J. of Marine Eng. Vol. 21, Iss. 47, 2025. (77-88)

Journal of Marine Engineering

Journal homepage: marine-eng.ir

Automatic recognition of SONAR targets based on group classifier with majority voting weighted by the Hiking Optimization Algorithm

Abbas Saffai[1], Mehdi Jafari Moghaddam[2*], Najme Ghanbari[3]

[1] *Teacher and researcher at the Imam Ja'far Sadiq Naval Special Training Center, Bushehr* Abbas.saffari@birjand.ac.ir
[2] *Instructor at Imam Khomeini University of Marine Sciences in Noshahr and researcher at the Organization of Research and Self-Sufficiency Jihad* mjafarim@ihu.ac.ir
[3]*Assistant Professor of the Faculty of Electrical Engineering at University of Zabol* n.ghanbari@uoz.ac.ir

ARTICLE INFO

Article History:
Received: 12 May 2025
Last modification: 14 Oct 2025
Accepted: 18 Oct 2025
Available online: 18 Oct 2025

Article type:
Research paper

Keywords:
Hiking Optimization Algorithm
Automatic Target Recognition
AI
SONAR
Group Classifier

ABSTRACT

This paper investigates the automatic recognition of sonar targets using group classification that uses majority votes weighted and optimized by the Hiking Optimization Algorithm (HOA). Complex sonar targets and environmental challenges in the seas have increased the need for advanced AI techniques that are highly accurate and flexible. The HOA, which is based on the climbing model, strives to provide a more accurate optimization for the weighting of base classifications. This paper uses five basic classifiers, including XGBoost, LightGBM, CatBoost, Logistic Regression (LR), and Gradient Boosting Machine (GBM), which improve the accuracy of recognition and error reduction by combining them into an MV-HOA-based group classifier. The results show that the use of group classification method with HOA algorithm has significant capabilities in identifying sonar targets and can be useful for industrial and military applications. This innovative method not only optimizes classifier votes, but also reduces computational complexity and allows it to be applied in complex marine environments.

ISSN: 2645-8136

DOI: http://dx.doi.org/10.66224/marineeng.21.47.7

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/]

نشریه مهندسی دریا، جلد ۲۱، شماره ۴۷، ۱۴۰۴، (۸۸-۷۷)

نشریه مهندسی دریا

صفحه اصلی نشریه: marine-eng.ir

بازشناسی خودکار اهداف سونار مبتنی بر طبقه‌بند گروهی با آرای اکثریت وزن‌دهی شده با الگوریتم بهینه‌سازی پیاده‌روی

عباس صفاری[۱و۳]، مهدی جعفری مقدم[۱و۲*]، نجمه قنبری[۴]

[۱] مدرس دانشگاه علوم دریایی امام خمینی (ره) نوشهر

[۲] پژوهشگر سازمان تحقیقات و جهاد خودکفایی نداجا، تهران mjafarim@ihu.ac.ir

[۳] مرکز آموزشهای تخصصی دریایی امام جعفر صادق (ع) نداجا، بوشهر، Abbas.saffari@birjand.ac.ir

[۴] استادیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه زابل، n.ghanbari@uoz.ac.ir

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۰۲/۲۲

تاریخ اصلاح مقاله: ۱۴۰۴/۰۷/۲۲

تاریخ پذیرش مقاله: ۱۴۰۴/۰۷/۲۶

تاریخ انتشار مقاله: ۱۴۰۴/۰۷/۲۶

نوع مقاله:

مقاله پژوهشی

کلمات کلیدی:

الگوریتم پیاده‌روی

بازشناسی خودکار

هوش مصنوعی

سونار

طبقه‌بند گروهی

چکیده

این مقاله به بررسی بازشناسی خودکار اهداف سونار با استفاده از طبقه‌بند گروهی می‌پردازد که از آرای اکثریت وزن‌دهی شده و بهینه‌سازی شده با الگوریتم بهینه‌سازی پیاده‌روی (HOA) بهره می‌گیرد. اهداف پیچیده سونار و چالش‌های محیطی در دریاها، نیاز به تکنیک‌های پیشرفته هوش مصنوعی را افزایش داده است که دقت و انعطاف‌پذیری بالایی دارند. HOA، که بر اساس الگوی کوهنوردی است، تلاش می‌کند تا بهینه‌سازی دقیق‌تری را برای وزن‌دهی طبقه‌بندهای پایه فراهم کند. این مقاله از پنج طبقه‌بند پایه شامل XGBoost، LightGBM، CatBoost، رگرسیون لجستیک (LR)، و تقویت گرادیانی (GBM) استفاده می‌کند که با ترکیب آن‌ها در یک طبقه‌بند گروهی مبتنی بر MV-HOA، دقت بازشناسی و کاهش خطا بهبود می‌یابد. نتایج نشان می‌دهند که استفاده از روش طبقه‌بند گروهی با الگوریتم HOA، توانایی‌های قابل توجهی در شناسایی اهداف سونار دارد و می‌تواند برای کاربردهای صنعتی و نظامی مفید باشد. این روش نوآورانه علاوه بر بهینه‌سازی آرای طبقه‌بندها، کارایی مناسب را درعملکرد خود نشان داده و امکان به‌کارگیری آن در محیط‌های پیچیده دریایی را فراهم می‌کند.

ISSN: 2645-8136

DOI: http://dx.doi.org/10.66224/marineeng.21.47.7

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

۱ - مقدمه

ویژگی‌های فیزیکی پیچیده اهداف سوناری، سبب شده است که موضوع طبقه‌بندی و شناسایی خودکار اهداف سونار، به یکی از موضوعات مورد علاقه محققان و صنعتگران فعال در این حوزه تبدیل شود. مطالعات اخیر نشان می‌دهد که تکنیک‌های هوش مصنوعی، در حل مشکلات مهندسی در دنیای واقعی، مخصوصا در حوزه‌ی اهداف سونار، عملکرد موفقی داشته‌اند.

مدل‌های هوش مصنوعی ویژگی‌های مهمی مانند دقت بالا، انعطاف‌پذیری و ساختار موازی ذاتی دارند. این ویژگی‌ها در حوزه‌ی مهندسی دریا اهمیت ویژه‌ای دارند. به طور خاص، سامانه‌های سونار که برای کشف و شناسایی اهداف زیرسطحی مانند زیردریایی‌ها، مین‌های دریایی و حتی کشتی‌های سطحی به‌کار می‌روند، به دلیل نویز شدید محیطی، شرایط متغیر هیدروآکوستیکی و وجود تداخل‌های ناشی از امواج و جریان‌های دریایی، نیازمند روش‌های هوش مصنوعی دقیق و مقاوم هستند. بنابراین، آنها می‌توانند در حل چالش‌های موجود در مسائل مربوط به محیط پیچیده‌ی اقیانوس و دریا، بویژه طبقه‌بندی اهداف سونار مفید باشند. اخیراً طبقه‌بندی با دو رویکرد بررسی شده است. روش اول روش های قطعی مبتنی بر اقیانوس شناسی [1]، مدل سازی و مهندسی سونار [2] و پردازش آماری [3] است. روش دوم، روش‌های تصادفی با کاربردهای متفاوت است که شامل پیش‌بینی پدیده اقیانوسی، افزایش رویکردهای استخراج ویژگی و معرفی تکنیک‌های طبقه‌بندی جدید است [4]. استفاده از روش اول مستلزم سرمایه گذاری پرهزینه در تجهیزات، منابع انسانی و پشتیبانی می‌باشد، در حالی که استفاده از روش دوم علاوه بر کاهش هزینه‌ها، پیچیدگی را کاهش می‌دهد. یادگیری ماشین حیاتی‌ترین زیر مجموعه هوش مصنوعی است. یادگیری تحت نظارت مناسب ترین روش برای طبقه‌بندی مسائل است [5]. الگوریتم یادگیری خروجی داده های آموزشی را در این روش به صورت تکراری محاسبه می کند. هنگامی که الگوریتم به عملکرد قابل قبولی دست می یابد، ناظر این خروجی‌ها را تصحیح می‌کند و فرآیند یادگیری متوقف می‌شود [6].

تشخیص خودکار هدف[1] (ATR) یکی از مهمترین کاربردهای تشخیص الگو در علوم کامپیوتر است [7]. سیستم‌های ATR به گونه‌ای عمل می‌کنند که با استفاده از طبقه‌بندی‌کننده‌های مختلف، می‌توانند اهداف ناشناس را در فضای ویژگی تشخیص دهند. از سوی دیگر، گاهی اوقات وجود نویز در داده ها باعث اشتباه طبقه‌بندی کننده‌ها می‌شود. در این حالت، ادغام تصمیمات طبقه‌بندی‌کننده‌های مختلف می‌تواند میزان خطا را کاهش داده و عملکرد سیستم را افزایش دهد. به عبارت دیگر، استفاده از آرای اکثر طبقه‌بندی کننده های مختلف می تواند عملکرد سیستم را بهبود بخشد. با این حال، همه طبقه‌بندی کننده ها در مجموعه عملکرد یکسانی ندارند و به ندرت پیش می‌آید که عملکرد یکسانی داشته باشند [8]. در این صورت سنجیدن آرا راهبرد درستی است. وزن دهی تکنیک های مختلفی دارد. یکی از جدیدترین و کارآمدترین تکنیک های وزن دهی استفاده از الگوریتم های اکتشافی است. یک رویکرد موثر، مربوط به استفاده از یک طبقه‌بندی کننده‌ی گروهی است که از تکنیک MV-HOA استفاده می کند.

هدف این تحقیق بررسی کامل پتانسیل MV-HOA به عنوان یک روش موثر و کارآمد برای بازشناسی خودکار اهداف سونار می‌باشد. بنابراین می توان گفت که سهم اصلی ما در این مقاله به شرح زیر است:

- بازشناسی خودکار داده های سونار با استفاده از طبقه‌بندی کننده‌های XGBoost، LightGBM، CatBoost، LR و GBM
- استفاده از طبقه‌بندی‌کننده گروه توسط MV-HOA
- تولید وزن بهینه برای آرای طبقه‌بندی کننده های پایه با استفاده از HOA[2]

مقاله به شرح زیر سازماندهی شده است: بخش ۲ به مبانی نظری و مرور آثار مرتبط می‌پردازد. در بخش ۳، بازشناسی خودکار اهداف سوناری مبتنی بر طبقه‌بند گروهی با آرای اکثریت وزن‌دهی شده، همراه با الگوریتم بهینه‌سازی پیاده‌روی، مورد بحث قرار می‌گیرد. بخش ۴ نتایج آزمایش‌ها را با استفاده از داده‌های شبیه‌سازی‌شده و واقعی ارائه و تحلیل می‌کند. نهایتاً، بخش ۵ به جمع‌بندی یافته‌ها و نتیجه‌گیری کلی مطالعه اختصاص دارد.

۲- مبانی نظری و تکنیک‌های پایه‌ای طبقه‌بندی و بهینه‌سازی الگوریتم بهینه‌سازی پیاده روی و طبقه‌بندهای پایه

در این بخش، به معرفی پنج طبقه‌بند پلیه که در طبقه‌بند گروهی به‌کار گرفته شده‌اند، پرداخته می‌شود. در ادامه، الگوریتم HOA

[1] Automatic Target Recognition (ATR)

[2] Hiking Optimization Algorithm

که به منظور وزن‌دهی به طبقه‌بند گروهی مورد استفاده قرار گرفته است، به‌تفصیل شرح داده خواهد شد.

۲-۱- طبقه‌بندهای پایه

XGBoost[3] یکی از الگوریتم‌های پیشرفته‌ی تقویت گرادیانی است که با استفاده از درخت تصمیم‌گیری بهینه‌سازی شده، سرعت و کارایی بالایی در مسائل رگرسیون و طبقه‌بندی ارائه می‌دهد. این الگوریتم از ویژگی‌های مانند توانایی تنظیم بایاس، دسته‌بندی داده‌ها، و مقابله با داده‌های مفقود بهره می‌برد. همچنین به دلیل موازی‌سازی داخلی و مصرف حافظه کم، کاربرد وسیعی در مسابقات علمی و صنعتی دارد.

LightGBM[4] یک الگوریتم تقویتی مبتنی بر درخت تصمیم‌گیری است که با هدف کاهش زمان آموزش و استفاده از حافظه بهینه‌تر طراحی شده است. این الگوریتم به خصوص برای داده‌های بزرگ موفقیت‌های زیادی را کسب کرده است.

CatBoost یک الگوریتم تقویت گرادیانی مبتنی بر درخت تصمیم‌گیری است که برای کار با داده‌های دسته‌ای بهینه‌سازی شده است. این الگوریتم بدون نیاز به پیش‌پردازش‌های پیچیده می‌تواند به طور خودکار با داده‌های دسته‌ای[5] کار کند و از مسئله بیش برازش جلوگیری کند. CatBoost به دلیل قابلیت پردازش داده‌های غیر عددی و عملکرد بالا در مسائل مختلف شناخته شده است.

LR[6] رگرسیون لجستیک یکی از الگوریتم‌های کلاسیک یادگیری ماشین است که برای مسائل طبقه‌بندی باینری به کار می‌رود. این الگوریتم با مدل‌سازی احتمالی برای پیش‌بینی دسته‌بندی‌های دودویی (۰ یا ۱) و استفاده از تابع لجستیک برای تغییر متغیرهای ورودی به خروجی‌های احتمالی، یکی از ساده‌ترین و کارآمدترین الگوریتم‌ها در زمینه طبقه‌بندی است.

GBM[7] یک تکنیک قوی برای بهبود دقت مدل‌های یادگیری است که با ترکیب چندین مدل ضعیف مانند درخت‌های تصمیم‌گیری به مدل‌های قوی‌تر دست می‌یابد. این الگوریتم از رویکردی تکراری استفاده می‌کند که در هر مرحله یک مدل جدید به مدل‌های قبلی اضافه می‌کند تا خطاهای مدل‌های قبلی به حداقل برسد. GBM با انعطاف‌پذیری بالا و قابلیت تنظیمات گسترده، در مسائل رگرسیون و طبقه‌بندی بسیار موفق عمل می‌کند.

۲-۲- الگوریتم بهینه‌سازی پیاده روی

HOA از تجربیات کوهنوردانی که در تلاش برای صعود به قله‌ی کوه‌ها، تپه‌ها یا صخره‌ها هستند، الهام می‌گیرد. در مسیر پیاده‌روی، کوهنوردان آگاهانه یا ناخودآگاه شیب زمین را در نظر می‌گیرند. آنها برای حفظ سرعت پیاده‌روی خود از زمین ها و مسیرهای بسیار شیب دار اجتناب می‌کنند. به عبارت دیگر، زمین‌ها و مسیرهای بسیار شیب‌دار باعث کاهش سرعت کوهنوردان و در نهایت طولانی‌تر شدن مسیر پیاده‌روی می‌شود. کوهنوردان با آگاهی از ویژگی‌های زمین می‌توانند زمان رسیدن به قله را تعیین کنند یا تقریباً تخمین بزنند. این رفتار شبیه روند جستجوی عامل‌ها در مسائل بهینه‌سازی است. به عبارت دیگر فضای جستجو همانند یک محیط کوهستانی با قله‌های متعدد (بهینه‌های محلی) و یک قله اصلی (بهینه سراسری) در نظر گرفته می‌شود. عوامل جستجو (کوهنوردان) ممکن است در نقاط دشوار فضای جستجو گرفتار شوند و رسیدن به بهترین جواب کلی زمان‌بر شود.

۲-۳- مدل ریاضی

HOA بر اساس تابع معروف توبلر هایکینگ[8] [10] ,[9] است که توسط یک جغرافیدان و نقشه‌بردار آمریکایی سوئیسی، والدو توبلر[9]، فرموله شده است. تابع پیاده‌روی توبلر یک تابع نمایی است که سرعت یک کوهنورد را با در نظر گرفتن شیب یا شیب زمین یا مسیر تعیین می‌کند. THF به شرح زیر است:

$$W_{i,t} = 6e^{-3.5|S_{i,t}+0.05|} \quad (۱)$$

که در آن $W_{i,t}$ سرعت پیاده‌روی کوهنورد i (بر حسب کیلومتر بر ساعت) در تکرار t است، و $S_{i,t}$ شیب مسیر یا زمین است که از رابطه زیر محاسبه می‌شود:

$$S_{i,t} = \frac{dh}{dx} = tan\,\theta_{i,t} \quad (۲)$$

که در آن dh و dx به ترتیب نشان دهنده تفاوت ارتفاع و مسافت طی شده توسط کوهنورد است. $\theta_{i,t}$ زاویه شیب مسیر (شیب زمین) است و مقدار آن $[0^{\circ}, 50^{\circ}]$ قرار دارد.

در مدلسازی HOA از رفتار فردی کوهنوردان و تعامل گروهی آنها بهره گرفته می شود. سرعت به‌روز شده یک کوهنورد (کوهنورد i ام) تابعی از سرعت قبلی، موقعیت رهبر گروه، موقعیت واقعی فعلی کوهنورد و ضریب رفت و برگشت[10] می باشد و توسط معادله (۳) محاسبه می‌شود:

---

[3] Xtreme Gradient Boosting (XGBoost)
[4] Light Gradient Boosting Machine (LightGBM)
[5] Categorical Data
[6] Logistic Regression (LR)
[7] Gradient Boosting Machine (GBM)
[8] Tobler's Hiking Function (THF)
[9] Waldo Tobler
[10] sweep factor (SF)

$$W_{i,t} = W_{i,t-1} + \gamma_{i,t}\left(\beta_{best} - \alpha_{i,t}\beta_{i,t}\right) \quad (۳)$$

در معادله (۳)، $\gamma_{i,t}$ یک مقدار تصادفی با توزیع یکنواخت در بازه‌ی [۰،۱] است. $W_{i,t}$ و $W_{i,t-1}$ به ترتیب نشان دهنده سرعت فعلی و سرعت اولیه کوهنورد i هستند. β_{best} موقعیت کوهنورد پیشرو و $\alpha_{i,t}$ ضریب رفت و برگشت کوهنورد i-ام در بازه‌ی [۱،۳] می‌باشد. ضریب $\alpha_{i,t}$ مانع از فاصله گرفتن بیش‌ازحد کوهنوردان از رهبر می‌شود.

موقعیت کوهنورد i ام نیز بر اساس رابطه (۴) به‌روزرسانی می‌شود:

$$\beta_{i,t+1} = \beta_{i,t} + W_{i,t} \quad (۴)$$

در ابتدای اجرا، موقعیت کوهنوردان به‌صورت تصادفی در محدوده کران‌های بالا (ϕ_j^1) و پایین (ϕ_j^2) مقداردهی اولیه می‌شود:

$$\beta_{i,t} = \phi_j^1 + \delta_j\left(\phi_j^2 - \phi_j^1\right) \quad (۵)$$

که در آن δ_j عددی تصادفی در بازه ی [۰،۱] است. همچنین، ϕ_j^1 و ϕ_j^2 نشان دهنده کران های پایین و بالای بعد j-ام هستند.

رفتار الگوریتم HOA در دو فاز اکتشاف و بهره‌برداری با پارامتر SF کنترل می‌شود. در این مدل‌سازی، ارتباط مستقیم میان پارامترهای HOA و شرایط واقعی انتشار صوت در محیط‌های دریایی نیز قابل توجه است. برای مثال، زاویه‌ی مسیر حرکت کوهنوردان در مدل HOA مشابه زاویه‌ی انتشار موج صوتی در آب دریاست که تحت تأثیر دما، شوری و عمق آب تغییر می‌کند. همچنین، کران‌های بالا و پایین در معادله (۵) به عنوان محدودیت‌های فیزیکی محیط آکوستیکی در نظر گرفته شوند. بنابراین، استفاده از HOA نه‌تنها یک مدل ریاضی صرف، بلکه بازتابی از شرایط واقعی انتشار صوت در دریا محسوب می‌شود. افزایش مقدار SF تمایل الگوریتم به بهره‌برداری را بیشتر کرده و کاهش آن، جستجو را به سمت اکتشاف سوق می‌دهد. همچنین تغییر زاویه شیب مسیر نقش مهمی در تنظیم این تعادل دارد. به عبارت دیگر هنگامی که محدوده SF افزایش می یابد، HOA تمایل بیشتری به سمت فاز بهره‌برداری دارد. در مقابل کاهش دامنه SF تمایل به مرحله اکتشاف در HOA دارد. علاوه بر این کاهش دامنه زاویه شیب مسیر، HOA را به سمت فاز بهره‌برداری هدایت می‌کند. این عوامل به شکل‌دهی رفتار و عملکرد HOA در حل مسائل بهینه‌سازی کمک می‌کنند. در مقایسه با الگوریتم‌های شناخته‌شده‌ای مانند الگوریتم بهینه‌سازی ازدحام ذرات (PSO[11]) و الگوریتم نهنگ (WOA[12])، HOA دارای مزیتی کلیدی است: تعادل بهتر میان اکتشاف و بهره‌برداری. در حالی که PSO گاهی در بهینه‌های محلی گرفتار می‌شود و WOA نیازمند تنظیمات حساس پارامترهاست، HOA با استفاده از مدل‌سازی طبیعی مسیرهای کوهنوردی، امکان جستجوی منعطف‌تری را فراهم می‌سازد. این ویژگی می‌تواند در شرایط دریایی که داده‌های سونار بسیار پرنویز و متغیر هستند، مزیت عملی محسوب شود. وجود نسخه‌های بهبودیافته در این الگوریتم‌ها از جمله [14]–[11] گواه نیاز این الگوریتم‌ها به تعیین مرز بین فاز اکشاف و استخراج می‌باشد.

```
Input: UB, LB, T, I , d
F      ← Preallocate fitness vector ℝ^(I×1)
F_best ← Preallocate best fitness vector ℝ^((T+1)×1)
β← Initialize the hikers' position randomly
for i = 1 to I do
    F_i← Evaluate a hiker's fitness
end for
F_best,1← min(F)
for t = 1 to T do
    F_best,t ← Determine the best fitness hiker
    β_best ← Extract position of best fitness F_best,t
    for i = 1 to I do
        β_i,t ← Extract initial position of hiker i
        θ_i,t ← Determine trail/terrain angle of elevation
        S_i,t ← Compute the slope using (2)
        W_i,t−1 ← Compute the initial hiking velocity using (1)
        W_i,t ← Determine the actual velocity of hiker i using (3)
        β_i,t+1 ← Update the hiker's position using (4)
        β_i,t ← Bound β_i,t+1 within LB and UB
        if F_n ≤ F(n) then
            γ(n,:) ← H⃗
            F(n)   ← F_n
        end if
    end for
    F_sol(i + 1) ← min(F)
end for
F*_sol ← argmin(F_sol)
return
```

شکل ۱- شبه کد الگوریتم بهینه‌سازی HOA

۳ – بازشناسی خودکار اهداف سوناری مبتنی بر طبقه‌بند گروهی با آرای اکثریت وزن‌دهی شده با للگوریتم بهینه‌سازی پیاده روی

در این بخش ابتدا دادگان مورد استفاده معرفی می‌شوند. سپس، روش استخراج ویژگی شرح داده می‌شود. در ادامه، نحوه طراحی طبقه‌بند گروهی مورد بررسی قرار می‌گیرد.

۳-۱- مجموعه دادگان

در این مقاله ابتدا برای داشتن یک ارزیابی منصفانه، علاوه بر سنجش طبقه‌بندهای پایه و گروهی بوسیله سه مجموعه داده‌ی معیار موجود در UCI (شامل Iris، Glass، و Wine)، از مجموعه دادگان سونار گورمن[13] و سجنوسکی[14] و داده‌گان شبیه‌سازی

[11] Particle Swarm Optimization
[12] Whale Optimization Algorithm

[13] Gorman
[14] Sejnowski

شـده با اسـتفاده از پارامترهای واقعی اهداف سـوناری اسـتفاده می‌شود.

مجموعه داده Iris شامل ۶۹۰ نمونه، ۴ ویژگی و سه کلاس مرجع اســت. مجموعه داده Glass شـــامل ۲۶۴ نمونه، ۳ ویژگی و دو کلاس مرجع می‌باشد. مجموعه داده Wine شامل ۶۷۸ نمونه، ۶۹ ویژگی و سه کلاس مرجع است.

داده‌ها سونار مورد استفاده از آزمایش گورمن و سجنوسکی موجود در مرجع [15] استخراج شده است. این داده‌ها شرایطی مشابه سناریوهای عملیاتی سونار در دریا را بازتاب می‌دهند، چرا که در آن‌ها بازگشت سیگنال از اهداف واقعی (مانند سیلندر فلزی) و اهداف کاذب (مانند صخره‌ی دریایی) مورد بررسی قرار گرفته است. چنین شرایطی به خوبی چالش‌های واقعی شناسایی اهداف دریایی را نشان می‌دهد؛ جایی که یک سامانه‌ی سونار باید بتواند بین کشتی‌های باری، زیردریایی‌ها و اجسام طبیعی بستر دریا تمایز قائل شود. در این آزمایش دو نوع سیگنال بازگشتی وجود دارد، اولی مربوط به یک سیلندر فلزی (نقش هدف واقعی را برعهده دارد) و دومی مربوط به یک صخره‌ی هم اندازه‌ی سیلندر (نقش کلاتر یا هدف کاذب را ایفا می‌کند) می‌باشد. در این آزمایش یک سیلندر فلزی به طول ۵ فوت و یک صخره هم‌اندازه با آن در بستر شنی دریا قرار داده شده‌اند و یک پالس چیرپ FM خطی پهن باند[15] (*ka*=55/6) به سمت آن‌ها فرستاده شده است. بر اساس *SNR* اکوی دریافتی، از ۱۲۰۰ اکو جمع‌آوری شده، ۲۰۸ اکو که *SNR* آن‌ها بین ۴*dB* تا ۱۵*dB* است، انتخاب شده‌اند. از این ۲۰۸ اکو، ۱۱۱ عدد مربوط به سیلندر فلزی و ۹۷ عدد مربوط به صخره هستند.

در مرجع [۷] مدل ریاضی سیگنال بازگشتی از پروانه به شرح زیر ارائه شده است. پارامترهای مورد استفاده در معادله (۶) در جدول (۱) توضیح داده شده است. دراین مدل فرض شده است که هدف در محدوده سیگنال ارسالی قرار دارد و سیگنال به پروانه هدف برخورد می کند. در این داده، پارامترهایی همچون زاویه دید و نسبت سیگنال به نویز با در نظر گرفتن شرایط واقعی انتشار صوت در آب دریا لحاظ شده‌اند که باعث افزایش شباهت نتایج به محیط عملیاتی می‌شود.

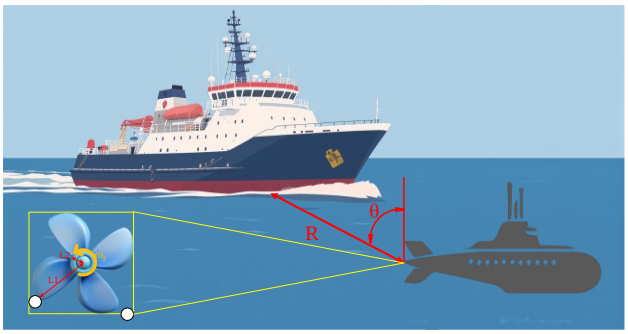
شکل ۲ نحوه به دست آوردن سیگنال بازگشت با استفاده از معادله پارامتر A_r نقش اساسی در معادله (۲-۳) دارد. برای مثال، اگر هدف در امتداد گیرنده سونار باشد ($A_r = 1$)، سیگنال تقریباً به طور کامل مدوله شده است، درحالی که اگر ملخ هدف دقیقاً در کنار گیرنده ($A_r = 0$) قرار گیرد و سیگنالی تولید نمی‌شود.

[15] Wide-Band Linear FM

۶ را نشان می‌دهد.

$$s_r(t) = \sum_{n=0}^{N-1} A_r(L_2 - L_1)e^{j(\beta)} \cdot sinc\left(\frac{4\pi}{\lambda}\frac{(L_2 - L_1)}{2}cos(\theta)\, sin\left(\omega_r t + \frac{2\pi n}{N}\right)\right) \quad (۶)$$

$$\beta = \omega_c t - \frac{4\pi}{\lambda}\left(R + vt + \frac{L_1 + L_2}{2}\, cos(\theta)\, sin\left(\omega_r t + \frac{2\pi n}{N}\right)\right)$$



شکل ۲: نحوه به دست آوردن سیگنال بازگشت با استفاده از معادله (۶)

جدول ۱: پارامترهای مورد استفاده در معادله ۶

پارامترها	توضیح
$s_r(t)$	سیگنال برگشتی بر حسب زمان
N	تعداد پره‌های پروانه
A_r	یک عامل نرمالیزه کننده
L_1	فاصله ابتدای پره‌ها تا مرکز چرخش
L_2	فاصله انتهای پره‌ها تا مرکز چرخش
ω_c	فرکانس زاویهای موج ارسالی
λ	طول موج سیگنال ارسالی
R	فاصله مرکز چرخش از سونار
v	سرعت هدف نسبت به سونار
θ	زاویه دید هدف
ω_r	فرکانس زاویهای چرخش قسمت چرخان هدف

فرآیندهای تصادفی زیادی در آب دریا و اقیانوس ها وجود دارد. هر یک از این فرآیندهای تصادفی توزیع خاص خود را دارند. طبق قضیه حد مرکزی، زمانی که فرآیندهای تصادفی با هر نوع توزیع افزایش می‌یابند، توزیع آنها گاوسی است [۱۶]. بنابراین، نویز

مخلوط با سیگنال بازگشتی از هدف، نویز گاوسی سفید فرض می‌شود و نمونه‌های تصادفی آن با استفاده از متغیرهای تصادفی یکنواخت شبیه‌سازی می‌شوند. قدرت نویز را با تغییر واریانس آن تغییر می دهیم. نسبت های مختلف SNR با تغییر جداگانه توان نویز برای هر هدف انجام می شود. قدرت سیگنال برای هر هدف، قدرت متناظر آن در همان زاویه دید است. در این مقاله برای حفظ کیفیت و وضوح سیگنال، از نرخ نمونه برداری ۱۰۰۰ kHz در محدوده ۴ s /۰—۰ استفاده گردیده است.

کلاس‌های مرجع با بیســـت و پنج هدف جدول۱ مطابقت دارند. نمونه های هر کلاس شـــامل بردارهای ویژگی در هفت SNR ، (۲۰-، ۱۵-، ۱۰-، ۵-، ۰، ۵، ۱۰ دســـی بل) و هشـــت زاویه دید (۱۰، ۲۰، ۳۰، ۴۰، ۵۰، ۶۰، ۷۰ و ۸۰ درجه) می‌باشـد. هر کلاس شـامل ۳۰ نمونه در SNR و زوایای دید مشـخص اسـت. بنابراین، ۱۶۸۰ نمونه در هر کلاس (مرتبط با هر هدف) برای همه SNR ها و زوایای دید وجود دارد. در مجموع، مجموعه داده شامل ۴۲۰۰۰ نمونه است.

۲-۳- استخراج ویژگی

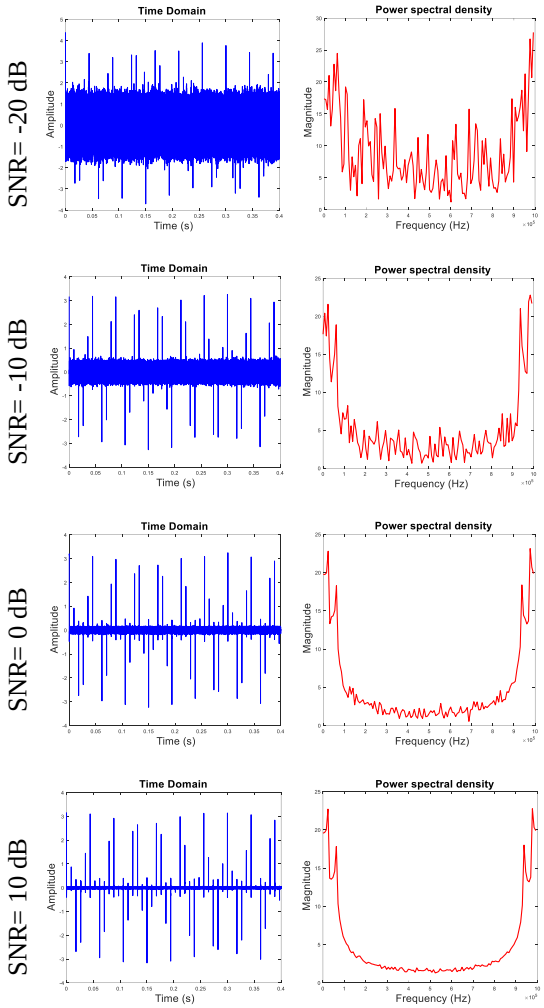
با توجه به نیاز به پردازش بلادرنگ در کاربردهای دفاعی و نظامی، ویژگی اســـتخراج شـــده از این ســـیگنال‌ها، اجزای ۱۲۸ نقطه ای تبدیل فوریه سـریع[۱۶] (FFT) می‌باشـد. معادله (۷) سـاختار بردار ویژگی هدف را برای داده های شبیه سازی شده در زاویه دید θ و نسبت SNR مشخص شده به صورت زیر بیان می‌کند.

$$feature\ vector = [\, f_1 . f_2 . f_3 . \ldots . f_{126} . f_{127} . f_{128} \,]_{(SNR.\theta)} \quad (۷)$$

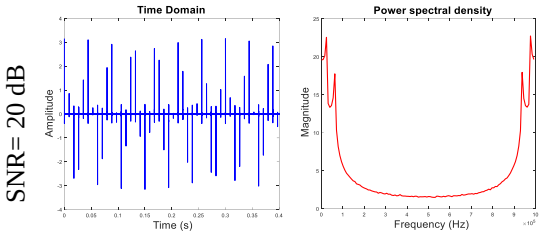
هر یک از اجزا در بردار ویژگی، مربوط به نقطه $FFT\ 128$ نقطه‌ای در زاویه دید و SNR مشخص شده است. شکل ۳ تأثیر مقدار SNR را بر سیگنال بازگشتی در زاویه دید ۲۰ درجه برای هدف شماره ۶ نشان می‌دهد.

جدول۲- اهداف مرجع

ردیف	نوع	مدل
۱	کشتی کانینربر	Emma Maersk
۲	کشتی کانینربر	MV Barzan
۳	کشتی کانینربر	MSC Oscar
۴	کشتی نفت‌کش	Front Century
۵	کشتی نفت‌کش	Seawise Giant
۶	کشتی مسافربری	Motorboat
۷	کشتی مسافربری	Oasis of the Seas
۸	کشتی مسافربری	Leading Atlas
۹	کشتی تفریحی	Harmony of the Seas
۱۰	کشتی یدک‌کش	ASD TUG 2913
۱۱	کشتی یدک‌کش	Chinese Oceanic Tug Boat
۱۲	کشتی تحقیقاتی	Nathaniel B. Palmer
۱۳	زیردریایی بدون سرنشین	Tech 475 AUV
۱۴	نظامی	Torpedo No. 1
۱۵	نظامی	Torpedo No. 2
۱۶	نظامی	Logistic Support
۱۷	نظامی	Littoral Combat Ship No. 1
۱۸	نظامی	Littoral Combat Ship No. 2
۱۹	نظامی	Destroyer No. 1
۲۰	نظامی	Destroyer No. 2
۲۱	نظامی	Frigates
۲۲	نظامی	Aircraft Carrier
۲۳	نظامی	Light Submarine
۲۴	نظامی	Semi-Heavy Submarine
۲۵	نظامی	Heavy Submarine



[16] Fast Fourier Transform (FFT)



شکل ۳- نمونه‌هایی از سیگنال‌های صوتی شبیه سازی شده و امضای فرکانسی از میکرو داپلر سونار در SNRهای مختلف برای هدف شماره ۶

۳-۳- طبقه‌بند گروهی با آرای اکثریت وزن‌دهی شده با الگوریتم بهینه‌سازی پیاده روی

گاهی اوقات وجود نویز در داده ها باعث اشتباه تصمیم در طبقه‌بندها می‌شود. در این حالت ترکیب تصمیمات طبقه‌بندهای مختلف می‌تواند باعث کاهش میزان خطا و افزایش کارایی سامانه شود. به عبارت دیگر، استفاده از رای اکثریت طبقه‌بندهای پایه می‌تواند عملکرد سامانه را بهبود بخشد. اگرچه رای اکثریت ممکن است به روش‌های مختلفی انجام شود، اما معمول‌ترین روش، اختصاص یک نمونه به کلاسی است که بیشترین آرا را دارد، یعنی تخصیص یک نمونه به کلاسی که اکثر طبقه‌بندی‌کننده‌های پایه با آن موافق هستند. با این حال، همه طبقه‌بندهای پایه‌ی استفاده شده، عملکرد یکسانی ندارند و به ندرت پیش می‌آید که عملکرد یکسانی داشته باشند. بنابراین، برخورد یکسان با آنها ممکن است بهترین رویکرد نباشد. در این مورد، وزن دادن به آرا یک استراتژی مناسب به شمار می‌رود. وزن‌دهی تکنیک‌های مختلفی دارد. یکی از جدیدترین و کارآمدترین تکنیک‌های وزن‌دهی، استفاده از الگوریتم‌های ابتکاری می‌باشد. در این مقاله از روش تلفیق تصمیم با استفاده از روش آرای وزن‌دهی شده با HOA با نام MV-HOA استفاده شده است. شکل ۴ مراحل بازشناسی را با استفاده از MV-HOA نشان می‌دهد.

وزن‌های پنج طبقه‌بند پایه یک کوهنورد را در HOA تشکیل می‌دهند. معادله‌ی زیر بردار وزن را برای طبقه‌بندهای پایه نشان می‌دهد.

$$\overline{Weight\ vector} = w_1, w_2, w_3, w_4, w_5, w_6 \qquad (۸)$$

تابع برازندگی برای هدایت کل الگوریتم به پاسخ بهینه کلی استفاده می‌شود. معادله زیر تابع برازندگی استفاده شده را نشان می‌دهد.

$$fitness(i) = \frac{\sum_{j=1}^{C} Correct\ recognition\ rate}{C} \qquad (۹)$$

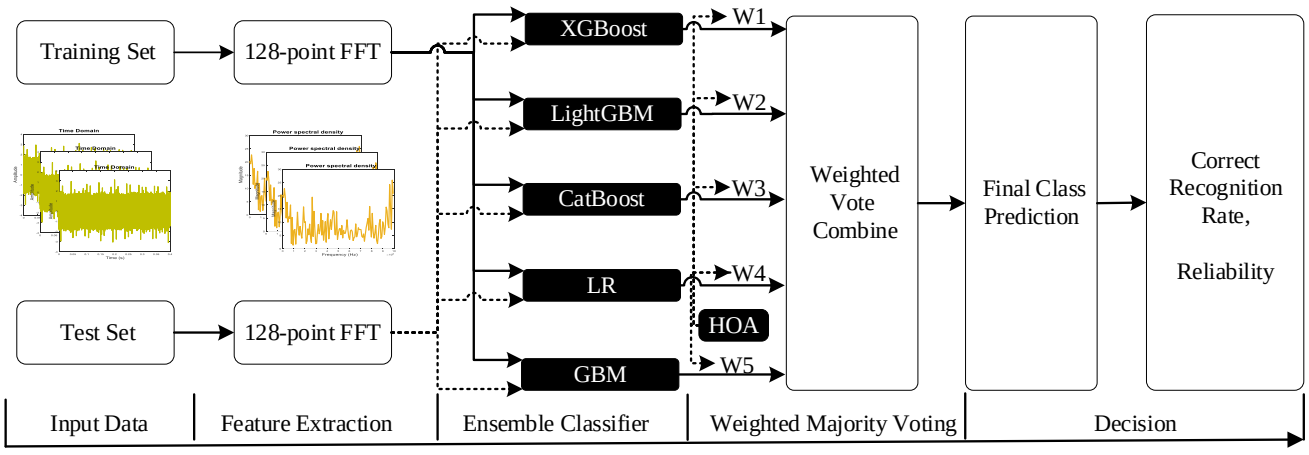
که در آن i نشان دهنده کوهنورد i–ام و C نشان‌دهنده تعداد کلاس‌ها است.

۴- شبیه‌سازی و بررسی نتایج

در این قسمت ابتدا به بازشناسی خودکار اهداف سونار با استفاده از طبقه‌بندهای پایه و سپس به بازشناسی با استفاده از MV-HOA برای هر سه مجموعه داده‌ی سونار پرداخته می‌شود. تمام ارزیابی‌ها در MATLAB R2020a، روی رایانه شخصی با پردازنده Intel Core i7-4500u با پردازنده ۲/۳ گیگاهرتز، ۵ گیگابایت حافظه رم در ویندوز ۷ انجام شد.

جدول ۲ نتایج بازشناسی را برای مجموعه داده‌ی Iris ، Wine، Glass ، گورمن و سجنوسکی نشان‌دهد. جدول ۳ نتایج را برای بازشناسی اهداف سونار شبیه‌سازی شده با پارامترهای واقعی نشان می‌دهد.

معیار ارزیابی در تمامی جداول، دقت بازشناسی است که به صورت درصد گزارش شده است. دقت به عنوان نسبت نمونه‌های به درستی طبقه‌بندی‌شده به کل نمونه‌ها تعریف می‌شود.



شکل ۴- مراحل بازشناسی با استفاده از MV-HOA

جدول ۳- دقت بازشناسی برای مجموعه داده‌ی Iris، Wine، Glass ، گورمن و سجنوسکی

داده	XGBoost	LightGBM	CatBoost	LR	GBM	MV-HOA
Iris	۸۴/۵۶	۹۱/۰۵	۹۰/۴۷	۶۸/۰۰	۷۸/۶۵	۹۳/۴۳
Wine	۹۳/۱۴	۷۸/۷۱	۹۰/۲۲	۷۰/۷۹	۷۳/۸۶	۹۳/۶۴
Glass	۷۹/۶۵	۷۳/۹۲	۶۷/۶۴	۵۸/۶۸	۸۲/۷۱	۸۴/۱۱
Gorman & Sejnowski	۹۱/۷۵	۷۰/۳۹	۹۲/۳۶	۶۱/۹۹	۵۹/۲۸/	۹۳/۱۵

جدول ۴- دقت بازشناسی اهداف سونار شبیه‌سازی شده مبتنی بر پارامترهای واقعی

SNR	پارامتر	زاویه دید (درجه)							
		۱۰	۲۰	۳۰	۴۰	۵۰	۶۰	۷۰	۸۰
۱۰	XGBoost	۹۵/۶۰	۹۴/۴۰	۹۵/۶۰	۹۵/۲۰	۹۶/۰۰	۹۶/۰۰	۹۵/۲۰	۹۶/۸۰
	LightGBM	۹۵/۶۰	۹۴/۰۰	۹۶/۳۹	۹۶/۰۰	۹۵/۵۹	۹۶/۰۰	۹۵/۵۹	۹۶/۰۰
	CatBoost	۹۶/۰۰	۹۴/۸۰	۹۴/۸۰	۹۶/۴۰	۹۵/۶۰	۹۶/۴۰	۹۶/۴۰	۹۶/۸۰
	LR	۷۴/۶۳	۷۴/۰۵	۷۳/۱۱	۷۲/۵۴	۷۲/۳۷	۷۲/۱۱	۷۱/۸۹	۷۱/۳۴
	GBM	۹۴/۸۰	۹۴/۰۰	۹۵/۲۰	۹۴/۸۰	۹۴/۸۰	۹۵/۶۰	۹۶/۸۰	۹۶/۸۰
	MV-HOA	۹۹/۶۳	۹۹/۶۳	۱۰۰/۰	۹۹/۶۳	۹۹/۲۰	۹۹/۶۳	۹۹/۲۰	۹۹/۶۳
۵	XGBoost	۹۷/۲۰	۹۶/۰۰	۹۳/۶۰	۹۶/۴۰	۹۶/۸۰	۹۵/۲۰	۹۶/۴۰	۹۶/۸۰
	LightGBM	۹۸/۰۰	۹۶/۳۹	۹۵/۱۹	۹۴/۷۹	۹۷/۵۹	۹۶/۰۰	۹۶/۰۰	۹۵/۱۹
	CatBoost	۹۷/۶۰	۹۶/۰۰	۹۵/۲۰	۹۴/۴۰	۹۷/۲۰	۹۵/۲۰	۹۶/۰۰	۹۵/۲۰
	LR	۷۱/۴۱	۷۱/۳۰	۷۰/۷۸	۷۰/۰۹	۷۰/۱۱	۶۹/۱۴	۶۸/۹۹	۶۸/۲۳
	GBM	۹۵/۶۰	۹۶/۰۰	۹۴/۴۰	۹۴/۸۰	۹۳/۶۰	۹۴/۸۰	۹۶/۰۰	۹۴/۸۰
	MV-HOA	۱۰۰/۰	۹۹/۶۳	۹۹/۶۳	۹۹/۳۳	۹۹/۶۳	۹۹/۶۳	۱۰۰/۰	۱۰۰/۰
۰	XGBoost	۹۶/۰۰	۹۵/۲۰	۹۵/۶۰	۹۵/۲۰	۹۶/۸۰	۹۶/۴۰	۹۶/۴۰	۹۲/۰۰
	LightGBM	۹۶/۰۰	۹۶/۰۰	۹۶/۳۹	۹۵/۵۹	۹۶/۰۰	۹۶/۷۹	۹۴/۷۹	۹۴/۷۹
	CatBoost	۹۵/۲۰	۹۶/۴۰	۹۴/۸۰	۹۵/۶۰	۹۶/۰۰	۹۶/۰۰	۹۵/۲۰	۹۵/۲۰
	LR	۶۹/۳۳	۶۹/۰۵	۶۸/۱۴	۶۷/۸۹	۶۷/۰۳	۶۶/۶۱	۶۵/۸۰	۶۵/۱۱
	GBM	۹۴/۸۰	۹۴/۸۰	۹۶/۴۰	۹۶/۰۰	۹۴/۸۰	۹۳/۶۰	۹۵/۶۰	۹۲/۰۰
	MV-HOA	۹۹/۶۳	۹۹/۶۳	۱۰۰/۰	۱۰۰/۰	۹۹/۶۳	۱۰۰/۰	۹۹/۶۳	۹۹/۶۳
-۵	XGBoost	۹۵/۲۰	۹۷/۶۰	۹۷/۲۰	۹۴/۰۰	۹۳/۲۰	۹۳/۶۰	۹۵/۲۰	۹۰/۸۰
	LightGBM	۹۶/۰۰	۹۶/۷۹	۹۵/۵۹	۹۴/۳۴	۹۴/۳۹	۹۴/۰۰	۹۴/۷۹	۹۱/۲۰
	CatBoost	۹۵/۶۰	۹۶/۴۰	۹۴/۸۰	۹۵/۲۰	۹۴/۴۰	۹۴/۴۰	۹۶/۰۰	۸۸/۸۰
	LR	۶۸/۴۴	۶۷/۲۸	۶۷/۰۳	۶۶/۷۹	۶۶/۲۵	۶۵/۷۸	۶۵/۰۰	۶۴/۳۴
	GBM	۹۴/۴۰	۹۲/۰۰	۹۳/۲۰	۹۴/۰۰	۹۳/۲۰	۹۱/۲۰	۹۴/۰۰	۹۲/۰۰
	MV-HOA	۹۹/۶۳	۹۹/۶۳	۹۹/۶۳	۹۹/۶۳	۹۹/۲۷	۹۹/۶۳	۹۹/۳۳	۹۸/۴۷
-۱۰	XGBoost	۸۶/۰۰	۹۰/۰۰	۸۸/۰۰	۸۸/۸۰	۸۶/۸۰	۸۲/۰۰	۸۲/۰۰	۷۴/۴۰
	LightGBM	۸۹/۲۰	۸۷/۲۰	۹۰/۰۰	۹۰/۰۰	۸۶/۷۹	۸۷/۲۰	۸۸/۷۹	۸۴/۳۹
	CatBoost	۹۰/۴۰	۸۹/۶۰	۸۹/۶۰	۸۶/۴۰	۸۷/۶۰	۸۶/۰۰	۸۱/۲۰	۸۲/۴۰
	LR	۶۵/۴۲	۶۴/۵۱	۶۳/۱۰	۶۲/۷۷	۶۲/۱۵	۶۲/۱۰	۶۱/۶۰	۶۱/۱۱
	GBM	۸۲/۴۰	۸۲/۸۰	۸۸/۴۰	۸۷/۲۰	۸۵/۶۰	۸۷/۲۰	۸۷/۲۰	۷۵/۶۰
	MV-HOA	۹۵/۶۴	۹۵/۳۴	۹۵/۸۰	۹۶/۳۰	۹۵/۱۱	۹۴/۷۳	۹۵/۰۶	۸۹/۶۸
-۱۵	XGBoost	۸۰/۸۰	۸۰/۰۰	۷۷/۲۰	۸۴/۴۰	۷۳/۲۰	۷۰/۴۰	۷۰/۴۰	۶۴/۸۰
	LightGBM	۸۵/۲۰	۸۶/۴۰	۸۳/۵۹	۸۴/۰۰	۸۴/۰۰	۷۹/۲۰	۸۴/۰۰	۷۵/۵۹
	CatBoost	۸۴/۸۰	۸۴/۴۰	۸۱/۲۰	۸۲/۰۰	۸۰/۰۰	۷۴/۴۰	۷۴/۴۰	۶۹/۲۰

	LR	۶۳/۲۴	۶۲/۹۴	۶۲/۵۳	۶۱/۷۸	۶۱/۱۴	۶۰/۹۰	۵۹/۹۸	۵۹/۱۵
	GBM	۸۱/۲۰	۸۲/۸۰	۷۳/۶۰	۷۵/۲۰	۷۷/۶۰	۷۸/۰۰	۷۵/۶۰	۶۳/۲۰
	MV-HOA	۹۱/۵۷	۸۹/۵۴	۸۸/۰۸	۹۱/۳۷	۸۸/۸۱	۸۵/۰۵	۸۶/۴۳	۷۹/۰۷
-۲۰	XGBoost	۶۴/۰۰	۶۸/۸۰	۶۴/۸۰	۶۵/۶۰	۷۰/۴۰	۶۳/۲۰	۵۶/۴۰	۵۰/۸۰
	LightGBM	۷۹/۶۰	۷۹/۶۰	۷۷/۲۰	۸۱/۲۰	۸۲/۳۹	۸۰/۸۰	۷۲/۳۹	۷۳/۵۹
	CatBoost	۷۶/۰۰	۷۸/۸۰	۷۴/۰۰	۷۶/۰۰	۷۳/۶۰	۷۴/۸۰	۷۰/۰۰	۶۳/۶۰
	LR	۶۰/۴۵	۶۰/۲۳	۶۰/۷۵	۵۹/۷۱	۵۹/۳۸	۵۸/۶۸	۵۸/۱۹	۵۷/۷۷
	GBM	۶۷/۶۰	۶۸/۸۰	۶۴/۰۰	۶۹/۲۰	۶۶/۴۰	۶۵/۶۰	۶۳/۲۰	۵۴/۰۰
	MV-HOA	۸۵/۲۴	۸۰/۴۰	۷۷/۴۸	۸۳/۹۸	۸۳/۰۸	۷۹/۴۶	۷۸/۴۶	۷۱/۶۸

نتایج ارائه‌شده در جدول ۳ نشان می‌دهند که مدل MV-HOA در بازشناسی داده‌های استاندارد مانند Iris، Wine و Glass عملکرد بهتری نسبت به سایر طبقه‌بندها داشته است. این برتری به دلیل ویژگی گروهی مدل MV-HOA است که از یک طبقه‌بندی مبتنی بر آرای اکثریت با وزن‌دهی استفاده می‌کند و از الگوریتم بهینه‌سازی پیاده‌روی HOA برای بهبود وزن‌دهی و افزایش دقت بهره می‌برد. در این جدول، میزان دقت بالای این مدل در مقایسه با مدل‌های دیگری چون GBM، CatBoost و LightGBM به وضوح قابل مشاهده است.

در جدول ۴ نیز نتایج بازشناسی اهداف سونار تحت شرایط مختلف از جمله *SNR*های متفاوت و زوایای دید مختلف ارائه شده است. مدل MV-HOA در تمامی شرایط مختلف، دقت بالایی را نسبت به سایر مدل‌ها از خود نشان داده است. این موضوع به دلیل استفاده از الگوریتم HOA در بهینه‌سازی وزن‌دهی است که باعث می‌شود طبقه‌بندی اهداف سونار با دقت و پایداری بیشتری انجام شود. به طور مثال، در شرایطی با *SNR* بالا، مدل MV-HOA به دقتی نزدیک به ۹۹٪ دست یافته است که نشان از کارایی بالای این روش در تشخیص دقیق اهداف دارد.

جدول ۵- میانگین زمان پردازش (بر اساس ثانیه) برای مجموعه داده‌ی Iris، Wine، Glass ، گورمن و سجنوسکی و دادگان شبیه‌سازی شده مبتنی بر پارامترهای واقعی

داده	XGBoost	LightGBM	CatBoost	LR	GBM	MV-HOA
Iris	۰/۶۰	۰/۳۵	۰/۷۵	۰/۰۵	۱/۲۵	۱/۸۵
Wine	۰/۸۰	۰/۴۵	۰/۹۵	۰/۰۷	۰/۶۰	۲/۲۰
Glass	۱/۰۰	۰/۵۵	۱/۱۵	۰/۰۹	۱/۹۵	۲/۷۵
Gorman & Sejnowski	۱/۹۰	۱/۰۵	۲/۱۰	۰/۱۵	۲/۸۰	۴/۵۰
دادگان شبیه‌سازی شده مبتنی بر پارامترهای واقعی	۴۸/۴۰	۲۴/۲۵	۶۰/۳۰	۳/۲۰	۹۶/۷۵	۱۷۷/۳۵

برای ارزیابی دقیق‌تر اثربخشی MV-HOA، نتایج آن با دو الگوریتم بهینه‌سازی پرکاربرد (PSO و WOA) مقایسه شد که نتایج آن در جدول ۵ نشان داده شده است. نتایج جدول ۵ نشان می‌دهد که روش پیشنهادی MV-HOA از نظر زمان پردازش در مقایسه با سایر طبقه‌بندهای پایه عملکردی متعادل دارد. با وجود اینکه این روش یک مدل ترکیبی همراه با بهینه‌سازی است و طبیعتاً انتظار می‌رود زمان بیشتری صرف کند، مقادیر به‌دست‌آمده نشان می‌دهد افزایش زمان پردازش نسبت به طبقه‌بندهای منفرد بسیار محدود بوده و در حدی نیست که مانع استفاده عملی شود. از سوی دیگر، این اختلاف ناچیز در زمان در برابر بهبود قابل توجه در دقت بازشناسی که در جداول ۳ و ۴ دیده می‌شود کاملاً توجیه‌پذیر است. نکته مهم آن است که MV-HOA علی‌رغم پیچیدگی بیشتر، زمان پردازشی تقریباً هم‌تراز با الگوریتم‌های پرکاربردی چون XGBoost و LightGBM ارائه می‌دهد. بنابراین، می‌توان نتیجه گرفت که این روش با ایجاد تعادل میان پیچیدگی محاسباتی و زمان پردازش، قابلیت استفاده در کاربردهای حساس و بلادرنگ (مانند پردازش سیگنال‌های سونار) را دارا بوده و از منظر عملی نیز یک انتخاب کارآمد است.

جدول ۶ - مقایسه دقت بازشناسی صحیح MV-HOA با دو الگوریتم معیار PSO و WOA برای مجموعه داده‌ی Iris، Wine، Glass ، گورمن و سجنوسکی

مجموعه دادگان

مدل‌ها		Iris	Wine	Glass	Gorman & Sejnowski
MV-HOA	دقت بازشناسی (٪)	۹۳/۴۳	۹۳/۶۴	۸۴/۱۱	۹۳/۱۵
	زمان پردازش (S)	۱/۸۵	۲/۲۰	۲/۷۵	۴/۵۰
PSO	دقت بازشناسی (٪)	۹۲/۰۵	۹۱/۲۰	۸۱/۵۰	۹۰/۸۰
	زمان پردازش (S)	۱/۴۰	۱/۸۰	۲/۳۰	۳/۲۰
WOA	دقت بازشناسی (٪)	۹۰/۶۰	۸۹/۷۵	۸۰/۲۵	۸۹/۴۵
	زمان پردازش (S)	۱/۳۰	۱/۶۰	۲/۱۰	۲/۹۰

در جدول ۶ مشاهده می‌شود که MV-HOA در همه‌ی مجموعه‌داده‌ها بالاترین دقت بازشناسی را به دست آورده است؛ این برتری در برخی مجموعه‌ها (مانند Wine و Iris) به بیش از ۲ درصد می‌رسد. هرچند زمان پردازش آن نسبت به PSO و WOA اندکی بیشتر است، اما این افزایش در حد ثانیه و جزئی بوده و در برابر بهبود دقت قابل چشم‌پوشی است. بنابراین می‌توان نتیجه گرفت که ترکیب رأی‌گیری با الگوریتم HOA توانسته است نقاط ضعف دو الگوریتم معیار (PSO و WOA) را پوشش دهد و مدلی پایدارتر و دقیق‌تر برای بازشناسی ارائه کند.

یکی از نکات مهم در این نتایج، ارتباط مستقیم آن‌ها با کاربردهای دریایی است. بهبود دقت در بازشناسی اهداف سونار (تا حدود ٪۹۹) بدین معناست که احتمال اشتباه در تفکیک کشتی‌های تجاری از اهداف نظامی یا اجسام طبیعی بستر دریا به شدت کاهش می‌یابد. این امر می‌تواند در سامانه‌های دفاعی نیروی دریایی، پایش امنیت مرزهای آبی و حتی مدیریت ترافیک کشتی‌ها نقش تعیین‌کننده داشته باشد. به عنوان مثال، دقت بالاتر در شرایط SNR پایین بیانگر آن است که الگوریتم پیشنهادی حتی در محیط‌های پر نویز ناشی از امواج، باد یا فعالیت کشتی‌های اطراف نیز قابلیت اطمینان بالایی دارد.

در نهایت، نتایج به‌دست‌آمده نشان می‌دهند که استفاده از MV-HOA به عنوان یک طبقه‌بند گروهی مبتنی بر آرای اکثریت با الگوریتم بهینه‌سازی HOA، باعث افزایش دقت و پایداری در بازشناسی اهداف سونار، به ویژه در شرایط با نویز و زاویه دید متفاوت می‌شود. این روش با ترکیب مزایای طبقه‌بندی گروهی و

بهینه‌سازی مبتنی بر الگوریتم‌های هوشمند، به یکی از گزینه‌های موثر در بازشناسی اهداف در سیستم‌های مختلف شبیه‌سازی تبدیل شده است.

اگرچه فرآیند آموزش و بهینه‌سازی گروهی با استفاده از HOA به دلیل ماهیت تکراری آن از پیچیدگی محاسباتی برخوردار است، اما مرحله استنتاج نهایی مدل پیشنهادی بسیار کارآمد است. از آنجایی که مدل‌های پایه در این روش، مدل‌هایی بسیار بهینه‌شده هستند و امکان اجرای موازی دارند، زمان استنتاج مدل نهایی MV-HOA تقریباً معادل زمان استنتاج کندترین مدل پایه آن است. این در حالی است که برای دستیابی به سطح دقت مشابه با یک مدل منفرد، ممکن است نیاز به استفاده از یک معماری بسیار عمیق و پیچیده (مانند یک شبکه عصبی عمیق) باشد که زمان استنتاج آن به مراتب بیشتر خواهد بود. نتایج زمان‌سنجی انجام شده بر روی سیستم آزمایش نشان داد که زمان استنتاج برای یک نمونه توسط MV-HOA به طور متوسط ۲.۱ میلی ثانیه است.

۵- نتیجه‌گیری

در این مقاله، بازشناسی خودکار اهداف سونار با بهره‌گیری از ترکیب طبقه‌بندهای گروهی مبتنی بر آرای اکثریت وزن‌دهی شده و بهینه‌سازی شده با HOA مورد بررسی قرار گرفت. چالش‌های ناشی از پیچیدگی اهداف سونار و شرایط نامساعد محیطی در دریاها، ضرورت استفاده از روش‌های نوین هوش مصنوعی را برای ارتقاء دقت و کاهش خطا در فرآیند شناسایی اهداف نمایان می‌سازد. الگوریتم HOA با بهره‌گیری از شبیه‌سازی رفتار کوهنوردان در شرایط مختلف، قابلیت بهینه‌سازی دقیق وزن‌های طبقه‌بندها را فراهم نموده و منجر به بهبود عملکرد سامانه‌ی بازشناسی شده است.

نتایج حاصل از ارزیابی‌های تجربی نشان می‌دهند که مدل پیشنهادی MV-HOA، با ترکیب دقیق طبقه‌بندهای متنوع مانند XGBoost، LightGBM، CatBoost، رگرسیون لجستیک و تقویت گرادیانی، توانسته است دقت شناسایی اهداف را به میزان قابل توجهی افزایش دهد و از میزان خطا در شناسایی کاسته شود. این روش، علاوه بر افزایش کارایی، با توانایی پردازش سریع، امکان استفاده در سامانه‌های صنعتی و نظامی را نیز فراهم می‌سازد. به طور خاص، این سامانه می‌تواند در کاربردهای دریایی نظیر شناسایی سریع زیردریایی‌ها، کشتی‌های سطحی و اجسام ناشناخته در بستر دریا به‌کار رود. همچنین، استفاده از این

الگوریتم می‌تواند دقت سامانه‌های ناوبری کشتی‌های تحقیقاتی را افزایش داده و در بهبود امنیت تردد دریایی در مناطق پرترافیک نقش مهمی ایفا کند. در نتیجه، مدل پیشنهادی MV-HOA علاوه بر نوآوری در حوزه‌ی هوش مصنوعی، ارزش افزوده‌ی قابل توجهی برای کاربردهای عملی در علوم و مهندسی دریا به همراه دارد.

این پژوهش با ارائه یک طبقه‌بند گروهی بهینه‌سازی شده، گامی مهم در جهت بهبود بازشناسی خودکار اهداف سونار برداشته و نشان داده است که استفاده از الگوریتم‌های بهینه‌سازی مبتنی بر رفتار گروهی می‌تواند به طرز مؤثری قابلیت اطمینان سامانه‌های شناسایی اهداف را ارتقاء دهد. پیشنهاد می‌شود که در تحقیقات آتی، تأثیر شرایط محیطی و ویژگی‌های دینامیک در بهینه‌سازی وزن‌های طبقه‌بندها و دقت شناسایی بیشتر بررسی شود.

۶ – مراجع

1- M. Khishe and H. Mohammadi, “Passive sonar target classi fi cation using multi-layer perceptron trained by salp swarm algorithm,” *Ocean Eng.*, vol. 181, no. May 2018, pp. 98–108, 2019, doi: 10.1016/j.oceaneng.2019.04.013.

2- W. Qiao, M. Khishe, and S. Ravakhah, “Underwater targets classification using local wavelet acoustic pattern and Multi-Layer Perceptron neural network optimized by modified Whale Optimization Algorithm,” *Ocean Eng.*, vol. 219, no. June 2020, p. 108415, 2021, doi: 10.1016/j.oceaneng.2020.108415.

3- F. A. Alenizi, O. M. Alsalami, A. Safari, S. H. Zahiri, and M. Mohammadi, “Decision Fusion and Micro-Doppler Effects in Moving Sonar Target Recognition,” vol. 2023, 2023.

4- A. SAFFARI, S. H. ZAHIRI, and N. K. GHANAD, “Using SVM Classifier and Micro-Doppler Signature for Automatic Recognition of Sonar Targets,” *Arch. Acoust.*, vol. 48, no. 1, pp. 49–61, 2023.

5- W. Kazimierski and G. Zaniewicz, “Determination of process noise for underwater target tracking with forward looking sonar,” *Remote Sens.*, vol. 13, no. 5, pp. 1–21, 2021, doi: 10.3390/rs13051014.

6- N. Hurtós, N. Palomeras, A. Carrera, and M. Carreras, “Autonomous detection , following and mapping of an underwater chain using sonar,” *Ocean Eng.*, vol. 130, no. May, pp. 336–350, 2016, doi: 10.1016/j.oceaneng.2016.11.072.

7- A. Saffari, S. H. Zahiri, and M. Khishe, “Automatic recognition of sonar targets using feature selection in micro-Doppler signature,” *Def. Technol.*, 2022, doi: 10.1016/j.dt.2022.05.007.

8- D. Neupane and J. Seok, “A review on deep learning-based approaches for automatic sonar target recognition,” *Electron.*, vol. 9, no. 11, pp. 1–30, 2020, doi: 10.3390/electronics9111972.

9- W. Tobler, *Three presentations on geographical analysis and modeling: National Center for Geographic Information and Analysis.*, no. February. 1993.

10- M. F. Goodchild, *Beyond Tobler’s Hiking Function*, vol. 52, no. 4. 2020. doi: 10.1111/gean.12253.

11- A. Kaveh and M. R. Moghaddam, “A hybrid WOA-CBO algorithm for construction site layout planning problem,” vol. 25, pp. 1094–1104, 2018, doi: 10.24200/sci.2017.4212.

12- A. Saffari, M. Khishe, M. Mohammadi, A. Hussein Mohammed, and S. Rashidi, “DCNN-FuzzyWOA: Artificial Intelligence Solution for Automatic Detection of COVID-19 Using X-Ray Images,” *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/5677961.

13- M. Khishe and M. R. Mosavi, “Improved whale trainer for sonar datasets classification using neural network,” *Appl. Acoust.*, vol. 154, pp. 176–192, 2019, doi: 10.1016/j.apacoust.2019.05.006.

14- A. Saffari, S. H. Zahiri, and M. Khishe, “Fuzzy whale optimisation algorithm: a new hybrid approach for automatic sonar target recognition,” *J. Exp. Theor. Artif. Intell.*, no. February, 2022, doi: 10.1080/0952813X.2021.1960639.

15- R. P. Gorman and T. J. Sejnowski, “Analysis of hidden units in a layered network trained to classify sonar targets,” *Neural Networks*, vol. 1, no. 1, pp. 75–89, 1988, doi: 10.1016/0893-6080(88)90023-8.

16- A. Saffari, S. Zahiri, and M. Khishe, “Automatic recognition of sonar targets using feature selection in micro-Doppler signature,” *Def. Technol.*, no. xxxx, 2022, doi: 10.1016/j.dt.2022.05.007.