



## Application of Artificial Intelligence in Surface Currents of the Persian Gulf

Milad Moradi<sup>1</sup>, Madjid Abbaspour Tehrani Fard<sup>2</sup>, Alireza Taheri<sup>3</sup>

<sup>1</sup> M.Sc., Sharif University of Technology, student of Marine Engineering, [moradimilad2000@gmail.com](mailto:moradimilad2000@gmail.com)

<sup>2</sup> Ph.D., Sharif University of Technology, Faculty of Marine Engineering, [abbpor@sharif.edu](mailto:abbpor@sharif.edu)

<sup>3</sup> Ph.D., Sharif University of Technology, Faculty of Mechanical Engineering, [artaheri@sharif.edu](mailto:artaheri@sharif.edu)

### ARTICLE INFO

#### Article History:

Received: 16 May 2025

Last modification: 19 May 2026

Accepted: 21 May 2026

Available online: 25 May 2026

#### Article type:

Research Article

#### Keywords:

Surface Currents

Persian Gulf

CNN-LSTM

Marine Forecasting

Artificial Intelligence

### ABSTRACT

This study aims to achieve accurate prediction of surface currents in the Persian Gulf. Reliable forecasting of these currents is of critical importance for various applications, including the improvement of maritime navigation, sustainable management of fisheries resources, mitigation of oil pollution, and enhancement of search and rescue operations.

In this research, an advanced hybrid model based on Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) networks is employed. The required data, including zonal and meridional velocity components, are extracted from the HYCOM model for the period 2010–2015 with a spatial resolution of 8 km. In the proposed architecture, the CNN network is responsible for extracting spatial features, while the LSTM network captures temporal patterns and dependencies.

The results indicate that the optimal selection of the spatial radius of the input data plays a crucial role in improving prediction accuracy. The findings show that as the forecasting time horizon increases, a larger spatial radius becomes necessary; however, increasing the spatial radius does not always lead to improved performance. The prediction error for all investigated forecasting horizons remains below 7.95%, based on the normalized mean squared error (NMSE) metric.

ISSN: 2645-136



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/>]



## کاربرد هوش مصنوعی در جریانات سطحی خلیج فارس

میلاذ مرادی<sup>۱</sup>، مجید عباسپورتهرانی فرد<sup>۲</sup>، علیرضا طاهری<sup>۳</sup>

<sup>۱</sup> کارشناسی ارشد، دانشگاه صنعتی شریف، دانشکده مکانیک، گروه دریا، [moradimilad2000@gmail.com](mailto:moradimilad2000@gmail.com)

<sup>۲</sup> دکتری، دانشگاه صنعتی شریف، دانشکده مکانیک، گروه دریا، [abbpor@sharif.edu](mailto:abbpor@sharif.edu)

<sup>۳</sup> دکتری، دانشگاه صنعتی شریف، دانشکده مکانیک، [artaheri@sharif.edu](mailto:artaheri@sharif.edu)

### چکیده

این پژوهش با هدف پیش‌بینی دقیق جریانات سطحی در خلیج فارس انجام شده است. پیش‌بینی این جریانات به دلایل متعددی از جمله بهبود ناوبری دریایی، مدیریت پایدار منابع شیلاتی، کنترل آلودگی‌های نفتی و افزایش اثربخشی عملیات امداد و نجات از اهمیت حیاتی برخوردار است. در این مطالعه، از یک مدل ترکیبی پیشرفته مبتنی بر شبکه‌های عصبی کانولوشنی (CNN) و حافظه بلندمدت (LSTM) استفاده شده است. داده‌های مورد نیاز اعم از سرعت عمودی و سرعت افقی از مدل HYCOM برای بازه زمانی ۲۰۱۰ تا ۲۰۱۵ با دقت مکانی ۸ کیلومتر استخراج شده است. در این معماری، شبکه CNN مسئول استخراج ویژگی‌های مکانی و شبکه LSTM عهده‌دار تحلیل الگوهای زمانی بوده است. یافته‌های تحقیق نشان می‌دهد که انتخاب بهینه شعاع مکانی داده‌های ورودی نقش تعیین‌کننده‌ای در دقت پیش‌بینی‌ها دارد. نتایج حاکی از آن است که با افزایش افق زمانی پیش‌بینی، نیاز به استفاده از شعاع مکانی بزرگتر بیشتر می‌باشد، اما این افزایش شعاع همواره منجر به بهبود نتایج نمی‌گردد. خطای پیش‌بینی در تمامی افق‌های زمانی مورد بررسی کمتر از ۷.۹۵٪ (بر اساس معیار میانگین مربعات خطای نرمال شده) بوده است.

### اطلاعات مقاله

ناریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۰۲/۲۶

تاریخ اصلاح مقاله: ۱۴۰۵/۰۲/۲۹

تاریخ پذیرش مقاله: ۱۴۰۵/۰۲/۳۱

تاریخ انتشار مقاله: ۱۴۰۵/۰۳/۰۴

سوع مقاله:

مقاله پژوهشی

کلمات کلیدی:

جریانات سطحی

خلیج فارس

CNN-LSTM

پیش‌بینی دریایی

هوش مصنوعی

### 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



قادر است با استفاده از حجم عظیم داده‌ها، الگوهای پنهان و روابط پیچیده زمانی و مکانی را استخراج کند و در شرایطی که مدل‌های سنتی ناکارآمد هستند، پیش‌بینی‌های دقیقی ارائه دهد [۸، ۹]. در سال‌های اخیر، مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی به‌طور گسترده‌ای در پیش‌بینی پدیده‌های محیطی و دریایی مورد استفاده قرار گرفته‌اند. شبکه‌هایی نظیر پرسپترون‌های چندلایه، شبکه‌های بازگشتی و به‌ویژه مدل‌های حافظه‌دار مانند LSTM به دلیل توانایی در تحلیل وابستگی‌های زمانی، جایگاه ویژه‌ای در مدل‌سازی پارامترهایی چون سرعت و جهت جریان، تراز سطح دریا، دمای سطحی و کیفیت آب پیدا کرده‌اند [۱۰، ۱۱].

در همین راستا، شبکه عصبی کانولوشنی نیز که برای تحلیل الگوهای فضایی توسعه یافته‌اند، در استخراج ویژگی‌ها از داده‌های تصویری و ماهواره‌ای کاربرد فراوانی داشته و به‌ویژه در تحلیل داده‌های مکانی جریان‌های دریایی عملکرد قابل توجهی نشان داده‌اند. با توجه به ماهیت پیچیده و چندبعدی پدیده‌های اقیانوسی که ترکیبی از ویژگی‌های مکانی و زمانی هستند، ترکیب این دو نوع شبکه یعنی شبکه‌های عصبی کانولوشنی و حافظه‌دار بلندمدت، به‌عنوان یک رویکرد نوین و مؤثر معرفی شده است. مدل ترکیبی CNN-LSTM، این امکان را فراهم می‌کند که الگوهای فضایی از طریق شبکه عصبی کانولوشنی استخراج شده و سپس تغییرات زمانی آن‌ها از طریق حافظه‌دار بلندمدت تحلیل شود. این ساختار ترکیبی، عملکردی به‌مراتب دقیق‌تر نسبت به استفاده منفرد از هر یک از این شبکه‌ها دارد و در تحقیقات متعددی مانند مطالعات [۱۲] برتری آن در پیش‌بینی جریان‌های سطحی اقیانوس تأیید شده است. همچنین، در پژوهش‌هایی نظیر [۱۳]، این مدل‌ها در پیش‌بینی دقیق پارامترهایی نظیر سطح آب و کیفیت آن موفق عمل کرده‌اند. در مجموع، تلفیق شبکه عصبی کانولوشنی و حافظه‌دار بلندمدت با بهره‌گیری از قابلیت‌های مکمل این دو شبکه، ابزاری توانمند برای تحلیل و مدل‌سازی پدیده‌های دینامیکی دریایی فراهم کرده است. در همین راستا، هدف اصلی این پژوهش، پیش‌بینی جریان‌های دریایی در بخشی از حوزه خلیج فارس با بهره‌گیری از ساختار ترکیبی شبکه‌های عصبی کانولوشنی و حافظه‌دار بلندمدت است.

## ۲- روش شناسی

### ۲-۱- داده‌های مورد استفاده:

در این پژوهش، به‌منظور بررسی جریان‌های دریایی در محدوده‌ای از آب‌های خلیج فارس (بین عرض‌های جغرافیایی ۲۵،۰۸۷۴ تا ۲۶،۲۲۸ درجه شمالی و طول‌های جغرافیایی ۵۲،۲۶۰۴ تا ۵۳،۳۶ درجه شرقی) در سطح دریا، از داده‌های مدل عددی HYCOM در بازه‌ی زمانی سال‌های ۲۰۱۰ تا ۲۰۱۵ استفاده شده است.

جریان‌های سطحی اقیانوسی از اجزای اساسی و تأثیرگذار در نظام اقلیمی کره زمین محسوب می‌شوند. این جریان‌ها به‌طور مستقیم بر انتقال گرما، شوری آب، مواد مغذی و گازهای گلخانه‌ای در سراسر اقیانوس‌ها اثر گذاشته و نقش مهمی در تنظیم دمای سطحی زمین و تعادل حرارتی اتمسفر ایفا می‌کنند [۱]. در کنار نقش اقلیمی، این جریان‌ها نقش تعیین‌کننده‌ای در پایداری اکوسیستم‌های دریایی، مهاجرت گونه‌های دریایی، پراکنش پلانکتون‌ها و شکل‌گیری مناطق صیادی دارند [۲]. همچنین، پدیده‌هایی چون نوسانات جنوبی ال‌نینو و نوسانات اطلس شمالی نیز به‌شدت تحت تأثیر تغییرات جریان‌های سطحی هستند و متقابلاً بر آن‌ها تأثیر می‌گذارند [۳].

با توجه به اهمیت فراگیر و چندوجهی جریان‌های سطحی، تلاش برای پیش‌بینی، مدل‌سازی و پیش‌بینی دقیق آن‌ها همواره مورد توجه جامعه علمی و نهادهای اجرایی بوده است. کاربردهای این پیش‌بینی‌ها در حوزه‌هایی چون ناوبری دریایی، عملیات امداد و نجات، حفاظت از منابع دریایی، کنترل آلودگی، طراحی سازه‌های ساحلی و فراساحلی و مدیریت حوادث دریایی (نظیر نشت نفت یا گم‌شدن شناورها) بسیار گسترده است [۴]. اگرچه مدل‌های عددی و فیزیکی توسعه‌یافته‌ای برای شبیه‌سازی جریان‌های سطحی وجود دارد، اما در عمل، این مدل‌ها با محدودیت‌هایی نظیر وابستگی به شرایط اولیه دقیق، پیچیدگی پارامترسازی فرآیندهای فیزیکی، هزینه محاسباتی بالا و عدم قطعیت در شرایط مرزی مواجه‌اند [۵]. این محدودیت‌ها، به‌ویژه در مناطق با ویژگی‌های دینامیکی خاص، موجب کاهش دقت و کارایی پیش‌بینی‌ها می‌شود. یکی از نمونه‌های بارز این مناطق، خلیج فارس است؛ منطقه‌ای نیمه‌بسته با ویژگی‌های منحصر به‌فردی چون دمای بالای آب، تبخیر شدید، شوری بالا و تبادل محدود با دریای عمان و اقیانوس هند [۶]. این شرایط باعث ایجاد الگوهای جریانی پیچیده و ناپایدار شده است که پیش‌بینی آن‌ها به چالشی علمی تبدیل شده است. علاوه بر این ویژگی‌های طبیعی، فعالیت‌های گسترده انسانی در خلیج فارس از جمله حمل‌ونقل نفتی، بهره‌برداری شیلاتی، تاسیسات فراساحلی و پروژه‌های توسعه‌ای، لزوم پیش‌بینی دقیق و به‌موقع جریان‌های سطحی را دوچندان کرده است. داده‌های حاصل از مدل‌های جهانی مانند HYCOM، اگرچه اطلاعات ارزشمندی را فراهم می‌کنند، اما به‌تنهایی برای تحلیل‌های منطقه‌ای دقیق کافی نیستند و نیاز به پردازش‌های هوشمند و به‌روز دارند [۷].

در چنین بستری، هوش مصنوعی به‌عنوان یکی از ابزارهای نوین در علوم داده و مدل‌سازی غیرخطی، چشم‌اندازی جدید در پیش‌بینی پدیده‌های پیچیده اقیانوسی گشوده است. هوش مصنوعی، به‌ویژه با رویکردهای یادگیری ماشین و یادگیری عمیق،

مدل HYCOM<sup>۵</sup> یک مدل عددی پیشرفته و بین‌المللی برای شبیه‌سازی شرایط فیزیکی اقیانوس‌هاست که توسط مراکز علمی معتبری مانند دانشگاه میامی و آزمایشگاه ملی لس‌آلاموس توسعه یافته است. این مدل از مختصات عمودی ترکیبی بهره می‌برد که شامل سه نوع مختصات ایزوپیکنیک (چگالی ثابت)، z-level (عمق ثابت) و سیگما (تابع توپوگرافی بستر) است. این ویژگی منحصر به فرد به HYCOM امکان می‌دهد تا بتواند شرایط پیچیده‌ی مناطق مختلف دریایی - از نواحی عمیق و لایه‌لایه شده گرفته تا مناطق کم‌عمق و ساحلی - را با دقت بالا و پایداری عددی مناسب شبیه‌سازی کند.

یکی از دلایل اصلی انتخاب مدل HYCOM، دسترسی آسان به داده‌های دقیق، جهانی و بلندمدت آن است. این مدل برای بیشتر مناطق جهان، داده‌هایی با دقت مکانی حدود ۸ کیلومتر و دقت زمانی سه‌ساعته ارائه می‌دهد (جدول ۱). چنین دقت بالایی برای تحلیل جریان‌های دریایی، نوسانات سطح دریا، تغییرات دما و شوری، و سایر ویژگی‌های فیزیکی محیط دریایی بسیار مناسب و کارآمد است.

جدول ۱- داده‌های ۲۴ ساعته سرعت عمودی و افقی (متر بر ثانیه) یک نقطه از خلیج فارس با فاصله زمانی ۳ ساعته

TIME	LAT	LON	U	V
۱۰۹۵۴۸	۲۵.۱۲	۵۲.۲۳	۰.۳۰	۰.۳۱
۱۰۹۵۵۱	۲۵.۱۲	۵۲.۲۳	-۰.۳۷	-۰.۱۱
۱۰۹۵۵۴	۲۵.۱۲	۵۲.۲۳	-۰.۰۴	-۰.۸۶
۱۰۹۵۵۷	۲۵.۱۲	۵۲.۲۳	۰.۰۲	-۰.۱۶

در این تحقیق از داده‌های خروجی مدل HYCOM، شامل مؤلفه‌های سرعت افقی و عمودی سطح دریا (متر بر ثانیه)، استفاده شده است. این داده‌ها برای هر پیکسل مکانی با ابعاد تقریبی ۸ کیلومتر تهیه شده‌اند و جزئیات آن‌ها در جدول شماره ۱ ارائه شده است.

در ادامه‌ی پژوهش، هدف اصلی، پیش‌بینی مؤلفه‌های سرعت جریان‌های سطحی دریایی برای یک پیکسل مکانی مشخص در بازه‌های زمانی آینده بود. برای این منظور، مدل با بهره‌گیری از داده‌های مربوط به ۲۴ ساعت گذشته آموزش داده شد و پیش‌بینی‌ها با گام‌های زمانی سه‌ساعته، در بازه‌های بین ۳ تا ۲۴ ساعت آینده صورت گرفت.

به‌منظور بررسی تأثیر شعاع مکانی داده‌های ورودی بر عملکرد مدل، مجموعه‌های متعددی از داده‌ها با پوشش‌های مکانی مختلف مورد استفاده قرار گرفت. به‌طور مشخص، شعاع مکانی داده‌های ورودی از ۸ کیلومتر (تنها شامل یک پیکسل اطراف نقطه‌ی هدف)


آغاز شده و به‌تدریج تا ۴۸ کیلومتر (معادل ۶ پیکسل در هر جهت) گسترش یافت. این رویکرد امکان تحلیل و ارزیابی تأثیر میزان پوشش مکانی داده‌های ورودی بر دقت پیش‌بینی مدل را فراهم ساخت.

## ۲-۲- معماری شبکه‌های مورد استفاده و هایپر پارامترها:

در این مدل، با توجه به ماهیت فضا-زمانمند داده‌ها، از ترکیب یک شبکه‌ی عصبی کانولوشنی و یک شبکه‌ی بازگشتی حافظه‌دار برای پیش‌بینی جریان‌های دریایی استفاده شده است. در بخش نخست مدل، یک شبکه‌ی عصبی کانولوشنی طراحی شده که وظیفه‌ی استخراج ویژگی‌های مکانی از داده‌های ورودی را بر عهده دارد. پس از اعمال شبکه‌ی کانولوشنی، اطلاعات زمانی شامل ساعت، روز و ماه برداشت داده‌ها به‌صورت سینوسی و کسینوسی کدگذاری شده و به خروجی شبکه‌ی عصبی کانولوشنی افزوده می‌شود. این کدگذاری زمانی به مدل کمک می‌کند تا چرخه‌های روزانه و فصلی، از جمله اثرات جزر و مد و جریان‌های ماهیانه، را بهتر درک نماید.

در مرحله‌ی بعد، ویژگی‌های استخراج‌شده به یک شبکه‌ی حافظه‌دار بلندمدت منتقل می‌شوند که وظیفه‌ی یادگیری و حفظ توالی‌های زمانی را بر عهده دارد. بدین ترتیب، با وارد کردن اطلاعات مربوط به ۲۴ ساعت گذشته به مدل - که با توجه به بازه‌ی زمانی برداشت داده‌ها (هر ۳ ساعت)، شامل ۸ نمونه‌ی داده‌ی سرعت جریان است - مدل پس از دریافت آخرین ورودی، پیش‌بینی سرعت جریان را با گام‌های زمانی سه‌ساعته برای بازه‌ی ۲۴ ساعت آینده آغاز می‌کند.

معماری شبکه‌ی تلفیقی مورد استفاده در (شکل ۱) نمایش داده شده است. لازم به ذکر است که در این شکل، تنها یک گام زمانی پیش‌بینی‌شده به‌صورت نمونه نمایش داده شده است.



شکل ۱- معماری شبکه‌ی تلفیقی CNN-LSTM مورد استفاده در پژوهش


HYCOM مقایسه شده و مقدار درصد خطای نرمال شده ی ریشه میانگین مربعات<sup>۵</sup> محاسبه می گردد. فرمول این معیار به صورت زیر است:

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^N (v_i - \hat{v}_i)^2}{N}}}{v_{MAX} - v_{MIN}} \quad (1)$$

که در این فرمول  $v_i$  بیانگر سرعت واقعی داده ارزیابی  $\hat{v}_i$ ،  $\hat{v}_i$  سرعت پیش بینی شده داده ارزیابی  $\hat{v}_i$ ،  $N$  تعداد کل داده های ارزیابی،  $v_{MAX}$  بیشترین سرعت واقعی و  $v_{MIN}$  کمترین سرعت واقعی میباشد.

### ۳- نتایج:

در این بخش، نتایج حاصل از اجرای مدل ها و تحلیل های انجام شده در راستای اهداف این پژوهش ارائه می شود. در شکل ۲ درصد خطای میانگین مربعات نرمال شده برای مدل های مختلف در حالت پیش بینی سه ساعته نمایش داده شده است.



شکل ۲- مقدار NRMSE برای مدل های مختلف در حالت پیش بینی سرعت افقی جریان در افق سه ساعته (مدل ها بر حسب شعاع پیکسل مکانی داده های ورودی شماره گذاری شده اند)

در جداول ۲ و ۳، درصد خطای میانگین مربعات نرمال شده (NRMSE) برای مدل های مختلف در افق های زمانی متفاوت پیش بینی، به تفکیک مؤلفه های افقی و عمودی سرعت جریان، ارائه شده است.

در این پژوهش، شش مدل مجزا طراحی و مورد استفاده قرار گرفته اند که هر یک وظیفه ی پیش بینی مؤلفه های سرعت جریان سطحی در دو جهت افقی و عمودی را در بازه های زمانی ۳ تا ۲۴ ساعت آینده بر عهده دارند. تفاوت این مدل ها در شعاع مکانی داده های ورودی آن ها است؛ به گونه ای که مدل اول با داده هایی از شعاعی معادل یک پیکسل مکانی آموزش دیده و در مدل های بعدی، شعاع مکانی به تدریج افزایش یافته است، تا جایی که مدل ششم از داده هایی با شعاع شش پیکسل مکانی استفاده می کند. این ساختار به ما امکان می دهد تا تأثیر افزایش پوشش مکانی داده های ورودی بر عملکرد مدل در پیش بینی جریان های سطحی را بررسی و تحلیل کنیم.

### ۳-۲- آموزش مدل:

برای آموزش مدل، در ابتدا تابع هدف بهینه سازی تعریف شده است. با توجه به هدف این پژوهش که تخمین سرعت جریان در دریایی است، از تابع هدف مبتنی بر مجموع مربعات خطا بین مقادیر پیش بینی شده و مقادیر واقعی استفاده شده است.

فرآیند آموزش مدل با بهره گیری از روش اعتبارسنجی متقابل ۱۰ تایی انجام گرفته است. این روش موجب افزایش قابلیت تعمیم پذیری مدل و اطمینان از صحت نتایج می شود. در این روش، مجموعه ی داده به ۱۰ بخش مساوی تقسیم می شود. در هر تکرار، مدل با استفاده از ۹ بخش آموزش داده می شود و عملکرد آن بر روی بخش باقی مانده ارزیابی می گردد. این فرآیند ۱۰ بار تکرار می شود به گونه ای که هر بخش دقیقاً یک بار به عنوان داده ی اعتبارسنجی مورد استفاده قرار می گیرد. بدین ترتیب، مدل با بخش های مختلفی از داده ها آموزش و ارزیابی می شود و اثر احتمالی وجود نویز یا ویژگی های خاص در یک بخش از داده ها کاهش می یابد.

در گام بعدی، آموزش مدل با استفاده از الگوریتم بهینه سازی ADAM<sup>۱</sup> و روش پس انتشار خطا<sup>۲</sup> انجام شده است. مقدار اولیه ی نرخ یادگیری<sup>۳</sup> برابر با ۰.۰۰۱ در نظر گرفته شده است. به منظور بهینه سازی فرآیند آموزش، در صورتی که طی پنج دوره ی متوالی<sup>۴</sup> بهبودی در مقدار تابع هزینه مشاهده نشود، نرخ یادگیری به ۰.۱ برابر مقدار فعلی کاهش می یابد.

### ۳-۴- معیار ارزیابی:

برای ارزیابی عملکرد مدل، داده های پیش بینی شده ی مربوط به سرعت افقی و عمودی با داده های واقعی گرفته شده از

<sup>۴</sup> Epoch  
<sup>۵</sup> NRMSE

<sup>۱</sup> Adaptive Moment Estimation  
<sup>۲</sup> Backpropagation  
<sup>۳</sup> Learning Rate

جدول ۲- مقدار  $NRMSE$  برای مدل‌های مختلف در پیش‌بینی سرعت افقی جریان‌ها در افق‌های ۳ تا ۲۴ ساعته (مدل‌ها بر اساس شعاع پیکسل مکانی داده‌های ورودی شماره‌گذاری شده‌اند). مقادیر پررنگ نمایانگر مدل بهینه برای هر افق زمانی پیش‌بینی می‌باشند.

شماره مدل	افق پیش‌بینی [ساعت]							
	۲۴	۲۱	۱۸	۱۵	۱۲	۹	۶	۳
۱	۷.۳۲	۶.۵۳	۶.۲۹	۶.۱۰	۵.۹۷	۵.۸۹	۵.۲۴	۳.۹۸
۲	۷.۰۷	۶.۲۸	۶.۰۰	۵.۸۹	۵.۷۸	۵.۷۷	۵.۲۸	۴.۲۶
۳	۷.۰۴	۶.۳۳	۶.۱۰	۶.۰۱	۵.۸۵	۵.۸۶	۵.۴۰	۴.۴۴
۴	۷.۱	۶.۴۰	۶.۲۱	۶.۰۸	۵.۹۵	۵.۹۵	۵.۵۲	۴.۶۹
۵	۷.۲۴	۶.۵۳	۶.۳۷	۶.۲۶	۶.۱۳	۶.۱۱	۵.۶۴	۴.۸۵
۶	۷.۳۲	۶.۵۳	۶.۲۹	۶.۱۰	۶.۲۲	۶.۱۹	۵.۷۳	۵.۰۲

جدول ۳- مقدار  $NRMSE$  برای مدل‌های مختلف در پیش‌بینی سرعت عمودی جریان‌ها در افق‌های ۳ تا ۲۴ ساعته (مدل‌ها بر اساس شعاع پیکسل مکانی داده‌های ورودی شماره‌گذاری شده‌اند). مقادیر پررنگ نمایانگر مدل بهینه برای هر افق زمانی پیش‌بینی می‌باشند.

شماره مدل	افق پیش‌بینی [ساعت]							
	۲۴	۲۱	۱۸	۱۵	۱۲	۹	۶	۳
۱	۸.۲۶	۷.۳۱	۷.۰۳	۷.۰۶	۷.۰۰	۶.۹۳	۶.۳۸	۴.۸۲
۲	۷.۹۵	۷.۱۱	۶.۸۲	۶.۷۶	۶.۷۰	۶.۷۵	۶.۳۲	۵.۰۰
۳	۸.۱۶	۷.۲۲	۶.۸۷	۶.۸۷	۶.۸۹	۶.۹۰	۶.۵۸	۵.۳۸
۴	۸.۲۳	۷.۳۷	۷.۱۰	۷.۰۷	۷.۰۳	۷.۰۴	۶.۷۵	۵.۶۹
۵	۸.۵۴	۷.۷۰	۷.۳۸	۷.۳۹	۷.۳۷	۷.۴۱	۷.۱۷	۶.۱۸
۶	۸.۸۲	۸.۰۴	۷.۷۸	۷.۷۳	۷.۶۹	۷.۷۰	۷.۴۶	۶.۵۷

اطلاعات محلی کافی بوده و افزودن داده‌های مکانی گسترده‌تر نه تنها مفید نیست، بلکه می‌تواند موجب افزایش نویز و کاهش دقت مدل شود. در مقابل، برای پیش‌بینی‌های بلندمدت، در نظر گرفتن تأثیرات فضایی از مناطق دورتری از نقطه‌ی پیش‌بینی، به مدل در درک روندهای گسترده‌تر کمک می‌کند.

همچنین، پایداری نسبی میزان خطای مدل در افق‌های مختلف زمانی، بدون نوسانات شدید، گویای تونلایی مدل در یادگیری الگوهای پایدار در داده‌های آموزشی است. این ویژگی می‌تواند در کاربردهای عملی که نیاز به پیش‌بینی‌های پیوسته و مطمئن دارند، حائز اهمیت باشد.

با توجه به یافته‌های این پژوهش، برای پیش‌بینی جریان‌ها سطحی دریایی در خلیج فارس در افق‌های زمانی حداکثر یک‌روزه، نیازی به در نظر گرفتن فضای وسیع برای ورودی مدل نیست. در اکثر مواقع، مدل شماره دو با استفاده از ورودی‌هایی با شعاع دو پیکسل مکانی (معادل شعاع ۱۶ کیلومتری)، به نتایج بهینه دست یافته است و استفاده از شعاع‌های بزرگتر معمولاً ضروری نمی‌باشد.

در مجموع، نتایج این پژوهش می‌تواند به طراحی مدل‌های پیش‌بینی مؤثرتر برای داده‌های فضازمان‌مند کمک کند، به‌ویژه در انتخاب بهینه شعاع مکانی داده‌های ورودی بر اساس افق زمانی پیش‌بینی و همچنین استفاده از کدگذاری زمانی در ورودی مدل برای بهبود دقت پیش‌بینی‌ها.

#### ۵- مراجع:

- 1- Siedler, G., Griefffies, S., Gould, J., & Church, J. (2013). *Ocean Circulation and Climate: A 21st Century Perspective*. Academic Press.
- 2- (WMO). (2015)
- 3- Unravelling ENSO complexity. (2023). *Nature Geoscience*, 16(2), 105. <https://doi.org/10.1038/s41561-023-01134-1>
- 4- Dohan, K. (2017). *Ocean surface currents from satellite data*. *Journal of Geophysical Research: Oceans*, 122(4), 2647–2651. <https://doi.org/10.1002/2017JC012961>
- 5- Bolaños, R., Sørensen, J. V. T., Benetazzo, A., Carniel, S., & Sclavo, M. (2014). *Modelling ocean currents in the northern Adriatic Sea*. *Continental Shelf Research*, 87, 54–72. <https://doi.org/10.1016/j.csr.2014.03.009>
- 6- Rahmstorf, S. (2003). *Thermohaline circulation: The current climate*. *Nature*, 421(6924), 699. <https://doi.org/10.1038/421699a>
- 7- Wen, J., Yang, J., Jiang, B., Song, H., & Wang, H. (2021). *Big data driven marine environment information forecasting: A time series prediction network*. *IEEE Transactions on Fuzzy Systems*, 29(1), 4–18. <https://doi.org/10.1109/TFUZZ.2020.3012393>

#### ۴- بحث و نتیجه‌گیری:

نتایج حاصل از این پژوهش نشان می‌دهند که مدل ترکیبی CNN-LSTM طراحی شده، عملکرد قابل قبولی در پیش‌بینی جریان‌ها دریایی در افق‌های زمانی مختلف ارائه داده است. استفاده از شبکه کانولوشنی برای استخراج ویژگی‌های مکانی، در کنار شبکه عصبی حافظه دار بلند مدت برای تحلیل الگوهای زمانی، به مدل این امکان را داده که روابط پیچیده فضازمان‌مند در داده‌ها را شناسایی و یادگیری کند. علاوه بر این، کدگذاری زمانی به صورت سینوسی و کسینوسی نقش مهمی در درک بهتر الگوهای چرخه‌ای مانند جزر و مد و تغییرات فصلی ایفا کرده است.

از تحلیل عملکرد مدل در افق‌های زمانی مختلف می‌توان نتیجه گرفت که افزایش شعاع مکانی ورودی به مدل، تنها در بازه‌های زمانی بلندمدت مفید واقع می‌شود. در افق‌های کوتاه‌مدت (مانند ۳ تا ۹ ساعت)، مدل‌هایی با شعاع مکانی کمتر عملکرد بهتری داشته‌اند. در حالی که در افق‌های طولانی‌تر (بیش از ۱۵ ساعت)، افزایش شعاع مکانی داده‌های ورودی موجب بهبود نتایج شده است. این یافته نشان می‌دهد که برای بازه‌های زمانی کوتاه،

- 8- Song, T., Pang, C., Hou, B., Xu, G., Xue, J., Sun, H., & Meng, F. (2023). *A review of artificial intelligence in marine science*. *Frontiers in Earth Science*, 11, Article 1090185. <https://doi.org/10.3389/feart.2023.1090185>
- 9- Xu, L., Chen, N., Chen, Z., Zhang, C., & Yu, H. (2021). Spatiotemporal forecasting in earth system science: Methods, uncertainties, predictability and Earth-Science Reviews, 222, Article 103828. <https://doi.org/10.1016/j.earscirev.2021.103828>
- 10- Durazo, R., & Baumgartner, T. R. (2002). *Evolution of oceanographic conditions off Baja California: 1997–1999*. *Progress in Oceanography*, 54(1), 7–31. [https://doi.org/10.1016/S0079-6611\(02\)00041-1](https://doi.org/10.1016/S0079-6611(02)00041-1)
- 11- Zandi, O., Zahraie, B., Nasser, M., & Behrangi, A. (2022). *Stacking machine learning models versus a locally weighted linear model to generate high-resolution monthly precipitation over a topographically complex area*. *Atmospheric Research*, 272(106159). <https://doi.org/10.1016/j.atmosres.2022.106159>
- 12- Bayindir, C. (2019). *Predicting the Ocean Currents using Deep Learning*. arXiv preprint. <https://arxiv.org/abs/1906.08066>
- 13- Baek, S.-S., Pyo, J., & Chun, J. A. (2022). *Prediction of Water Level and Water Quality Using*. <https://doi.org/10.3390/w12123399>