



Presenting the Detection Algorithm of All Types of Vessels In The Persian Gulf Region Using Radar Images In order to Improve the Security of Navigation

Ali Hanafi^{1✉} | Mahdi Keykhaei²

1. Corresponding Author, Associate Professor, Department of Geography, Faculty of Basic Sciences, Imam Ali University, Tehran, Iran.

E-mail: Hanafi772@gmail.com

2. PhD in GIS, Department of Geography, Faculty of Basic Sciences, Imam Ali University, Tehran, Iran.

E-mail: m_keykhaee60@yahoo.com

Article Info

Article type:
Research Article

Article history:
Received
29 June 2023
Received in revised form
11 November 2023
Accepted
09 February 2024
Published online
17 September 2024

Keywords:
remote sensing,
radar images,
kernel,
deep learning,
ship identification

ABSTRACT

Objective: Detecting the presence of vessels near the coast and far from it by radar sensor image and deep learning.

Method: Traditional methods of detecting vessels include the use of human observers or systems that transmit characteristics on vessels. In this research, an attempt has been made to optimize the combination of kernels (MKL) by using deep neural network for the first time and finally identify the ship in the Persian Gulf.

Data analysis: In this research, Sentinel-1 radar sensor images were used, and finally, using K-means algorithm, 365 training samples of the sea and ships in the Persian Gulf were prepared in different weather conditions. 70% of it is introduced to the network as training data and 30% as test data. In this article, using RBF kernels and polynomials of the first, second and third degrees, features are extracted, and then using a deep neural network, the output of the kernels is combined and high-level features are extracted.

Conclusion: The results of the introduced network showed 88% accuracy of the model in identifying and detecting vessels in the Persian Gulf region based on training data. Finally, the network was implemented for validation purposes in Bandar Abbas and Bandar Lange regions and acceptable results were obtained.

Cite this article: Hanafi, A. , & Keykhaei, M. , (2024). Presenting the detection algorithm of all types of vessels in the Persian Gulf region using radar images in order to improve the security of navigation, *Military Science and Tactics*, 20 (68), 203-226.

DOI: <http://doi.org/10.22034/qjmst.2024.2005909.1904>

Publisher: A.J.A. Command and Staff University

DOI: 10.22034/qjmst.2024.2005909.1904





ارائه الگوریتم آشکارسازی انواع شناورها در منطقه خلیج فارس با استفاده از تصاویر راداری در جهت ارتقاء امنیت دریانوردی

علی حنفی^۱ | مهدی کیخایی^۲

۱. نویسنده مسئول، دانشیار گروه جغرافیا دانشکده علوم پایه، دانشگاه امام علی (ع)، تهران، ایران.

ایمانامه: Hanafi772@gmail.com

۲. دکتری سنجش از دور و GIS، گروه جغرافیا دانشکده علوم پایه، دانشگاه امام علی (ع)، تهران، ایران.

ایمانامه: m_keykhah60@yahoo.com

اطلاعات مقاله چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۲/۰۴/۰۸

تاریخ بازنگری:

۱۴۰۲/۰۸/۲۰

تاریخ پذیرش:

۱۴۰۲/۱۱/۲۰

تاریخ انتشار:

۱۴۰۳/۰۶/۲۷

کلیدواژه‌ها:

سنجش از دور،

تصاویر راداری،

کرنل،

آموزش عمیق،

شناسایی شناورها.

هدف: تشخیص و شناسایی شناورها در نزدیکی ساحل و دور از آن با استفاده از تصاویر راداری و یادگیری عمیق.

روش: روش‌های سنتی تشخیص شناورها شامل استفاده از ناظر انسانی یا سیستم‌های ارسال کننده مشخصات در شناورها است. در این پژوهش با استفاده از روش شبکه عصبی عمیق اقدام به بهینه کردن ترکیب کرنل‌ها (MKL) و در نهایت شناسایی کشتی‌ها در منطقه مورد مطالعه (خلیج فارس) شده است.

تجزیه و تحلیل داده‌ها: شناسایی شناورها یکی از مسائل مهمی است که کاربردهای زیادی در صنایع نظامی و غیرنظامی دارد. این کار برای راهبری ترافیک دریایی و امنیت ترافیک در دریا بسیار مورد مفید است. بدین منظور از تصاویر راداری سنجنده سنتینل-۱ و با استفاده از الگوریتم K-means، ۳۶۵ نمونه آموزشی از دریا و کشتی‌ها در خلیج فارس در شرایط جوی مختلف تهیه شده است که ۷۰ درصد از آن به عنوان داده آموزشی و ۳۰ درصد به عنوان داده آزمون به شبکه معرفی گردید.

نتیجه‌گیری: نتایج شبکه معرفی شده نشان دهنده دقت ۸۸ درصدی مدل در شناسایی و آشکارسازی شناورها در منطقه خلیج فارس می‌باشد. شبکه به منظور اعتبارسنجی در دو منطقه بندرعباس و بندرلنگه اجرا گردید نتایج حاصل از این پژوهش می‌تواند به منظور حفاظت و امنیت کشتی‌ها در دریانوردی و کنترل عبور و مرور در آبراهه‌ها حائز اهمیت می‌باشد.

استناد: حنفی، علی؛ کیخایی، مهدی. (۱۴۰۳). ارائه الگوریتم آشکارسازی انواع شناورها در منطقه خلیج فارس با استفاده

از تصاویر راداری در جهت ارتقاء امنیت دریانوردی. *علوم و فنون نظامی*، ۲۰ (۶۸)، ۲۰۳-۲۲۶.

DOI: <http://doi.org/10.22034/qjmst.2024.2005909.1904>

ناشر: دانشگاه فرماندهی و ستاد ارتش جمهوری اسلامی ایران.

DOI: 10.22034/qjmst.2024.2005909.1904



مقدمه

شناسایی اهداف دریایی به طور صحیح، کنترل دقیق شناورهای عبوری خودی و غیرخودی و مدیریت بهینه عبور و مرور دریایی به خصوص در تنگه‌ها و آبراهه‌ها از اهمیت بالایی در حوزه امنیت برخوردار است؛ به عبارت دیگر یکی از پارامترهای مهم و تأثیرگذار در امور دریانوردی امن و فعالیت‌های مرتبط با کشتی‌رانی که دارای صنایع و خطوط کشتی‌رانی هستند، امنیت دریانوردی می‌باشد. در راستای تأمین امنیت دریانوردی، در یک محیط اطلاعاتی مانند مرکز کنترل تردد، مجموعه‌ای از افراد، سازمان‌ها و سامانه‌ها اطلاعات را گردآوری، پردازش و توزیع می‌نمایند و در این بین نیروی انسانی در جمع‌آوری، پردازش و به‌کارگیری اطلاعات ناوبری، نقش کلیدی و اساسی را بر عهده دارد (امیری، ۱۳۹۰: ۱۰۰). تجزیه و تحلیل سریع اطلاعات و تهیه گزارشهای مدیریتی در سامانه‌های فرماندهی و کنترل دریایی از اهمیت خاصی برخوردار است (نقوی و همکاران، ۱۴۰۱).

نظارت بر دریاها موضوعی است که در سال‌های اخیر مورد توجه قرار گرفته است؛ به‌ویژه، نیازها برای امنیت دریاها و برنامه‌های امنیتی افزایش یافته و در پیرو آن روش‌های پایش و ردیابی کشتی‌ها، ناوها و محموله‌ها مورد توجه قرار گرفته است. فن‌های نوین که داده‌های حاصل از منابع مختلف را ادغام کرده و مزایای آن‌ها را با یکدیگر ترکیب می‌کنند، در حال توسعه هستند. به‌عنوان مثال، آزمایشگاه علوم و فناوری دفاعی^۱ دستگاهی به نام تلستو^۲، یک نرم‌افزار ردیابی کشتی بر اساس شبکه‌های سامانه‌های شناسایی خودکار^۳ طراحی، توسعه و استقرار داده است. یک منبع اطلاعاتی دیگر برای سامانه‌های چند منبعی می‌تواند حسگرهای راداری دریاچه مصنوعی^۴ در نظر گرفته شود و به دلیل موفقیت آن‌ها در شناسایی کشتی‌ها و ظرفیت بالای آن‌ها در ردیابی کشتی‌های کوچک، به‌عنوان یک مکمل در روش‌های سنتی در نظر گرفته می‌شود (بروش و همکاران^۵، ۲۰۱۰).

¹ Defence Science and Technology Laboratory (DSTL)

² TELESTO

³ Automatic Identification Systems

⁴ Synthetic Aperture Radar (SAR)

⁵ Brusch and et al

تاکنون، بسیاری از الگوریتم‌های شناسایی کشتی به‌طور عمده بر اساس یک روش نرخ هشدار کاذب ثابت^۱ انجام شده است؛ پس‌زمینه‌ی دریا توسط یک توزیع مناسب مدل می‌شود و یک حد آستانه برای رسیدن به هشدار کاذب تعریف می‌شود (آن و همکاران^۲، ۲۰۱۳). تمام پیکسل‌هایی که شدتی بیشتر از حد آستانه داشته باشند به‌عنوان کشتی شناسایی می‌شود؛ اما این روش‌ها قادر به شناسایی کشتی‌هایی که مقادیری نزدیک به پس‌زمینه دریا داشته باشند نخواهند بود و همچنین محاسبه یک حد آستانه‌ی مناسب نیاز به صرف زمان زیادی دارد (کریسپ^۳، ۲۰۰۴). از سایر روش‌های شناسایی کشتی می‌توان به استخراج رفتارهای همبسته‌ی پراکنش^۴ کشتی‌ها در مقایسه با پراکنش تصادفی از سطح دریا و همچنین روش‌های مبتنی بر خوشه‌بندی برای جداسازی پس‌زمینه‌ی دریا، کشتی و سایر تجهیزات دریایی اشاره کرد (ایروولینو و همکاران^۵، ۲۰۱۵).

در روش‌های ذکر شده از روش‌های یادگیری ماشین غیر نظارت شده استفاده شده است که علاوه بر زمان‌بر بودن احتیاج به یافتن یکسری مقادیر ثابت مانند حد آستانه با وارد کردن داده‌های جدید نیاز است. از طرفی روش‌های نوین یادگیری ماشین مانند شبکه‌های عصبی عمیق که بسیار موفق عمل کرده‌اند و به دقت‌های بالایی در رگرسیون و طبقه‌بندی رسیده‌اند، تعداد بسیار زیادی مؤلفه‌های آموزش پذیر دارند؛ در نتیجه، استفاده از روش‌های یادگیری ماشین عمیق دقت بالاتری خواهند داشت اما به داده آموزشی زیادی احتیاج دارند که تهیه‌ی آن‌ها بسیار زمان‌بر و هزینه‌بر هستند.

الگوریتم‌های یادگیری چند کرنل^۶ (MKL) که گروهی از الگوریتم‌های یادگیری کرنل هستند و هدف آن‌ها بهبود دقت و کارایی الگوریتم‌های مبتنی بر کرنل (مانند الگوریتم ماشین بردار پشتیبان) است، می‌توانند با انتقال داده‌ها به فضای هیلبرت اقدام به استخراج ویژگی کنند (نیازمرادی و همکاران، ۲۰۱۷). به این منظور روش‌ها و الگوریتم‌های مختلفی برای معرفی و آموزش کرنل‌ها معرفی شده است که از جمله آن‌ها می‌توان به آموزش کرنل‌ها با استفاده از شبکه‌های عصبی عمیق به‌منظور تسریع، کاهش

^۱ Constant False Alarm Rate (CFAR)

^۲ An and etal

^۳ Crisp

^۴ backscattering

^۵ Iervolino and etal

^۶ Multiple Kernel Learning (MKL)

نیاز به داده‌های میدانی و آموزش یکسره اشاره کرد (سونگ و همکاران^۱، ۲۰۱۸). به این منظور در این پژوهش، راهکاری برای شناسایی کشتی‌ها با استفاده از MKL ارائه شده است. الگوریتم‌های MKL به جای استفاده از یک کرنل در الگوریتم‌های مبتنی بر کرنل، از یک کرنل ترکیبی که حاصل ادغام گروهی از کرنل‌ها است، استفاده می‌کنند. تفاوت الگوریتم‌های MKL مختلف، روش‌های گوناگون استفاده شده توسط آن‌ها برای بهینه کردن ترکیب کرنل‌هاست. در این پژوهش تلاش بر آن است تا با استفاده از شبکه‌ی عصبی عمیق اقدام به بهینه کردن ترکیب کرنل‌ها و در نهایت شناسایی کشتی‌ها و شناورها در منطقه خلیج فارس به عنوان یکی از مناطق حساس و پر تردد در غرب آسیا گردد.

آموزش یک شبکه عصبی علی‌الخصوص در حالت‌های پیچشی و بازگشتی به تعداد بالای داده آموزشی نیاز دارد که برای رفع این مشکل دو راه کار پیشنهاد داده شده است: پیشنهاد اول استفاده از روش‌های یادگیری ماشین غیر نظارت شده، مانند الگوریتم K-means، برای تولید داده‌های میدانی و پیشنهاد دوم استفاده از کرنل‌ها برای استخراج ویژگی‌ها مستقل از شبکه عصبی که این امر موجب حذف قسمت پیچشی شبکه عصبی و در نتیجه کاهش تعداد پارامترها می‌شود (سلیمانی و همکاران، ۱۳۹۵). در ادامه پژوهش این سؤال اصلی مطرح می‌گردد که آیا با استفاده از تصاویر راداری و به کارگیری شبکه‌های عصبی عمیق امکان آشکارسازی کشتی‌ها و شناورهای سطح آب میسر می‌باشد؟ با توجه به اینکه منطقه خلیج فارس یکی از مناطق پر تردد از نظر شناورهای با مقیاس‌های کوچک و بزرگ در منطقه غرب آسیا بوده و حفظ تأمین آن به وسیله کشورهای منطقه و امنیت دریانوردی در آن بسیار حائز اهمیت می‌باشد لذا این منطقه به عنوان منطقه مطالعه انتخاب گردیده است. بدین منظور در این تحقیق اهداف زیر دنبال می‌گردد.

- ارائه‌ی یک روش یادگیری ماشین نظارت شده برای شناسایی کشتی در این منطقه با استفاده از تصاویر راداری سنتینل ۱.
- ادغام کرنل‌ها به منظور تولید و آموزش یک یا چند کرنل با استفاده از شبکه عصبی عمیق به منظور شناسایی کشتی‌ها.

¹ Song and et al

• استفاده از کرنل‌ها به منظور تسریع و کاهش نیاز به داده‌های میدانی در شبکه‌های عصبی عمیق در شناسایی شناورها.

• کمک به ارتقاء امنیت دریایی با شناسایی شناورهای سطحی.

این پژوهش در چهاربخش سازمان‌دهی گردیده است. پس از بیان مقدمه به مبانی و پیشینه تحقیق پرداخته شده و سپس به روش‌شناسی و یافته‌ها می‌پردازد. در نهایت نتیجه‌گیری پژوهش ارائه شده است.

مبانی نظری و پیشینه پژوهش

مبانی نظری

دورسنجی امروزه نقش مهمی را در شناسایی اهداف سطح زمین بدون نیاز به تماس مستقیم و روش‌های اکتشافی صحرایی ایفا می‌کند. توسعه روش‌های پردازش این داده‌ها در زمینه‌های مختلف آماده‌سازی داده‌ها و استخراج اطلاعات گوناگون مانند خصوصیات طیفی اجزاء سازنده تصویر و فراوانی آن‌ها در پیکسل‌های متشکله تصویر، تمهیدات لازم برای کاربرد این روش‌ها را بیش‌ازپیش مهیا کرده است. از طرف دیگر بهره‌گیری مناسب از این روش‌های آنالیز همانند هر فن‌آوری جدیدی نیاز به بومی‌سازی دارد (کیخایی و همکاران، ۱۳۹۹).

سنتینل ۱^۱ در آوریل ۲۰۱۴ مأموریت خود را آغاز کرد. این ماهواره به‌صورت راداری تصویربرداری را انجام می‌دهد و قادر است که پدیده‌ها و عوارض را در شب و روز بدون در نظر داشتن شرایط آب و هوایی جمع‌آوری کند. همچنین می‌تواند در بدترین شرایط آب و هوایی نیز به جمع‌آوری اطلاعات از سطح زمین بپردازد. این ماهواره در محدوده طول موج ماکروویو و باند C تصویربرداری می‌نماید. سنتینل ۱ در چهار حالت مختلف، تصویربرداری با وضوح قابل‌قبول تا حد ۵ متری و پوششی در عرض ۴۰۰ کیلومتری را فراهم می‌آورد. مدار قطبی بودن آن قابلیت قطبش دوگانه این ماهواره باعث تحویل سریع داده‌ها از ماهواره به ایستگاه زمینی شده است. این ماهواره از یک رادار با روزنه مجازی برخوردار است و تصویری با قدرت تفکیک بالا را ارائه می‌دهد. این ماهواره همچنین به‌گونه‌ای طراحی شده است تا در یک حالت عملیاتی بدون وقفه تصویربرداری از تمام مناطق کره زمین از جمله مناطق ساحلی، راه‌های حمل‌ونقل و پوشش اقیانوسی در سطح کلان را انجام دهد (<https://sentinels.copernicus.eu/>).

¹ Sentinel_1

الگوریتم‌های MKL

فرض کنید که مجموعه‌ی $T = \{x_i, y_i\}$ و $I=1, \dots, n$ شامل n نمونه‌ی آموزشی $x_i = \mathbb{R}^D$ به همراه برچسب کلاس‌های متناظر آن‌ها y_i در دسترس باشد. با استفاده از این داده‌ها، مجموعه‌ای از M کرنل مبنا $\{K_1, K_2, \dots, K_M\}$ محاسبه شده است، که فضای کرنل هریک از آن‌ها با \mathcal{H}_m نمایش داده می‌شود. کرنل‌های مبنا می‌توانند از ویژگی‌های مختلف داده و یا انتخاب توابع کرنل مختلف و از یک داده محاسبه شوند (گونن و آلپایدین^۱، ۲۰۱۱). هدف الگوریتم‌های MKL تخمین ترکیب بهینه‌ای از کرنل‌های مبنا برای بیشینه‌سازی استخراج اطلاعات از داده است. برای دستیابی به این هدف، این الگوریتم‌ها، با استفاده از یک تابع ترکیب، کرنلی به نام کرنل ترکیبی $K_C(\cdot, \cdot) = \langle \emptyset_C(\cdot), \emptyset_C(\cdot) \rangle$ را از ادغام کرنل‌های مبنا می‌سازند (گو و همکاران^۲، ۲۰۱۲). کرنل ترکیبی محتوای اطلاعات بسیار غنی‌تری برای طبقه‌بندی داده‌ها در مقایسه با هریک از کرنل‌های مبنا خواهد داشت، چراکه تمام اطلاعات مفید هر کرنل مبنا توسط تابع ترکیب به این کرنل انتقال یافته است. تابع ترکیب می‌تواند هر تابعی از کرنل‌های مبنا باشد مادامی‌که کرنل ترکیبی حاصل از آن، یک کرنل مثبت-معین باشد. انواع مختلفی از این تابع ارائه شده است، اما معمولاً تابع خطی که در معادله (۱) نشان داده شده است، به‌عنوان تابع ترکیب استفاده می‌شود (کامپس و همکاران^۳، ۲۰۰۸).

$$K_C = \sum_{i=1}^M d_i K_i \quad (1)$$

از کرنل‌های مطرح در سنجش‌ازدور می‌توان به کرنل توابع شعاعی پایه (RBF)^۴ و چندجمله‌ای^۵ اشاره کرد که روابط آن‌ها مطابق زیر است:

$$K_{RBF}(x, y) = e^{(-\gamma \|x-y\|^2)} \quad (2)$$

$$K_{\text{polynomial}}(x, y) = (\gamma(x, y))^{\text{degree}} \quad (3)$$

که در آن‌ها γ و degree جزء پارامترهایی است که باید مقدار بهینه‌ی آن‌ها یافت شود. با این تعاریف اگر تصویر ورودی دارای n سطر، m ستون و l باند باشد، اگر p تا نمونه آموزشی استخراج شود، با ورود به فضای هیلبرت توسط یک کرنل تعداد باندها یا به

¹ Gönen, & Alpaydın

² Gu and etal

³ Camps and etal

⁴ Radial Basis Function

⁵ polynomial

عبارتی ویژگی‌ها از مقدار l به p می‌رسد که معمولاً بیشتر است (امپس و همکاران، ۲۰۰۶).

یادگیری عمیق در شبکه‌ها عصبی تمام متصل

طی سال‌های اخیر، یادگیری عمیق در حوزه‌های مختلف به صورت گسترده مورد مطالعه قرار گرفته است. واحد پردازشی در شبکه‌ها عصبی تمام متصل نورون‌ها هستند که همگام باهم کار می‌کنند تا مشکل مشخصی را حل کنند، یادگیری عمیق با مثال یک شبکه برای یک درخواست مشخص مثل تشخیص الگوها یا طبقه‌بندی داده‌ها در طول یک پردازش یادگیری عمیق ایجاد می‌شود. نورون‌های مصنوعی واحدهای پردازشی هستند که بعضی عملیات محاسباتی را روی چندین متغیر ورودی انجام می‌دهند و معمولاً یک خروجی محاسبه‌شده را در طول تابع فعال‌ساز تولید می‌کنند. به طور نوعی یک نورون مصنوعی یک بردار وزن $W = (w_1, w_2, \dots, w_n)$ و بعضی متغیرهای ورودی $X = (x_1, x_2, \dots, x_n)$ و یک آستانه یا جهت b (bias) را دارا است. از دید ریاضی، بردارهای W و X بعد یکسانی دارند. پردازش کامل نورون به شکل معادله‌ی (۴) بیان می‌شود (بنگیو^۱، ۲۰۰۹).

$$Z = f(\sum_i^N X_i \times W_i + b) \quad (۴)$$

درحالی‌که Z, X, W و b به ترتیب بیان‌کننده خروجی، ورودی، وزن و آستانه هستند. $F(\cdot): R \rightarrow R$ تابع فعال‌ساز را بیان می‌کند. به طور قراردادی، یک تابع غیرخطی برای $F(\cdot)$ در نظر گرفته می‌شود. توابع مورد استفاده زیادی به عنوان تابع فعال‌ساز وجود دارد، مانند: Sigmoid، Herbolich و همچنین تابع اصلاح‌شده‌ی خطی. تابع اصلاح‌شده خطی، در این مقاله مورد استفاده قرار گرفته است؛ نورون‌هایی با این مشخصات وقتی که با دیگر نورون‌ها مقایسه می‌شوند، سه مزیت دارند: ۱- بهتر کار می‌کنند طوری که از اشباع برنامه در حین پردازش یادگیری دوری می‌کنند. ۲- موجب عدم تراکم در واحدهای مخفی می‌شوند. ۳- مانند توابع Sigmoid و Tanh دچار مشکل ناپدید شدن شیب نمی‌شوند. واحد پردازشی که از تابع اصلاح‌گر به عنوان تابع فعال‌ساز استفاده می‌کند، واحد فعلی اصلاح‌شده^۲ (ReLU) نامیده می‌شود که مطابق رابطه زیر است:

$$a = \begin{cases} z, & z > 0 \\ 0, & z \leq 0 \end{cases} \leftrightarrow a = f(z) = \max(0, z) \quad (۵)$$

^۱ Bengio

^۲ Rectified Linear Units

شبکه‌های عصبی تمام متصل از چندلایه تشکیل شده‌اند که لایه‌های اولیه ویژگی‌های سطح پایین و لایه‌های آخر ویژگی‌های سطح بالا را استخراج می‌کنند. در هر مرحله مانند معادله ۱ هر پیکسل در وزن متناظر با خودش ضرب می‌شود و خروجی نورون را تولید می‌کند (هو و همکاران^۱، ۲۰۱۵).

ادبیات و پیشینه تحقیق

اولین پژوهش در زمینه شناسایی کشتی با استفاده از تصاویر راداری توسط آقای آن و همکاران (۲۰۱۳) در مقاله‌ای با عنوان "یک طرح سانسور تکراری بهبود یافته برای تشخیص کشتی CFAR با تصاویر SAR" صورت گرفته است، در این پژوهش با استفاده از تصاویر دریچه مصنوعی رادار اقدام به تعیین موقعیت شناورها شده است و با استفاده از الگوریتم‌های خوشه‌بندی و استفاده از یک حد آستانه به تفکیک آب از خشکی پرداخته شده است و در نهایت با استفاده از یک توزیع آماری و حد آستانه به تعیین موقعیت شناورها پرداخته شده است. در اینجا شناسایی کشتی و تجهیزات دریایی توأم صورت گرفته است؛ در نتیجه شناسایی آن دو دقت خوبی داشته ولی تفکیک‌پذیری کشتی و تجهیزات دریایی به خوبی صورت نگرفته است. به دلیل عدم وجود داده‌های واقعیت زمینی امکان اعتبار سنجی وجود نداشته است. در پیرو مطالعات قبلی، آقای مارینو و همکاران^۲ (۲۰۱۴) در پژوهش خود با ارائه یک روش جدید اقدام به تعیین موقعیت شناورها کردند.

در این مقاله با استفاده از ضریب پراکنش کشتی‌ها و رفتار همدوس آن برای جدا کردن کشتی‌ها از دریا اقدام به تفکیک هرچه بهتر شناورها شده است اما در راستای برطرف کردن ایرادات قبلی عدم تفکیک شناورها از سایر تجهیزات دریایی اقدامی صورت نگرفته است. شایان ذکر است که نتایج قابل قبول به دست آمده در این روش به شدت وابسته به منطقه مورد استفاده است و قابلیت تعمیم ندارد.

تحقیق بهتر و جامع‌تر در همین زمینه توسط آقای ایرولینو و همکاران^۳ (۲۰۱۵) صورت گرفته است. در این پژوهش برای تفکیک شناورها و سایر تجهیزات دریایی اقداماتی صورت گرفته است در این روش ابتدا با استفاده از نقشه رقومی منطقه، تفکیک آب از خشکی صورت گرفته است و پس از آن با استفاده از حد آستانه برای تفکیک آب از

¹ Hu and etal

² Marinoo and etal

³ Iervolino and etal

کشتی‌ها و تجهیزات دریایی و درنهایت با استفاده از روش‌های خوشه‌بندی برای تفکیک کشتی از تجهیزات دریایی اهتمام ورزیده شده است. در بسیاری از مطالعات در ادبیات علم بینایی ماشین اثبات شده است؛ که عملکرد روش‌های بر پایه کرنل‌های عمیق بسیار موفق بوده است. این نوع از روش‌ها به راحتی می‌توانند ویژگی‌های پیچیده را با ترکیب بازنمایی کرنل‌ها و ویژگی آموزش یکسره شبکه‌های عصبی عمیق، استخراج کنند. مطالعات در زمینه کرنل‌های عمیق در دو رویکرد صورت گرفته است؛ رویکرد اول برقراری ارتباط بین روش‌های مبتنی بر آموزش عمیق و روش‌های مبتنی بر کرنل‌ها است و رویکرد دوم برقراری ارتباط بین روش‌های مبتنی بر آموزش عمیق و آموزش کرنل‌های چندگانه به منظور بهبود یکدیگر است. حنفی و لطفی (۱۳۹۵) در پژوهشی به ارائه مدلی جهت گسترش سامانه‌های متحرک موشکی در جنگ‌های آینده در منطقه کرمانشاه پرداختند.

کیخایی و همکاران (۱۴۰۰) در پژوهشی به طراحی سامانه Web-GIS مبتنی بر مسیریابی بهینه بین نقاط مختلف صحنه نبرد به منظور مدیریت و طرح‌ریزی صحیح عملیات‌های نظامی آینده پرداختند. نتایج نشان داده که به کارگیری سامانه مسیریاب Web-GIS، نقش اساسی این سامانه در موقعیت‌یابی در میدان نبرد، دسترسی به نقشه‌های اردوگاه‌ها و ایجاد سامانه جامع آفلاین، مدیریت لجستیک، فرماندهی و کنترل عملیات‌های نظامی آینده نمود پیدا خواهد کرد. کیخایی و همکاران (۱۳۹۹) در پژوهشی به ارائه روشی در زمینه آشکارسازی اهداف در تصاویر ماهواره‌ای با استفاده از یادگیری عمیق و با رویکرد سنجش‌ازدور و GIS پرداختند. در این تحقیق با بهره‌گیری از آموزش شبکه به وسیله داده‌های آموزشی به آشکارسازی کشتی‌های موجود در تصاویر ماهواره‌ای با ایجاد یک شبکه تمام کانولوشنال FCN پرداخته شده است. جهت ارزیابی عملکرد و دقت الگوریتم استفاده شده در یافتن و آشکارسازی کشتی‌های موجود در تصاویر ماهواره‌ای، با اعمال این الگوریتم آشکارساز بر روی چندین تصویر ماهواره‌ای دیگر از معیارهای ارزیابی Precision، Recall و F1-Score استفاده شده است.

روش‌شناسی پژوهش

روش انجام این تحقیق مطالعه موردی بوده و از مستندات به روش کتابخانه‌ای بهره‌گیری شده است. در این پژوهش از تصاویر سنجنده سنتینل-۱ که در باند C و با پلاریزیشن‌های VV و VH تصویربرداری می‌کند، استفاده شده است که مشخصات آن

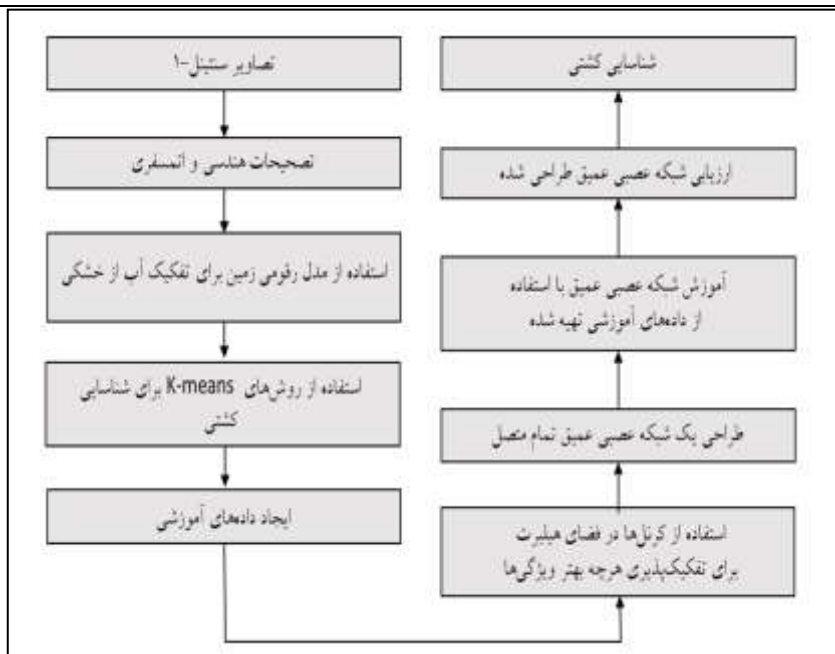
در جدول (۱) آورده شده است. همچنین برای تولید داده‌های میدانی از ۱۰ تصویر سنتینل-۱ در مدارهای ۵۷ و ۱۶۶ در سال ۲۰۲۰ استفاده شده است. به‌منظور تصحیح تصاویر راداری اقدام به حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون و درنهایت حذف اسپیکل‌ها شده است؛ درنهایت با زمین مرجع کردن تصاویر و تبدیل مقادیر باز پراکنش به واحد دسی‌بل، تصاویر قابل‌پردازش حاصل شده است.

جدول (۱) مشخصات سنجنده سنتینل-۱

حالت	طول موج	زاویه فرود	قدرت تفکیک زمانی	قدرت تفکیک قطبش ^۱	قدرت تفکیک مکانی	سنجنده
IW	۵۴۷.۵ سانتی‌متر	۲۰-۴۶ درجه	۱۲ روز	VV- VH	۵ × ۲۰	سنتینل-۱

ابتدا با انجام تصحیحات لازم بر روی تصاویر راداری مقادیر ضریب پراکنش (σ^0) برای دو قطبش VV- VH محاسبه شده است و سپس با استفاده از مدل رقومی زمین سنجنده SRTM اقدام به حذف خشکی و ساحل شده است و درنهایت با استفاده از روش غیر نظارت‌شده K-means اقدام به طبقه‌بندی دو کلاسه برای شناسایی کشتی‌ها و تولید داده‌ی میدانی انجام گرفته است. در مرحله بعد با وارد کردن داده‌های میدانی به فضای هیلبرت توسط کرنل‌ها اقدام به استخراج هرچه بیشتر ویژگی‌های کشتی‌ها شده است و خروجی کرنل‌ها به یک شبکه عصبی عمیق تمام متصل معرفی شده تا با آموزش کرنل‌ها یک MKL برای شناسایی هرچه بهتر و بیشتر کشتی‌ها طراحی شود. فلوچارت این پروژه در شکل (۱) نمایش داده شده است.

^۱ Polarization



شکل (۱) فلوجارت روش پیشنهادی

به‌منظور تولید داده‌های آموزشی توسط خوشه‌بندی K-means، بدین‌صورت عمل می‌شود که ابتدا برای تمامی کلاس‌های داده‌های آموزشی یک مقدار میانگین قطبشی محاسبه می‌شود؛ سپس فواصل قطبشی تک‌تک نمونه‌های آموزشی با این نمونه‌ها به دست می‌آیند. اگر نمونه موردبررسی دارای کمترین فاصله از میانگین کلاس خود باشد آن داده به‌عنوان داده آموزشی صحیح تلقی می‌شود و اگر این کمترین فاصله با میانگین کلاسی غیر از کلاس خود باشد داده آموزشی اشتباه است و از مجموعه داده‌ها حذف می‌گردد. این کار در طی چندین تکرار می‌تواند انجام می‌پذیرد.

منطقه مورد مطالعه

منطقه خلیج فارس در ۲۴ تا ۳۰ درجه و ۳۰ دقیقه عرض شمالی و ۴۸ تا ۵۶ درجه و ۲۵ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار دارد و توسط تنگه هرمز با دریای عمان و اقیانوس هند مرتبط است. خلیج فارس با مساحتی بالغ بر ۲۳۹۰۰۰ کیلومتر مربع و عمق متوسط ۳۵ تا ۴۰ متر حوضه آبی کم‌عمقی محسوب می‌شود. برای تولید داده‌های آموزشی منطقه موردنظر، از بندرهایی مانند بندرعباس، استفاده شده است،

زیرا در این صورت با اطمینان بالایی می‌توان بیان کرد که پراکنش‌های بالای ثبت‌شده در تصویر راداری مربوط به کشتی‌ها است. شکل (۲) موقعیت بندرعباس و کشتی‌های آن منطقه را نشان می‌دهد.




شکل (۲) موقعیت بندرعباس که کشتی‌های منطقه با دایره‌های زرد مشخص شده‌اند

پیاپیاده‌سازی، بحث و یافته‌های پژوهش

برای شناسایی موقعیت شناورها در منطقه خلیج فارس، ابتدا با استفاده از روش غیر نظارت‌شده K-means داده‌های آموزشی تولید گردید و در نهایت با استفاده از کرنل‌ها و آموزش عمیق تمام متصل اقدام به شناسایی کشتی‌ها صورت گرفت. برای تولید داده‌های میدانی اقدام به حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون و در نهایت حذف اسپیکل‌ها شده و به مقادیر بار پراکنش در قطبش‌های VV و VH می‌رسیم که در شکل (۳) قسمت (الف) نتیجه‌ی حاصل‌شده در تصویر سنتینل-۱ در مدار ۵۷ و تاریخ ۲۰۲۰/۴/۲۴ قابل‌رؤیت است. با حذف خطاهای هندسی و زمین مرجع کردن تصاویر، موقعیت اصلی منطقه در هنگام تصویربرداری حاصل می‌شود که نتیجه‌ی آن در تصویر مذکور در شکل (۳) قسمت (ب) نشان داده شده است. در مرحله‌ی بعد با استفاده از مدل رقومی زمین که با استفاده از سنجنده SRTM تهیه‌شده است اقدام به حذف خشکی در تصاویر می‌کنیم (شکل (۳) قسمت (پ) و در نهایت با استفاده از روش نظارت‌نشده K-means اقدام به شناسایی کشتی‌ها می‌کنیم که نتیجه در شکل (۳)

قسمت (ج) مشخص شده است. در روش نظارت نشده K-means حداکثر سی تکرار و دو کلاس در نظر گرفته شده است.



شکل (۳) نحوه تولید داده‌ی میدانی. (الف) حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون و حذف اسپیکل‌ها، (ب) حذف خطاهای هندسی و زمین مرجع کردن تصاویر، (پ) حذف خشکی در تصاویر با استفاده از سنجنده SRTM، (ج) شناسایی کشتی‌ها با استفاده از روش نظارت نشده K-means.

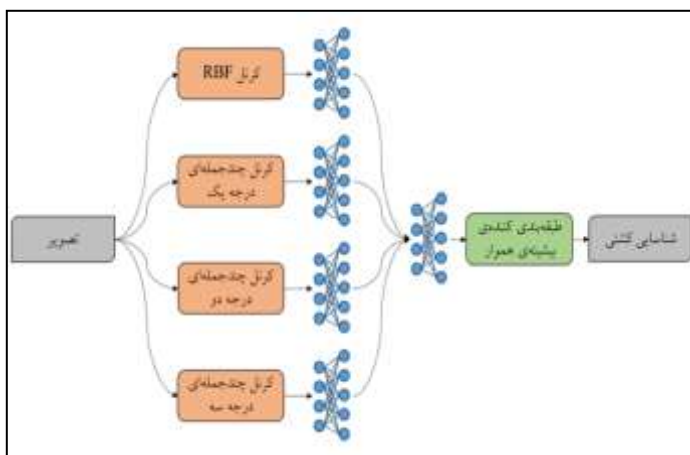
تعداد داده‌های آموزشی به دست آمده برای دو کلاس آب و کشتی در جدول (۲) نشان داده شده است. در اینجا تعداد داده‌های آموزشی برای دو کلاس مذکور مساوی در نظر گرفته شده است.

جدول (۲) تعداد داده‌های آموزشی به دست آمده

کلاس	آب	کشتی
تعداد داده‌های آموزشی	۲۰۰	۱۶۵
تعداد کل داده‌های آموزشی	۳۶۵	

از این تعداد داده، ۳۰ درصد از هر کلاس و در مجموع ۳۰ درصد از کل داده‌ها (۱۱۰) برای آموزش شبکه استفاده شده است. ۷۰ درصد باقیمانده (۲۵۵) برای اعتبارسنجی شبکه مورد استفاده قرار گرفته است. در این مقاله از یک کرنل RBF و سه کرنل

چند جمله‌ای با درجه‌های ۱، ۲ و ۳ استفاده شده است. مقدار γ برای کرنل RBF، ۲ و برای سایر کرنل‌ها ۱ به صورت تجربی، در نظر گرفته شده است. پس از اعمال کرنل‌ها بر داده‌های ورودی، داده‌ها وارد یک شبکه عصبی تمام متصل که متشکل از چهار لایه می‌باشد، شده‌اند؛ که تعداد نورون‌های هر لایه به ترتیب عبارت‌اند از ۲۵۶، ۵۱۲، ۲۵۶ و ۱۲۸ که مطابق با شبکه معرفی شده در پژوهش است. تابع فعال‌سازی برای تمام لایه‌ها ReLU در نظر گرفته شده است. در نهایت با استفاده از لایه آخر که از طبقه‌بندی کننده بیشینه هموار^۱ استفاده نموده و از دو نورون (تعداد کلاس‌ها) تشکیل گردیده، کار طبقه‌بندی انجام شده است.




شکل (۴) فلوچارت شبکه ارائه شده

ابتدا کار طبقه‌بندی به صورت تک-کرنل انجام گرفته است و نتیجه‌ی آن در جدول ۳ آورده شده است. برای ارزیابی شبکه‌ها از پارامتر دقت^۲ استفاده شده است. در ادامه با استفاده از چهار کرنل اشاره شده اقدام به آموزش آن‌ها به صورت MKL توسط شبکه عصبی عمیق، با ویژگی‌های ذکر شده، شده است. شکل (۴) نمایی از شبکه موردنظر را نشان می‌دهد که هر شبکه متشکل از ۴ لایه می‌باشد و تعداد نورون‌های هر لایه به ترتیب عبارت‌اند از ۲۵۶، ۵۱۲، ۲۵۶ و ۱۲۸ که مطابق با شبکه معرفی شده می‌باشد. تابع فعال‌سازی برای تمام لایه‌ها ReLU در نظر گرفته شده است. برای نظارت بر شبکه حین آموزش، دو درصد از داده‌های آموزشی برای ارزشیابی در حین آموزش

¹ Softmax

² Overall Accuracy

استفاده شده است. شکل (۵) نحوه همگرایی داده‌های آموزشی و ارزیابی را در حین آموزش نشان می‌دهد.



شکل (۵) نحوه همگرایی داده‌های آموزشی و ارزیابی در حین آموزش

پس از آموزش شبکه با استفاده از داده‌های آموزشی و ارزیابی شبکه با استفاده از داده‌های آزمون، دقت شبکه حاصل گردیده که نتیجه آن در جدول (۳) قابل مشاهده است.


جدول (۳) دقت به دست آمده با استفاده از شبکه پیشنهادی در حالت‌های مختلف

تک کرنل و چند کرنل

تعداد کرنل	شبکه	دقت
۱	RBF	۷۸.۰۰
۱	چندجمله‌ای با درجه‌ی ۱	۵۸.۰۰
۱	چندجمله‌ای با درجه‌ی ۲	۶۶.۰۰
۱	چندجمله‌ای با درجه‌ی ۳	۷۳.۰۰
۴	پیشنهادی	۸۸.۰۰


پس از آموزش و ارزیابی شبکه توسط داده‌های آموزشی و آزمون اقدام به اعتبارسنجی شبکه صورت گرفته است. به این منظور از دو تصویر سنتینل-۱ در مدار ۵۷ و تاریخ

۲۰۲۰/۶/۱۵ و مدار ۲۸ و تاریخ ۲۰۲۰/۶/۱۳ استفاده شده است. موقعیت تصاویر در شکل (۶) قابل مشاهده است؛ که در آن موقعیت تصویر اول با شماره ۱ (بندرعباس) و موقعیت تصویر دوم با شماره ۲ (بندرلنگه) مشخص شده‌اند.




شکل (۶) موقعیت تصاویر اعتبارسنجی


به دو دلیل از این دو تصویر برای ارزیابی شبکه استفاده شده است: ۱- از دو تصویر مذکور هیچ داده میدانی استخراج نشده است در نتیجه در فرآیند آموزش و آزمون شبکه حضور نداشته‌اند. ۲- تصویر اول دارای تعداد زیادی کشتی است (به دلیل نزدیکی به بندر قشم) و تصویر دوم به دلیل نزدیکی به پالایشگاه پارس جنوبی دارای لکه‌های نفتی است و این دو مورد چالش‌های زیادی را برای ارزیابی شبکه ایجاد می‌کنند. شکل ۷ و شکل ۹ دو تصویر مذکور را بعد از حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون، حذف اسپکل‌ها، حذف خطاهای هندسی، زمین مرجع کردن تصاویر و درنهایت حذف خشکی‌ها نشان می‌دهد. شکل ۸ و شکل ۱۰ نقشه‌های شناورهای شناسایی شده را نشان می‌دهند.



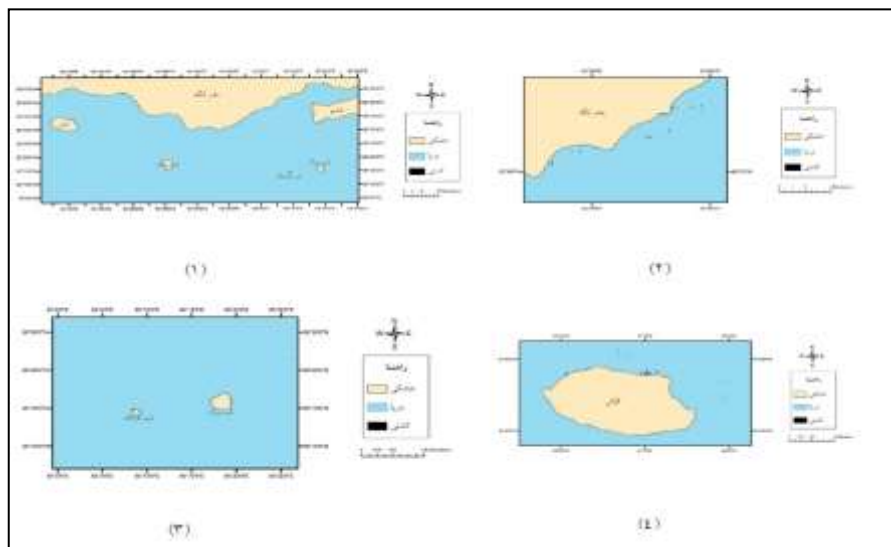
شکل (۷) (۱) حذف خط‌های هندسی و زمین مرجع کردن تصویر از منطقه بندرعباس، (۲) حذف خشکی در تصاویر با استفاده از سنجنده SRTM، (۳) حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون، (۴) حذف اسپکل‌ها.



شکل (۸) تصاویر خروجی اعتبارسنجی شبکه پیشنهادی در تصویر سنتینل-۱ در مدار ۵۷ و تاریخ ۲۰۲۰/۶/۱۵ از منطقه بندرعباس. (۱) نقشه‌ی کلی از منطقه، (۲) نقشه‌ی بندرعباس، (۳) نقشه‌ی جزیره قشم و (۴) نقشه‌ی جزیره هرمز.



شکل (۹) (۱)، (ب) حذف خطاهای هندسی و زمین مرجع کردن تصویر از منطقه بندرلنگه، (پ) حذف خشکی در تصاویر با استفاده از سنجنده SRTM، (۳) حذف نویزهای حرارتی، نویزهای مرزی، کالیبراسیون، (۴) حذف اسپکل‌ها.



شکل (۱۰) تصاویر خروجی اعتبارسنجی شبکه پیشنهادی در تصویر سنتینل-۱ در مدار ۵۷ و تاریخ ۲۰۲۰/۶/۱۵ از منطقه بندرلنگه. (۱) نقشه‌ی کلی از منطقه، (۲) نقشه‌ی بندرلنگه، (۳) نقشه‌ی تنب کوچک و بزرگ و (۴) نقشه‌ی جزیره‌ی کیش.

نتیجه گیری

شناسایی کشتی در دریاها توسط تصاویر راداری بخصوص در منطقه‌های حساس مانند خلیج فارس امری مهم برای حفظ امنیت و مدیریت کشتی‌ها است. الگوریتم‌های شناسایی کشتی در صورتی مفید هستند که در حد امکان سریع و قابل‌تعمیم برای تصاویر در مناطق مختلف باشند. الگوریتم‌های شناسایی کشتی SAR ارائه شده به‌طور عمده بر اساس یک روش نرخ هشدار کاذب ثابت (CFAR) انجام شده است؛ به این صورت که پس‌زمینه دریا توسط یک توزیع مناسب مدل می‌شود و یک حد آستانه برای رسیدن به هشدار کاذب تعریف می‌شود و تمام پیکسل‌هایی که شدتی بیشتر از حد آستانه داشته باشد به‌عنوان کشتی شناسایی می‌شود؛ اما این روش‌ها قادر به شناسایی کشتی‌هایی که مقادیری نزدیک به پس‌زمینه دریا داشته باشند نخواهند بود و همچنین محاسبه یک حد آستانه مناسب نیاز به صرف زمان زیادی خواهد. استخراج رفتارهای همبسته پراکنش کشتی‌ها در مقایسه با پراکنش تصادفی از سطح دریا از سایر روش‌های شناسایی کشتی هستند؛ همچنین روش‌های مبتنی بر خوشه‌بندی برای جداسازی پس‌زمینه‌ی دریا، کشتی و سایر تجهیزات دریایی از دیگر روش‌های نوین برای شناسایی کشتی‌ها هستند.

در روش‌های ذکر شده از روش‌های یادگیری ماشین غیر نظارت شده استفاده شده است که علاوه بر زمان‌بر بودن احتیاج به یافتن یکسری مقادیر ثابت مانند حد آستانه با وارد کردن داده‌های جدید نیاز است؛ این‌گونه از الگوریتم‌ها حساسیت لازم برای تفکیک کشتی‌ها و نویزهای شدید را ندارند به همین دلیل تصاویر با نویز شدید یا در منطقه‌های با لکه‌های نفتی نمی‌توانند به‌خوبی قبل عمل کنند. از طرفی روش‌های نوین یادگیری ماشین مانند شبکه‌های عصبی عمیق که بسیار موفق عمل کرده‌اند و به دقت‌های بالایی در رگرسیون و طبقه‌بندی رسیده‌اند، تعداد بسیار زیادی مؤلفه‌های آموزش پذیر دارند در نتیجه، استفاده از روش‌های یادگیری ماشین عمیق دقت بالاتری خواهند داشت اما به داده آموزشی زیادی احتیاج دارند که تهیه‌ی آن‌ها بسیار زمان‌بر و هزینه‌بر هستند.

در این پژوهش به دلیل عدم وجود داده‌های آموزشی از روش K-means برای استخراج داده‌های میدانی استفاده شده است که نتیجه‌ی آن در شکل (۳) قابل مشاهده است؛ اگرچه این روش هم در شناسایی کشتی‌ها خوب عمل کرده است اما به دلیل آموزش پذیر نبودن آن نمی‌شود به نتایج آن اعتماد کرد بعلاوه آنکه روش مذکور، مانند

سایر روش‌های آموزش ماشین غیر نظارت‌شده، احتیاج به ورود مقادیر اولیه دارد و قدرت تعمیم آن‌ها مانند روش‌های آموزش ماشین نظارت‌شده نیست. با توجه به جدول (۲) تعداد نمونه‌های تهیه بسیار کمتر از مقداری است که برای آموزش یک شبکه عصبی عمیق بخصوص در حالت پیچشی نیاز است؛ در تهیه داده‌های آموزشی سعی بر آن شده است که از نمونه‌های متنوع در شرایط مختلف اعم از شرایط طوفانی، شرایط جوی نامناسب که موجب ایجاد نویز در تصویر می‌شود و حضور لکه‌های نفتی در دریا استفاده شود که این امر موجب شده که شبکه طراحی‌شده با همین تعداد کم به‌دقت ۸۸ درصد (جدول (۳)) برسد؛ که قابل قبول می‌باشد. در واقع استفاده از کرنل‌ها و انتقال داده‌های ورودی به فضای هیلبرت نیاز به داده‌های آموزشی را کمتر کرده است؛ به عبارت دیگر، با توجه به نتایج حاصل شده، ادغام کرنل‌ها به‌منظور تولید و آموزش یک یا چند کرنل با استفاده از شبکه عصبی عمیق و استفاده از آن‌ها به‌منظور تسریع و کاهش نیاز به داده‌های میدانی در شبکه‌های عصبی عمیق در شناسایی شناورها مؤثر واقع گردیده است.

با توجه به شکل (۵) نحوه همگرایی داده‌های آموزشی به‌درستی و به‌خوبی میسر شده است؛ در واقع سیر نزولی نمودار زیان و میل کردن آن به مقدار صفر و همچنین سیر صعودی نمودار دقت و میل کردن آن به مقدار یک نشان از آن دارد که شبکه در هر مرحله از ۳۰۰ مرحله آموزش در حال یادگیری و بهبود است و این نوید از آن دارد که با ورود داده‌های آموزشی بیشتر امکان افزایش دقت شبکه پیشنهادی وجود دارد. از طرف دیگر آموزش کرنل چندگانه توسط شبکه عصبی عمیق منجر به استخراج ویژگی‌های سطح بالای کشتی‌ها در تصاویر راداری شده است که منجر به عملکرد مناسب در تشخیص کشتی‌ها شده است.

با آموزش این شبکه این امکان میسر می‌شود که به‌صورت هر لحظه یا حداقل با سرعتی بیشتر از سایر روش‌های شناسایی کشتی پیشنهادشده، کشتی‌ها را شناسایی کرد؛ زیرا پس از آموزش شبکه، مرحله استفاده از شبکه امری سهل و سریع هست. نتایج حاصل شده به همراه اعتبارسنجی آن در دو منطقه دیگر به‌خوبی دقت روش ارائه شده به منظور شناسایی شناورهای سطحی را نشان می‌دهد. با توجه به این مهم که اهمیت شناخت شناورهای کوچک و بزرگ به منظور مدیریت صحیح ترانزیت کالا از نظر اقتصادی و همچنین امنیتی حائز اهمیت است لذا در این پژوهش به استفاده از تصاویر

راداری و به کارگیری الگوریتم‌های مناسب (نظیر شبکه عصبی عمیق) به صورت هم‌زمان جهت این موضوع پرداخته شد که می‌تواند به شناسایی کشتی‌ها و شناورهای مختلف با دقت بالا کمک شایانی نماید. این مهم باعث ارتقاء امنیت دریایی و کمک به نظم بیشتر در عبور و مرور و کنترل ساده‌تر و جلوگیری از خرابکاری‌های احتمالی و تروریستی نیز خواهد انجامید. در ادامه برای پژوهش‌های بعدی پیشنهاد می‌شود که بجای شبکه‌های تمام متصل از شبکه‌های پیش‌تک-بعدی به منظور استخراج هرچه بیشتر ویژگی‌های سطح بالاتر از تصاویر راداری استفاده شود. همچنین می‌توان با تقریب کرنل‌ها با استفاده از روش‌های بر پایه سری فوریه، اقدام به افزایش سرعت شبکه کرد.

تقدیر

از کلیه اساتید، دانشجویان و متخصصان که در انجام این پژوهش، با محقق همکاری لازم را داشته‌اند کمال تشکر را می‌نماییم.

منابع

- امیری، کامبیز. (۱۳۹۰). نقش نیروی انسانی سامانه کنترل تردد شناورها (VTS) در ارتقاء امنیت دریانوردی، فصلنامه علوم و فنون نظامی، شماره ۲۱، ص ص ۹۹-۱۲۰.
- حنفی، علی؛ لطفی، احمد. (۱۳۹۵). ارائه مدل گسترش سامانه‌های متحرک موشکی در جنگ‌های آینده با استفاده از نظریه بازی و GIS مطالعه موردی: منطقه کرمانشاه. *آینده پژوهی دفاعی*. ۱ (۲)، ۶۷-۹۲.
- کیخایی، مهدی، رفیع زاده ملک‌شاه، ارسلان، بیرانوند، نادر. (۱۴۰۰). طراحی سامانه-Web GIS مبتنی بر مسیریابی بهینه بین نقاط مختلف صحنه نبرد به منظور مدیریت و طرح‌ریزی صحیح عملیات‌های نظامی آینده. *آینده پژوهی دفاعی*، ۶ (۲۲)، ۶۹-۹۴. doi: 10. 22034/dfs. 2021. 532116. 1503 .
- کیخایی، مهدی. بیرانوند، نادر و ممانی، رویین (۱۳۹۹). ارائه روشی در زمینه آشکارسازی اهداف در تصاویر ماهواره‌ای با استفاده از یادگیری عمیق و با رویکرد سنجش‌ازدور و GIS، فصلنامه جغرافیایی سرزمین، سال هجدهم، شماره ۶۹، بهار ۱۴۰۰.
- سلیمانی، آرزو. عسگری، محمد. دادالهی، سهراب. علمی زاده، علی. خزاعی، هیوا. (۱۳۹۵). بررسی تأثیر ریزگردها بر تولید اولیه در خلیج فارس با استفاده از داده‌های سنجش‌ازدور، *نشریه محیط‌زیست طبیعی*.. 69(3) 715-728

نقوی، احد، مختازاده، ناصر، مقدس، مسعود. (۱۴۰۱). الگوی فرماندهی و کنترل یکپارچه هوشمند با رویکرد تحلیل داده حسگری. *دوفصلنامه بازی جنگ*, 5(11), 107-123.

doi: 10.22034/ijwg.2023.171248

- An, W. , Xie, C. , & yuan, X. (2013). An improved iterative censoring scheme for CFAR ship detection with SAR imagery. *IEEE transactions on geoscience and remote sensing*, 52(8), 4585-4595
- A. Marino, M. J. Sanjuan-Ferrer, I. Hajnsek, and K. Ouchi, "Ship detectors exploiting spectral analysis of SAR images," in 2014 IEEE Geoscience and Remote Sensing Symposium, 2014: IEEE, pp. 978-981.
- Bengio, Y. , (2009). Learning deep architectures for ai, *Foundations and trends in Machine Learning*.
- Bruschi, S. , Lehner, S. , Fritz, T. , Soccorsi, M. , Soloviev, A. , & van Schie, B. (2010). Ship surveillance with TerraSAR-X. *IEEE transactions on geoscience and remote sensing*, 49(3), 1092-1103.
- Crisp, D. J. (2004). The state-of-the-art in ship detection in synthetic aperture radar imagery. Retrieved from.
- Emery, K. O. (1956). Sediments and water of Persian Gulf. *AAPG Bulletin*, 40(10), 2354-2383.
- F. Hu, G. -S. Xia, J. Hu, L. Zhang, Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery, *Remote Sensing*, 7(11) (2015) 1468014707.
- G. Camps-Valls, L. Gomez-Chova, J. Muñoz-Marí, J. Vila-Francés, and J. Calpe-Maravilla, "Composite kernels for hyperspectral image classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 3, pp. 93-97, 2006.
- Guida, and P. Whittaker, "A novel ship-detection technique for. P. Iervolino, R Sentinel-1 SAR data," in 2015 IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR), 2015: IEEE, pp. 797-801.
- Gönen, M. , Alpaydın, E. , (2011). Multiple kernel learning algorithms. *Journal of Machine Learning Research*, 12(3), 2211-2268, 2011.
- G. Camps-Valls, L. Gómez-Chova, J. Muñoz-Marí, J. L. Rojo-Álvarez, and M. Martínez-Ramón, "Kernel-based framework for multitemporal and multisource remote sensing data classification and change detection," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, pp. 1822-1835, 2008.
- Iervolino, P. , Guida, R. , & Whittaker, P. (2015). A novel ship-detection technique for Sentinel-1 SAR data. Paper presented at the 2015 IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR).

- L. A. Belanche Muñoz and M. Ruiz Costa-Jussà, "Bridging deep and kernel Artificial Neural methods," in Proceedings of the 25th European Symposium on Networks, Bruges, Belgium, 2017, pp. 1-10.
- Mather, P. , & Tso, B. (2016). Classification methods for remotely sensed data. *Journal of Machine Learning Research*, 12(3), 2211-2268, 2011.
- Niyazmardi, S. , Homayouni, S. , Safari, A. , Shang, J. , Heather, M. , (2017). Multiple kernel representation and classification of multivariate satellite-image time-series for crop mapping. *International Journal of Remote Sensing*, 39(3), 1092-1103. <https://doi.org/10.1080/01431161.2017.1381351>.
- <https://sentinels.copernicus.eu/>
- Song, H. , Thiagarajan, J. J. , Sattigeri, P. , & Spanias, A. (2018). Optimizing kernel machines using deep learning. *IEEE transactions on neural networks and learning systems*, 29(11), 5528-5540.
- Souyris, J. -C. , Henry, C. , & Adragna, F. (2003). On the use of complex SAR image spectral analysis for target detection: Assessment of polarimetry. *IEEE transactions on geoscience and remote sensing*, 41(12), 2725-2734.
- T. Wang, L. Zhang, and W. Hu, "Bridging deep and multiple kernel learning: A review," *Information Fusion*, 2020.
- Y. Gu, C. Wang, D. You, Y. Zhang, S. Wang, and Y. Zhang, "Representative multiple kernel learning for classification in hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, pp. 2852-2865, 2012.
- Zhang, J. and Marszalek, M. and Lazebnik, S. and Schmid, C (2007). Local features and kernels for classification of texture and object categories. A comprehensive study *International Journal of Computer Vision*, 29(11), 5528-5540.