

Raport științific – Etapa III

Titlul proiectului: *„Inspectia scenelor subacvatice iluminate artificial folosind OpenROV*

Trident”

Codul proiectului: **PN-III-P2-2.1-PED-2019-2805**

Tip proiect: Proiect experimental - demonstrativ (PED)

Acronim: **UW-ROV**

Director proiect: **Dr. Ing. Cosmin Ancuti**

Universitatea Politehnica Timișoara, Facultatea de Electronică și
Telecomunicații, Departamentul MEO

E-mail: cosmin.ancuti@upt.ro

Website proiect: <http://ancuti.meo.etc.upt.ro/PED2019/>

Obiectiv Etapa III: *Testarea si validarea aplicatiei prototip in scenarii de laborator.*

Obiectivul principal al acestei etape a fost de a defini scenarii de laborator specifice pentru care metoda de imbunatatire a vizibilitatii in scene subacvatice (dezvoltata in etapa anterioara) sa fie testata atat calitativ dar si cantitativ in comparatie cu metode specializate.

Etapa III. Testarea si validarea aplicatiei prototip in scenarii de laborator.

3.1 Potrivirea punctelor caracteristice locale (*local feature matching*) pentru aplicatii SLAM (*Simultaneous Localization And Mapping*) in mediul subacvatic

Una dintre aplicatiile cele mai importante in *computer/robot vision* se refera la determinarea localizarii robotului (senzorului). Locația care trebuie determinata descrie estimarea modificărilor pozitiei unui robot (senzor) în timp ce acesta isi modifica coordonatele spatiale. Dificultatea rezolvării acestei probleme constă în faptul că in general aceste modificari nu se pot măsura in mod direct. În schimb, poziția trebuie să fie derivată din datele senzorului, care include de obicei informatie afectata de zgomot. Pentru a urmări poziția, datele acestuia trebuie să fie acumulate, ceea ce de multe ori înseamnă că de asemenea erorile se pot acumula si ele.

SLAM (*Simultaneous Localization And Mapping*) este aplicatia care se refera la determinarea poziției și orientării unui senzor (de imagine) față de împrejurimile sale, în timp ce cartografiază simultan mediul din jurul senzorului respectiv. Aceasta aplicatie de cartografierea a devenit rapid foarte importanta si in mediul subacvatic existand o nevoie tot mai mare de cartografiere de harti subacvatice folosind roboti specializati.

Evident, in cazul imaginilor subacvatice, unde cantitatea de lumină disponibilă depinde de mai mulți factori, aplicatiile SLAM sunt mult mai complexe in special datorita vizibilitatii reduse (imaginile subacvatice capturate sunt caracterizate de un contrast redus, distorsiuni de culoare, zgomot si *blur* aditional).

Relativ recent, in [1], s-a aratat ca pentru mediul subacvatic algoritmi de SLAM bazati pe detectia si descrierea punctelor caracteristice (si apoi urmarirea acestora) reprezinta una dintre cele mai eficiente metode de localizare si mapare. Adicional, SLAM-ORB [2], metoda bazata pe detectia si descrierea punctelor caracteristice folosind operatorul ORB [3] a fost metoda care a obtinut printre cele mai bune rezultate pentru scene inregistrate subacvatic. Totusi, trebuie mentionat ca testarea directa a aplicatiilor SLAM in mediu subacvatic este complexa deoarece nu exista baze

de imagini specifice înregistrate în scenarii subacvatice. Prin urmare, așa cum vom detalia în secțiunea următoare, în definirea scenariilor din acest proiect am considerat problema potrivirii punctelor caracteristice (partea esențială și cea mai complexă a multor aplicații SLAM) extrase și descrise cu operatorul ORB.

3.2 Extragerea/filtrarea și potrivirea punctelor caracteristice ORB

Deși operatorul SIFT [4] a reprezentat un punct de referință crucial pentru multe aplicații *computer vision*, acesta s-a dovedit a fi relativ costisitor din punct de vedere al calculului și prin urmare nu s-a putut folosi pentru aplicații în timp real. Derivat din SIFT, operatorul ORB [3] este cu două ordine de mărime mai rapid decât SIFT și s-a dovedit a avea performanțe la fel de bune ca și SIFT, reprezentând la ora actuală unul dintre cei mai eficienți operatori pentru extragerea/filtrarea și potrivirea punctelor caracteristice locale. Prin urmare, în această proiect unul din scenariile de laborator s-a bazat pe validarea metodei propuse utilizând operatorul ORB.

Operatorul ORB filtrează punctele caracteristice pe baza detectorului de puncte caracteristice FAST îmbunătățit [5]. FAST s-a dovedit a fi o soluție eficientă pentru extragerea punctelor caracteristice în aplicații în timp real. Acest detector extrage punctele caracteristice folosind un cerc Bresenham cu raza de dimensiuni mici și pentru a îmbunătăți scorul de potrivire a punctelor caracteristicilor selectate acestea sunt extrase folosind o procedură similară utilizată de operatorul Harris [6].

Punctele caracteristice extrase sunt apoi descrise de o versiune invariantă la rotație în plan a descriptorului BRIEF [5]. Descriptorul BRIEF convertește regiunea vecină a unui punct caracteristic detectat într-un vector binar. La final, fiecare punct caracteristic este descris pe baza informațiilor sale de vecinătate printr-un șir de biți.

Potrivirea vectorilor descriptori extrași cu BRIEF se bazează pe procedura *Brute-Force*. Aceasta procedură consideră descriptorul unui punct caracteristic dintr-un prim set de puncte și îl potrivește cu toate celelalte puncte caracteristice din al doilea set de puncte filtrate folosind un calcul de distanță. Punctul caracteristic care are distanța cea mai mică (cel mai apropiat) este returnat ca fiind punctul care se potrivește cel mai bine.

3.3. Definirea scenariilor de laborator

Scenariile de validare s-au bazat pe doua baze de imagini subacvatice care sunt descrise pe scurt mai jos. Am definit doua scenarii principale.

In primul scenariu, folosind baza de date introdusa de Treibitz et al. [7], ne-am axat pe o evaluare calitativa a rezultatelor metodei propuse comparandu-ne cu cateva metode recente de imbunatatire a vizibilitatii in imagini subacvatice.

In scenariul al doilea am efectuat o evaluare atat calitativa a rezultatelor dar si cantitativa bazandu-ne pe potrivirea punctelor caracteristice extrase in imagini subacvatice. In acest caz am folosit baza de date TURBID care ofera si imagini referinta.

Bazele de date in mediul subacvatic:

a. Baza de date introdusa de Treibitz et al. [7]

Aceasta baza de date a fost publicata relativ recent iar setul de date include imagini RAW (neprelucrate), fișiere TIF, fișiere de calibrare a camerei și hărți de adancime. Baza de date conține 57 de perechi stereo de la patru locatii diferite din Israel, două în Marea Roșie




Figura 1: Imagini din baza de date introdusa de Treibitz et al. [7]

(reprezentând apa tropicală) și două în Marea Mediterană (apă temperată). În Marea Roșie, locurile sunt reprezentate un recif de corali („Katzaa”) care are 10-15 metri adâncime (15 perechi) și o epavă („Satil”), 20-30 metri adâncime (8 perechi). În Marea Mediterană, ambele locuri sunt medii de recif stâncos, separate de 30 km, Nachsholim la 3-6 metri adâncime (13 perechi) și Mikhmoret la 10-12 metri adâncime (21 perechi).

b. Baza de date TURBID [8].

În contextul evaluării cantitative folosind potrivirea punctelor caracteristice, ne-am bazat pe baza de date TURBID [8] care este singura la ora actuală care oferă imagini referință. Această bază de date utilizează fotografii reale cu scene subacvatice. Pozele sunt plasate pe fundul unui bazin/rezervor umplut cu o soluție specială care imită diverse grade de adâncime subacvatică și apoi sunt re-fotografiate cu o degradare controlată (Figura 2). Această bază de date ne-a permis să testăm rezultatele potrivirii de puncte caracteristice extrase cu operatorul ORB luând în considerare diferite metode recent introduse pentru restaurarea vizibilității în imagini subacvatice.




Figura 2: Modul de înregistrare a imaginilor subacvatice din baza TURBID.

3.3. Metodele de imbunatatire a vizibilitatii in imagini subacvatice cu care ne-am comparat

- a. **HE et al. [9] (DCP).** Este o metoda care se bazeaza pe informatia de prior DCP (*Dark Channel Prior*) si initial a fost introdusa pentru restaurarea scenelor afectate de ceata dar ulterior s-a dovedit ca este performanta si pentru imagini subacvatice. DCP face posibilă estimarea aproximativă a hărții de adâncime a unei scene afectate de ceata. Pentru a obține o hartă de transmisie filtrata, valorile estimării hartii de transmisie sunt extrapolate printr-o metoda relativ costisitoare din punct de vedere computațional.
- b. **Drews Jr. et al. [10] (UDCP).** Aceasta metoda extinde DCP adaptand-o pentru imagini subacvatice. Metoda presupune că sursa predominantă de informații vizuale sub apă se află în canalele de culoare de albastru și verde. Prin aceasta asumare, UDCP a demonstrat ca permite sa estimeaze mai bine transmisia/informatia de adancime din scenele subacvatice decât metoda traditionala bazata pe DCP.
- c. **Ancuti et al.[11].** Metoda introduce o abordare care se bazează pe fuziunea multi-scala, derivand din imaginea initiala două intrări: prima are corectat contrastului iar celei de-a doua i se aplica o metoda originala de *white-balancing*. Aceste intrari sunt ponderate cu ajutorul unor masuri/ponderi caracteristice. Intr-un final acestea se combina intr-o singura iesire folosind fuziunea multi-scala care are ca rezultat o reducere semnificativa a nivelului de artefacte.
- d. **Berman et al. [12].** Este o metoda introdusa recent si care ia in considerare profiluri spectrale diferite ale diferitelor scene subacvatice reducand problema la o problema clasica de eliminare a cetii prin estimarea doar a rapoartelor de atenuare a canalelor roșul-albastru si verde-albastru.

4. Rezultate obtinute

4.1. Primul scenariu de testare (folosind baze de date introduse de Treibitz et al. [7])

Ne-am comparat doar calitativ (nu exista la ora actuala o metoda de masurare comun acceptata pentru evaluarea restaurarii in imagini subacvatice) cu metodele introduse de Drews Jr. et al. [10], Berman et al.[12], Ancuti et al. [11] si He et al.[9]. Asa cum se poate observa, metoda propusa produce rezultate comparative si chiar mai bune decat rezultatele metodelor considerate, atat din punct de vedere al restaurarii culorilor cat si al recuperarii de detalii.




Figura 3 : Rezultate comparative folosind baza de date introdusa de Treibitz et al. [7]. Ne-am comparat cu metodele lui Drews Jr. et al [10], Berman et al.[12], Ancuti et al.[11], and He et al.[9].

4.2 Al doilea scenariu de testare (folosind baza de date TURBID [8])

În acest al doilea scenariu ne-am comparat și calitativ (folosind potrivirea punctelor caracteristice extrase de operatorul ORB) cu rezultatele produse de două tehnici subacvatice performante: metoda lui Drews-Jr et al. (UDCP) [10] și metoda lui Berman et al. [12]. Figura 4 prezintă rezultatele comparative numerice obținute de metoda noastră și metoda lui Berman et al. [12].

Figura 5 prezintă rezultate calitative dar și cantitative pentru setul 5 al subsetului „Deep Blue” (din baza de date TURBID). Așa cum am menționat anterior în acest studiu, imaginile sunt potrivite folosind operatorul ORB. După cum se vede, procesând perechea de imagini originală (neprocesată) se obțin zero potriviri valide, procesând rezultatele generate cu UDCP [10] sunt identificate 2 potriviri corecte, rezultatele generate cu metoda propusă de Berman et al. [1] identifică 2 potriviri corecte iar pe rezultatele generate cu metoda propusă în acest proiect sunt 20 de potriviri corecte.

În mod similar, Figura 6 prezintă comparativ rezultate calitative și cantitative pentru setul 5 al „Subsetul Front View” (din baza de date TURBID). Procesând imaginile originale (neprocesate) s-au obținut 2 puncte potrivite corect. Pe de altă parte considerând imaginile rezultate prin procesarea cu UDCP s-au identificat 13 potriviri corecte iar folosind rezultatele obținute cu metoda lui Berman et al. au rezultat 51 de potriviri corecte. Pe imaginile rezultate procesate cu metoda propusă s-au identificat 153 potriviri corecte. Am folosit operatorul ORB și aceeași procedură de potrivire descrisă în secțiunile anterioare.






Figura 4. Metoda noastră ajută la îmbunătățirea considerabilă a numărului de potriviri corecte (operator ORB). Pentru acest set de imagini ale setului de date TURBID am obținut 94 de potriviri corecte comparativ cu numai 50 de potriviri obținute atunci când imaginea a fost prelucrată cu metoda lui Berman et al. [12]


Original



Berman et al.



UDCP



Ours




Figura 5. Rezultate pentru setul 5 din Deep Blue. Ne-am comparat cu tehnicile subacvatice specializate ale lui Drews-Jr et al. (UDCP) și Berman et al.. Procesand perechea de imagini originala (neprocesata) se obtin zero potriviri valide, pe rezultatele generate cu UDCP [10] sunt 2 potriviri corecte, pe rezultatele generate cu metoda propusa de Berman et al. [1] sunt 2 potriviri corecte iar pe rezultatele generate cu metoda propusa sunt 20 de potriviri corecte.




Figura 6: Rezultate pentru setul 5 al subsetului Chlorophyll-Front View. Ne-am comparat cu tehnicile specializate ale lui Drews-Jr et al. (UDCP) [10] și Berman et al. [12]. Pe imaginile originale (neprocesate) s-au identificat 2 potriviri valide, pe rezultatul procesate cu UDCP exista 13 potriviri corecte, pe Berman et al. [12] au rezultat 51 de potriviri corecte, iar pe rezultatele procesate cu metoda noastra sunt 153 de potriviri corecte

Tabelele I, II, III și IV prezintă în detaliu numărul de potriviri corecte obținute atunci când imaginile din fiecare subset au fost prelucrate cu metodele lui Drews-Jr et al. (UDCP) , Berman et al. și, de asemenea, atunci când sunt prelucrate folosind tehnica propusă în acest proiect. După cum se poate observa, în general tehnica de îmbunătățire a vizibilității în imagini subacvatice propusă de noi ajută la identificarea unui număr considerabil mai mare de potriviri corecte în comparație cu celelalte metode specializate considerate (am utilizat aceeași procedură de filtrare a punctelor caracteristice utilizând ORB și aceeași procedură de potrivire a acestora). Singura excepție este subsetul Milk în care UDCP are performanțe ceva mai bune comparativ cu abordarea noastră.

<i>Chlorophyll - Front View</i>					
	set 1	set 2	set3	set 4	set 5
Original	4	3	2	2	2
UDCP	37	24	23	17	13
Berman	75	72	78	61	51
Ours	205	186	194	185	153

Tabelul I: Evaluarea cantitativă a numărului total de potriviri folosind cinci seturi de imagini din **Chlorophyll – Frontal View** a setului de Imagini TURBID. Ne-am comparat cu tehnicile specializate ale lui Drews-Jr et al. (UDCP) [10] și Berman et al.[12]

<i>Chlorophyll - Side View</i>					
	set 1	set 2	set3	set 4	set 5
Original	11	4	4	1	1
UDCP	56	51	47	28	13
Berman	114	95	94	72	50
Ours	132	124	126	116	94

Tabelul II: Evaluarea cantitativă a numărului total de potriviri folosind cinci seturi de imagini din **Chlorophyll – Side View** a setului de Imagini TURBID.

<i>Milk</i>					
	set 1	set 2	set3	set 4	set 5
Original	42	16	7	1	0
UDCP	151	122	113	74	64
Berman	147	113	101	47	32
Ours	134	124	107	67	58

Tabelul III: Evaluarea cantitativă a numărului total de potriviri folosind cinci seturi de imagini din **Milk** a setului de Imagini TURBID.

<i>Deep Blue</i>					
	set 1	set 2	set3	set 4	set 5
Original	2	0	0	0	0
UDCP	6	3	4	2	3
Berman	14	9	17	2	4
Ours	23	24	21	20	14

Tabelul IV: Evaluarea cantitativă a numărului total de potriviri folosind cinci seturi de imagini din **Deep Blue** a setului de Imagini TURBID. Ne-am comparat cu tehnicile specializate ale lui Drews-Jr et al. (UDCP)[10] și Berman et al.[12]

5. Participare la conferințe în Etapa III a proiectului:

În cea de-a doua etapă am participat la o conferința internațională cotelată ISI/WOS:

1. **IEEE ELMAR 2022, 13-15 septembrie, Zadar Croatia.**

6. Rezultate Etapa III

În această etapă rezultatele au fost publicate într-o lucrare ISI/WoS:

- Arpad Kis, Horia Balta and Cosmin Ancuti, "Effective restoration of underwater images to improve local feature matching", IEEE ELMAR, Zadar, Croatia, septembrie 2022

Director de proiect
Dr. Ing. Cosmin Ancuti
Data: 17.10.2022

Referințe bibliografice:

- [1] Maxime Ferrera, Julien Moras, Pauline Trouveloux, and Vincent Creuze, "Real-time monocular visual odometry for turbid and dynamic underwater environments," Sensors, 2020.
- [2] Raul Mur-Artal, J. M. M. Montiel, and Juan D. Tardós, "ORB-SLAM: a versatile and accurate monocular SLAM system," IEEE Transactions on Robotics, 2015
- [3] Ethan Rublee, Vincent Rabaud, Kurt Konolige, and Gary R. Bradski, "ORB: an efficient alternative to Sift or Surf," IEEE ICCV, 2011.
- [4] D. Lowe, "Distinctive image features from scale-invariant keypoints," Int. Journal of Comp. Vision, 2004.
- [5] R. Porter E. Rosten and T. Drummond, "Faster and better: A machine learning approach to corner detection," IEEE Trans. Pattern Analysis and Machine Intelligence, 2010.
- [6] C. Harris and M. Stephens, "A combined corner and edge detector," In Alvey Vision Conference, 1988.
- [7] T. Treibitz D. Berman, D. Levy and S. Avidan, "Underwater single image color restoration using haze-lines and a new quantitative dataset," IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020
- [8] Amanda Duarte, Felipe Codevilla, Joel Gaya, and Silvia Botelho, "A dataset to evaluate underwater image restoration methods," in IEEE OCEANS, 2016.
- [9] K. He, J. Sun, and X. Tang, "Single image haze removal using dark channel prior," IEEE TPAMI, 2011.
- [10] P.L.J. Drews Jr., E. R. Nascimento, S.S.C. Botelho, and M. F. M. Campos, "Underwater depth estimation and image restoration based on single images," IEEE Computer Graphics and Applications, 2016
- [11] C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and P. Bekaert, "Color balance and fusion for underwater image enhancement," in IEEE Transactions on Image Processing, 2018
- [12] D. Berman , T. Treibitz and S. Avidan, "Diving into haze-lines: Color restoration of underwater images," Proc. of British Machine Vision Conference (BMVC), 2017