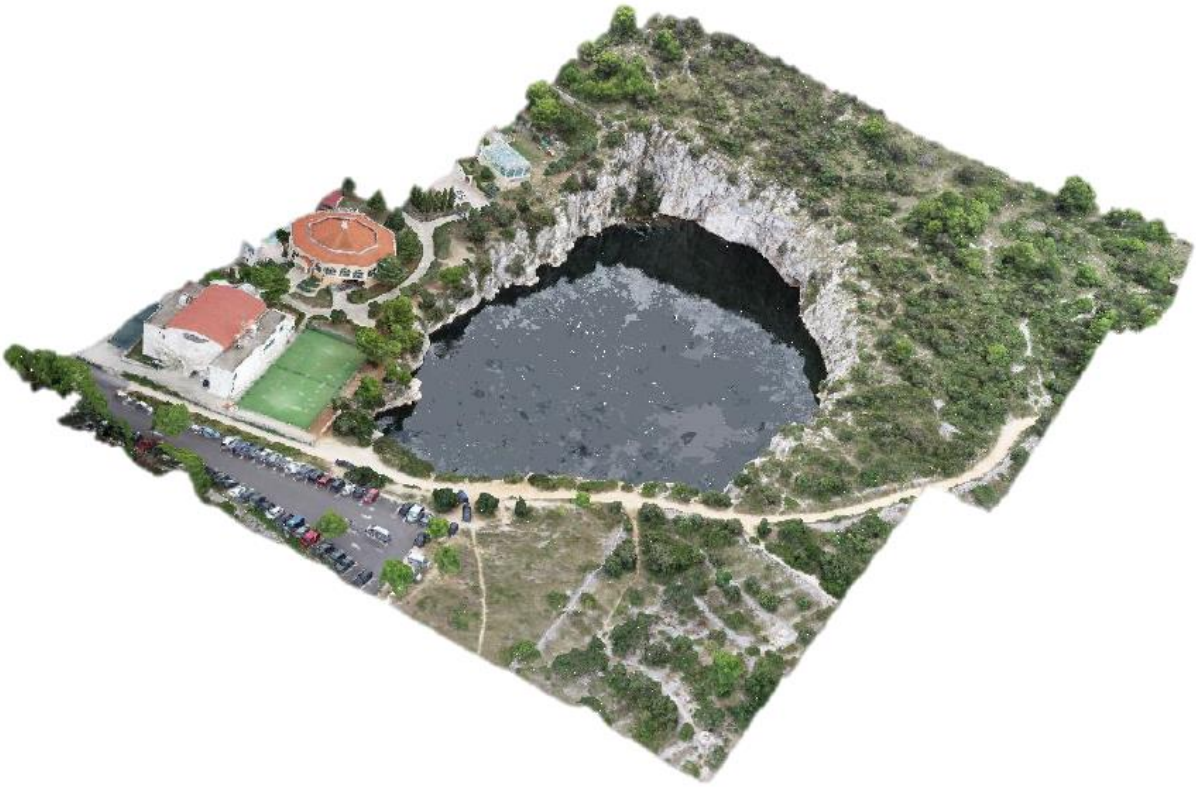

Slika 49. 3D model užeg prostora jezera Zmajevo oko

5.4. Vertikalna i horizontalna preciznost integralnog mjernog sustava

Pomoću alata *C2C* generiran je *C2C absolute distances* model koji prikazuje razlike između dva gusta oblaka točaka u metrima (Slika 50). Model potvrđuje pretpostavku da je najveća razlika među udaljenostima u onim dijelovima jezera koji nisu obuhvaćeni s oba ciklična snimanja. Razlog tomu je taj što je naglasak u OP_2 bio u kartiranju bočnih tunela (pukotina) pri čemu je brzina plovljenja brodom bila znatno manja te je često dolazilo do izmjene kursa što je utjecalo na veću gustoću uzorkovanja. Isto tako u OP_2 ne postoje podaci iz sredine jezera, jer to područje nije bilo u planu tog cikličnog snimka, što je također utjecalo na maksimalne vrijednosti udaljenosti točaka.

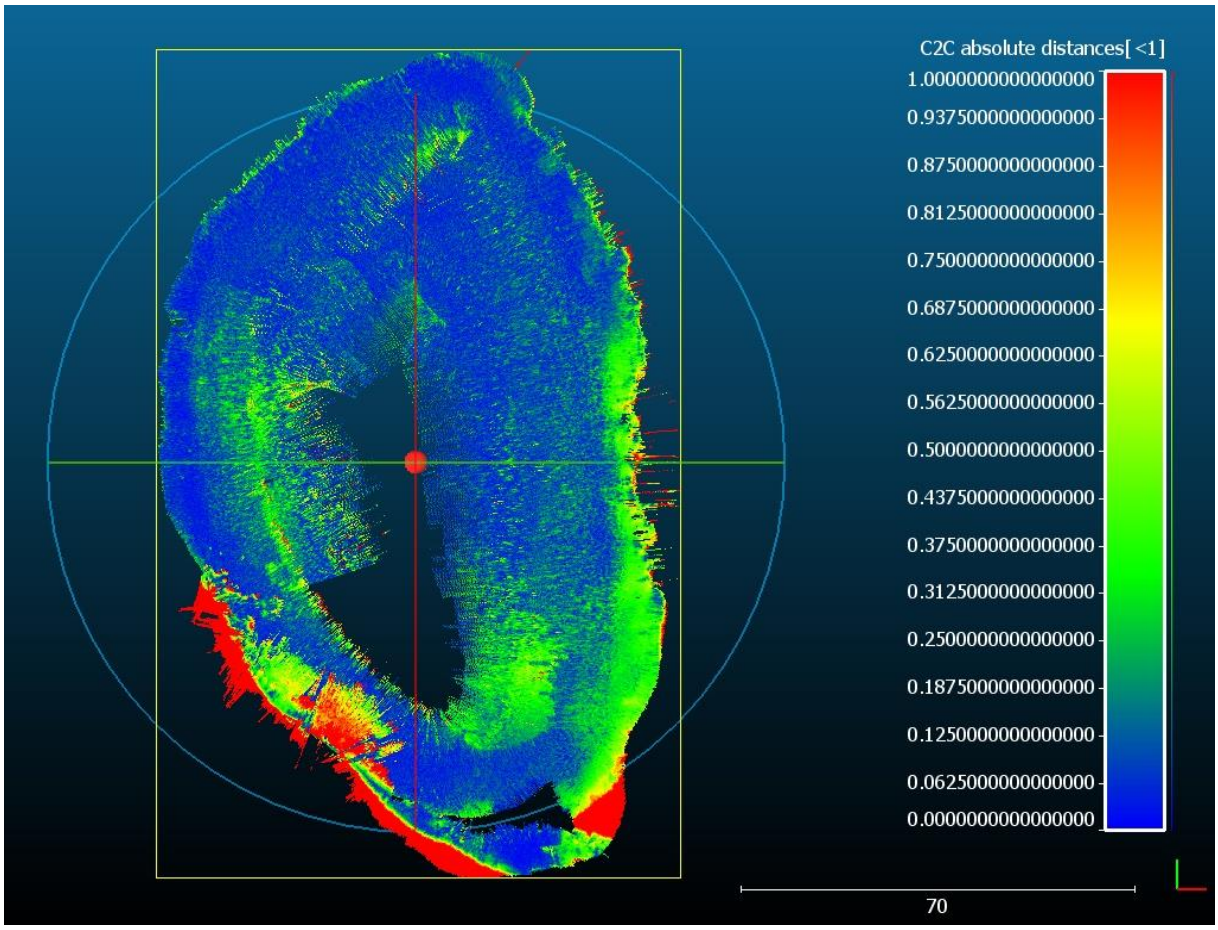

Slika 50. *C2C absolute distances* model

S ciljem prikazivanja distribucije vrijednosti standardne devijacije za vertikalnu i horizontalnu preciznost generirana je tematska karta koja prikazuje preklapanje uspoređenih oblaka točaka (Slika 52). Na generiranoj tematskoj karti nesigurnosti podataka se uočava kako > 90% vrijednosti se nalazi unutar 0,1 m (Slika 51).

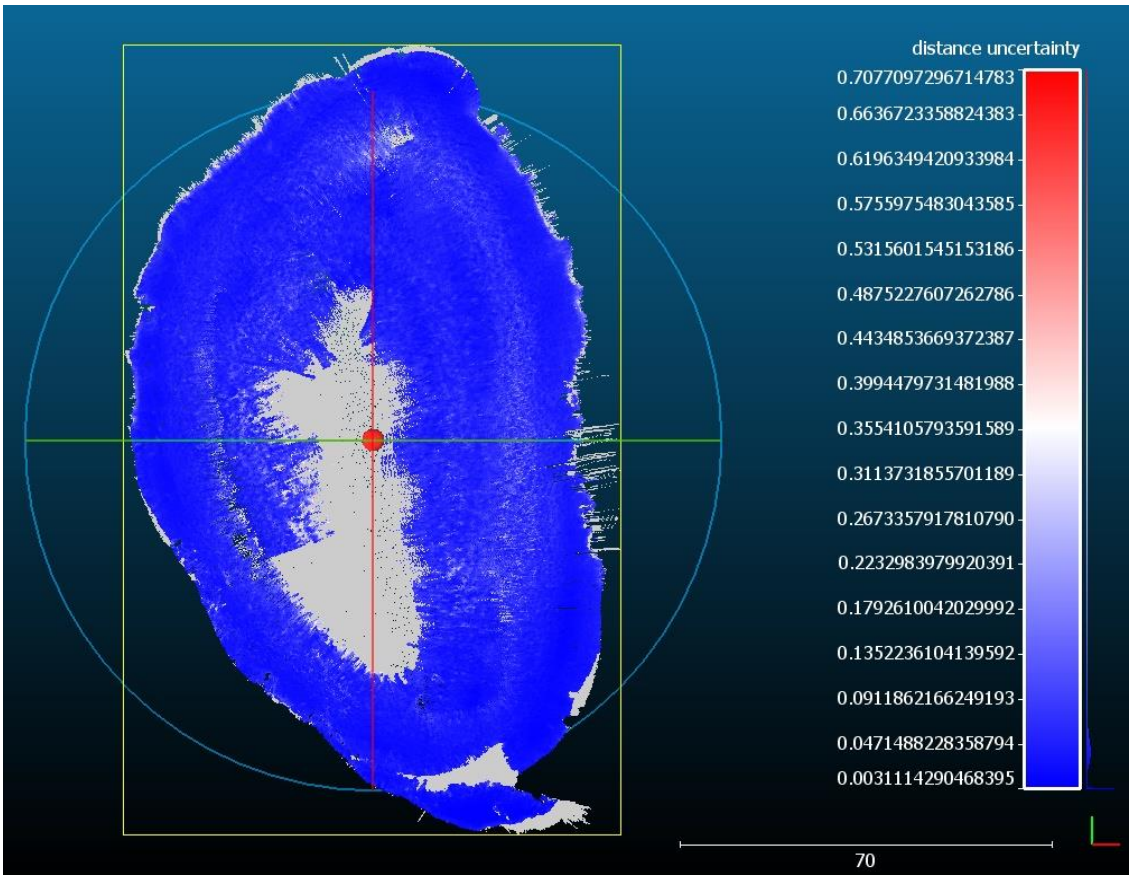

Slika 51. Tematska karta nesigurnosti podataka

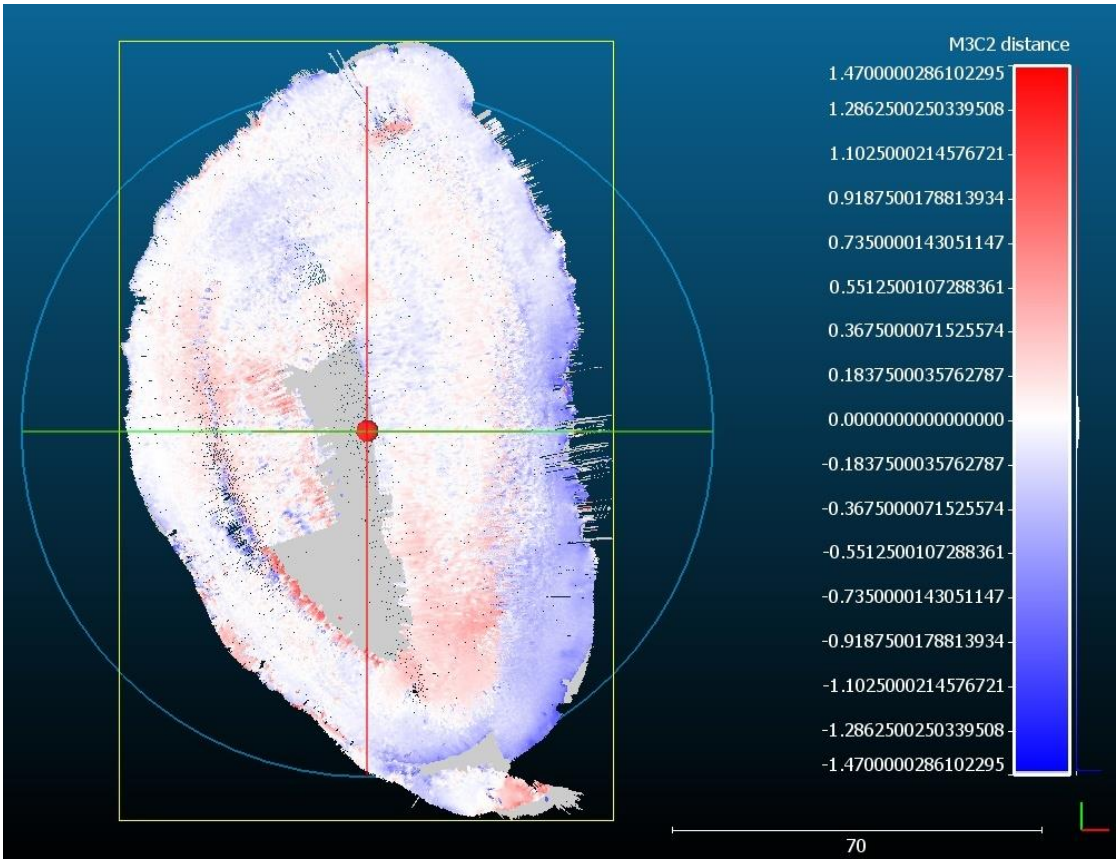

Slika 52. Tematska karta s vrijednostima odstupanja uspoređenih oblaka točaka OP_0 i OP_2

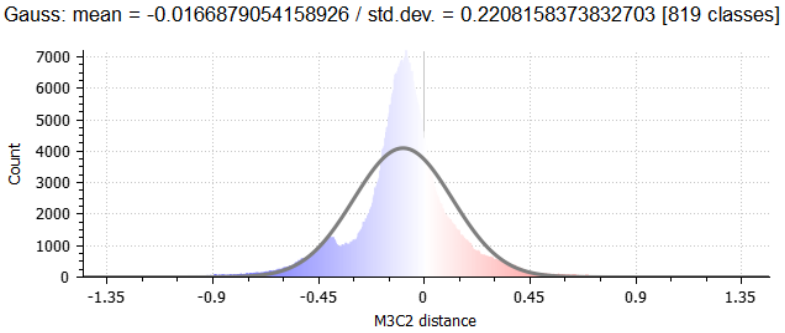

Slika 53. Histogram standardne devijacije za vertikalnu preciznost

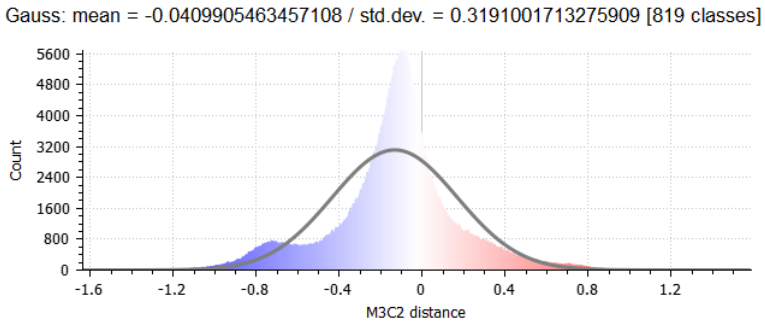

Slika 54. Histogram standardne devijacije za horizontalnu preciznost

Histogrami prikazuju distribuciju vrijednosti standardne devijacije za vertikalnu (Slika 53) i horizontalnu (Slika 54) preciznost. SD izračunata na temelju usporedbe gustih oblaka točaka OP_0 i OP_2 u alatu *M3C2* za vertikalnu preciznost iznosi 22,1 cm, a za horizontalnu 31,9 cm.

SD izračunata je za dva slučaja. U prvom slučaj je OP_0 postavljen kao referentni oblak, a u drugom OP_2. Uočena je razlika u SD s obzirom na to koji je oblak točaka postavljen kao referentni (Slika 55).

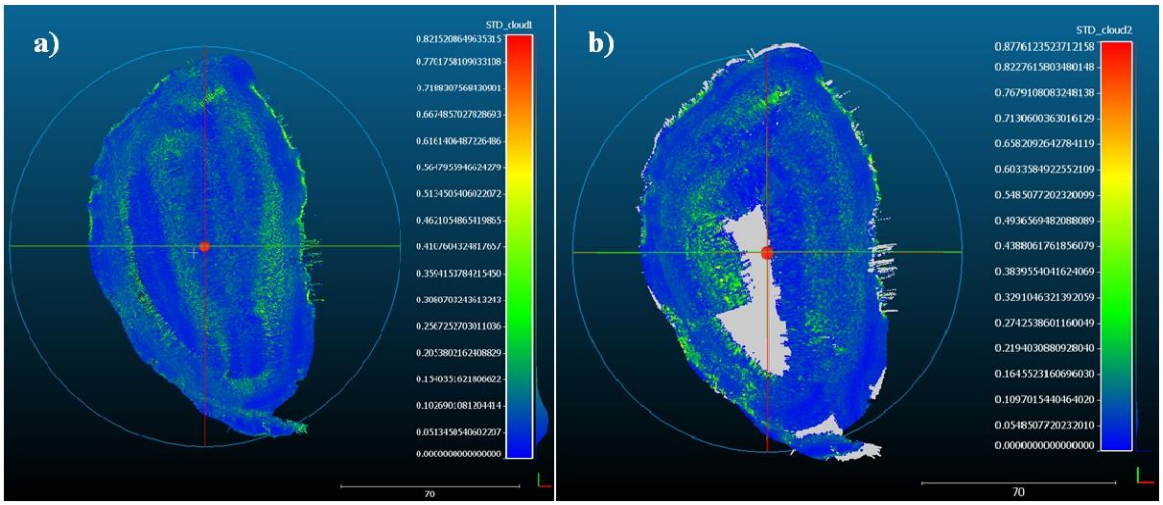

Slika 55. Vrijednosti SD za vertikalnu preciznost u slučaju: a) OP_0 kao referentni oblak i b) OP_2 kao referentni oblak

Važno je istaknuti kako maksimalna udaljenost između točaka iznosi 8,524 m (Tablica 7), što je i očekivano jer postoje dijelovi jezera koji nisu obuhvaćeni u oba ciklična snimanja. U OP_2 nedostaju točke sa sredine jezera, a u OP_0 nedostaju točke iz bočnih tunela (pukotina). Upravo je to razlog zašto je standardna devijacija računata ponovno, ali ovaj put na manjem testnom području koje je obuhvaćeno s tri ciklična snimanja na kojima je približno jednaka gustoća uzorkovanja (OP_0, OP_2 i OP_3) (Slika 43). SD je računata za svih mogućih šest kombinacija pri kojima uzorak svakog cikličnog snimka bio u ulozi referentnog i uspoređenog oblaka točaka (Slika 56-58).

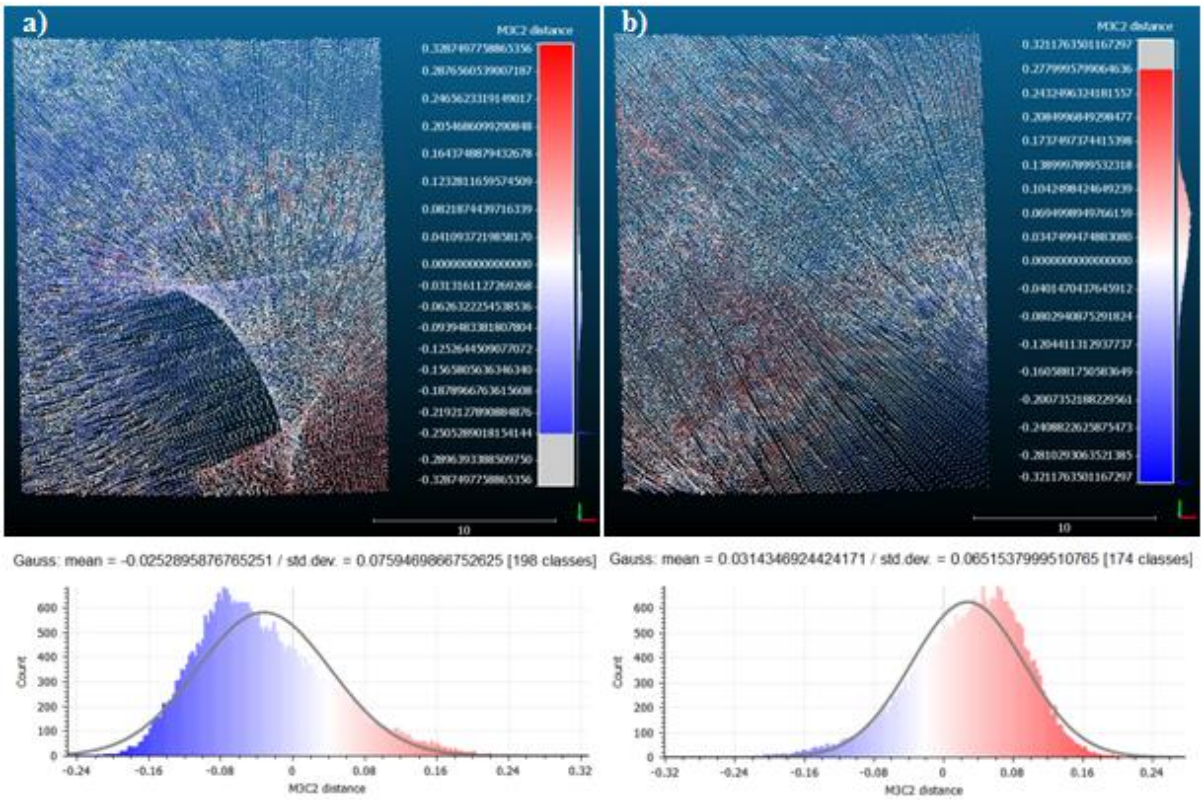

Slika 56. Vertikalna preciznost - odnos snimaka: a) OP_0 - OP_2 i b) OP_2 - OP_0

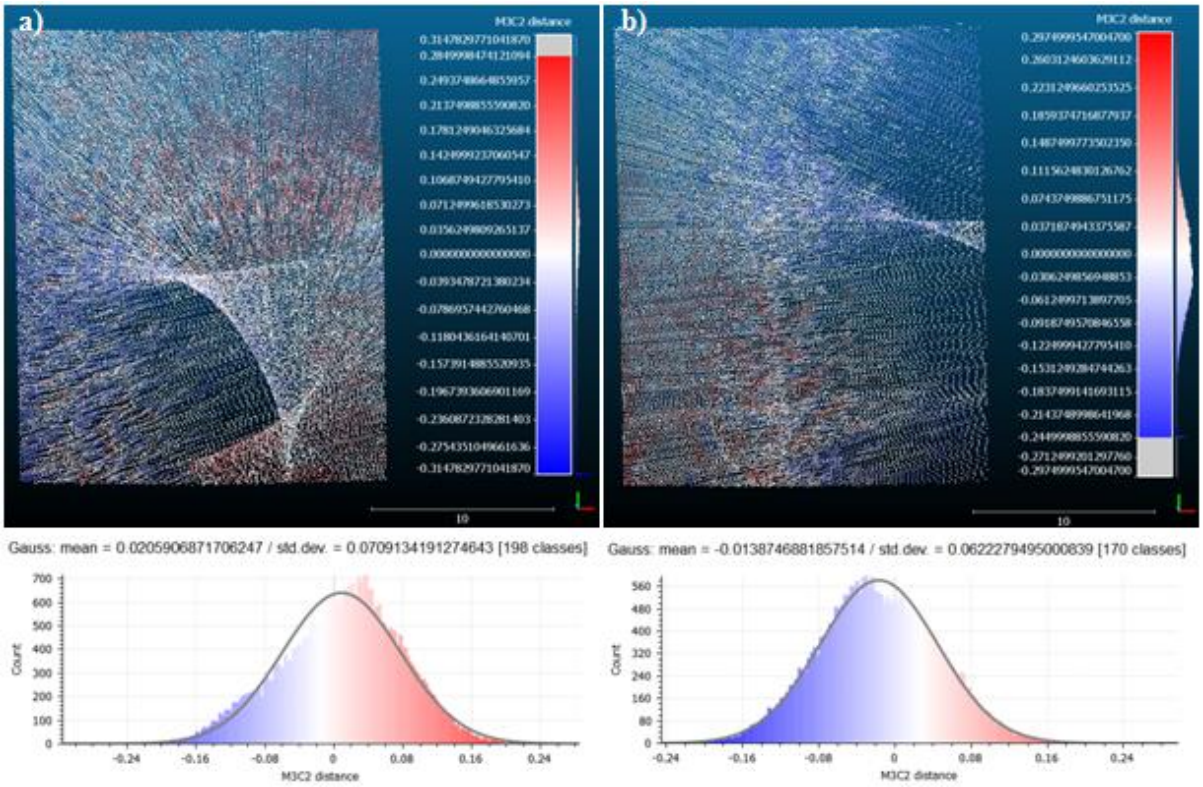

Slika 57. Vertikalna preciznost - odnos snimaka: a) OP_0 - OP_3 i b) OP_3 - OP_0

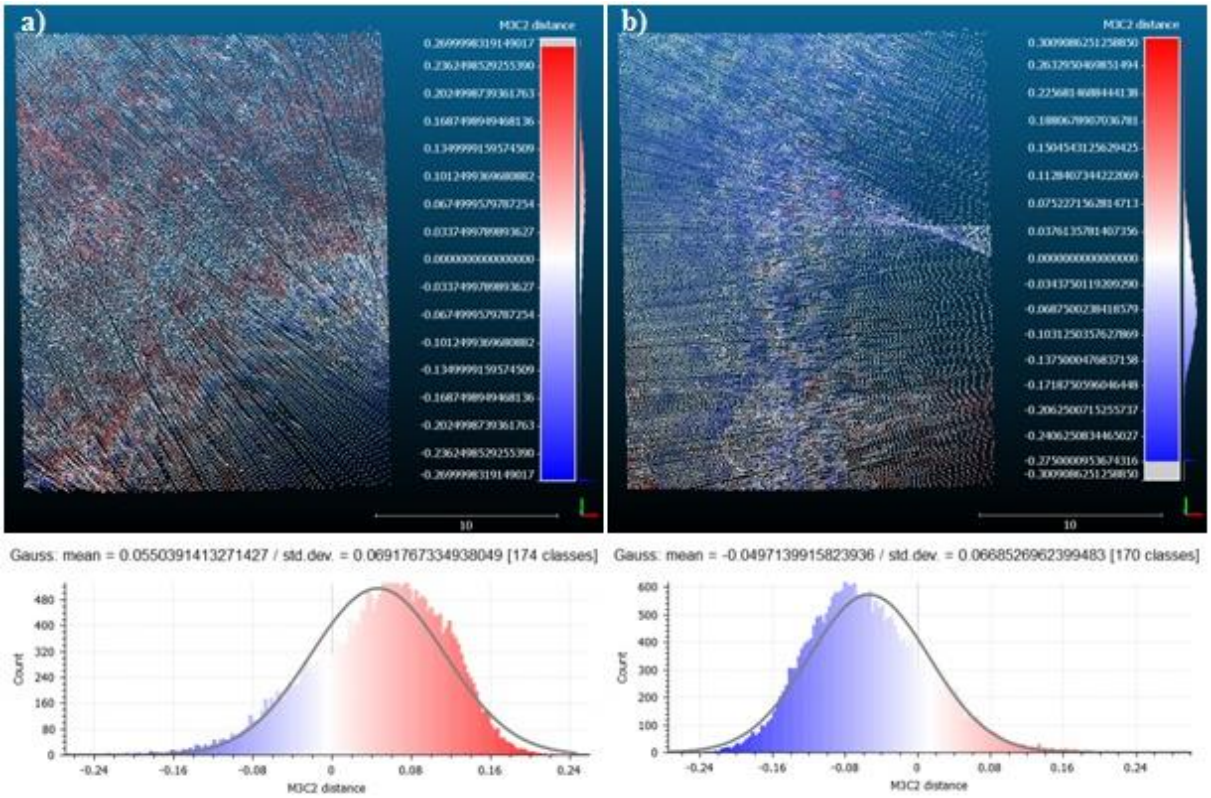

Slika 58. Vertikalna preciznost - odnos snimaka: a) OP_2 - OP_3 i b) OP_3 - OP_2

Dobivene su vrijednosti standardne devijacije za vertikalnu preciznost integralnog mjernog sustava. SD za vertikalnu preciznost izračunata je kao srednja vrijednost svih šest kombinacija. Ona iznosi 6,8 cm (Tablica 10).

Tablica 10. *Vrijednosti standardne devijacije za vertikalnu preciznost integralnog mjernog sustava za uspoređene testne uzorke cikličnih snimaka*

Usporedba	Standardna devijacija (cm)
OP_0 - OP_2	7,6
OP_2 - OP_0	6,5
OP_0 - OP_3	7,1
OP_3 - OP_0	6,2
OP_2 - OP_3	6,9
OP_3 - OP_2	6,7
Ukupno	**6,8**

Ispitivanje horizontalne preciznosti integralnog mjernog sustava provedeno je na temelju usporedbe testnog područja trećeg (OP_2) i četvrtog (OP_3) cikličnog snimka (Slika 59).

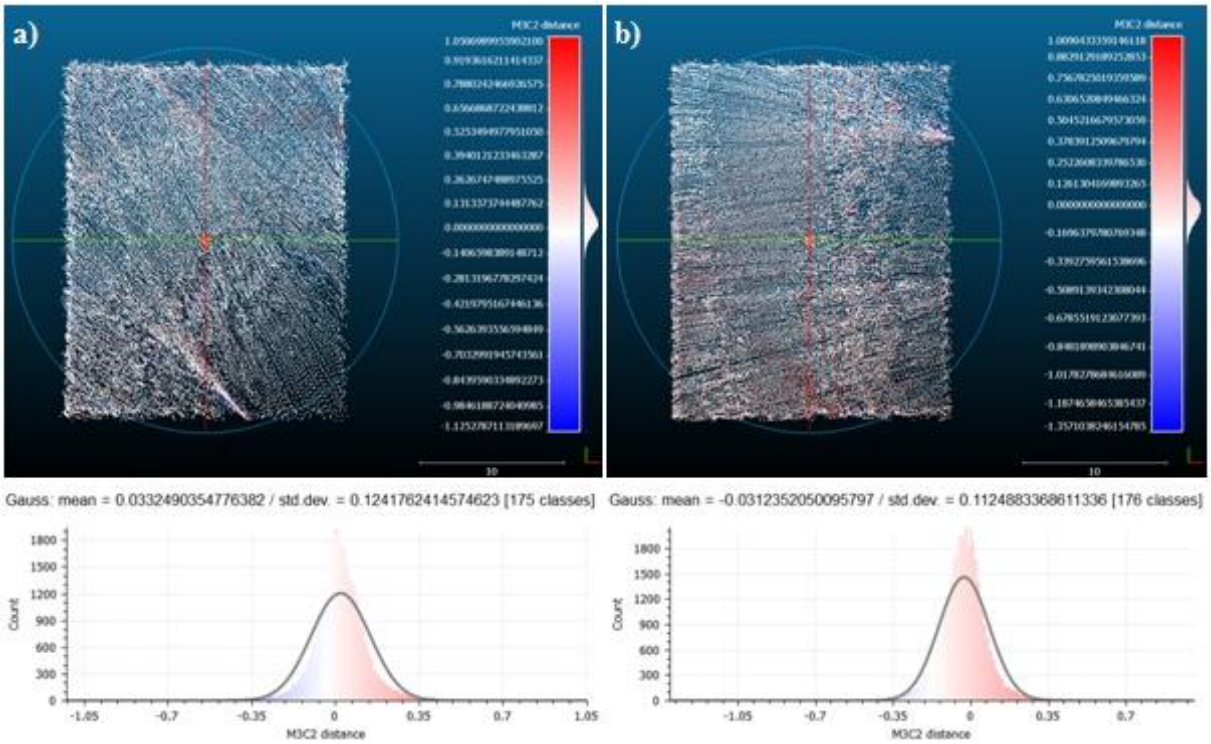

Slika 59. Horizontalna preciznost - odnos snimaka: a) OP_2 - OP_3 i b) OP_3 - OP_2

Srednja vrijednost standardne devijacije za horizontalnu preciznost integralnog mjernog sustava iznosi 11,8 cm (Tablica 11).

Tablica 11. *Vrijednosti standardne devijacije za horizontalnu preciznost integralnog mjernog sustava za uspoređene testne uzorke cikličnih snimaka*

Usporedba	Standardna devijacija (cm)
OP_2 - OP_3	12,4
OP_3 - OP_2	11,2
Ukupno	**11,8**

5.5. Podvodni tuneli (pukotine)

Obradom podataka prikupljenih batimetrijom uklonjene su maksimalne vrijednosti koje se odnose na greške pri prikupljanju podataka i potencijalne vertikalne tunele (pukotine). Zahvaljujući širokom kutu snimanja te mogućnosti bočnog skeniranja i odabranoj operativnoj frekvenciji, detektirano je deset horizontalnih podvodnih tunela (pukotina) u bočnim stranama snimljenog bazena (Slika 60).

Slika 60. Podvodni tuneli (pukotine)

5.6. Integralni modeli jezera Zmajevo oko

Generiran je model dna kojem maksimalna dubina iznosi -13,45 m. Spajanje modela dna s aerofotogrametrijskim snimkama rezultiralo je prvim integralnim modelom jezera Zmajevo oko kojem maksimalna visina iznosi 37,14 m. Perspektivni blokovski prikaz (Slika 61) klasificiran je metodom jednakih intervala, dok je integralni model jezera (Slika 62) klasificiran *Stretch* metodom klasifikacije koja je idealna za prikaz kontinuiranih vrijednosti piksela koji imaju veliki raspon vrijednosti.

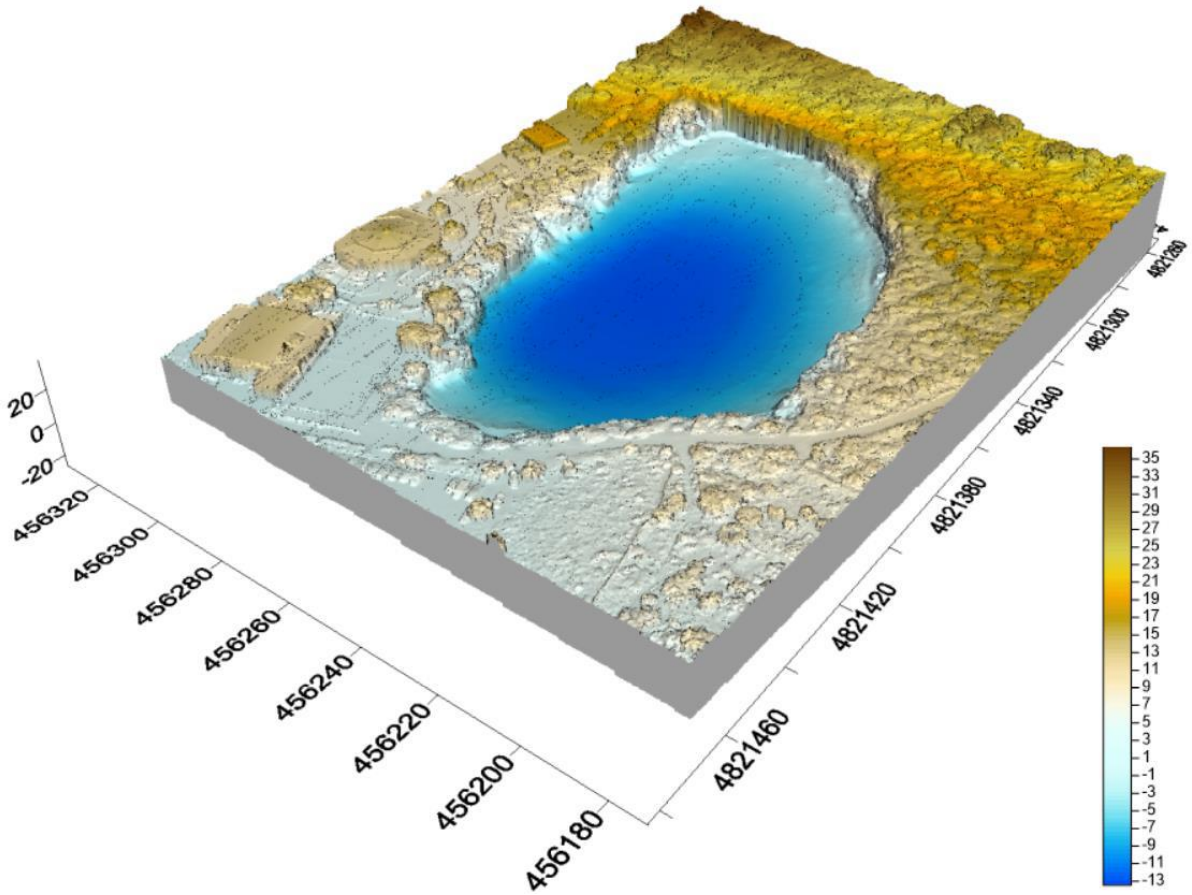

Slika 61. Perspektivni blokovski prikaz integralnog modela kopna i jezera

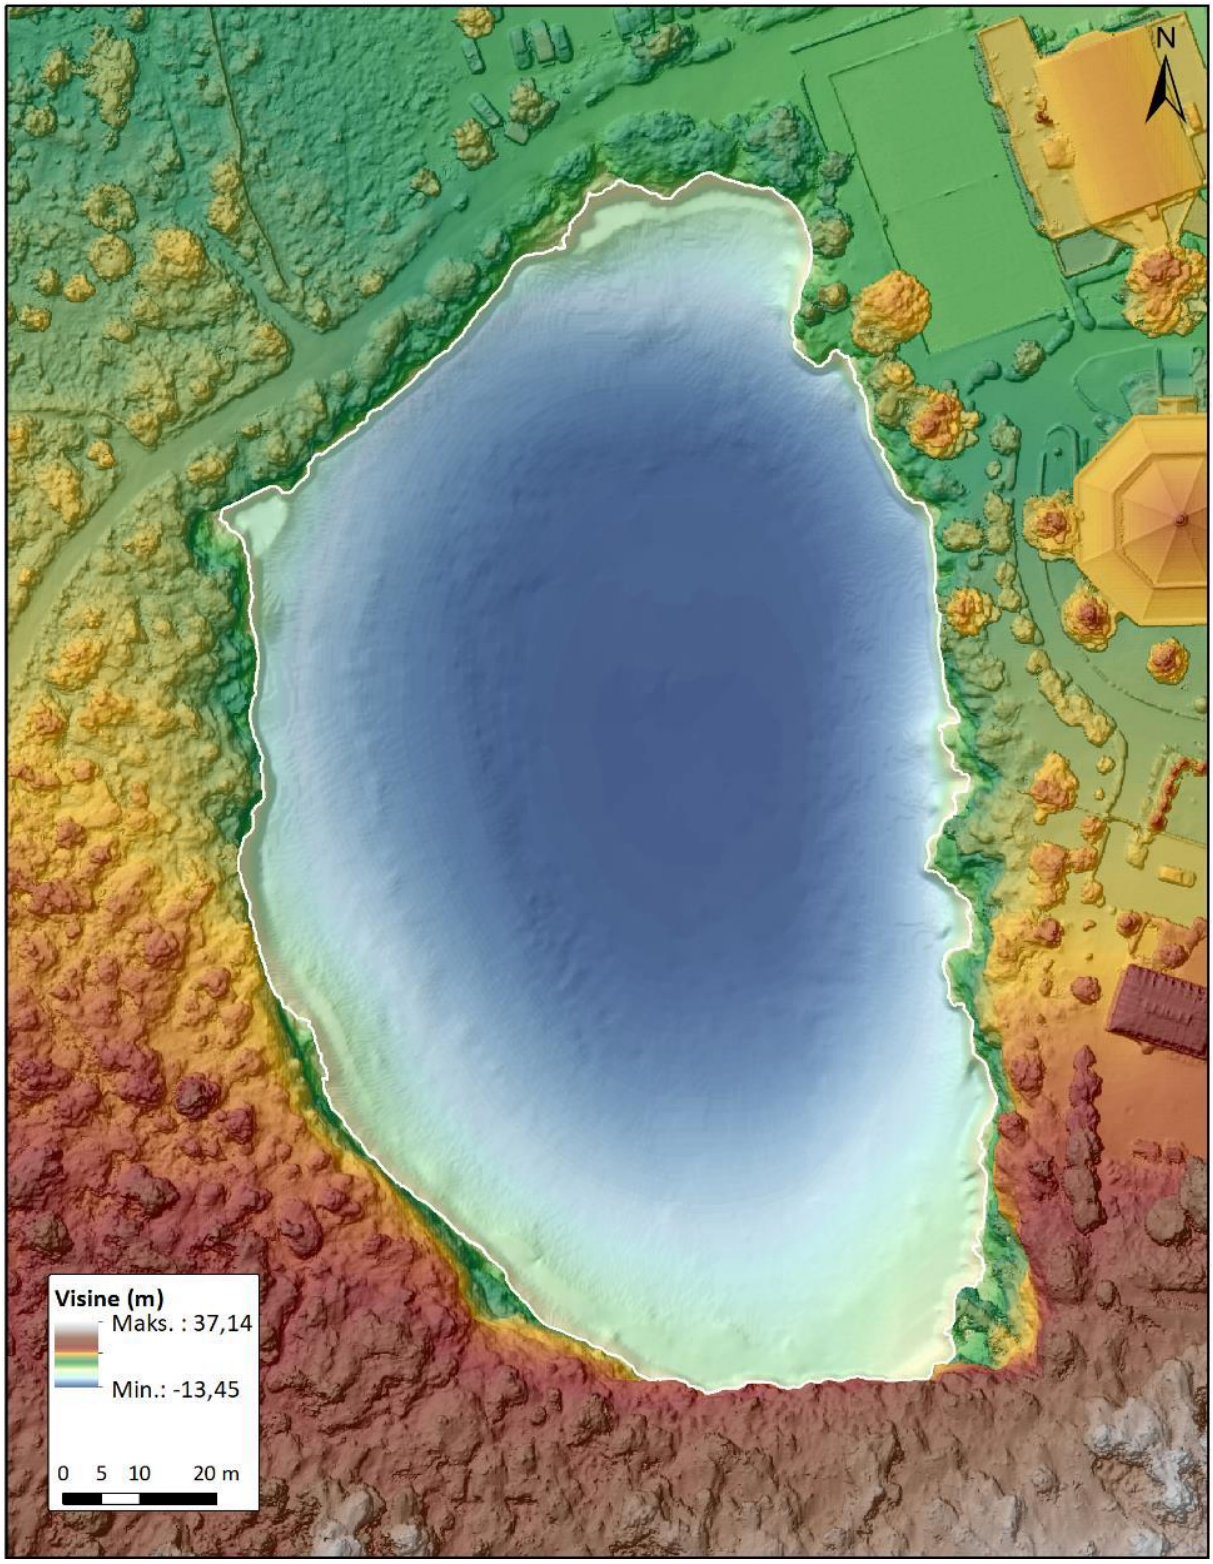

Slika 62. Integralni model jezera Zmajevo oko

5.7. Volumen, površina i duljina obalne linije jezera Zmajevo oko

Iz generiranog digitalnog modela dubina izveden je podatak o volumenu jezera Zmajevo oko na dan snimanja od 90691,738 m^3

Volumen jezera u odnosu na vodostaj na dan snimanja (0,21 m)

Ukupan volumen prema:

- Produljenom trapezoidnom pravilu: 188816,62391633
- Produljenom Simpsonovom 1/3 pravilu: 188815,15825672
- Produljenom Simpsonovom 3/8 pravilu: 188817,58456407

Cut&*Fill* volumeni:

- *Positive Volume* [*Cut*]: 279508,36215978
- *Negative Volume* [*Fill*]: 90691,738248897
- *Net Volume* [*Cut-Fill*]: 188816,62391088

Iz DEM-a usklađenog s DOF-om izvedeni su podaci o površini i duljini obalne linije jezera Zmajevo oko na dan snimanja.

Površina jezera iznosi 0,9904 ha

Duljina obalne linije iznosi 513,14959 m.

5.8. Virtualna šetnja jezerom Zmajevo oko

Rezultat procesa izrade virtualne šetnje je promotivni video šetnje jezerom Zmajevo oko pod nazivom *Zmajevo Oko Virtual Walk (Rogoznica, Croatia)* (Slika 63). Objavljen je na službenim stranicama *Laboratorija za geoprostorne analize* (GAL - *Geospatial Analysis Laboratory*). Renderirano je i šest stajališta na kojima su panoramske 360° snimke (Slika 64). One u potpunosti pokrivaju istraženo područje te potencijalnom posjetitelju daju kvalitetnu informaciju o izgledu ovog zaštićenog područja. Video i panoramske snimke mogu poslužiti u svrhu promocije Zmajevog oka putem interneta.

Slika 63. Isječak iz promotivnog videa *Zmajevo Oko Virtual Walk (Rogoznica, Croatia)*

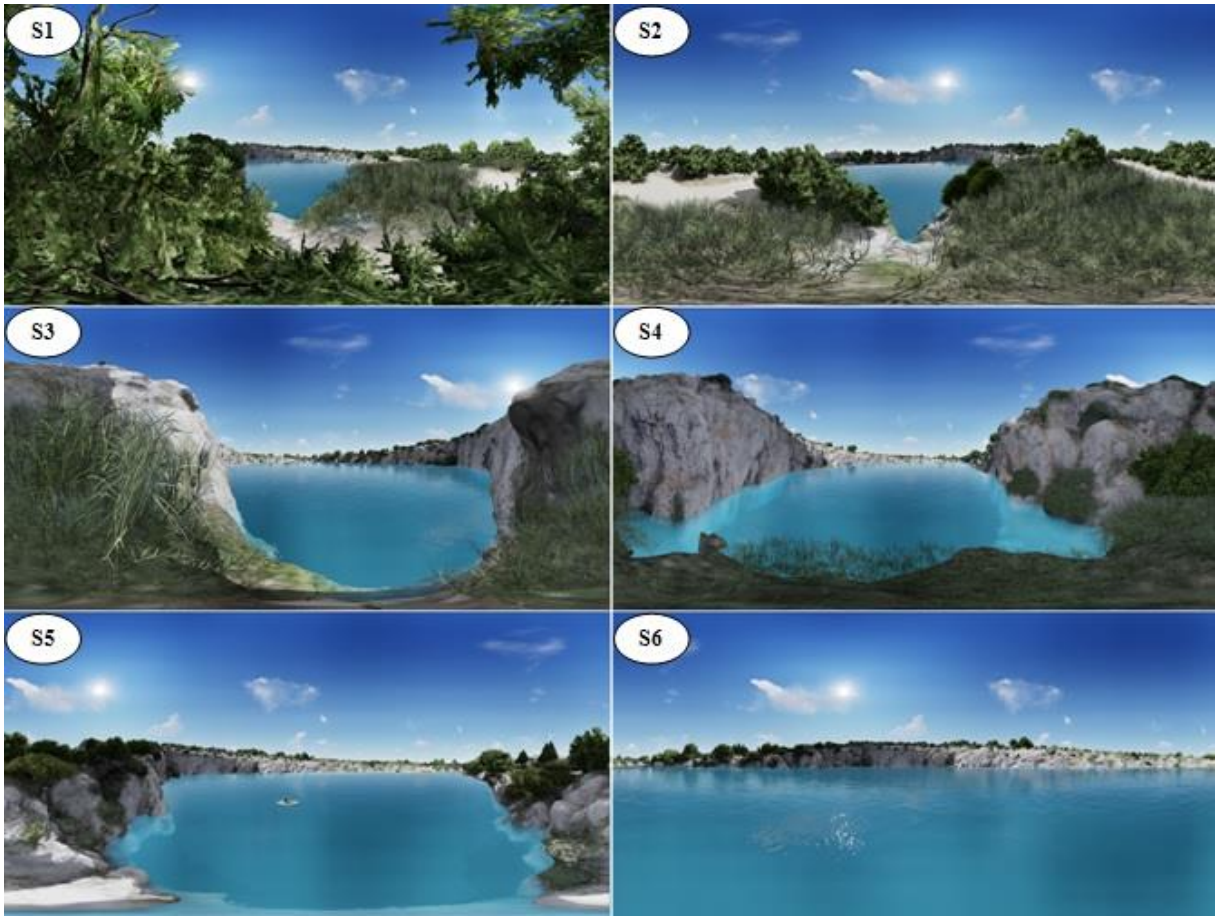

Slika 64. Panoramski 360° snimci jezera Zmajevo oko sa šest stajališta

Panoramski 360º snimci Zmajevog oka mogu se pronaći na platformi *360Cities* koja služi za besplatno kreiranje virtualnih šetnji. Snimke je moguće pogledati na sljedećim poveznicama:

S1: https://www.360cities.net/image/zmajevo-oko-panorama-1

S2: https://www.360cities.net/image/zmajevo-oko-panorama-2

S3: https://www.360cities.net/image/zmajevo-oko-panorama-3

S4: https://www.360cities.net/image/zmajevo-oko-panorama-4

S5: https://www.360cities.net/image/zmajevo-oko-panorama-5

S6: https://www.360cities.net/image/zmajevo-oko-panorama-6

5.9. Suvenir jezera Zmajevo oko

Fizički model Zmajevog oka (Slika 65) dobiven je ispisom 3D modela jezera i okolnog područja na 3D pisaču *Prusa i3 MK3*. Ovaj model može poslužiti kao suvenir, a po želji se može i personalizirati te kao takav biti unikatan za svakog korisnika. Filament kojim je izrađen u potpunosti je obradiv i može se bojiti po želji.

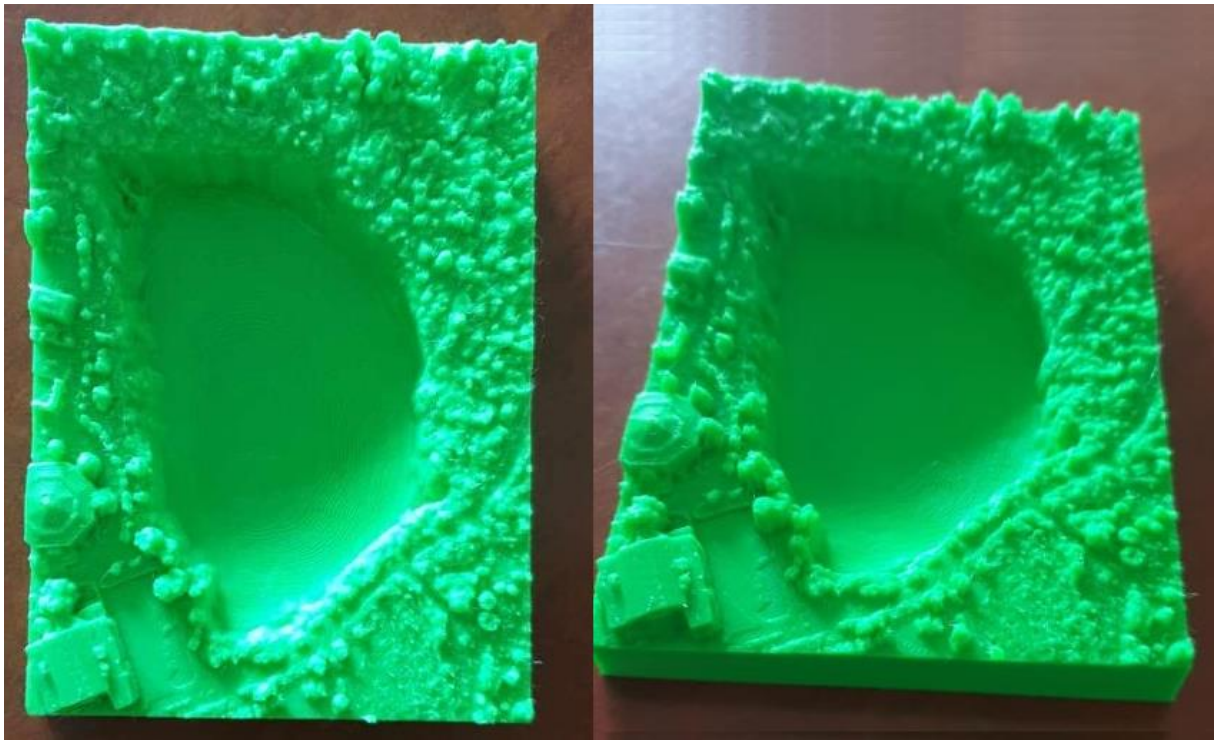

Slika 65. Fizički model (suvenir) jezera Zmajevo oko

6. Rasprava i zaključak

Provedenim istraživanjem na području jezera Zmajevo oko cilj je bio prikazati suvremene geoprostorne tehnologije i njihovo korištenje u promotivne svrhe. Po prvi put je izrađen integralni model ovog prirodnog fenomena metodama aerofotogrametrije i višesnopnog dubinomjera. Poseban naglasak je stavljen na integralni mjerni sustav koji uključuje višesnopni dubinomjer *WASSP S3* i *Hemisphere V320 GNSS* pametnu antenu. Oni su prvi put korišteni u Republici Hrvatskoj te je izuzetno važno bilo ispitati njihovu preciznost.

S obzirom na fizikalno-kemijske karakteristike jezera, najveći izazov predstavljao je odabir operativne frekvencije višesnopnog dubinomjera. Potvrđena je pretpostavka da će operativna frekvencija od 160 kHz omogućiti kartiranje stvarnog dna jezera unatoč prisutnosti debelog sloja sumporovodika u pridnenom sloju te razlika u gustoći vode. Sva četiri snimanja su odrađena s istom postavljenom frekvencijom te je uspješno prikupljen gusti oblak točaka koji reprezentira dno jezera.

Potvrđena je pretpostavka i da će integralni mjerni sustav omogućiti detekciju podvodnih tunela (pukotina) kojima je jezero spojeno s okolnim morem. Naime, već ranije spomenute fizikalno-kemijske karakteristike jezera u početku istraživanja nisu garantirale uspjeh. No širina snopa (4-120°) i mogućnost bočnog skeniranja te odabrana operativna frekvencija omogućili su detekciju deset horizontalnih tunela (pukotina) na bočnim stranama jezera koji su uspješno kartirani. Detektirano je i nekoliko pukotina na samom dnu, no ne može se sa sigurnošću potvrditi jesu li to one ili greške nastale pri prikupljanju podataka. Za potvrdu toga predlaže se ponovljeno snimanje na istoj XY lokaciji s minimalnom širinom snopa koja je kvalitetnije rješenje za detekciju vertikalnih uskih pukotina.

Kao glavna statistička metoda za provjeru vertikalne i horizontalne preciznosti integralnog mjernog sustava korištena je standardna devijacija (SD). Prvo su uspoređena dva gusta oblaka točaka cikličnih snimaka OP_0 i OP_2. Dobivene su vrijednosti SD od 22,1 cm za vertikalnu i 31,9 cm za horizontalnu preciznost. No utvrđeno je kako veliki utjecaj na završne rezultate imaju uvjeti pri kojima su podaci prikupljani (brzina i azimut plovidbe) te koji je snimak u procesu uspoređivanja postavljen kao referentni. Stoga je određeno manje testno područje na kojem se preklapaju ciklični snimci OP_0, OP_2 i OP_3 te je svaki uspoređen sa svakim i to u ulogama referentnog i uspoređenog oblaka točaka. Dobiveni su mnogo bolji rezultati SD koji su potom svi zbrojeni i podijeljeni sa šest koliko je bilo

međusobnih kombinacija. SD za vertikalnu preciznost stoga iznosi 6,8 cm. Horizontalna preciznost je izračunata na najreprezentativnijem uzorku usporedbom testnih područja OP_2 i OP_3. Dobivena je vrijednost SD od 11,8 cm. Rezultati dobiveni računanjem SD za preciznost integralnog mjernog sustava (kombinacija *WASSP S3* višesnopnog dubinomjera i *Hemisphere V320 GNSS* pametne antene) predstavljaju napredak u preciznosti tehnologije višesnopnih dubinomjera i RTK GPS antena s obzirom na to da su Ernstsen i dr., 2006. dobili rezultate SD za vertikalnu preciznost > 8 cm, a za horizontalnu > 20 cm. Također, rezultati SD su bolji nego što je navedeno u specifikacijama *Hemisphere V320 GNSS* pametne antene (URL11) upravo zbog mogućnosti spajanja na CROPOS sustav. S obzirom na to da su dobiveni rezultati > 5 cm hipoteza da će preciznost integralnog mjernog sustava biti < 5 cm je odbačena. Potrebno je istaknuti kako s obzirom na brojne korisničko definirane parametre i uvjete na terenu (razina vodostaja, fizikalno-kemijska svojstva jezera, izmjerena brzina zvuka u vodi, operativna frekvencija, brzina i azimut plovidbe, broj spojenih satelita, karakteristike svih sastavnica integralnog mjernog sustava i GPS prijamnika itd.) koji utječu na izlazne rezultate, ovi podaci predstavljaju polazište za daljnja istraživanja na području Zmajevog oka.

Procesom aerofotogrametrije pri kojoj je korišten *Phantom 4 Pro* opremljen fotoaparatom visoke razlučivosti obuhvaćeno je vodno lice jezera te šire obalno područje u tampon zoni od 100 m. Pretpostavka je glasila da će točnost modela dobivenih procesom aerofotogrametrije biti < 5 cm. Za izračun točnosti izvedenih modela korištena su dva statistička pokazatelja za šest orijentacijskih i tri kontrolne točke. Metodom računanja srednje apsolutne pogreške (MAE) dobivena je ukupna pogreška od 3,99 cm za kontrolne točke i 2,44 cm za orijentacijske. Metodom računanja srednje kvadratne pogreške (RMSE) dobivena je pogreška od 4,13 cm za kontrolne točke i 2,53 cm za orijentacijske. Izračunate vrijednosti MAE i RMSE se gotovo u potpunosti podudaraju i pogreška ne prelazi 5 cm čime je hipoteza potvrđena. Razlika u pogrešci između orijentacijskih i kontrolnih točaka u korist prvih je očekivana s obzirom na to da su modeli orijentirani preko orijentacijskih, a ne kontrolnih točaka. Rezultati MAE i RMSE se u potpunosti podudaraju s rezultatima iz rada Marić i dr., 2019. čija je metodologija upotrebljena pri izvođenju aerofotogrametrije na području Zmajevog oka.

Na temelju DOF-a i DEM-a izvedeni su egzaktni podatci o volumenu, površini i duljini obalne linije jezera na dan snimanja pri vodostaju od 0,21 m. Volumen je izračunat pomoću tri *Newton-Cotesove* formule integrirane unutar softvera *Surfer* te je na dan snimanja

iznosio 90 691,738 m^3. Površina jezera je iznosila 0,9904 ha, a duljina obalne linije 513,14959 m.

Generiran je integralni model Zmajevog oka spajanjem podataka prikupljenih aerofotogrametrijom i batimetrijom. Podaci o visinama, odnosno dubinama su klasificirani dvjema metodama (jednaki intervali i *Stretch*). Najdublja točka jezera se nalazi na -13,45 m, dok najveća izmjerena visina u široj obalnoj zoni iznosi 37,14 m.

Izrađen je i 3D model jezera na temelju kojeg je izvedena virtualna šetnja. Promotivni video postavljen je na stranice *Laboratorija za geoprostorne analize* (GAL), dok su panoramski snimci postavljeni na internetsku platformu *360Cities* na kojoj je moguće sa šest lokacija oko Zmajevog oka pogledati 3D model jezera i okolnog područja. Virtualna šetnja omogućila je potencijalnom posjetitelju da prošeta oko jezera i vidi posebnosti Zmajevog oka.

Na posljetku je upotrebom suvremenog 3D printera *Prusa i3 MK3* izrađen i fizički model jezera sa širim obalnim područjem koji u svrhu promocije Zmajevog oka može poslužiti kao suvenir. Fizički model ima mogućnost daljnje obrade i personalizacije s obzirom na to da je izrađen od obradivog i u potpunosti biorazgradivog materijala PLA.

Dokumentacija trenutnog stanja jezera uz detaljno opisanu metodologiju omogućila je daljnje praćenje promjena i polazište je za buduća istraživanja na ovom području.

Literatura

1. Abdalla, R. (2016): Geospatial Data Integration, *Introduction to Geospatial Information and Communication Technology (GeoICT)*, Springer International Publishing, 105–124.
2. Ahmad, A., Samad, A.M. (2010): Aerial mapping using high resolution digital camera and unmanned aerial vehicle for Geographical Information System, *2010 6th International Colloquium on Signal Processing & its Applications* Mallaca City: IEEE1–6.
3. Amiri-Simkooei, A.R., Snellen, M. and Simons, D.G. (2011): Principal Component Analysis of Single-Beam Echo-Sounder Signal Features for Seafloor Classification, *IEEE Journal of Oceanic Engineering*, 36(2), 259–272.
4. Anastasiadou, C., Vettese, S. (2019): "From souvenirs to 3D printed souvenirs", Exploring the capabilities of additive manufacturing technologies in (re)-framing tourist souvenirs, *Tourism Management* 71, 428–442.
5. Anthes, C., Garcia-Hernandez, R.J., Wiedemann, M., Kranzlmuller, D. (2016): State of the art of virtual reality technology, *2016 IEEE Aerospace Conference* Big Sky, MT, USA: IEEE1–19.
6. Aykut, N.O., Akpınar, B. (2013): Determining the dynamic draught for precise hydrographic surveying, *Ocean Engineering* 62, 38–44.
7. Bakran-Petricioli, T., Petricioli, D., Požar-Domac, A. (1998): Influence of isolation and peculiar ecological properties on biodiversity – an example of marine lake Zmajevo Oko near Rogoznica (Adriatic Sea), *Rapp Comm int Mer Médit*, 35, 518-9.
8. Barilar, M., Todić, F., Kriste, I. (2015): Korištenje fotogrametrijskog materijala u izradi 3D modela i fototekstuririranje, *Ekscentar* (18), 50–56.
9. Bergmann, T., Balzer, M., Hopp, T., van de Kamp, T., Kopmann, A., Tan Jerome, N., Zapf, M. (2017): Inspiration from VR Gaming Technology: Deep Immersion and Realistic Interaction for Scientific Visualization: *Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications* Porto, Portugal: SCITEPRESS - Science and Technology Publications 330–334.
10. Bhagat, K.K., Liou, W.-K., Chang, C.-Y. (2016): A cost-effective interactive 3D virtual reality system applied to military live firing training, *Virtual Reality* 20(2), 127–140.

11. Biffard, B.R. (2011): Seabed Remote Sensing by Single-Beam Echosounder: Models, Methods and Applications, doktorski rad, *University of Victoria*, Victoria, British Columbia, Canada
12. Bishop, M.P., James, L.A., Shroder, J.F., Walsh, S.J. (2012): Geospatial technologies and digital geomorphological mapping: Concepts, issues and research, *Geomorphology* 137(1), 5–26.
13. Blaszczynski, J.S., (1997): Landform characterization with geographic information systems, *Photogrammetric Engineering and Remote Sensing* 63(2), 183–191.
14. Bodzin, A.M., Cirucci, L. (2009): Integrating Geospatial Technologies to Examine Urban Land Use Change: A Design Partnership, *Journal of Geography* 108(4–5), 186–197.
15. Boehler, W., Heinz, G., Scherer, Y., Siebold, M. (2001): Topographic Information in Cultural and Natural Heritage Visualization and Animation, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 56-61.
16. Bruno, F., Bruno, S., De Sensi, G., Luchi, M.-L., Mancuso, S., Muzzupappa, M. (2010): From 3D reconstruction to virtual reality: A complete methodology for digital archaeological exhibition, *Journal of Cultural Heritage* 11(1), 42–49.
17. Bura-Nakić E., Ciglenečki I., Bošković N., Burić Z., Ćosović B. (2007): Sezonska i okomita raspodjela organske tvari i reduciranih sumpornih vrsta u vodenom stupcu Rogozničkog jezera, *Hrvatske vode i Europska Unija - izazovi i mogućnosti: zbornik radova*, Zagreb: Hrvatske vode, 85-90.
18. Bura-Nakić, E., Marguš, M., Orlić, S., Ciglenečki, I. (2012): Zmajevo oko – a unique example of anchialine system on the Adriatic coast (Croatia) during spring-summer stratification and autumn mixing period, *Natura Croatica: Periodicum Musei Historiae Naturalis Croatici*, 21(suppl. 1), 17-20.
19. Chai, T., Draxler, R.R. (2014): Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature, *Geoscientific Model Development* 7(3), 1247–1250.
20. Ciglenečki I., Kodba Z., Ćosović B., (1996): Sulphur species in the Rogoznica lake, *Marine Chemistry*, 53,101-111.
21. Cipolla-Ficarra, F.(2012): The Expansion Era of the Communicability: First Nations for the Local and Global Promotion of Cultural and Natural Heritage, u: Veltman, K., Chih-Fang, H., Cipolla-Ficarra, M., Kratky, A.:*Human-Computer Interaction, Tourism and Cultural Heritage*, Cordoba, Argentina, Springer, 25-37.

22. Dong, Q., Cui, M., Zhou, J., Wang, J., Xu, Y. (2011): Analysis and Processing of TransformGeography of Convex and Concave in Multi-beam Sounding System, *Hydro-graphic Surveying and Charting* 31(1), 32-35.
23. Dong, Q., Han, H., Fang, Z. (2007): The Influence of Sound Speed Profiles Correction on Multi-beam Survey, *Hydrographic Surveying and Charting* (2), 56-58.
24. Eisenbeiß, H. (2009):UAV Photogrammetry, doktorski rad, *Institut für Geodesie und Photogrammetrie, ETH-Zürich,*Zürich, Švicarska
25. Eleftherakis, D., Berger, L., Le Bouffant, N., Pacault, A., Augustin, J.-M., Lurton, X. (2018): Backscatter calibration of high-frequency multibeam echosounder using a reference single-beam system, on natural seafloor, *Marine Geophysical Research* 39(1–2), 55–73.
26. Ernstsen, V.B., Noormets, R., Hebbeln, D., Bartholomä, A. and Flemming, B.W. (2006): Precision of high-resolution multibeam echo sounding coupled with high-accuracy positioning in a shallow water coastal environment, *Geo-Marine Letters* 26(3), 141–149.
27. Evans, B. (2012):*Practical 3D Printers: The Science and Art of 3D Printing*, Apress.
28. Fabris, M., Baldi, P., Anzidei, M., Pesci, A., Bortoluzzi, G., Aliani, S. (2010): High resolution topographic model of Panarea Island by fusion of photogrammetric, LiDAR and bathymetric digital terrain models: High resolution topographic model of Panarea Island, *The Photogrammetric Record* 25(132), 382–401.
29. Ferreira, H., Almeida, C., Martins, A., Almeida, J., Dias, N., Dias, A., Silva, E. (2009): Autonomous bathymetry for risk assessment with ROAZ robotic surface vehicle, *OCEANS 2009-EUROPE*, Bremen, Germany: IEEE 1-6.
30. Ferretti, R., Fumagalli, E., Caccia, M., Bruzzone, G. (2015): Seabed classification using a single beam echosounder, *OCEANS 2015 - Genova*, Genova, Italy: IEEE1–5.
31. Kearns A., Breman, J., (2010): Bathymetry - The art and science of seafloor modeling for modern applications, *Ocean Globe* (ur. Breman J.), Redlands: ESRI Press, 1-36.
32. Kuspilić, N., Bekic, D., Gilja, G. (2010): Praćenje morfodinamičkih promjena korita vodotoka u zoni stupova mostova,Prometnice - nove tehnologije i materijali, *Građevinski fakultet Sveučilišta u Zagrebu, Zavod za prometnice*, 69-112.
33. Laurel, B. (2016):*What Is Virtual Reality?*, Dostupno na:https://medium.com/@blaurel/what-is-virtual-reality-77b876d829ba (24.3.2020.)

34. Lee, M.P., Cooper, G.J.T., Hinkley, T., Gibson, G.M., Padgett, M.J., Cronin, L. (2015): Development of a 3D printer using scanning projection stereolithography, *Scientific Reports* 5(1), 9875.

35. Leonov, A., Aleynikov, A., Belosokhov, D., Bobkov, A., Eremchenko, E., Frolov, P., Klimenko, A., Klimenko, S.. (2011): 3D Documentation of Natural Heritage for Virtual Environments and Web — Case Study: Valley of Geysers, Kamchatka, *IADIS International Conferences Computer Graphics, Visualization, Computer Vision and Image Processing*

36. Gessler, P., Pike, R., MacMillan, R.A., Hengl, T., Reuter, H.I., (2009). The future of geomorphometry, u: Hengl, T., Reuter, H.I.: *Geomorphometry—Concepts, Software, Applications: Developments in Soil Science*, Amsterdam, Elsevier 33, 637–652.

37. Guth, P.L. (2013): The giga revolution in geomorphometry: gigabytes of RAM, gigabyte-sized data sets, and gigabit internet access, u: Guoan T., Qiming Z., Mitasova H., Hengl T.:*Zbornik radova Međunarodne konferencije Geomorphometry 2013*, Nanjing Normal University, Nanjing, Kina, 41−44.

38. Hengl, T. (2006): Finding the right pixel size, *Computer and Geosciences* 32(9), 1283-1298.

39. Huang, Y.C., Backman, K.F., Backman, S.J., Chang, L.L. (2016): Exploring the Implications of Virtual Reality Technology in Tourism Marketing: An Integrated Research Framework: The Implications of Virtual Reality Technology in Tourism Marketing, *International Journal of Tourism Research* 18(2), 116–128.

40. Clarke, J.E.H. (2006): Multibeam Echosounders,u: Micallef A., Krastel S., Savini A.: *Submarine Geomorphology*, Cham, Springer, 25-41.

41. IHO(2005): *Manual of Hydrography*, Publication M-13, 1st edition, International Hidrographic Bureau, Monaco.

42. Jackson, M., Schell, D., Taylor, D.R.F. (2009): The evolution of geospatial technology calls for changes in geospatial research, education and government management, *Directions Magazine*, Dostupno na: shorturl.at/gjAT4 (16.2.2020.)

43. Janowski, L., Trzcinska, K., Tegowski, J., Kruss, A., Rucinska-Zjadacz, M., Pocwiardowski, P. (2018): Nearshore Benthic Habitat Mapping Based on Multi-Frequency, Multibeam Echosounder Data Using a Combined Object-Based Approach: A Case Study from the Rowy Site in the Southern Baltic Sea, *Remote Sensing* 10(12), 1983.

44. Jordan, J. M.(2019): *3D Printing*, MIT Press, Cambridge, MA, U.S.A., 1-24. Dostupno na: https://mitpress.mit.edu/books/3d-printing (26.2.2020.)

45. Jung, T.H., tom Dieck, M.C. (2017): Augmented reality, virtual reality and 3D printing for the co-creation of value for the visitor experience at cultural heritage places, *Journal of Place Management and Development* 10(2), 140–151.

46. Klein, S., Avery, M., Adams, G., Pollard, S., Simske, S. (2014): From Scan to Print: 3D Printing as a Means for Replication, *NIP & Digital Fabrication Conference* 2014 (1), 417–421.

47. Letessier, T.B., Hosegood, P.J., Nimmo-Smith, A., Fernandes, M.C., Proud, R., Turner, J., Carr, P., Schaellert, R., Froman, N., Belamy, Z., Addison, S., Brierley, A.S. (2016): Chagos Archipelago Pelagic Expedition, February 5-24, 2016., *Scientific Report to The Bertarelli Foundation and the Foreign and Commonwealth Office*.

48. Lurton, X. (2016): Modelling of the sound field radiated by multibeam echosounders for acoustical impact assessment, *Applied Acoustics* 101, 201–221.

49. Manić, Lj., Aleksić, M., Tankosić, M., (2013): Possibilities of New Technologies in Promotion of the Cultural Heritage: Danube Virtual Museum, *Advances in Environment, Ecosystems and Sustainable Tourism*.

50. Mareddy, A.R., Shah, A., Davergave, N. (2017): *Environmental Impact Assessment: Theory and Practice*, Butterworth-Heinemann.

51. Marić, I., Šiljeg, A., Domazetović, F. (2019): Geoprostorne tehnologije u 3D dokumentaciji i promociji kulturne baštine – primjer utvrde Fortica na otoku Pagu, *Geodetski glasnik*, (50), 19-44.

52. Matthews, N. A. (2008): Aerial and Close-range Photogrammetric Technology - Providing Resource Documentation, Interpretation, and Preservation, US Bureau of Land Management Technical Note 428. US Bureau of Land Management: Washington, DC. Dostupno na: https://www.blm.gov/documents/national-office/blm-library/technical-note/aerial-and-close-range-photogrammetric (19.2.2020.)

53. Medak, D., Pribicevic, B., Krivoruchko, K. (2008): Geostatistical Analysis of Bathymetric Measurements: Lake Kozjak Case Study, *Geodetski List*, 62, 131-142.

54. Medved, I., Pribičević, B., Medak, D. i Kuzmanić, I. (2010): Usporedba metoda interpolacije batimetrijskih mjerenja za praćenje promjena volumena jezera, *Geodetski list*, 64(87) (2), 71-86. Dostupno na:https://hrcak.srce.hr/57672 (20.2.2020.)

55. Meyer, W. (1995): *Concepts of Mathematical Modelling*, McGraw-Hill Book Company, New York.

56. NOAA (1976): *Hydrographic Manual*, 4th edition, National Oceanic and Atmospheric Administration, US Department of Commerce.
57. Nonnis, O., Maggi, C., Lanera, P., Proietti, R., Izzi, A., Antonelli, P., Gabellini, M. (2016): The Management of Information to Identify the Submarine Cable Route: the Case Study of Campania islands, *Journal of Coastal Research* 75 (sp1), Coastal Education and Research Foundation 1002–1006.
58. Pao, C. (2018). *The importance of IMU Motion Sensors*, Dostupno na: https://www.ceva-dsp.com/ourblog/what-is-an-imu-sensor/ (18.3.2020.)
59. Pike, R.J. (2000): Geomorphometry – diversity in quantitative surface analysis, *Progress in Physical Geography: Earth and Environment* 24(1), 1–20.
60. Prusa, J. (2019). 3D printing handbook, Prusa research s.r.o. Dostupno na: https://prusa3d.com/downloads/manual/prusa3d_manual_mk3_en_3_04.pdf (23.5.2020.)
61. Raquez, J.-M., Habibi, Y., Murariu, M., Dubois, P. (2013): Polylactide (PLA)-based nanocomposites, *Progress in Polymer Science* 38(10–11), 1504–1542.
62. Remondino, F., Fraser, C. (2006): Digital camera calibration methods: Considerations and comparisons. ETH Zurich.
63. Remondino, F., Rizzi, A. (2010): Reality-based 3D documentation of natural and cultural heritage sites - techniques, problems, and examples, *Applied Geomatics* 2(3), 85–100.
64. Sciortino, J.A.(2010): *Fishing harbour planning, construction and management*, Food and Agriculture Organization of the United Nations, Rome.
65. Shen, J., Liu, J.,Zhao, R.(2011): A KD-tree-based outlier detection method for airborne LiDAR point clouds,*International Symposium on Image and Data Fusion*, 1-4.
66. Shroder, J.F., Bishop, M.P. (2003): A perspective on computer modeling and fieldwork, *Geomorphology* 53(1–2), 1–9.
67. 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.
68. Snellen, M., Siemes, K., Simons, D.G. (2011): Model-based sediment classification using single-beam echosounder signals, *The Journal of the Acoustical Society of America* 129(5), 2878–2888.

69. Song, E.Y., Lee, K. (2008): Understanding IEEE 1451-Networked smart transducer interface standard - What is a smart transducer?, *IEEE Instrumentation Measurement Magazine* 11(2), 11–17.

70. Streiner, D.L. (1996): Maintaining Standards: Differences between the Standard Deviation and Standard Error, and When to Use Each, *The Canadian Journal of Psychiatry* 41(8), 498–502.

71. Surić, M. (2005): Submerged karst – dead or alive? Examples from the Eastern Adriatic coast (Croatia), *Geoadria*, 10(1), 5-19.

72. Šiljeg, A., Barada, M., Marić, I. (2018): Digital Terrain Modelling. *Alfa d.d. i Sveučilište u Zadru*, Zagreb.

73. Šiljeg, A. (2013): Digitalni model reljefa u analizi geomorfometrijskih parametara - primjer PP Vransko jezero, doktorski rad, *Prirodoslovno-matematički fakultet, Geografski odsjek*, Zagreb

74. Šiljeg, A. (2019): Višerezolucijsko modeliranje krajolika primjenom geoprostornih tehnologija, *Međunarodni dan precizne poljoprivrede*, Osijek, 2019.

75. 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), 17-37.

76. Šiljeg, A, Jurišić, M., Marić, I. (2016): Batimetrijska izmjera jezera Skradinskog buka, *Geodetski list*, 3, 231–252

77. Tussyadiah, I.P., Wang, D., Jung, T.H., tom Dieck, M.C. (2018): Virtual reality, presence, and attitude change: Empirical evidence from tourism, *Tourism Management* 66, 140–154.

78. UNESCO (1972): *UNESCO konvencija za zaštitu svjetske kulturne i prirodne baštine*, Organizacija Ujedinjenih naroda za obrazovanje, nauku i kulturu, Pariz (1972).

79. ENL Group (2016): WASSP Multibeam, WASSP Sensor Box Installation Manual, Dostupno na: https://enl.co.nz/pages/wassp (4.4.2020.)

80. Wawro, C. (2013):*Aerial photography mount*, 8434950

81. Whiteway, T., (2009): *Australian bathymetry and topography* grid, Geoscience Australia, Department of Industry, Tourism and Resources, Canberra

82. Wilson, M.F.J., O'Connell, B., Brown, C., Guinan, J.C., Grehan, A.J. (2007): Multiscale Terrain Analysis of Multibeam Bathymetry Data for Habitat Mapping on the Continental Slope, *Marine Geodesy* 30(1–2), 3–35.

83. Wilson, C.J., Soranzo, A. (2015): The Use of Virtual Reality in Psychology: A Case Study in Visual Perception,*Computational and Mathematical Methods in Medicine*, Hindawi Publishing Corporation.

84. Wu, J., Marceau, D., 2002: Modeling complex ecological systems: an introduction, *Ecological Modelling* 153, 1-6.

Izvori

Državna geodetska uprava Republike Hrvatske, (2020): WMS server Republike Hrvatske: DOF 1:5000, HOK 1:5000 (geoportal.dgu.hr/wms)

URL1: http://www.dgu.hr/ (27.5.2020.)

URL2: https://www.dji.com/hr/phantom-4-pro (2.3.2020.)

URL3: https://drive.google.com/file/d/1nbxkYsO-M9h8WNTdOvWjPP4ViNtQp7oU/view (4.4.2020.)

URL4: https://droneshop.nl/pub/media/catalog/product/cache/57e05a978a5497b203ff83c2f6f349f4/d/j/dji-phantom-4-pro-plus-v20.jpg (3.3.2020.)

URL5: http://www.dsmt.com/resources/ip-rating-chart/ (4.4.2020.)

URL6: https://enl.co.nz/pages/wassp-s3 (4.4.2020.)

URL7: https://www.fabtolab.com/image/cache/data/Consumer/3D/abs-filament-multicolour-228x228.JPG (24.5.2020.)

URL8: https://fiverr-res.cloudinary.com/images/t_main1,q_auto,f_auto,q_auto,f_auto/gigs/123334399/original/9af1a092d1b83b2cb20952e85dd7d460d54a9cd1/convert-stl-file-to-gcode-as-your-3d-printer-requires.jpg (24.5.2020.)

URL9: https://www.furuno.com/img/product_features/F3_transducer.jpg (6.4.2020.)

URL10: https://www.furunousa.com/en/products/wsp002-inu (7.4.2020.)

URL11: https://hemispheregnss.com/wp-content/uploads/2018/12/hemispheregnss_v320_ug_userguide_875-0351-0_a1-1.pdf (26.3.2020.)

URL12: https://i1.wp.com/makezine.com/wp-content/uploads/2017/09/Prusa_i3_mk3_White-1.jpg?fit=1600%2C1067&ssl=1 (24.5.2020.)

URL13: https://lumion.com/product.html (3.6.2020.)

URL14: https://www.pugetsystems.com/pic_disp.php?id=54822&width=500 (24.5.2020.)

URL15: http://www.stonex.hr/s10.html (3.3.2020.)

URL16: https://www.stonex.hr/S10_111.jpg (3.3.2020.)

URL17: https://support.pix4d.com/hc/article_attachments/115002939483/home_screen.png (5.3.2020.)

URL18: https://user-images.githubusercontent.com/2337234/27012871-381b968c-4ed9-11e7-969d-ceccea990046.png (24.5.2020.)

Popis grafičkih priloga

Slika 1. Geografski položaj A) Republike Hrvatske, B) Rogoznice i C) jezera Zmajevo oko

Slika 2. Područje izmjere – Zmajevo oko

Slika 3. Princip rada jednosnopnog i višesnopnog dubinomjera

Slika 4. Veza dubine i *footprint*-a snimka

Slika 5. a) *Phantom 4 Pro* i b) *Stonex S10*

Slika 6. Shema aerofotogrametrijskog procesa Zmajevog oka

Slika 7. Primjer označene orijentacijske točke OT1

Slika 8. Distribucija orijentacijskih i kontrolnih točaka oko jezera Zmajevo oko

Slika 9. Vrste misija korištene prilikom snimanja jezera Zmajevo oko

Slika 10. Primjer snimljenih zračnih snimaka Zmajevog oka a) *Grid Mission*, b) *Double Grid Mission*, c) *Circular Mission* i d) *Free Flight Mission*

Slika 11. a) Lokacije fotografija te broj preklapanja b) *Image residuals* (8.8 mm)

Slika 12. a) Kalibracijsko sučelje aplikacije *DJI GO* te b) kalibracija IMU sustava na terenu

Slika 13. Rijetki oblak točaka te izračunate lokacije kamere

Slika 14. Označene orijentacijske i kontrolne točke na gustom oblaku točaka

Slika 15. Proces obrade zračnih snimaka u *Agisoft Metashape 1.5.1*

Slika 16. Gumenjak *Luna* na kojem je instaliran integralni mjerni sustav

Slika 17. Komponente integralnog mjernog sustava

Slika 18. Višesnopni dubinomjer *WASSP S3*

Slika 19. Sastavnice aplikacije *CDX*

Slika 20. Prikazi jezera: a) dvodimenzionalni; b) perspektivni (3D); c) bočni; d) sonarna ploča; e) profilni

Slika 21. Primjer snimljenog dna (dubina) Zmajevog oka s višesnopnim dubinomjerom *WASSP S3*

Slika 22. Primjer snimljenog dna (tvrdoća) Zmajevog oka s višesnopnim dubinomjerom *WASSP S3*

Slika 23. Sučelje softvera *Data Manager*

Slika 24. Sonda *WMB-160* i njezina pozicija u integralnom mjernom sustavu

Slika 25. Utjecaj a) prednjih i b) bočnih valova na registraciju podataka

Slika 26. *WASSP Sensor Box* s integriranim *Advanced Navigation Spatial IMU WSP002-INU*

Slika 27. *Hemisphere V320 GNSS Smart Antenna*

Slika 28. Netočnosti prikaza morskog dna zbog pogrešne brzine zvuka

Slika 29. Prikaz Sonarne ploče koja prikazuje vodeni stup i profil morskog dna ispod sonde a) primjer jezera Zmajevo oko; b) generalan primjer sa sastavnicama

Slika 30. Sučelje softvera *CDX* s podatkom o brzini zvuka

Slika 31. Izmjerene dubine jezera Zmajevo oko

Slika 32. Gusti oblak neobrađenih prikupljenih točaka cikličnih mjerenja

Slika 33. Uspoređeni gusti oblaci točaka s karakteristikama

Slika 34. Odabir referentnog i uspoređenog oblaka točaka u opciji *Choose role* unutar programa *CloudCompare*

Slika 35. a) Ciklični snimci (OP_0, OP_2 i OP_3) i b) područje preklapanja snimaka korišteno za procjenu vertikalne preciznosti integralnog mjernog sustava

Slika 36. a) Ciklični snimci (OP_2 i OP_3) i b) područje preklapanja snimaka korišteno za procjenu horizontalne preciznosti integralnog mjernog sustava

Slika 37. Primjer ručnog uklanjanja grešaka iz 3D prikaza u softveru *CloudCompare*

Slika 38. Primjer ručnog uklanjanja grešaka iz profila u softveru *CloudCompare*

Slika 39. Primjer automatskog filtriranja gustog oblaka točaka procesom segmentacije u softveru *CloudCompare*

Slika 40. Uzdužni AB i poprečni CD profili jezera Zmajevo oko

Slika 41. Lokacije panoramskih 360° snimaka

Slika 42. Postavljeni parametri za a) panoramske 360° snimke u opciji *Render all 360 Panoramas* i za b) promotivni video u opciji *Render Clip* u softveru *Lumion 10.0.1*.

Slika 43. Shematski prikaz procesa 3D ispisa jezera Zmajevo oko

Slika 44. Procjena pogreške za orijentacijske i kontrolne točke (X, Y pogreške su predstavljene oblikom elipse, Z pogreška je predstavljena bojom elipse)

Slika 45. Generirani gusti oblak točaka užeg područja jezera Zmajevo oko

Slika 46. Poligonski model jezera Zmajevo oko

Slika 47. Visoko-rezolucijski DOF snimak jezera Zmajevo oko

Slika 48. Digitalni model površina (DSM) užeg područja jezera Zmajevo oko

Slika 49. 3D model užeg prostora jezera Zmajevo oko

Slika 50. *C2C absolute distances* model

Slika 51. Tematska karta nesigurnosti podataka

Slika 52. Tematska karta s vrijednostima odstupanja uspoređenih oblaka točaka OP_0 i OP_2

Slika 53. Histogram standardne devijacije za vertikalnu preciznost

Slika 54. Histogram standardne devijacije za horizontalnu preciznost

Slika 55. Vrijednosti SD za vertikalnu preciznost u slučaju: a) OP_0 kao referentni oblak i b) OP_2 kao referentni oblak

Slika 56. Vertikalna preciznost - odnos snimaka: a) OP_0 - OP_2 i b) OP_2 - OP_0

Slika 57. Vertikalna preciznost - odnos snimaka: a) OP_0 - OP_3 i b) OP_3 - OP_0

Slika 58. Vertikalna preciznost - odnos snimaka: a) OP_2 - OP_3 i b) OP_3 - OP_2

Slika 59. Horizontalna preciznost - odnos snimaka: a) OP_2 - OP_3 i b) OP_3 - OP_2

Slika 60. Podvodni tuneli (pukotine)

Slika 61. Perspektivni blokovski prikaz integralnog modela kopna i jezera

Slika 62. Integralni model jezera Zmajevo oko

Slika 63. Isječak iz promotivnog videa *Zmajevo Oko Virtual Walk (Rogoznica, Croatia)*

Slika 64. Panoramski 360° snimci jezera Zmajevo oko sa šest stajališta

Slika 65. Fizički model (suvenir) jezera Zmajevo oko

Popis tabličnih priloga

Tablica 1. Specifikacije *Phantom 4 Pro*

Tablica 2. Specifikacije *Stonex S10*

Tablica 3. Točke lokalne geodetske osnove prikupljene na terenu

Tablica 4. Osnovna specifikacija višesnopnog dubinomjera *WASSP S3*

Tablica 5. Specifikacija GNSS senzora

Tablica 6. Karakteristike prikupljenih neobrađenih točka

Tablica 7. Prosječne udaljenosti točaka uspoređenih oblaka OP_0 i OP_2

Tablica 8. Točnost orijentacijskih točaka preuzeta iz *Agisoft* izvješća

Tablica 9. Točnost kontrolnih točaka preuzeta iz *Agisoft* izvješća

Tablica 10. Vrijednosti standardne devijacije za vertikalnu preciznost integralnog mjernog sustava za uspoređene testne uzorke cikličnih snimaka

Tablica 11. Vrijednosti standardne devijacije za horizontalnu preciznost integralnog mjernog sustava za uspoređene testne uzorke cikličnih snimaka

Sažetak

Proučavanje prirodne baštine uvelike ovisi o njenoj očuvanosti jer globalne klimatske promjene, prirodne katastrofe, masovni turizam, terorizam te ljudski nemar uvelike utječu na promjene u krajoliku, a samim time i na zaštićena područja. Posljednjih desetljeća geoprostorne tehnologije je zahvatio proces ubrzanog razvoja. One su omogućile dokumentaciju trenutnog stanja i izradu modela visoke kvalitete u svrhu očuvanja i promocije zaštićenih područja. Područje istraživanja ovog diplomskog rada bilo je jezero Zmajevo oko kod Rogoznice. Cilj istraživanja bio je utvrditi preciznost integralnog mjernog sustava kombinacija RTK GPS i višesnopnog dubinomjera s obzirom na to da je isti prvi put korišten u Republici Hrvatskoj te dobiti informacije o osnovnim karakteristikama jezera (površina, volumen, dubina). Također, jedan od ciljeva je bio kartirati te klasificirati dno jezera kao i utvrditi podvodne tunele. Aerofotogrametrijom, za koju je korištena bespilotna letjelica *Phantom 4 Pro* opremljena fotoaparatom visoke razlučivosti, obuhvaćeno je vodno lice jezera i šire obalno područje u tampon zoni od 100 m. Batimetrijskom izmjerom, za koju se po prvi put u RH koristio integralni mjerni sustav kombinacija višesnopnog dubinomjera *WASSP S3* i *Hemisphere V320 GNSS* pametne antene, obuhvaćeno je dno jezera. Integralni mjerni sustav s operativnom frekvencijom od 160 kHz u potpunosti je omogućio kartiranje dna te deset bočnih tunela (pukotina). U završnoj fazi istraživanja, podaci prikupljeni objema metodama su spojeni te je izrađen integralni model jezera visoke kvalitete. Na temelju 2.5D i 3D modela izračunati su volumen, površina i duljina obalne linije jezera. Točnost modela dobivenog aerofotogrametrijom iznosi < 5 cm. Vertikalna preciznost, nefiltriranih podataka, integralnog mjernog sustava iznosi 6,8 cm, a horizontalna 11,8 cm. U programu *Lumion* izrađena je virtualna šetnja jezerom u svrhu promocije, a pomoću 3D printera *Prusa i3 MK3* ispisan je i fizički model jezera koji može poslužiti kao suvenir. Prikupljeni podaci visoke kvalitete predstavljaju temelj za buduća istraživanja na ovom zaštićenom području.

Summary

The study of natural heritage largely depends on its preservation because global climate change, natural disasters, mass tourism, terrorism and human negligence greatly affect changes in the landscape, and thus protected areas. In recent decades, geospatial technologies have been affected by a process of rapid development. They enabled the documentation of the current situation and the development of high quality models for the purpose of preserving and promoting protected areas. The research area of this graduation thesis was Lake Zmajevo oko near Rogoznica. The objective of the research was to determine the accuracy of the integrated measuring system of combinations of RTK GPS and multi-beam depth sounder, given that it was used for the first time in the Republic of Croatia and to obtain information on the basic characteristics of the lake (area, volume, depth). Also, one of the objectives was to map and classify the bottom of the lake as well as to identify underwater tunnels. Aerial photogrammetry used by the *Phantom 4 Pro* UAV equipped with a high-resolution camera covered the water surface of the lake and the wider coastal area in the buffer zone of 100 m. The bathymetric survey, for which, for the first time in the Republic of Croatia, an integrated measuring system of combinations of the *WASSP S3* multi-beam depth sounder and the *Hemisphere V320 GNSS smart antenna* was used, covered the bottom of the lake. An integrated measuring system with an operating frequency of 160 kHz has fully enabled the mapping of the bottom and ten side tunnels (cracks). In the final phase of the research, the data collected by both methods were combined and an integrated model of a high quality lake was developed. Based on the 2.5D and 3D models, the volume, area, and length of the lake shoreline were calculated. The accuracy of the model obtained by aerial photogrammetry is < 5 cm. The vertical precision of unfiltered data of the integral measuring system is 6.8 cm, and the horizontal is 11.8 cm. In the *Lumion* software, a virtual walk through the lake was made for the purpose of promoting. A physical model of the lake, which can serve as a souvenir, was printed by the help of the 3D printer *Prusa i3 MK3*. The collected high quality data are the basis for future research in this protected area.