Kartiranje otpada na morskom dnu primjenom podvodnog drona i višesnopnog dubinomjera

Krekman, Sara

Master's thesis / Diplomski rad

2022

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:162:646449

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Image not found or type unknown

Repository / Repozitorij:

University of Zadar Institutional Repository

zir.nsk.hr

Image not found or type unknown

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni jednopredmetni studij primijenjene geografije

Sara Krekman

Kartiranje otpada na morskom dnu primjenom podvodnog drona i višesnopnog dubinomjera

Diplomski rad

Zadar, 2022.

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni jednopredmetni studij primijenjene geografije

Kartiranje otpada na morskom dnu primjenom podvodnog drona i višesnopnog dubinomjera

Diplomski rad

Studentica:

Sara Krekman

Mentor:

Doc. dr. sc. Ivan Marić

Komentor:

Izv. prof. dr. sc. Ante Šiljeg

Zadar, 2022.

Izjava o akademskoj čestitosti

Ja, **Sara Krekman,** ovime izjavljujem da je moj **diplomski** rad pod naslovom **Kartiranje otpada na morskom dnu primjenom podvodnog drona i višesnopnog dubinomjera** 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, 28. listopada 2022.

SADRŽAJ

1. UVOD....4
1.2. Objekt, ciljevi i svrha istraživanja....7
1.3. Hipoteze istraživanja....8
1.4. Prostorni obuhvat istraživanja....9
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA....10
3. TEORIJSKA OSNOVA....14
3.1. Razvoj batimetrije....14
3.1.1 Povijesni razvoj batimetrije....14
3.1.2. Princip rada dubinomjera....18
3.1.3. Backscatter....25
3.1.4 Daljinski upravljana ronilica (engl. *remotely operated vehicle*)....26
3.2 Morski otpad....31
3.2.1 Morski otpad u Jadranskom moru....33
4. METODOLOGIJA ISTRAŽIVANJA....34
4.1 UAV fotogrametrija šireg područja....34
4.1.1. Prikupljanje orijentacijskih (GCP) točaka....35
4.1.3 Obrada UAV snimaka....37
4.2. 3D skeniranje ručnim skenerom....38
4.3. MBES izmjera testne plohe....40
4.3.1 Prikupljanje batimetrijskih podataka....42
4.3.2 Obrada batimetrijskih podataka....47
4.4. ROV snimanje testne plohe....49
4.4.1 Izvođenje fotografija iz videa....51
4.4.2 Priprema podataka za obradu....52
4.4.3 Obrada podvodnih fotografija....54
4.5. Usporedba intervalnih MBES snimanja MBES....56
5. REZULTATI I RASPRAVA....57
5.1. Morski otpad detektiran ROV-om....57
5.1.1. Smjernice za izvođenje podvodne fotogrametrije primjenom ROV-a....60
5.2. MBES intervalna snimanja - gustoća uzorkovanja....62
5.2.1 Detekcija otpada primjenom MBES-a....64
5.2.2 Razlozi izostanka detekcija otpada primjenom MBES-a....69
5.2.3 Ispitivanje preciznosti MBES....72
5.2.4 Rezultati senzora povratnog raspršenja....73
5.3 Smjernice za primjenu MBES-a i ROV-a u detekciji otpada na morskom dnu....74
6. ZAKLJUČAK....77
7. LITERATURA....79
8. IZVORI....87
Popis grafičkih priloga....89
Popis tabličnih prikaza....91

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zadru

Odjel za geografiju Diplomski rad

KARTIRANJE OTPADA NA MORSKOM DNU PRIMJENOM PODVODNOG DRONA I VIŠESNOPNOG DUBINOMJERA

Sara Krekman

Sažetak

Morski otpad predstavljaja sve veću opasnost za morski okoliš. Važnost njegovog kartiranja s ciljem otkrivanja potencijalnih žarišta te prevencije širenja takvih površina postaje sve važnije. U radu je ispitana primjenjivost podvodne bespilotne ronilice (ROV) *Chasing M2* i višesnopnog dubinomjera (MBES) *WASSP S3* u kartiranju, odnosno detekciji i kvantifikaciji morskog otpada na širem području kanala Sv. Ante (Šibenik), u blizini istraživačke postaje Martinska (Institut Ruđer Bošković). Utvrđeno je da se ROV *Chasing M2* može učinkovito primjenjivati u inicijalnoj detekciji otpada u plitkim vodama. Međutim, u slučaju nekorištenja sustava podvodne navigacije ROV-a te pomoćnih mjerenih skala ROV ima ograničene mogućnosti u kvantifikaciji otpada na morskom dnu. Navedeno je utvrđeno usporedbom morfometrijskih parametara gume koji su izvedeni iz 3D modela ručnim 3D skenerom. Prema dobivenim rezultatima višesnopsni dubinomjer *WASSP S3* i senzor povratnog raspršenja (engl. *backscatter*) nisu primjenjivi u identifikaciji mikro i mezo otpada na morskom dnu na dubinama do 10 m. Utvrđeno je da minimalna jedinica kartiranja, odnosno najmanji detektiran objekt morskog otpada, koji *WASSP S3* na dubini do 10 m može detektirati, ima površinu 100 cm * 100 cm, s visinom od oko 40 cm. Nadalje, intervalna MBES mjerenja utvrdila su da *WASSP S3* ima centimetarsku pouzdanost mjerenja (<10 cm) pri različim brzinama plovidbe. Dobiveni rezultati pomogli su oblikovanju smjernica za primjenu MBES-a i ROV-a u detekciji otpada na morskom dnu.

Ključne riječi: otpad na morskom dnu, višesnopni dubinomjer, podvodna bespilotna ronilica, senzor povratnog raspršenja

Voditelji: doc. dr. sc. Ivan Marić, izv. prof. dr. sc. Ante Šiljeg (komentor)

Povjerenstvo: doc. dr. sc. Denis Radoš, doc. dr. sc. Ivan Marić, Mentor, dr. sc Fran Domazetović, izv. prof. dr. sc. Nina Lončar

BASIC DOCUMENTATION CARD

University of Zadar

Department of geography Graduation thesis

MAPPING OF MARINE LITTER ON THE SEAFLOOR USING AN UNDERWATER DRONE AND A MULTIBEAM SENSOR

Sara Krekman

Abstract

Marine litter is an increasing threat to the marine environment. The importance of mapping it with the aim of detecting potential hotspots and preventing their spread is becoming increasingly important. In this paper, the applicability of the *Chasing M2* remotely operated underwater vehicle (ROV) and *Wasp S3* multi-beam echo sounder (MBES) in mapping - detecting and quantifying marine litter in the wider area of the St. Anthony's Channel (Šibenik), near the Martinska Research Station (Ruđer Bošković Institute), is investigated. It's been shown that the ROV *Chasing M2* can be used effectively for the initial detection of marine debris in shallow waters. However, if the ROV's underwater navigation system and auxiliary measurement scales aren't used, the ROV has limited capabilities in quantifying marine debris on the seabed. The named was determined by comparing the morphometric parameters of the tire derived from the 3D model with a manual 3D scanner. According to the results, the *WASSP S3* multi-beam echo sounder and backscatter sensor aren't suitable for identifying micro and meso marine debris on the seabed at depths up to 10 meters. It was found that the used MBES *Wasp S3* can detect marine debris with an area of 100 * 100 centimeters and a height of about 40 centimeters at depths of up to 10 meters. In addition, MBES interval measurements have shown that *WASSP S3* has a measurement accuracy in the centimeter range (< 10cm) at different cruising speeds. The results obtained have helped to establish the guidelines for the use of MBES and ROV in the detection of marine debris on the seabed.

Keywords: marine litter, multi-beam echo sounder, remotely operated underwater vehicle, backscatter sensor

Supervisor: Assistant Professor Ivan Marić, PhD, Associate Profesor Ante Šiljeg, PhD.

Reviewers: Assistant Professor Denis Radoš, PhD, Assistant Professor Ivan Marić, PhD, PhD Fran Domazetović, Associate Profesor Nina Lončar, PhD

1. UVOD

Morski je otpad jedan od glavnih problema današnjice (Pham i dr., 2014; Ioakeimidis i dr., 2015; Consoli i dr., 2018; Tubau i dr., 2015; Vlachogianni i dr., 2018; Kühn i dr., 2015; Jeftić i dr., 2009; Galgani i dr., 2015; Löhr i dr., 2017; Lusher, 2015), a kao jedan od čimbenika koji utječe na ovaj podatak činjenica je da više od polovine stanovništva živi na području do 100 km od obale (Brown i Blondel, 2009). Ovisno o autoru, on se definira na različite načine, no najviše je u uporabi definicija dana od strane UNEPa (UNEP, 2009) koja opisuje morski otpad kao „bilo koji postojani, proizvedeni ili prerađeni čvrsti materijal odbačen, odložen ili napušten u morski i obalni okoliš“ (Pham i dr., 2014). Morski se otpad također definira kao otpad proizveden od strane ljudi koji je odbačen u obalni ili morski okoliš, a rezultat je ljudskih aktivnosti na moru ili kopnu (Löhr i dr., 2017). Morski je otpad definiran i kao „bilo koji postojani, proizvedeni ili prerađeni čvrsti materijal koji nije prirodnog podrijetla nego je proizveden, korišten ili odbačen od strane čovjeka izravno u more ili je u more dospio iz kopnenih izvora putem rijeka, otpadnih voda ili vjetrom“ (URL 1). S obzirom na to da je prisutan u svim oceanima (Galgani i dr., 2015; Tubau i dr., 2015), on ne predstavlja samo estetski problem, nego također ima veliki utjecaj na okoliš, ekonomiju, zdravlje te brojne ljudske aktivnosti diljem svijeta (Jeftić i dr., 2009). Posljednjih se desetljeća sve više povećava iskorištavanje morskih resursa što negativno utječe na sam morski okoliš. Razne ljudske aktivnosti stvaraju velike količine morskog otpada koji ondje može ostati desetljećima ili čak stoljećima (Galgani i dr., 2013). U posljednje se vrijeme naglašava izrazita ugroženost Sredozemnog mora morskim otpadom (Cincinelli i dr., 2019; Pham i dr., 2014; Ioakeimidis i dr., 2015; Costanzo i dr., 2020; Consoli i dr., 2018; Tubau i dr., 2015), koji se s ovim problemom susreće od 70-ih godina prošlog stoljeća (Jeftić i dr., 2009).

Sredozemno more obilježeno je visokorazvijenim turizmom, industrijskim i ribarskim djelatnostima, ali i gustom naseljenošću, što uvelike utječe na količinu morskog otpada toga područja (Cincinelli i dr., 2019). Kao rezultat su povećanje zabrinutosti morskim otpadom što je rezultiralo provedenim istraživanjima s ciljem njegova kartiranja. Detekcija i klasifikacija otpada na morskom dnu temelji se na tri različita pristupa koji se u većini slučajeva kombiniraju (Madricado i dr., 2020). Oni uključuju prikupljanje otpada (A) pomoću pridnenih koćarica (Maes i dr., 2018; Gerigny i dr., 2019; Spedicato i dr., 2019); (B) optičko kartiranje (Oliveira i dr., 2015; Huvenne i dr., 2018; Pierdomenico i dr., 2019), te u novije vrijeme (C) akustičko (MBES) kartiranje morskog dna (Mayer i dr., 2007; Hughes Clarke, 2018; Madricardo i dr., 2019).

Metoda (A) ima sljedeća ograničenja primjene: invazivnost za morsko dno, nemogućnosti primjene na kamenitom morskog dnu te dobivanje nepreciznih informacija o prostornom rasporedu detektiranog otpada (Madricardo i dr., 2020).

Optičke metode kartiranja temelje se na fotografijama i videozapisima, u pravilu u plitkim obalnim područjima, koje mogu prikupiti ronioci (Bauer i dr., 2008), podvodne bespilotne ronilice ili podvodni dronovi (engl. *remotely operated underwater vehicle* - ROV) (Oliveira i dr., 2019), podmornice s posadom (Watters i dr., 2010), bespilotna površinska vozila (engl. *unmanned surface vehicles* - USV) (Wynn i dr., 2014) te autonomna podvodna vozila (engl. *autonomous underwater vehicles* - AUV). Prednost optičkih metoda su sljedeće: neinvazivnost, sposobnost generiranja kvantitativnih podataka, primjena na svim vrstama morskog dna, mogućnost izvođenja ortofoto mozaika morskog dna te 3D modela iz kojih se mogu analizirati morfometrijske značajke detektiranih objekata (Price i dr., 2019). Međutim, njihova primjena može biti ograničena vidljivošću, hidrodinamičkim uvjetima mora (Madricado i dr., 2020) te složenim setom parametara povezanih s izvođenjem procesa podvodne fotogrametrije (engl. *underwater photogrammetry*) (Kalacska i dr., 2018).

Primjerice, na području Katalonije provedeno je istraživanje morskog otpada pomoću ROV-a, koje je rezultiralo dobivenim snimkama morskog dna gdje je morski otpad na gotovo svakoj od snimaka identificiran. Klasificiran je prema tipu, veličini i procijenjenoj težini (Tubau i dr., 2015). Uz klasične primjene kao što su istraživanja infrastrukture (cjevovoda), akvakulture (URL 27), proučavanje olupina na morskome dnu (Warren i dr., 2004) ROV je svoju primjenu pronašao i u istraživanju povezanosti morskog otpada i biodiverziteta mora (Costanzo i dr., 2020; Van Den Beld i dr., 2017; Goodman i dr., 2020), što je pokazatelj važnosti istraživanja ugroženosti morskim otpadom i njegovog kartiranja. Zbog brojnih prednosti koje ROV pruža (prikupljanje video i foto snimaka visoke rezolucije s podacima o dubini i koordinatama samog istraživanog područja, neznatan utjecaj na morski okoliš (URL 28)), upravo su pomoću ove tehnologije provedena istraživanja morskog otpada u pojedinim dijelovima Sredozemnog mora (Consoli i dr., 2018; Enrichetti i dr., 2020; Ioakeimidis i dr., 2015; Tubau i dr., 2015; Costanzo, 2020).

Iako je detektirani otpad Mediterana raznolik, i u njegovom sastavu prevladava plastika koja najvećim dijelom dolazi s kopna, a predstavlja veliku opasnost zbog utjecaja raznih procesa uslijed kojih se degradira na manje fragmente (Cincinelli i dr., 2019). Problemom morskog otpada nije pošteđeno ni Jadransko more, koje se prema količini i zastupljenosti plastičnog otpada nalazi na popisu jednog od najonečišćenijih mora Europe, odmah iza

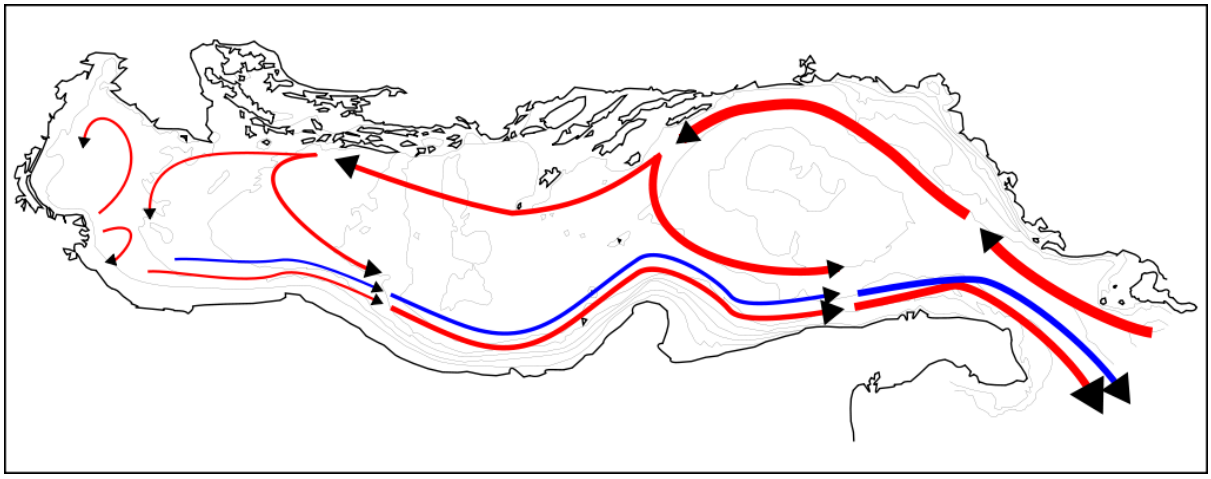
Keltskog mora i sjeveroistoka Sredozemlja. Na ovaj podatak utječu brojni čimbenici kao što su morske struje (Slika 1), priobalne industrije, turizam te brodski promet (Bule i dr., 2020).

Uz ROV, kartiranje makro (velikog) otpada, moguće je primjenjujući tehnologiju višesnopnog dubinomjera (engl. *multibeam echosounder* - MBES) (Madricardo i dr., 2019). Upravo su pomoću njega provedena brojna istraživanja koja su kao rezultat dala podatke visoke rezolucije i pomogla pri detektiranju morskoga otpada (Madricardo i dr., 2019; Mayer i dr., 2007; Kostylev i dr., 2001). Usprkos naglom razvoj tehnologije MBES-a i dalje se kao glavno ograničenje akustičnih metoda navodi rezolucija, odnosno detaljnost prikupljanja podataka, koja primarno ovisi o značajkama korištenog sonara, udaljenosti od morskog dna (dubini) i brzini plovidbe (Madricado i dr., 2020).

Uz višesnopni dubinomjer, pomoć pri klasifikaciji snimanog dna pruža senzor o povratnom raspršenju (engl. *backscatter*) (Brown i dr., 2019), koji ujedno može poslužiti i za klasifikaciju snimljenog morskog otpada (Pierdomenico i dr., 2019). Dakle, podaci o povratnom raspršenju mogu se koristiti za klasifikaciju (sastav) morskog dna i detekciju objekata (Simons i Snellen, 2009; Lacharité i dr., 2018). Prikupljeni se podaci mogu koristiti za istraživanje obilježja morskog dna kao što su tvrdoća, karakteristike sedimenta pa čak i veličina zrna sedimenta. Batimetrijski (MBES) podaci (dubina) povratnog raspršenja prikupljaju se u isto vrijeme. Naime, vremenska razlika između emitiranja pulsa i prijema povratnog zvučnog signala omogućuje mjerenje dubine, dok snaga (intenzitet) vraćenog signala ukazuje na refleksivnost morskog dna (*backscatter* podatak). Broj znanstvenih radova u kojima je rađena detekcija otpada na morskom dnu je oskudan (Hughes Clarke i dr., 1999; Goodman i dr., 2020; Fakiris i dr., 2022). Međutim primjenjivost senzora o opovratnom raspršenju u detekciji otpada na morskom dnu ostaje upitna. Primjerice, Goodman i dr. (2020) ne navode jasno pomaže li im primjena podataka o povratnom raspršenju, uz sve druge prikupljene podatke, u detekciji otpada na morskom dnu. Fakiris i dr. (2022) koriste skupove podataka o povratnom raspršenju sonara kao sekundarne podatke u detekciji otpada na morskom dnu, odnosno za određivanje geomorfoloških značajki morskog dna koje utječu na disperziju i sastav otpada.

S obzirom na to da Jadransko more obilježava strujanje morske vode u smjeru obrnutom od kazaljke na satu (URL 2), odnosno ciklonalna cirkulacija koju karakterizira dolazna struja u smjeru sjevera (uz istočnu, hrvatsku obalu Jadrana) te izlazna struja u smjeru juga (uz zapadnu, talijansku obalu Jadranskog mora), morskim su otpadom ponajviše pogođeni otoci smješteni u južnoj Dalmaciji (Vis, Korčula, Mljet, Lastovo) (Plan gospodarenja morskim otpadom, 2020), čije je ishodište u Grčkoj, Albaniji i Crnoj Gori. Dosadašnja su istraživanja

morskog otpada Jadranskog mora pokazala najveću zastupljenost plastike, koja ne predstavlja samo estetski problem, nego ozbiljno ugrožava cijeli morski okoliš (Kwokal i Štefanović, 2009).



Slika 1. Morske struje Jadranskog mora

Izvor: URL 24

Sve veće količine morskog otpada i njegova spora razgradnja predstavljaju veliku opasnost za morski okoliš (Ioakeimidis i dr., 2015) te je važno njegovo kartiranje s ciljem otkrivanja potencijalnih žarišta te prevencije širenja takvih površina.

U ovom je radu ispitana mogućnost primjene osnovnog paketa bespilotne podvodne ronilice (ROV) *Chasing M2* i višesnopnog dubinomjera (MBES) *WASSP S3* u kartiranju, odnosno detekciji i kvantifikaciji morskog otpada na širem području kanala Sv. Ante (Šibenik), u blizini istraživačke postaje Martinska (Institut Ruđer Bošković).

1.2. Objekt, ciljevi i svrha istraživanja

Objekt istraživanja je **kartiranje otpada na morskom dnu primjenom višesnopnog dubinomjera** *WASSP S3* **(engl. *MBES*) i podvodnog drona** *Chasing M2* **(engl. *ROV*)**.

Glavni je cilj istraživanja **utvrditi prednosti i ograničenja primjene višesnopnog dubinomjera i podvodnog drona u kartiranju otpada na morskom dnu**. Za potrebe ostvarivanja glavnog cilja, bilo je potrebno prije samog istraživanja postaviti nekoliko sekundarnih ciljeva. Oni su sljedeći:

1) Izvesti teksturirane 3D modele morskog otpada na odabranim testnim lokacijama.
2) Ispitati mogućnost primjene uređaja za mjerenje tvrdoće dna (engl. *backscatter*) u detekciji otpada na morskom dnu.

3) Izvesti digitalne batimetrijske modele (engl. *digital bathymetric model*) primjenom višesnopnog dubinomjera.
4) Procijeniti apsolutnu točnost višesnopnog dubinomjera (*WASSP S3*) u izvođenju digitalnih batimetrijskih modela.

1.3. Hipoteze istraživanja

Iz postavljenih ciljeva istraživanja proizašle su sljedeće hipoteze:

- **H1** Uređaj za mjerenje tvrdoće dna (engl. *backscatter*) omogućit će klasifikaciju morskog otpada prema tvrdoći materijala.

Za razliku od dubinomjera, koji mjeri vrijeme proteklo od slanja zvučnog signala do njegovog povratka s ciljem dobivanja dubinskih podataka (Šiljeg i dr., 2017), uređaj za mjerenje tvrdoće dna mjeri intenzitet povratnog signala (URL 3). S obzirom na tip morskoga dna, reflektirani će signal biti jači (ukoliko se radi o tvrđem morskom dnu, npr. kamenju) ili slabiji (ukoliko se radi o mulju ili drugim tipovima morskoga dna koje karakterizira manji stupanj tvrdoće) (URL 3).

- **H2** Višesnopni dubinomjer će omogućiti kartiranje otpada minimalne širine 20 cm na dubinama do 10 metara.

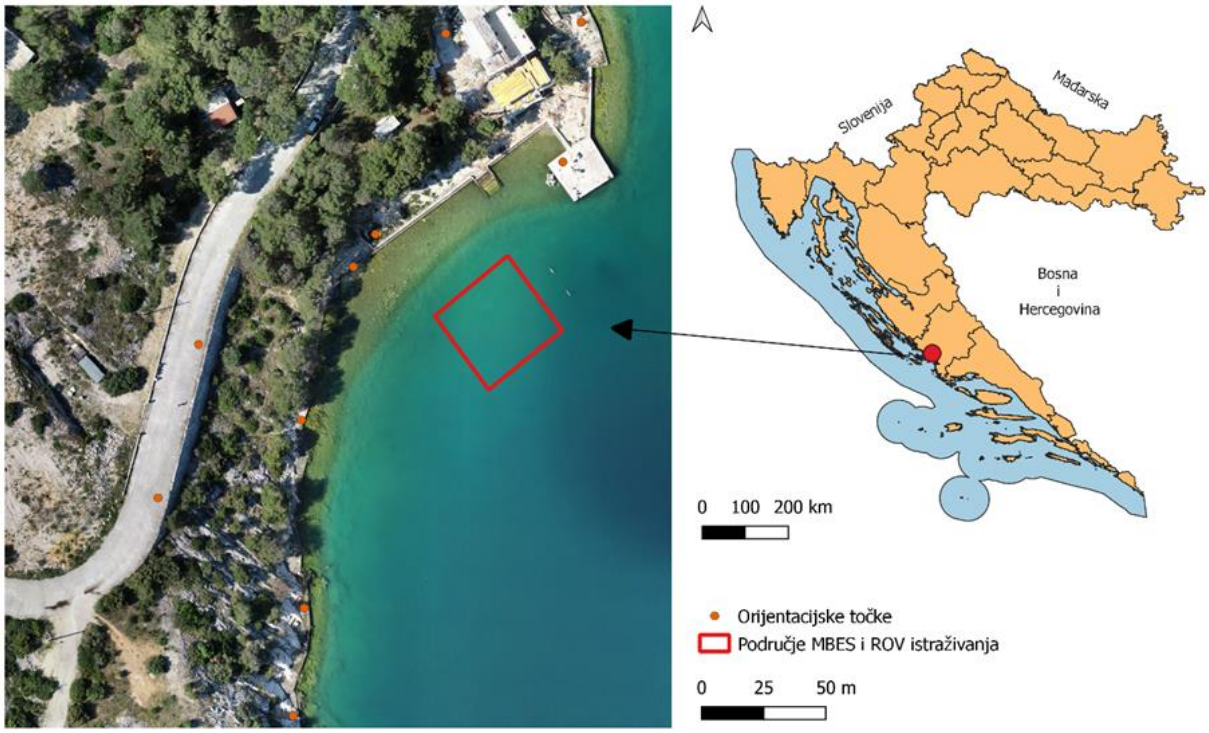
Postavljena se hipoteza odnosi na mogućnost višesnopnog dubinomjera (u ovom slučaju *WASSP S3* modela) da kartira otpad na morskom dnu minimalne širine 20 cm na dubinama do 10 metara.

- **H3** Preciznost višesnopnog dubinomjera će biti manja od 10 cm na dubinama do 10 metara pri različitim brzinama snimanja

Sposobnost mjernog uređaja da prilikom više mjerenja pokazuje jednake ili slične rezultate naziva se pouzdanost mjerenja ili preciznost. Preciznost se višesnopnog dubinomjera ispitala na temelju intervalnih snimanja odabrane testne plohe. Intervalna su se snimanja izvodila pod različtim smjerom snimanja i brzine plovidbe. S navedenim se ispitao utjecaj korisničko-definiranih parametara na pouzdanost mjerenja s WASSP S3-om. Preciznost se sustava ispitala u programu *CloudCompare*, primjenom alata M3C2.

1.4. Prostorni obuhvat istraživanja

Prostorni obuhvat istraživanja obuhvaća testnu plohu površine 400 m² na širem području kanala Sv. Ante u blizini istraživačke postaje Martinska (Ruđer Bošković Institut) (Slika 2).



Slika 2. Geografski položaj područja istraživanja

Brojni su razlozi zbog kojih je upravo prikazana lokacija odabrana kao područje istraživanja. Prije svega, Martinska je jedna od istraživačkih postaja Instituta Ruđer Bošković. Na toj su lokaciji postavljene podvodne kamere te je na navedenom području prisustvo otpada od prije poznato, što je, prije svega, posljedica velike koncentracije pomorskog prometa koji za sobom vuče i bačeni otpad. Održavanje ljetnih festivala te ribolov povod su okupljanja ljudi na ovome području koji, iskorištavajući zabačenost lokacije, odlučuju odlagati otpad koji nerijetko završi upravo u moru.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Dosadašnja se istraživanja, s obzirom na složenost istraživanja ovog rada, mogu podijeliti u tri grupe: (1) znanstvena istraživanja koja obrađuju problematiku ROV-a;

Van Den Beld i dr. (2017) pomoću ROV-a i vučne kamere istražuju stanje u podmorju Biskajskog zaljeva koje je obilježeno brojnim podmorskim kanjonima u kojima se nalaze ranjivi ekosustavi. Cilj je istraživanja otkriti gustoću morskog otpada, njegove glavne izvore, utjecaj okoliša na distribuciju morskog otpada te utjecaj istog na bentoske zajednice. Istraživanjem morskog otpada utvrđuju najveću zastupljenost plastike i ribolovne opreme.

Tubau i dr. (2015) pomoću *Liropus 2000* ROV-a opremljenog s tri kamere proučavaju zastupljenost morskog otpada sjeverozapadnog Sredozemlja (Katalonija, Španjolska). Morski je otpad pronađen na dubinama od 140 do 1731 m, prilikom 24 od ukupno 26 zaranjanja. Svi su podaci imali vremenski kod kako bi ih se povezalo s geografskim položajem i dubinom na kojoj su prikupljeni, a za izdvajanje su pojedinačnih kadrova koristili *Videolan* softver. Utvrđeno je dominantno prisustvo plastike, nakon čega slijede ribolovni otpad te objekti sačinjeni od metala.

Kwasnitschka i dr. (2013) prikupljaju podatke morskog dna na području Zelenortskih Otoka pomoću ronilice ROV *Kiel 6000* te izrađuju trodimenzionalni model snimljenog područja. Ističu važnost posjedovanja kvalitetne kamere prilikom istraživanja s obzirom da ona ima značajan utjecaj na izlazne rezultate.

Ioakeimidis i dr. (2015) na području Saronikos zaljeva (Grčka) pomoću ROV-a provode istraživanje morskog otpada. Morski je otpad prema tipu materijala kategoriziran u šest skupina te se pokušao utvrditi njihov izvor. Plastika se sa svojih 55% zajedno s metalom (36%) ističe kao najzastupljeniji tip morskog otpada.

Constanzo i dr. (2020) provode istraživanje morskog dna obala Sicilije s ciljem utvrđivanja utjecaja ribarstva (i ribarskog otpada) na morski sustav. U svome istraživanju koriste podvodni dron (ROV) kojim snimaju morsko dno i proučavaju njegovo stanje. Gustoću morskog otpada izražavaju kao broj komada morskog otpada pronađenog na jedinici površine od 100 kvadratnih metara.

Consoli i dr. (2018) pomoću ROV-a snimaju gotovo 30 km dugo područje srednjeg Mediterana s ciljem otkrivanja sastava gustoće morskoga otpada toga područja. Gustoća

morskog otpada snimanog područja varira od 0 do 0,64 komada otpada/m^2, od čega najveći udio zauzima plastika.

Christ i Wernli (2007) u priručniku kroz 14 poglavlja daju kratak povijesni pregled bespilotnih ronilica, objašnjavaju njihov dizajn i komponente, osnove sonara, oceanografije te navode različita područja njihove primjene.

Matika i Liović (2014) u članku daju pregled bespilotnih ronilica kroz njihov povijesni razvoj. Navode glavne tipove i primjenu bespilotnih ronilica, naglašavajući efikasnost i prilagodljivost, ovisno o svrsi njihova istraživanja.

(2) znanstvena istraživanja koja obrađuju MBES-a i backscattera

Buhl-Mortensen i dr. (2014) u sklopu MAREANO programa u razdoblju od 2006. do 2013. godine provode kartiranje morskog dna nizozemske obale. Koristeći razne metode za provedbu istraživanja, ističu važnost višesnopnog dubinomjera pomoću kojeg dobivaju podatke o dnu i njegovoj tvrdoći. Pomoću dobivenih podataka dolaze do zaključaka i o zagađenosti morskog dna tog područja.

Madricardo i dr. (2019) koristeći višesnopni dubinomjer dobivaju batimetrijske podatke za područje Venecijske lagune te provode kvantitativnu analizu ljudskog djelovanja na morsko dno. Naglašavaju važnost proučavanja posljedica koje izravne i neizravne ljudske aktivnosti imaju na obalne sustave, stavljajući naglasak na pomorski promet.

Hell (2011) u svojoj doktorskoj disertaciji naglašava važnost koju batimetrijska izmjera ima za prostorno planiranje uz obalu, istraživanje morskih resursa, zaštitu okoliša, sigurnost plovidbe, fizičku oceanografiju, dokumentiranje morskih staništa i brojne druge. Objašnjava razne metode prikupljanja batimetrijskih podataka te navodi njihove prednosti i mane.

Kearns i Breman (2010) kroz svoj rad naglašavaju važnost batimetrije s ciljem što boljeg razumijevanja oceana, ali i same Zemlje. U radu daju pregled batimetrijskih tehnologija, uključujući satelite, LiDAR, jednosnopni i višesnopni dubinomjer, kao i izlazne rezultate koje svaka tehnologija daje.

Lim i dr. (2018) koristeći višesnopni dubinomjer, ROV te uzorke s morskog dna proučavaju dubokomorske koralje, uspoređujući prikupljene podatke.

Wölfl i dr. (2019) u svom radu daju pregled tehnika batimetrijskih istraživanja kroz njihov povijesni razvoj. Kroz razne primjere ističu važnost batimetrijskih istraživanja, no isto tako

naglašavaju činjenicu da vodene površine zauzimaju 71% ukupne Zemljine površine, no unatoč tome, mnoga su područja i dalje neistražena.

(3) znanstvena istraživanja koja obrađuju problematiku morskog otpada

Derraik (2002) u radu naglašava opasnost koju plastični otpad predstavlja za morski okoliš. Ističe prijetnju koju on ima na opstanak brojnih vrsta te predlaže razne načine pomoću kojih bi se problem mogao ublažiti; kao što su edukacija, korištenje biorazgradive plastike te samo istraživanje morskog dna s ciljem dobivanja podataka o zastupljenosti morskog otpada na određenom području.

Löhr i dr. (2017) stavljaju naglasak na zamjetno povećanje plastike u morima nakon 1950ih godina te njegove izvore, ali i učinke koje ima na morski ekosustav. Kompilacijom postojeće literature detaljno istražuju izvore i učinke morskog otpada te predlažu moguća rješenja s ciljem poboljšanja stanja morskog otpada.

Goodman i dr. (2020) u svome istraživanju provode kvantitativnu i kvalitativnu analizu morskog otpada na području zaljeva Fundy u istočnoj Kanadi pomoću videozapisa morskoga dna prikupljenih pomoću sustava padajućih kamera. Zaključuju kako se otpad većinski nalazi uz samu obalu, a njegov najveći dio zauzimaju upravo plastika te ribolovna oprema.

Gonçalves i dr. (2020) uz korištenje bespilotne letjelice *DJI Phantom 4 Pro* prikupljaju visokorezolucijske podatke portugalske plaže Cabedelo te uz pomoć algoritama *Random forest* te *Convolutional neural network* provode analizu otpada koji se ondje nalazi. U svom radu naglašavaju važnost praćenja izvora i stanja onečišćenja s obzirom na veliku prisutnost otpada.

Alomar i dr. (2019) u svome radu daju pregled petnaestogodišnjeg istraživanja prostornog i vremenskog rasporeda morskog otpada na dnu zapadnog Mediterana. Kroz istraživanje nije zapažen vremenski trend povećanja ili smanjenja plastike na morskom dnu, koja zauzima najveći dio ukupnog morskog otpada (66%).

Vlachogianni i dr. (2018) daju pregled jednogodišnjeg istraživanja sastava, količine i izvora morskog otpada Jadransko-Jonske regije provedenog u sedam zemalja, uključujući i Hrvatsku. Pronađeni je otpad (veći od 2.5 cm) na području 100 m prema pučini i 10 metara prema unutrašnjosti plaže razvrstan te je izračunata njegova gustoća koja je u prosjeku iznosila 0.67 komada otpada/ m^2.

Galgani i dr. (2015) iznose činjenicu o prisutnosti morskoga otpada u svim oceanima. U svome se radu bave problemom morskog otpada, čija se količina povećala posljednjih desetljeća. Izvore morskog otpada dijele na kopnene i morske (koji se ponajviše odnose na ribolov). Ističu plastiku kao najučestaliji tip morskoga otpada te proučavaju raspored morskog otpada na plažama, stupcu vode te morskome dnu.

Andrady (2015) u svome radu ističe problem morskoga otpada, posebice plastike, koja se pojavljuje na morskoj površini, vodenom stupcu te na morskome dnu, ali je također zastupljena i na plažama. Ističe plastiku kao jednu od glavnih komponenata morskoga otpada te prikazuje njen proces raspadanja na manje fragmente.

Pham i dr. (2014) na 32 lokacije u Europi pomoću videozapisa i koća proučavaju gustoću i rasprostranjenost morskog otpada. Kao mjeru gustoće uzimaju količinu i masu (izraženu u kg) pronađenog morskog otpada na jedinici površine. Ističu plastiku, uz ribolovnu opremu, kao najučestaliju vrstu pronađenog otpada. Istraživanje je rađeno s ciljem prevencije akumulacije morskog otpada u morskom okolišu.

3. TEORIJSKA OSNOVA

3.1. Razvoj batimetrije

Batimetrija se definira kao znanost koja se bavi proučavanjem dubina (Kearns i Breman, 2010) i podvodnom topografijom mora, oceana i jezera (Hell, 2011). Povijest ove znanosti seže unatrag do više od 3000 godina, uzimajući u obzir dokaze iz drevnog Egipta (Wölf i dr., 2019). Kao jedna od grana hidrografije (Šiljeg i dr., 2017), batimetrija pronalazi svoju primjenu u raznim aktivnostima kao što su plovidba, arheologija podmorja, praćenje sedimenata (Hell, 2011), ribarstvo i mineralna industrija (Elhassan, 2015.a), izgradnja lučkih terminala (Šiljeg i dr., 2018), kartiranje morskog otpada (Gonçalves i dr., 2020) te mnogim drugima. S obzirom na to da je morsko dno podložno promjenama uslijed gibanja mora, batimetrijske bi se izmjere, koje bi trebale biti polazne točke svakog projekta vezanog uz marinski okoliš (Mateo-Pérez i dr., 2020), trebale redovno ponavljati s ciljem ažuriranja i nadopune već postojećih podataka (Yunus i dr., 2019). Batimetrijskim se istraživanjem dobivaju podaci koji imaju svoje x, y i z koordinate. Koordinate x i y označavaju horizontalnu poziciju, dok z koordinate izražavaju dubinu izmjerenog područja (Šiljeg i dr., 2017). Svaka se batimetrijska izmjera razlikuje s obzirom na to koju preciznost pruža, što samim time može utjecati na točnost izlaznih rezultata (Mateo-Pérez i dr., 2020).

3.1.1 Povijesni razvoj batimetrije

Kroz povijest su se tehnike batimetrijske izmjere izmjenjivale usporedno s napretkom tehnologije. Stoga pratimo razvoj od ručnih dubinomjera s utegom (Slika 3), dubinomjernih motki (Šiljeg i dr., 2017; Elhassan, 2015b), Tannerovog sondnog uređaja (Slika 4) do ultrazvučnih dubinomjera koji su promijenili i unaprijedili batimetrijske izmjere kakve se do tada poznavalo (Elhassan, 2015b).

3.1.1.1 Ručni dubinomjer s utegom

Ručni je dubinomjer svoju primjenu pronašao 85. p. n. e. kada ga je Posidonije iskoristio kako bi izmjerio dubinu mora kod Sardinije (Elhassan, 2015b) koja je iznosila 1000 fantoma (1 fantom = 1,8m) te predstavlja jedino zabilježeno uspješno mjerenje dubina do toga vremena (Elhassan, 2015a). Tijekom ekspedicije *HMS Challenger* 1870ih su se godina provodila višestruka istraživanja dubina mora pomoću ove klasične batimetrijske metode, koja je svoju primjenu pronalazila u istraživanjima sve do početka 20. stoljeća (Wölfl i dr., 2019).

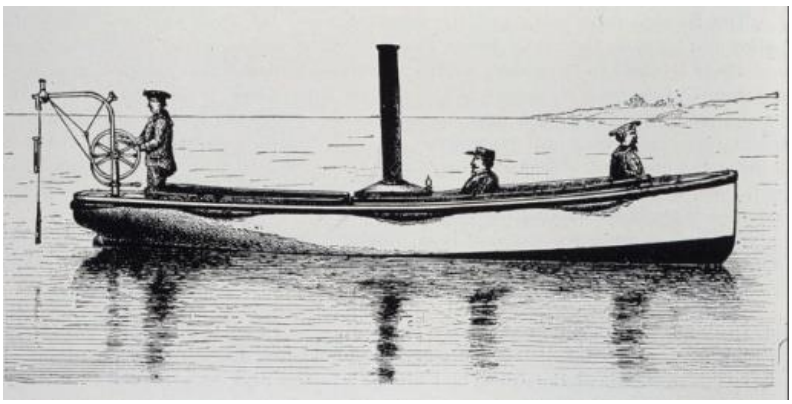


Slika 3. Ručni dubinomjer s utegom

Izvor: URL 4

3.1.1.2 Tannerov sondni uređaj

U 19. je stoljeću Sir William Thomson izumio instrument za mjerenje dubina koji koristi cijevi obložene srebrovim kromatom, a podatke o dubini istraživanog područja nastaju kao rezultat tlaka zraka u njima. Nedugo nakon, zapovjednik Tanner je također izumio stroj koji je bio učinkovit u mjerenju plićih područja (Elhassan, 2015a).



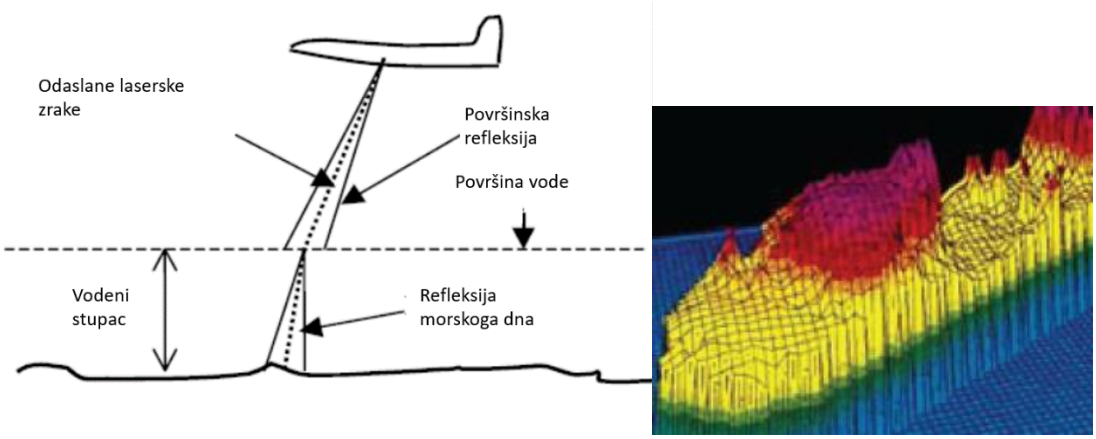
Slika 4. Korištenje Tannerovog sondnog uređaja

Izvor: URL 5

3.1.1.3 Zračni LiDAR

LiDAR (engl. *Light Detection and Ranging*) je tehnologija koja se, između ostaloga, koristi i za mjerenje dubina plićih područja (Irish i White, 1998). Prepoznat je kao potpuno automatiziran, aktivan, optičko-mehanički postupak prikupljanja prostornih podataka s aktualnih snimališta (Gajski, 2007). Princip rada ove tehnologije započinje odašiljačem koji odašilje impulse prema vodenoj površini te se za dobivanje podataka o dubini koristi vremenska razlika između laserskog impulsa koji se odbio o vodenu površinu i onog odbijenog o morsko dno (Irish i White, 1998; Wölfl, 2019). Važno je naglasiti kako se, jednom odbijeni

laserski impuls odašilje u svim smjerovima te se samo mali dio vraća natrag prema senzoru, ovisno o stupnju refleksije snimanog objekta, koji za uzburkanu vodu iznosi 20% za valnu duljinu 900nm (Gajski, 2007). Impulsni laseri odašilju svjetlost valne duljine λ=1064nm (blisko infracrveno) koja se koristi jer ne može oštetiti ljudski vid. Izrazito upijanje infracrvenog zračenja jedna je od karakteristika vode te se zbog toga pri batimetrijskim istraživanjima istodobno koriste i zračenja valnih duljina λ=532nm (zelena svjetlost). Podaci se o dubini dobivaju pomoću vremenske razlike dobivene odašiljanjem obje frekvencije (Gajski, 2007). Zračni se LiDAR (Slika 5) pokazao kao efikasna metoda batimetrijske izmjere u plićim, obalnim područjima s kvalitetnim izlaznim rezultatima (ukoliko su uvjeti snimanja zadovoljeni) (Guenther, 2007). Zbog nemogućnosti svjetla da prodre u dublje dijelove (i vrati se natrag) (Brown i Blondel, 2009), ipak je ograničen na plitka područja (Wölfl, 2019) te samim time ne može predstavljati adekvatnu zamjenu za snimanje sonarom (Guenther, 2007).



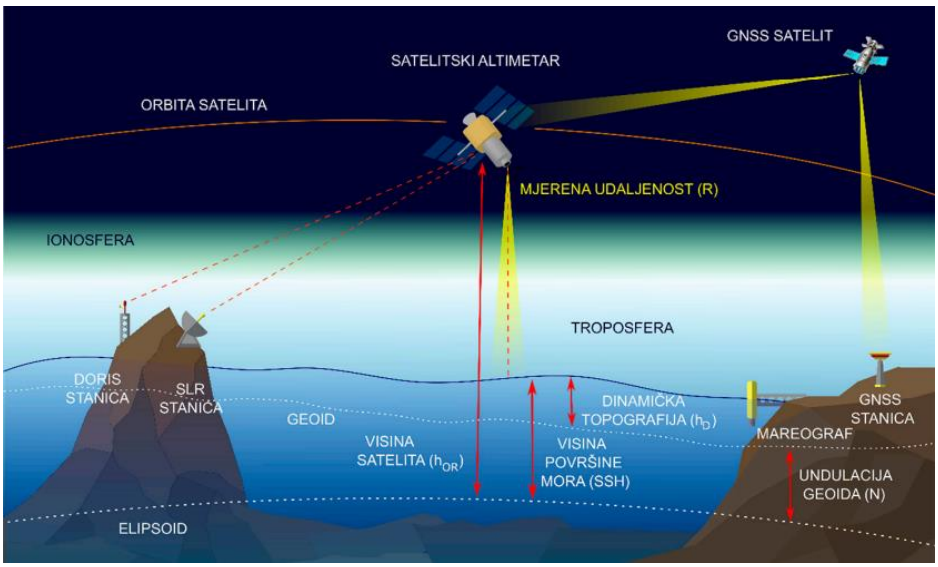
Slika 5. a) Princip rada LiDAR-a; b) primjer modela izvedenog zračnim LiDAR-om

Izvor: URL 29, Gajski, 2007.

3.1.1.4. Satelitska altimetrija

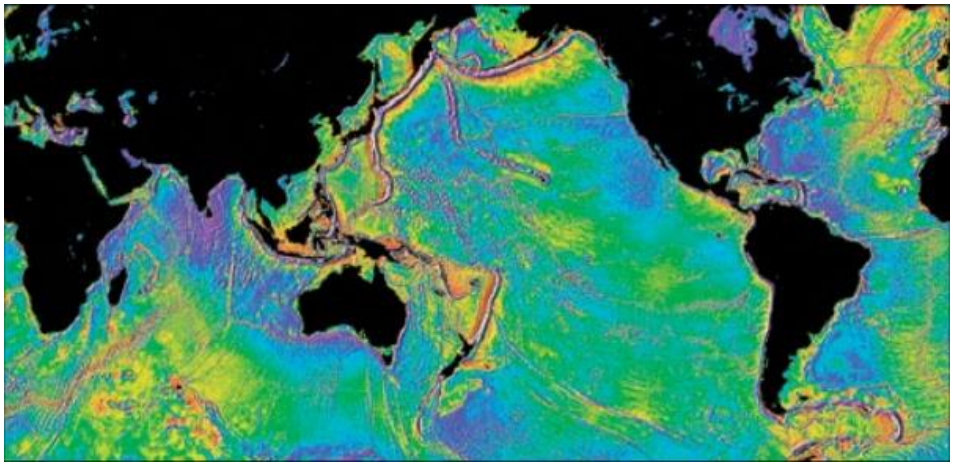
Satelitska je altimetrija prva tehnika koja pomoću radiovalova mjeri Zemljinu površinu, a koja se pokazala izrazito dobrom zbog svojstava refleksije vode (Stržak i Vudrag, 2005). Poznavajući visinu satelita iznad trenutne površine mora, dobivaju se podaci o površini mora putem radara-altimetra, koji odašilje radiovalove s ciljem dobivanja podataka (Bašič, 1993) koji, prije svega, svoju primjenu pronalazi u geodeziji (Stržak i Vudrag, 2005). Ovom se tehnikom prikupljanja podataka dobivaju korisni podaci o morskoj topografiji i samoj cirkulaciji vodene mase. Šezdesetih je godina prošlog stoljeća razvijen sami koncept ove tehnologije koja, između ostaloga, služi i za praćenje klimatskih promjena. Poznavanjem udaljenosti satelita od morske površine (izračunava se pomoću vremena koje je potrebno

radarskom signalu da prijeđe put od satelita do površine vode i natrag), moguće je izračunati visinu vodenog stupca u odnosu na referentni elipsoid ili geoid. Prilikom je računanja udaljenosti satelita od površine vode potrebno uzeti i niz drugih faktora koji mogu utjecati na brzinu odaslanog signala, kao što su atmosferski utjecaji (atmosferski tlak, troposferska korekcija, ionosferska korekcija…), morske mijene vode područja istraživanja i brojni drugi (Grgić i dr., 2017). Satelitska se altimetrija (Slika 7) pokazala korisnom u izradi generalnih batimetrijskih karata, kada je potrebno interpolirati područja koja nisu snimljena batimetrijskim istraživanjima *in-situ*. Također, prednost ove tehnologije je dobivanje batimetrijskih podataka za područja udaljena od kopna, no s upitnom točnošću u odnosu na druge tehnologije prikupljanja podataka (Slika 6) čiji su izlazni rezultati karakterizirani s većom točnošću od satelitske altimetrije (Kearns i Bremen, 2010).



Slika 6. Usporedba principa rada satelitskog altimetra i mareografa

Izvor: Grgić i dr., 2017.



Slika 7. Primjer modela izvedenog satelitskom altimetrijom

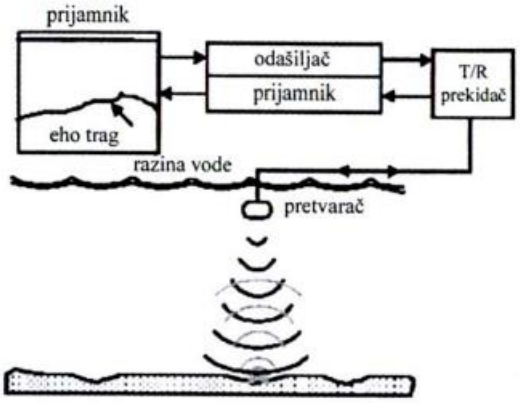
Izvor: Kearns i Bremen, 2010.

3.1.2. Princip rada dubinomjera

Uređaj za mjerenje dubine vode, dubinomjer, svoju primjenu pronalazi u brojnim oceanografskim istraživanjima. Danas je ultrazvučni dubinomjer u najširoj upotrebi (URL 30), a sastoji se od pet sastavnica:

1. odašiljač (engl. *transmiter*);
2. O/P prekidač (engl. *T/R switch*);
3. pretvarač (engl. *transducer*);
4. prijemnik (engl. *reciever)*;
5. sustav za snimanje (engl. *recorder*) (Slika 8).

Odašiljač generira i odašilje elektronski impuls preko O/P prekidača koji ga dalje prenosi do pretvarača. U pretvaraču se on pretvara u zvučni impuls koji se kao takav šalje prema dnu (de Jong i dr., 2002) i reflektira natrag do prijemnika preko O/P prekidača (gdje se iznova transformira u elektronski signal) (Šiljeg i dr., 2017) te se u sustavu za snimanje mjeri vrijeme putovanja zvučnog signala, a prikupljeni se podaci pohranjuju (de Jong i dr., 2002). Pretvarač (sonda) je u neprestanom kontaktu s vodom jer je postavljen na trup broda, a služi za pretvaranje elektronskog impulsa u zvučni, odašiljanje zvučnog impulsa u vodu te primanje povratnog zvučnog vala (de Jong i dr., 2002).



Slika 8. Princip rada ultrazvučnog dubinomjera

Izvor: de Jong i dr., 2002.

S ciljem dobivanja točnih podataka o dubini, važno je znati brzinu zvuka u vodi i frekvenciju kojom se signal šalje. Brzina zvuka u vodi doseže otprilike 1500 m/s pod uvjetom da je vrijednost temperature 0°C, saliniteta 35‰ i tlaka 760mmHg (Šiljeg i dr., 2017). Niža je frekvencija efikasnija za veću dubinu, dok je domet ograničen prilikom korištenja viših frekvencija (de Jong i dr., 2002). Dubina se računa prema sljedećoj formuli:

$$D = ½ (v \cdot t) + k + d_r + r \quad (1)$$

gdje je:

v = brzina zvuka u vodi

t = proteklo vrijeme poslanog impulsa od pretvarača do dna i natrag do pretvarača

k = konstanta indeksa sustava

d_r = udaljenost od referentne površine vode do pretvarača

r = korekcija referentnog datuma (korekcija plime) (USACE, 2002).

3.1.2.1 Jednosnopni dubinomjer (engl. *single-beam echo sounders*)

Jednosnopni je dubinomjer (engl. *single-beam echo sounders*) izumljen 1900-tih godina, a svoju je primjenu u batimetriji pronašao 30-ak godina kasnije (Kearns i Breman, 2010). Jednosnopni je dubinomjer (Slika 9) označio znatan napredak batimetrijskih istraživanja zbog svoje točnosti i učinkovitosti u odnosu na prijašnje instrumente (Wölfl, 2019). Ovim se uređajem batimetrijski podaci prikupljaju direktno ispod broda (izmjerena jedna vrijednost dubine), dok je njihova frekvencija intervala od 12 do 710 kHz (Šiljeg i dr., 2017; Kearns i Breman, 2010), a širina snopa od 30° (de Jong i dr., 2002). Zbog jeftinije se cijene opreme i lakše obrade podataka često koriste, a zbog načina je snimanja prilikom obrade prikupljenih

podataka potrebno koristiti metode interpolacije (Slika 10). Jednosnopni dubinomjeri danas nude centimetarsku točnost (Šiljeg i dr., 2018). Međutim, ovakav tip tehnologije nije namijenjen snimanju velike površine morskog dna (Šiljeg i dr., 2017; Kearns i Breman, 2010), kao što je slučaj s višesnopnim dubinomjerima (Kearns i Breman, 2010). Tri su glavna faktora koja utječu na prostornu rezoluciju podataka prikupljenih jednosnopnim dubinomjerom:

a) dubina mjernog područja;

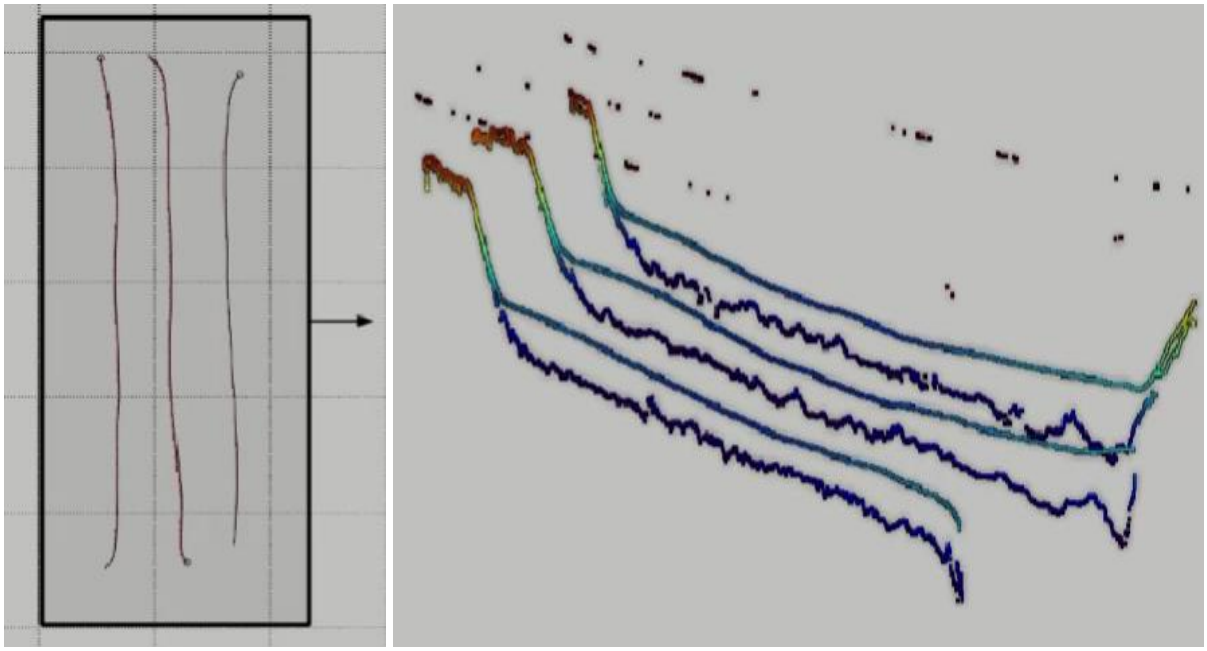
b) obilježja senzora;

c) planiranje batimetrijske izmjere (Kearns i Breman, 2010).



Slika 9. Jednosnopni dubinomjer

Izvor: URL31

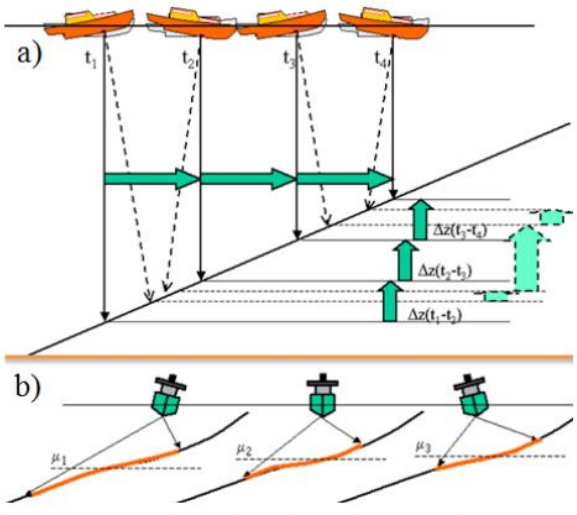


Slika 10. Prikaz podataka prikupljenih jednosnopnim dubinomjerom

Izvor: URL 32

3.1.2.3 Višesnopni dubinomjer (engl. *multi-beam echo sounders*)

Višesnopni su se dubinomjeri počeli koristiti 1970-ih godina, istovremeno s razvojem GPS-a (Wölfl i dr., 2019). Glavna razlika koja čini višesnopni dubinomjer naprednijim od jednosnopnog je mjerenje više vrijednosti dubina za isto vrijeme snimanja (Šiljeg i dr., 2018), što omogućuje veću produktivnost (Elhassan, 2015a). Takav tip prikupljanja podataka rezultira većom pokrivenosti površine te dobivenim modelom morfologije dna bez potrebe korištenja interpolacijskih metoda, kao što je slučaj kod jednosnopnog dubinomjera (Šiljeg i dr., 2018). No, višesnopni dubinomjer prati i nekoliko nedostataka, kao što su kompleksna obrada prikupljenih podataka i visoka cijena same opreme za čije je korištenje potrebno poznavanje tehnologije i načina korištenja s ciljem dobivanja što preciznijih podataka (Šiljeg i dr., 2017). Tijekom batimetrijske izmjere valovi mogu imati značajan utjecaj na brod, a samim time i na sondu koja je za njega pričvršćena te pod jednakim utjecajem vanjskih faktora (Slika 11). Ukoliko se brod naginje po *roll* (longitudinalna os) osi u smjeru *starboard*-a, snopovi će se proširiti na njegovu drugu, *port* stranu. S druge pak strane, ako se brod pomiče po *pitch* osi (lateralna os) prema naprijed, *footprint* (područje snimanja) će se u tom slučaju pomaknuti prema krmi broda, tj. u smjeru suprotnom plovidbi. Naposljetku, ako brod promijeni svoj smjer plovidbe (vertikalna os, *yaw*) područje će se snimanja zarotirati prema onom smjeru prema kojemu se i sam brod zarotirao (Galway, 2000). Horizontalno se i vertikalno pozicioniranje mjeri pomoću GPS-a i IMU (inercijalni mjerni sustav) sustava (Slika 12). S obzirom na to da je plovilo u neprestanom kretanju i samim time i pod utjecajem valova, važno je konstantno praćenje njegovog položaja (Kearns i Breman, 2010).



Slika 11. Prikaz utjecaja prednjih (a) i bočnih (b) valova na plovilo i prikupljanje podataka

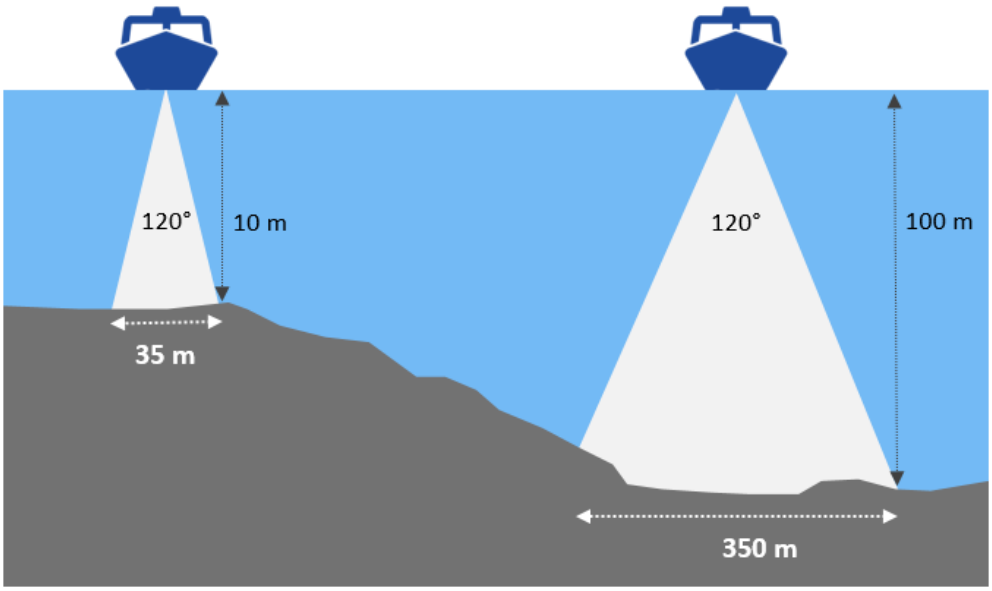
Izvor: Šiljeg, 2013.



Slika 12. WASSP senzorna kutija s integriranim IMU sustavom

Izvor: Šiljeg i dr., 2022

Zbog velike horizontalne (od ±20 do ±30 cm) i vertikalne (od ±2 do ±8 cm) točnosti, koja se postiže pomoću RTK-GPS-a, višesnopni dubinomjeri svoju primjenu pronalaze u podvodnoj arheologiji, podvodnoj gradnji i brojnim drugim znanstvenim istraživanjima (Šiljeg i dr., 2017) te se smatraju jednim od najučinkovitijih alata prilikom kartiranja morskog dna (Parnum i Gavrilov, 2011). Prilikom se batimetrijskih istraživanja ističe važnost utjecaja dubina (Slika 13) na točnost prikupljenih podataka (Kearns i Breman, 2010). Veličina okvira snimka (engl. *footprint*) je u prosjeku 1-10% dubine vode (Galway, 2000), a ona se s porastom dubine povećava, što utječe na smanjenje prostorne rezolucije. Višesnopni i zračni laserski dubinomjeri upotrebljavaju preklapanje s ciljem dobivanja kontinuirane i potpune snimke snimljenog područja (Kearns i Breman, 2010).



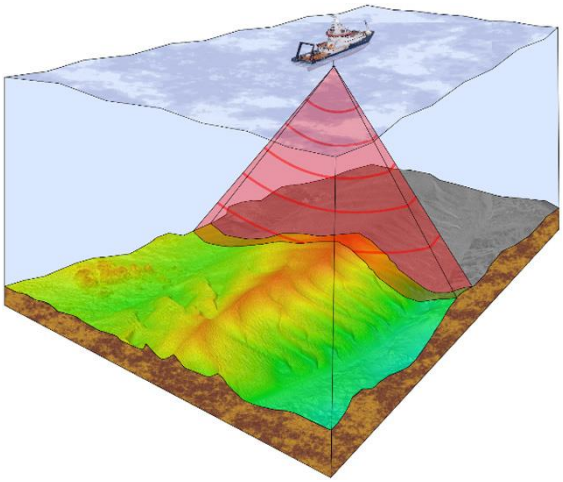
Slika 13. Utjecaj dubine na povećanje okvira (engl. footprint) snimka

Izvor: Kearns i Breman, 2010.

Višesnopni se dubinomjeri mogu podijeliti u dvije skupine: *swath* i *sweep* sustavi (de Jong i dr., 2002). *Swath*-ovi označavaju kontrolne linije, dok nizovi s više pretvarača označavaju *sweep* sustave (URL 33):

1) *Swath* sustav

Razvoj *swath* sustava se počinje pratiti od 70-ih godina prošlog stoljeća. Pretvarač proizvodi višestruke zvučne snopove te ih odašilje prema dnu, a kao rezultat su mjerenja dobiveni batimetrijski podaci širokog područja (sustav osigurava 100 postotnu pokrivenost) koji se mogu koristiti prilikom geološkog kartiranja, oceanografskih i brojnih drugih znanstvenih istraživanja (de Jong i dr., 2002). *Swath* se višesnopni dubinomjeri (Slika 14) mogu postaviti ispod ili sa strane broda, no pronalaze primjenu i u kombinaciji s podvodnim dronovima (ROV) (de Jong i dr., 2002). Ne smije se zanemariti mogućnost integriranja ovakvog sustava na ROV, koji potom služi za daljnja istraživanja (URL 34, URL 35). Brojni su primjeri gdje se uz kupnju ROV-a može kupiti i sonar koji se na njega potom može integrirati (URL 36).



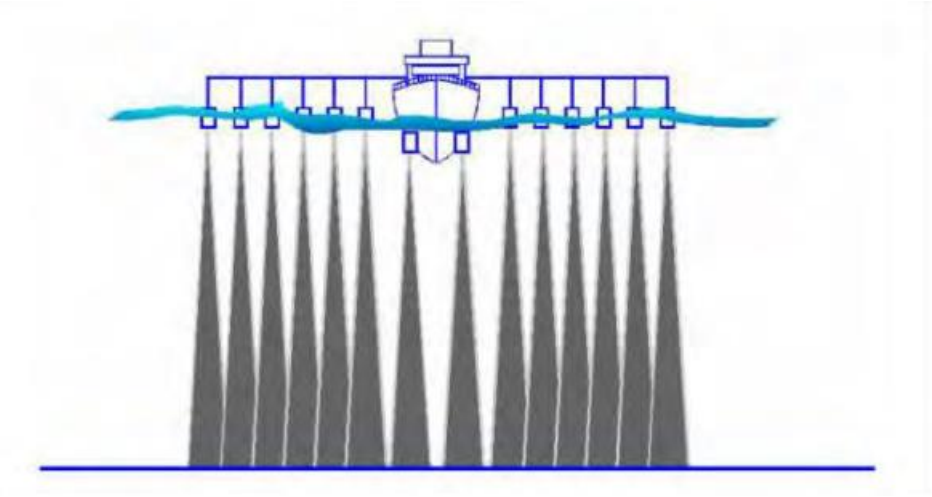
Slika 14. Primjer Swath višesnopnog dubinomjera

Izvor: URL 37

S ciljem dobivanja snimke što većeg područja prilikom batimetrijske izmjere, zvučni je impuls širokog spektra odaslan u jednom smjeru. Pretvarač, koji je zvučni impuls odaslao i primio natrag prikupljene podatke, sada ih pretvara u više manjih snimaka. Kolike će one biti širine ovisi o samome sustavu, a u prosjeku su nekoliko stupnjeva. Ovakvim se načinom snimanja dobivaju količinski veći podaci o dubinama za svaki poslani impuls (de Jong i dr., 2002).

1) *Sweep* sustav

Sweep se sustav sastoji od većeg broja jednosnopnih dubinomjera postavljenih jedni do drugih na nosačima s obje strane plovila (Slika 15), najčešće s ciljem snimanja luka i kanala, tj. uskih i plitkih vodenih površina (de Jong i dr., 2002), dok njihovo korištenje opada prilikom snimanja područja većih dubina uslijed češćeg korištenja višesnopnih dubinomjera (USACE, 2013). Ukoliko su sonde postavljene na pravilnim udaljenostima s obzirom na mjereno područje (URL 38), ovi sustavi nude 100 postotnu pokrivenost, no unatoč tome svoju primjenu najčešće pronalaze u lukama i užim područjima (de Jong i dr., 2002).



Slika 15. Vertikalni Sweep sustav

Izvor: USACE, 2013.

Broj sondi u *sweep* sustavu varira od tri do 32, ovisno o veličini broda na koji je ovaj sustav postavljen (USACE, 2013). *Sweep* sustavi svoju primjenu pronalaze u otkrivanju potencijalnih opasnosti koje se nalaze na morskom dnu za plovidbu u lukama, kanalima i rijekama, prilikom istraživanja ušća, močvara, praćenja procesa jaružanja, nakupljanja mulja i sl. (URL 7).

Dubinomjeri se osim na jednosnopne i višesnopne dijele i na:

1) Jednofrekventne i dvofrekventne (jedna ili dvije postavljene sonde različite frekvencije (Galloway i Collins, 1998))
2) Uskosnopne i širokosnopne (uskosnopni su dubinomjeri u primjeni ukoliko je cilj dobivanje podataka visoke rezolucije sa što manjim stupnjem pogreške)
3) Jednokanalne i višekanalne (višekanalni dubinomjeri u isto vrijeme odašilju različite frekvencije (Šiljeg i dr., 2017)).

3.1.3. Backscatter

Prilikom kartiranja morskoga dna koriste se sonarni sustavi koji omogućavaju dobivanje dva tipa informacija:

1) dubina (batimetrija)

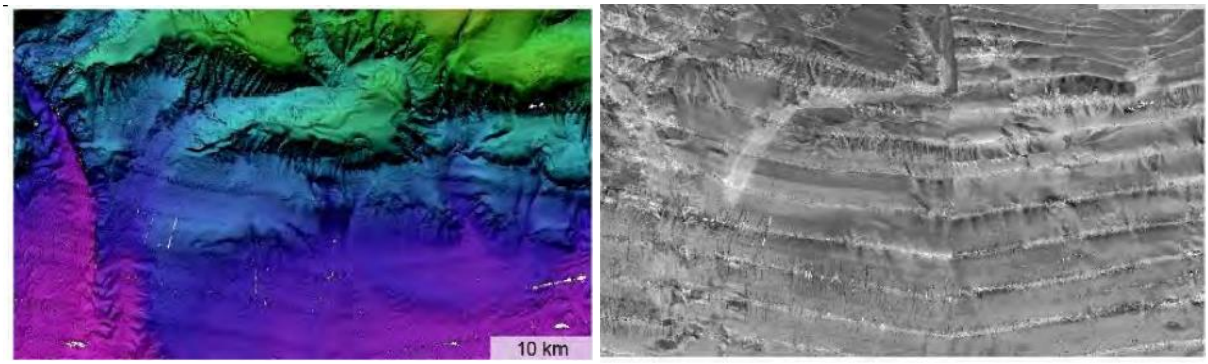
2) akustična refleksija morskog dna (energija povratnog signala koja ovisi o karakteristikama morskoga dna) (Lurton i dr., 2015).

Backscatter označava refleksiju zvučnog signala natrag prema mjestu odakle je on odaslan (Slika 16). Dakle, prilikom kartiranja morskog dna se, ukoliko su potrebni podaci o njegovoj tvrdoći, mjeri intenzitet vraćenog signala. Poznato je da će tvrđa dna (primjerice kamenito morsko dno) reflektirati jači signal od onog mekanijeg (npr. vegetacija, muljevito tlo, itd.) (URL 7). Također će grublje površine reflektirati jaču količinu zvučne energije od onih glađih (Lurton i dr., 2015). Na povratni zvučni signal, osim morfologije morskoga dna, utjecaj imaju i širina snopa te duljina putujućeg signala, odnosno dubina snimanja (Gavrilov i Parnum, 2010).

Dva su pristupa u obradi backscatter podataka:

1) računanje povratnog signala za svaki snop (odnosno jačine povratnog signala od morskoga dna);

2) izrada podataka panoramskog dubinomjera (*side-scan sonar*) lijevih *(port)* i desnih (*starboard)* snopova (Parnum i Gavrilov, 2011).



Slika 16. Usporedba batimetrijske i backscatter snimke istoga područja istraživanja

Izvor: Lurton i dr., 2015.

Ovakav tip snimaka svoju primjenu pronalazi u brojnim sferama kao što su hidrografija, industrija, geoznanosti itd. (Lurton i dr., 2015).

3.1.4 Daljinski upravljana ronilica (engl. *remotely operated vehicle*)

Daljinski upravljane ronilice (engl. ROV) su uređaji koji se uz pomoć propelera kreću kroz vodu (Slika 17). Njihovim se kretanjem upravlja od strane operatera pomoću kabla (engl. *tether*) s kojim su povezane, a obilježava ih relativno mala brzina gibanja te napajanje električnom energijom (Radionov Radenković i Mandžuka, 2007). Pojednostavljeno objašnjeno, kamera je u ROV-u smještena u vodootporno kućište, dok je sam ROV povezan kablom s kontrolorom putem kojeg prima naredbe i prenosi video signal (Christ i Wernli, 2007).



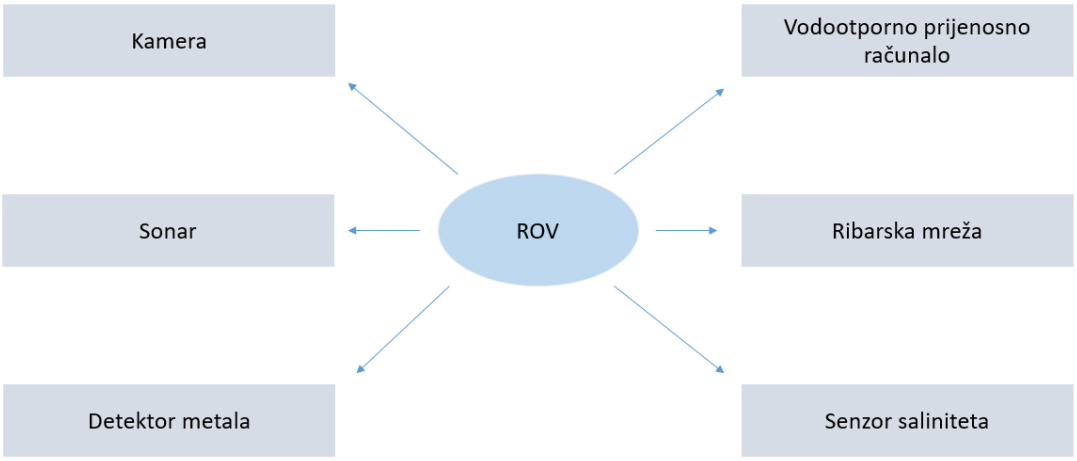
Slika 17. Osnovne sastavnice ROV sustava

Izvor: URL 39

Općenito se podvodni dronovi mogu podijeliti u dvije skupine:

1) ROV (engl. *remotely operated vehicles*), odnosno daljinski upravljane ronilice
2) AUV (engl. *autonomus underwater Vehicles*), odnosno autonomne ronilice (Matika i Liović, 2014).

Daljinski upravljane ronilice (ROV) su značajne jer mogu sadržavati razne senzore, kao što su ultrazvučni dubinomjer (de Jong i dr., 2002) te video kamere kojima prenose sliku korisniku, iako je važno naglasiti da se oprema razlikuje s obzirom na to koja je namjena same ronilice (Radionov Radenković i Mandžuka, 2007). Kamera, sonar, vodootporno prijenosno računalo, detektor metala, laser, robotska ruka, ribarska mreža, altimetar, spremnik za prikupljanje uzorka vode, tla, senzor saliniteta (Slika 18) samo su neki od alata koji se mogu integrirati na ROV (URL 40).



Slika 18. Prikaz određenih dodataka za ROV

Važno je istaknuti činjenicu da uvjeti snimanja pod vodom nisu uvijek idealni. Ponekad se maksimalna vidljivost kamere smanji zbog mutnoće vode. No, zbog sposobnosti integriranja raznih tehnologija na ronilicu (kao što je npr. sonar), određeno istraživanje i dalje može biti izvedivo. Naime, vidljivost pod vodom nema utjecaja na ovu tehnologiju koja slanjem i primanjem zvučnih signala dobiva prikaz morskoga dna pa stoga može značajno poslužiti u detekciji podvodne infrastrukture i drugim podvodnim industrijama (URL 41). Definiranje određenih objekata na morskome dnu ponekad može biti zahtjevno jer na fotografije dobivene podvodnom ronilicom utjecaj ima distorzija. Kao pomoć u razlikovanju oblika, veličine i materijala karakterističnog za određeni objekt pod vodom, može poslužiti integriranje višesnopnog dubinomjera (URL 42). Također jedna od bitnih komponenti koja se može instalirati na ROV je sonar 360, uređaj koji omogućuje dobivanje podataka u vidnom polju od 360°. Ova se karakteristika pokazuje vrlo korisnom pri identifikaciji objekata te izbjegavanju prepreka (URL 43).

S obzirom na činjenicu da se ROV pozicija ne može mjeriti na isti način kao i pozicija broda na kojem je instaliran višesnopni dubinomjer, točnu lokaciju ronilice stoga određuje USBL (engl. *ultra-short baseline acoustic positioning*) sustav. Poznavajući točnu poziciju broda i njegove kutne nagibe, zvučni se signali šalju prema ronilici, koja, nakon što primi zvučni signal s broda, također odašilje zvučni povratni signal (URL 44). USBL sustav, mjerenjem udaljenosti i smjera odaslanih signala određuje položaj ronilice, dok računalni senzor povezuje dobivene podatke s informacijama o smjeru, GPS senzorima i samom položaju broda (URL 45). Ova se metoda podvodnog akustičnog pozicioniranja ROV-a pokazala kao najjednostavnija i najefikasnija. Točnu je poziciju ronilice na još jednostavniji način moguće odrediti ukoliko ona ima jedan smjer kretanja (primjerice kroz tunel ili niz cijev). S obzirom

na to da je unaprijed poznata lokacija kroz koju se ronilica kreće, u odnosu na dužinu kabla koja je potrebna za izvođenje snimanja, može se izračunati točna pozicija ronilice. (URL 46). Tri su glavne skupine daljinski upravljanih ronilica (Christ i Wernli, 2007):

1) Promatračke daljinski upravljane ronilice (engl. *observation ROVs*)- ovakve su ronilice dizajnirane za nešto jednostavnije operacije (Christ i Wernli, 2007), a ujedno su i najmnogobrojnije i najrasprostranjenije (Radionov Radenković i Mandžuka, 2007; Matika i Liović, 2014). Duljine su raspona od 0,5 do 1 m, dok masa varira od nešto lakših (ispod 10kg) do težih (preko 100kg) (Radionov Radenković i Mandžuka, 2007).

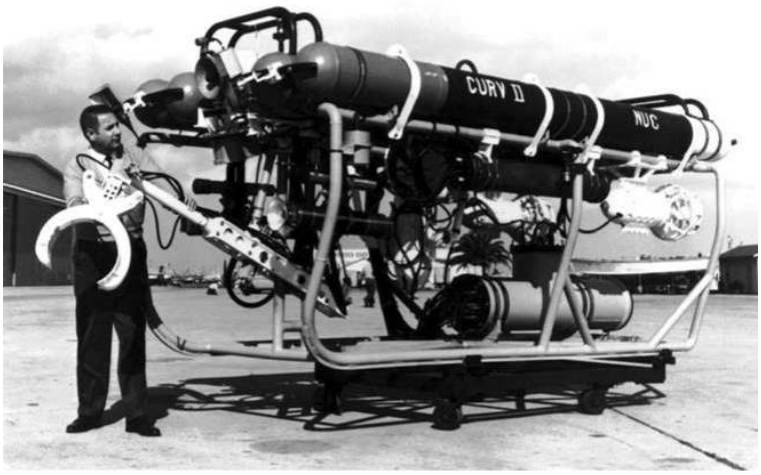
2) Radne daljinski upravljane ronilice (engl. *work ROVs*)- namijenjene su većim podvodnim građevinskim projektima (Christ i Wernli, 2007) te su ujedno i većih dimenzija od prethodnih (Matika i Liović, 2014). Na svom donjem dijelu sadrže dodatnu opremu potrebnu za izvođenje predviđenih zadataka (Radionov Radenković i Mandžuka, 2007).

3) ROV za specijalnu upotrebu (engl. *special-use ROVs*)- ronilice namijenjene za specijalnu upotrebu mogu se koristiti prilikom inspekcije, potrage (Radionov Radenković i Mandžuka, 2007), zatrpavanja telekomunikacijskih kablova (Christ i Wernli, 2007), i mnogih drugih podmorskih operacija.

Danas daljinski upravljane ronilice pronalaze primjenu u akvakulturi, znanstvenim istraživanjima (Christ i Wernli, 2007), nadzoru i postavljanju cjevovoda i kablova, raznim inspekcijama i ispitivanjima (Matika i Liović, 2014), potrazi i spašavanju (URL 8), proučavanju morskog otpada (Van Den Beld i dr., 2017) te mnogim drugima. Brojni su razlozi široke primjene ove tehnologije- sposobnost istraživanja određenog područja u stvarnom vremenu, praktičnost, sposobnost obavljanja raznih podvodnih zadataka što je čini jednom od najupotrebljivanijih alata podvodnih istraživanja (Klump i dr., 2001).

3.1.4.1. Povijesni razvoj ROV-a

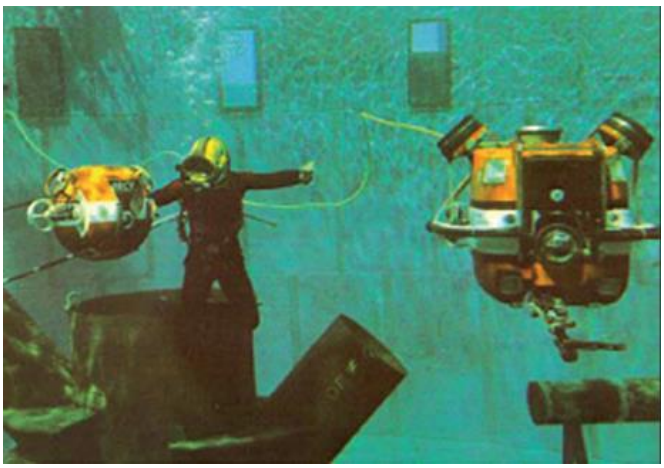
Prvu je daljinski upravljanu ronilicu, koja je služila za arheološke potrebe, izumio Dimitri Rebikoff 1953. godine pod nazivom *POODLE* (Christ i Wernli, 2007). Sedam godina kasnije, američka je mornarica razvila *CURV* (engl. *cable-controlled underwater recovery vehicle*) ronilicu (Slika 19) koja je poslužila u naftnoj industriji, kao i izvlačenju davno izgubljene nuklearne bombe (Matika i Liović, 2014).



Slika 19. CURV II ronilica američke mornarice

Izvor: Christ i Wernli, 2007.

Prva je daljinski upravljana ronilica (Slika 20), čija je primarna namjena bila komercijalna, bila *RCV-225* (engl. *remotely controlled vehicle*) od strane *Hydro Products*-a, a nakon nje, 70-ih godina 20. stoljeća započinje projektiranje i razvoj drugih koje su svoju primjenu pronalazile u raznim područjima. Desetak godina kasnije, napretkom podvodne tehnologije, počinje izrada ronilica manjih dimenzija (Matika i Liović, 2014).



Slika 20. Ronilice RCV 225 i RCV 150

Izvor: Matika i Liović, 2014.

Godine 1999. najprodavanija je ronilica bila *VideoRay*, teška 5 kilograma, proizvedena od istoimene tvrtke, prikazana na slici 21 (Matika i Liović, 2014).



Slika 21. VideoRay ROV

Izvor: Matika i Liović, 2014.

Napretkom su se tehnologije na ronilice počeli integrirati razni dodaci. Danas se, ovisno o svrsi istraživanja, koriste ronilice različite veličine (Slika 22, 23). Primjerice, za inspekciju se cjevovoda koriste ronilice većih dimenzija od onih koje služe za istraživanje plićih područja (Christ i Wernli, 2007). Brojne su tvrtke u svijetu koje se bave proizvodnjom ROV-ova: Mariscope, Ocean Modules, Saab Seaeye, Seamor Marine, Video Ray i brojne druge (URL 47).



Slika 22. RSL Workclass Seaker ROV

Izvor: URL 48



Slika 23. Commander MK II ROV

Izvor:URL 49

3.2 Morski otpad

Posljednjih je desetljeća zabilježena povećana količina morskog otpada na obalama, ali i na vodenoj površini te morskome dnu (Galgani i dr., 2015). Povećana proizvodnja plastike rezultira i povećanom količinom otpada koji, u velikoj većini slučajeva, na kraju završi u morima i oceanima (Rochman, 2015) te ima vidljivi utjecaj i na morske organizme (Kühn i dr., 2015). Gdje će se on akumulirati ovisi o više faktora- velikim gradovima uz obalu,

aktivnostima na moru i obali itd. (Galgani i dr., 2015). Važno je naglasiti kako se i pojačane aktivnosti tijekom turističke sezone negativno odražavaju na količinu morskog otpada; ponajviše plastike, aluminija i stakla (Galgani i dr., 2015). Navedene aktivnosti na obali, zajedno s razvijenom industrijom i ribarstvom te neadekvatno zbrinjavanje otpada u pojedinim mediteranskim državama, rezultirale su činjenicom da je ono danas pod velikim utjecajem morskog otpada (Cincinelli i dr., 2018). Morski se otpad prema lokaciji pronalaska dijeli na:

1) površinski morski otad;
2) morski otpad u vodenom stupcu;
3) morski otpad na morskom dnu.

Važno je istaknuti njegovo akumuliranje i na obalama (Plan gospodarenja morskim otpadom, 2020; URL 9) jer tamošnji otpad također može završiti u moru valovima i vjetrom (Andrady, 2011).

Najveći dio morskog otpada zauzima plastika (Galgani i dr., 2019; Galgani i dr., 2015; Andrady, 2015; Kühn i dr., 2015; Derraik, 2002; Cincinelli i dr., 2019; Pham i dr., 2014), koja je prisutna čak i u najudaljenijim dijelovima svijeta zbog svoje male gustoće koja joj omogućuje laku pokretljivost vodom i vjetrom. Obilježava je velika izdržljivost zbog koje ostaje u okolišu dugi niz godina, predstavljajući opasnost za morski okoliš (Ryan, 2015; Andrady, 2015; Derraik, 2002). Nakon nekog se vremena, nizom raznih procesa, ona raspada na manje fragmente te se, u ovisnosti o njenoj veličini, može podijeliti na makroplastiku (≥1 cm), mezoplastiku (≥5 mm to 1 cm), mikroplastiku (≤5 mm) i nanoplastiku (≤100 μm) (Cincinelli i dr., 2019).

Gustoća se morskog otpada može odrediti kao ukupan broj komada morskog otpada pronađenog na jedinici površine od jednog kvadratnog metra i mase pronađenog otpada na istoj površini izražene u kilogramima (Terzi i dr., 2020; Pham i dr., 2014). Jedinica se površine prilikom izračunavanja gustoće morskog otpada može povećati i na $100m^2$ (Gvozdenović i dr., 2021; Consoli i dr., 2018), ovisno o području istraživanja. U nekim se dijelovima svijeta čistoća plaže izražava prema količini pronađene plastike. Tako je u Izraelu uspostavljen *Clean Coast Indeks* (URL 10) prema kojemu se plaže dijele na:

1) Jako čisto: manje od 2 komada plastike pronađena na području
2) Čisto: 2-5 komada plastike pronađena na području
3) Prosječno: 5-10 komada plastike pronađena na području
4) Prljavo: 10-20 komada plastike pronađena na području

5) Jako prljavo: Više od 20 komada plastike pronađena na području

3.2.1 Morski otpad u Jadranskom moru

Jadransko more je sa svojom ukupnom površinom od 138 595 km² i prosječnom dubinom od 173 m od velikog strateškog značenja za Republiku Hrvatsku (URL 11). Uslijed brojnih aktivnosti (npr. turizam, uzgoj ribe, eksploatacija ugljikovodika, itd.) Jadransko more je danas zahvaćeno problemom morskog otpada (URL 12). Ono se, odmah iza sjeveroistoka Sredozemlja i Keltskog mora, nalazi na popisu najonečišćenijih mora u Europi, misleći pritom na zastupljenost i količinu plastičnog otpada (Bule i dr., 2020). Čak 80% ukupnog morskog otpada zauzimaju kopneni, tj. obalni izvori (Kwokal i Štefanović, 2009) kao što su turizam, kanalizacija, nekontrolirana odlagališta (URL 13), industrije smještene u priobalju (Bule i dr., 2020), otpad dospio u more putem rijeka (Kwokal i Štefanović, 2009), dok preostalih 20% otpada zauzimaju morski izvori (ribarstvo, marikultura, turizam,…) (URL 13).

Projektom je DeFishGear (engl. *Derelict Fishing Gear Management System in the Adriatic Region*) u razdoblju od 2013. do 2016. godine započelo kontinuirano praćenje morskog otpada hrvatske obale Jadranskog mora (Plan gospodarenja morskim otpadom, 2020). Ciljevi su ovog projekta obuhvaćali unaprjeđenje znanja vezanih uz morski otpad s imperativom na što lakše rješavanje navedenog problema, prevenciju i ublažavanje problema morskog otpada Jadransko-Jonske makroregije, provedbu koordiniranih akcija i mjera za more bez otpada (URL 14). Ovim je projektom na području hrvatske obale utvrđena zastupljenost plastike (92%) (Plan gospodarenja morskim otpadom), što potvrđuje prethodno navedenu činjenicu da upravo ona zauzima najveći dio morskog otpada.

4. METODOLOGIJA ISTRAŽIVANJA

Metodologija se istraživanja može podijeliti u šest glavnih koraka koji su uključivali sljedeće aktivnosti:

- UAV fotogrametrija šireg područja istraživanja;
- 3D skeniranje automobilske gume primjenom ručnog 3D skenera;
- MBES snimanje odabrane testne plohe
- ROV snimanje odabrane testne plohe
- Detekcija i kvantifikacija morskog otpada
- Usporedba generiranih rezultata

4.1 UAV fotogrametrija šireg područja

UAV fotogrametrija šireg područja testne plohe izvršena je 16. svibnja 2022. godine. Uključivala je snimanje definirane testne plohe na moru (400 m²) na kojoj je provedeno batimetrijsko istraživanje. Testna ploha označena je bovama te je zajedno s okolnim područjem imala ukupnu površinu 7,6 ha. Snimanje je obavljeno koristeći bespilotnu letjelicu *Phantom 4 Pro V2.0* (Slika 24). U Tablici 1 navedene su najbitnije specifikacije UAV-a *Phantom 4 ProV2.0*. Svrha snimanja bespilotnom letjelicom je kreiranje digitalnog ortofota (DOF-a) i digitalnog modela površina (DSM) koji su poslužili za vizualizaciju šireg područja Martinske te vizualizaciju testne plohe na moru.



Slika 24. Snimanje istraživanog područja bespilotnom letjelicom Phantom 4 Pro

Tablica 1. Specifikacije UAV-a Phantom 4 Pro

Model	**Phantom 4 Pro V2.0**
Težina (uključujući bateriju i propelere)	1375 g
Maksimalna brzina	S-mod: 45 mph (72 km/h) A-mod: 36 mph (58 km/hh) P-mod: 31 mph (50 km/h)
Maksimalna kutna brzina	S-mod: 250°/s A-mod: 150°/s
Maksimalna visina iznad morske razine	19685 ft (6000 m)
Maksimalna otpornost na brzinu vjetra	10 m/s
Maksimalno vrijeme leta	≈ 30 minuta
Radna temperatura	od 0° do 40°C
Satelitski sustavi pozicioniranja	GPS/GLONASS
Raspon točnosti leta	Vertikalni: ±0.1 m (s vizualnim pozicioniranjem) ±0.5 (s GPS pozicioniranjem) Horizontalni: ±0.3 m (s vizualnim pozicioniranjem) ±1.5 m (s GPS pozicioniranjem)
Visiony System	
FOV	Naprijed: 60° (Horizontalno), ±27° (Vertikalno) Natrag: 60° (Horizontalno), ±27° (Vertikalno) Dolje: 70° (Ispred i iza), 50° (Lijevo i desno)
Kamera	
Senzor	1″ CMOS Efektivni pikseli: 20M
Objektiv	FOV 84° 8.8 mm/24 mm (35 mm format ekvivalent) f/2.8-f/11 auto fokus na 1 m-∞
Mehanički *Shutter speed*	8-1/2000 s
Elektronski *Shutter speed*	8-1/8000 s
Veličina fotografije	3:2 Format prikaza: 5472×3648 4:3 Format prikaza: 4864×3648 16:9 Format prikaza: 5472×3078

Izvor: (URL 15)

4.1.1. Prikupljanje orijentacijskih (GCP) točaka

Označavanje i prikupljanje orijentacijskih točaka (engl. *ground control points* - GCP) prvi je korak aerofotogrametrijskog istraživanja, a izvodi se s ciljem dobivanja modela što bolje apsolutne i relativne orijentacije rekonstruiranog modela. Svaka točka prikupljena na terenu ima svoju X, Y i Z lokaciju u odabranom koordinatnom sustavu. Orijentacijske točke su prikupljene pomoću *Trimble R12i GNSS* prijemnika (Tablica 3). Uz njih, prikupljen je i podatak o trenutnoj visini vodostaja. *Trimble R12i GNSS* (Slika 25) prijemnik obilježava 672 kanala, integrirana GNSS antena i spajanje na sedam sustava (GPS, GLONASS, Galileo,

BeiDou, NavIC, QZSS i SBAS) (URL 16). Osnovne specifikacije navedenog sustava su prikazane u Tablici 2.



Slika 25. Trimble R12i GNSS i Trimble TDC600 upravljač

Izvor: URL 16

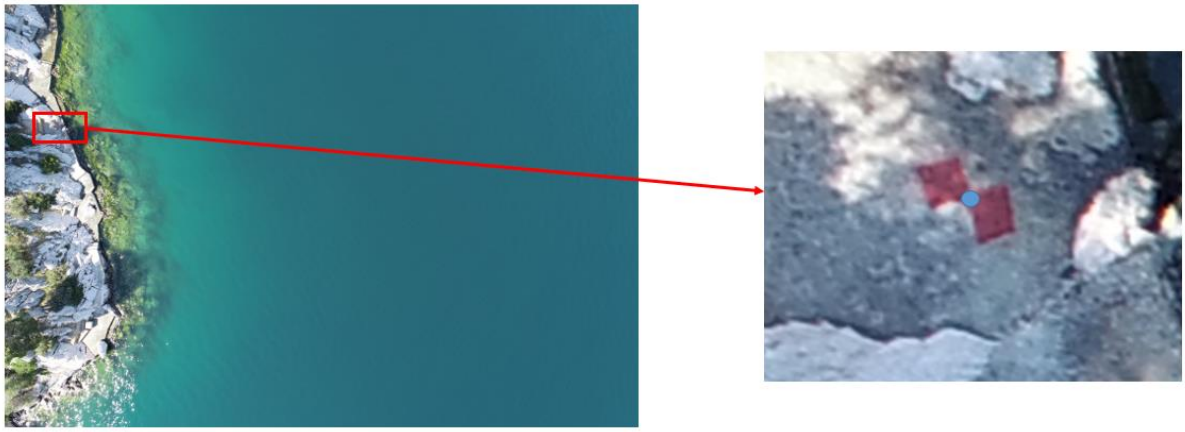
Tablica 2. Specifikacije Trimble R12i GNSS prijemnika

Model	**Trimble R12i**
Maksimalna preciznost	8 mm H/15 mm V
Kanali	672
Antena	Integrirana
UHF Radio	Receive & Transmit
Kompatibilnost s RTK	Da
xFill	Da
Memorija	6GB
Cellular	Da
Sateliti	GPS, GLONASS, Galileo, BeiDou, NavIC, QZSS, SBAS
Dodatne karakteristike	ProPoint, TIP Tilt Compensation

Izvor: URL 16

Tablica 3. Koordinate prikupljenih orijentacijskih točaka

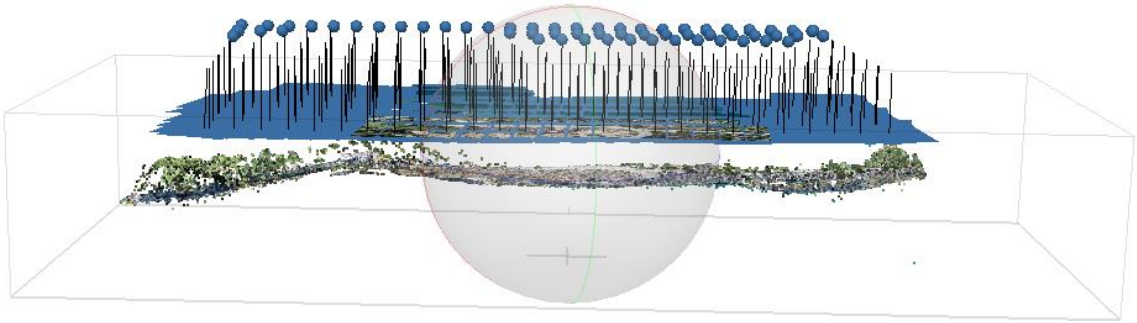
FID	Naziv	X	Y	Z
1	OT1	4844207,713	449805,6115	0,78224
2	OT2	4844238,649	449809,7389	0,58304
3	OT3	4844191,754	449764,067	0,42329
4	OT4	4844184,526	449759,1408	0,34915
5	OT5	4844150,627	449747,631	0,61045
6	OT6	4844109,05	449748,2258	0,23627
7	OT7	4844085,198	449745,7814	0,62702
8	OT8	4844167,337	449724,7944	12,91127
9	OT9	4844133,391	449715,8041	14,61392
10	OT10	4844236,133	449779,6246	5,66552



Slika 26. Primjer označene orijentacijske točke na terenu

4.1.3 Obrada UAV snimaka

UAV snimanjem ukupno su prikupljene 224 fotografije. *Agisoft Metashape 1.5.1.* je korišten za obradu zračnih snimaka i generiranje digitalnog modela površina. Pomoću automatske procjene kvalitete fotografija (engl. *image quality*) uklonjene su zamućene fotografije zato što mogu imati negativan utjecaj na izlazne rezultate. Sljedeći korak obrade se odnosio na povezivanje, odnosno spajanje preklapajućih snimaka (engl. *align photos*) te označavanje orijentacijskih točaka na rekonstruiranom modelu rijetkog oblaka točaka. Ovim korakom rješava se problem relativne orijentacije kamera, procjenjuju se unutarnji kalibracijski parametri (samokalibracija) te se izvodi rijetki oblak točaka koji podrazumijeva podudarajuće piksele na fotografijama koje se preklapaju. Ovim korakom izvedeno je 185 745 veznih točaka. Dio točaka je alatima postupne selekcije (engl. *gradual selection*) izbrisan čime je unaprijeđena relativna točnost rekonstruiranog modela. Time su unutarnji parametri kamere naknadno ažurirani, odnosno procijenjeni.



Slika 27. Izvedeni oblak točaka i procjenjene lokacije kamera nakon povezivanja fotografija

Nakon dodvanja orijentacijskih točaka, u završnom koraku aerofotogrametrijske obrade kreiran je gusti oblak točaka (Slika 27). Iz njega su potom izvedeni digitalni ortofoto snimak (DOF) i digitalni model površina (DSM). Na DOF-u je poligonom označen prostor unutar kojeg je izvedeno snimanje podvodnim dronom i višesnopnim dubinomjerom (Slika 2).

4.2. 3D skeniranje ručnim skenerom

Prije izvođenja snimanja označene testne plohe podvodnim dronom (ROV) i višesnopnim dubinomjerom (MBES) izvedeno je 3D skeniranje ručnim skenerom odabranog otpada (automobilska guma) koji je pronađen u neposrednoj blizini obale (Slika 28). Svrha ovog skeniranja utvrđivanje je relativne točnosti navedenih senzora. Ispitivanje relativne točnosti se će izvesti na temelju morfometrijskih parametara modela gume izvedenih s ROV-om i MBES-om i ručnim 3D skenerom. Naravno, usporedba morfometrijskih parametara sva tri senzora će biti moguća u slučaju da MBES uspije detektirati otpad na dnu mora. U tom slučaju model izveden s ručnim 3D skenerom *Artec Eva* služio bi kao referentni podatak. S točnošću do 0.1 mm (Tablica 4) predstavlja izvrstan senzor za snimanje objekata srednje-male veličine (minimalna veličina objekta 10 cm) (URL 17).

Tablica 4. Specifikacije 3D ručnog skenera Artec Eva

Model	**Artec Eva**
3D točnost	do 0.1 mm
3D rezolucija	do 0.2 mm
Minimalna veličina snimanog objekta	10 cm
Skeniranje u boji	Da
3D vrijeme ekspozicije	0.0002 s
Stopa 3D rekonstrukcije	16 FPS
Izlazni formati	Svi popularni, uključujući ST, OBJ i PLY
Težina	0.9 kg
Udaljenost prilikom snimanja	0.4 do 1 m
Mogućnost izvođenja teksture	Da

Izvor: URL 17



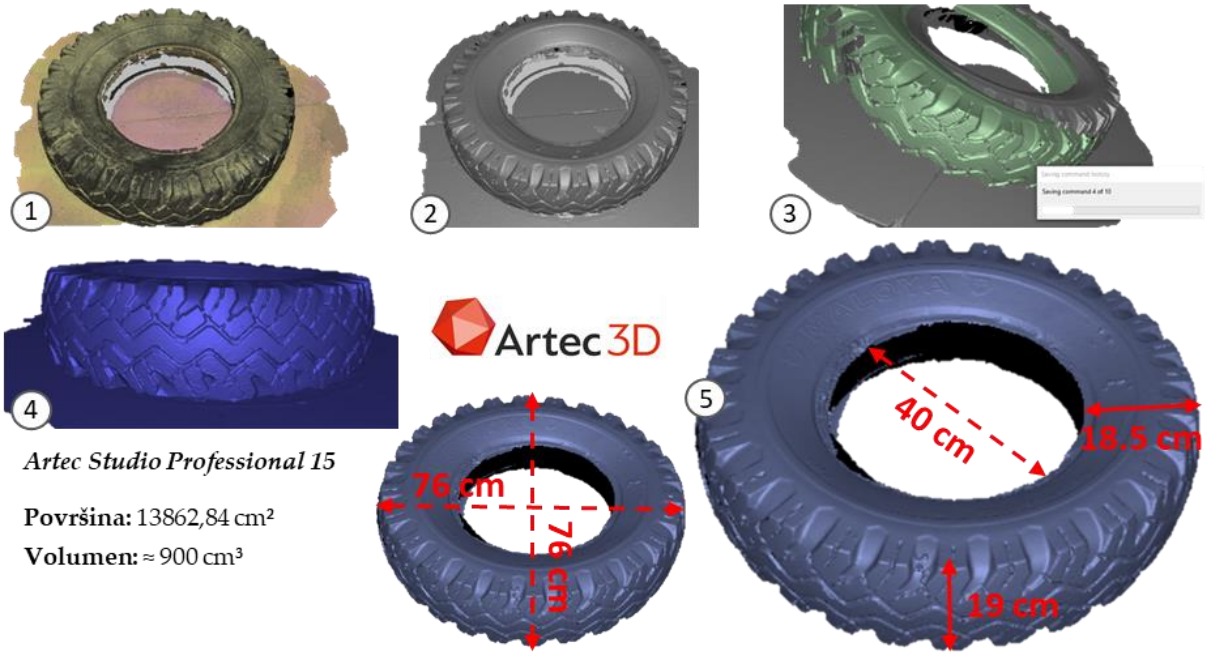
Slika 28. Proces 3D skeniranja

Prilikom skeniranja potrebno je obratiti pažnju na postolje gdje se snimani predmeti nalaze (podloga u cijelosti treba biti veća od snimanog objekta s ciljem kontinuiranog 3D skeniranja cijelog objekta, bez naglih prekidanja u području nedostatka podloge), dok je za sami predmet koji se skenira važno da ne bude proziran, sjajan i vlažan. Prilikom skeniranja je prikupljeno nekoliko 3D skenova koji su potom obrađeni u programu *Artec Studio Professional 15* kroz pet koraka:

1) *Global registration* - pomoću veznih točaka na prikupljenim 3D skenovima izvršena je registracija (uklapanje) skenova koji su potom smješteni u isti koordinatni sustav.
2) *Crop surrondings* - odnosi se na uklanjanje svih podataka snimljenog okolnog područja koristeći alat *rectangular selection* koji nisu bili potrebni za izvođenje morfometrijskih analiza.
3) *Outliner removal* - uključuje uklanjanje svih netočnih podataka (manjih poligona) koji mogu imati utjecaj na izlazne rezultate, a generirani su prilikom globalne registracije.
4) *Sharp fusion* - generira prvobitni površinski 3D model objekta sa sačuvanim površinskim detaljima.

5) *Apply texture*- uključuje integriranje teksture na skenirani model.

Iz izvedenog 3D modela koristeći set alata iz opcije *Measure* generirani su jednostavni morfometrijski parametri skenirane gume (Slika 29). Nakon snimanja automobilska guma je postavljena na morsko dno unutar odabrane testne plohe kako bi je poslije mogao snimiti MBES sustav i podvodna bespilotna ronilica. Po završetku snimanja automobilska guma je izvađena iz mora.



Slika 29. Proces obrade automobilske gume snimljene ručnim 3D skenerom Artec Eva

4.3. MBES izmjera testne plohe

Batimetrijsko je istraživanje provedeno 16. svibnja 2022. godine, a njime je obuhvaćeno kartiranje morskog otpada područja testne plohe 20 x 20 metara (Slika 30). Navedeni prostor je intervalno snimljen osam puta. Snimanja su se razlikovala po brzini plovidbe i smjeru snimanja u odnosu na definiranu plogu (Slika 30). Testiranje preciznosti MBES snimanja primjenom M3C2 alata izvršeno je za prvih 6 MBES snimanja izvedenih u smjerovima SI - JZ, JI -SZ te pri brzinama od 1,5, 3 i 4,5 čvorova. Cilj ovakvog načina intervalnog snimanja je bio utvrditi pouzdanost MBES-a u kontekstu izvođenja batimetrije. Osam scenarija MBES snimanja je izvedeno, a oni uključuju:

A) Brzina 1,5 čvor (2.78 km/h) smjer SI - JZ sa S dijela plohe

B) Brzina 1,5 čvor (2.78 km/h) smjer JI - SZ kretanje sa S dijela plohe

C) Brzina 4,5 čvora (8,33 km7h) smjer SI - JZ sa S dijela plohe

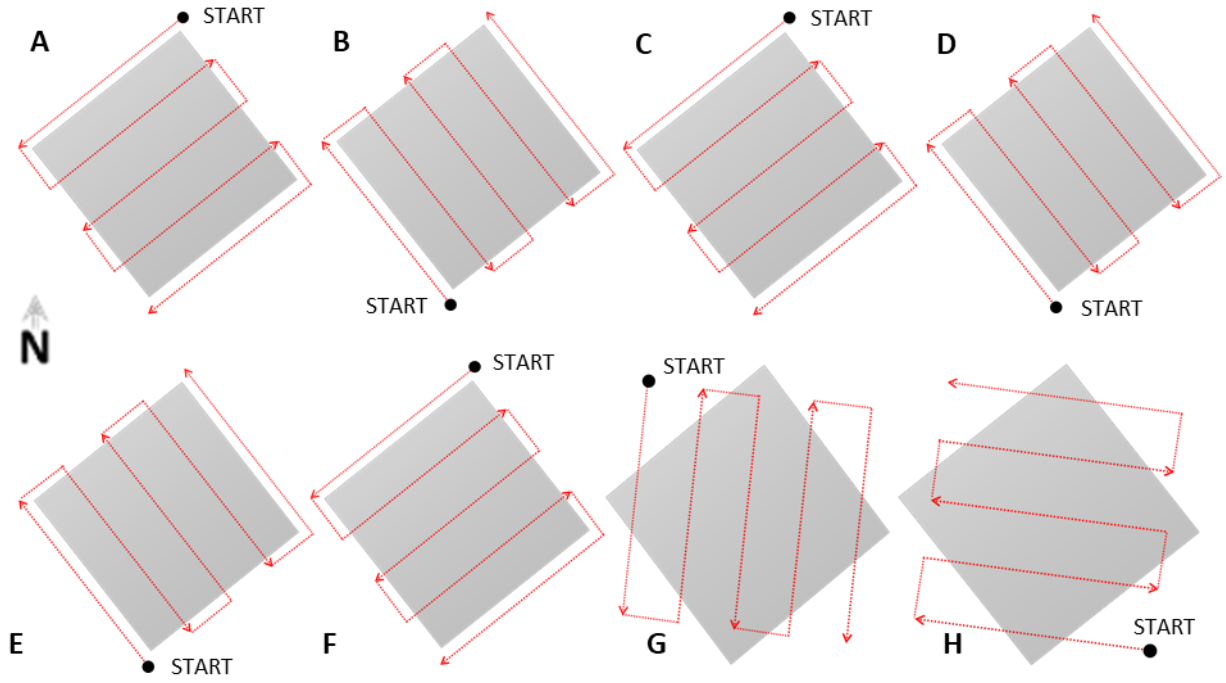
D) Brzina 4,5 čvora (8,33 km/h) smjer JI - SZ kretanje sa J dijela plohe

E) Brzina 3 čvora (5.55 km/h) smjer JI - SZ kretanje sa J dijela plohe

F) Brzina 3 čvora (5.55 km/h) smjer SI - JZ kretanje sa S dijela plohe

G) Brzina 3 čvora (5.55 km/h) smjer S - J kretanje sa S dijela plohe

H) Brzina 3 čvora (5.55 km/h) smjer I - Z sa J dijela plohe



Slika 30. Izvedeni scenariji MBES snimanja odabrane testne plohe

Sve su komponente višesnopnog dubinomjera instalirane na gumenjak *Luna*, koji se u više navrata pokazao učinkovitim u ovakvim istraživanjima zbog lake instalacije potrebnih komponenti na njega, ali i svoje relativno male duljine (oko 2,5m) (Slika 31).



Slika 31. Gumenjak Luna s instaliranim integralnim mjernim sustavom

Prije samog je batimetrijskog istraživanja važno napraviti plan batimetrijske izmjere, a on uključuje sedam koraka:

1) Određivanje područja izmjere
2) Definiranje svrhe izmjere
3) Uporaba metoda batimetrijskog istraživanja (točnost, oprema, referentni vertikalni i horizontalni geodetski sustav)
4) Određivanje kraćeg ili dužeg vremenskog roka izmjere
5) Prikupljanje sekundarnih parametara (salinitet, temperatura, zračne snimke, vodostaj)
6) Analiziranje ograničavajućih podataka (logistika, proračun, nepristupačan teren…)
7) Obrada prikupljenih podataka (Šiljeg i dr., 2017).

4.3.1 Prikupljanje batimetrijskih podataka

Šest je glavnih komponenti integralnog mjernog sustava kojim je izvršena batimetrijska izmjera:

1) *WASSP S3 Multibeam Wideband Sounder c/w DRX*
2) *WASSP Sensor Box* s integriranim *Spatial IMU*
3) *Hemisphere V320 GNSS Smart Antenna* (mFreq, mGNSS, RTK, SBAS)
4) akumulator i kabel za napajanje
5) konfiguracijsko računalo i kabel
6) softveri za konfiguraciju (*PoketMax, NtripClient, DRX Setup Webpages*)
7) softveri za navođenje (*CDX*) i eksportiranje podataka (*Data Manager*).

WASSP (engl. *Wide Angle Sonar Seafloor Profiler*) *S3* višesnopni je dubinomjer S (engl. *survey*) generacije jedan od najprofesionalnijih i najisplativijih višesnopnih dubinomjera, koji skraćuje vrijeme batimetrijske izmjere za deset puta u odnosu na jednosnopni dubinomjer (URL 18). *WASSP S3* (Slika 32) koristi 224 snopa raspona od 4 do 120 stupnjeva. Njegova maksimalna vertikalna rezolucija iznosi 2 cm, čime se smatra jednim od učinkovitijih instrumenata za batimetrijsku izmjeru onih područja velike vertikalne raščlanjenosti terena do 400 m dubine (URL 19). Preostale specifikacije *WASSP S3* višesnopnog dubinomjera prikazane su u Tablici 5.



Slika 32. WASSP S3 višesnopni dubinomjer

Izvor: URL 19

Tablica 5. Specifikacije WASSP S3 višesnopnog dubinomjera

Model	**S3**
Frekvencija	160 kHz (WideBand Variable)
Tip sonde	DRX-32
Podržana sonda	WMB - 160
IMU	Vanjski
Dubina - *swath*	200 m
Maksimalna dubina	400 m
Efektivna širina snopa	120º x 4º
Širina snopa PS	4º
Širina snopa FA	3º
Nominalni razmak snopova	0.54º - 120º (224 snopa)
Maksimalna vertikalna rezolucija	2 cm
Povezanost senzora	DRX
PSU	9-32VDC (30W)
Sučelje	RS232/422/NMEAO183
Batimetrija 2D / 3D	Da
Sonar polar view	Da
Sounder (quint beam)	Ne

Izvor: URL 19

Sonda (engl. *transducer*) je uređaj koji pretvara elektronski impuls u zvučni te ga šalje prema morskome dnu, a pričvršćena je za čeličnu motku i uronjena u vodu (de Jong i dr., 2002). Na temelju vremenskog zaostajanja zvučnoga vala mjeri se dubina morskoga dna. Za potrebe batimetrijske izmjere na Martinskoj, korištena je sonda *WMB-160*, koju karakterizira operativna frekvencija od 160 kHz. Primjena vrlo niskih frekvencija (90 kHz ili 100 kHz) omogućuje istraživanje velikih dubina (nekoliko stotina metara), dok snimanja na vrlo visokim frekvencijama (npr. 700 kHz) omogućuju prikupljanje podataka ultra visoke rezolucije zahvaljujući većoj akustičnoj rezoluciji (vertikalna rezolucija) i manjoj širini snopa (engl. *bandwith*) (horizontalna rezolucija). Sonda *WMB-160* je pričvršćena za čeličnu motku s ciljem što manjeg utjecaja na izlazne rezultate, s obzirom da se ovako pričvršćena i postavljena što

dalje od pente (koji utječe na izlazne rezultate ukoliko njene turbulencije utječu na sondu) prilikom batimetrijskog istraživanja ne pomiče (Slika 33). S obzirom na to da je uronjena u vodu (50 cm), važno je naglasiti kako je vertikalna razlika između sonde i vodene površine uzeta u obzir prilikom izmjere. S ciljem postizanja najkraćeg puta odaslanog zvučnog signala i njegovog točnog georeferenciranja pomoću antene postavljene točno iznad sonde, ona je orijentirana pod kutem od 90º.



Slika 33. (A) Sonda WMB-160; (B) Hemisphere V320 GNSS Smart Antenna

Izvor: URL 19, URL 20

Hemisphere V320 (Slika 33) je antena korištena u batimetrijskoj izmjeri s ciljem RTK preciznog pozicioniranja. Nakon što na vidljivom nebu pronađe četiri ili više GNSS satelita koji odašilju informacije određene frekvencije, na osnovu vremena koje je potrebno da signal stigne od satelita do antene, ona daje informacije o X, Y i Z koordinati te smjeru kretanja (URL 20). U tablici 6 navedene su detaljne specifikacije GNSS senzora koji je integriran u *Hemisphere V320* antenu.

Tablica 6. Specifikacije GNSS senzora

Model	**V320**
Reciever type	Vector GNSS RTK Reciever
Channels	744
Update rate	10 Hz standard, 20 Hz available by activation
Position accuracy	RMS (67%): Horizontal Vertical
	Single point: 1.2m 2.5m
	SBAS (WAAS): 0.3m 0.6m
	L-Band: 0.1m 0.2m
	RTK: 10mm+1ppm 20mm+ppm
Heading accuracy (RMS)	<0.17º
	Normal operation: GNSS
	Coasting (no GNSS): Gyro
Heave accuracy (RMS)	<30cm (DGNSS)
	<10cm (RTK)
	Normal operation: GNSS

	Coasting (no GNSS): None
Pitch accuracy	<1º RMS
	Normal operation: GNSS
	Coasting (no GNSS): Inertial sensor
Roll accuracy	<1º RMS using accelerometer
	Normal operation: Inertial sensor
	Coasting (no GNSS): Inertial sensor
Rate of turn	100º/s maximum
Maximum speed	1,850kph (999kts)
Maximum altitude	18,288m (60, 000ft)

Izvor: URL 20

Prilikom izvođenja svih osam scenarija MBES batimetrijske izmjere testne plohe more je bilo u idealnim uvjetima. Valovi su bili gotovo nezamjetne veličine (Slika 34).



Slika 34. Uvjeti na moru prilikom izvođenja MBES snimanja

Unatoč gotovo idealnim uvjetima na moru, gumenjak su u svakom trenutku nalazi u pokretu po X, Y i Z osi, što, ako nije primjereno registrirano, može utjecati na izlazne rezultate. Stoga veliku važnost pri batimetrijskoj izmjeri ima korišteni inercijalni mjerni sustav (IMU), koji registrira svaki pokret broda po X, Y i Z osi.

Advanced Navigation Spatial IMU WSP002-INU navigacijski je sustav koji, u kombinaciji s *Hemisphere V320 GNSS* antenom omogućuje dobivanje podataka o brzini, lokaciji, ubrzanju i orijentaciji prilikom batimetrijske izmjere (Slika 35). Nalazi se u senzornoj kutiji, a sadrži inertni navigacijski sustav GPS-a te AHRS-a (engl. *attitude and heading reference system*). Korišteni INU sustav karakterizira visoka osjetljivost na kretanja po različitim osima, stoga daje podatke o kutnom nagibu i smjeru kretanja broda neovisno o njegovoj veličini (URL 22).



Slika 35. Advanced Navigation Spatial IMU WSP002-INU

Izvor: URL 22

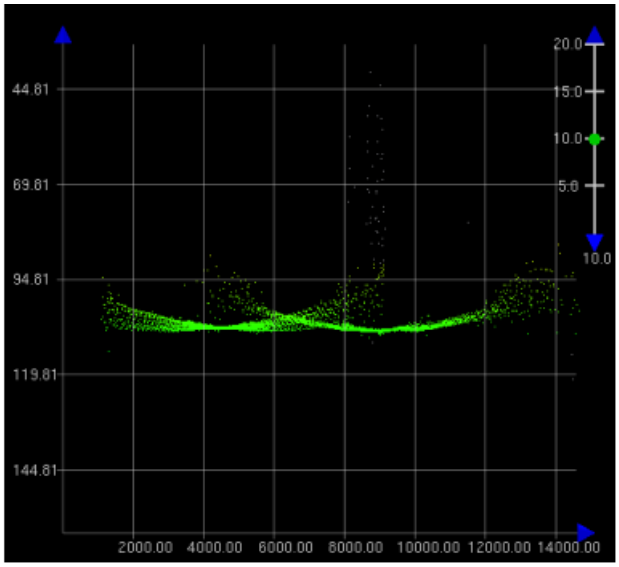
Tri su glavna tipa senzora pokreta:

1) akcelerometar – mjeri promjenu brzine
2) žiroskop – mjeri kutne pomake po x, y i z osi
3) magnetometar – uz pomoć magnetnog polja, akcelerometra i žiroskopa mjeri smjer kretanja (URL 21)

Prije same batimetrijske je izmjere potrebno prikupljanje sekundarnih podataka s ciljem točne kalibracije sustava. Zvučni se val iz sonde, nakon pretvorbe iz elektronskog, odašilje prema morskome dnu i s obzirom na njegovo vremensko zaostajanje u sustavu se za snimanje dobivaju podaci o dubini morskog dna (Šiljeg i dr., 2017). Na brzinu zvuka u vodi utjecaj imaju temperatura, salinitet te tlak zraka. Stoga je važno prikupiti navedene parametre s ciljem izbjegavanja refrakcije- neispravne brzine zvuka koja se, ako do nje dođe, naknadno mora ispravljati.

Brzina zvuka (engl. *sound velocity* - SV) izvedena je iz izravnih podataka o temperaturi morske vode (◦C) i salinitetu (ppt). Podaci o temperaturi i salinitetu morske vode izmjereni su pomoću EXO2 višeparametarske sonde. SV parametar ključan je u anuliranju netočnosti raspona mjerenja uzrokovanih varijacijama brzine zvuka u vodi. Smatra se jednim od ključnih čimbenika koji mogu utjecati na kvalitetu MBES podataka. Nadalje, izvedeni SV je provjeren vizualnom sastavnicom na CDX sučelju iznad ravnog morskog dna. Naime, vizualni efekt netočnog SV očituje se konkavnom ili konveksnom zakrivljenošću ravnog morskog dna. Ovisno o lokaciji, SV je redovito podešen i ručno provjeravan pomoću zvučnog zaslona. Područje je istraživanja u trenutku snimanja obilježavala temperatura vode od 17°C te salinitet 33 ‰, čime je izračunata brzina zvuka u vodi koja je iznosila 1510,54 m/s. Promjene

temperature i saliniteta u stupcu vode mogu utjecati na promjenu brzine zvučnoga vala što kao posljedicu može imati distorziju morskoga dna (Slika 36) u konkavnom ili konveksnom obliku (ako je brzina zvuka na morskoj površini manja od zvuka u dubljim dijelovima, doći će do konkavne distorzije) (Jin i dr., 2015).



Slika 36. Primjer distorzije terena uzrokovan refrakcijom

Izvor: Jin i dr., 2015.

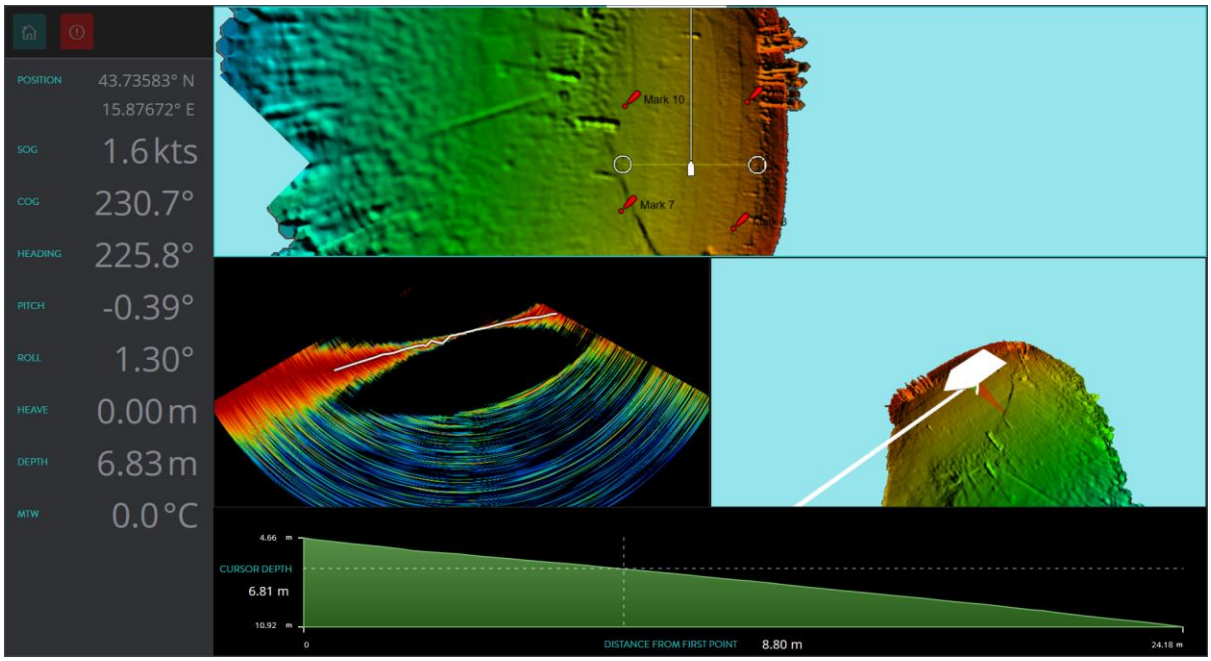
4.3.2 Obrada batimetrijskih podataka

CDX napredni je softver koji omogućuje vizualizaciju, kontrolu i upravljanje prikupljenim podacima u visokoj rezoluciji. Uz pomoć naprednog algoritma ovaj softver omogućuje prikaz morskoga dna bez grubih prijelaza između više batimetrijskih snimaka, s ciljem dobivanja kontinuirane površine. Važnost ove karakteristike posebice dolazi do izražaja u područjima koje obilježavaju riplovi i pomicanje morskoga dna uslijed jakih valova i struja. Ukupno je šest komponenti koje čine aplikaciju CDX:

1) *Home* pristup – služi za konfiguraciju zaslona, alate, definiranje korisničkih parametara…
2) Okviri zaslona – povezani posebnim kategorijama podataka koji služe za kontrolu i vizualizaciju
3) CS (engl. *context sensitive*) izbornik – desnim klikom omogućuje laku konfiguraciju posebnih ploča za prikaz
4) Zaslon s informacijama – omogućuje preklapanje podataka na ploči zaslona s *context sensitive* izbornikom
5) Alati za kontrolu – služe za upravljanje preklapanjem upravljačke ploče na zaslonu

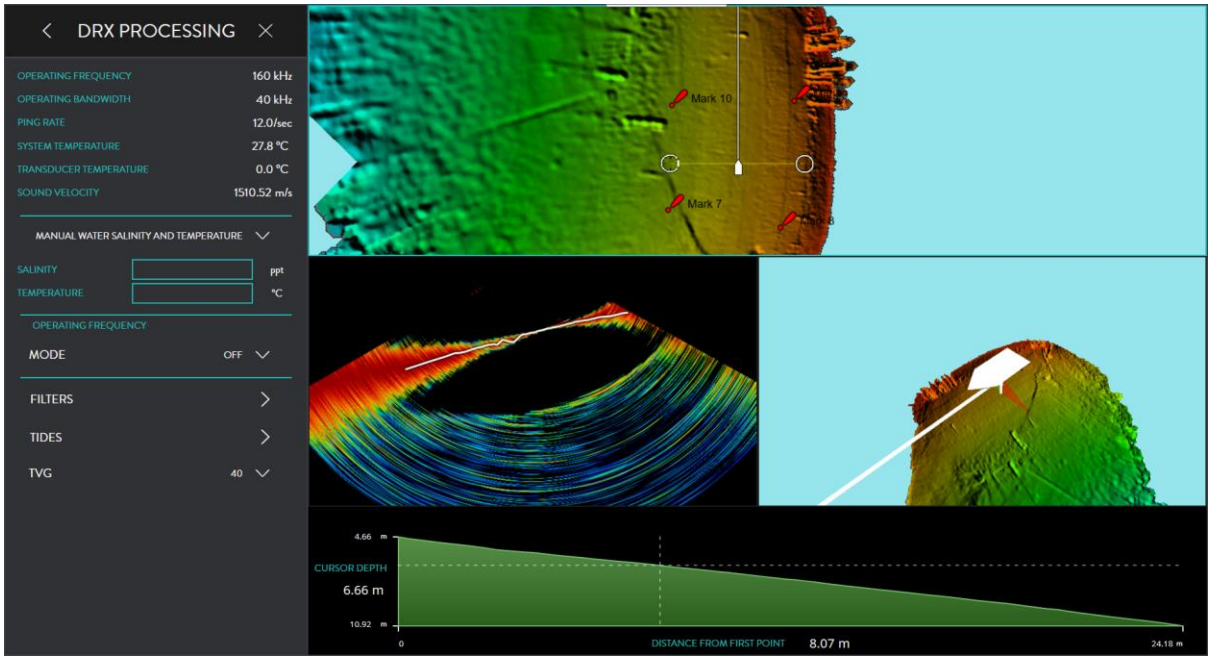
6) Opcijski alati – omogućuju pregled općih podataka

Prilikom batimetrijske izmjere, ovaj sustav omogućuje vizualizaciju snimanog područja kroz četiri prikaza: a) dvodimenzionalni, b) perspektivni (3D), c) sonarno polje te d) profil (Slika 37).



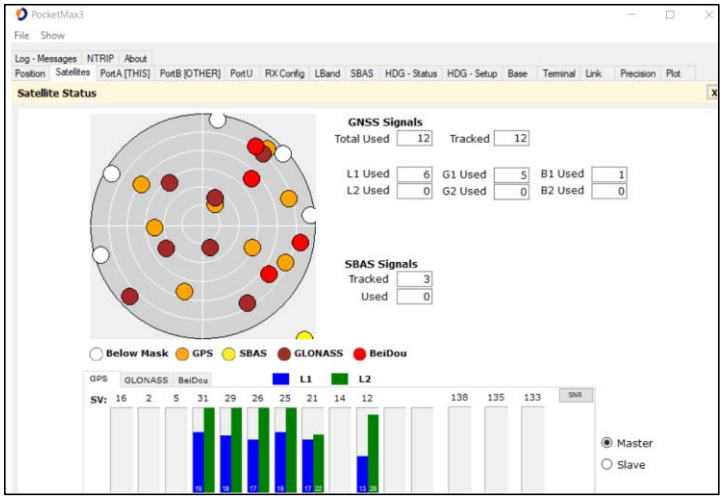
Slika 37. Različiti prikazi snimanog područja prilikom izvođenja MBES batimetrijske izmjere

Središnja referentna točka plovila (engl. *vessel central reference point* - CRP) određena je nakon instalacije MBES-a. Definirane postavke (otvor snopa, duljina impulsa, razmak snopa) kontrolirao je ugrađeni softver i ostale su konstantne tijekom snimanja višesnopnim dubinomjerom. Brzina odašiljanja zvučnog pulsa (engl. *ping rate*) tijekom intervalnih MBES snimanja bila je oko 12/sekundi, dok je širina operativnog snopa bila oko 40 kHz (Slika 38).



Slika 38. Pregled osnovnih parametara MBES snimanja u CDX-u

Važna faza procesa kalibracije sustava bila je konfiguracija GPS antene za što je korišten softver *PocketMax3*. Antena je spojena na sustav CROPOS_VRS_RTCM31 putem softvera *NtripClient* koji omogućuje registraciju podataka u realnom vremenu (Slika 39). Proces obrade prikupljenih oblaka točaka detaljno je opisan u Šiljeg i dr. (2022).



Slika 39. Konfiguracija GPS antene u PocketMax3 programu

4.4. ROV snimanje testne plohe

Chasing M2 podvodna je bespilotna ronilica (Slika 40) dizajnirana i proizvedena od strane CHASING tvrtke smještene u Shenzenu (Kina) (URL 23). Opremljena je baterijom s vremenom trajanja do čak 4 sata. S nešto manje od 5 kg karakterizira ju lako upravljanje i kretanje u svim smjerovima, postižući maksimalnu brzinu od 1.5 m/s do dubine od 100 m. U

ovaj su dron integrirani kamera rezolucije 12 Mpx, LED svjetla od 4000 lumena, kao i razni dodaci s ciljem što veće iskoristivosti. Pogodan je za različite primjene s obzirom na to da podržava 1.5 kg dodatne opreme (URL 24). Preostale su specifikacije podvodne ronilice prikazane u Tablici 7. Korištenje podvodne bespilotne ronilice na testnoj plohi prikazano je na Slici 41.



Slika 40. Chasing M2 podvodni dron

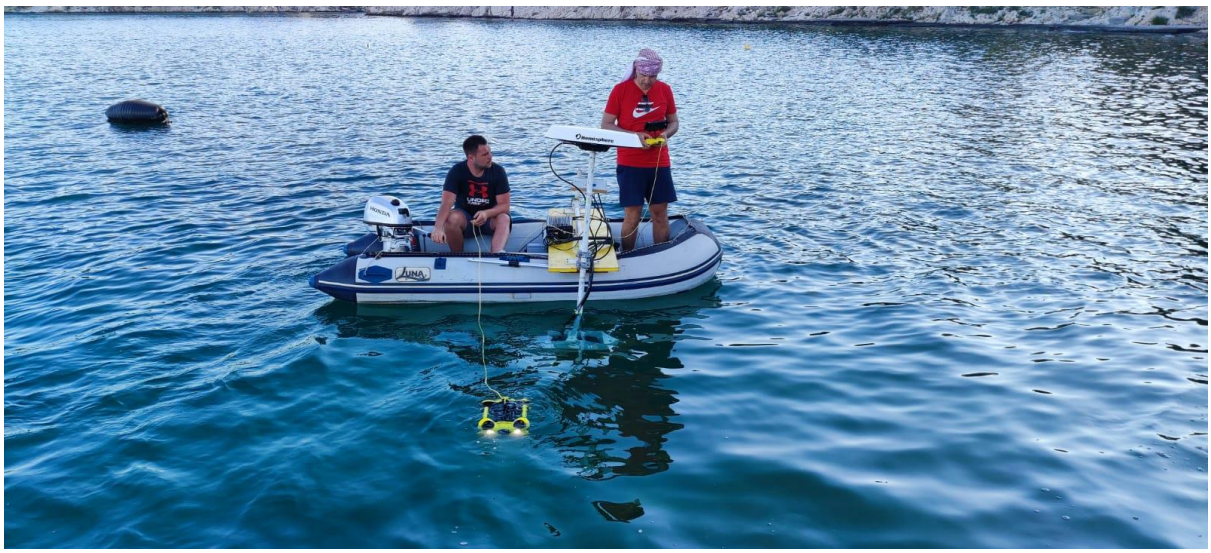
Izvor: URL 24

Tablica 7. Specifikacije podvodnog drona Chasing M2

Model	**Chasing M2 ROV**
Dimenzije	380 x 267 x 165 mm
Težina	4.5 kg
Maksimalna dubina	100 m
Maksimalna brzina	1.5 m/s
Vrijeme izvođenja	3 h
Baterija	97.68 Wh
Radna temperatura	-10℃~45℃
Kamera	
CMOS	1/2.3 inča
Leća	F 1.8
Fokus	1 m
ISO	100-6400
FOV	152°
Maksimalna rezolucija	12 Mpx
Format	JPEG/DNG
Video	UHD: 3840*2160 (4K) 30fps FHD: 1920*1080 (1080p) 30/60/120fps FHD: 1920*1080 120fps FHD: 3840*2160(4K) 30fps

Ubrzani snimak	4K / 1080p
Stopa bitova	60 M
Video format	MP4
SD kartica	64 G
Daljinski upravljač	
Dimenzije	160x155x125 mm
Težina	685 g
Baterija	2500 mAh
Vrijeme izvođenja	≥ 6 h (ovisno o okolini)
Senzor	
IMU	3 osi žiroskop, akcelerometar i kompas
Senzor dubine	< ± 0.25 m
Senzor temperature	< ± 2 °C
LED	
Svjetlina	2 x 2000 lumena
Temperatura boja	5000 K - 5500 K

Izvor: URL 50



Slika 41. Korištenje podvodne bespilotne ronilice Chasing M2 prilikom kartiranja morskog otpada unutar odabrane testne plohe

4.4.1 Izvođenje fotografija iz videa

Podvodno snimanje ROV-om je trajalo 15-20 minuta. Obrada podataka prikupljenih ROV-om se izvršila u programu *Agisoft Metashape*. S obzirom na to da je podvodno fotogrametrijsko snimanje u ovom slučaju izrađeno s osnovnim paketom senzora koji dolazi s *Chasing M2* podvodnom ronilicom, obilježava ga puno više ograničavajućih čimbenika u odnosu na UAV snimanje. Stoga je odlučeno da se snimi duži videozapis morskog otpada na odabranoj testnoj plohi iz kojeg će se izvući fotografije potrebne za obradu. Spomenuti ograničavajući čimbenici podvodne fotogrametrije uključuju:

- težu kalibraciju kamere;

- izostanak svjetla na većim dubinama;
- otežanu orijentaciju ROV-a u podmorju;
- izostanak teksture potrebne za povezivanje snimaka;
- nemogućnosti kreiranja misija s odgovarajućim preklapanjem;
- otežano postavljanje orijentacijskih točaka;
- izostanak EXIF podataka fotografija

Prilikom podvodnog snimanja nastojalo se održati konstantnu udaljenost između kamera i objekta snimanja te obuhvatiti cijeli objekt. Nakon ubacivanja videozapisa u *Agisoft Metashape* te određivanja korisničko-definiranih parametara u opciji *Import Video* koji definira broj izvedenih *frame*-ova, iz videozapisa je izvedeno ukupno 7875 fotografija morskog dna.

4.4.2 Priprema podataka za obradu

Nakon izvođenja fotografija izvršeno je testno povezivanja svih 7875 fotografija u jednom okviru podataka (engl. *chunk*) kako bi se pokušao dobiti jedinstveni model podmorja definirane testne plohe. Očekivano, proces nije uspio zbog tri glavna razloga:

(a) velik broj fotografija slične teksture (dominantna plava boja)

(b) izostanak EXIF podataka (XYZ)

(c) kvaliteta podvodnih fotografija je lošija od UAV fotografija.

Zbog navedenog razloga krenulo se u selekciju podvodnih fotografija u više okvira podataka. U tom slučaju svaki okvir podataka sadrži fotografije jednog ili više komada morskog otpada, ako su relativno blizu jedan drugom.

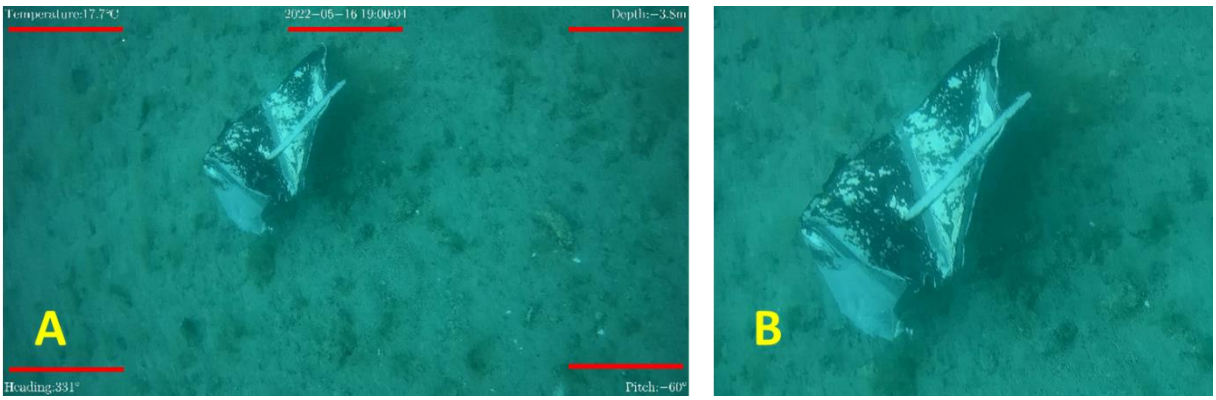
S obzirom na to da kamera korištenog ROV-a ima malu žarišnu udaljenost (engl. *focal lengt*) što generira veliki kut pogleda (eng. *field of view*) jasno je da su izvedene fotografije na svojim rubovima proizvele određene distorzije objekata. Iako tijekom rješavanja pitanja relativne orijentacije *Agisoft Metashape* radi samokalibraciju u sklopu rekonstrukcije snimljenih objekta, odlučeno je da se na svim fotografijama koji prikazuju morski otpad, a bit će korišteni u procesu izvođenja 3D modela, rubovi fotografija koji su pod distorzijom maskiraju (Slika 42), odnosno ne koriste u procesu traženja veznih točaka i izvođenju gustog oblaka točaka (Kwasnitschka i dr., 2013).

Prilikom povezivanja fotografija program pronalazi vezne točke pomoću kojih rješava problem relativne orijentacija snimaka. Međutim, prilikom izvođenja fotografija iz videozapisa uočeno je da one sadrže podatke o temperaturi, dubini, otklonu, datumu i vremenu snimanja,

što potencijalno može uzrokovati probleme prilikom povezivanja fotografija te kreiranja ortomozaika. Stoga su i ti dijelovi fotografija maskirani (Slika 43).



Slika 42. Primjer jedne fotografija s maskiranim rubnim dijelovima



Slika 43. Fotografija a) prije i b) poslije brisanja netočnih podataka

Optičke aberacije uzrokovane lomom svjetlosti na kontaktu s vodom nisu uzete u obzir zbog nedostatka dostupne informacije. Nadalje, Young i dr. (2017) su utvrdili da su nekalibrirane kamere proizvodile točne i precizne rekonstrukcije u centimetarskom mjerilu, sugerirajući da *Agisoft* može primjereno raditi s nekalibriranim kamerama i fotografijama većih distorzija. Nadalje, s obzirom na to da korištenje osnovnog paketa podvodne ronilice ne uključuje mogućnost dobivanja EXIF podataka za svaku fotografiju (XYZ), odlučeno je da se, s ciljem olakšavanja povezivanja (engl. *align*) fotografija, odnosno rekonstrukcije modela, podatci koji su vidljivi na svakoj fotografiji (*Depth*, *Heading*, *Pitch*) prebace u Excel tablicu,

potom konvertiraju u tekstualni dokument te se ponovno importiraju u pojedine *data frame*-ove (Slika 44). Time bi fotografije od EXIF podataka bar posjedovale podatke o dubini (engl. *depth*) i dva kutna pomaka. Naime, u drugim istraživanjima, gdje je uz podvodnu bespilotnu ronilicu dostupna i USBL metoda podvodnog akustičnog pozicioniranja, izvodi se povezivanje svake fotografije (engl. *frame*) sa svojim USBL položajem što omogućuje izravno izvođenje georeferenciranih modela (Price i dr., 2019).

	A	B	C	D	E	F	G
1	FRAME	X	Y	Z	YAW	PITCH	ROLL
2	Aframe0.png	0	0	-4,9	174°	-67°	0
3	Aframe1	0	0	-4,9	174°	-67°	0
4	Aframe2	0	0	-4,9	174°	-67°	0
5	Aframe3	0	0	-4,9	174°	-67°	0
6	Aframe4	0	0	-4,9	174°	-67°	0
7	Aframe5	0	0	-4,9	174°	-67°	0
8	Aframe6	0	0	-4,9	174°	-67°	0
9	Aframe7	0	0	-4,9	174°	-67°	0
10	Aframe8	0	0	-4,9	174°	-67°	0
11	Aframe9	0	0	-4,9	174°	-67°	0
12	Aframe10	0	0	-4,9	174°	-67°	0
13	Aframe11	0	0	-4,9	174°	-67°	0
14	Aframe12	0	0	-4,9	174°	-67°	0

Slika 44. Preuzeti i importirani podatci

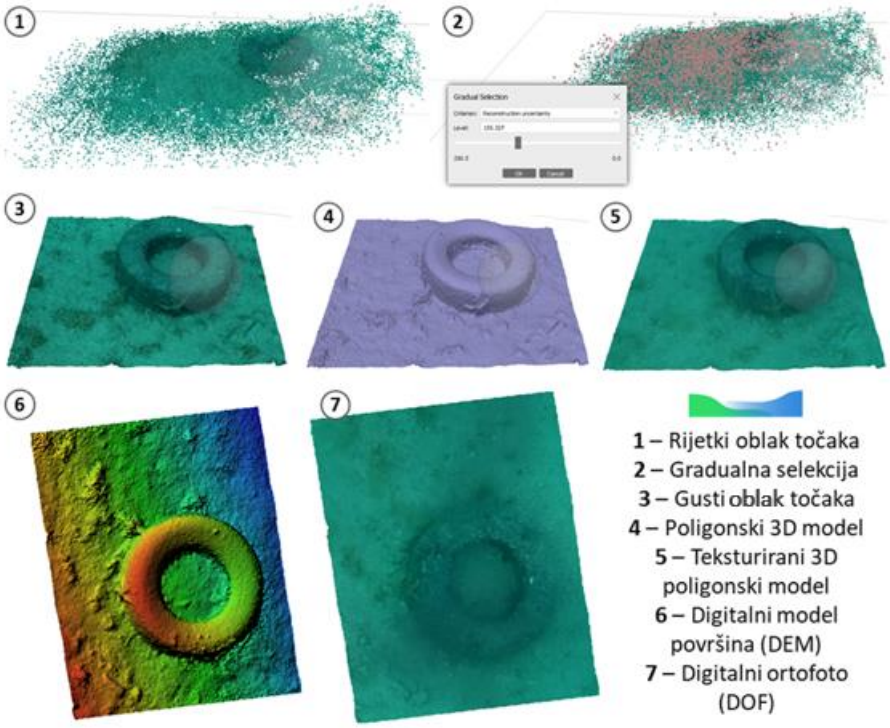
4.4.3 Obrada podvodnih fotografija

Proces obrade podvodnih fotografija sastojao se od nekoliko koraka. Prvi korak odnosi se na (1) orijentaciju aerofotogrametrijskih snimaka (engl. *align photos*) koji uključuje prepoznavanje i izdvajanje veznih točaka, uz pomoć kojih softver povezuje i orijentira fotografije i izrađuje rijetki oblak točaka (engl. *sparse point cloud*). Varijabla točnosti (engl. *accuracy*) je postavljena na *high*, dok su parametri *key point limit* i *tie point limit* postavljeni na vrijednost 0 kako bi se generirao maksimalan broj mogućih veznih točaka s obzirom na specifičnom snimljenog okruženja (izostanak razlika u teksturi).

Nakon izvođenja rijetkog oblaka točaka za svaki okvir podataka izvršeno je njegovo (2) selektivno brisanje s ciljem poboljšanja relativne orijentacije rekonstruiranog modela. Korišten je set alata unutar opcije *Gradual Selection* te su odabrani parametri nesigurnost rekonstrukcije (engl. *reconstruction uncertainty*) i pogreška reprojekcije (engl. *reprojection error*). Svakim parametrom odabrano je 10% od ukupnog broja izvedenih veznih točaka koje

su potom obrisane. Nakon brisanja izvršena je iterativna optimizacija rijetkog oblaka točaka, čime su nanovo procijenjeni intrinzični kalibracijski parametri kamere.

Sljedeći korak odnosio se na (3) izradu gustog oblaka točaka gdje se automatski rijetki oblak točaka progušćuje ovisno o odabranoj varijabli parametra kvalitete i metodi dubinskog filtriranja (engl. *depth filtering*). Varijabla kvalitete određuje udio piksela iz orijentiranih fotografija koje se koriste za izradu gustog oblaka točaka. U procesu obrade odabran je parametar visoke (engl. *high*) kvalitete. Nakon izrade gustog oblaka točaka izvedeni su (6) digitalni modeli površina (DEM) i (7) digitalni ortofoto (DOF) modeli morskog podmorja (Slika 45).



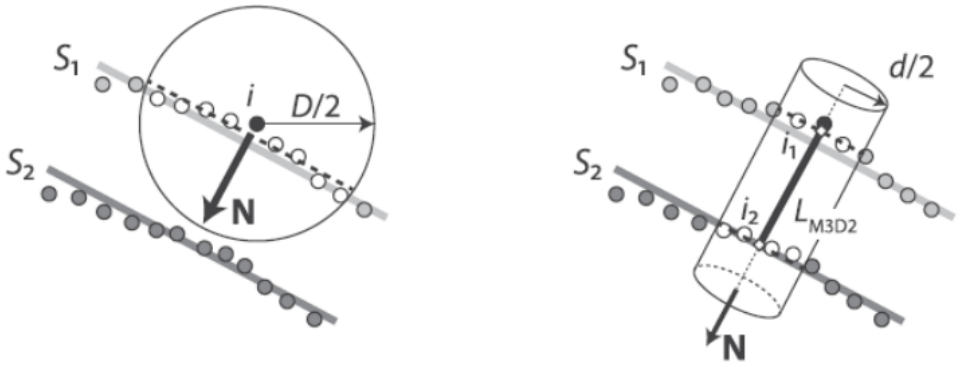
Slika 45. Izlazni rezultati u procesu obrade podvodnih fotografija u Agiosft Metashape-u

Posljednji korak uključivao je povezivanje i spajanje pojedinih okvira podataka (engl. *chunk*) u jedinstveni okvir s ciljem boljem vizualizacije i usporedbe modela. Navedeno je izvršeno koristeći opcije *Align Chunk* i *Merge Chunk*. Povezivanje je postavljeno na najveću kvalitetu (eng. *highest*). S obzirom na izostanak orijentacijskih točaka metoda povezivanja je postavljena na *Point Based*, dok je granica broja veznih točaka koji sudjeluje u povezivanju postavljena na 10 000.

4.5. Usporedba intervalnih MBES snimanja MBES

Intervalno snimljeni oblaci točaka uspoređeni su unutar *CloudCompare* programa. U njemu je korišten alat M3C2 (engl. *Multiscale Model to Model Cloud Comparison)* koji služi za izračun udaljenosti i izravnu usporedbu između dva oblaka točaka. Paralelno izračunava procjenu pouzdanosti uzimajući u obzir složenost terena i registracijsku pogrešku. Algoritam se temelji na principu da za svaku pojedinu točku referentnog ili inicijalnog oblaka točaka izračunava „lokalnu" prosječnu udaljenost od drugog oblaka točaka.

Prvo određuje lokalnu normalu (N) točke (i) iz referentnog oblaka točaka (i) podešavajući ravnine kroz susjedne točke iz drugog oblaka točaka unutar zadanog radijusa normale od točke i (D/2) (Domazetović, 2021; James i dr., 2017). U drugom se koraku određuje prosječna pozicija točaka jednog i drugog oblaka unutar cilindra specifično postavljenog polumjera (d/2), koji je orijentiran duž određene normale (N). Tako algoritam definira srednji položaj točke u referentnom ($i1$) i u drugom oblaku točaka ($i2$) te udaljenost ($LM3C2$) između te dvije pozicije (Slika 46) (Domazetović, 2021).



Slika 46. Način određivanja udaljenosti između dva oblaka točaka primjenom M3C2

Izvor: James i dr., 2017.

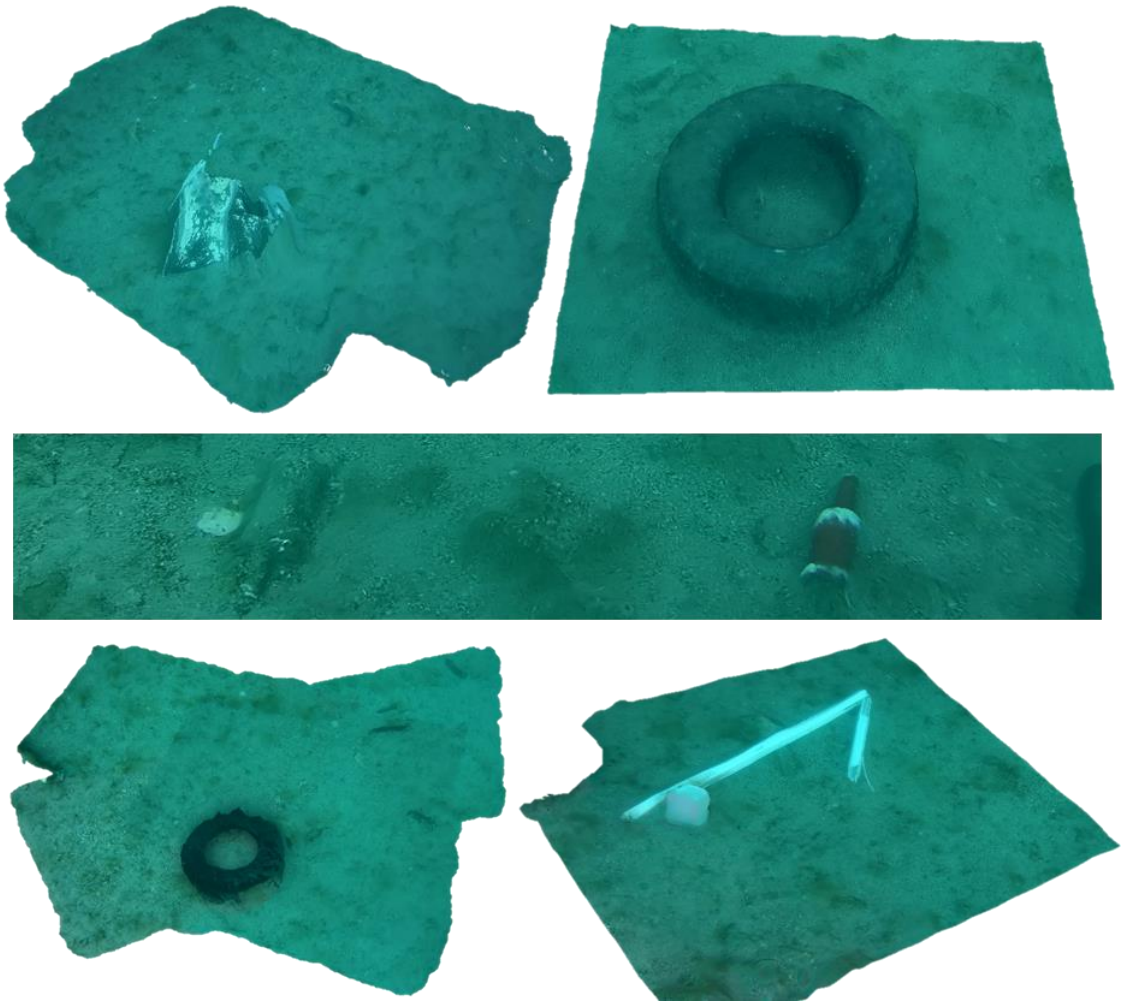
Naravno, autori ističu da tijekom korištenja algoritma treba poznavati korisničko-definirane parametre. Oni mogu značajno utjecati na izlazne rezultate. Tako je za prikupljene oblake točaka parametar promjera normale (engl. *normals diameter*) podešen na **1.76 m**. Promjer cilindra (engl. *projection diameter*) je postavljen je na **0.88 m**, dok je maksimalna dubina (engl. *max depth*) postavljena na **2.014 m**. Potrebno je istaknuti da su orijentacije cilindra (engl. *prefered orientation*) postavljene na +Z i -Z. Vrijednosti navedenih parametara određene su empirijski, iterativnom primjenu M3C2 algoritma s različitim vrijednostima.

5. REZULTATI I RASPRAVA

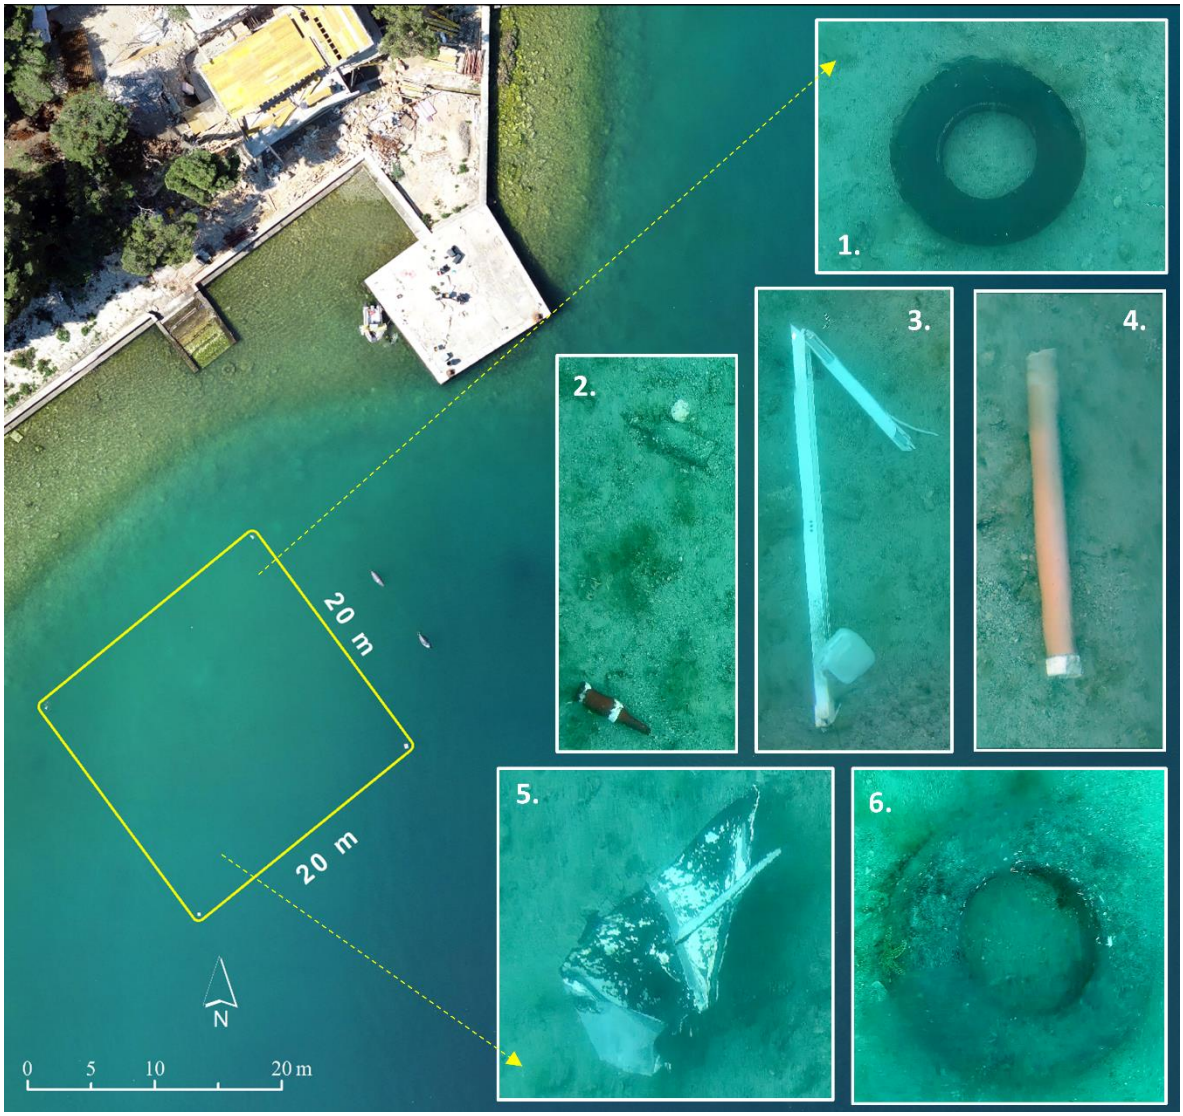
5.1. Morski otpad detektiran ROV-om

Proces obrade podvodnih fotografija izvedenih iz videozapisa uspješno je izvršen za svaki od postavljenih okvira podataka. Na Slici 47 prikazani su izvedeni 3D modeli i digitalni ortofoto modeli (DOF) detektiranog otpada na morskom dnu unutar odabrane plohe snimanja. Detektiran je sljedeći otpad:

1) Automobilska gumu (snimljena *Artec Evom*)
2) Dvije staklene boce
3) Komad PVC-a
4) Plastična cijev
5) Lim
6) Stara automobilska guma.



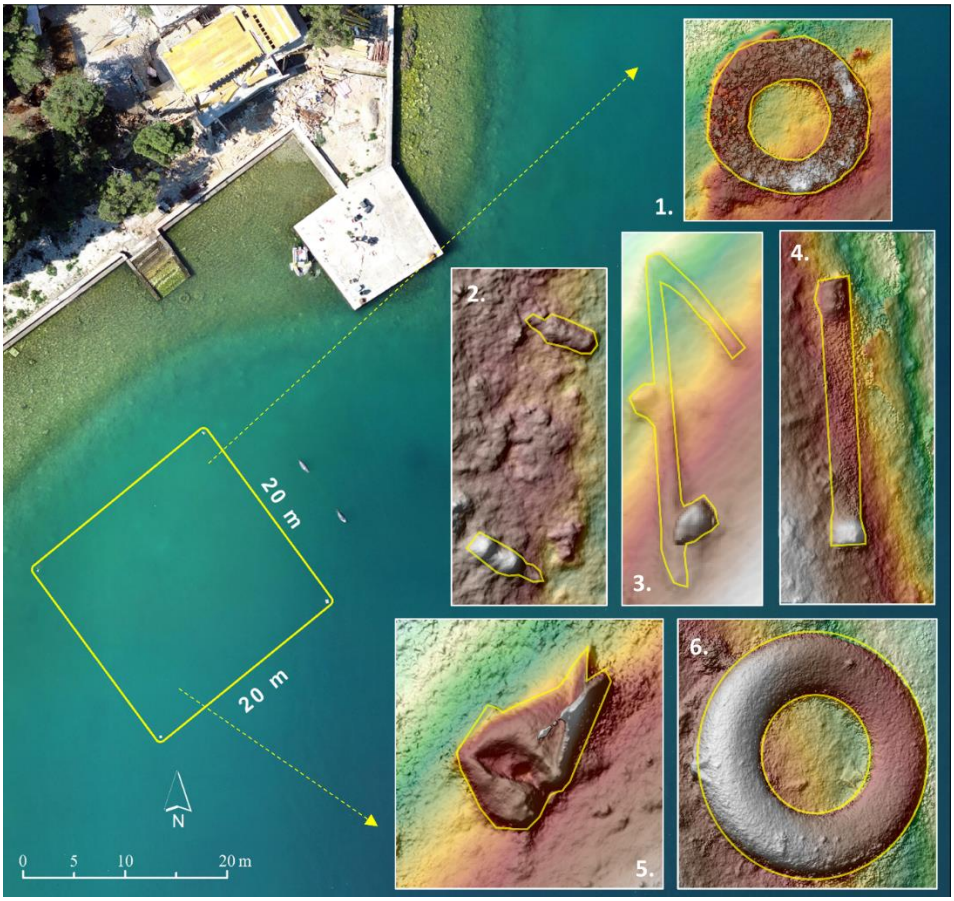
Slika 47. Primjeri izvedenih 3D modela detektiranog otpada na morskom dnu



Slika 48. Otpad detektiran na morskom dnu primjenom bespilotne podvodne ronilice (DOF

Nadalje, na slici 49 prikazani su digitalni modeli površina (DEM) detektiranog otpada na morskom dnu. Preko digitalnih modela površina postavljen je model reljefa sjenčanjem (engl. *hillshade*) s ciljem boljeg isticanja obruba samih objekata. Iako je proces obrade svih okvira podatak uspješno završen te su svi elementi otpada detektirani na morskom dnu, potrebno je istaknuti da primjena osnovnog paketa bespilotne podvodne ronilice ne omogućava izvođenje točnih morfometrijskih parametara snimljenih objekata. To je najbolje vidljivo na primjeru (1) automobilske gume koja je snimljena ručnim 3D skenerom *Artec Eva*. Naime, širina i dužina automobilske gume (Slika 48) izračunata iz 3D modela *Artec Evom* iznosi 76 cm, dok u rekonstruiranom modelu iz podvodnih snimaka iznosi 560 cm.

Naime, dodatak različitih podvodnih sustav za pozicioniranje koji mogu uključivati LBL, USBL, SBL i GPS „inteligentne“ plutače, uvelike bi olakšao proces povezivanja podvodnih fotografija, dok bi postojanje lokalnog koordinatnog sustava ili odgovarajućih mjerila omogućilo točno izvođenje morfometrijskih parametara (Drap, 2012; Kwasnitschka i dr., 2013; Ioakeimidis i dr., 2015). Nadalje, samokalibracija se bez inicijalnih parametara pokazala kao nedovoljno dobar način utvrđivanja unutarnjih kalibracijskih parametara. Navedeno je očekivao, s obzirom da se zaista točna rekonstrukcija modela može postići jedino ako postoje precizni podaci o unutarnjim parametrima i nekim minimalnim vanjskim informacijama o položaju i orijentaciji kamere ili referentnim točkama na predmetu (Kwasnitschka i dr., 2013). U slučaju da se i primjenjuje neki od podvodnih sustava za pozicioniranje potrebno je prikupljene navigacijske podatke podvrgnuti korekciji (Kwasnitschka i dr., 2013). Izostanak ovakvog sustava onemogućuje izračun jednostavnog pokazatelja zagađenosti podmorja morskim otpadom kao što je srednja gustoća morskog otpada (engl. *mean marine litter density*) koja se računa kao broj komada otpada po jedinici površine (Ioakeimidis i dr., 2015). U ovom kontekstu, osnovni paket podvodne bespilotne ronilice može se koristiti samo za detekciju otpada na morskom dnu i izvođenje inicijalnih modela (Slika 48). Za potrebe izvođenja složenijih morfometrijskih analiza potrebno je koristiti podvodne sustave za pozicioniranje te odgovarajuća podvodna mjerila.



Slika 49. Otpad detektiran na morskom dnu primjenom bespilotne podvodne ronilice (DEM)

5.1.1. Smjernice za izvođenje podvodne fotogrametrije primjenom ROV-a

Podvodna fotogrametrija se smatra relativno novom vrstom fotogrametrije te se stoga na internetu ne može pronaći puno smjernica o njenom izvođenju. Podvodna fotogrametrija znatno je teža u usporedbi s terestričkom fotogrametrijom zbog vrlo složenih okolišnih uvjeta (udaljenost snimanja je ograničena, okruženje kontroliranog svjetla gotovo da ne postoji, izrazito je teško postaviti i izmjeriti orijentacijske i/ili kontrolne točke na scenu snimanja). Detaljnost smjernica za izvođenje podvodne fotogrametrije ovisi primarno o svrsi izvođenja snimanja. Ukoliko je svrha samo inicijalna detekcija otpada na morskom dnu ili nekog drugog elementa, bez potrebe za poznavanjem njegove točne morfometrije, u tom je slučaju broj i složenost smjernica kojih se treba pridržavati značajno manja. U nastavku su pružene smjernice za izvođenje podvodne fotogrametrije koja ima svrhu detekciju i utvrđivanje relativno točne morfometrije snimanih objekata.

- **Dostupna dodatna ROV oprema**

Kvaliteta i primjenjivost rekonstruiranih 3D modela na morskom dnu ovisit će primarno o dostupnoj opremi i stručnosti korisnika. Ukoliko je moguće, korisnik bi na raspolaganju

trebao iamti sljedeću dodatnu opremu koja bi mu omogućila lakše izvođenje procesa podvodne fotogrametrije:

(a) dodatno osvjetljenje koje uvodi više svjetla u snimano područje; navedeno pomaže u isticanju pravih boja snimanih objekata i smanjuje zelene i plave valne duljine koje u pravilu dominiraju većinom podvodnih fotografija. Nadalje, veća količina svjetla će omogućiti postavljanje više vrijednosti brzine zatvarača (engl. *shutter speed*) što će omogućiti snimanje oštre fotografije (zamrzavanje pokreta);

(b) sustav za podvodno pozicioniranje bespilotne ronilice koji u realnom vremenu omogućuje poznavanje lokacije bespilotne ronilice te kasnije korištenje tih podataka u rješavanju problema relativne i apsolutne orijentacije modela

- **Kvaliteta ulaznih podataka**

Primarni čimbenik na koji korisnik može utjecati u izvođenju primjenjivih 3D modela je kvaliteta snimljenih fotografija što je izravna posljedica same strategije snimanja.

Ukoliko je moguće, podvodno fotografiranje treba obaviti vrijeme idealnih vremenskih uvjeta (mirno vrijeme, nema valova i difuzno svjetlo). Navedeno omogućava povećanje udaljenosti snimanja. Bitan čimbenik je primjena senzora visoke razlučivosti s niskom razinom šuma. Snimanje tijekom jakog svjetla nije preporučljivo u plitkim područjima zbog stvaranja uzoraka valova na sceni/modelu. Leća bi trebala imati vrlo veliku dubinu polja ili fiksni fokus uravnotežen s malim relativnim otvorom blende. Potrebno je zadovoljiti tri osnovna uvjeta: fotografije moraju biti u fokusu, imati dobru ekspoziciju i dovoljnu rezoluciju. Uvijek se treba voditi osnovnim pravilom fotogrametrije: snimanje više fotografija bolje je od nedovoljnog preklapanja slika ili nepotpunog skupa podataka. Ukoliko se fotografije izvode iz videa ili nema sustava za podvodno pozicioniranje, a time nedostaju EXIF informacije, potrebno je postaviti parametre senzora kamere (žarišnu duljinu i veličinu piksela senzora) u *Metashape*-u prije pokretanja operacije povezivanja fotografija. U slučaju da se fotografije ne izdvajaju iz videa, potrebno je primjereno postaviti parametre kamere. Ukoliko se brzina zatvarača (engl. *shutter speed*) postavi na manju brzinu (npr. 1/5), dobit će se više svjetla, ali će objekti biti mutni zbog vašeg kretanja ili kretanja sniamanog objekta. Suprotno, veća brzina zatvarača će zamrznuti kretanje i uhvatiti detalje, ali potencijalno će biti nedovoljno svjetla. Zbog toga se u podvodnoj fotogrametriji preporučuje postavljanje visokih ISO postavki, korištenje dodatnih izvora svjetlosti te korištenje srednje brzine zatvarača. Poželjno je kameru držati okomito na snimane objekte jer izrazito kosi snimci mogu otežati proces rekonstrukcije ili rezultirati netočnošću modela. Prilikom snimanja potrebno je izbjeći nagle i brze pokrete ROV-om jer to može rezultirati zamućivanjem fotografije ili netočnostima u određivanju položaja bespilotne

letjelice, u slučaju korištenja sustava za podvodno pozicioniranje. Preporučuje se izrazito veliko preklapanje između fotografija te smjerovi snimanja okomiti jedan na drugi (engl. *double grid mission*).

- **Primjena mjernih skala**

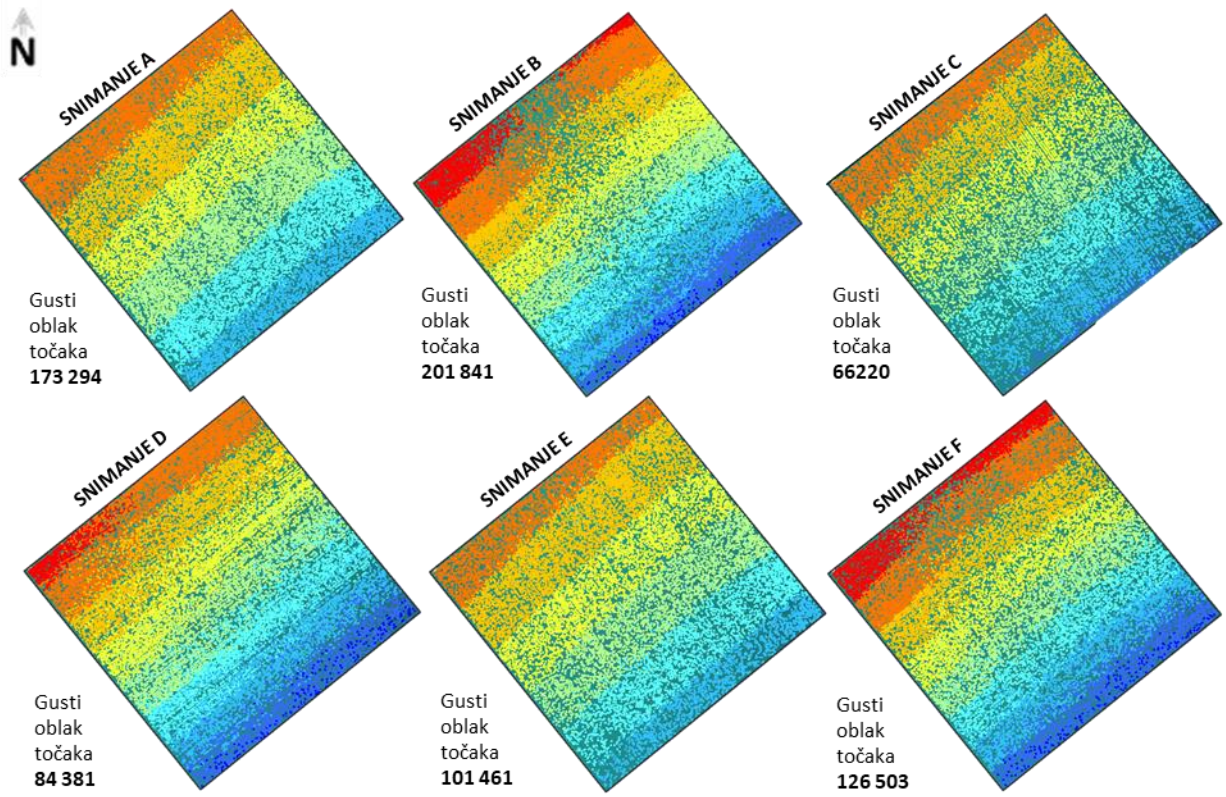
Mjerne bi skale trebale biti onoliko dugačke koliko to praktičnost primjene dozvoljava. Način postavljanja trebao bi biti okomit jedan na drugi kako bi se mogla smanjiti pogreška relativne duljine i moguća pogreška u jednom smjeru. Za potrebe procjene točnosti rekonstrukcije moguće je postavaljanje dodatnih mjernih skala. Mjerne je skale potrebno uniformno rasporediti po sceni snimanja.

- **Postavljanje podvodnih orijentacijskih ili kontrolnih točaka**

Slično praksi izvođenja UAV fotogrametrije, poželjno je postaviti podvodne orijentacijske ili kontrolne točke unutar prostora snimanja. Iako nisu obvezne, moguće je poslužiti se fotogrametrijskim programom u georeferenciranju modela (ako su određene XYZ koordinate) ili povezivanju različitih rekonstruiranih modela.

5.2. MBES intervalna snimanja - gustoća uzorkovanja

Na slici 50 prikazani su nefiltrirani podaci gustih oblaka točaka izrezani prema granicama testne plohe (20 * 20 m) za odabranih šest intervalnih MBES snimanja (SI - JZ, JI -SZ pri brzinama od 1,5, 3 i 4,5 čvora). Izvedeni parametri broja i gustoće prikupljenih točaka najbolje pokazuju koliko brzina kretanja i smjer plovila mogu utjecati na gustoću uzorkovanja primjenom MBES-a.



Slika 50. Gusti oblaci točaka za intervalna MBES snimanja

Najveći je broj točaka očekivano prikupljen u snimanjima (A) i (B) gdje je brzina plovila bila najmanja, odnosno iznosila 1,5 čvor. Naime, u snimanju (A) je prikupljena 201 841 točka, a u snimanju (B) 173 294 točke. Prosječan broj točaka prikupljen u snimanju pri najmanjoj mogućoj brzini iznosi 187 685 točaka. Dakle, gustoća uzorkovanja testne plohe pri brzini od 1,5 čvor iznosi 470 točaka/m².

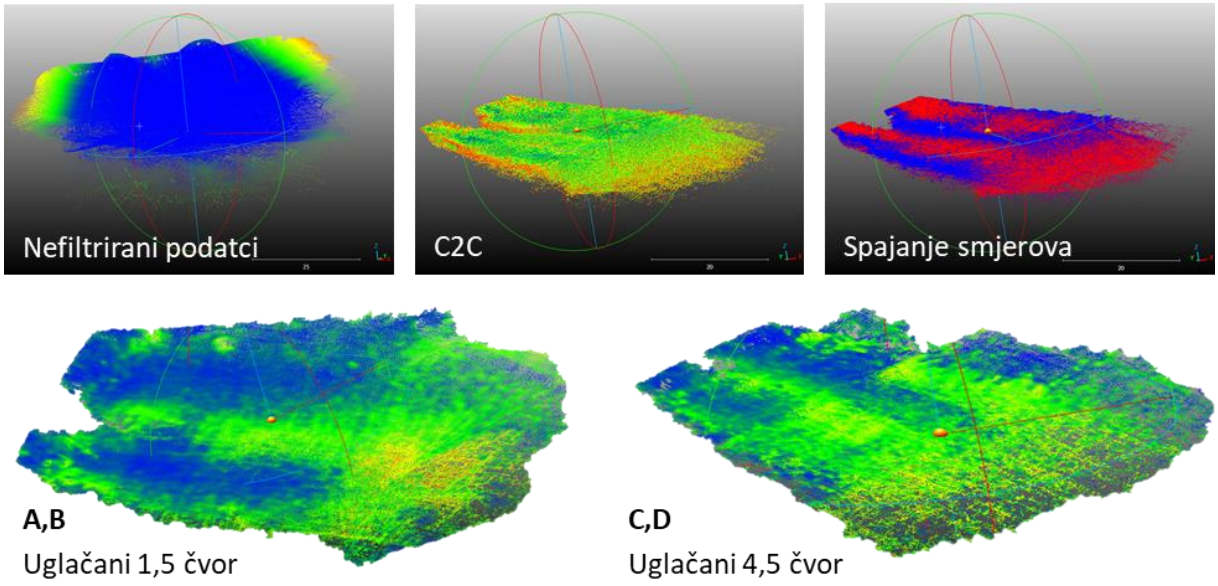
Najmanji je broj točaka očekivano prikupljen u snimanjima (C) i (D) gdje je brzina plovila bila najveća, odnosno iznosila 4,5 čvora. Naime, u snimanju (C) je prikupljeno 66 220 točaka, a u snimanju (D) 84 381 točka. Prosječan broj točaka prikupljen u snimanju pri najvećoj mogućoj brzini plovila je iznosio 75 300 točaka. Dakle, gustoća uzorkovanja testne plohe pri brzini od 4,5 čvora iznosila je 188 točaka/m² ili 2,5 puta manje od gustoće uzorkovanja pri najmanjoj brzini. Navedeno približno odgovara i razlikama u brzini plovidbe.

Srednji je broj točaka prikupljen u snimanjima (E) i (F) gdje je brzina plovila bila 3 čvora. Naime, u snimanju (E) je prikupljena 101 461 točka, a u snimanju (E) 126 503 točaka. Prosječni broj točaka prikupljen u snimanju pri srednjoj brzini plovila je iznosio 113 982 točke. Dakle, gustoća uzorkovanja testne plohe pri brzini od 3 čvora je iznosila 285 točaka/m² ili 1,7 puta manje od gustoće uzorkovanja pri najmanjoj brzini. Navedeno približno odgovara i razlikama u brzini plovidbe.

5.2.1 Detekcija otpada primjenom MBES-a

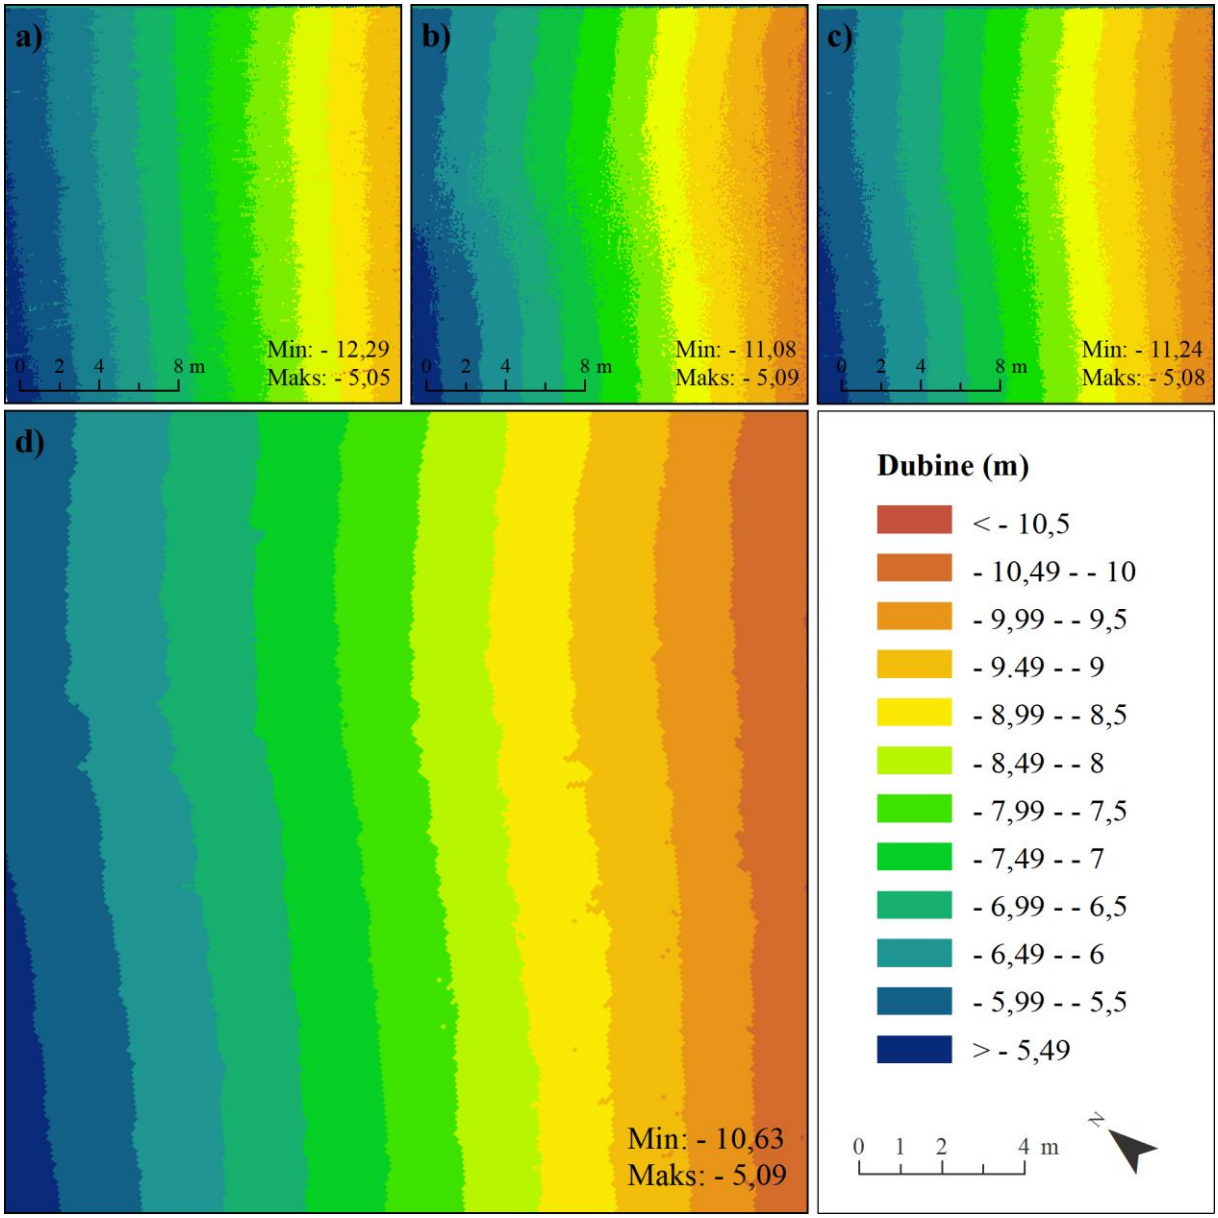
5.2.1.1 Izvođenje digitalnih modela dubina

Iz gustih oblaka točaka izvedenih MBES snimanjima pri različitim smjerovima te najmanjoj (1,5 čvor) i najvećoj (4,5 čvora) brzini plovidbe generirani su digitalni model dubina (DMB) definirane testne plohe. Cilj izvođenja bio je uočiti mogu li se na DMB-u uočiti razlike u detaljnosti morskog dna, a time i u potencijalnoj detekciji otpada na morskom dnu. Proces obrade gustih oblaka točaka najmanje (A,B) i najveće brzine (C,D) plovila sastojao se od nekoliko istih koraka. Proces je izvršen za šire snimljeno područje (Slika 51) te je nakon obrade izrezan prema poligonskim granicama testne plohe.

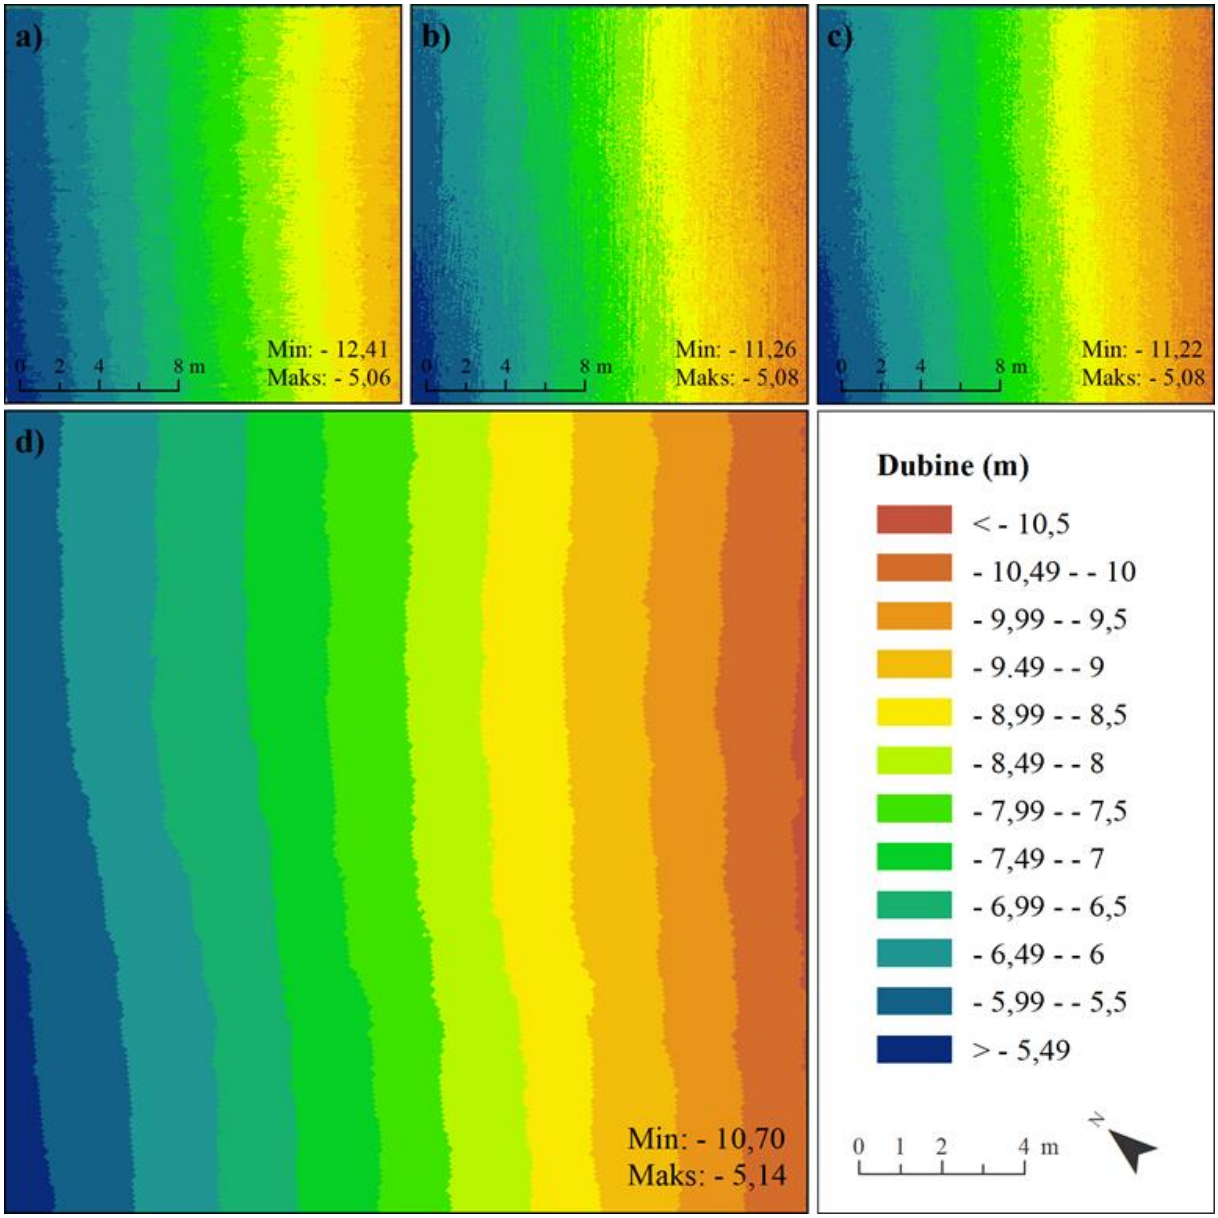


Slika 51. Proces obrade nefiltriranih oblaka točaka u izvođenju DBM-a šireg područja

Prije izvođenja DMB-a izvršena je filtracija gustih oblaka točaka snimanja A i B. Primijenjen je novi metodološki pristup filtracije gustog oblaka točaka temeljen na polu-automatskom uklanjanje pogrešaka (Šiljeg i dr., 2022). Pristup je nadograđen s novim korakom primjene alata *Cloud to Cloud* gdje su sve točke koje imaju apsolutnu udaljenost veću od 15 cm između dva korištena gusta oblaka točaka uklonjene (Slika 51). Potom je korišten alat *Moving Least Squares* (MLS) u *Cloud Compare*-u koji služi za uglačavanje gustog oblaka točaka. Parametar SR je optimiziran na 0.5 jer je iterativno metodom određeno da daje najbolje rezultate. Nakon filtracije točaka spojeni oblaci točaka najmanje brzine plovidbe (A,B) su imali preko 1 mil. točaka, dok su spojeni oblaci točaka najveće brzine (C,D) plovidbe imali nekoliko stotina tisuća točaka. Rasterizacija oba spojena oblaka točaka izvršena je u *ArcMap*-u koristeći alat *LAS Dataset to Raster*.



Slika 52. a) DBM (A) snimanja nefiltrirani; (b) DBM (B) snimanja nefiltrirani; (c) DMB integrirani A i B nefiltrirani; (d) DBM filtrirani integralni model

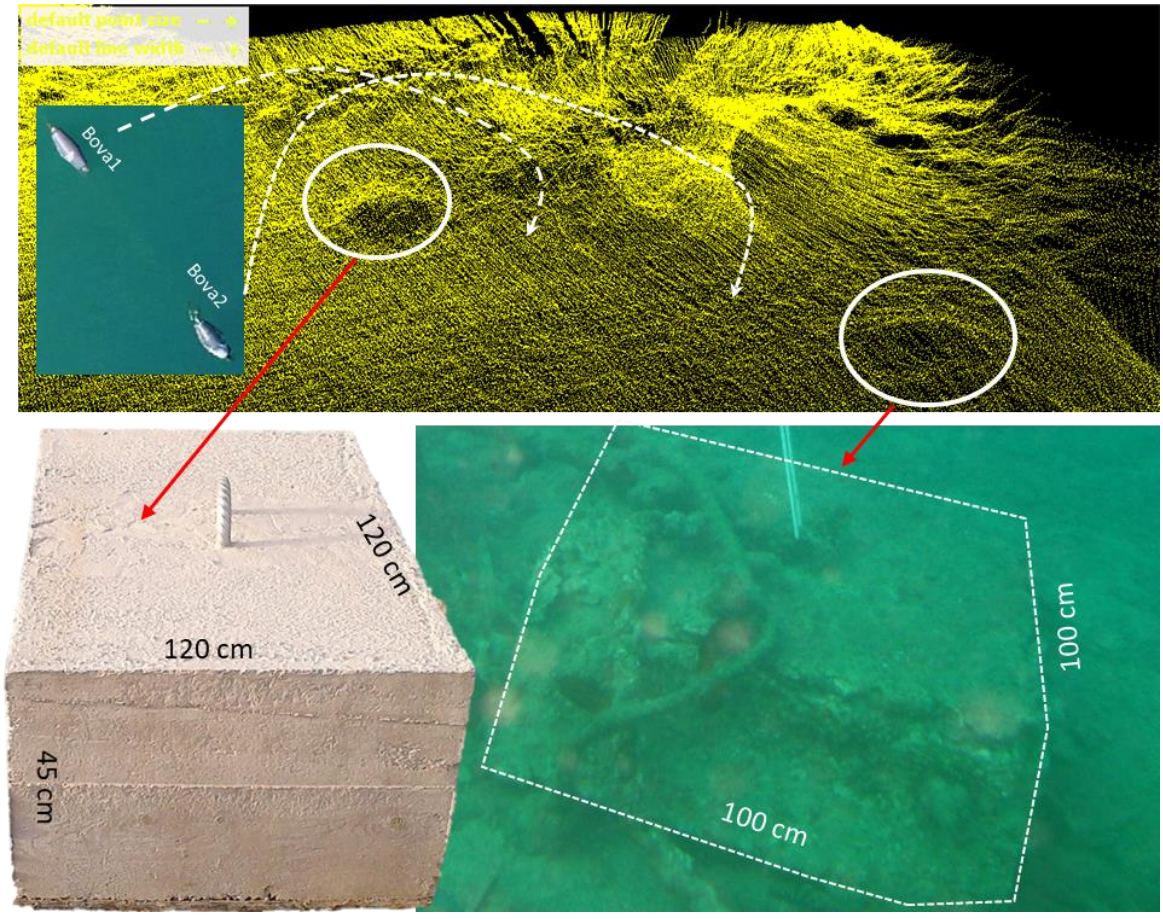


Slika 53. a) DBM (C) snimanja nefiltrirani; (b) DBM (D) snimanja nefiltrirani; (c) DMB integrirani C i D nefiltrirani; (d) DBM filtrirani integralni model

Iza oba generirana DBM-a (spora brzina i najveća moguća brzina plovila) moguće je uočiti da otpad nije detektiran na morskom dnu. To je potvrđeno izvođenjem različitih morfometrijskih analiza (izohipse, nagib i vertikalna raščlanjenost) (Slika 52). To vrijedi za filtrirane integralne model i nefiltrirane integralne modele brzog i sporog snimanja. Stoga je za detekciju morskog otpada korišten vizualni element, odnosno detaljno pregledavanje nefiltriranih oblaka točaka u *CloudComapre*-u, s ciljem uočavanja određenih odstupanja koji mogu ukazivati na određene objekte na morskom dnu.

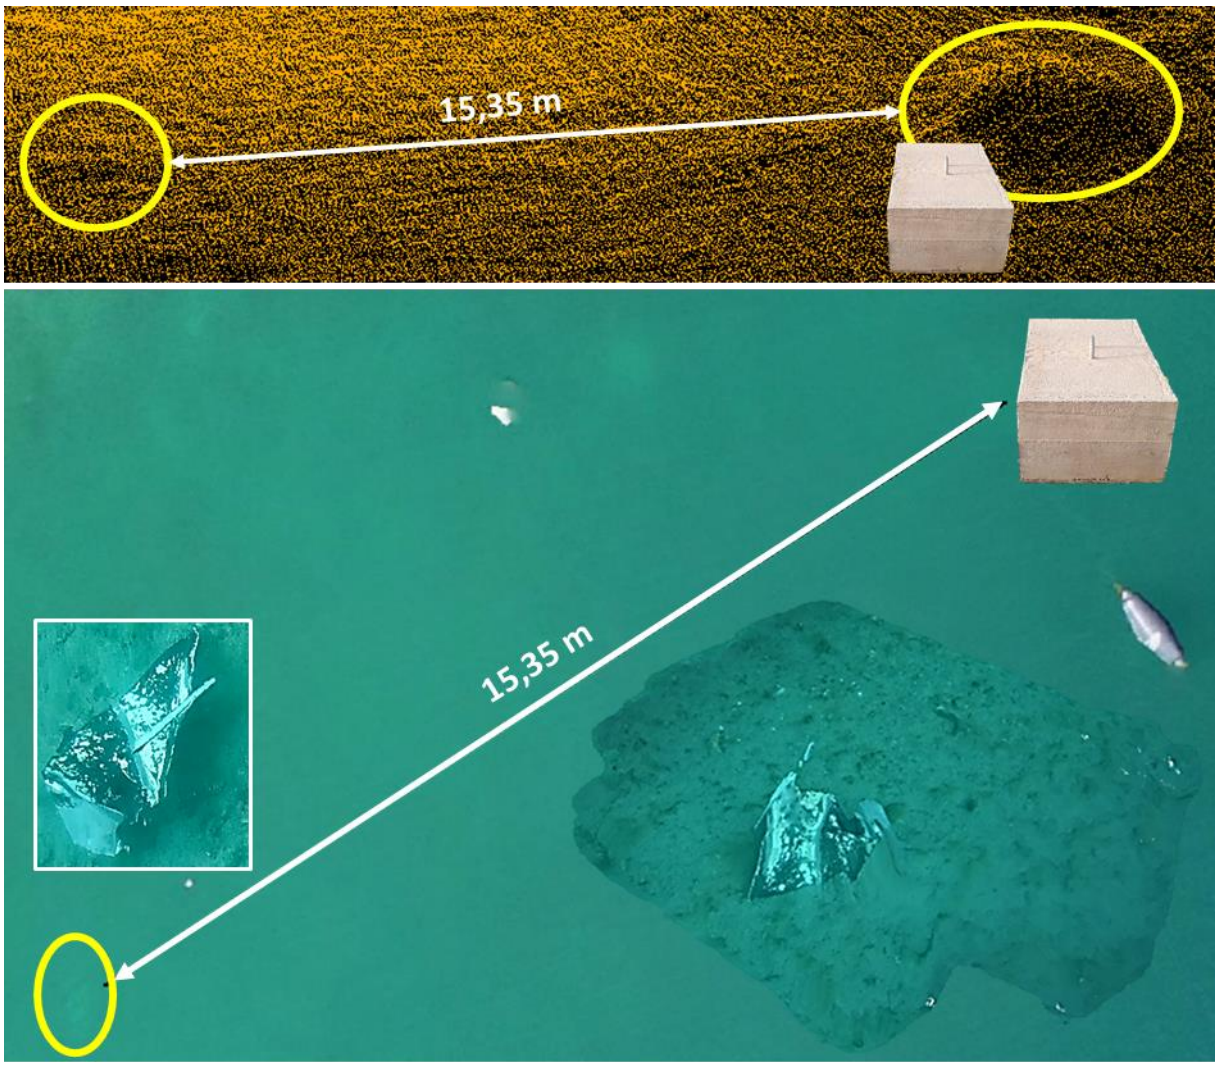
5.2.1.2 Uočavanje morskog otpada iz nefiltriranih oblaka točaka

Zbog nemogućnosti detekcije morskog otpada na izvedenim filtriranim i nefiltriranim DBM-a spore i jako brze plovidbe pribjeglo se detaljnom pregledavanju nefiltriranog oblaka točaka najveće gustoće (A i B snimanje). S obzirom na to da je MBES snimanje uključivao šire područje izvan testne plohe iz nefiltriranog oblaka točaka, detektirani su betonski blokovi dimenzija 100 cm * 100 cm * 40 cm koji se nalaze sjeveroistočno od testne plohe, a na koje su privezane velike bove vidljive na DOF snimku. Jedan se betonski blok nalazi na dubini od 6,5 m te je gore navedenih dimenzija, dok se drugi betonski blok nalazi nešto jugoistočnije na dubini od 9 metara te je nešto manjih dimenzija. Uvažavajući navedene dimenzije objekata te činjenicu da su betonski blokovi detektirani sa stopostotnom sigurnošću, što je potvrđeno i od strane ronioca koji poznaje morfologiju snimanog morskog dna, može se reći da minimalna jedinica kartiranja morskog otpada MBES-a *WASSP S3* sustava do dubine od 10 m iznosi 100 cm * 100 cm, s visinom od oko 40 cm. Drugim riječima, samo oni objekti koji imaju površinu veću od 1 m² te visinu izdignutu 40 cm od morskog dna mogu biti učinkovito detektirani iz nefiltriranog oblaka točaka i DBM-a (Slika 54).



Slika 54. Detektirani betonski blokovi iz nefilttriranog oblaka točaka najsporije brzine

Ipak, poznavanje lokacije morskog otpada unutar testne plohe, kroz UAV DOF snimak i ROV modele, omogućilo je rubnu detekciju objekta lima u nefiltriranom oblaku točaka. Međutim, njegova je detekcija izrazito nesigurna s obzirom da ovisi o položaju pod kojim se gleda oblak točaka te se čak i tad ne može sa sigurnošću ustanoviti radi li se o limu. Naime, tek ako se oblak točaka gleda u specifičnom položaju, na lokaciji gdje bi prema DOF-u trebao biti lim, može se uočiti određeno ispupčenje u oblaku točaka (Slika 55).



Slika 55. Ispupčenje u gustom nefiltriranom oblaku točaka - objekt lima na morskom dnu

5.2.2 Razlozi izostanka detekcija otpada primjenom MBES-a

Iako je MBES-om plan izmjere točno definiran te je osigurana stopostotna pokrivenost područja istraživanja, ipak gotovo nijedan objekt nije detektiran. Na svim gustim oblacima točaka izvedenim iz intervalnih snimaka uočen je tek objekt lima i to ne sa sto postotnom sigurnošću.

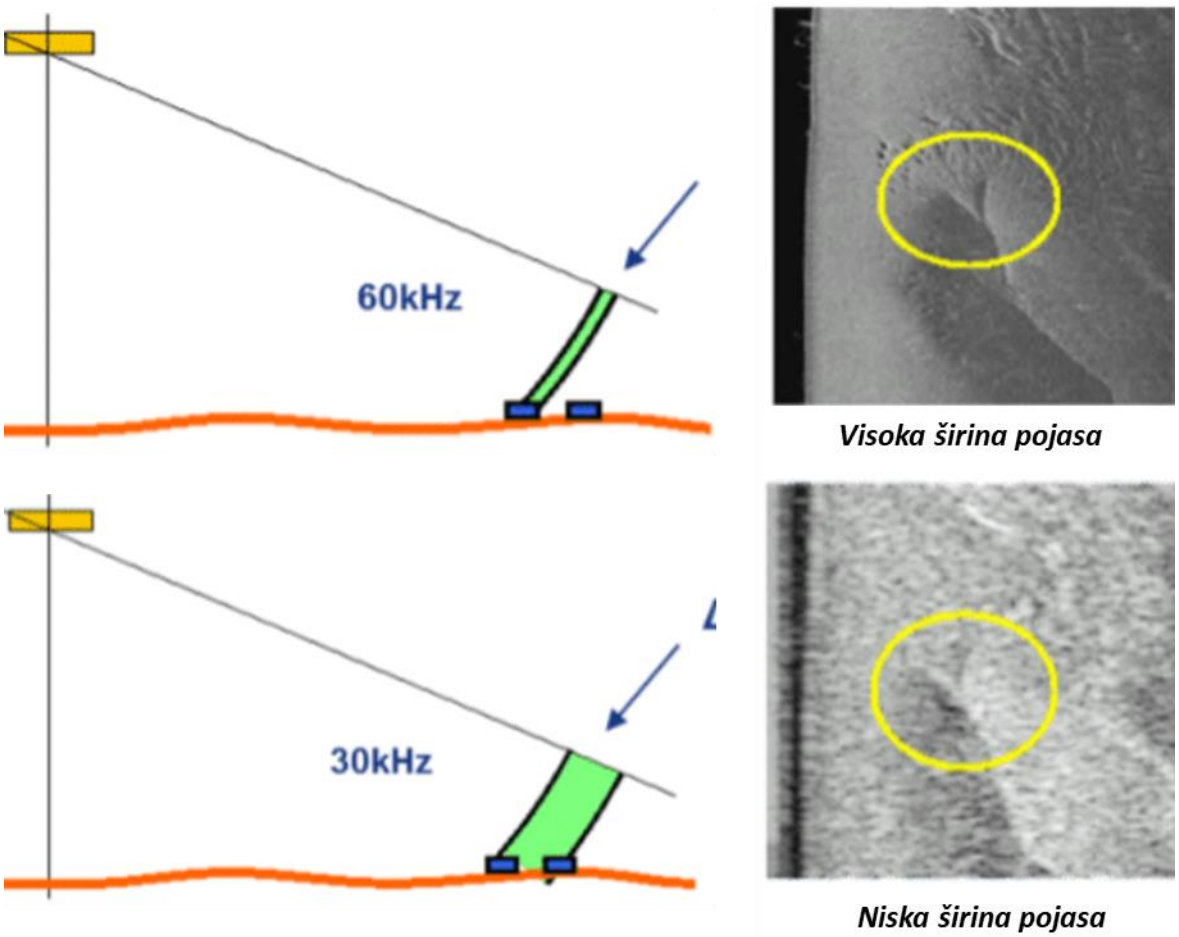
Razlog tomu specifikacije su višesnopnog dubinomjera koje određuju minimalnu jedinicu kartiranja i samim time, minimalnu veličinu objekta koja može biti detektiran (Hughes-Clarke, 1998). Obradom se podataka može zaključiti kako se morski otpad manje površine od 1 m² izrazito teško, gotovo nemoguće može kartirati višesnopnim dubinomjerom *WASSP S3* na dubinama do 10 m. Razlozi za to mogu biti razni: frekvencija snimanja, miješanje slatke i slane vode na području snimanja (haloklina), broj kratkih akustičkih signala (engl. *ping rate)* koju MBES mjeri u sekundi te operativna širina pojasa (engl. *operational bandwidth*).

Broj akustičnih signala (engl. *ping rate*)

Broj akustičkih signala ovisi o dubini vode, a može iznositi i do 60 signala u sekundi u plitkoj vodi. U intervalnim je snimanja testne plohe *ping rate* bio tek 12. Visok broj kratkih akustičkih signala znači da se prikuplja mnogo više podataka. MBES kontinuirano odašilje kratke akustične signale prema morskome dnu koji su karakterizirani duljinom i amplitudom.

Duljina zvučnih signala (engl. *pulse lenght*) i **širina pojasa** (engl. *bandwidth*)

Duljina odaslanih zvučnih signala obrnuto je proporcionalna vertikalnoj rezoluciji (Hellequin i dr., 2003) i širini pojasa (engl. *bandwidth*) (URL 50). Što je duljina odaslanih zvučnih signala (engl. *pulse lenght*) kraća/manja, to je veća vertikalna rezolucija snimanja. Snimanje s kratkom duljinom zvučnih signala moguće je s MBES-om visokih performansi izvrsne elektronike koji stvaraju malo ili nimalo buke. Širina pojasa *(*engl. *bandwidth)* je prilikom snimanja testne plohe iznosila 40 kHz, a kontrolira se duljinom odaslanih zvučnih signala (engl. *pulse width*). Što je manja duljina odaslanih zvučnih signala, to je viša širina pojasa i veća rezolucija te bolja detekcija morskoga dna (Le Bouffant i dr., 2013). Primjerice, na manjim duljinama odaslanih zvučnih signala širina pojasa iznosi 60 kHz što rezultira boljom rezolucijom morskog dna (Slika 56).



Slika 56. Primjer detaljnosti morskog dna pri različim širinama pojasa

Izvor: URL 51

Operativna frekvencija (engl. *operative frequency*)

U ovisnosti o dubini područja istraživanja, važno je upotrebljavati optimalnu frekvenciju, s ciljem dobivanja točnih i kvalitetnih podataka. Naime, snimanje niskofrekventnim valovima karakteristično je za dublja područja (npr. valne duljine frekvencije 90 ili 100 kHz optimalne su za snimanja područja od 700 m dubine, ili čak i dublja), dok su visoke frekvencije optimalne za snimanje plićih područja (URL 50) ili za snimanje detalja na morskom dnu, kao što je npr. otpad. Primjerice, Madricardo i dr. (2019) su koristili MBES podatke visoke rezolucije kako bi procijenili brojnost morskog makro otpada na velikom području Venecijanske lagune. MBES snimanje je izvedeno pod frekvencijom od čak 360 kHz. Snimanje visokom frekvencijom uzrokuje smanjenje kuta snimanja (engl. *beam angle*) u odnosu na niskofrekventno snimanje. U ovom slučaju korišten je *WASSP S3* koji ima frekvenciju od 160 kHz. Ovaj MBES sustav ne podržava promjenu, odnosno povećanje frekvencije snimanja.

Brzina plovidbe

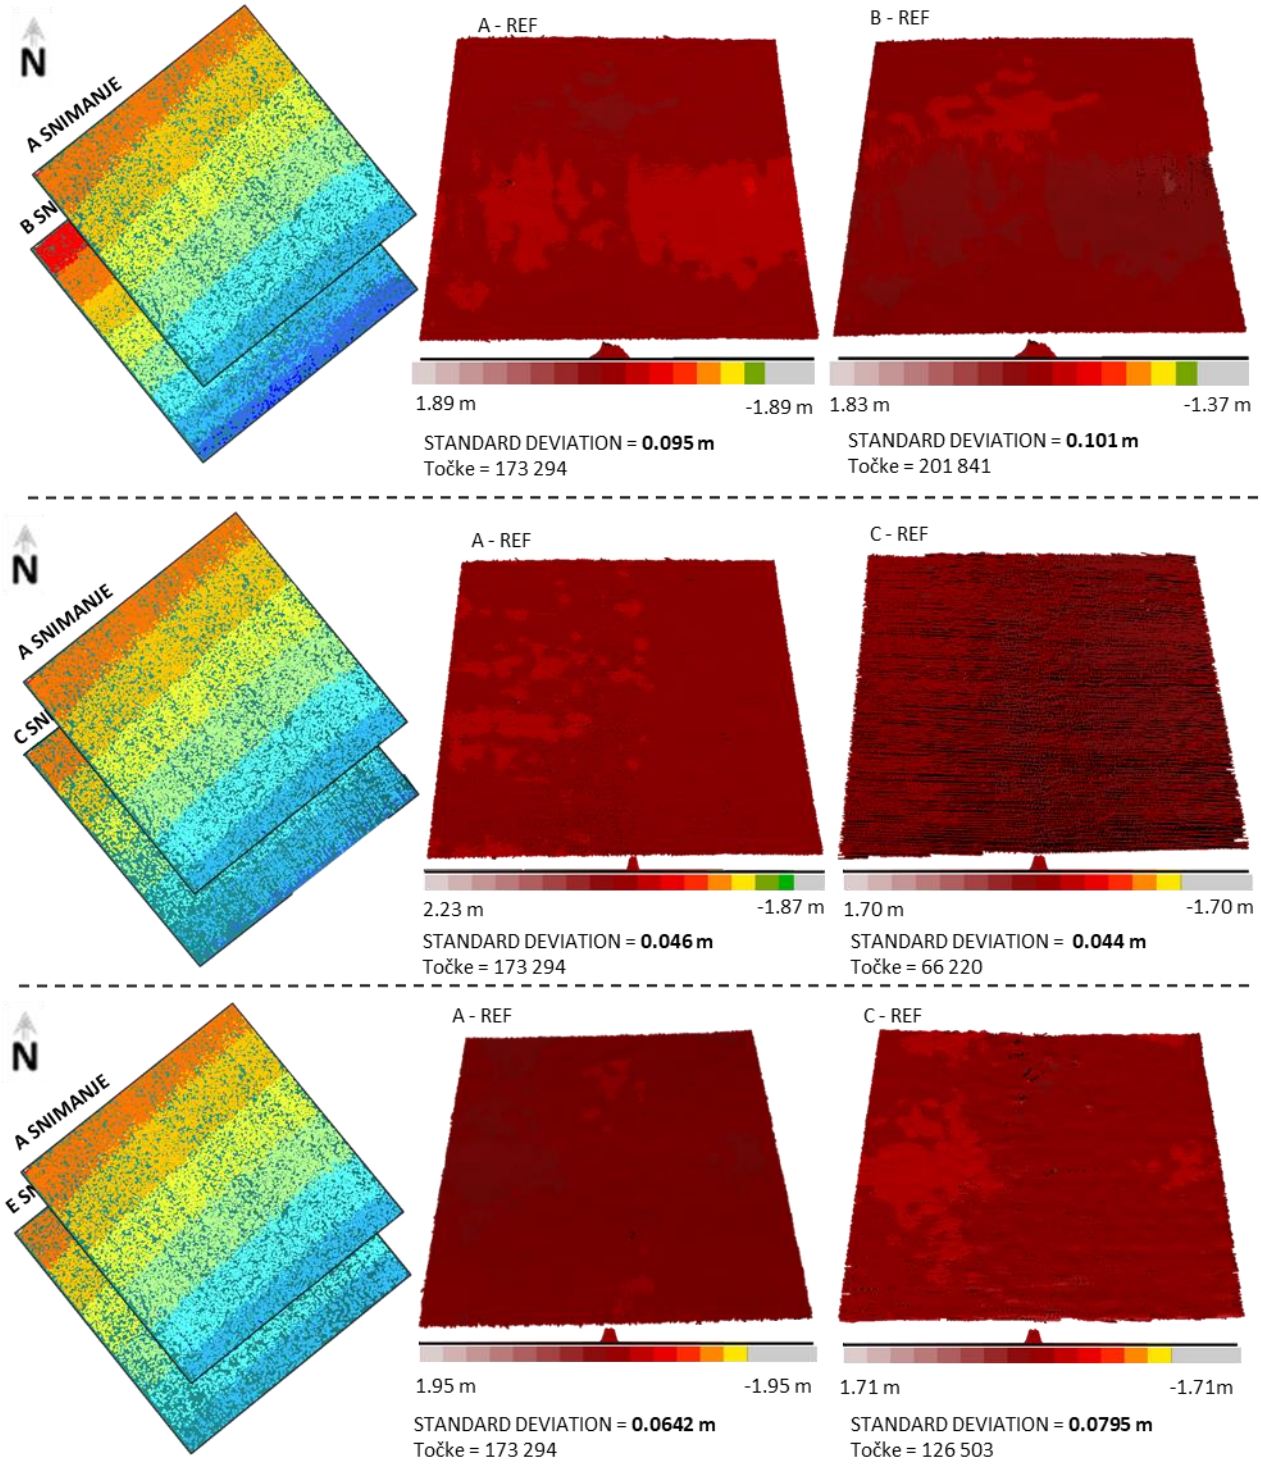
Brzina plovidbe prilikom snimanja također može imati utjecaj na izlazne rezultate. Naime, ovisno o specifikacijama senzora i snimanog područja, određuje se maksimalna dopuštena brzina kojom će se osigurati potpuna pokrivenost snimljenog područja (URL 50). Naime, što je brže snimanje određenog područja, to će biti veće rupe u podacima (Gallway, 2000). Snimanje se testne plohe provodilo pri različitim brzinama, s ciljem dokazivanja utjecaja brzine plova na dobivene rezultate. Maksimalna je brzina snimanja iznosila 4,5 čvora, a minimalna 1,5 čvor. Gotovo se sav morski otpad nije uspio detektirati niti pri najmanjoj brzini plova. Posrednom analizom, ali ne sa stopostotnom sigurnošću, iz gustog oblaka točaka uočen je tek lim u sredini testne plohe. Dakle, u ovom slučaju brzina plovidbe ne može biti razlog izostanka detekcije otpada.

Miješanje slane i slatke vode (haloklina)

Područje istraživanja ujedno je i dio estuarija rijeke Krke, što treba uzeti u obzir prilikom interpretacije dobivenih rezultata. Naime, uslijed miješanja slatke i slane vode dolazi do promjene brzine zvuka u vodi. Ukoliko ona nije poznata, izlazni rezultati neće biti točni, što će biti najvidljivije na krajevima snimaka koji će pokazivati da je snimljeno područje pliće ili dublje od ostatka linije (Snellen i dr., 2009). Shodno navedenom, izlazni rezultati koji nisu pokazali nikakav morski otpad na morskome dnu mogu biti posljedica upravo miješanja voda različitog saliniteta, iako je ovakav razlog teško vjerojatan.

5.2.3 Ispitivanje preciznosti MBES

U nastavku je dan pregled udaljenosti između šest intervalnih snimanja testne plohe, odnosno izvedenih MBES oblaka točaka. Analiza udaljenosti izvedena je primjenom M3C2 algoritma unutar *CloudCompare*-a. Na slici 57 prikazan je dio izvedenih modela udaljenosti između A snimanja (brzina 1,5 čvor smjer SI i JZ) te B, C i E snimanja.



Slika 57. Modeli udaljenosti izvedeni u M3C2 alatu između A te B, C i E snimanja

U tablici 8 dan je pregled svih vrijednosti standardnih devijacija (SD) izvedenih za sve moguće kombinacije intervalnog snimanja. j

Tablica 8. Izračun SD između sve moguće kombinacije scenarija snimanja

ID	Usporedba	REF	Broj uzoraka	SD	ID	Usporedba	REF	Broj uzoraka	SD
1	A-B	A	173294	0,095	16	A-D	D	84381	0,073
2	A-C	A	173294	0,046	17	B-D	D	84381	0,058
3	A-E	A	173294	0,064	18	C-D	D	84381	0,087
4	A-D	A	173294	0,088	19	E-D	D	84381	0,057
5	A-F	A	173294	0,036	20	F-D	D	84381	0,080
6	A-B	B	201841	0,101	21	A-E	E	126503	0,080
7	B-C	B	201841	0,103	22	B-E	E	126503	0,081
8	B-D	B	201841	0,070	23	C-E	E	126503	0,075
9	B-E	B	201841	0,076	24	D-E	E	126503	0,080
10	**B-F**	**B**	**201841**	**0,100**	25	F-E	E	126503	0,076
11	A-C	C	66220	0,044	**26**	**A-F**	**F**	**101461**	**0,037**
12	B-C	C	66220	0,097	27	B-F	F	101461	0,098
13	C-D	C	66220	0,091	28	C-F	F	101461	0,056
14	C-E	C	66220	0,065	29	D-F	F	101461	0,091
15	C-F	C	66220	0,049	30	E-F	F	101461	0,066
						MEAN			**0,0740**

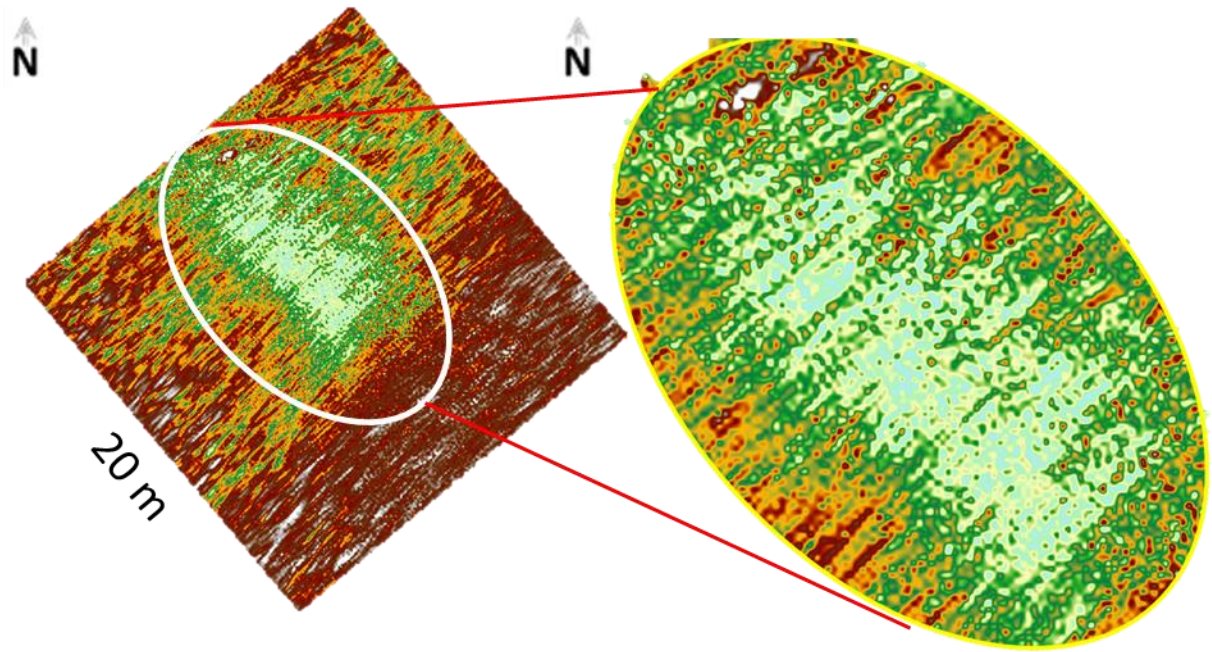
Najveća SD u iznosu od 10 cm između uspoređenih oblaka točaka odnosi se na oblak točaka izveden u snimanju B (1,5 čvor, JI - SZ) te oblaka točaka izvedenog u snimanju F (3 čvora, SI - JZ) gdje se oblak točaka B promatrao kao referentni. Najmanja SD izmjerena je između oblaka točaka F (3 čvora, SI - JZ) te oblaka točaka A (1,5 čvor, SI - JZ), a iznosi 3,7 cm. U navedenom slučaju oblak točaka F postavljen je kao referentni. Prosječna SD gdje su kao referentni modeli postavljeni oblaci točaka izvedeni iz snimanja s najvećom brzinom (4,5 čvora) plovidbe (C, D) iznosi 7 cm. Navedeno dokazuje da oblaci točaka, usprkos puno manjoj gustoći uzorkovanja, koji su izvedeni pri maksimalnoj brzini kretanja plovila ne odstupaju značajno od oblaka točaka izvedenih pri gotovo minimalnoj brzini kretanja od 1,5 čvora. Srednja vrijednost SD svih proučavanih oblaka točaka izvedenih iz svih snimanja iznosi 7,4 cm. M3C2 analiza potvrdila je značajnu podudarnost svih uspoređenih oblaka točaka, odnosno visoku pouzdanost *WASSP*-a *S3*.

5.2.4 Rezultati senzora povratnog raspršenja

Sustav senzora povratnog raspršenja *WASSP S3* prikazuje refleksiju tvrdoće morskog dna, što pomaže razlikovati tvrdi (stijene) i meki (mulj) materijal u područjima na morskom

dnu. Senzor povratnog raspršenja idealan je za operacije istraživanja, identificiranje ribljih staništa ili lociranje prikladnog sidrišta.

U ovom istraživanju, od svih provedenih MBES intervalnih snimanja, generiran je model tvrdoće dna samo za prvo snimanje (A). Na slici 58 može se vidjeti model tvrdoće morskog dna za snimanje A odabrane testne plohe. Može se uočiti da postoji varijabilnost u tvrdoći materijala u središnjem dijelu testne plohe. Međutim, s obzirom na poznavanje lokacije morskog otpada unutar testne plohe, koja je određena iz DOF snimka generiranog UAV i ROV-om, ipak nije moguće utvrditi detekciju otpada na morskom dnu koristeći senzor povratnog raspršenja. Razlog tome povezan je s navedenim razlozima detaljnosti kartiranja korištenog senzora koji su objašnjeni u poglavlju 5.2.2. Razlozi izostanka detekcija otpada primjenom MBES-a.



Slika 58. Model tvrdoće morskog dna za snimanje A - izostanak obrisa morskog otpada

5.3 Smjernice za primjenu MBES-a i ROV-a u detekciji otpada na morskom dnu

Od 2017. se godine u Republici Hrvatskoj (RH) provode kontinuirana sustavna praćenja morskog otpada naplavljenog na obali, na površini mora i na morskom dnu, mikroplastike na površini mora i plažama te progutani morski otpad (morski organizmi). Primjenjuje se metodologija sukladna zahtjevima *Okvirne direktive o morskoj strategiji Europskog parlamenta* (ODMS). Međutim, ističe se da su spoznaje o pritiscima i negativnim utjecajima morskog otpada još uvijek nepotpune.

Prema dokumentu *Plan gospodarenja morskim otpadom*, izdanom u svibnju 2020. godine od strane Ministarstva gospodarstva i održivog razvoja navodi se da je u RH problematika morskog otpada obuhvaćena krovnim *Zakonom o održivom gospodarenju otpadom* (NN, br. 94/13, 73/17, 14/19 i 98/19). U odlomku *1.1.3. Sastav, količina i prostorna raspodjela krupnog otpada na morskom dnu* navodi se da je morski otpad prikupljen primjenom koćarskih lovina u okviru projekta MEDITS[1].

Iz rezultata ovog istraživanja mogu se izvući sljedeće smjernice primjene ROV-a i MBES-a u detekciji otpada na morskom dnu :

- **(Vizualna inspekcija morskog otpada primjenom ROV-a**)

Sukladno primjerima dobre prakse (Ioakeimidis i dr., 2015; Consoli i dr., 2018; Enrichetti i dr., 2020; Constanzo i dr., 2020; Escobar-Sánchez i dr., 2022) osnovni se paket opreme ROV-a može koristiti za inicijalnu vizualnu inspekciju otpada na morskom dnu s naglaskom na ona područja gdje morski otpad nije moguće identificirati ronjenjem ili pridnenim povlačnim mrežama. Navedeno se primarno odnosi na vizualnu inspekciju morskog otpada u plitkim vodama gdje je otežano korištenje pridnenih koćarica. Nadalje, u detekciji otpada na morskom dnu u plitkim vodama najčešće se primjenjuje metoda ronjenja s bocom koja, iako je široko primjenjiva i validirana, može biti vremenski intenzivna, zahtjevati visoke troškove, stručnost i napor većeg tima (Escobar-Sánchez i dr., 2022). Klasifikacija se otpada prema vrsti materijala i veličini objekta na morskom dnu može napraviti empirijski, pomnim pregledavanjem snimljenih videozapisa i izvedenih fotografija (Ioakeimidis i dr., 2015). Međutim, potrebno je biti svjestan nedostatka primjene ROV-a u vizualnoj inspekciji, a to je moguće podcjenjivanje količine otpada na morskom dnu budući da zakopane elemente morskog otpada nije moguće detektirati. Nadalje, njegova primjena u klasifikaciji objekata može biti ograničena lošim uvjetima vidljivosti.

- **(Razvijanje svijesti očuvanja morskog okoliša - ROV)**

Morski je otpad veliki ekološki problem u kojem ljudsko ponašanje igra glavnu ulogu. Primjena ROV-a u promotivne svrhe, čak i samo osnovnog paketa, gdje se ne radi detaljna morfometrijska analiza morskog otpada, pomaže u razvijanju svijesti o njegovom negativnom utjecaju na morski okoliš (Ioakeimidis i dr., 2015). Navedeno je osobito kod učinkovito kod mlađih generacija (Lallensack, 2018).

- **(Preselekcija lokacija za inspekciju otpada - GIS/MCDA)**

[1] Mediterranean International Bottom Trawl-Srveys

U velikom broju istraživanja odabir lokacija za monitoring otpada određuje se bez provođenja složenijih analiza. S obzirom na to da se ROV ne može primjenjivati za velike transkte predlaže se pažljiviji izbor lokacija za vizualnu inspekciju morskog dna. Naime, odabrane najpodložnije lokacije pojave otpada na morskom dnu mogu se izdvojiti primjenom višekriterijskih GIS analiza (engl. *multiple-criteria decision analysis*) s obzirom da brojna istraživanja (Ioakeimidis i dr., 2015) pokazuju povezanost između pojave morskog otpada te sljedećih parametar: udaljenost od kopna, blizina ribarskih ruta, udaljenost od naselja, turistička aktivnosti, gustoća naseljenosti, dubina mora, morske struje. Ovo bi potencijalno rezultiralo boljim uvidom u stvarnu distribuciju otpada na morskom dnu.

- **(MBES - optimizacija parametara)**

Akustička istraživanja za kartiranje mikro-mezo i makro otpada na morskom dnu mogu potencijalno pomoći u popunjavanju praznina u znanju, no potrebno je pažljivo odabrati specifikacije MBES uređaja, odnosno korisnički definirane parametre prilikom MBES snimanja. Ako se žele detektirati manji oblici morskog otpada na morskom dnu frekvencija MBES snimanja mora biti veća, broj akustičnih signala (*ping rate*) mora biti veći te širina pojasa (*bandwidth*) mora biti manja.

6. ZAKLJUČAK

U radu je ispitana primjenjivost podvodne bespilotne ronilice (ROV) *Chasing M2* i višesnopnog dubinomjera (MBES) *WASSP S3* u kartiranju, odnosno detekciji i kvantifikaciji morskog otpada na širem području kanala Sv. Ante (Šibenik) u blizini istraživačke postaje Martinska (Institut Ruđer Bošković). Prema izvedenim rezultatima u nastavku su potvrđene ili odbaćene postavljene hipoteze istraživanja.

- **(H1)** Uređaj za mjerenje tvrdoće dna (engl. *backscatter*) omogućit će klasifikaciju morskog otpada prema tvrdoći materijala.

Prva hipoteza (H1) je odbačena. Senzor povratnog raspršenja koji je namjenjen za mjerenje tvrdoće dna nije omogućio detekciju i klasifikaciju morskog otpada prema tvrdoći materijala. Iako se može uočiti da postoji varijabilnost u tvrdoći materijala u središnjem dijelu testne plohe gdje se i nalazio otpad na morskom dnu, prikaz je pregeneral te nije moguće utvrditi mogućnost detekcije otpada na morskom dnu koristeći senzor povratnog raspršenja. Razlog tome povezan je s detaljnim specifikacijama korištenog senzora.

- **(H2)** Višesnopni dubinomjer će omogućiti kartiranje otpada minimalne širine 20 cm na dubinama do 10 metara.

Druga hipoteza (H2) je odbačena. MBES *WASSP S3* nije omogućio kartiranje otpada minimalne širine 20 cm na dubinama do 10 metara. Kroz analizu digitalnih modela dubina i nefiltriranog oblaka točaka dobivenog pri najmanjim brzinama snimanja utvrđena je minimalna jedinica kartiranja, odnosno najmanji detektiran objekt morskog otpada, koji *WASSP S3* na dubini do 10 m može detektirati. Njegova površina iznosi 100 cm * 100 cm, s visinom od oko 40 cm.

- **(H3)** Preciznost višesnopnog dubinomjera će biti manja od 10 cm na dubinama do 10 metara pri različitim brzinama snimanja

Treća hipoteza (H3) je potvrđena. Intervalna MBES mjerenja utvrdila su da *WASSP S3* ima centimetarsku pouzdanost mjerenja (<10 cm) pri različim brzinama plovidbe. Naime, prosječna SD gdje su kao referentni modeli postavljeni oblaci točaka izvedeni iz snimanja s najvećom brzinom (4,5 čvora) plovidbe (C, D) iznosi 7 cm. Navedeno dokazuje da oblaci točaka, usprkos puno manjoj gustoći uzorkovanja, koji su izvedeni pri maksimalnoj brzini kretanja plovila, ne odstupaju značajno od oblaka točaka izvedenih pri gotovo minimalnoj brzini kretanja od 1,5 čvora. Srednja vrijednost SD svih proučavanih oblaka točaka izvedenih

iz svih snimanja iznosi 7,4 cm. M3C2 analiza potvrdila je značajnu podudarnost svih uspoređenih oblaka točaka, odnosno visoku pouzdanost dubinomjera *WASSP S3*.

Nadalje, utvrđeno je da se ROV *Chasing M2* može učinkovito primjenjivati u inicijalnoj detekciji otpada u plitkim vodama. Međutim, u slučaju nekorištenja sustava podvodne navigacije ROV-a te pomoćnih mjerenih skala, ROV ima ograničene mogućnosti u kvantifikaciji otpada na morskom dnu. Navedeno je utvrđeno usporedbom morfometrijskih parametara gume koji su izvedeni iz 3D modela ručnim 3D skenerom.

Dobiveni rezultati pomogli su oblikovanju smjernica za primjenu MBES-a i ROV-a u detekciji otpada na morskom dnu koji su sažeti u odlomku *5.3 Smjernice za primjenu MBES-a i ROV-a u detekciji otpada na morskom dnu*.

7. LITERATURA

1) Alomar, C., Compa, M., Deudero, S., & Guijarro, B. (2019). Spatial and temporal distribution of marine litter on the seafloor of the Balearic Islands (western Mediterranean Sea). Deep Sea Research Part I: Oceanographic Research Papers, 103178.

2) Andrady, A. L. (2011). Microplastics in the marine environment. Marine Pollution Bulletin, 62(8), 1596–1605.

3) Bašić, T. (1993). Primjena satelitske altimetrije u istraživanju Zemljinog polja sile teže na Jadranu (The Use of Satellite Altimetry for the Gravity Field Investigation in the Area of Adriatic Sea)

4) Bauer, L., Kendall, M., and Jeffrey, C. (2008). Incidence of marine debris and its relationships with benthic features in Gray's Reef National Marine Sanctuary, Southeast USA. Mar. Pollut. Bull. 56, 402–413. doi: 10.1016/j.marpolbul.2007.11.001

5) Brown, C. J., & Blondel, P. (2009). Developments in the application of multibeam sonar backscatter for seafloor habitat mapping. Applied Acoustics, 70(10), 1242–1247.

6) Buhl-Mortensen, L., Buhl-Mortensen, P., Dolan, M. F. J., & Holte, B. (2014). The MAREANO programme – A full coverage mapping of the Norwegian off-shore benthic environment and fauna. Marine Biology Research, 11(1), 4–17.

7) Bule, K., Zadro, K., Tolić, A., Radin, E., Milološa, M., Bulatović, V. O., & Grgić, D. K. (2020). Mikroplastika u morskom okolišu Jadrana. Kemija u Industriji, 69.

8) Christ D. R., Wernli L.R. (2007). The ROV Manual: A User Guide for Observation Class Remotely Operated Vehicles, Elsevier Ltd., 2007., Oxford

9) Cincinelli, A., Martellini, T., Guerranti, C., Scopetani, C., Chelazzi, D., & Giarrizzo, T. (2018). A potpourri of microplastics in the sea surface and water column of the Mediterranean Sea. TrAC Trends in Analytical Chemistry

10) Consoli, P., Falautano, M., Sinopoli, M., Perzia, P., Canese, S., Esposito, V., Battaglia, P., Romeo, T., Andaloro, F., Galgani, F., Castriota, L. (2018). Composition and abundance of benthic marine litter in a coastal area of the central Mediterranean Sea. Marine Pollution Bulletin, 136, 243–247.

11) Constanzo, L. G., Marletta, G., Alongi, G. (2020). Assesment of Marine Litter in the Coralligenous Habitat of a Marine Protected Area along the Ionian Coast of Sicily (Central mediterranean). Marine Science and Engineering 8(9):656

12) Derraik, J. G. (2002). The pollution of the marine environment by plastic debris: a review. Marine Pollution Bulletin, 44(9), 842–852.

13) Domazetović, F. (2021). Višerezolucijsko modeliranje erozije tla korištenjem geoprostornih tehnologija, Doktorski rad, Odjel za geografiju, Sveučilište u Zadru, Zadar.

14) Drap, P. (2012). Underwater photogrammetry for archaeology. Special applications of photogrammetry, 114.

15) Elhassan, I. (2015.a). Bathymetric Techniques, Civil Eng. Dept., King Saud University, Riyadh

16) Elhassan, I. (2015.b). Development of Bathymetric Techniques, Civil Eng. Dept., King Saud University, Riyadh

17) Enrichetti, F., Dominguez-Carrió, C., Toma, M., Bavestrello, G., Canese, S., & Bo, M. (2020). Assessment and distribution of seafloor litter on the deep Ligurian continental shelf and shelf break (NW Mediterranean Sea). Marine Pollution Bulletin, 151, 110872.

18) Escobar-Sánchez, G., Markfort, G., Berghald, M., Ritzenhofen, L., & Schernewski, G. (2022). Aerial and underwater drones for marine litter monitoring in shallow coastal waters: factors influencing item detection and cost-efficiency. Environmental monitoring and assessment, 194(12), 863.

19) Fakiris, E., Papatheodorou, G., Kordella, S., Christodoulou, D., Galgani, F., & Geraga, M. (2022). Insights into seafloor litter spatiotemporal dynamics in urbanized shallow Mediterranean bays. An optimized monitoring protocol using towed underwater cameras. Journal of Environmental Management, 308, 114647.

20) Gajski, D. (2007). Osnove laserskog skeniranja iz zraka. Ekscentar, (10), 16-22.

21) Galgani L., Beiras R., Galgani F., Panti C.,Borja A. (2019). Editorial: Impacts of Marine Litter. Front. Mar. Sci. 6:208.

22) Galgani, F., Hanke, G., Maes, T. (2015). Global Distribution, Composition and Abundance of Marine Litter. In: Bergmann, M., Gutow, L., Klages, M. (eds) Marine Anthropogenic Litter. Springer, Cham

23) Galgani, F., Hanke, G., Werner, S., De Vrees, L. (2013). Marine litter within the European Marine Strategy Framework Directive, ICES Journal of Marine Science, Volume 70, Issue 6, September 2013, Pages 1055–1064

24) Galway, Sean. (2000). Comparision of Target Detection Capabilities of the Reson Seabat 8101 and Reson Seabat 9001 Multibeam Sonars.

25) Gavrilov, A. N., & Parnum, I. M. (2010). Fluctuations of Seafloor Backscatter Data From Multibeam Sonar Systems. IEEE Journal of Oceanic Engineering, 35(2), 209–219.

26) Gerigny, O., Brun, M., Fabri, M. C., Tomasino, C., Le Moigne, M., Jadaud, A., et al. (2019). Seafloor litter from the continental shelf and canyons in French Mediterranean water:

distribution, typologies and trends. Mar. Pollut. Bull. 146, 653–666. doi: 10.1016/j.marpolbul.2019.07.030

27) Gonçalves, G., Andriolo, U., Pinto, L., & Duarte, D. (2020). Mapping marine litter with Unmanned Aerial Systems: A showcase comparison among manual image screening and machine learning techniques. Marine Pollution Bulletin, 155, 111158.

28) Goodman, A. J., Walker, T. R., Brown, C. J., Wilson, B. R., Gazzola, V., & Sameoto, J. A. (2020). Benthic marine debris in the Bay of Fundy, eastern Canada: Spatial distribution and categorization using seafloor video footage. Marine pollution bulletin, 150, 110722.

29) Grgić, M., Jukić-Vrgorac, S., Nerem-Boulder, R.S., Bašić, T. (2017). Satelitska altimetrija: tehnologija i primjena u geodeziji, Geodetski list 2017, 4, 307–326

31) Guenther G. 2007. Airborne LiDAR bathymetry digital elevation. In Model Technologies and Applications: The DEM Users Manual, Maune D (ed.). American Society for Photogrammetry and Remote Sensing: Bethesda, MD

30) Gvozdenović, S., Mačić, V., Petović, S., Đorđević, N., Mandić, M. (2021). Seafloor litter in two protected areas (Sopot and Dražin vrt) in the Boka Kotorska Bay (Montenegro, southeast Adriatic Sea). Studia Marina 2021, 34 (2): 23-33

31) Hell, B. (2011). Mapping bathymetry: From measurement to applications (PhD dissertation, Department of Geological Sciences, Stockholm University)

32) Hellequin, L., Boucher, J.-M., & Lurton, X. (2003). Processing of high-frequency multibeam echo sounder data for seafloor characterization. IEEE Journal of Oceanic Engineering, 28(1), 78–89.

33) Hughes Clarke, J. E. (2018). "Multibeam echosounders," in Submarine Geomorphology, eds A. Micallef, S. Krastel, and A. Savini (Cham: Springer), 25–41. doi: 10.1007/978-3-319-57852-1_3

34) Hughes Clarke, J. E., Mayer, L. A., Shaw, J., Parrott, R., Lamplugh, M., and Bradford, J. (1999). "Data handling methods and target detection results for multibeam and sidescan data collected as part of the search for SwissAir Flight 111," in Proceedings of the Shallow Water Survey Conference (SWS), Durham, NH.

35) Huvenne, V. A., Robert, K., Marsh, L., Iacono, C. L., Le Bas, T., and Wynn, R. B. (2018). "Rovs and auvs," in Submarine Geomorphology, eds A. Micallef, S. Krastel, and A. Savini (Cham: Springer), 93–108.

36) Ioakeimidis, C., Papatheodorou, G., Fermeli, G., Streftaris, N., Papathanassiou, E. (2015). Use of ROV for assessing marine litter on the seafloor of Saronikos Gulf (Greece): a way to fill data gaps and deliver environmental education. SpringerPlus, 4(1).

37) Irish, J. L., & White, T. E. (1998). Coastal engineering applications of high-resolution lidar bathymetry. Coastal Engineering, 35(1-2), 47–71

38) James, M. R., Robson, S., i Smith, M. W. (2017). 3-D uncertainty-based topographic change detection with structure-from-motion photogrammetry: precision maps for ground control and directly georeferenced surveys. Earth Surface Processes and Landforms, 42(12), 1769-1788

39) Jeftić, Lj., Sheavly, S., Adled, E., (2009). UNEP, 2009. Marine Litter: A Global Challenge. Nairobi: UNEP. 232 pp.

40) Jin, S., Sun, W., Bao, J., Liu, M., Cui, Y. (2015). Sound velocity profile (SVP) inversion trough correcting the terrain distortion, International Hydrographic, Review, Department of Hydrography and Cartography, Dalian Naval Academy, China

41) Jong, C. D., Lachapelle, G., Skone, S., Elema, I. A., (2002). Hydrography, Delft University Press, Netherlands.

42) Kalacska, M., Lucanus, O., Sousa, L., Vieira, T., & Arroyo-Mora, J. P. (2018). Freshwater fish habitat complexity mapping using above and underwater structure-from-motion photogrammetry. Remote Sensing, 10(12), 1912.

43) 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

44) Kim, M., Hizir, O., Turan, O., Day, S., & Incecik, A. (2017). Estimation of added resistance and ship speed loss in a seaway. Ocean Engineering, 141, 465–476

45) Klump, J. V., Padock, R. W., Babb, I. G., & Auster, P. J. (n.d.). The evolution and development of the small ROV as an essential experimental tool in limnological and coastal marine research. MTS/IEEE Oceans 2001. An Ocean Odyssey. Conference Proceedings

46) Kühn, S., Bravo Rebolledo, E. L., & van Franeker, J. A. (2015). Deleterious Effects of Litter on Marine Life. Marine Anthropogenic Litter, 75–116.

47) Kwasnitschka, T., Hansteen, T. H., Devey, C. W., & Kutterolf, S. (2013). Doing fieldwork on the seafloor: Photogrammetric techniques to yield 3D visual models from ROV video. Computers & Geosciences, 52, 218–226.

48) Kwokal, Ž., Štefanović, B. (2009). Plutajući otpad iz mora zanemarivanje ne znači nepostojanje, Adriatic Boat Show 2009, Šibenik, Hrvatska, str. 17–21

49) Lacharité, M., Brown, C. J., Gazzola, V. (2018). Multisource multibeam backscatter data: Developing a strategy for the production of benthic habitat maps using semi-automated seafloor classification methods. Marine Geophysical Research, 39(1), 307-322.

50) Lallensack, R. (2018) This 12-Year-Old Girl Built a Robot That Can Find Microplastics In the Ocean, dostupno na: https://www.smithsonianmag.com/innovation/12-year-old-girl-built-robot-can-find-microplastics-ocean-180970607/, 24.10.2022.

51) Le Bouffant, N., Berger, L., & Lurton, X. (2013, January). Simple method for multiple soundings extraction for wide beamwidth echosounders. In UAM 2013-1st international conference and exhibition on Underwater Acoustics (UA2013), 23-26 June 2013, Corfu island, Greece.Lim, A., Huvenne, V. A. I., Vertino, A., Spezzaferri, S., & Wheeler, A. J. (2018). New insights on coral mound development from groundtruthed high-resolution ROV-mounted multibeam imaging. Marine Geology, 403, 225–237.

52) Löhr, A., Savelli, H., Beunen, R., Kalz, M., Ragas, A., Van Belleghem, F., (2017). Solutions for global marine litter pollution, Current Opinion in Environmental Sustainability, Volume 28, Pages 90-99, ISSN 1877-343

53) Lurton, X., Lamarche, G., Brown, C., Lucieer, V. L., RIce, G., Schimel, A., & Weber, T. (2015). Backscatter measurements by seafloor-mapping sonars: guidelines and recommendations. A collective report by members of the GeoHab Backscatter Working Group, (May), 1-200.

54) Lusher, A. (2015). Microplastics in the Marine Environment: Distribution, Interactions and Effects. Marine Anthropogenic Litter, 245–307.

55) Madricardo, F., Foglini, F., Campiani, E., Grande, V., Catenacci, E., Petrizzo, A., Kruss, A., Toso, C. & Trincardi, F. (2019). Assessing the human footprint on the sea-floor of coastal systems: the case of the Venice Lagoon, Italy. Scientific Reports, 9(1).

56) Madricardo, F., Ghezzo, M., Nesto, N., Mc Kiver, W. J., Faussone, G. C., Fiorin, R., ... & Moschino, V. (2020). How to deal with seafloor marine litter: an overview of the state-of-the-art and future perspectives. Frontiers in Marine Science, 7, 505134.

57) Maes, T., Barry, J., Leslie, H. A., Vethaak, A. D., Nicolaus, E. E. M., Law, R. J., et al. (2018). Below the surface: twenty-five years of seafloor litter monitoring in coastal seas of North West Europe (1992–2017). Sci. Total Environ. 630, 790–798. doi: 10.1016/j.scitotenv.2018.02.245

58) Mateo-Pérez, V., Corral-Bobadilla, M., Ortega-Fernández, F., & Vergara-González, E. P. (2020). Port Bathymetry Mapping Using Support Vector Machine Technique and Sentinel-2 Satellite Imagery. Remote Sensing, 12(13), 2069.

59) Matika, D., & Liović, I. (2014). Suvremene bespilotne ronilice (podvodna vozila). Polytechnic and design, 2(2), 236-247.

60) Mayer, L. A., Raymond, R., Glang, G., Richardson, M. D., Traykovski, P., and Trembanis, A. C. (2007). High-resolution mapping of mines and ripples at the Martha's Vineyard coastal observatory. IEEE J. Ocean. Eng. 32, 133–149. doi: 10.1109/joe.2007.890953

61) Oliveira, F., Monteiro, P., Bentes, L., Henriques, N. S., Aguilar, R., and Gonçalves, J. M. S. (2015). Marine litter in the upper São Vicente submarine canyon (SW Portugal): abundance, distribution, composition and fauna interactions. Mar. Pollut. Bull. 97, 401–407. doi: 10.1016/j.marpolbul.2015.05.060

62) Parnum, I. M., & Gavrilov, A. N. (2011). High-frequency multibeam echo-sounder measurements of seafloor backscatter in shallow water: Part 1 – Data acquisition and processing. Underwater Technology, 30(1), 3–12.

63) Pham, C. K., Ramirez-Llodra, E., Alt, C. H. S., Amaro, T., Bergmann, M., Canals, M, Company, J- B., Davies, J., Duineveld, G., Galgani, F., Howell, K. L., Huvenne, V. A., Isidro, E., Jones, D. O. B., Lastras, G., Morato, T., Gomes-Pereira, J. N., Purser, A., Stewart, H., Tojeira, I., Tubau, X., Rooij, D. V., Tyler, P. A. (2014). Marine Litter Distribution and Density in European Seas, from the Shelves to Deep Basins. PLoS ONE, 9(4), e95839.

64) Pierdomenico, M., Casalbore, D., and Chiocci, F. L. (2019). Massive benthic litter funnelled to deep sea by flash-flood generated hyperpycnal flows. Sci. Rep. 9:5330.

65) Price, D. M., Robert, K., Callaway, A., Hall, R. A., & Huvenne, V. A. (2019). Using 3D photogrammetry from ROV video to quantify cold-water coral reef structural complexity and investigate its influence on biodiversity and community assemblage. Coral Reefs, 38(5), 1007-1021.

66) Radionov Radenković, N. i Mandžuka, S. (2007). Autonomne podvodne ronilice: Novi pojam hrvatskog pomorskog prava. Poredbeno pomorsko pravo, 46 (161), 41-62.

67) Rochman, C. M. (2015). The Complex Mixture, Fate and Toxicity of Chemicals Associated with Plastic Debris in the Marine Environment. Marine Anthropogenic Litter, 117–140.

68) Ryan, P. G. (2015). A Brief History of Marine Litter Research. Marine Anthropogenic Litter, 1–25.

69) Simons, D. G., Snellen, M. (2009). A Bayesian approach to seafloor classification using multi-beam echo-sounder backscatter data. Applied Acoustics, 70(10), 1258-1268.

70) Snellen, M., Siemes, K., & Simons, D. G. (2009). A model-based method for reducing the sound speed induced errors in multi-beam echo-sounder bathymetric measurements. OCEANS 2009-EUROPE

71) Spedicato, M. T., Zupa, W., Carbonara, P., Fiorentino, F., Follesa, M. C., Galgani, F., et al. (2019). Spatial distribution of marine macro-litter on the seafloor in the northern Mediterranean Sea: the MEDITS initiative. Sci. Mar. 83, 257–270.

72) Strižak, Z. i Vudrag, V. (2005). Satelitska altimetrija i razumijevanje topografije oceana. Ekscentar, (7), 75-80.

73) Šiljeg, A. (2013.): Digitalni model reljefa u analizi geomorfometrijskih parametara – primjer PP Vransko jezero, disertacija, PMF – Geografski odsjek, Sveučilište u Zagrebu.

74) Šiljeg, A., Marić, I., Domazetović, F., Cukrov, N., Lovrić, M. & Panđa, L. (2022). Bathymetric Survey of the St. Anthony Channel (Croatia) Using Multibeam Echosounders (MBES)- A New Methodological Semi-Automatic Approach of Point Cloud Post-Processing. Journal of Marine Science and Engineering, 10(1), 101

75) Šiljeg, A.; Barada, M., Marić, I. (2018). Digitalno modeliranje reljefa, sveučilišni priručnik, Sveučilište u Zadru, Alfa d.d., Zagreb

76) Terzi, Y., Erüz, C., & Özşeker, K. (2020). Marine litter composition and sources on coasts of south-eastern Black Sea: A long-term case study. Waste Management, 105, 139–147.

77) Tubau, X., Canals, M., Lastras, G., Rayo, X., Rivera, J., & Amblas, D. (2015). Marine litter on the floor of deep submarine canyons of the Northwestern Mediterranean Sea: The role of hydrodynamic processes. Progress in Oceanography, 134, 379–403.

78) USACE. (2002). Engineering and Design. Hydrographic Surveying. Engineer Manual EM 1110-2-1003.

79) USACE. (2013). Engineering and Design. Hydrographic Surveying. Engineer Manual EM 1110-2-1003

80) Van den Beld, I. M. J., Guillaumont, B., Menot, L., Bayle, C., Arnaud-Haond, S., & Bourillet, J.-F. (2017). Marine litter in submarine canyons of the Bay of Biscay. Deep Sea Research Part II: Topical Studies in Oceanography, 145, 142–152.

81) Vlachogianni, T., Fortibuoni, T., Ronchi, F., Zeri, C., Mazziotti, C,Tutman, P., Bojanić Varezić, D., Palatinus, A., Trdan, Š., Peterlin, M., Mandic, M., Markovic, O., Prvan, M., Kaberi, H., Prevenios, M., Kolitari, J., Kroqi, G., Fusco, M., Kalampokis, E., Scoullos, M. (2018). Marine litter on the beaches of the Adriatic and Ionian Seas: An assessment of their abundance, composition and sources. Marine Pollution Bulletin. 131

82) Watters, D. L., Yoklavich, M. M., Love, M. S., and Schroeder, D. M. (2010). Assessing marine debris in deep seafloor habitats off California. Mar. Pollut. Bull. 60, 131–138.

83) Wölfl, A.-C., Snaith, H., Amirebrahimi, S., Devey, C. W., Dorschel, B., Ferrini, V., … Wigley, R. (2019). Seafloor Mapping – The Challenge of a Truly Global Ocean Bathymetry. Frontiers in Marine Science, 6

84) Wong hao, H., Fengmiao, S., Qiang, L., Shijun, L., & Zhen, G. (2018). Study on the application of point cloud denoising in Gobi desert surface. IOP Conference Series: Earth and Environmental Science, 189, 022011

85) Wynn, R. B., Huvenne, V. A., Le Bas, T. P., Murton, B. J., Connelly, D. P., Bett, B. J., et al. (2014). Autonomous underwater vehicles (AUVs): their past, present and future contributions to the advancement of marine geoscience. Mar. Geol. 352, 451–468.

86) Young GC, Dey S, Rogers AD, Exton D (2017) Cost and timeeffective method for multiscale measures of rugosity, fractal dimension, and vector dispersion from coral reef 3D models. Plos One 12:e0175341

87) Yunus, A. P., Dou, J., Song, X., & Avtar, R. (2019). Improved Bathymetric Mapping of Coastal and Lake Environments Using Sentinel-2 and Landsat-8 Images. Sensors, 19(12), 2788.

8. IZVORI

URL 1 https://mingor.gov.hr/o-ministarstvu-1065/djelokrug/uprava-vodnoga-gospodarstva-i-zastite-mora-2033/more-i-priobalje-opcenito/1437, 7.9.2022.

URL 2 https://enciklopedija.hr/natuknica.aspx?ID=28478, 7.9.2022.

URL 3 https://oceanservice.noaa.gov/facts/backscatter.html, 7.9.2022.

URL 4 https://www.osculati.com/hr/11598-29.510.00/ru%C4%8Dni-dubinomjer-od-olova, 7.9.2022.

URL 5 https://blog.nls.uk/plumbing-the-depths-the-challenge-of-measuring-sea-depth/, 7.9.2022.

URL 6 https://www.kongsberg.com/ru/maritime/products/ocean-science/mapping-systems/es_bottommapping/echosounder-sweep-system, 7.9.2022.

URL 7 https://oceanservice.noaa.gov/facts/backscatter.html, 7.9.2022.

URL 8 https://www.gaelforcegroup.com/application/files/2016/1375/0959/CHASING_M2_PRO_Product_Introduction_V2.0.pdf, 7.9.2022.

URL 9 http://www.ml-repair.eu/hr/morski-otpad, 7.9.2022.

URL 10 https://www.gov.il/en/departments/publications/reports/clean_coast_index_data, 7.9.2022.

URL 11 https://enciklopedija.hr/natuknica.aspx?ID=28478, 7.9.2022.

URL 12 https://mingor.gov.hr/o-ministarstvu-1065/djelokrug/uprava-vodnoga-gospodarstva-i-zastite-mora-2033/more-i-priobalje-opcenito/1437, 7.9.2022.

URL 13 http://www.ml-repair.eu/hr/morski-otpad, 7.9.2022.

URL 14 https://defishgear.net/project/objectives, 7.9.2022.

URL 15 https://www.dji.com/hr/phantom-4-pro-v2/specs, 7.9.2022.

URL 16 https://geospatial.trimble.com/products-and-solutions/trimble-r12i, 7.9.2022.

URL 17 https://www.artec3d.com/portable-3d-scanners/artec-eva/#specifications, 7.9.2022

URL 18 https://www.enl.co.nz/pages/wassp-s3, 7.9.2022.

URL 19 https://www.furunousa.com/-/media/sites/furuno/document_library/documents/brochures/brochures/wassp_s_brochure.pdf 7.9.2022.

URL 20 https://hemispheregnss.com/wp-content/uploads/2018/12/hemispheregnss_v320_ug_userguide_875-0351-0_a1-1.pdf, 7.9.2022.

URL 21 https://www.ceva-dsp.com/ourblog/what-is-an-imu-sensor/, 7.9.2022.
URL 22 https://www.furunousa.com/en/products/wsp002-inu, 7.9.2022.
URL 23 https://www.chasing.com/company-profile.html, 7.9.2022.
URL 24 https://www.chasing.com/chasing-m2-overview, 7.9.2022.
URL 25 https://www.chasing.com/chasing-m2-specs, 7.9.2022.
URL 26 https://prirodahrvatske.com/jadran/ 1.6.2022.
URL 27 https://www.qysea.com/products/fifish-v6/ 15.5.2022.
URL 28 https://www.sciencedirect.com/science/article/abs/pii/S0025326X18306738
15.5.2022.
URL 29 http://home.iitk.ac.in/~blohani/LiDAR_Tutorial/Bathymetric%20LiDAR.html
15.5.2022.
URL 30 https://www.enciklopedija.hr/natuknica.aspx?id=16410 15.5.2022.
URL 31 https://www.seawardtech.com.cn/en/product/1321.html 15.5.2022.
URL 32 https://www.beamworx.com/sbedit/ 15.5.2022.
URL 33 https://narodne-novine.nn.hr/clanci/sluzbeni/full/2018_12_120_2418.html 1.9.2022.
URL 34 https://www.researchgate.net/publication/316894338_Multi-
beam_Echo_Sounder_Operations_for_ROV_Hemire_-
_Exploration_of_Mariana_Hydrothermal_Vent_Site_and_Post-Processing 1.9.2022.
URL 35 https://norbit.com/multibeam-survey-operations-on-rov-with-norbit-winghead/
1.9.2022.
URL 36 https://www.deeptrekker.com/products/underwater-rov/rov-add-ons,
https://www.blueyerobotics.com/blog/improve-rov-navigation-and-avoid-obstacles-
underwater-with-sonars 1.9.2022.
URL 37 http://www.seacams.ac.uk/seacams2/seascapes/MBES.php.en 1.9.2022.
URL 38 https://narodne-novine.nn.hr/clanci/sluzbeni/full/2018_12_120_2418.html 1.9.2022.
URL 39 https://www.dronenerds.com/products/drones/consumer-
drones/underwaterdrones/chasing-m2-with-100m-tether.html 1.9.2022.
URL 40 https://www.qysea.com/products/attachment-tools/ 1.9.2022.
URL 41 https://www.deeptrekker.com/news/what-can-sonar-and-usbl-do-for-me 1.6.2022.
URL 42 https://www.boxfish.nz/products/boxfish-rov/accessories/multibeam-sonar/
1.6.2022.
URL 43 https://www.impactsubsea.co.uk/iss360-imaging-sonar/ 1.6.2022.

URL 44 https://www.seaviewsystems.com/questions/what-are-your-means-of-positioning-the-rov/ 1.6.2022.
URL 45 https://www.seaviewsystems.com/wp-content/uploads/2011/06/USBL.pdf 15.6.2022.
URL 46 https://www.seaviewsystems.com/questions/what-are-your-means-of-positioning-the-rov/ 15.6.2022.
URL 47 https://www.researchgate.net/figure/List-of-remotely-operated-vehicle-ROV-manufacturers-and-their-products-suitable-for_tbl1_324477008 15.6.2022.
URL 48 https://rovtechsolutions.com/products/underwater-rovs/workclass-seaker/ 15.6.2022.
URL 49 https://www.mariscope.de/product/commander-mk2/ 10.9.2022.
URL 50 https://www.chasing.com/chasing-m2.html 10.9.2022.
URL 51 https://www.r2sonic.com/types-of-resolution/ 10.9.2022.

Popis grafičkih priloga

Slika 1. Morske struje Jadranskog mora 7
Slika 2. Geografski položaj područja istraživanja 9
Slika 3. Ručni dubinomjer s utegom 15
Slika 4. Korištenje Tannerovog sondnog uređaja 15
Slika 5. a) Princip rada LiDAR-a; b) primjer modela izvedenog zračnim LiDAR-om 16
Slika 6. Usporedba principa rada satelitskog altimetra i mareografa 17
Slika 7. Primjer modela izvedenog satelitskom altimetrijom 18
Slika 8. Princip rada ultrazvučnog dubinomjera 19
Slika 9. Jednosnopni dubinomjer 20
Slika 10. Prikaz podataka prikupljenih jednosnopnim dubinomjerom 20
Slika 11. Prikaz utjecaja prednjih (a) i bočnih (b) valova na plovilo i prikupljanje podataka 21
Slika 12. WASSP senzorna kutija s integriranim IMU sustavom 22
Slika 13. Utjecaj dubine na povećanje okvira (engl. footprint) snimka 22
Slika 14. Primjer Swath višesnopnog dubinomjera 23
Slika 15. Vertikalni Sweep sustav 24
Slika 16. Usporedba batimetrijske i backscatter snimke istoga područja istraživanja 25

Slika 17. Osnovne sastavnice ROV sustava....26
Slika 18. Prikaz određenih dodataka za ROV....27
Slika 19. CURV II ronilica američke mornarice....29
Slika 20. Ronilice RCV 225 i RCV 150 29
Slika 21. VideoRay ROV....30
Slika 22. RSL Workclass Seaker ROV....31
Slika 23. Commander MK II ROV 31
Slika 24. Snimanje istraživanog područja bespilotnom letjelicom Phantom 4 Pro 34
Slika 25. Trimble R12i GNSS i Trimble TDC600 upravljač....36
Slika 26. Primjer označene orijentacijske točke na terenu....37
Slika 27. Izvedeni oblak točaka i procjenjene lokacije kamera nakon povezivanja fotografija 38
Slika 28. Proces 3D skeniranja 39
Slika 29. Proces obrade automobilske gume snimljene ručnim 3D skenerom Artec Eva 40
Slika 30. Izvedeni scenariji MBES snimanja odabrane testne plohe 41
Slika 31. Gumenjak Luna s instaliranim integralnim mjernim sustavom....41
Slika 32. WASSP S3 višesnopni dubinomjer 43
Slika 33. (A) Sonda WMB-160; (B) Hemisphere V320 GNSS Smart Antenna....44
Slika 34. Uvjeti na moru prilikom izvođenja MBES snimanja....45
Slika 35. Advanced Navigation Spatial IMU WSP002-INU....46
Slika 36. Primjer distorzije terena uzrokovan refrakcijom 47
Slika 37. Različiti prikazi snimanog područja prilikom izvođenja MBES batimetrijske izmjere....48
Slika 38. Pregled osnovnih parametara MBES snimanja u CDX-u....49
Slika 39. Konfiguracija GPS antene u PocketMax3 programu....49
Slika 40. Chasing M2 podvodni dron 50
Slika 41. Korištenje podvodne bespilotne ronilice Chasing M2 prilikom kartiranja morskog otpada unutar odabrane testne plohe 51
Slika 42. Primjer jedne fotografija s maskiranim rubnim dijelovima....53
Slika 43. Fotografija a) prije i b) poslije brisanja netočnih podataka 53
Slika 44. Preuzeti i importirani podatci 54
Slika 45. Izlazni rezultati u procesu obrade podvodnih fotografija u Agiosft Metashape-u ...55
Slika 46. Način određivanja udaljenosti između dva oblaka točaka primjenom M3C2 56
Slika 47. Primjeri izvedenih 3D modela detektiranog otpada na morskom dnu....57

Slika 48. Otpad detektiran na morskom dnu primjenom bespilotne podvodne ronilice (DOF58
Slika 49. Otpad detektiran na morskom dnu primjenom bespilotne podvodne ronilice (DEM)
.....60
Slika 50. Gusti oblaci točaka za intervalna MBES snimanja.....63
Slika 51. Proces obrade nefiltriranih oblaka točaka u izvođenju DBM-a šireg područja.....64
Slika 52. a) DBM (A) snimanja nefiltrirani; (b) DBM (B) snimanja nefiltrirani; (c) DMB integrirani A i B nefiltrirani; (d) DBM filtrirani integralni model.....65
Slika 53. a) DBM (C) snimanja nefiltrirani; (b) DBM (D) snimanja nefiltrirani; (c) DMB integrirani C i D nefiltrirani; (d) DBM filtrirani integralni model.....66
Slika 54. Detektirani betonski blokovi iz nefilttriranog oblaka točaka najsporije brzine.....67
Slika 55. Ispupčenje u gustom nefiltriranom oblaku točaka - objekt lima na morskom dnu...68
Slika 56. Primjer detaljnosti morskog dna pri različim širinama pojasa 70
Slika 57. Modeli udaljenosti izvedeni u M3C2 alatu između A te B, C i E snimanja.....72
Slika 58. Model tvrdoće morskog dna za snimanje A - izostanak obrisa morskog otpada 74

Popis tabličnih prikaza

Tablica 1. Specifikacije UAV-a Phantom 4 Pro 35
Tablica 2. Specifikacije Trimble R12i GNSS prijemnika.....36
Tablica 3. Koordinate prikupljenih orijentacijskih točaka 37
Tablica 4. Specifikacije 3D ručnog skenera Artec Eva 38
Tablica 5. Specifikacije WASSP S3 višesnopnog dubinomjera 43
Tablica 6. Specifikacije GNSS senzora 44
Tablica 7. Specifikacije podvodnog drona Chasing M2 50
Tablica 8. Izračun SD između sve moguće kombinacije scenarija snimanja 73