



Spatio-temporal Deep Learning for Maritime Routes: A Unified Model for Behavior-Aware Vessel Prediction

Yousef Esmaeili¹, Hamid Motieyan^{2*}, Reza Dezvareh³

¹ Master's Student in Geospatial Information Science, Faculty of Civil Engineering, Babol Noshirvani University of Technology, Babol, Iran; yousefes@stu.nit.ac.ir

² Assistant Professor, Department of Geomatics Engineering, Faculty of Civil Engineering, Babol Noshirvani University of Technology, Babol, Iran; h.motieyan@nit.ac.ir

³ Associate Professor, Department of Structural and Earthquake Engineering, Faculty of Civil Engineering, Babol Noshirvani University of Technology, Babol, Iran; rdezvareh@nit.ac.ir

ARTICLE INFO

Article History:

Received: 12 May 2025

Last modification: 17 Jun 2025

Accepted: 9 Jul 2025

Available online: 9 Jul 2025

Article type:

Research paper

Keywords:

Vessel trajectory prediction

Attention mechanism

LSTM-Attention model

Spatio-temporal modeling

Maritime navigation

ABSTRACT

Accurate vessel trajectory prediction is a critical requirement for enhancing maritime safety, reducing collision risk, optimizing fuel consumption, and enabling intelligent traffic management at sea. In this study, a comprehensive and data-driven framework is proposed for vessel trajectory prediction, developed using real Automatic Identification System (AIS) data and relevant environmental information such as significant wave height. The dataset includes movement trajectories of cargo vessels, fishing vessels, and passenger vessels within the Gulf of Mexico. A rich and structured dataset was constructed by extracting derived features such as turn rate, acceleration, and geographic coordinates. To model the trajectories, a hybrid architecture based on Long Short-Term Memory (LSTM) networks and an attention mechanism was implemented, enabling the model to effectively learn long-term temporal dependencies and adaptively focus on critical segments of vessel routes. In addition, SHapley Additive exPlanations (SHAP) were used to enhance the interpretability of the model and analyze the contribution of each feature to the prediction process. The feature analysis revealed that latitude, longitude, acceleration, and wave height played the most significant roles in improving predictive accuracy. Experimental evaluation using a held-out test dataset and comparison with a baseline LSTM model demonstrated that the proposed framework reduced the Average Displacement Error (ADE) by approximately 44% and the Final Displacement Error (FDE) by about 39%. These results confirm the effectiveness of combining spatiotemporal deep learning with interpretable feature analysis for precise vessel trajectory forecasting. The proposed framework offers a reliable foundation for developing navigation support systems, autonomous ship routing, smart port management, and maritime traffic forecasting. Furthermore, it can be extended to various types of vessels and other maritime regions.

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/>]



یادگیری عمیق مکانی-زمانی برای مسیرهای دریایی: مدلی یکپارچه برای پیش‌بینی مبتنی بر رفتار کشتی‌ها

یوسف اسماعیلی^۱ ID، حمید مطیعان^۲ ID*، رضا دزواره رسانی^۳ ID

^۱ دانشجوی کارشناسی ارشد سیستم اطلاعات مکانی، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، yousefes@stu.nit.ac.ir

^۲ استادیار گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، h.motieyan@nit.ac.ir

^۳ دانشیار گروه مهندسی سازه و زلزله، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، rdezvareh@nit.ac.ir

چکیده

در حوزه‌ی ناوبری دریایی، پیش‌بینی دقیق مسیر کشتی‌ها یکی از الزامات حیاتی برای ارتقاء ایمنی دریانوردی، کاهش تصادفات، بهینه‌سازی مصرف سوخت و مدیریت هوشمند ترافیک دریایی است. در این پژوهش، یک چارچوب جامع و داده‌محور برای پیش‌بینی مسیر کشتی‌ها ارائه شده است که با بهره‌گیری از داده‌های واقعی سامانه‌ی شناسایی خودکار و داده‌های محیطی نظیر ارتفاع موج توسعه یافته است. داده‌های استفاده‌شده شامل مسیرهای حرکتی کشتی‌های حمل کانتینر، ماهیگیری و مسافربری در منطقه‌ی خلیج مکزیک بوده و با استخراج ویژگی‌های مشتق‌شده نظیر نرخ چرخش، شتاب، و مختصات جغرافیایی، یک مجموعه‌داده‌ی غنی و ساختاریافته تولید گردیده است. رای مدل‌سازی مسیر، از یک معماری ترکیبی مبتنی بر شبکه‌ی عصبی بازگشتی LSTM و مکانیزم توجه استفاده شده که توانایی بالایی در درک وابستگی‌های زمانی طولانی‌مدت و تمرکز تطبیقی بر نقاط کلیدی مسیر دارد. همچنین، به‌منظور افزایش تفسیرپذیری مدل و تحلیل سهم هر ویژگی در تصمیم‌گیری، از روش SHAP بهره گرفته شده است. نتایج حاصل از تحلیل ویژگی‌ها نشان داد که متغیرهای عرض و طول جغرافیایی، شتاب و ارتفاع موج موثرترین نقش را در دقت پیش‌بینی دارند. ارزیابی تجربی مدل با استفاده از داده‌های آزمون و مقایسه با مدل پایه نشان داد که چارچوب پیشنهادی موفق شده است میزان خطای میانگین جابه‌جایی را تا حدود ۴۴٪ و خطای نهایی مسیر را تا حدود ۳۹٪ کاهش دهد. این دستاورد، مؤید اثربخشی ترکیب یادگیری عمیق مکانی-زمانی با تحلیل تفسیرپذیر ویژگی‌ها در پیش‌بینی دقیق مسیر کشتی‌ها است. این چارچوب می‌تواند به‌عنوان زیرساختی قابل اتکا برای توسعه‌ی سامانه‌های کمک‌ناوبری، هدایت کشتی‌های خودران، مدیریت ورود و خروج بنادر هوشمند و نیز پیش‌بینی ترافیک دریایی مورد استفاده قرار گیرد. همچنین، قابلیت تعمیم آن به دیگر انواع شناورها و مناطق دریایی مختلف وجود دارد.

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۰۲/۲۲

تاریخ اصلاح مقاله: ۱۴۰۴/۰۳/۲۷

تاریخ پذیرش مقاله: ۱۴۰۴/۰۴/۱۸

تاریخ انتشار مقاله: ۱۴۰۴/۰۴/۱۸

نوع مقاله:

مقاله پژوهشی

کلمات کلیدی:

پیش‌بینی مسیر کشتی

مکانیزم توجه

مدل LSTM-Attention

مدلسازی مکانی-زمانی

ناوبری دریایی

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

حرکت به عنوان یکی از مؤلفه‌های اساسی در فرآیندهای مکانی-زمانی^۱، نقش مهمی در تحلیل پدیده‌های پویا ایفا می‌کند. درک صحیح از ویژگی‌ها و الگوهای حرکتی در حوزه‌های مختلفی از جمله علوم رفتاری، برنامه‌ریزی حمل‌ونقل، و هواشناسی از اهمیت ویژه‌ای برخوردار است [۱]. با پیشرفت فناوری‌های موقعیت‌یابی مانند سامانه موقعیت‌یاب جهانی^۲، امکان ردیابی دقیق اشیای متحرک فراهم شده و در نتیجه، حجم عظیمی از داده‌های حرکتی در سال‌های اخیر تولید شده است [۲]. اشیاء متحرک در طول زمان اثری از موقعیت خود به جا می‌گذارند که به آن خطوط سیر^۳ می‌گویند. این داده‌ها با هدف تحلیل الگوها، ارزیابی شباهت‌ها، و پیش‌بینی^۴ مسیرهای آینده مورد استفاده قرار می‌گیرند. یکی از مهم‌ترین کاربردهای این داده‌ها، پیش‌بینی موقعیت^۵ یا مسیر حرکت اشیاء^۶ در بازه‌های زمانی آینده است [۳]. حمل‌ونقل دریایی یکی از ارکان اصلی اقتصاد جهانی به‌شمار می‌رود؛ به‌طوری‌که نزدیک به ۹۰ درصد از حجم و ۷۰ درصد از ارزش تجارت جهانی از طریق دریا انجام می‌شود. این روش، در عین کارایی بالا در مصرف انرژی، نقش حیاتی در زنجیره تأمین جهانی ایفا می‌کند [۴]. با این حال، آمارها نشان می‌دهند که درصد بالایی از تصادفات دریایی ناشی از خطاهای انسانی، به‌ویژه ضعف در آگاهی موقعیتی است. بخشی از این خطاها نیز مربوط به ناتوانی در پیش‌بینی اقدامات آتی در محیط دریایی می‌باشد [۵].

یادگیری عمیق به یکی از شاخه‌های پراهمیت تحقیقاتی در سال‌های اخیر تبدیل شده و نتایج چشمگیری در تحلیل داده‌های سری زمانی به‌دست آورده است. در حوزه پیش‌بینی مسیر کشتی‌ها، که نوعی تحلیل سری زمانی محسوب می‌شود، مدل‌های مبتنی بر یادگیری عمیق توجه زیادی را به خود جلب کرده‌اند. این مدل‌ها، به‌ویژه در شرایط داده‌های پیچیده و غیرخطی، عملکرد بهتری نسبت به روش‌های کلاسیک و الگوریتم‌های متداول یادگیری ماشین از خود نشان داده‌اند [۶]. شبکه‌های LSTM^۷ [۷] نوعی از شبکه‌های عصبی بازگشتی^۸ عمیق هستند که برای پردازش و مدل‌سازی داده‌های ترتیبی^۹ و سری‌های زمانی^{۱۰} طراحی شده‌اند. این شبکه‌ها با استفاده از ساختار سلول حافظه و

دروازه‌های^{۱۱} ورودی، خروجی و فراموشی، قادر به نگهداری و به‌روزرسانی اطلاعات مهم در طول توالی زمانی هستند. از سوی دیگر، مکانیزم توجه^{۱۲} [۸] روشی برای تخصیص وزن بیشتر به بخش‌های مهم‌تر ورودی است. این مکانیزم به مدل کمک می‌کند تا به‌جای بررسی یکنواخت کل دنباله، تمرکز بیشتری بر قسمت‌هایی از داده داشته باشد که برای تولید خروجی مرتبط‌تر اهمیت دارند. هدف این پژوهش طراحی و پیاده‌سازی یک مدل پیش‌بینی مسیر کشتی مبتنی بر شبکه عصبی LSTM همراه با مکانیزم توجه است. در این مدل، از ساختار LSTM برای استخراج وابستگی‌های زمانی در داده‌های حرکتی استفاده شده و مکانیزم توجه به منظور تمرکز پویا بر نقاط کلیدی دنباله به آن افزوده شده است. علاوه بر ویژگی‌های استاندارد موجود در داده‌های AIS^{۱۳}، ویژگی‌های مشتق‌شده‌ای همچون نرخ چرخش^{۱۴}، شتاب^{۱۵} و داده محیطی نظیر ارتفاع موج نیز در فرآیند یادگیری مدل لحاظ شده‌اند. هدف از ترکیب این ویژگی‌ها، بهبود گزینش اطلاعات و افزایش دقت مدل در شرایط پیچیده و واقعی دریایی است.

۲ - مروری بر تحقیقات گذشته

برگر و همکاران (۲۰۲۲)، یک مدل بر پایه رگرسیون خطی^{۱۶} ارائه کرده و آن را با روش جستجوی همسایه تک نقطه‌ای^{۱۷} مقایسه کردند [۸]. رانگ و همکاران (۲۰۱۹)، مدلی مبتنی بر فرآیند گاوسی^{۱۸} برای پیش‌بینی مسیر کشتی با در نظر گرفتن عدم قطعیت در موقعیت‌های آینده کشتی ارائه دادند [۱۰]. تانگ و همکاران (۲۰۱۹)، مدل LSTM برای پیش‌بینی مسیر کشتی‌ها در یک بندر بر اساس داده‌های AIS پیشنهاد دادند [۱۱]. سو و همکاران (۲۰۲۰)، یک الگوریتم پیش‌پردازش داده به نام SSPD^{۱۹} را برای بهبود کیفیت داده‌ها و یک شبکه عصبی GRU برای پیش‌بینی مسیر کشتی استفاده کردند [۱۲]. علیزاده و همکاران (۲۰۲۱)، مدل‌های مختلف مبتنی بر شباهت برای پیش‌بینی مسیر کشتی در مدت زمان‌های مختلف پیشنهاد کردند [۱۳]. موراوی و همکاران (۲۰۲۱)، یک چارچوب یادگیری ماشین برای پیش‌بینی مسیر کشتی با استفاده از داده‌های تاریخی AIS و خوشه‌بندی رفتار کشتی‌ها پیشنهاد کردند [۱۴]. برگر و همکاران (۲۰۲۲)، مدل

11 Gates

12 Attention

13 Automatic Identification System

14 Turn rate

15 Acceleration

16 Linear Regression

17 Single Point Neighbor Search (SPNS)

18 Gaussian Process

19 Symmetrized Segment-Path Distance

1 Spatio-temporal

2 Global Positioning System (GPS)

3 Trajectory

4 Prediction

5 Location Prediction

6 Route Prediction

7 Long short-term memory

8 Recurrent neural network


9 Sequence data

10 Time series

ترکیبی رگرسیون خطی و جستجوی همسایه تک نقطه‌ای^۱ برای پیش‌بینی مسیر کشتی‌ها را ارائه دادند [۱۵]. سان و همکاران (۲۰۲۲)، مدل ترکیبی از LSTM و رگرسیون گاوسی برای پیش‌بینی دقیق مسیر کشتی در کوتاه‌مدت ارائه دادند [۱۶]. ژائو و همکاران (۲۰۲۴)، با استفاده از ترکیب شبکه‌های MLP^۲ و GRU^۳ مدلی ارائه کردند، که توانستند دقت پیش‌بینی را نسبت به بهترین مدل پایه تا ۵۵/۴٪ افزایش دهند [۱۷]. لی و همکاران (۲۰۲۴)، یک مدل جدید مبتنی بر شبکه LSTM و شبکه توجه گرافی^۴ را پیشنهاد کردند و نام آن را GAT-LSTM نامیدند. این مدل توانست دقت پیش‌بینی را تا ۴۴/۵۲٪ نسبت به بهترین مدل پایه افزایش دهد [۱۸]. مهری و همکاران (۲۰۲۳)، یک مدل CLSTM^۵ برای پیش‌بینی مسیر کشتی با استفاده از عوامل محیطی و داده‌های زمینه‌ای ارائه دادند [۱۹].

این پژوهش‌ها نشان‌دهنده روند توسعه مدل‌های پیچیده و دقیق‌تر برای پیش‌بینی مسیر کشتی‌ها هستند که در زمینه‌های مختلف کاربردهای مختلفی دارند و به ویژه در صنایع دریایی و حمل‌ونقل کمک شایانی می‌کنند. این مجموعه از مطالعات، به‌ویژه در زمینه استفاده از داده‌های AIS و مدل‌های یادگیری عمیق برای پیش‌بینی مسیر کشتی‌ها، به بهبود ایمنی و کارایی ناوبری کمک می‌کند و نشان‌دهنده پیشرفت‌های قابل توجه در این حوزه است.

۳ - چارچوب پیشنهادی، منطقه مورد مطالعه و داده




شکل ۱ - چارچوب پیشنهادی

در این پژوهش، چارچوبی جامع (شکل ۱) برای پیش‌بینی و بهینه‌سازی مسیر حرکت کشتی‌ها با بهره‌گیری از مدل LSTM همراه با مکانیزم توجه ارائه شده است. ابتدا داده‌های خام در دو

دسته‌ی داده‌های محیطی (ارتفاع موج) و داده‌های حرکتی کشتی‌ها جمع‌آوری می‌شوند. داده‌های محیطی پس از استخراج ویژگی‌های مؤثر، آماده‌سازی شده و هم‌زمان، داده‌های حرکتی کشتی‌ها با انجام محدودسازی داده‌های مکانی و ارزیابی کیفیت، پالایش می‌گردند. در ادامه، مسیر سفر کشتی‌ها بازسازی شده و داده‌های پرت یا تکراری حذف می‌شوند. این دو دسته داده پس از پردازش، ادغام شده و مجموعه‌داده نهایی جهت آموزش مدل آماده می‌گردد. مدل پیشنهادی با بهره‌گیری از این داده‌ها آموزش می‌بینند. در این فرآیند، تابع هزینه‌ای طراحی شده که با محاسبه مقدار هزینه مسیر، امکان بهینه‌سازی مدل را فراهم می‌سازد. روند آموزش و بهینه‌سازی تا زمانی ادامه می‌یابد که مقدار هزینه به حالت پایدار برسد. پس از آن، مدل نهایی ذخیره شده و بر روی داده‌های آزمون با استفاده از معیارهای ارزیابی، مورد سنجش قرار می‌گیرد. به‌منظور تحلیل میزان اهمیت هر ویژگی در تصمیم‌گیری مدل، از روش SHAP^۶ استفاده شده است. در نهایت، خروجی مدل شامل موقعیت نهایی کشتی (به‌صورت مختصات جغرافیایی) و میزان تأثیر ویژگی‌ها استخراج شده می‌باشد. از مدل آموزش دیده و ذخیره شده می‌توان در یک بستر وب جهت استفاده عملیاتی استفاده کرد.

۳-۱ منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، خلیج مکزیک^۷ است که به عنوان یکی از پرترددترین مناطق کشتیرانی در نیمکره غربی شناخته می‌شود. این منطقه به دلیل فعالیت‌های گسترده تجاری، ماهیگیری و گردشگری، مکان مناسبی برای تحلیل داده‌های مکانی-زمانی کشتی‌ها محسوب می‌شود. یکی از عوامل مؤثر در انتخاب خلیج مکزیک به عنوان منطقه مورد مطالعه، دسترسی آزاد و مناسب به داده‌های AIS مربوط به این منطقه بوده است. نقشه‌ی مسیرهای حرکتی کشتی‌ها در این منطقه، در شکل ۲ نمایش داده شده است. در این نقشه، مسیر سه نوع کشتی شامل کشتی‌های حمل کانتینر، کشتی‌های ماهیگیری، و کشتی‌های مسافری در طول ماه ژانویه ۲۰۲۴ به تصویر کشیده شده‌اند.



شکل ۲ - مسیر حرکتی سه نوع کشتی شامل کشتی‌های کانتینر، ماهیگیری و مسافری در خلیج مکزیک

¹ Single Point Neighbor Search (SPNS)

² Multi Linear Perceptron

³ Gated Recurrent Unit

⁴ Graph-Attention Network (GAT)

⁵ Context-aware LSTM

⁶ SHapley Additive exPlanations

⁷ Gulf of Mexico

۲-۳ داده کشتی

$$\sigma.4 = SWH \quad (۳)$$

در این فرمول، σ انحراف معیار سطح دریا نسبت به میانگین سطح آب است (بر اساس تحلیل طیفی). مقدار SWH در واحد متر بیان می‌شود.

داده‌های موج در قالب یک شبکه با رزولوشن مکانی 0.25×0.25 درجه و با بازه زمانی ساعتی فراهم شده‌اند. برای هم‌راستا شدن داده‌های محیطی با داده‌های حرکتی کشتی‌ها، برای هر موقعیت مکانی و زمانی از کشتی‌ها، مقدار موج از طریق درون‌یابی زمانی و مکانی دوسویه^{۱۰} استخراج شد. در جدول ۱ مشخصات کامل این داده ارائه شده است.

جدول ۱ - مشخصات داده محیطی استفاده شده برای استخراج ارتفاع موج

پارامتر	منبع داده	نام محصول	دقت مکانی	دقت زمانی	دوره	واحد
ارتفاع موج	ECMWF	ERA5	0.25×0.25	ساعتی	تا ۱۹۴۰	متر
					کنون	

در این مطالعه تنها از مقادیر موج در محدوده‌ی زمانی ژانویه ۲۰۲۴ و در محدوده‌ی جغرافیایی خلیج مکزیک استفاده شده است.

۴-۳ پیش‌پردازش داده

داده‌های AIS و لایه‌ی محیطی پس از جمع‌آوری، تحت یک فرآیند پیش‌پردازش چندمرحله‌ای قرار گرفتند تا از دقت مکانی، یکنواختی زمانی، و آمادگی برای ورود به مدل پیش‌بینی اطمینان حاصل شود.

محدودسازی داده‌های مکانی^{۱۱} و فیلتر کیفیت داده‌ها، داده‌های اولیه AIS مناطق خلیج مکزیک، برمودا و خلیج کالیفرنیا را پوشش می‌دادند. این داده‌ها به کمک مرز چندضلعی منطقه‌ی مورد مطالعه در خلیج مکزیک برش داده شدند تا فقط داده‌های مربوط به ناحیه مورد نظر باقی بماند. سپس برای حذف داده‌های نامعتبر، فقط رکوردی‌هایی با کد MMSI^{۱۲} نه‌رقمی نگه داشته شدند و داده‌هایی با سرعت کمتر از ۱ گره^{۱۳} حذف شدند تا کشتی‌های ساکن یا سرگردان کنار گذاشته شوند.

ساخت مسیر کشتی‌ها و کاهش نمونه‌برداری پرتکرار، ابتدا داده‌ها براساس نوع کشتی (حمل کانتینر، ماهیگیری و مسافربری) گروه‌بندی و سپس براساس شناسه MMSI و زمان دریافت

برای تحلیل رفتار حرکتی کشتی‌ها، داده‌های سیستم شناسایی خودکار کشتی‌ها از وب‌سایت MarineCadastre^۱ استخراج شد. این داده‌ها شامل اطلاعاتی همچون عرض جغرافیایی^۲، طول جغرافیایی^۳، نوع کشتی^۴، سرعت روی آب^۵، جهت حرکت^۶ و زمان ثبت موقعیت هستند. از این داده‌های خام، چندین ویژگی ثانویه استخراج شد که در ادامه معرفی می‌شوند.

نرخ چرخش، این ویژگی میزان تغییر در زاویه‌ی حرکت کشتی را بین دو زمان متوالی محاسبه می‌کند و طبق معادله (۱) تعریف می‌شود.

$$COG_{t-1} - COG_t = COG \text{ Change} \quad (۱)$$

در این معادله، COG_t زاویه‌ی حرکت کشتی در زمان t و COG_{t-1} زاویه ثبت شده در زمان قبلی است. این شاخص در تحلیل رفتار چرخشی کشتی‌ها اهمیت دارد و می‌تواند الگوهای تغییر ناگهانی را آشکار کند.

شتاب، برای بررسی تغییرات سرعت در طول زمان استفاده شد. این ویژگی در معادله (۲) تعریف شده است.

$$\frac{SOG_t - SOG_{t-\Delta t}}{\Delta t} = Acceleration_t \quad (۲)$$

در این معادله، SOG_t سرعت کشتی در زمان t و Δt فاصله زمانی بین دو ثبت موقعیت متوالی (بر حسب ثانیه) است. این پارامتر به درک رفتار دینامیکی کشتی در شرایط مختلف کمک می‌کند.

۳-۳ داده موج

برای بررسی تأثیر شرایط محیطی بر رفتار حرکتی کشتی‌ها، از داده‌ی ارتفاع موج استفاده شد. این داده‌ها از محصول ERA5 متعلق به مرکز پیش‌بینی‌های میان‌مدت اروپایی^۷ استخراج شده‌اند و از طریق پایگاه Store Copernicus Climate Data^۸ در دسترس هستند.

ارتفاع موج مشخصه^۹، به صورت میانگین ارتفاع یک‌سوم بلندترین امواج در یک بازه‌ی زمانی خاص تعریف می‌شود. این پارامتر نمایانگر قدرت کلی دریا است و به عنوان معیاری کلیدی در مطالعات دریایی و ایمنی ناوبری استفاده می‌شود. معادله (۳)

¹ <https://marinecadastre.gov/>

² Latitude

³ Longitude

⁴ Vessel type

⁵ Speed Over Ground (SOG)

⁶ Course Over Ground (COG)

⁷ ECMWF

⁸ <https://doi.org/10.24381/cds.adbb2d47>

⁹ Significant Wave Height (SWH)

¹⁰ Bilinear interpolation

¹¹ Spatial clipping


¹² Maritime Mobile Service Identity

¹³ Knot

بلند ممکن است دچار مشکل محو گرادیان^۲ شود. پدیده‌ی محو گرادیان زمانی رخ می‌دهد که طی فرایند آموزش، مقدار گرادیان در لایه‌های ابتدایی بسیار کوچک شود و عملاً به‌روز رسانی وزن‌ها متوقف گردد، در نتیجه، مدل در یادگیری ارتباطات زمانی طولانی‌مدت با چالش مواجه می‌شود. برای غلبه بر این محدودیت، مکانیزم توجه به مدل افزوده شده تا با تمرکز تطبیقی بر نقاط مهم در دنباله، اطلاعات مؤثر را تقویت کرده و نقش آن‌ها را در پیش‌بینی گام‌های آینده پررنگ‌تر کند. این ترکیب به مدل اجازه می‌دهد تا ضمن حفظ ویژگی‌های حافظه‌دار LSTM، بر اجزای کلیدی مسیر تمرکز کرده و دقت پیش‌بینی را در سناریوهای پیچیده افزایش دهد.

۴-۱ مدل LSTM

شبکه‌ی LSTM (شکل ۳) نوعی از شبکه‌های عصبی بازگشتی عمیق می‌باشد که برای یادگیری وابستگی‌های بلندمدت در داده‌های دنباله‌ای طراحی شده است. تفاوت اصلی آن با شبکه‌های عصبی بازگشتی ساده در استفاده از حافظه سلولی و دروازه‌های کنترلی است که امکان فراموشی و افزودن اطلاعات را فراهم می‌کند. این ساختار باعث می‌شود اطلاعات مهم در طول زمان حفظ شوند و اطلاعات غیرضروری حذف شوند.



شکل ۳ - معماری مدل LSTM

ساختار اصلی LSTM شامل چهار مؤلفه است، دروازه فراموشی^۳، دروازه ورودی^۴، دروازه^۵ و دروازه خروجی^۶. در ادامه نحوه عملکرد این اجزا بررسی می‌شوند. دروازه فراموشی، در این بخش تصمیم‌گیری می‌شود که چه بخشی از حافظه قبلی باید فراموش شود. ورودی فعلی x_t و خروجی مرحله قبلی h_{t-1} پس از عبور از لایه‌های تماماً متصل^۷، با یکدیگر جمع می‌شوند و سپس از تابع سیگموید^۸ عبور می‌کنند.

اطلاعات، مرتب‌سازی شدند تا مسیرهای زمانی هر کشتی به‌درستی ساخته شود. برای جلوگیری از تراکم بیش‌ازحد نقاط، اگر دو نقطه متوالی فاصله‌ای کمتر از ۱۰۰ متر داشتند یا کمتر از ۲ دقیقه [۱۳] با هم اختلاف زمانی داشتند، یکی از آن‌ها حذف شد. برای محاسبه فاصله مکانی از هاورساین^۱ [۲۰] معادله (۴) استفاده شده است. برای محاسبه فاصله‌ی بین دو نقطه مکانی روی سطح کره زمین، از معادله هاورساین استفاده شد. معادله (۴) یکی از دقیق‌ترین روش‌ها برای تخمین فاصله بین دو مختصات (عرض جغرافیایی و طول جغرافیایی) در سطح زمین است که انحنای کره زمین را در نظر می‌گیرد.

$$d = 2r \cdot \sin^{-1} \left(\sin^2 \left(\frac{\Delta \text{Longitude}}{2} \right) + \cos(\text{Latitude}_1) \cdot \cos(\text{Latitude}_2) \cdot \sin^2 \left(\frac{\Delta \text{Longitude}}{2} \right) \right) \quad (4)$$

در معادله (۴)، d فاصله‌ی دو نقطه بر حسب کیلومتر یا متر، r شعاع زمین (۶۳۷۱ کیلومتر)، $\Delta \text{Latitude}$ اختلاف عرض جغرافیایی (بر حسب رادیان)، $\Delta \text{Longitude}$ اختلاف طول جغرافیایی (بر حسب رادیان) می‌باشند. ابتدا اختلاف عرض و طول جغرافیایی را محاسبه کرده، سپس با استفاده از توابع مثلثاتی و شعاع زمین، فاصله مستقیم بین دو نقطه را بر روی سطح کره زمین تخمین زده می‌شود.

درون‌یابی متغیر محیطی، برای تلفیق داده‌های محیطی و حرکتی کشتی‌ها، از روشی ترکیبی در دو بعد مکانی و زمانی استفاده شد. در بعد مکانی، برای هر نقطه از مسیر کشتی، نزدیک‌ترین سلول از شبکه داده‌های موج با دقت 0.25×0.25 درجه انتخاب گردید. در بعد زمانی نیز، با توجه به این‌که زمان ثبت داده‌های AIS دقیقاً با زمان ثبت داده‌های موج منطبق نبوده، از درون‌یابی دوسویه خطی بین دو زمان متوالی در داده‌های موج استفاده شد. به این ترتیب، ارتفاع موج متناسب با موقعیت مکانی و زمان دقیق هر رکورد AIS محاسبه شد و هرگونه اختلاف یا تأخیر زمانی بین دو مجموعه داده به‌صورت ضمنی برطرف گردید. این تأخیر زمانی به صورت یک بازه خطا تعریف شده تا نزدیک‌ترین زمان انتخاب شود.

در پایان فرآیند پیش‌پردازش، مجموع داده‌های مکانی-زمانی مرتبط با مسیر کشتی‌ها به ۵,۰۹۰,۷۰۰ نقطه رسید.

۴ - روش

در این پژوهش، به‌منظور پیش‌بینی دقیق‌تر مسیر حرکت کشتی‌ها، از ترکیب مدل LSTM و مکانیزم توجه استفاده شده است. مدل LSTM به دلیل توانایی در یادگیری وابستگی‌های زمانی، برای تحلیل داده‌های دنباله‌ای مناسب است. اما در مواجهه با توالی‌های

² Vanishing gradient

³ Forget gate

⁴ Input gate

⁵ Gate

⁶ Output gate

⁷ Fully connected


⁸ Sigmoid

¹ Haversine

بازگشتی ساده، تعداد پارامترهای بیشتری دارند (حدود ۴ برابر)، زیرا برای هر یک از دروازه‌ها وزن‌ها^۱ و بایاس‌های^۲ جداگانه‌ای وجود دارد. این افزایش پارامتر باعث می‌شود LSTM توانایی بالاتری در یادگیری وابستگی‌های پیچیده و بلندمدت داشته باشد.

۲-۴ مکانیزم توجه

در مدل‌های سنتی مبتنی بر شبکه‌های بازگشتی، تمام اطلاعات دنباله ورودی در یک بردار ثابت فشرده می‌شود. این امر به‌ویژه در پردازش دنباله‌های طولانی، منجر به افت کیفیت یادگیری و کاهش دقت مدل می‌گردد. مکانیزم توجه به‌عنوان راهکاری مؤثر برای رفع این محدودیت معرفی شده و به مدل اجازه می‌دهد تا در هر گام زمانی، به بخش‌های مختلفی از دنباله ورودی با درجات متفاوتی از اهمیت توجه کند.



شکل ۴ - مکانیزم توجه

در شکل ۴، ساختار کلی مکانیزم توجه نمایش داده شده است. ابتدا مدل بردارهای پنهان^۳ تولید شده توسط رمزگذار^۴ را دریافت می‌کند و با استفاده از بردار پرس‌وجو^۵ که معمولاً وضعیت فعلی رمزگشا^۶ (s_t) است، میزان اهمیت هر بردار h_i را نسبت به زمان فعلی تعیین می‌کند.

محاسبه نمرات توجه^۷، برای هر بردار پنهان h_i ، یک نمره توجه یا امتیاز همترازی^۸ با استفاده از ضرب داخلی با بردار s_t محاسبه می‌شود. معادله (۱۳)

$$\alpha_i = s_t h_i^T \quad (13)$$

این امتیاز میزان ارتباط بین وضعیت فعلی رمزگشا و هر موقعیت از دنباله ورودی را مشخص می‌سازد.

$$f_t = \sigma(w_{hf}h_{t-1} + w_{if}x_t + b_{hf} + b_{if}) \quad (5)$$

خروجی معادله (۵) مقداری بین ۰ و ۱ دارد، که مشخص می‌کند کدام بخش از حافظه c_{t-1} حفظ یا فراموش شود. معادله (۶)

$$c_t = c_{t-1} \odot f_t \quad (6)$$

دروازه ورودی، این مرحله برای افزودن اطلاعات جدید به حافظه طراحی شده است. ابتدا یک کاندید برای حافظه جدید ساخته می‌شود. معادله (۷)

$$g_t = \tanh(w_{hg}h_{t-1} + w_{ig}x_t + b_{hg} + b_{ig}) \quad (7)$$

سپس دروازه ورودی تصمیم می‌گیرد که این اطلاعات تا چه اندازه باید وارد حافظه شوند. معادله (۸)

$$i_t = \sigma(w_{hi}h_{t-1} + w_{ii}x_t + b_{hi} + b_{ii}) \quad (8)$$

در نهایت، حاصل ضرب این دو مقدار (i_t و g_t) یعنی اطلاعات مفیدی که ارزش ذخیره شدن دارند به حافظه اضافه می‌شوند. معادله (۹)

$$c_t = c_t + (g_t \odot i_t) \quad (9)$$

در واقع، این مرحله بررسی می‌کند که اطلاعات لحظه‌ای تا چه اندازه مهم هستند و باید به حافظه بلندمدت اضافه شوند یا خیر. دروازه خروجی، در این مرحله خروجی نهایی مدل h_t تولید می‌شود. ابتدا حافظه فعلی c_t از تابع $\tanh$ عبور داده می‌شود. معادله (۱۰)

$$c'_t = \tanh(c_t) \quad (10)$$

سپس دروازه خروجی مانند مراحل قبل با استفاده از ورودی و خروجی قبلی ساخته می‌شود. معادله (۱۱)

$$o_t = \sigma(w_{ho}h_{t-1} + w_{io}x_t + b_{ho} + b_{io}) \quad (11)$$

در نهایت خروجی نهایی از ضرب این دو مقدار بدست می‌آید. معادله (۱۲)

$$h_t = o_t + \tanh(c'_t) \quad (12)$$

چون همیشه نیازی به استفاده از تمام اطلاعات حافظه نیست، دروازه خروجی مشخص می‌کند که چه مقدار از حافظه به عنوان خروجی مدل ارسال شود.

بخش g_t که با استفاده از $\tanh$ ساخته می‌شود، نقش مشابه با شبکه‌های عصبی بازگشتی ساده دارد، اما در LSTM همراه با دروازه ورودی استفاده می‌شود تا کنترل بیشتری روی اطلاعات داشته باشد. شبکه‌های LSTM نسبت به شبکه‌های عصبی

¹ Weight
² Bias
³ Hidden state
⁴ Encoder
⁵ Query
⁶ Decoder
⁷ Attention score
⁸ Alignment score

نرمال سازی با تابع Softmax، برای تبدیل نمرات توجه به وزن هایی قابل تفسیر، از تابع Softmax استفاده می شود. معادله (۱۴)

$$\frac{\exp(s_t h_i^T)}{\sum_j \exp(s_t h_j^T)} \quad (14)$$

در نتیجه، وزن های توجه α_i به گونه ای نرمال می شوند که مجموع آنها برابر با یک باشد و بتوان از آنها در ترکیب بردارها استفاده کرد.

محاسبه بردار زمینه^۱، وزن های توجه به دست آمده به عنوان ضرایب وزنی برای ترکیب خطی بردارهای h_i استفاده می شوند و بردار زمینه c_t محاسبه می گردد. معادله (۱۵)

$$c_t = \sum_i \alpha_i h_i \quad (15)$$

بردار c_t اطلاعات مربوط بخش هایی از دنباله ورودی، که مدل در گام زمانی فعلی به آنها بیش تر توجه کرده است را در خود جمع آوری می کند.

نمایش ماتریسی مکانیزم توجه، برای انجام محاسبات به صورت برداری و تسریع فرآیند آموزش، می توان روابط فوق را به شکل ماتریسی بیان کرد. معادله (۱۶).

$$C = \text{softmax}(SH^T)H \quad (16)$$

S ماتریس پرس و جو است که معمولاً بردارهای وضعیت رمزگشا در هر گام زمانی را شامل می شود. H ماتریس بردارهای حالت پنهان تولید شده توسط رمزگذار است. عملیات ضرب ماتریسی و تابع Softmax منجر به محاسبه ماتریسی وزن های توجه که در ادامه ضرب با H ، بردار زمینه C را تشکیل می دهد.

۴-۳ ترکیب مدل LSTM و مکانیزم توجه

در مسئله پیش بینی مسیر کشتی ها، مدل سازی دقیق وابستگی های زمانی و مکانی در طول زمان از اهمیت بالایی برخوردار است. مسیر حرکت یک کشتی تحت تأثیر عوامل متعددی مانند موقعیت های قبلی، سرعت، جهت حرکت، شرایط محیطی (باد، موج، جریان های دریایی) و رفتارهای گذشته کشتی یا کشتی های مجاور قرار دارد. در چنین شرایطی، استفاده از مدل LSTM به تنهایی می تواند تا حدی این وابستگی های زمانی را یاد بگیرد، اما در مواجهه با دنباله های بلند یا اطلاعات متغیر محیطی، ممکن است اطلاعات مهم از بین برود یا تضعیف شود.

ترکیب LSTM با مکانیزم توجه، این ضعف را پوشش می دهد و دقت مدل را در پیش بینی مسیر کشتی ها به طور قابل توجهی افزایش می دهد. در این ترکیب، LSTM توالی داده های ورودی شامل موقعیت مکانی، شتاب، نرخ چرخش، و سایر ویژگی ها را

پردازش کرده و در هر گام زمانی یک بردار وضعیت پنهان تولید می کند. مکانیزم توجه با تمرکز تطبیقی روی گام های زمانی قبلی، تعیین می کند که کدام موقعیت ها یا ویژگی ها در زمان های گذشته بیشترین اهمیت را برای پیش بینی موقعیت بعدی دارند. به عنوان مثال، در شرایطی که کشتی در حال تغییر جهت است، اطلاعات مربوط به چند گام قبل از تغییر، اهمیت بیشتری نسبت به گام های اولیه دارد.

این ترکیب مزایای زیادی دارد. از جمله، درک بهتر وابستگی های طولانی مدت، افزایش دقت در شرایط محیطی پیچیده، و انعطاف پذیری بیشتر در یادگیری الگوهای حرکتی متنوع. مدل می تواند بر گام هایی تمرکز کند که در پیش بینی آینده تأثیر بیشتری دارند، حتی اگر این گام ها در ابتدای توالی باشند.

از دیدگاه فنی، ابتدا توالی داده های نرمال شده شامل موقعیت، سرعت، نرخ چرخش، شتاب و ارتفاع موج، به لایه های LSTM وارد می شود. خروجی این لایه ها که شامل بردارهای پنهان برای هر گام زمانی است، به مکانیزم توجه ارسال می گردد. به طوری که بردار پنهان مربوط به آخرین گام زمانی به عنوان Query و تمامی بردارهای پنهان قبلی به عنوان Keys و Values عمل می کنند. سپس، بردار زمینه از طریق ترکیب وزنی softmax بین این بردارها محاسبه شده و به صورت الحاق یافته^۲ با خروجی نهایی LSTM به لایه خروجی متصل می شود تا پیش بینی نهایی تولید گردد.

۵ - پیاده سازی و ارزیابی

برای آموزش مدل های پیشنهادی، از ۱۵۰ دوره ی تکرار^۳ استفاده شد. نرخ یادگیری اولیه برابر با ۰/۰۰۱ در نظر گرفته شد و جهت جلوگیری از ایستایی در فرآیند یادگیری، از یک سازوکار تغییر نرخ یادگیری استفاده گردید، به گونه ای که پس از عدم بهبود در مقدار تابع خطا طی چند دوره ی متوالی، نرخ یادگیری با ضریبی کمتر به روزرسانی می شد. تابع هزینه^۴ مورد استفاده در هر دو مدل، میانگین مربعات خطا^۵ بوده که برای مسائل رگرسیونی با خروجی پیوسته مناسب است. مقدار ۷۰ درصد از کل داده به آموزش، ۱۵ درصد به اعتبارسنجی و ۱۵ درصد به تست اختصاص داده شده است. اندازه ی دسته^۶ برای آموزش برابر با ۲۵۶ انتخاب شد تا تعادلی میان کارایی محاسباتی و همگرایی مدل ها برقرار گردد. مدل پیشنهادی با وجود داشتن مکانیزم توجه، دارای ساختار نسبتاً سبک و بهینه است و روی یک GPU معمولی زمان پیش بینی برای هر

² Concatenated

³ Epoch

⁴ Loss function

⁵ Mean Squared Error (MSE)

⁶ Batch size

¹ Context vector


N تعداد کل مسیر در مجموعه داده ارزیابی، t_{obs} زمان آخرین نقطه‌ی مشاهده شده، Δt گام‌های زمانی آینده برای پیش‌بینی، موقعیت پیش‌بینی شده برای مسیر n در زمان t و P_t^n موقعیت واقعی برای مسیر n در زمان t می‌باشند. خطای نهایی جابجایی، فاصله‌ی اقلیدسی بین آخرین نقطه‌ی پیش‌بینی شده و آخرین نقطه‌ی واقعی مسیر را اندازه‌گیری می‌کند. این معیار میزان دقت مدل در پیش‌بینی مقصد نهایی کشتی را نشان می‌دهد. معادله (۱۸)

$$FDE = \frac{\sum_{n=1}^N \|P_t^n - P_t^n\|_2}{N}, t = t_{obs} + \Delta t \quad (18)$$

این دو معیار مکمل یکدیگر هستند. به گونه‌ای که میانگین خطای جابه‌جایی دقت کلی مدل در طول مسیر را نشان می‌دهد، در حالی که خطای نهایی جابه‌جایی بر دقت نقطه‌ی نهایی تمرکز دارد. استفاده هم‌زمان از این دو شاخص، امکان مقایسه‌ی کامل و جامع عملکرد مدل‌های مختلف را فراهم می‌سازد.

جدول ۲ - عملکرد مدل‌ها در پیش‌بینی کل داده تست (متر)

مدل‌های استفاده شده	بازه‌های زمانی (دقیقه)				
	۱۲۰	۶۰	۳۰	۱۰	۵
LSTM	۳۸۴۸/۲	۲۵۵۴/۴	۱۹۵۴/۶	۱۵۵۶/۴	۷۱۴/۸
LSTM-Attention	۲۱۱۱/۳	۱۴۳۲/۹	۱۰۶۲/۸	۸۲۲/۴	۶۰۹/۴




شکل ۶ - نمودار مقایسه مدل‌ها در ارزیابی (متر)

در شکل ۶، مقادیر میانگین خطای جابه‌جایی و خطای نهایی جابه‌جایی برای دو مدل LSTM و LSTM-Attention در بازه‌های زمانی مختلف پیش‌بینی (۵ دقیقه تا ۲ ساعت) ارائه شده‌اند. همچنین ارزیابی عملکرد مدل به صورت یکپارچه بر کل مجموعه داده‌ی تست انجام شده و تفکیکی بر اساس نوع کشتی (ماهگیری، کانتینری، مسافری) صورت نگرفته است.

نتایج حاصل از مقایسه نشان می‌دهد که مدل LSTM-Attention به طور معناداری عملکرد بهتری نسبت به مدل پایه‌ی LSTM داشته است. در تمامی افق‌های زمانی، مقادیر ADE و FDE

مسیر تنها حدود ۱ تا ۲ ثانیه بوده است. همچنین لازم به ذکر است که ساختار مدل دارای حدود ۱/۵ برابر پارامتر بیشتر نسبت به LSTM ساده است، ولی این افزایش تأثیر قابل توجهی در زمان پیش‌بینی نداشته است. این امر نشان می‌دهد که افزودن مکانیزم توجه، بار محاسباتی قابل توجهی به سیستم تحمیل نکرده است. برای پیش‌بینی مسیر نیاز به منابع محاسباتی بسیار قدرتمندی نیست و با یک GPU متوسط هم می‌توان فرآیند پیش‌بینی را انجام داد. اما برای آموزش مدل به علت حجم بالای داده و پیچیدگی مدل نیاز به یک GPU قدرتمند می‌باشد.

نمودار مقایسه‌ی خطای آموزش و اعتبارسنجی در شکل ۵ زیر آمده است. همان گونه که مشاهده می‌شود، مدل LSTM-Attention با سرعت بیشتری به همگرایی رسیده و نوسانات کمتری در اعتبارسنجی از خود نشان داده است. این موضوع نشان‌دهنده‌ی عمومی‌سازی بهتر مدل ترکیبی و توانایی تمرکز آن بر ویژگی‌های مهم‌تر در دنباله‌ی زمانی است.



شکل ۵ - نمودار هزینه مدل‌ها

۵-۱ معیارهای ارزیابی


برای ارزیابی عملکرد مدل در پیش‌بینی مسیر کشتی، از دو معیار استاندارد و پرکاربرد در حوزه‌ی یادگیری ماشین و تحلیل حرکت، یعنی میانگین خطای جابه‌جایی^۱ و خطای نهایی جابه‌جایی^۲ استفاده شده است. این دو معیار دقت پیش‌بینی مکانی مدل را در بازه‌ی زمانی آینده بررسی می‌کنند.

میانگین خطای جابه‌جایی، میانگین فاصله‌ی اقلیدسی بین نقاط پیش‌بینی شده و موقعیت‌های واقعی در طول بازه‌ی زمانی پیش‌بینی است. این معیار نشان‌دهنده‌ی دقت کلی مدل در طول تمام گام‌های زمانی آینده می‌باشد. معادله (۱۷)

$$ADE = \frac{\sum_{n=1}^N \sum_{t=t_{obs}+1}^{t_{obs}+\Delta t} \|P_t^n - P_t^n\|_2}{N \times (\Delta t - 1)} \quad (17)$$


^۱ Average Displacement Error (ADE)

^۲ Final Displacement Error (FDE)



شکل ۷ - مقایسه عملکرد دو مدل در پیش‌بینی مسیر

با بررسی مسیرهای پیش‌بینی‌شده توسط دو مدل در مقایسه با مسیر واقعی (شکل ۷)، می‌توان به وضوح مشاهده کرد که مدل ترکیبی LSTM-Attention توانسته است عملکرد دقیق‌تری نسبت به مدل پایه‌ی LSTM ارائه دهد. مسیرهای تولیدشده توسط این مدل نه تنها تطابق بهتری با شکل کلی و نقاط کلیدی مسیر دارند، بلکه در بخش‌هایی که تغییرات شدید در جهت حرکت کشتی رخ می‌دهد نیز واکنش دقیق‌تری نشان می‌دهند. این موضوع نشان‌دهنده‌ی توانایی بیشتر مدل در درک وابستگی‌های زمانی پیچیده‌تر در دنباله‌ی داده‌هاست. از سوی دیگر، مسیرهای مدل LSTM در برخی نواحی دچار انحراف از مسیر واقعی شده‌اند که می‌تواند ناشی از محدودیت آن در مدل‌سازی وابستگی‌های بلندمدت باشد. به طور کلی، این نتایج مؤید آن است که مکانیزم توجه با هدایت تمرکز مدل به بخش‌های مهم‌تر ورودی، به بهبود دقت پیش‌بینی در شرایط پیچیده‌تر کمک قابل توجهی کرده است. بررسی کیفی مسیرهای پیش‌بینی‌شده (شکل ۷) نشان می‌دهد که خطاها به‌طور عمده در سناریوهایی با تغییر جهت‌های ناگهانی یا رفتارهای غیرخطی رخ داده‌اند. در این وضعیت‌ها، مدل گاهی دچار تأخیر در واکنش شده یا شدت تغییر را به‌درستی تخمین نزده است. این ضعف‌ها به‌ویژه در پیش‌بینی افق‌های زمانی بلندتر (۶۰ تا ۱۲۰ دقیقه - شکل ۶) تأثیر محسوس‌تری بر افزایش مقدار FDE داشته‌اند.




شکل ۸ - میزان تاثیر هر ویژگی در یادگیری مدل

مربوط به مدل LSTM-Attention کمتر بوده و این اختلاف با افزایش مدت زمان پیش‌بینی، محسوس‌تر شده است. به‌عنوان نمونه، در افق زمانی ۲ ساعته، مقدار ADE برای مدل LSTM برابر با حدود ۴۷ متر و برای مدل LSTM-Attention برابر با حدود ۲۱ متر است. همچنین مقدار FDE نیز در همین بازه زمانی برای LSTM برابر با ۶۲ متر و برای LSTM-Attention حدود ۳۲ متر به‌دست آمده است.

این اختلاف قابل توجه در مقادیر خطا به‌ویژه در بازه‌های زمانی بلند، بیانگر برتری مدل Attention در یادگیری وابستگی‌های طولانی‌مدت در داده‌های زمانی است. در واقع، بهره‌گیری از مکانیزم توجه موجب شده تا مدل بتواند اطلاعات مربوط به نقاط کلیدی در گذشته را بهتر استخراج کرده و در پیش‌بینی‌های آتی لحاظ کند. این مسئله به‌ویژه در کاربردهایی نظیر پیش‌بینی مقصد کشتی‌ها، که در آن دقت نهایی اهمیت بالایی دارد، از اهمیت ویژه‌ای برخوردار است. در مجموع، این نتایج بیانگر آن است که ترکیب معماری LSTM با مکانیزم توجه منجر به بهبود قابل توجه در دقت پیش‌بینی مسیر و مقصد نهایی کشتی شده و استفاده از آن در مسائل مرتبط با تحلیل حرکت دریایی توصیه می‌شود.

۶ - نتایج و تحلیل



تجربی نشان داد که مدل ترکیبی LSTM-Attention نسبت به مدل پایه‌ی LSTM، عملکرد به مراتب بهتری ارائه داده است. به‌طور خاص، کاهش میانگین خطای جابجایی به میزان ۴۴/۵٪ و کاهش خطای نهایی مسیر به میزان ۳۹/۲٪ نسبت به مدل LSTM حاصل شد. علاوه بر این، مدل ترکیبی توانست در نقاطی با چرخش‌های تند یا توقف‌های ناگهانی، مسیر دقیق‌تری نسبت به داده‌ی واقعی تولید کند. تحلیل اهمیت ویژگی‌ها با استفاده از SHAP نیز نشان داد که ترکیب ویژگی‌های مکانی، دینامیکی و محیطی تأثیر قابل توجهی در تصمیم‌گیری مدل دارد.

با وجود دقت بالای مدل پیشنهادی، همچنان فرصت‌هایی برای بهبود عملکرد در آینده وجود دارد. استفاده از مدل‌های مبتنی بر ترنسفورمر^۱، این مدل‌ها با بهره‌گیری از مکانیزم توجه در سطوح عمیق‌تر و توانایی بالا در درک وابستگی‌های طولانی‌مدت، می‌توانند جایگزینی قدرتمند برای LSTM باشند. افزایش دقت مدل از طریق بهره‌گیری از داده‌های محیطی غنی‌تر، نظیر جهت و سرعت باد، جریان‌های سطحی و عمقی، دمای سطح آب و عمق بستر دریا از جمله مسیرهای بهبود آتی است. همچنین، گسترش مدل به ساختارهای چندعاملی^۲ که تعامل میان کشتی‌ها، وضعیت ترافیک دریایی و پدیده‌های رفتاری جمعی را در نظر بگیرد، می‌تواند به پیش‌بینی‌های واقع‌گرایانه‌تر و کاربردی‌تر در شرایط پیچیده منجر شود.

نتایج حاصل از این مدل می‌تواند تأثیرات قابل توجهی در حوزه‌های کلیدی صنعت دریانوردی داشته باشد. در حوزه امنیت و ایمنی دریایی، به کاهش احتمال تصادفات و افزایش قابلیت پیش‌بینی مسیر در شرایط پرترافیک یا نامساعد جوی کمک می‌کند. در زمینه هدایت و ناوبری، می‌تواند به عنوان پشتیبان سیستم‌های کمک‌ناوبری و مسیریابی هوشمند عمل کند. در توسعه بنادر هوشمند، داده‌های پیش‌بینی‌شده‌ی مدل امکان مدیریت بهینه‌ی ورود و خروج کشتی‌ها را فراهم می‌آورد. همچنین، در حوزه سیاست‌گذاری و حکمرانی، این مدل ابزاری مؤثر برای تصمیم‌گیری بهتر در زمینه کنترل ترافیک و تدوین راهبردهای کلان دریایی فراهم می‌سازد. در نهایت، در زمینه فناوری‌های نوین مانند ربات‌های دریایی و شناورهای بدون سرنشین نیز، این مدل می‌تواند به عنوان بخشی از سامانه‌های هوشمند مسیریابی و تصمیم‌گیری مورد استفاده قرار گیرد. یکی از مهم‌ترین محدودیت‌های اعمال چنین پژوهشی در کشور ایران، محدودیت در دسترسی عمومی به داده‌های AIS با وضوح بالا و پوشش کامل مسیرهای کشتی‌هاست. در کشور ما، داده‌های دقیق موقعیت مکانی کشتی‌ها به دلایل امنیتی، تجاری یا حریم خصوصی، تنها در اختیار نهادهای رسمی یا

برای تحلیل میزان تأثیر هر ویژگی در مدل پیشنهادی، از روش SHAP استفاده شده است. SHAP یک چارچوب تفسیرپذیری مبتنی بر نظریه‌ی بازی‌های مشارکتی است که هدف آن تخصیص منصفانه سهم هر ویژگی در تصمیم نهایی مدل می‌باشد. در این روش، فرض می‌شود هر ویژگی مانند یک بازیکن در یک بازی مشارکتی است، و خروجی مدل به‌عنوان پاداش بازی در نظر گرفته می‌شود. مقدار SHAP برای هر ویژگی نشان می‌دهد که آن ویژگی به‌صورت مستقل، چقدر در تغییر پیش‌بینی مدل نسبت به مقدار پایه نقش داشته است. این مقدار با در نظر گرفتن تمامی زیرمجموعه‌های ممکن از ویژگی‌ها محاسبه می‌شود، که آن را از نظر ریاضی کاملاً قابل اثبات، منصفانه و تفسیرپذیر می‌سازد. در این مطالعه، مقادیر SHAP برای مجموعه داده‌ی تست محاسبه شده‌اند و میانگین قدرمطلق این مقادیر برای هر ویژگی به‌عنوان شاخص کلی اهمیت آن در پیش‌بینی مسیر مورد استفاده قرار گرفته است.

همان‌طور که در شکل ۸، نتایج SHAP مشاهده می‌شود، عرض جغرافیایی و طول جغرافیایی بیشترین سهم را در تصمیم‌گیری مدل برای پیش‌بینی مسیر دارند. این مسئله از نظر مفهومی نیز قابل توجیه است، چرا که موقعیت مکانی فعلی کشتی بنیان اصلی تعیین جهت حرکت و تخمین ادامه‌ی مسیر می‌باشد. ویژگی‌های دینامیکی نظیر شتاب و نرخ چرخش نیز تأثیر مهمی بر خروجی مدل دارند، به‌ویژه در مسیرهایی که تغییر جهت یا توقف ناگهانی اتفاق می‌افتد. از سوی دیگر، ارتفاع موج به‌عنوان یک عامل محیطی، اهمیت نسبتاً بالایی در مدل داشته است. این موضوع نشان می‌دهد که مدل به شرایط دریایی نیز حساس بوده و آن‌ها را در پیش‌بینی‌های خود لحاظ می‌کند. به‌ویژه در نواحی پرتلاطم که ممکن است کشتی مجبور به تغییر مسیر یا کاهش سرعت شود.

در نهایت، نوع کشتی نیز گرچه یکی از ویژگی‌هایی بوده که اهمیت کمتری داشته، اما همچنان نقش آن قابل چشم‌پوشی نیست. تفاوت در ویژگی‌های فیزیکی و نحوه‌ی حرکت کشتی‌های مختلف به وضوح در رفتار حرکتی آن‌ها تأثیر می‌گذارد، و مدل موفق به شناسایی این الگوها شده است.

این نتایج نشان می‌دهد که مدل پیشنهادی نه تنها به متغیرهای موقعیتی وابسته است، بلکه توانایی درک تأثیر ترکیبی ویژگی‌های دینامیکی و محیطی را نیز دارد، نکته‌ای که برای کاربردهای واقعی در پیش‌بینی حرکت دریایی بسیار حائز اهمیت است.

۷ - نتیجه‌گیری و کارهای آینده

در این پژوهش، مدلی ترکیبی مبتنی بر شبکه‌ی LSTM و مکانیزم توجه برای پیش‌بینی مسیر کشتی‌ها ارائه شد. هدف اصلی، افزایش دقت پیش‌بینی در شرایط پیچیده‌ی حرکتی و محیطی بود. نتایج

¹ Transformer

² Multi-agent

9- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30. <https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>

10- Rong, H., Teixeira, A. P., & Soares, C. G. (2019). Ship trajectory uncertainty prediction based on a Gaussian Process model. *Ocean Engineering*, 182, 499–511. <https://doi.org/10.1016/j.oceaneng.2019.04.024>

11- Tang, H., Yin, Y., & Shen, H. (2019). A model for vessel trajectory prediction based on long short-term memory neural network. *Journal of Marine Engineering & Technology*, 21(3), 136-145. <https://doi.org/10.1080/20464177.2019.1665258>

12- Suo, Y., Chen, W., Claramunt, C., & Yang, S. (2020). A ship trajectory prediction framework based on a recurrent neural network. *Sensors*, 20(18), 5133. <https://doi.org/10.3390/s20185133>

13- Alizadeh, D., Alesheikh, A. A., & Sharif, M. (2021). Vessel trajectory prediction using historical automatic identification system data. *the Journal of Navigation*, 74(1), 156-174. <https://doi.org/10.1017/S0373463320000442>

14- Murray, B., & Perera, L. P. (2021). An AIS-based deep learning framework for regional ship behavior prediction. *Reliability Engineering & System Safety*, 215, 107819. <https://doi.org/10.1016/j.ress.2021.107819>

15- Burger, C. N., Kleynhans, W., & Grobler, T. L. (2022). Extended linear regression model for vessel trajectory prediction with a-priori AIS information. *Geo-spatial Information Science*, 27(1), 202-220. <https://doi.org/10.1080/10095020.2022.2072241>

16- Sun, Q., Tang, Z., Gao, J., & Zhang, G. (2022). Short-term ship motion attitude prediction based on LSTM and GPR. *Applied Ocean Research*, 118, 102927. <https://doi.org/10.1016/j.apor.2021.102927>

17- Xiao, Y., Hu, Y., Liu, J., Xiao, Y., & Liu, Q. (2024). An Adaptive Multimodal Data Vessel Trajectory Prediction Model Based on a Satellite Automatic Identification System and Environmental Data. *Journal of Marine Science and Engineering*, 12(3), 513. <https://doi.org/10.3390/jmse12030513>

18- Li, Y., Yu, Q., & Yang, Z. (2024). Vessel Trajectory Prediction for Enhanced Maritime Navigation Safety: A Novel Hybrid Methodology. *Journal of Marine Science and Engineering*, 12(8), 1351. <https://doi.org/10.3390/jmse12081351>

19- Mehri, S., Alesheikh, A. A., & Basiri, A. (2023). A context-aware approach for vessels' trajectory prediction. *Ocean Engineering*, 282, 114916. <https://doi.org/10.1016/j.oceaneng.2023.114916>

شرکت‌های خاص قرار دارند. این مسأله باعث می‌شود فرآیند جمع‌آوری داده‌های کافی برای آموزش و ارزیابی مدل‌های یادگیری عمیق با چالش جدی مواجه شود. اگرچه گزینه‌هایی مانند داده‌های شبیه‌سازی شده یا منابع ماهواره‌ای عمومی (نظیر Spire) وجود دارند، اما داده‌های شبیه‌سازی شده فاقد واقع‌گرایی کافی در بازنمایی رفتارهای پیچیده کشتی‌ها هستند و داده‌های ماهواره‌ای نیز به دلیل نرخ پایین ثبت، نبود دسترسی به داده‌ی خام، و پوشش محدود، برای آموزش مدل‌های یادگیری عمیق کفایت لازم را ندارند. همچنین، استفاده از منابع تجاری مانند MarineTraffic به دلیل هزینه‌های بالا، از دسترس پروژه‌های دانشگاهی خارج است.

۸ - مراجع

1- Dodge, S. (2011). Exploring movement using similarity analysis [PhD Thesis, University of Zurich]. <https://www.zora.uzh.ch/id/eprint/59842/>

2- Nathan, R., Getz, W. M., Revilla, E., Holyoak, M., Kadmon, R., Saltz, D., & Smouse, P. E. (2008). A movement ecology paradigm for unifying organismal movement research. *Proceedings of the National Academy of Sciences*, 105(49), 19052–19059. <https://doi.org/10.1073/pnas.0800375105>

3- Liu, X., & Karimi, H. A. (2006). Location awareness through trajectory prediction. *Computers, Environment and Urban Systems*, 30(6), 741–756. <https://doi.org/10.1016/j.compenvurbsys.2006.02.007>

4- Rodrigue, J.-P. (2020). *The geography of transport systems*. Routledge.

5- Grech, M. R., Horberry, T., & Smith, A. (2002). Human Error in Maritime Operations: Analyses of Accident Reports Using the Leximancer Tool. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 46(19), 1718–1721. <https://doi.org/10.1177/154193120204601906>

6- Shin, Y., Kim, N., Lee, H., In, S. Y., Hansen, M., & Yoon, Y. (2024). Deep learning framework for vessel trajectory prediction using auxiliary tasks and convolutional networks. *Engineering Applications of Artificial Intelligence*, 132, 107936. <https://www.sciencedirect.com/science/article/pii/S0952197624000940>

7- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://ieeexplore.ieee.org/abstract/document/6795963/>

8- Burger, C. N., Kleynhans, W., & Grobler, T. L. (2022). Extended linear regression model for vessel trajectory prediction with a-priori AIS information. *Geo-spatial Information Science*, 27(1), 202-220. <https://doi.org/10.1080/10095020.2022.2072241>

20- Employing Traditional Machine Learning Algorithms for Big Data Streams Analysis: The Case of Object Trajectory Prediction, 127 Journal of Systems and Software 249 (Elsevier 2017).
<https://www.sciencedirect.com/science/article/pii/S016412121630084X>