



## Implementation of a combined acoustic-optical obstacle avoidance system in autonomous underwater vehicles using wall following and stall following methods

Qolamreza Nadalinia Charei <sup>1\*</sup>, Alireza Ahmadyfard <sup>2</sup>

<sup>1</sup> Ph.D. Student, Shahrood University of Technology, Faculty of Electrical and Robotics Engineering,

[Reza.nadalinia@shahroodut.ac.ir](mailto:Reza.nadalinia@shahroodut.ac.ir)

<sup>2</sup> Professor, Shahrood University of Technology, Faculty of Electrical and Robotics Engineering,

[ahmadyfard@shahroodut.ac.ir](mailto:ahmadyfard@shahroodut.ac.ir)

### ARTICLE INFO

#### Article History:

Received: 17 Mar 2026

Last modification: 23 Jun 2026

Accepted: 27 Jun 2026

Available online: 27 Jun 2026

#### Article type:

#### Keywords:

auv

Obstacle avoidance

Sonar

Integrated acoustic-optic detection

Deep learning

### ABSTRACT

Obstacle detection and avoidance in marine environments remains a major challenge for autonomous underwater vehicles (AUVs) due to adverse lighting conditions, high noise of acoustic data, and high cost of long-range sonars. In this paper, we present an integrated acousto-optic framework for obstacle detection and safe path planning, which is developed based on the fusion of camera data and two consecutive sonar scans, using deep learning networks and the artificial potential field (APF) algorithm. In the surface motion phase, real camera images are combined with sonar data, while in the subsurface motion phase, estimated virtual images of obstacles are combined with sonar data to maintain detection stability. For obstacle detection, a U-NET network with a MobileNetV2 encoder and an LSTM network are used to predict the positions and motion of moving obstacles. In addition, two methods, the wall-following method (WFM) and the stagnation-following method (SFM), are introduced to convert the optimal path obtained from the APF into target images suitable for network training. Experimental results based on real and simulated data show that the proposed method provides high detection accuracy in both surface and subsurface phases, such that the safe path detection accuracy with two consecutive sonar scans using WFM based on the IOU criterion reaches 0.965. In addition, the integration of camera and sonar data increases the detection range of underwater obstacles by approximately 15 m compared to using sonar alone and significantly reduces the steering correction angle.

ISSN: 2645-8136



### DOI:

**Copyright:** © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license [<https://creativecommons.org/licenses/by/4.0/>]



## طراحی سامانه عبور از موانع تلفیقی اکوستیکی- اپتیکی در روندهای زیرآبی خودران به کمک روش پیروی دیواره و پیروی غرفه

غلامرضا نادعلی نیاچاری<sup>۱\*</sup>، علیرضا احمدی فرد<sup>۲</sup>

<sup>۱</sup> دانشجوی دکتری، گروه الکترونیک، دانشکده مهندسی برق و رباتیک، دانشگاه شاهرود، ایران، [Reza.nadalinia@shahroodut.ac.ir](mailto:Reza.nadalinia@shahroodut.ac.ir)  
<sup>۲</sup> استاد گروه الکترونیک، دانشکده مهندسی برق و رباتیک، دانشگاه شاهرود، ایران، [ahmadyfard@shahroodut.ac.ir](mailto:ahmadyfard@shahroodut.ac.ir)

### چکیده

تشخیص موانع و اجتناب از برخورد با آنها یکی از چالش‌های بزرگ برای وسایل نقلیه زیرآبی خودران (AUV) محسوب می‌شود. برای اجتناب از بکارگیری سونارهای بُرد بلند که قیمت بالایی دارند، این مسئله دشوارتر می‌شود. در این مقاله، یک چارچوب اکوستیکی-اپتیکی یکپارچه برای تشخیص مانع و برنامه‌ریزی مسیر ایمن ارائه می‌گردد. این روش بر اساس استفاده توأم تصویر دوربین مرنی، هنگامیکه وسیله نزدیک سطح آب بالا می‌آید، و دو اسکن متوالی سونار، هنگامیکه وسیله زیر آب حرکت می‌کند، طراحی شده است. در روش پیشنهادی از یک شبکه U-NET با یک رمزگذار MobileNetV2 برای تشخیص موانع و از یک شبکه LSTM برای پیش‌بینی موقعیت‌ها و حرکت موانع متحرک استفاده می‌شود. همچنین از ترکیب شبکه U-NET و الگوریتم میدان پتانسیل مصنوعی (APF) برای بدست آوردن مسیر بهینه وسیله نقلیه، استفاده شده است. علاوه بر این، دو روش، روش پیروی دیواره (WFM) و روش پیروی غرفه (SFM)، برای تبدیل مسیر بهینه به دست‌آمده از APF به تصاویر هدف مناسب برای آموزش شبکه معرفی شده‌اند. نتایج تجربی بر اساس داده‌های واقعی و شبیه‌سازی شده نشان می‌دهد که دقت تشخیص مسیر ایمن با استفاده از WFM بر اساس معیار IOU به ۰.۹۶۵ می‌رسد. علاوه بر این، بُرد تشخیص موانع زیر آب در مقایسه با استفاده از اطلاعات سونار به تنهایی با بُرد مشابه تقریباً ۱۵ متر افزایش می‌یابد. این مسئله زاویه تصحیح سمت حرکت وسیله را به طور قابل توجهی کاهش می‌دهد.

### اطلاعات مقاله

ناریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۱۲/۲۶  
تاریخ اصلاح مقاله: ۱۴۰۵/۰۴/۰۲  
تاریخ پذیرش مقاله: ۱۴۰۵/۰۴/۰۶  
تاریخ انتشار مقاله: ۱۴۰۵/۰۴/۰۶

نوع مقاله:

کلمات کلیدی:

وسایل نقلیه زیرآبی خودران  
اجتناب از موانع  
سونار  
یادگیری عمیق  
تلفیق اکوستیکی اپتیکی

DOI:

حق نشر: © ۲۰۲۵ توسط نویسندگان. این اثر برای انتشار با دسترسی آزاد، تحت شرایط و ضوابط مجوز (CC BY) ارسال شده است.

ISSN: 2645-8136



## ۱ - مقدمه

تشخیص موانع در ناوبری زیرآب به دلیل آشفتگی ناشی از تلاطم و شفاف نبودن محیط آب بسیار چالش برانگیز است. بنابراین، استفاده از تجهیزات زیرآبی مناسب برای تشخیص دقیق محیط آبی ضروری است [۱]. در سال‌های اخیر، پیشرفت در حساسیت و محدوده تشخیص حسگرهای سونار و فناوری های جدید در تامین انرژی الکتریکی، باعث شده است که روندهای بدون سرنشین خودکار (AUVها) به طور گسترده در بررسی منابع دریایی، اکتشاف زیرآبی و کاربردهای نظامی مورد استفاده قرار گیرند [۲-۳]. تشخیص و اجتناب از برخورد با موانع در محیط‌های آبی به طور گسترده مورد مطالعه قرار گرفته است [۴-۶]. در این مقاله، ما یک سیستم یکپارچه آکوستیک-اپتیکی برای تشخیص موانع و برنامه‌ریزی مسیر پیشنهاد می‌کنیم.

در سیستم‌های خودران زیرآبی، تشخیص و اجتناب از برخورد با موانع برای ایمنی و کارایی مأموریت حیاتی است. در این سیستم‌ها به طور گسترده از فناوری‌های تصویربرداری، پردازش داده‌ها و الگوریتم‌های هوشمند استفاده می‌شود. چهار نوع تکنولوژی تصویربرداری رایج شامل استفاده از حسگر نوری [۷-۹]، رادار [۱۰]، [۱۱]، مادون قرمز [۱۲]، [۱۳] و تصاویر مرئی [۱۴] می‌شود. تصاویر اخذ شده با دوربین‌های مرئی به دلیل وضوح بالا، تنوع رنگ و بافت، هزینه نسبتاً کم در شرایط مختلف محیطی خارج از آب، از رایج‌ترین روش‌های تصویربرداری هستند. در سال‌های اخیر، استفاده از شبکه‌های عصبی کانولوشن (CNN<sup>2</sup>) انقلاب بزرگی در تشخیص اهداف دریایی ایجاد کرده است [۱۵-۱۶]. الگوریتم‌هایی مانند Faster R-CNN [17]، YOLO v2 [18] و SSD [19]، به تعادلی بین دقت و سرعت دست یافته‌اند. R-CNN سریع‌تر [۲۰] به دلیل دقت بالای تشخیص شناخته شده است، نسخه‌های جدید YOLO به دلیل ساختار سرتاسری خود برای تشخیص بلادرنگ مناسب است و SSD نیز با استفاده از ساختار ویژگی‌های هرمی سلسله‌مراتبی در افزایش سرعت و دقت موفق بوده است. با این حال بدلیل عدم شفاف بودن محیط زیر آب محدوده تشخیص موانع زیر آب به کمک دوربین‌های مرئی بسیار کم است.

برخلاف تصویر برداری مرئی، حسگرهای سونار در شناسایی موانع زیر آب موفق‌تر هستند منتهی قیمت این تجهیزات با بُرد مناسب برای تشخیص موانع در ناوبری زیر آب بسیار بالا است. روش‌های سنتی تشخیص موانع به کمک تصاویر سونار، مانند جریان نوری و تفاضل فریم [۲۱-۲۳]، گام به گام، پیچیده و بسیار وابسته به

تجربه هستند. این روش‌ها اغلب تعمیم ضعیف، دقت کم و نوسانات زیادی در شرایط دنیای واقعی دارند [۲۴-۲۶]. رویکردهای یادگیری عمیق از CNNها برای استخراج ویژگی، تخمین احتمال وجود موانع استفاده می‌کنند [۲۷-۲۸]. مطالعات والدمار-تورو [۲۹] و کیم [۳۰-۳۱] نشان داده‌اند که شبکه‌های CNN و YOLO با استفاده از تکنیک‌هایی مانند آموزش چند مقیاسی و نرمال‌سازی دسته‌ای به طور قابل توجهی دقت و سرعت تشخیص موانع را افزایش می‌دهند. با این حال، پیچیدگی زیر آب، هنوز هم امکان بهبود مدل‌ها و افزایش پایداری در شرایط سخت را فراهم می‌کند.

پس از تشخیص موانع مرحله بعدی ناوبری خودران (AUV) برای اجتناب از برخورد با موانع است. این یک مسئله کلیدی در طراحی مسیر حرکت AUVها است. الگوریتم‌های اجتناب از موانع بسیار متنوع هستند. از روش‌های کلاسیک مانند تطبیق الگو که فقط در محیط‌های ایستا قابل استفاده هستند، گرفته تا روش‌های پیچیده‌تر مانند APF و الگوریتم‌های تکاملی که برای محیط‌های پویا مناسبند ولی خطر متوقف شدن در بهینه محلی را دارند [۳۲-۳۶]. الگوریتم‌های فازی که می‌توانند مسیر فرار مناسب را بدون نیاز به مدل‌سازی دقیق و تعریف قوانین منطقی تعیین کنند، ولی در پوشش همه سناریوها محدودیت دارند. الگوریتم‌های مبتنی بر شبکه عصبی، از جمله شبکه‌های هاپفیلد، نقشه‌های خودسازمانده و شبکه‌های تطبیقی، مزایای یادگیری و سازگاری محیطی را ارائه می‌دهند [۳۷-۳۸]. با این حال، چالش‌هایی مانند نیاز به مجموعه داده‌های بزرگ برای آموزش و تأخیر پردازش، عملکرد بلادرنگ را تهدید می‌کند.

در این مقاله، یک سیستم ترکیبی آکوستیک-اپتیکی برای تشخیص موانع و برنامه‌ریزی مسیر فرار پیشنهاد می‌شود. بُرد سونار که به شدت بر دقت تشخیص موانع تأثیر می‌گذارد، رابطه‌ای نمایی با قیمت حسگر سونار دارد. از طرفی بدلیل وجود تلاطم در سطح آب تصویر سونار در نزدیکی سطح آب دارای نویز زیادی است.

از سوی دیگر، سیستم تصویربرداری مرئی به دلیل پراکندگی جذب نور در زیر آب بُرد بسیار کوتاهی دارد. از آنجایی که بخشی از موانعی نظیر کشتی‌ها، صخره‌ها و جزایر، بالای سطح آب و بخشی زیر آب قرار دارند، ادغام داده‌های دوربین مرئی بالای سطح آب و تصاویر سونار در زیر سطح آب می‌تواند ضعف هر یک از این حسگر را جبران کند. از طرفی برای این منظور نیاز به حسگر سونار با بُرد بلند منتفی می‌شود. این رویکرد، میزان درک رونده از محیط اطراف را بدون نیاز به سونار بُرد بلند که پرهزینه است، کاهش می‌دهد. هنگامی که AUV در سطح آب است، دوربین مرئی از محیط خارج آب تصویر برداری می‌کند؛ هنگام حرکت رونده در زیر آب، داده‌های حسگر سونار و تصاویر مرئی ساختگی برای تشخیص موانع ترکیب می‌شوند. در مدت حرکت رونده در زیر آب، تصویر ساختگی مرئی

<sup>1</sup> Autonomous Underwater Vehicles

<sup>2</sup> Convolutional Neural Networks



شکل ۱- نمایی از AUV مجهز به سونار جلونگر و دوربین

جدول ۱- مشخصات اصلی AUV

پارامتر	مقدار
طول	۲.۴ متر
قطر	۲۵ سانتیمتر
وزن	۱۱۰ کیلوگرم
عمق عملکردی	۵۰ متر
سرعت	۲ متر بر ثانیه
سونار	جلونگر
نوع ناوبری	INS/GNSS/TAM

### ۱-۲- معرفی حسگر سونار و دوربین

یک سونار Ping360 موانع زیر آب و نزدیک سطح را تشخیص می‌دهد (شکل ۲-الف). زاویه دید سونار به ۹۰ درجه محدود شده است و هر اسکن ۱۲۲۴ بایت داده تولید می‌کند که یک تصویر ۹۰×۱۲۲۴ را تشکیل می‌دهد. ستون‌ها نشان‌دهنده زوایای اسکن و ردیف‌ها نشان‌دهنده فاصله هستند. برای راحتی و پردازش سریع‌تر، تصاویر به ۲۵۶×۱۲۸ تغییر اندازه داده شده‌اند. برای تصویربرداری از سطح آب، از یک دوربین SONY ضد آب ۲ مگاپیکسلی استفاده می‌شود (شکل ۲-ب). در جداول ۲ و ۳ مشخصات فنی حسگر سونار و دوربین خلاصه شده است.



شکل ۲- تصاویر حسگر سونار و دوربین مورد استفاده (الف) حسگر سونار (ب) دوربین

جدول ۲- مشخصات فنی سونار Ping360

پارامتر	مقدار
فرکانس	۷۵۰ کیلوهرتز
بیشینه بُرد	۶۰ متر
تغذیه الکتریکی	۱۱-۲۵ ولت
بیشینه توان مصرفی	۵ وات
پروتکل ارتباطی	RS485, USB, Ethernet
میدان دید	۳۶۰ درجه

توسط سیستم پیشنهادی تولید شده که موقعیت موانع را خارج آب مشخص می‌کند. تشخیص موانع و مسیر بهینه برای حرکت رونده با استفاده از یک شبکه U-NET با میدان پتانسیل مصنوعی (APF<sup>3</sup>) انجام می‌شود. همانطور که در بخش نتایج نشان داده خواهد شد، ادغام داده‌ها از دو اسکن متوالی سونار و تصاویر دوربین مرئی، دقت سیستم تشخیص موانع را نسبت به سیستمی که تنها بر اساس حسگر سونار طراحی شده است، افزایش می‌دهد. در روش پیشنهادی برای بازنمایی مسیر بهینه بدست آمده به تصویرهدف که مدل‌ها آموزش داده شوند، از روش‌های پیروی دیواره (WFM<sup>4</sup>) و پیروی غرفه (SFM<sup>5</sup>) استفاده می‌شود. این روش‌ها آموزش را تسهیل کرده و دقت تشخیص را افزایش می‌دهند. همچنین، از یک مدل حافظه طولانی کوتاه‌مدت (LSTM<sup>6</sup>) برای پیش‌بینی حرکات مانع بر اساس توالی مکان‌های قبلی آن استفاده می‌شود. نتایج تجربی نشان می‌دهد که ادغام داده‌های دو اسکن متوالی سونار و دوربین مرئی دقت و بُرد تشخیص موانع را افزایش می‌دهد. دستاوردهای این تحقیق عبارتند از:

- تشخیص موانع در فواصل دور در حین حرکت سطحی رونده
- کاهش ضعف حسگر سونار در نزدیکی مرز آب و هوا
- افزایش بُرد عملیاتی رونده و دقت تشخیص موانع با بهره‌گیری همزمان از تصاویر دوربین مرئی و حسگر سونار
- عدم نیاز به سونار بُرد بلند

### ۲- معرفی AUV

شکل ۱، تصویر رونده (AUV) مورد استفاده در این مطالعه را نشان می‌دهد. همانطور که نشان داده شده است، یک سونار در جلوی رونده و یک دوربین در بالای آن نصب شده است. هنگامی که رونده جهت اتصال حسگر GPS با ماهواره‌ها (تقریباً ۶۰ ثانیه) نزدیک سطح آب است، دوربین بالای سطح آب قرار گرفته و تصویری از صحنه بالای سطح آب را ثبت می‌کند. زمانی که (با توجه به حسگر ناوبری این مقدار متغیر است در این تحقیق ۶۰۰ ثانیه در نظر گرفته شده) رونده در زیر آب حرکت می‌کند، حسگر سونار محیط اطراف رونده را اسکن می‌کند. در سیستم پیشنهادی هنگام حرکت رونده در زیر آب تخمینی از تصویر محیط بالای آب به کمک مدل‌های یادگیری ایجاد می‌شود که در کنار اسکن‌های حسگر سونار برای تشخیص موانع و ناوبری مورد استفاده قرار می‌گیرد. سیستم کنترل مرکزی تعبیه شده در داخل رونده، سُکان رونده را برای یک مسیر ایمن بر اساس موانع شناسایی شده تنظیم می‌کند. مشخصات اصلی رونده در جدول ۱ ارائه شده است.

<sup>3</sup> Artificial Potential Field

<sup>4</sup> Wall Following Method

<sup>5</sup> Stall following method

<sup>6</sup> Long Short-Term Memory

جدول ۳ - مشخصات فنی دوربین 2MP SONY Image

پارامتر	مقدار
نوع سیستم	PAL/NTSC
وضوح	1920(H)*1080(V)
زمان شاتر	1/25(1/30) s to 1/50,000 s
زاویه میدان دید	120°
نرخ فیلم برداری	PAL: 1080p/25fps
ولتاژ مصرفی	DC5-12V
ابعاد	50mm×48mm
عمق عملکردی	500m

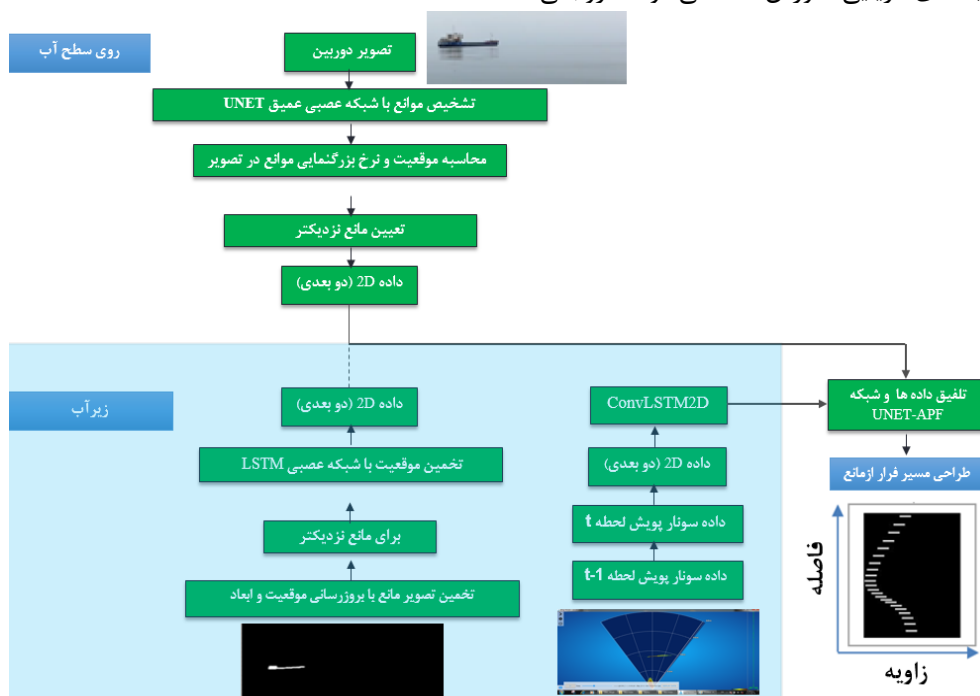
این شبکه یک تصویر باینری است که موانع احتمالی در آن با پیکسل‌های سفید مشخص شده‌اند.

ورودی اسکن حسگر سونار وارد یک بلوک حافظه شده تا امکان دسترسی به دو نسخه متوالی از اسکن حسگر سونار ممکن گردد. دو اسکن متوالی سونار برای تشخیص موانع زیر آب به یک شبکه ConvLSTM داده می‌شود. این شبکه برای تحلیل داده‌های سری زمانی عملکرد مطلوبی دارد. نکته‌ای که باید به آن توجه نمود این است که بخشی از موانع شناور، مثل کشتی‌ها، توسط دوربین در سطح آب و بخش دیگری توسط حسگر سونار در زیر آب قابل تشخیص هستند. ترکیب این اطلاعات به تشخیص دقیقتر موانع کمک می‌کند.

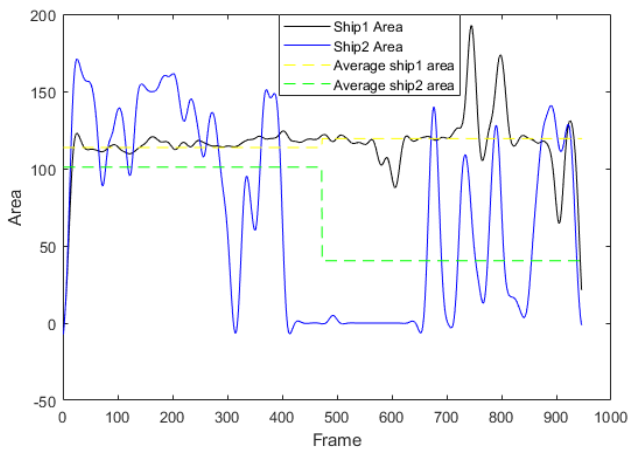
توجه به این نکته اهمیت دارد که بجز زمان‌های کوتاهی (تقریباً ۶۰ ثانیه) که رونده برای اصلاح سمت با GPS و تصویربرداری با دوربین به سطح آب می‌آید، بقیه مواقع (تقریباً ۱۰ دقیقه) در زیر آب حرکت می‌کند. لذا در لحظاتی که رونده زیر آب است تصویری از محیط بیرون آب در دسترس نیست تا با اطلاعات حسگر سونار در مدل پیشنهادی تلفیق شود. برای حل این مسئله، از تصویر باینری خروجی شبکه UNET در آخرین لحظه‌ای که رونده در سطح آب بوده استفاده نموده و به کمک یک شبکه STM با توجه به حرکت رونده، تخمینی از تصویر مانع شبیه‌سازی می‌شود. لذا مطابق شکل ۳ خروجی تشخیص مانع از حسگر سونار یا با تصویر خروجی باینری UNET تلفیق می‌شود (موقعی که رونده در سطح آب است) یا با تصویر شبیه‌سازی شده توسط شبکه LSTM تلفیق می‌شود (زمانی که رونده زیر آب حرکت می‌کند).

### ۳- سیستم تشخیص موانع و ناوبری رونده

برای ناوبری خودکار روندهی زیر آب از نقطه مبدا به سمت مقصد، دو هدف اساسی دنبال می‌شود: تشخیص موانع در مسیر حرکت و تغییر سمت رونده برای اجتناب از برخورد با آنها. ورودی‌های سیستم پیشنهادی، تصاویر دوربین اخذ شده در لحظات کوتاهی است که رونده به سطح آب می‌آید و اسکن حسگر سونار از محیط زیر آب است. شکل ۳ روند نمای مدل پیشنهادی را نشان می‌دهد. این مدل دارای دو شاخه ورودی است. در شاخه بالایی تصویر دوربین به یک شبکه UNET داده می‌شود تا نزدیکترین مانع قابل مشاهده در سطح آب را از پس زمینه جدا کند. در شاخه پایینی دو اسکن پی‌پی حسگر سونار برای استخراج ویژگی و شناسایی موانع زیر آب به یک شبکه ConvLSTM داده می‌شود. اطلاعات استخراج شده از این شاخه‌ها تلفیق شده تا در شاخه خروجی نزدیکترین مانع تشخیص داده شده و مسیر فرار طراحی شود. شبکه UNET برای ناحیه‌بندی موانع، به کمک پایگاه تصویری از اشیاء متعارف در محیط‌های دریایی آموزش داده می‌شود.



شکل ۳- نمودار بلوکی کلی سیستم تشخیص و اجتناب از مانع در دو فاز حرکت در سطح و زیر آب



شکل ۵- نمودار مساحت به دست آمده در فریم‌های ویدیویی برای دو مانع مختلف

### ۳-۳- تخمین موقعیت و حرکت مانع با استفاده از شبکه LSTM


پس از تشخیص مانع نزدیک به رونده، مرکز ثقل مانع در راستای محور X (افقی) در تصویر باینری ناحیه بندی شده محاسبه می‌شود. مرکز ثقل مانع در تصاویر متوالی بصورت داده های سری زمانی به یک شبکه LSTM داده می‌شود تا موقعیت مانع را هنگامی که رونده زیر آب است، پیش‌بینی کند. شکل‌های ۶ و ۷ معماری شبکه LSTM استفاده شده و نحوه تخمین مسیر حرکت مانع در راستای افقی توسط این شبکه را در روش پیشنهادی نشان می‌دهد.

### ۳-۱- تشخیص موانع در تصاویر دوربین با استفاده از UNET

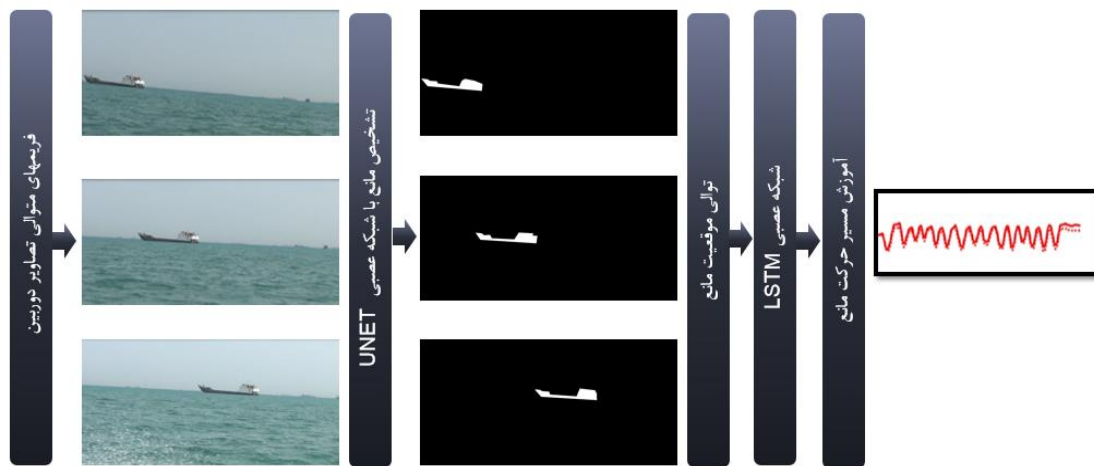
شبکه UNET مورد استفاده برای تشخیص موانع قابل مشاهده در سطح آب، از یک رمزگذار MobileNetV2 (شکل ۴) استفاده می‌کند که معماری استاندارد رمزگذار-رمزگشای UNET را حفظ می‌کند. با توجه به ساختار ساده MobileNetV2، پارامترهای قابل آموزش کمی دارد و تشخیص موانع سطح آب را در زمان واقعی ممکن می‌سازد. این شبکه برای سیستم‌هایی که قدرت پردازش محدود دارند، مناسب است. خروجی شبکه UNET یک تصویر باینری به ابعاد تصویر ورودی است.

### ۳-۲- تشخیص نزدیکترین مانع به رونده

وقتی چندین مانع در تصویر دوربین ظاهر می‌شوند، برای بهینه‌سازی مانورهای AUV باید نزدیکترین مانع شناسایی شود [۳۹]. تعیین مانع نزدیکتر با این اصل صورت می‌گیرد که با حرکت رونده، اجسام نزدیکتر نرخ رشد بیشتری نسبت به اجسام دورتر نسبت به دوربین دارند. برای نشان دادن این موضوع ویدئویی از دو مانع (دو کشتی) توسط یک دوربین تصویر برداری شدند. شکل ۵ (با ۹۴۶ فریم) تعداد پیکسل‌های اشغال شده هر کشتی در فریم تصویر و مقادیر میانگین آنها را نشان می‌دهد. مساحت پیکسلی کشتی نزدیکتر، در تصویر سریعتر رشد می‌کند و معیار دقیقی برای تشخیص مانع نزدیک ارائه می‌دهد.



شکل ۴- معماری شبکه پیاده‌سازی شده (UNET) برای ناحیه بندی مانع روی آب



شکل ۶- نحوه تخمین مسیر حرکت مانع در راستای افقی توسط شبکه LSTM در روش پیشنهادی



شکل ۷- مراحل تخمین جابجایی افقی مرکز ثقل مانع به کمک شبکه LSTM

APF، بدام افتادن در حداقل‌های محلی است که می‌تواند باعث حرکت نوسانی بین موانع شود. ادغام UNET با آموزش نظارت شده با ارائه مسیرهای ایمن بهینه حاصل از روش APF، بر این مشکل غلبه می‌کند. تصویر مانع زیر آب پیش‌بینی شده از داده‌های LSTM و سونار، ادغام شده و برای محاسبه ناحیه ناوبری ایمن به شبکه UNET-APF وارد می‌شود. این شبکه از سه بلوک اصلی Double\_conv\_block، Downsample\_block و Upsample\_block تشکیل شده است (شکل ۹).

#### ۴-۱- تبدیل تصویر پتانسیل مصنوعی به تصویر هدف برای آموزش شبکه

تصویر مسیر فرار باید با ابعاد ماتریس اسکن حسگر سونار مطابقت داشته باشد. ماتریس حسگر سونار به ابعاد  $1224 \times 90$  است که برای سادگی محاسبات به ابعاد  $256 \times 128$  تغییر اندازه داده می‌شود. همچنین فاصله ایمن حرکت رونده تا ۱۵ متر در اطراف هر مانع در نظر گرفته می‌شود (۵ تا ۸ برابر طول AUV). سرعت AUV و حداکثر انحراف برای ارائه مسیرهای ایمن بهینه حاصل از روش APF به ترتیب ۲ متر بر ثانیه و ۷ درجه بر ثانیه در نظر گرفته می‌شود. جهت تبدیل تصویر پتانسیل مصنوعی به یک تصویر قابل درک برای خروجی شبکه جهت تسهیل آموزش به عنوان تصویر هدف، دو راه حل در نظر گرفته شد که در ادامه توضیح داده می‌شود.

• روش پیروی غرفه (SFM): تغییرات جهت به صورت جعبه‌هایی در تصویر هدف نمایش داده می‌شوند تا اطلاعات

#### ۴-۳- شبیه‌سازی تصویر باینری مانع روی آب هنگام حرکت رونده در زیر آب

همانطوریکه گفته شد هنگام حرکت رونده در زیر آب مانع تشخیص داده شده از اسکن‌های حسگر سونار با تصویر شبیه‌سازی شده مانع سطح آب تلفیق می‌شود. برای شبیه‌سازی تصویر باینری مانع در سطح آب، هنگامی که رونده زیر آب حرکت می‌کند و دوربین در دسترس نیست، نیاز به اطلاعات میزان جابجایی مانع در راستای افقی و تغییر ابعاد مانع داریم. میزان جابجایی مانع همانطوریکه در بخش قبل اشاره شد توسط شبکه LSTM تخمین زده می‌شود. میزان تغییر ابعاد مانع با توجه به دو تصویر قبلی مانع در سطح آب محاسبه می‌گردد. شکل ۸ مثالی از تصویر باینری مانع سطح آب که شبیه‌سازی شده است، را نشان می‌دهد.

#### ۴-۴- انحراف مسیر رونده برای اجتناب از برخورد با مانع


روش‌های متعددی برای بهینه‌سازی مسیر حرکت رونده ارائه شده است که از جمله می‌توان به روش‌های شبه‌الگوریتم، APF با توابع گاوسی<sup>۷</sup> و FIRAS و الگوریتم‌های تابع وزنی اشاره کرد [۴۰-۴۲]. نتایج شبیه‌سازی یک AUV با ۶ درجه آزادی و هدایت<sup>۸</sup> LOS با کنترل ردیابی متقاطع، نشان داد که روش‌های APF با توابع گاوسی و FIRAS کوتاه‌ترین مسیرها برای رسیدن رونده به مقصد را تولید می‌کنند. همچنین رونده در این روش‌ها به کمترین انرژی برای تغییر مسیر حرکت نیاز دارد و پس از اجتناب از موانع، به سرعت به مسیر اصلی بازمی‌گردد. یکی از محدودیت‌های روش‌های

<sup>۷</sup> Force Inducing Artificial Repulsion From the Surface

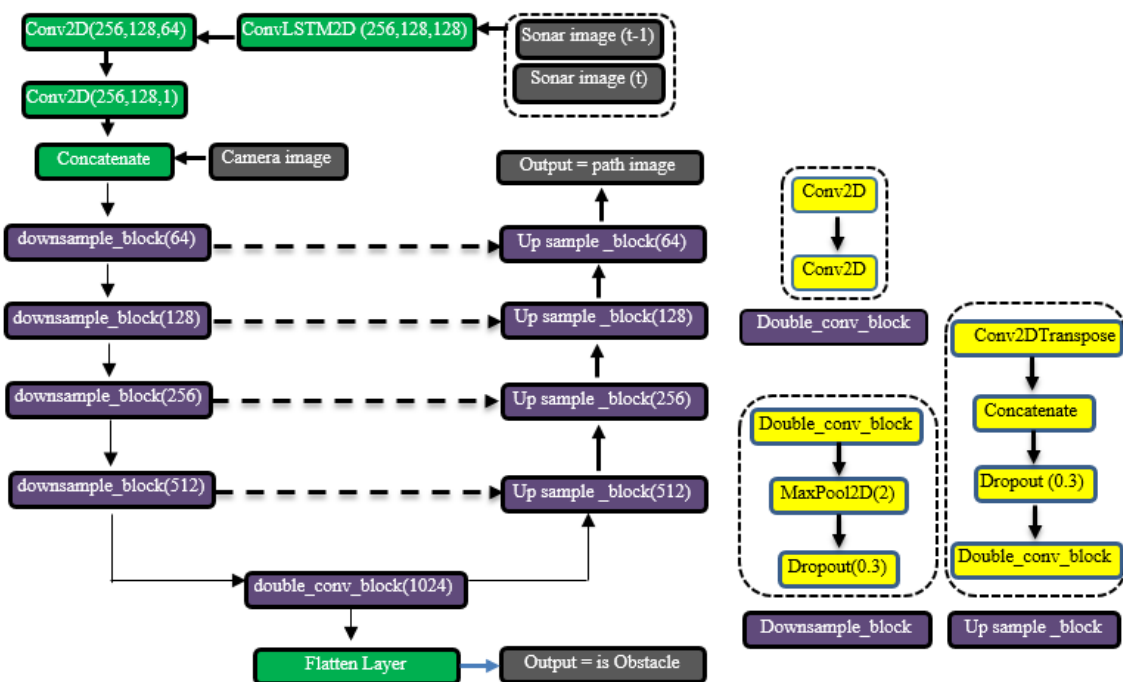
<sup>۸</sup> Line Of Sight

آموزشی افزایش یابد و امکان اصلاح مسیر در زمان واقعی فراهم شود (شکل ۱۰).

• روش پیروی دیواره (WFM): مسیر به دو ناحیه مجزا (تصویر دودویی) تبدیل می‌شود، که عبور از مرز، یک مسیر ایمن را تضمین می‌کند (شکل ۱۱).



شکل ۸- شبیه سازی تصویر باینری مانع هنگامی که رونده زیر آب حرکت می‌کند (الف) تصویر دوربین (ب) تصویر مانع آشکارسازی شده (ج) تصویر شبیه سازی شده مانع



شکل ۹- ساختار شبکه UNET که برای ادغام داده‌های دوربین و سونار و محاسبه مسیر فرار پیشنهاد شده است

## ۵- جمع‌آوری پایگاه‌های داده

برای انجام این تحقیق و ارزیابی روش پیشنهادی سه مجموعه داده تهیه شد (شکل ۱۲):

۱. تصاویر دوربین برای آموزش U-NET (۲۴۰۰ تصویر از ۱۲ نوع کشتی، ۲۵۶×۲۵۶ پیکسل، با ماسک متناظر به عنوان داده‌های واقعی).

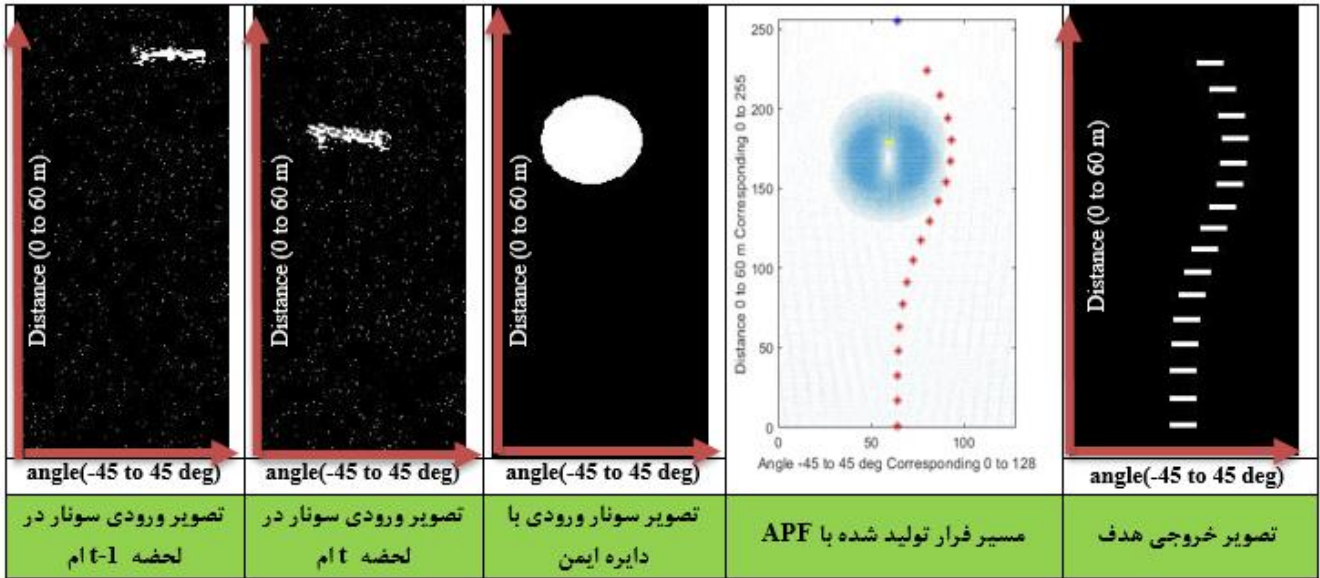
۲. جفت‌های تصویر سونار و مجازی برای آموزش UNET-APF (۲۲۰۰ جفت متوالی، سونار ۱۲۸×۲۵۶، تصویر مانع ۱۲۸×۲۵۶).

۳. ویدیوها برای آموزش LSTM (۱۸ ویدیوی حرکت کشتی، تعداد فریم‌های ویدئوها متفاوت هستند).

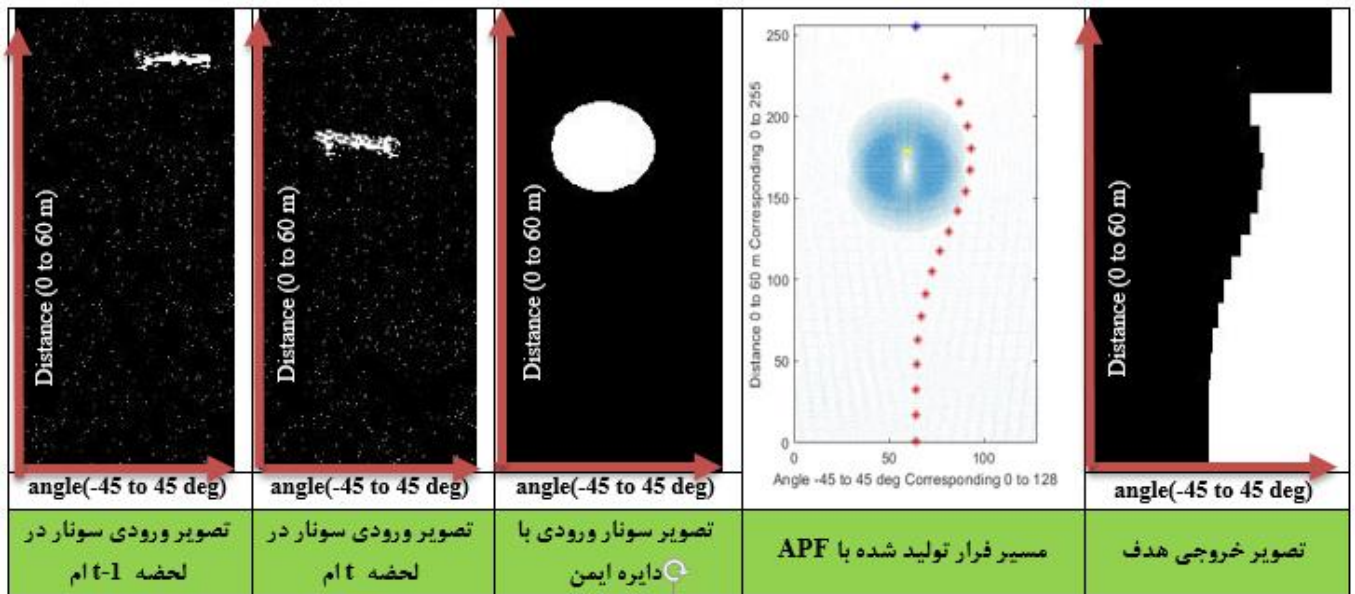
در جدول ۴ مشخصات مجموعه داده تهیه شده گزارش شده است.

جدول ۴- پارمترهای پایگاه‌های داده جمع‌آوری شده


پایگاه داده	کاربرد	تعداد تصاویر	ابعاد یا طول
اول	تشخیص مانع روی آب	۲۴۰۰	۲۵۶×۲۵۶
دوم	تشخیص مانع زیر آب	۲۲۰۰ جفت تصویر متوالی سونار و ۲۲۰۰ تصویر مانع متناظر	۱۲۸×۲۵۶ - ۲۵۶×۱۲۸
سوم	تخمین موقعیت مانع	۱۸ ویدئو	با طول دنباله متفاوت




شکل ۱۰- نمونه ای از تصویر ورودی سونار و تصویر منطقه امن متناظر آن، به همراه تصویر مسیر فرار بدست آمده از روش پتانسیل مجازی و تصویر هدف شبکه جهت آموزش، بدست آمده از روش SFM



شکل ۱۱- نمونه ای از تصویر ورودی سونار و تصویر منطقه امن متناظر آن، به همراه تصویر مسیر فرار بدست آمده از روش پتانسیل مجازی و تصویر هدف شبکه جهت آموزش، بدست آمده از روش WFM



(ب) نمونه ایی از تصاویر پایگاه داده موانع روی آب




(الف) سه نمونه از تصویر سونار

شکل ۱۲- نمونه ایی از تصاویر موانع (الف) حسگر سونار (ب) دوربین

## ۶- آموزش شبکه و ارزیابی نتایج

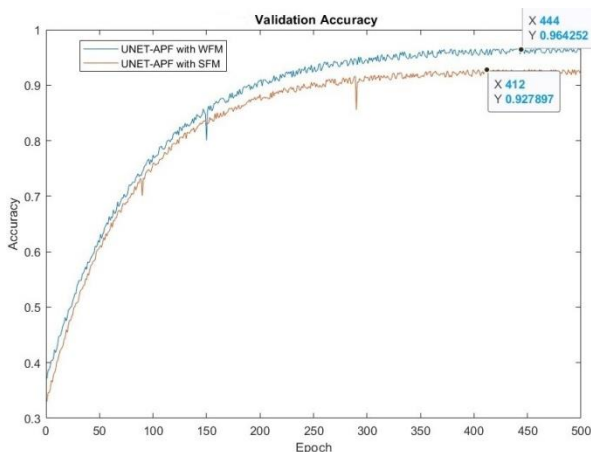
- آموزش UNET برای تشخیص موانع روی سطح آب: ۷۰٪ تصاویر پایگاه داده اول برای آموزش و ۳۰٪ برای اعتبارسنجی استفاده شدند. از آنتروپی متقاطع طبقه‌بندی پراکنده به عنوان تابع زیان استفاده شد و  $IOU^1$  دقت را اندازه‌گیری کرد. شکل‌های ۱۳ و ۱۴ نمودار دقت و اتلاف حاصل از آموزش این شبکه را برای ۱۸۰ دوره نشان می‌دهد. همچنین نمونه‌هایی از تصاویر ورودی، خروجی هدف و خروجی حاصل از این شبکه در شکل ۱۸ آمده است.




شکل ۱۳- نمودار دقت برای داده‌های آموزشی و اعتبارسنجی شبکه UNET جهت آشکارسازی تصاویر موانع روی سطح

استفاده شد. شکل ۱۷ نمودار RMSE و اتلاف برای آموزش شبکه LSTM، شکل ۱۶ RMSE را برای ۱۸ توالی موقعیت حرکت کشتی و شکل ۱۹ موقعیت‌های پیش‌بینی‌شده در مقابل موقعیت‌های واقعی را نشان می‌دهد.


- آموزش UNET-APF: جهت آموزش شبکه از پایگاه داده دوم تهیه شده با تعداد ۲۲۰۰ تصویر سه‌گانه ورودی استفاده شده است. به کمک الگوریتم پتانسیل مجازی که مسیر بهینه فرار از مانع را نشان می‌دهد [۴۰-۴۲]. تعداد ۲۲۰۰ تصویر خروجی با توجه به سه ورودی (دو اسکن متوالی سونار و یک تصویر دوربین) و همچنین جهت حرکت رونده ایجاد شد. برای مقایسه بهتر، نمودار دقت جهت آموزش شبکه UNET-APF برای دو روش SFM و WFM برای ۵۰۰ دوره در شکل ۱۵ گزارش شده است. شکل‌های ۲۰ و ۲۱ خروجی‌های نمونه برای روش‌های SFM و WFM به ازای ورودی نشان داده شده، نمایش می‌دهند. جدول ۶ دقت روش پیشنهادی را گزارش می‌کند.



شکل ۱۵- مقایسه نمودار دقت برای شبکه UNET-APF با دو روش SFM و WFM




شکل ۱۶- نمودار جذر میانگین مربعات خطا برای هر دنباله



شکل ۱۴- نمودار اتلاف برای داده‌های آموزشی و اعتبارسنجی شبکه UNET جهت آشکارسازی تصاویر موانع روی سطح

- آموزش LSTM: برای آموزش از پایگاه داده سوم که از ۱۸ ویدئوی حرکت متنوع کشتی روی آب دریا تهیه شده بود، استفاده شد. برای ارزیابی سیستم پیشنهادی در برابر نویز، به توالی داده‌ها نویز سفید گوسی با قدرت ۱۰ دسیبل اضافه کردیم. برای آموزش شبکه LSTM از پارامترهای جدول ۵

<sup>1</sup> Intersection Over Union



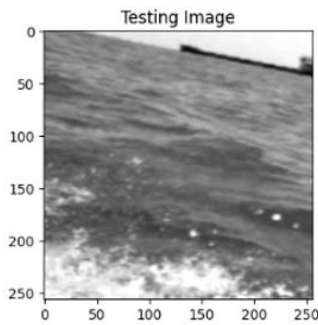
شکل ۱۷- نمودار RMSE و اتلاف برای آموزش شبکه LSTM جهت تخمین حرکت موانع

جدول ۷- پارامترهای ارزیابی و مقایسه دو روش

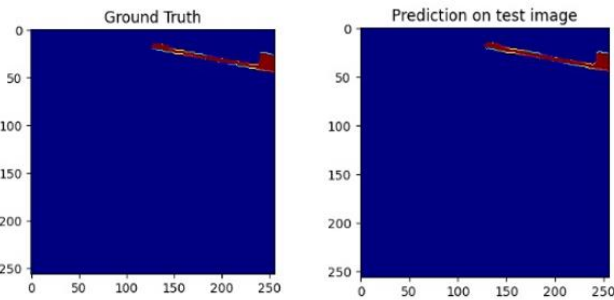
نوع روش	فقط با حسگر سونار	با تلفیق حسگر دوربین و سونار
میانگین دقت	٪۸۷	٪۹۶.۵
متوسط بیشترین زاویه فرمان سمت	۲۶ درجه	۱۸ درجه
متوسط فاصله آشکارسازی مانع (زیر سطح)	۳۱ متر	۴۶ متر

جدول ۵- پارامترهای آموزش شبکه LSTM

Training option	Value
Solver	'adam' (Adaptive moment estimation)
Hidden layer	100
Maximum Epoch	400
Initial Learning Rate	0.005
Iteration per epoch	1



الف



ج

ب

شکل ۱۸- نمونه‌ای از الف) ورودی و ب) خروجی شبکه UNET و مقایسه آن با ج) تصویر هدف

همچنین دقت تشخیص موانع روش پیشنهادی با حالتی که از تصویر دوربین و فقط یک اسکن حسگر سونار استفاده می‌شود مقایسه شد. دقت تشخیص مانع در روش پیشنهادی که از دو

در نهایت برای درک بهتر در جدول ۶ دقت حاصله برای هر ۳ پایگاه داده جمع‌آوری شده، با توجه به شبکه طراحی شده برای آن ذکر شده است.

جدول ۶- دقت حاصله برای ۳ پایگاه داده جمع‌آوری شده

پایگاه داده	کاربرد	نام شبکه	معیار دقت	دقت شبکه
اول	تشخیص موانع روی آب	UNET باکدگذار MobileNetV2	IOU	96%
دوم	تشخیص موانع و طراحی مسیر با نقشه SFM	UNET	IOU	92.8%
	تشخیص موانع و طراحی مسیر با نقشه WFM	UNET	IOU	96.5%
سوم	تخمین موقعیت مانع	LSTM	RMSE	1.89

در جدول ۷ کارایی روش پیشنهادی با سیستمی که در آن فقط از اسکن حسگر سونار استفاده شده است، مقایسه شده است. همانطوریکه ملاحظه می‌شود استفاده از حسگر سونار به تنهایی، موجب کاهش چشمگیر دقت تشخیص موانع می‌شود. علاوه بر آن برای تشخیص یک مانع بطور متوسط می‌بایست رونده حدود ۱۵ متر به مانع نزدیکتر شود. بهمین خاطر مسیرهای استخراج شده نیاز به زوایای اصلاح بزرگتری دارند (جدول ۷).

اسکن پیاپی حسگر سونار استفاده می‌کند بطور متوسط ۵/۰٪ بیشتر است.


با توجه به جدول ۸ و شکل ۲۳، مشاهده می‌شود که روش ترکیبی پیشنهادی با کمک روش پتانسیل مصنوعی، اگرچه در مقایسه با روش بدون پتانسیل مصنوعی، فاصله تشخیص مانع یکسانی دارد، اما به دلیل ایجاد زاویه اصلاح جهت کوچکتر، مسیر هموارتری را برای جلوگیری از برخورد با مانع استخراج می‌کند.

### ۱-۶- بررسی نقش روش پتانسیل مجازی در ایجاد مسیر بهینه در روش پیشنهادی

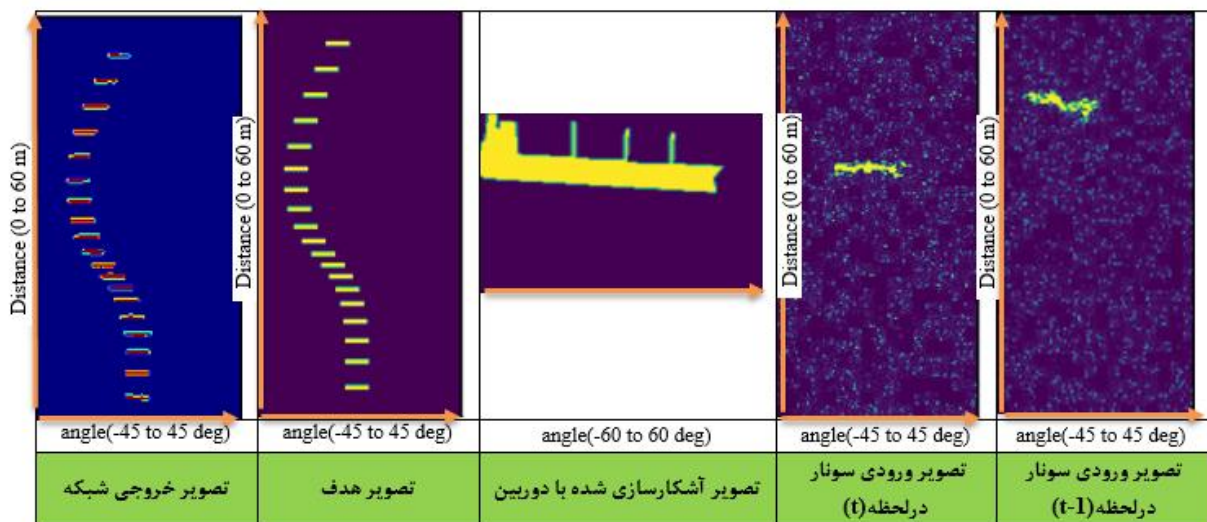
برای درک بهتر نقش روش میدان پتانسیل مصنوعی، یک شبکه مستقل طراحی شد که از تصاویر سونار و دوربین برای عبور از مانع استفاده می‌کند (شکل ۲۲). در این ساختار، ویژگی‌های هر تصویر توسط شبکه MobileNetV2 استخراج شده و پس از ترکیب، دو خروجی شامل فاصله رونده تا مانع و تغییر زاویه رونده برای فرار از مانع تولید می‌شود (شکل ۲۴). اگرچه این روش در هر اسکن سونار تنها یک زاویه فرار ارائه می‌دهد، اما مزیت آن سادگی و سرعت بالای محاسبات است. سایر بخش‌های سیستم مشابه طرح‌های قبلی باقی مانده و تنها تفاوت اصلی، حذف میدان پتانسیل و جایگزینی آن با خروجی مستقیم شبکه است.

جدول ۸- پارامترهای ارزیابی و مقایسه دو روش


با کمک روش پتانسیل مجازی	بدون روش پتانسیل مجازی	نوع روش
(IOU)/۹۶.۵	۳۴ (MAE)	میانگین دقت
۱۸ درجه	۳۲ درجه	متوسط بیشترین زاویه فرمان سمت
۴۶ متر	۴۹ متر	متوسط فاصله آشکارسازی مانع (زیر سطح)
۵.۷ متر	۱۳.۵ متر	متوسط مسیر اضافه شده



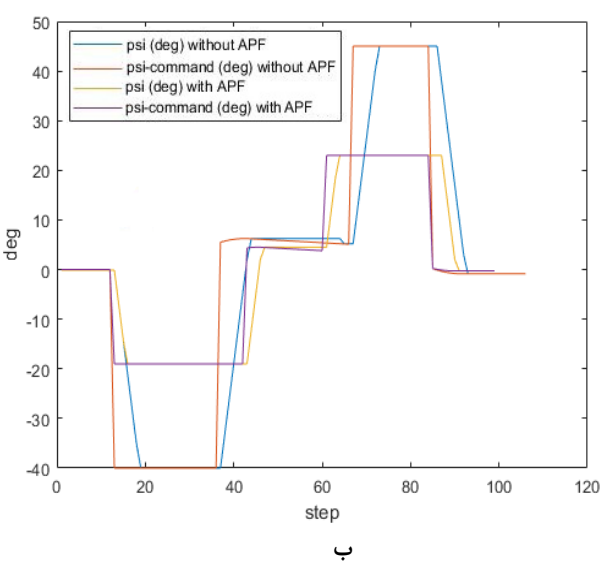
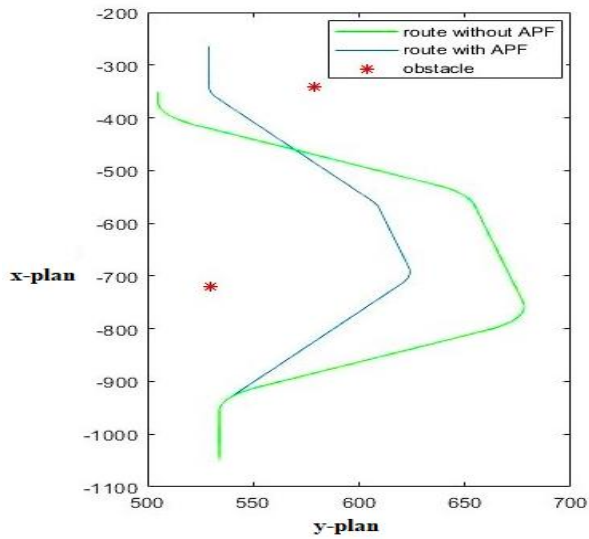
شکل ۱۹- چند نمونه از خروجی شبکه LSTM در تخمین موقعیت افقی مانع و مقایسه آن با مقدار واقعی (رنگ سیاه مقدار واقعی است).



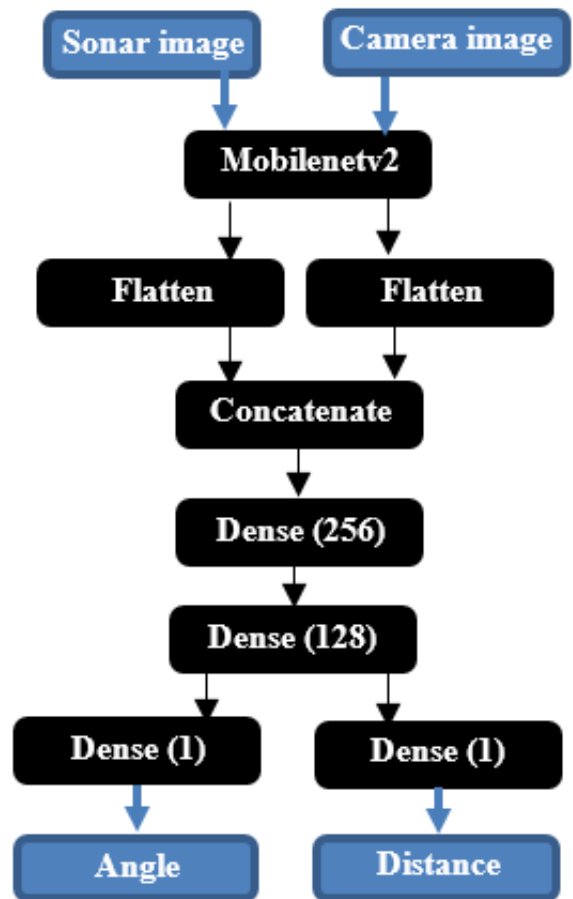
شکل ۲۰- نمونه ای از تصویر ورودی سونار و تصویر مانع متناظر، به همراه تصویر مسیر فرار و خروجی شبکه با روش SFM



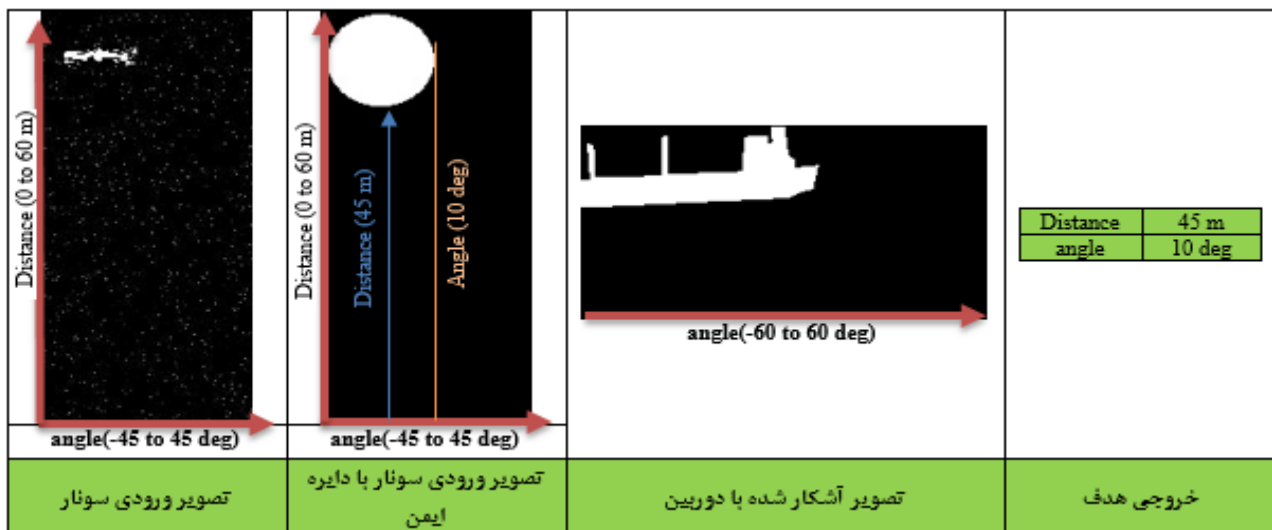
شکل ۲۱- نمونه ای از تصویر ورودی سونار و تصویر مانع متناظر، به همراه تصویر مسیر فرار و خروجی شبکه با روش WFM



شکل ۲۳- الف) مقایسه مسیر فرار از موانع، ب) مقایسه زاویه فرمان سمت



شکل ۲۲- بلوک دیاگرام شبکه طراحی شده بر اساس MobileNetV2 جهت بررسی نقش روش پتانسیل مجازی در ایجاد مسیر بهینه



شکل ۲۴- نمونه ای از تصویر ورودی سونار و تصویر منطقه امن متناظر آن، به همراه تصویر مانع متناظر و خروجی هدف شبکه شامل فاصله و سمت مانع نسبت به رونده

<https://doi.org/10.1016/j.oceaneng.2022.112252>.

3- H. Ling, T. Zhu, W. He, Z. Zhang, and H. Luo, (2019), *Cooperative search method for multiple AUVs based on target clustering and path optimization*, *Nat. Comput.*, vol. 20, no. 1, pp. 3–10.

<https://doi.org/10.1007/s11047-019-09749-3>.

4- B. Bourdin, M. J. Hasan, S. Kannan, and R. Prabhu, (2024), *Adaptive path-planning for AUVs in dynamic underwater environments using sonar data*, in *Artificial Intelligence for Security and Defence Applications II*, H. Bouma, Y. Yitzhaky, R. Prabhu, and H. J. Kuijff, Eds., SPIE, p. 42.

<https://doi.org/10.1117/12.3031644>.

5- C. Zhang, P. Cheng, B. Du, B. Dong, and W. Zhang, (2022), *AUV path tracking with real-time obstacle avoidance via reinforcement learning under adaptive constraints*, *Ocean Eng.*, vol. 256, p. 111453.

<https://doi.org/10.1016/j.oceaneng.2022.111453>.

6- C. Cheng, Q. Sha, B. He, and G. Li, (2021), *Path planning and obstacle avoidance for AUV: A review*, *Ocean Eng.*, vol. 235, p. 109355.

<https://doi.org/10.1016/j.oceaneng.2021.109355>.

7- S. Zhang, R. Wu, K. Xu, J. Wang, and W. Sun, (2019), *R-CNN-Based Ship Detection from High Resolution Remote Sensing Imagery*, *Remote Sens.*, vol. 11, no. 6, p. 631.

<https://doi.org/10.3390/rs11060631>.

8- J. Xu, X. Sun, D. Zhang, and K. Fu, (2014), *Automatic Detection of Inshore Ships in High-Resolution Remote Sensing Images Using Robust Invariant Generalized Hough Transform*, *IEEE Geosci. Remote Sens. Lett.*, vol. 11, no. 12, pp. 2070–2074. <https://doi.org/10.1109/lgrs.2014.2319082>.

9- G. Liu, Y. Zhang, X. Zheng, X. Sun, K. Fu, and H. Wang, (2014), *A New Method on Inshore Ship Detection in High-Resolution Satellite Images Using Shape and Context Information*, *IEEE Geosci.*

## ۷- نتیجه گیری

در این تحقیق یک سیستم یکپارچه مبتنی بر تصاویر سونار- دوربین مرئی برای تشخیص و اجتناب از برخورد با مانع AUV ارائه شد. این سیستم بر اساس ادغام داده‌های دوربین و دو اسکن متوالی حسگر سونار، با استفاده از شبکه‌های عمیق و الگوریتم APF توسعه داده شد. برای تشخیص مانع، از یک شبکه UNET برای پیش‌بینی موقعیت موانع متحرک از یک شبکه LSTM و برای فرار از مانع شبکه UNET-APF استفاده شد. نتایج تجربی نشان می‌دهد که ادغام اطلاعات دوربین و حسگر سونار، محدودیت‌های هر کدام از کاهش می‌دهد، دقت و برد تشخیص را بهبود می‌بخشد و مسیر حرکت AUV را هموارتر می‌کند. LSTM موقعیت موانع متحرک را به طور مؤثر پیش‌بینی می‌کند و UNET-APF مسیرهای هموارتری ایجاد می‌کند. WFM و SFM آموزش شبکه را تسهیل می‌کنند. البته WFM دقت بالاتری را نشان می‌دهد. این چارچوب امکان استفاده سونار بُرد متوسط را در نوبری خودکار روندها فراهم می‌کند، برد عملیاتی را افزایش می‌دهد و نوبری AUV ایمن‌تر و روان‌تر را در محیط‌های دریایی پیچیده تضمین می‌کند.

## مراجع

1- B. Wang, J. Liu, Z. Deng, and M. Fu, (2021), *A Model Free Calibration Method of Inertial Navigation System and Doppler Sensors*, *IEEE Sens. J.*, vol. 21, no. 2, pp. 2219–2229.

<https://doi.org/10.1109/JSEN.2020.3015845>.

2- M. Sabet and H. Nourmohammadi, (2022), *Water velocity sensor with the ability to estimate the sideslip angle based on Bernoulli's law for use in autonomous underwater vehicles*, *Ocean Eng.*, vol. 263, p. 112252.

<https://doi.org/10.1109/ICCV.2015.169>.

21- J. Yan, J. Meng, and J. Zhao,(2021) ,*Bottom detection from backscatter data of conventional side scan sonars through 1D-UNet*, *Remote Sens.*, vol. 13, no. 5, p. 1024. <https://doi.org/10.3390/rs13051024>.

22- J. Li, P. Jiang, and H. Zhu, (2020), *A local region-based level set method with Markov random field for side-scan sonar image multi-level segmentation*, *IEEE Sens. J.*, vol. 21, no. 1, pp. 510–519. <https://doi.org/10.1109/JSEN.2020.3013649>.

23- Z. Yan, J. Zhang, and J. Tang,(2020) , *Modified water wave optimization algorithm for underwater multilevel thresholding image segmentation*, *Multimed. Tools Appl.*, vol. 79, no. 43, pp. 32415–32448. <https://doi.org/10.1007/s11042-020-09664-1>.

24- J. Lu, S. Zhang, H. Zhang, and L. Lin,(2019) , *An Improved Target Detection Method Based on Sonar Image Processing*, in *2019 Photonics & Electromagnetics Research Symposium - Fall (PIERS - Fall)*, IEEE, pp. 1124–1128. <https://doi.org/10.1109/piersfall48861.2019.9021810>.

25- T. Guerneve, K. Subr, and Y. Petillot,(2018) ,*Three-dimensional reconstruction of underwater objects using wide-aperture imaging SONAR*, *J. F. Robot.*, vol. 35, no. 6, pp. 890–905. <https://doi.org/10.1002/rob.21783>.

26- W. Li, M. Liu, S. Zhang, R. Zheng, and J. Lan,(2020) , *Underwater Sonar Visual Tracking with Obstacle Solving Method*, in *39th Chinese Control Conference (CCC)*, IEEE, pp. 3044–3049. <https://doi.org/10.23919/ccc50068.2020.9189400>.

27- X. Wang, J. Jiao, J. Yin, W. Zhao, X. Han, and B. Sun, (2019), *Underwater sonar image classification using adaptive weights convolutional neural network*, *Appl. Acoust.*, vol. 146, pp. 145–154. <https://doi.org/10.1016/j.apacoust.2018.11.003>.

28- S. Lee, B. Park, and A. Kim,(2019) ,*Deep learning based object detection via style-transferred underwater sonar images*, *IFAC-PapersOnLine*, vol. 52, no. 21, pp. 152–155. <https://doi.org/10.1016/j.ifacol.2019.12.299>.

29- M. Valdenegro-Toro,(2016) ,*Object recognition in forward-looking sonar images with Convolutional Neural Networks*, in *OCEANS 2016 MTS/IEEE Monterey*, IEEE, pp. 1–6. <https://doi.org/10.1109/oceans.2016.7761140>.

30- J. Kim, H. Cho, J. Pyo, B. Kim, and S.-C. Yu,(2016) , *The convolution neural network based agent vehicle detection using forward-looking sonar image*, in *OCEANS MTS/IEEE Monterey*, pp. 1–5. <https://doi.org/10.1109/OCEANS.2016.7761209>.

31- X. Zhou, K. Yang, and R. Duan,(2019) ,*Deep Learning Based on Striation Images for Underwater and Surface Target Classification*, *IEEE Signal Process. Lett.*, vol. 26, no. 9, pp. 1378–1382. <https://doi.org/10.1109/lsp.2019.2919102>.

32- C. Lin, G. Han, J. Du, Y. Bi, L. Shu, and K. Fan,

*Remote Sens. Lett.*, vol. 11, no. 3, pp. 617–621.

<https://doi.org/10.1109/lgrs.2013.2272492>.

10- M. Tello, C. Lopez-Martinez, and J. J. Mallorqui, (2005), *A Novel Algorithm for Ship Detection in SAR Imagery Based on the Wavelet Transform*, *IEEE Geosci. Remote Sens. Lett.*, vol. 2, no. 2, pp. 201–205. doi: <https://doi.org/10.1109/lgrs.2005.845033>.

11- X. Xiang-wei, J. Ke-feng, K. Li-hong, Z. Ming ,(2015), *Review of Ship Surveillance Technologies Based on High-Resolution Wide-Swath Synthetic Aperture Radar Imaging*, *Journal of Radars*, Vol. 4, no. 1, pp. 107 – 121 doi: <https://doi.org/10.12000/JR14144>.

12- W. Tao, (2007), *Unified mean shift segmentation and graph region merging algorithm for infrared ship target segmentation*, *Opt. Eng.*, vol. 46, no. 12, p. 127002. doi: <https://doi.org/10.1117/1.2823159>.

13- S. Greenberg,(2005) ,*Region-of-interest-based algorithm for automatic target detection in infrared images*, *Opt. Eng.*, vol. 44, no. 7, p. 77002. doi: <https://doi.org/10.1117/1.1951547>.

14- M. Ren, Y. Cao, Z. Tang, J. Yang, B. Wang, and X. Geng,(1999) ,*One effective method for ship recognition in ship locks*, in *Signal Processing, Sensor Fusion, and Target Recognition VIII*, I. Kadar, Ed., SPIE, p. 467. doi: <https://doi.org/10.1117/12.357188>.

15- W. Ouyang, X. Wang, C. Zhang, and X. Yang,(2016) , *Factors in finetuning deep model for object detection with long-tail distribution*, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 864–873. doi: <https://doi.org/10.1109/CVPR.2016.100>.

16- J. Cao, Y. Pang, and X. Li,(2016) ,*Pedestrian detection inspired by appearance constancy and shape symmetry*, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1316–1324. doi: <https://doi.org/10.1109/CVPR.2016.147>.

17- S. Ren, K. He, R. Girshick, and J. Sun,(2017) ,*Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 39, no. 6, pp. 1137–1149. doi: <https://doi.org/10.1109/tpami.2016.2577031>.

18- J. Redmon and A. Farhadi,(2017) ,*YOLO9000: better, faster, stronger*, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 7263–7271. doi: <https://doi.org/10.48550/arXiv.1612.08242>.

19- W. Liu et al., (2016), *SSD: Single Shot MultiBox Detector*, in *Computer Vision – ECCV 2016*, Springer International Publishing, pp. 21–37. doi: [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2).

20- R. Girshick,(2015) ,*Fast r-cnn*, in *Proceedings of the IEEE international conference on computer vision*, pp. 1440–1448. doi:

- (2020), *A path planning scheme for AUV flock-based Internet-of-Underwater-Things systems to enable transparent and smart ocean*, *IEEE Internet Things J.*, vol. 7, no. 10, pp. 9760–9772. <https://doi.org/10.1109/JIOT.2020.2988285>.
- 33- R. Kot, (2024), *Fuzzy inference-based adaptive sonar control for collision avoidance in autonomous underwater vehicles*, *Polish Marit. Res.* <https://doi.org/10.2478/pomr-2024-0058>.
- 34- R. Cui, Y. Li, and W. Yan,(2016) ,*Mutual Information-Based Multi-AUV Path Planning for Scalar Field Sampling Using Multidimensional RRT*, *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 46, no. 7, pp. 993–1004. <https://doi.org/10.1109/tsmc.2015.2500027>.
- 35- X. Cao, D. Zhu, and S. X. Yang,(2016) , *Multi-AUV Target Search Based on Bioinspired Neurodynamics Model in 3-D Underwater Environments*, *IEEE Trans. Neural Networks Learn. Syst.*, vol. 27, no. 11, pp. 2364–2374. <https://doi.org/10.1109/tnnls.2015.2482501>.
- 36- Y. Liu and W. Xu, (2020), *Application of improved Hopfield Neural Network in path planning*, in *Journal of Physics: Conference Series*, p. 12154. <https://doi.org/10.1088/1742-6596/1544/1/012154>.
- 37- D. Zhu, H. Huang, and S. X. Yang,(2013) , *Dynamic Task Assignment and Path Planning of Multi-AUV System Based on an Improved Self-Organizing Map and Velocity Synthesis Method in Three-Dimensional Underwater Workspace*, *IEEE Trans. Cybern.*, vol. 43, no. 2, pp. 504–514. <https://doi.org/10.1109/tsmcb.2012.2210212>.
- 38- M. Chen and D. Zhu, (2019), *A Workload Balanced Algorithm for Task Assignment and Path Planning of Inhomogeneous Autonomous Underwater Vehicle System*, *IEEE Trans. Cogn. Dev. Syst.*, vol. 11, no. 4, pp. 483–493, <https://doi.org/10.1109/tcds.2018.2866984>.
- 39- R. Gladstone, Y. Moshe, A. Barel, and E. Shenhav, (2016), *Distance estimation for marine vehicles using a monocular video camera*, in *2016 24th European Signal Processing Conference (EUSIPCO)*, pp. 2405–2409. <https://doi.org/10.1109/EUSIPCO.2016.7760680>.
- 40- V. Antoska-Knights, Z. Gacovski, and S. Deskovski,(2017) , *Obstacles avoidance algorithm for mobile robots, using the potential fields method*, *Univ. J. Electr. Electron. Eng.*, vol. 5, pp. 75–84. <https://doi.org/10.13189/UJEEE.2017.050402>.
- 41- W. Ding et al.,(2024) , *Research on obstacle avoidance of multi-AUV cluster formation based on virtual structure and artificial potential field method*, *Comput. Electr. Eng.*, vol. 117, p. 109250. <https://doi.org/10.1016/j.compeleceng.2024.109250>.
- 42- Zia S V, Poyan Rad M,(2021) , *An obstacle avoidance algorithm for an autonomous underwater vehicle based on fuzzy-virtual*