CroMarX

Kooperativna robotika u nadzoru i istraživanju mora

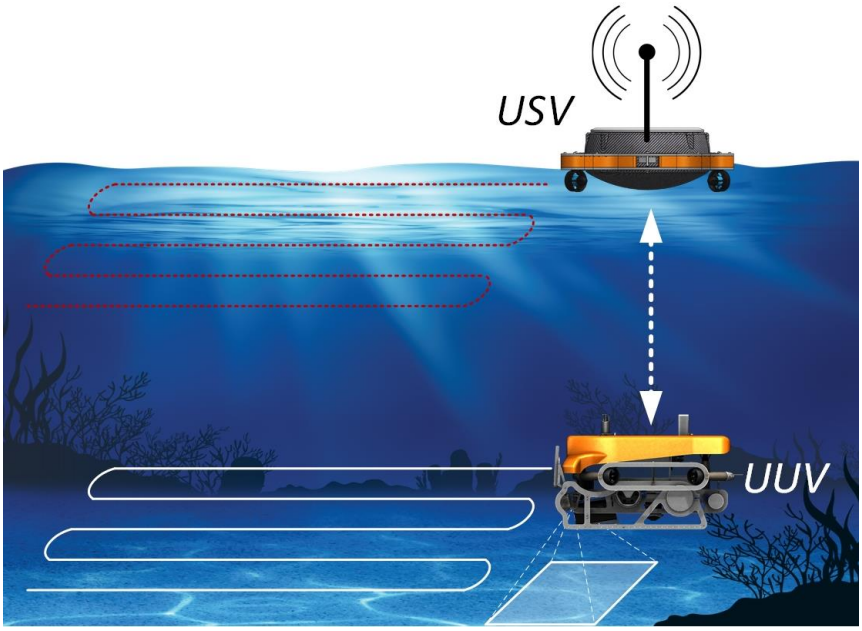

D6.3 Izvještaj o validacijskim eksperimentima Scenarija 2

Sveučilište u Zagrebu, Fakultet Elektrotehnike i Računarstva
Laboratorij za podvodne sustave i tehnologije

31. Prosinca 2019.

Sadržaj

Uvod 2
Validacija scenarija 2 2
Statički eksperiment 2
Eksperiment s linearnom trajektorijom 4
Eksperiment s nepredvidivim gibanjem i podaktuiranim vozilom 5
Zaključak 10
Reference 10

Uvod

Ovaj dokument predstavlja rezultate validacije algoritama za kooperativno upravljanje i distribuiranu lokalizaciju između bespilotnog površinskog plovila i podvodnog vozila. Tehnički podaci vozila korištenih u CroMarX istraživanju i ovoj validaciji su predstavljeni u D6.1. Za eksperimentalnu provjeru algoritama za kooperativno upravljanje bespilotnim površinskim plovilima kreiran je Scenarij 2. Scenarij demonstrira funkcionalnosti upravljanja formacijom površinskog plovila i podvodnog vozila. Inicijalni scenarij opisan je u D4.1, a uključuje više površinskih vozila s različitim senzorima za distribuiranu ispomoć u navigaciji podvodnog vozila. Izvještaj o rezultatima tog scenarija obrađeni su već u sklopu D4.3 i povezanoj publikaciji na međunarodnoj konferenciji. Tokom istraživanja pojavio se dodatni pristup kooperativnom upravljanju i lokalizaciji, prezentiran u D4.4, čiji rezultati će biti prezentirani u ovome dokumentu.

Dokument predstavlja rezultat aktivnosti T6.4. „Scenarij 2: Kooperativno mapiranje morskog dna korištenjem USV-a i UUV-a“ i potvrđuje ostvarenje kontrolne točke (milestone) MS9: „Scenarij 2 validiran“. Shodno tome rezultati validacije predstavljaju i važan korak u dostizanju cilja 5 „Eksperimentalna validacija razvijenih kooperativnih upravljačkih algoritama primijenjenih na flotu bespilotnih plovila i bespilotnu ronilicu“.

Validacija scenarija 2

Kao što je naglašeno u uvodu, dokument će se fokusirati na eksperimentalnu validaciju algoritma prezentiranog u D4.4. Eksperimentima se validira:

1. uspješno praćenje podvodnog vozila uz minimalnu izmjenu podataka
2. osigurana kvaliteta potpomognutih mjerenja udaljenosti za podvodno vozilo
3. kvaliteta algoritma u odnosu na popularnu metodu u literaturi koja koristi Fisher information matrix (vidi reference [1],[2],[3]).

Statički eksperiment

Prvi eksperimenti su provedeni s omnidirekcionalnom platformom i statičkim podvodnim vozilom. Podvodno vozilo bilo je Buddy autonomno vozilo zbog mogućnosti držanja statičke pozicije. Slika 1 prikazuje trajektorije površinskog i podvodnog vozila tokom statičkog eksperimenta. Za kontrolna (ground truth) mjerenja pozicije podvodnog vozila se koriste akustička USBL mjerenja. Podvodno vozilo estimira svoju poziciju korištenjem modela za relativnu udaljenost prezentiranu u D4.4. Na slici su također vidljive putanje u obliku kompresirane kružnice do čega dolazi zbog zasićenja u kontrolnom signalu. Efekt zasićenja pojavljuje se u slučaju kad se ne koristi visokopropusni prefilter mjere kvalitete osmotrivosti koja se dobiva preko akustike. Neovisno o zasićenju signala, vidljivo je da površinsko vozilo konvergira iznad pozicije statičkog podvodnog vozila.

Iznos kriterija osmotrivosti, računanog iz matrice kovarijance, prikazan je na slici 2. Na slici je vidljivo da, neovisno o zakašnjelim i neregularnim akustičkim mjerenjima, algoritam upravljanja konvergira površinsko vozilo iznad podvodnog. S druge strane, kvaliteta potpomognutih daljinskih mjerenja vidljiva je smanjenim iznosom kriterija osmotrivosti $J(\mathbf{P})$ – manji iznos korelira s informativnijim mjerenjem odnosno boljom osmotrivosti.

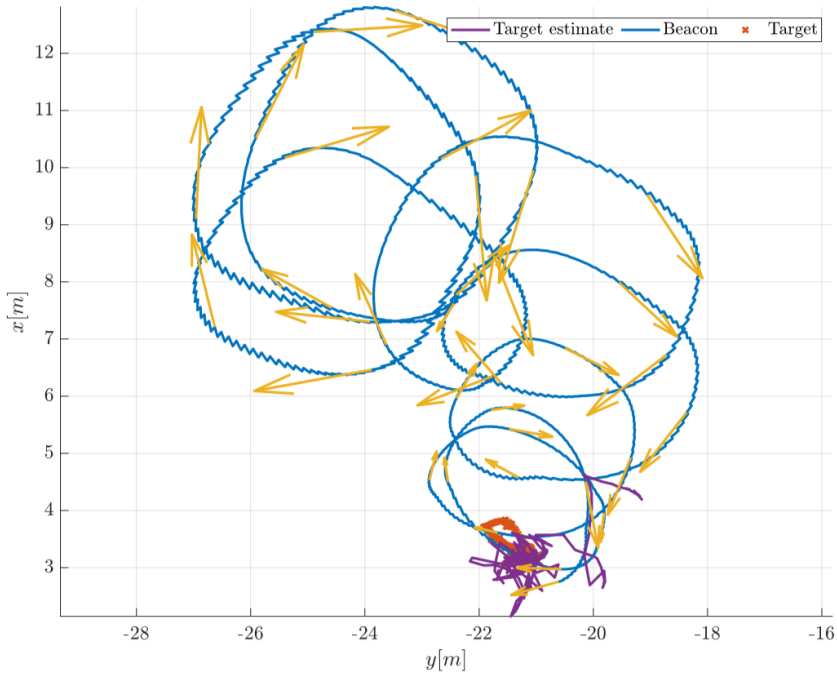

Slika 1. Trajektorija površinskog vozila (Beacon) i podvodnog vozila (Target)

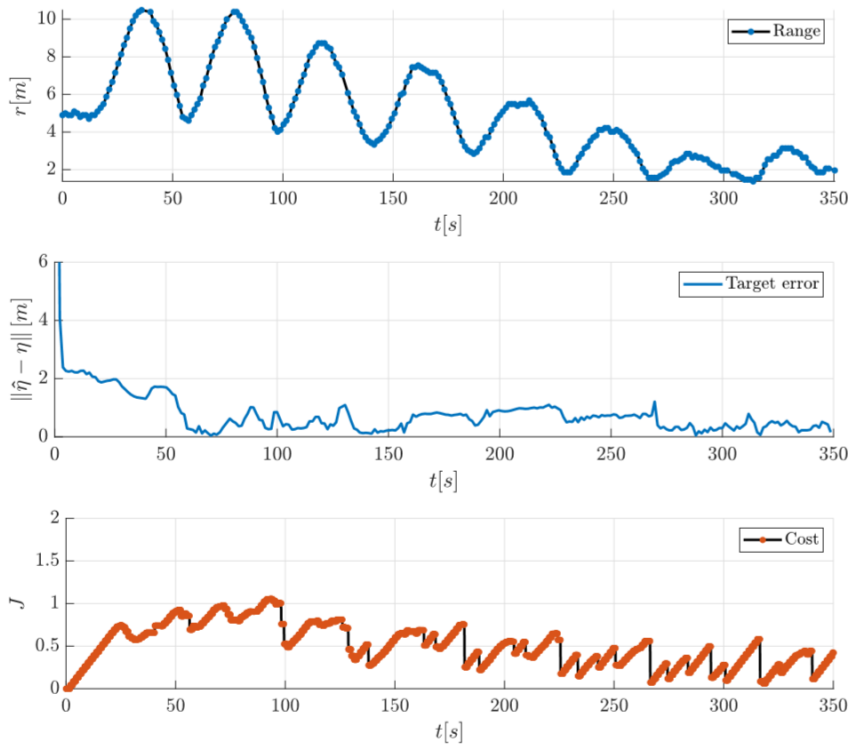

Slika 2. (*gore*) Prikaz udaljenosti od cilja pogreške, (*sredina*) u estimaciji pozicije podvodnog vozila (relativno na USBL mjerenja) i (*dolje*) kriterij osmotrivosti.

Eksperiment s linearnom trajektorijom

Nakon statičkog scenarija, proveden je eksperiment gdje se podvodno vozilo giba po ravnoj putanji. Trajektorije obaju vozila za ovaj eksperiment prikazane su na slici 3. Sa slike je vidljivo da površinsko vozilo sustiže i prati podvodno vozilo i tokom linearnog gibanja. Na slici 4 vidljiva je korelacija između udaljenosti vozila i funkcije osmotrivosti. Kako se udaljenost između vozila povećava, povećava se i iznos kriterija osmotrivosti $J(\mathbf{P})$. Zanimljivo je primijetiti da se pogreška u estimaciji povećava sukladno povećanjima $J(\mathbf{P})$. Ovo je vezano uz činjenicu da veći iznos kriterija osmotrivosti korelira s lošijom kvalitetom mjerenja. Šumovitost kontrolnih mjerenja u slici 3 i slici 1, su posljedica šumovitosti dostupnog USBL akustičkog senzora za 3D podvodnu lokalizaciju.

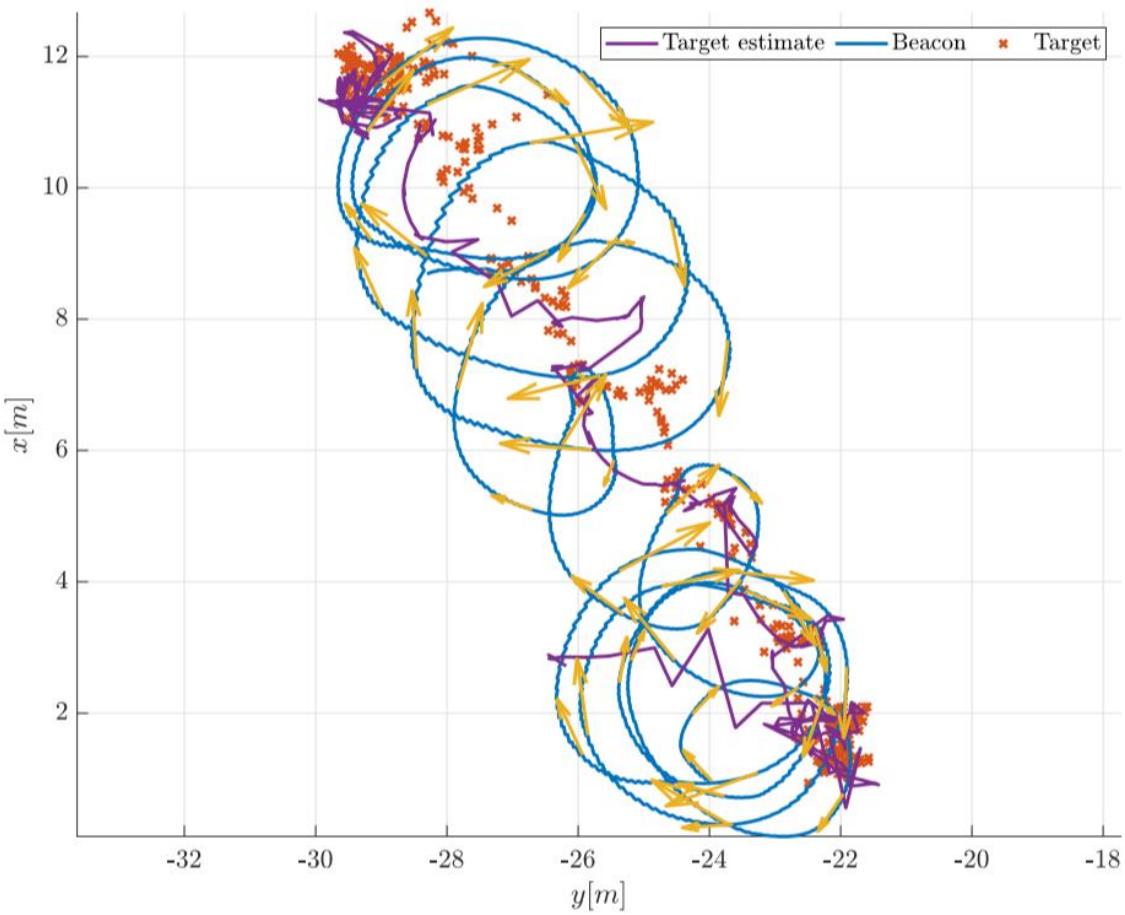

Slika 3. Trajektorija površinskog vozila (Beacon) i podvodnog vozila (Target)

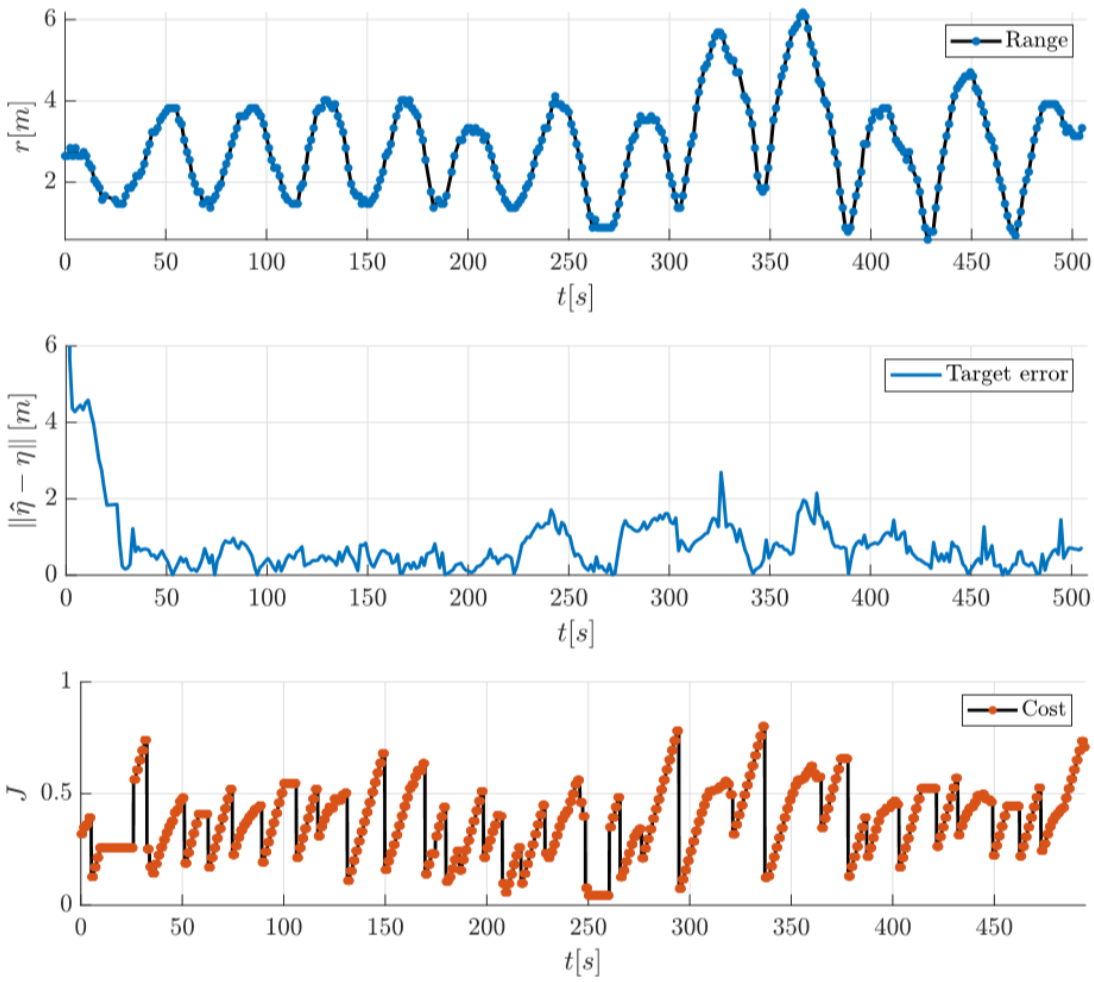

Slika 4. Prikaz udaljenosti od cilja, pogreške u estimaciji pozicije podvodnog vozila (relativno u odnosu na USBL) i funkcija osmotrivosti.

Eksperiment s nepredvidivim gibanjem i podaktuiranim vozilom

Prethodna dva eksperimenta provedena su s potpuno aktuiranim vozilima. Obzirom da se takva vozila mogu kretati neovisno u svim osima implementacija algoritma i provođenje eksperimenata je olakšano. Nažalost, većina pomorskih vozila je podaktuirana (npr. brod), tj. ne mogu se neovisno gibati u svim osima. Zbog toga, dizajn algoritma upravljanja podržava i podaktuirana vozila kako će se demonstrirati eksperimentom u ovom odjeljku. U eksperimentu će se koristiti podauktiranano podvodno i površinsko vozilo. Prednost korištenja podaktuiranih vozila u odnosu na potpuno aktuirana je ostvarivost većih brzina. Obzirom na metodu gibanja površinskog vozila, jasno je da je mogućnost veće brzine poželjnije za bolju konvergeniju predloženog algoritma.

Prethodni eksperimenti su također uključivali i strukturirano gibanje koje je lako predvidivo. Glavne poteškoće s praćenjem nastaju u slučajevima kad gibanja podvodnog vozila nisu predvidiva. To je slučaj u misijama koja zahtijevaju točkasta istraživanja i čestu izmjenu plana, misijama gdje samo podvodno vozilo prati drugi cilj s nestrukturiranim gibanjem ili misijama gdje je vozilo daljinski operirano. Zbog toga,

tokom prikazanog eksperimenta podvodno vozilo je provodilo nestrukturirano gibanje.

Trajektorije obaju vozila prikazane su na slici 5. Trajektorije su prikazane u horizontalnoj ravnini, a podvodno vozilo je držalo konstantu dubinu od 3m. Žute strelice prikazuju vektor brzine površinskog vozila čime se lako vide ubrzanja i usporavanja tokom praćenja.

Korištena vrijednost pojačanja je k=4, pomak c=0.1, a pertubacijska frekvencija je $\omega = \frac{2\pi}{80}\frac{rad}{s}$. Ovi parametri su odabrani ručno kako bi se dobilo kvalitetno praćenje. U realnim testiranjima, odabir pertubacijske frekvencije ovisi o ograničenjima akustičke komunikacije. Veća peturbacijska frekvencija povlači i bržu reakciju, ali to ima samo

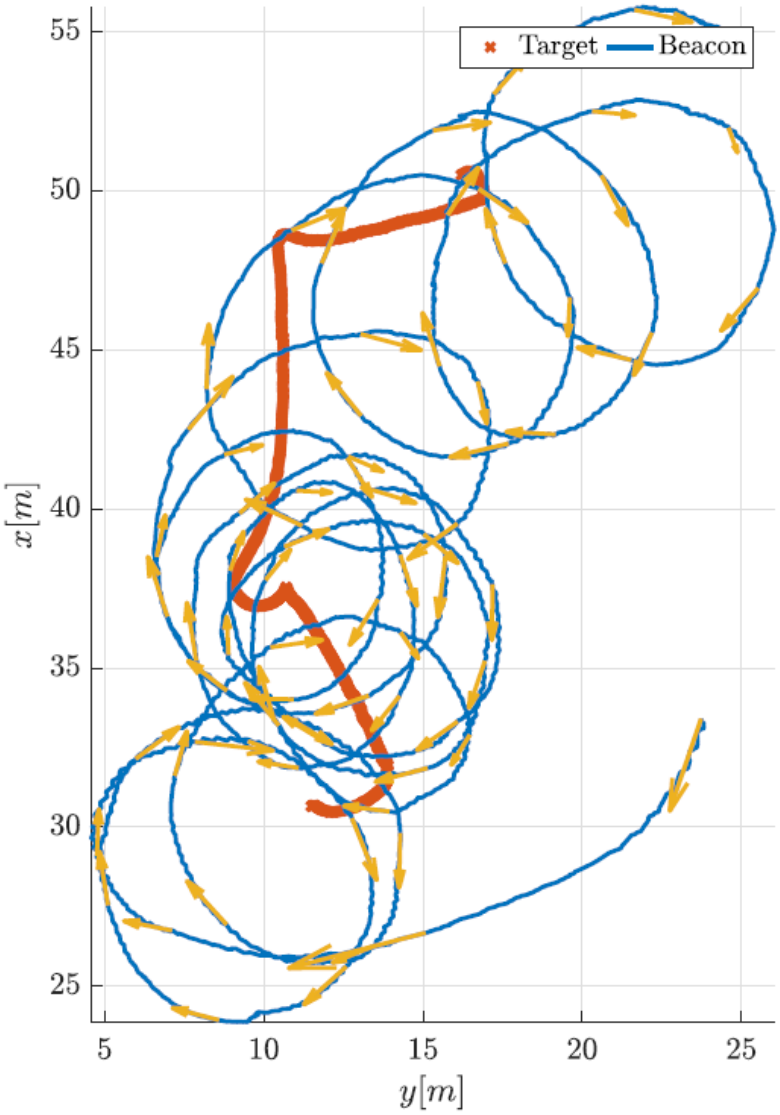

smisla kad kanal akustičke komunikacije dozvoljava brži prijenos podataka. Tokom ovog eksperimenta odabrana je perturbacijska frekvencija za prosječni period komunikacije od 3.4s.

Slika 5. Trajektorija površinskog (Beacon) i podvodnog (Target) vozila.

Iznosi kriterija osmotrivosti i njegov filtrirani signal (γ) prikazani su na slici 6. Iznos kriterija je u početku velik zbog smanjenje osmotrivosti, ali se tokom izvođenja algoritma smanjuje i ostaje ograničen u ostatku eksperimenta neovisno o gibanju podvodnog vozila. Filtrirani signal γ ne sadrži niske frekvencije pa je uvijek ograničen neovisno o apsolutnom iznosu kriterija. Kao što je spomenuto u D4.4, ovako filtrirani signal izbjegava zasićenje kontrolnog signala vozila što je nužno za kvalitetno praćenje kod složeniji trajektorija podvodnog vozila.

Relativna udaljenost dvaju vozila tokom eksperimenta prikazana je na slici 7. Na slici su točkama prikazani trenutci u kojima su dobivena akustička mjerenja. Vidljivo je da se udaljenost između dvaju vozila održava između 2-10 metara. Tokom sredine misije, gdje su akustička mjerenja dostupnija, vidljiva je postepena stabilizacija u praćenju. Prema kraju misije, zbog izostanaka akustičkog signala u nepogodnom okruženju, mjerenja su nedostupnija te se degradira kvaliteta praćenja. Degradacija je vidiljiva u obliku većih oscilacija udaljenosti odnosno težeg praćenja. Treba primijetiti da se nedostatak mjerenja reflektira i u porastu kriterijske funkcije u slici 6.

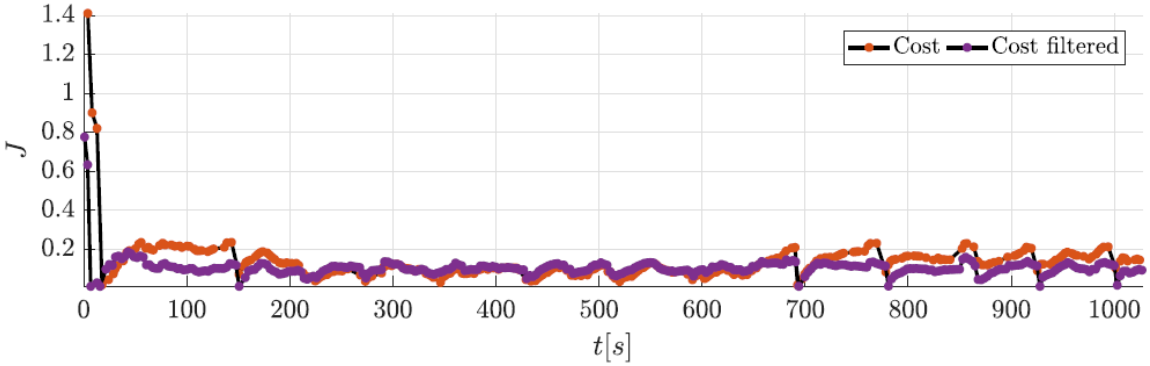

Slika 6. Kriterij osmotrivosti i njegova filtrirana vrijednost korištena za upravljanje.

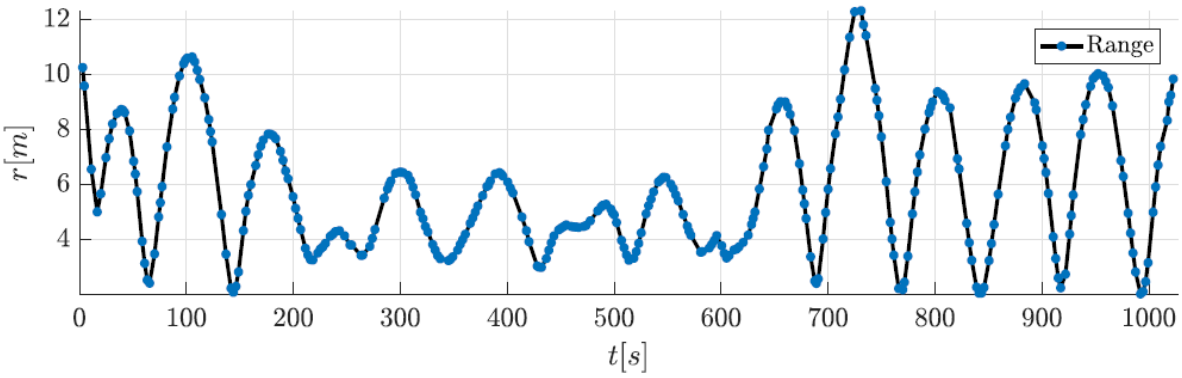

Slika 7. Relativna udaljenost površinskog i podvodnog vozila tokom eksperimenta.

Slično kao i u prethodnim eksperimentima, pozicija na podvodnom vozilu estimirana je kinematičkim modelom relativne udaljenosti čija matrica kovarijance se koristi za izračun kriterija optimizacije. Apsolutna pozicija površinskog vozila se estimira na podvodnom vozilu kako bi se mogla izračunati apsolutna pozicija podvodnog vozila. Ova estimacija koristi kinematički model korigiran s mjerenjima pozicije površinskog

vozila koja se dobivaju preko akustike. Na slici 8 su prikazani odzivi i pogreške u estimaciji pozicija na podvodnom vozilu. U slučaju kad akustička mjerenja nisu dostupna dulje vrijeme pojavljuje se odstupanje između estimata i prave pozicije površinskog vozila. Ovo je vidljivo u skokovima pogreške estimata za površinsko (Beacon) kad se dobije novo mjerenje. Promatrajući poziciju površinskog vozila, na slikama je vidljivo kruženje površinskog vozila (pravilne oscilacije u odzivu) i praćenje trajektorije podvodnog vozila.

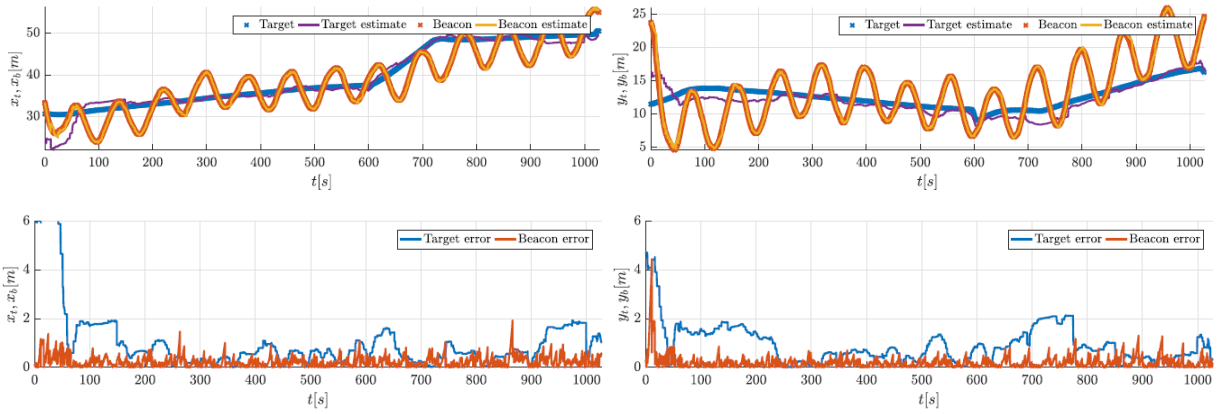

Slika 8. Estimacija pozicije podvodnog vozila (Target) i površinskog vozila (Beacon). Donje slike pokazuju pogrešku estimata pozicije na podvodnom vozilu za slučaj oba vozila.

U D4.4 definiran je kut $\tilde{\alpha}$ kao kut između vektora relativne udaljenosti i vektora brzine površinskog vozila. Ovaj kut je direktno vezan s osmotrivosti analiziranog sustava. Idealno bi spomenuti vektori bili pod pravim kutem kad je potpuno zadovoljena osmotrivost. Kako je objašnjeno u D4.4., zbog prirode gibanja, vektori neće biti stalno pod idealnim kutem, ali algoritam teži što manjoj varijaciji oko idealne vrijednosti. Slika 9 prikazuje raspored kuta $\tilde{\alpha}$ tokom eksperimenta. Iz slike je vidljivo da je većina mjerenja uzeta blizu idealnog relativnog kuta što validira funkcionalnost algoritma.

Kako bi se algoritam usporedio s alternativnim regulatorima dostupnim u literaturi, provedena je i dodatna analiza rezultata. Razmotrena je duljina pređene putanje (Σ_s) i FIM indeks kvalitete ($|FIM|_{avg}$). FIM metoda je izabrana obzirom da može dati optimalne trajektorije i maksimizirati osmotrivost sustava nakon provedenih eksperimenata. U tom slučaju poznata je trajektorija podvodnog vozila i algoritam se može provesti *offline*. Dodatni parametar m označava horizont mjerenja koji se uzima u obzir. U online operaciji FIM algoritma, kod manje mogućnosti predikcije trajektorije koristi se i manji horizont, dok se veći horizont uzima za lakše predvidiva gibanja podvodnog vozila (npr. linijsko gibanje). Sam FIM pristup je alternativa predloženom regulatoru koja može dati bolje rezultate, ali za izračune je potrebno poznavanje buduće putanje podvodnog vozila što za predloženi algoritam nije preduvjet.

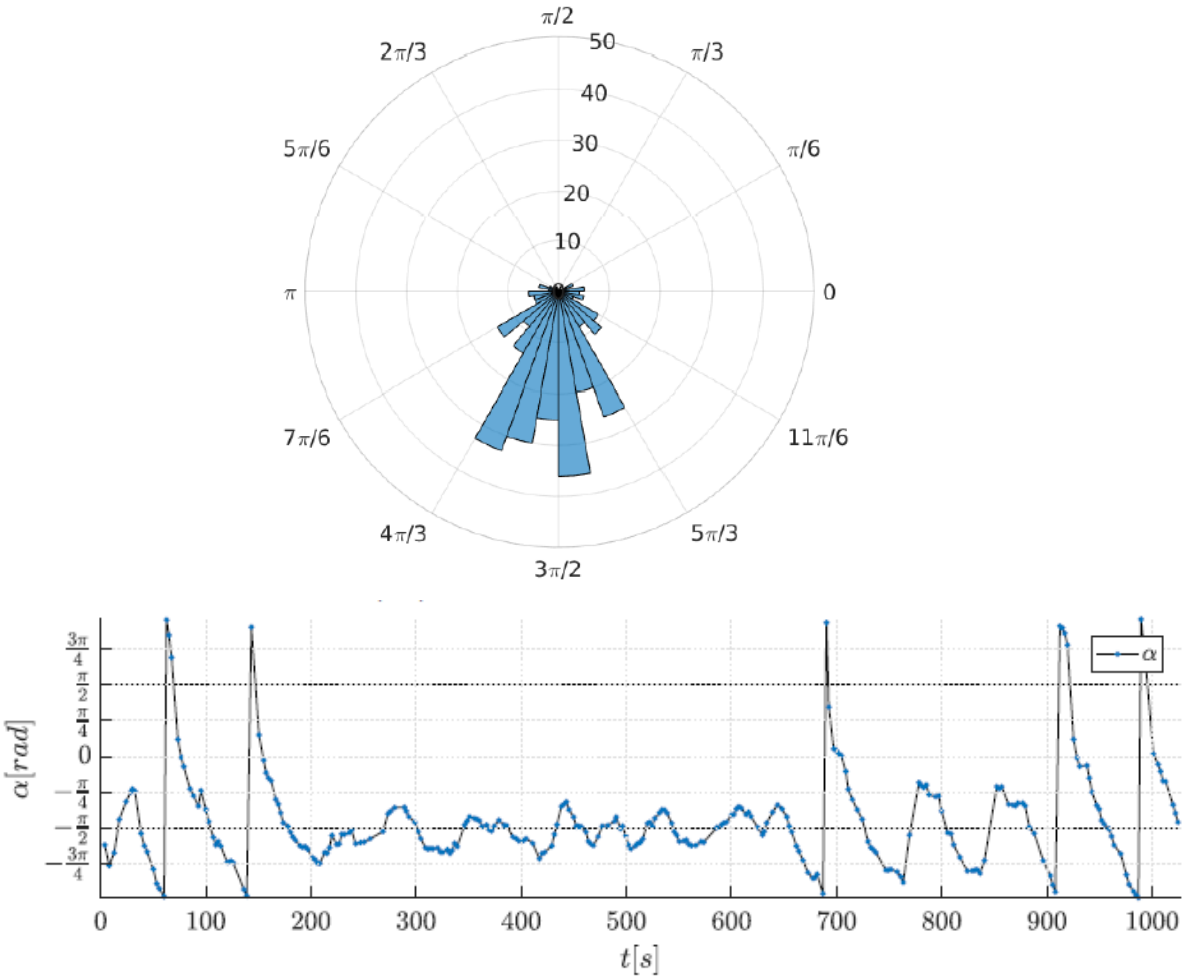

Slika 9. (gore) Raspored kuta $\tilde{\alpha}$ i njegov vremenski prikaz (dolje)

Rezultati su prikazani u tablici 1 i pokazuju da je predloženi algoritam sumjerljiv FIM algoritmu uz horizont m=3. Za veće horizonte ukupno pređena putanja površinskog vozila je kraća i indeks kvalitete veći što indicira i bolje rješenje za istu ili bolju kvalitetu mjerenja.

Tablica 1. Usporedba predloženog algoritma traženja maksimuma s alternativnom FIM metodom analiziranoj u drugoj literaturi.

	$\Sigma_s(m)$	$\lvert FIM \rvert_{avg}$
Predloženi algoritam	361	0.71
FIM (m=1)	468	0.12
FIM (m=3)	337	0.72
FIM (m=12)	204	0.93

Zaključak

S povećanim interesom za podmorje raste i potreba za kvalitetnom podvodnom lokalizacijom. Pristup koji koristi samo mjerenja udaljenosti je cijenom najpristupačniji i lako primjenjiv na razne sustave. Smanjenu informativnosti mjerenja udaljenosti potrebno je kompenzirati pokretljivošću platforme. U realnim slučajevima kod planiranja misija potrebno je razmotriti trajanje misije i količinu dostupne energije. Zbog toga u nekim slučajevima neće biti moguće koristiti predloženi algoritam dok će u drugima predstavljati kvalitetnu alternativu složenijim oblicima lokalizacije.

Eksperimenti su pokazali da uz nepoznatu dinamiku, smetnje i kašnjenje signala predloženi algoritam osigurava praćenje i ispomoć u navigaciji podvodnog vozila. Pokazana je primjenjivost na potpuno aktuirana i podaktuirana plovila. Posebna primjenjivost ovog algoritma je u slučajevima kad se prati sporija podvodna vozila s nepredvidivim gibanjem. Čak i u slučajevima kad možemo predvidjeti gibanje podvodnog vozila kroz nekoliko koraka pokazuje se da je predloženi algoritam kvalitetom usporediv drugim algoritmima u literaturi. S druge strane, za slučajeve vrlo predvidivog gibanja pokazano je da su alternativni algoritmi kao FIM vremenski i energetski efikasniji.

Reference

[1] Salinas, D., Pascoal, A., Aranda, J., “Optimal sensor trajectories for mobile underwater target positioning with noisy range measurements”, in Proc. 19th IFAC World Congress 2014, Cape Town, South Africa, 24-29 August, 2014. IEEE, 2014, pages 24-29.

[2] Moreno Salinas, D., “Adaptive sensor networks for mobile target localization and tracking”, PhD thesis, 2013.

[3] Pedro, M., Moreno-Salinas, D., Crasta, N., Pascoal, A., “Underwater single-beacon localization: Optimal trajectory planning and minimum-energy estimation”, IFACPapersOnLine, Vol. 48, No. 2, 2015, pages 155 - 160, 4th IFAC Workshop onNavigation, Guidance and Controlof Underwater Vehicles NGCUV 2015.