

Prediction of coastal berm changes in non-storm conditions using neural network

A. Jabari¹, M. Adjami^{*2}, S. Gharechelou²

1. Ph.D. Student of Coastal Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Shahrood, Iran.
2. Assistant Professor of Civil Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Shahrood, Iran.

Abstract

Coastal areas are among the most densely populated and developed regions globally. This is owing to high economic opportunities, maritime trade access, and a thriving tourism industry. These regions represent vulnerable environments facing threats such as storms and rising sea levels, predominantly stemming from human activities. Erosion stands out as one of the most pressing threats to these regions. It is crucial to continuously monitor these areas, record changes in beach profiles and shoreline alterations, and control erosion. This research looks into changes in the shoreline and coastal berm under non-storm conditions, employing machine learning algorithms to evaluate these phenomena in the Narrabeen coastal region of Australia. The Narrabeen-Collaroy embayment, spanning 3.6 kilometers, is located on the northern shores of Sydney. Narrabeen-Collaroy is among the most crucial databases in coastal engineering. Field data from the nearshore and coastal strip have been collected in this database from 1976 to 2019. Therefore, data related to storm profiles have not been considered (a condition that requires at least one profile to remain in each month). Based on this criterion, out of the 960 recorded profiles, 73 profiles were identified in severe storm conditions. Eventually, 887 profiles from 2006 to 2019 have been scrutinized. Initially, variations in the shoreline were investigated, focusing on the continuous area consistently interacting with waves. This region can play a significant role in evaluating the performance of models and algorithms. The geometric changes of the coastal berm, situated within the Shoreface zone, were investigated and analyzed. In this research, a wrapper backward future selection algorithm has been used to filter the effective parameters consisting of hydrodynamics and morphodynamics. Also, the objective functions include shoreline changes, variations in berm crest elevation, and the horizontal position of the berm crest. In this step, the parameters identified from the wrapper backward future selection algorithm, a feed-forward neural network algorithm was employed to predict the objective functions in the final stage. The values obtained from the neural network model for each of the three objective functions demonstrated an appropriate arrangement of parameters. When predicting shoreline changes in scenario DS4, including the wave-breaking index parameter led to more logical and acceptable outcomes compared to scenario DTS3; the resulting R^2 is 92% with an RMSE of 3.03 meters. Predicting variations of the berm crest elevation in scenario DY4 illustrates acceptable results: R^2 of 75% and RMSE of 0.35 meters. Furthermore, predicting the horizontal position of the berm crest in scenario DX7 shows that the wave-breaking index parameter, improved results compared to scenario DX6, the final results indicate an R^2 of 85.80% and an RMSE of 9.28 meters. To validate the obtained results, the differences in error between the objective function values and output data indicate that the selected scenarios predict data with minimal error. According to the results, it is crucial to accurately identify the relevant hydrodynamic and Morphodynamic parameters and correctly extracted them to achieve more precise predictions. Moreover, the results indicate that the neural network algorithm can accurately predict changes in beach morphology..

Review History

Received: Apr 30, 2024

Revised: Jul 01, 2024

Accepted: Jul 10, 2024

Keywords

Berm Crest

Shoreline Changes

Coastal Morphodynamic

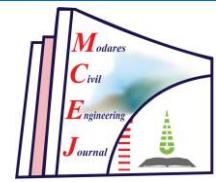
Non-Storm Condition

ANN Algorithm.

* Corresponding Author Email: adjami@shahroodut.ac.ir - ORCID: 0000-0002-0530-0411



Copyright © 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (<https://creativecommons.org/licenses/by-nc/4.0/>) which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.



پیش‌بینی تغییرات سکوی ساحلی در شرایط غیر طوفانی به کمک شبکه عصبی

امیر جباری^۱، مهدی عجمی^{۲*} [ID: ۱۰۲۵۰۳۱۱]، سعید قره چلو^۳

- دانشجوی دکتری، مهندسی عمران، دانشگاه صنعتی شهرود، شهرود، ایران.
- استادیار، مهندسی عمران، دانشگاه صنعتی شهرود، شهرود، ایران.
- استادیار، مهندسی عمران، دانشگاه صنعتی شهرود، شهرود، ایران.

تاریخچه داوری

دریافت: ۱۴۰۳/۰۲/۱۱

بازنگری: ۱۴۰۳/۰۴/۱۱

پذیرش: ۱۴۰۳/۰۴/۲۰

چکیده

فرسایش نواحی ساحلی از مهمترین عوامل مخرب این مناطق است که تحت تاثیر عوامل طبیعی و فعالیت‌های انسانی ایجاد می‌شود. این نواحی زیر مجموعه مناطق آسیب‌پذیر به شمار می‌آیند و بدین لحاظ نظارت و پایش مستمر آن‌ها اهمیت زیادی دارد. در این پژوهش ابتدا به کمک الگوریتم انتخاب ویژگی‌ها، دسته‌بندی پدیده‌های تأثیرگذار در ناحیه ساحلی نازاریین استرالیا در شرایط غیر طوفانی انجام شده است. در ادامه به کمک الگوریتم شبکه عصبی، پیش‌بینی توابع هدف شامل؛ تغییرات خط ساحل، تغییرات قائم و موقعیت افقی تاج سکوی ساحلی انجام گرفته است. در مرحله اول برای رسیدن به یک مدل مناسب، ابتدا حساسیت سنجی مدل برای رسیدن به بهترین هایپر پارامترها برای پیش‌بینی تغییرات خط ساحل انجام گرفته است که نتایج حاصل از سناریو انتخابی، مقدار خطای RMSE را ۳/۰۳ متر و R^2 را ۹۲٪ نشان می‌دهد. سپس به کمک مدل نهایی بدست آمده در مرحله قبل، نتایج پیش‌بینی تغییرات ارتفاعی سکوی ساحلی در سناریو منتخب، خطای RMSE را ۰/۳۵ متر و R^2 را ۷۵٪ نشان می‌دهد. همچنین نتایج حاصل از پیش‌بینی موقعیت افقی تاج سکوی ساحلی در سناریو منتخب، خطای RMSE را ۰/۲۸ متر و R^2 را ۸۵٪ نشان می‌دهد. جمع‌بندی نتایج نشان می‌دهد که دسته بندی پارامترهای بدست آمده از مدل انتخاب ویژگی کمک زیادی برای دستیابی به نتایج قابل قبول در مدل شبکه عصبی نموده است و همچنین نتایج شبکه عصبی برای پیش‌بینی مورفو دینامیک ساحلی، مناسب و قابل اعتماد است.

۱- مقدمه

در مطالعه خود در سواحل غربی آفریقا نشان دادند که اجرای سیستم منطقه‌بندی و پایش منظم سواحل می‌تواند رویکردی پایدار برای مدیریت نواحی ساحلی ایجاد نماید [۱]. پوپلامپو و همکاران با بررسی سواحل شرقی غنا دریافتند که؛ نرخ فرسایش در این مناطق بسیار بالا بوده و نظارت مستمر به همراه استراتژی‌های مبتنی بر اکوسیستم برای دستیابی به مدیریت پایدار ساحلی ضروری است [۲]. احمد و همکاران پایش میزان فرسایش در بخش‌هایی از سواحل هند را به کمک تصاویر ماهواره‌ای برای مدیریت صحیح این نواحی توصیه نموده‌اند [۳]. همچنین بیگ و همکاران نیز پایش و مدیریت سواحل شرقی بنگلا دش برای کنترل فرسایش را ضروری ارزیابی نمودند [۴]. زولینی و همکاران

مناطق ساحلی عموماً به دلیل وجود فرصت‌های اقتصادی بالا، دسترسی به تجارت حمل و نقل دریایی و صنعت توریسم، از پرجمعیت‌ترین و توسعه یافته ترین مناطق در جهان به شمار می‌روند. این مناطق با تهدیداتی از قبیل فرسایش، طوفان‌ها و افزایش تراز آب دریا مواجه هست که بخشی از این تهدیدات نتیجه فعالیت‌های انسانی بوده و از مهمترین تهدیدات این نواحی فرسایش است. بدین جهت نظارت مستمر بر این نواحی از قبیل ثبت تغییرات نیمرخ‌های ساحلی، تغییرات خط ساحل و لزوم کنترل فرسایش اهمیت زیادی دارند. در این زمینه پژوهش‌های متعددی انجام گرفته که در ادامه بررسی می‌شوند. آلوز و همکاران

* ریانه نویسنده مسئول: ORCID – adjami@shahroodut.ac.ir

Creative Commons Attribution-NonCommercial 4.0 International License. این مقاله به صورت دسترسی آزاد منتشر شده و تحت مجوز بین‌المللی (TMU Press). این مقاله بر اساس این مجوز، شما می‌توانید این مطلب را در هر قالب و رسانه‌ای کپی، بازنگری و بازآفرینی کنید و با آن را ویرایش و بازسازی نمایید، به شرط آنکه نام نویسنده را ذکر کرده و از آن برای مقاصد غیرتجاری استفاده کنید.



عملکرد بهتری نسبت به روش‌های دیگر برای مجموعه داده‌های آزمایشی با امواج نرمال دارد [15]. یین و همکاران، نظارت بر تغییرات خط ساحل در منطقه نهاترانگ را به کمک سه مدل، میانگین متحرک یکپارچه، شبکه عصبی رگرسیونی و حافظه کوتاه مدت طولانی، با مدل تابع متعامد تجربی مقایسه نمودند و در نهایت هر سه مدل از مدل تجربی بهتر عمل نموده و به کمک دوربین‌های نظارتی در شرایط آب و هوایی شدید بسیار موثر عمل می‌کنند [16]. بلینگ هاووزن و همکاران نیز به کمک الگوریتم جنگل تصادفی، شرایط حاد دریا در سواحل بالتیک را به مدت ۳ روز با نتایج قابل قبولی پیش‌بینی نمودند و نتیجه گرفتند که از این الگوریتم می‌توان به عنوان سیستم هشدار وضعیت حاد دریایی کمک گرفت [17]. همچنین مقالات مروری مرتبط با کاربردهای یادگیری ماشین در فرآیندهای ناحیه ساحلی نیز توسط دیگر پژوهشگران ارائه شده است [18 و 19]. تحقیقات مشابه دیگری نیز به کمک الگوریتم‌های یادگیری ماشین انجام گرفته است [20 تا 26].

وجود مجموعه داده‌های غنی و درازمدت می‌تواند به رشد و توسعه بهتر الگوریتم‌های یادگیری ماشین کمک نماید. در این راستا پایگاه‌های متعددی در نقاط مختلف دنیا جهت ثبت داده‌های مورفودینامیک، هیدرودینامیک و پایش ساحل در حال فعالیت هستند که سواحل ماسه‌ای نارابین، سن دیگو و ... زیر مجموعه آن‌ها هستند. بیوزن و همکاران در پژوهشی در ساحل نارابین، سه روش اصلی گستته سازی (دستی، بدون نظارت و نظارت شده) را در شبکه بیزین برای پیش‌بینی فرایش ساحل مقایسه نمودند. نتایج نشان داد که روش‌های نظارت شده بالاترین مهارت پیش‌بینی و به دنبال آن روش‌های دستی و بدون نظارت قرار دارند [27]. پژوهش دیگری توسط بیوزن و همکاران بر تغییرات خط ساحلی نارابین انجام گرفت که از رویدادهای طوفانی توسط الگوریتم بیزین برای پیش‌بینی بهره بردن. نتایج نشان داد که مدل بیزین توانایی مناسبی برای پیش‌بینی فرآیندهای پیچیده ساحلی دارد. همچنین مقادیر خروجی در بخش پیش‌بینی دارای ۳ پارامتر و مهارت ۶۵٪ در مشاهده داده‌ها ارائه نموده است [28]. زینلی و همکاران در تحقیقات خود در ساحل نارابین دریافتند که استفاده از شبکه‌های عصبی مصنوعی نارنت و نارکس نت می‌تواند عملکرد قابل اعتمادی را برای پیش‌بینی تغییرات خط ساحل با تعداد پارامترهای کمتر ارائه دهد [29]. هارلی و همکاران مجموعه

در مطالعه خود نشان داد که الگوریتم Dynamic J-Net ابزاری قدرتمند برای استخراج دقیق خط ساحل بوده و به مدیریت بهتر مناطق ساحلی کمک می‌نماید [5]. همچنین در تحقیقات دیگر، استفاده از سازه‌های حفاظتی را یکی از اقدامات موثر برای کنترل فرسایش معرفی می‌نمایند [6 و 7]. فرناندز مونتبلانک و همکاران در بررسی‌های خود دریافتند که؛ بازسازی تپه‌های ساحلی به کمک افزایش بودجه رسوبی اقدامی موثر برای کاهش فرسایش و خطرات ناشی از آن در ساحل بلوکیو ایتالیا هست که از آن به عنوان یک راه حل مناسب برای مقابله با افزایش تراز آب دریا در آینده نیز می‌توان بهره برد [8]. فلور بلانکو و همکاران، تغییرات ژئومورفولوژی سواحل آستوریاس اسپانیا را از سال ۱۹۹۲ تا ۲۰۱۴، مورد ارزیابی قرار دادند. نتایج نشان داد که افزایش رویدادهای طوفانی قدرتمند، اصلی ترین کاتالیزور برای فرسایش شدید تپه‌های ساحلی هست [9]. در مطالعه‌ای دیگر لمکه و میلس به نقش شدت طوفان و آسیب‌پذیری سواحل در کنترل فرسایش تپه‌ها پرداخته‌اند و دریافتند که پیک شدت فرسایش مهمترین پارامتر تغییرات در تپه‌های ساحلی است [10]. هارلی و همکاران در مطالعه خود روی سه مجموعه از داده‌های بازیابی شده طوفان‌های شدید در مناطقی از استرالیا، بریتانیا و مکزیک نشان دادند که؛ اطلاعات کم از بودجه رسوبی کوتاه مدت طوفان‌های شدید، پارامتر مهمی برای افزایش اطمینان در پیش‌بینی‌های خط ساحل هست [11]. ژنگ و همکاران نیز اهمیت در نظر گرفتن فرآیندهای ناشی از امواج مانند: جریان، چولگی، عدم تقارن و آثار شبی بستر را برای پیش‌بینی دقیق حمل رسوبات معرفی نمودند [12]. مطالعات دیگری نیز در زمینه انتقال رسوب و کنترل فرسایش نواحی ساحلی انجام گرفته است [13 و 14].

گسترش علم یادگیری ماشین و همچنین توسعه الگوریتم‌ها در کنار تحقیقات آزمایشگاهی، میدانی و عددی، کمک شایانی به شناخت هرچه بیشتر نواحی ساحلی نموده است. سایت‌های علمی تحقیقاتی زیادی در زمینه جمع‌آوری دراز مدت داده‌های محیطی و میدانی در مناطق ساحلی هلند، انگلستان، آمریکا، استرالیا و ... در حال فعالیت هستند که طی سال‌های اخیر به شکل گیری مطالعات ارزشمندی توسط پژوهشگران در حوزه علوم سواحل کمک نموده‌اند. دن بیمان و همکاران؛ مدل یادگیری ماشین جدیدی بنام XGBoost را برای پیش‌بینی روگذری موج متوسط ارائه نمودند که

کولاروی در بخش جنوبی این منطقه قراره گرفته است. دانه‌بندی منطقه در امتداد ساحل تقریباً یکنواخت بوده و ماسه کوارتز ریز تا متوسط ($D_{50} \approx 0.3$ میلی‌متر) می‌باشد. در شکل (۲) موقعیت این ساحل در کشور استرالیا، موقعیت نیمرخ‌های عرضی و بویه آب عمیق آن محدوده نشان داده شده است.

شکل ۲. نارابین-کولاروی، نیمرخ‌های عرضی و موقعیت بویه [31]




Fig. 2. Narrabeen – Collaroy, the position of Cross-shore profiles and deep-water buoy [31]

در این پایگاه از سال ۱۹۷۶ تا پایان ۲۰۱۹ میلادی داده‌های میدانی در ناحیه کم عمق و نوار ساحلی جمع آوری شده است [31]. کارهای تحقیقاتی دیگری نیز بر اساس داده‌های این پایگاه انجام گرفته است [32 و 33].

نیمرخ‌های عرضی در ۵ خط با فواصل ۹۰۰ متر از یکدیگر قرار گرفته و اندازه‌گیری‌ها با دقیقت ۱ متر انجام گرفته است. در شکل (۲) موقعیت نیمرخ‌های عرضی ۱، ۲، ۴، ۶ و ۸ نشان داده شده است. در این پژوهش برای به حداقل رساندن میزان خطأ، همچنین تغییر در الگوی خطوط ارتوگونال در بخش شمالی و جنوبی محدوده به دلیل وجود دماغه‌های صخره‌ای^۲، فقط نیمرخ‌های شماره ۲، ۴ و ۶ مورد استفاده قرار گرفته‌اند. نیمرخ‌های عرضی ساحل نارابین از داده‌های اویله استخراج شده و در شکل (۳) نشان داده شده‌اند.

بزرگی از داده‌های فرسایش ناشی از طوفان را ارائه نموده‌اند. این مجموعه شامل ۲۷۶ رویداد طوفانی در ساحل نارابین-کولاروی می‌باشد که به کمک مدل رگرسیون چندخطی پیش‌بینی دقیق فرسایش ناشی از طوفان را ارائه می‌دهد [30].

با جمع‌بندی تحقیقات انجام گرفته تاکنون، تمرکز عملده تحقیقات روی مطالعات مورفودینامیکی ساحل در شرایط طوفانی بوده است. با این حال یکی از شاخص‌های مهم در شناخت رفتار ساحل، وضعیت آن در شرایط غیر طوفانی یا پیش و پس از طوفان است (ازوماً رفتار تعادلی مد نظر نیست). هدف از این پژوهش بررسی تغییرات خط ساحل و موقعیت سکوی ساحلی در شرایط غیر طوفانی است که به کمک الگوریتم‌های یادگیری ماشین پیش‌بینی روی این عوارض در منطقه ساحلی نارابین استرالیا انجام می‌گیرد. ابتدا به کمک روش‌های انتخاب ویژگی، پارامترهای مناسب برای انجام پیش‌بینی انتخاب و سپس به کمک الگوریتم شبکه عصبی پیش‌بینی توابع هدف انجام می‌گیرد. در فلوچارت شکل (۱) خلاصه مراحل این پژوهش نشان داده شده است.

شکل ۱. فلوچارت مراحل پژوهش




Fig. 1. Flowchart of the research methodology

۲- مواد و روش‌ها

۱-۱- منطقه مورد مطالعه

منطقه نارابین-کلاروی^۱ به طول ۳,۶ کیلومتر در سواحل شمالی سیدنی واقع شده است. ساحل نارابین در بخش شمالی و ساحل

² Headlands

¹ Narrabeen-Collaroy

متر بوده و پریود حداکثر در محدوده ۳/۲۴ تا ۱۸/۶۲ ثانیه است. امواج با نزدیک شدن به ساحل دچار پدیده انکسار شده و خطوط اورتوگونال آن بر خط ساحل عمود می‌شوند. این پدیده موجب تغییراتی در مشخصات امواج از آب عمیق به کم عمق می‌شود. بدین شکل مطلوب است داده‌های امواج نزدیک به موقعیت برداشت پروفیل‌ها و در راستای هر پروفیل در نظر گرفته شوند. برای انتقال داده‌های امواج از آب عمیق به کم عمق، از مدل کد باز SWAN استفاده شده است که داده‌ها را از عمق ۸۰ متری به عمق ۱۰ متری و در راستای هر پروفیل منتقل می‌کند. این مدل برای ساحل مورد بررسی، ارزیابی و درستی آزمایش شده است. همچنین داده‌های تغییرات تراز دریا، در بازه سال‌های ۲۰۰۶ تا ۲۰۱۹ از پایگاه داده‌ای AVISO استخراج شده است [35]. در شکل (۵) سری زمانی تغییرات تراز سطح دریا مشاهده می‌شود. پیش از ژانویه ۲۰۱۳ نرخ افزایش تراز کمتر و پس از آن رو به افزایش است.

هدف از این پژوهش بررسی تغییرات مورفودینامیک ساحل در شرایط غیرطوفانی می‌باشد. روند تشخیص نیمرخ‌های طوفانی بدین شکل است که ابتدا با شناسایی نیمرخ‌هایی که سکوی ساحلی آن‌ها حذف شده بود (مقایسه با نیمرخ تعادلی دین) را انتخاب نموده سپس تغییرات ارتفاع امواج در بازه ۴۸ ساعت تا قبل از برداشت نیمرخ رجوع شد. پس از بررسی تغییرات ارتفاع امواج در این محدوده زمانی مشخص شد که ارتفاع امواج در محدوده زمانی مشخص افزایش قابل توجهی در مقایسه با شرایط نرمال داشته‌اند. همچنین این شرایط در بررسی تغییرات سرعت باد در همان محدوده زمانی مشخص شد. در انتها برای کنترل نهایی، با نیمرخ‌های طوفانی مستخرج از تصاویر آرگوس پژوهش آغازی بیوزن و همکاران کنترل نهایی انجام شد [28]. بر این اساس از ۹۶۰ نیمرخ ثبت شده، ۷۳ نیمرخ در موقعیت شرایط حاد طوفانی شناسایی شد. در نهایت ۸۸۷ نیمرخ در بازه سال‌های ۲۰۰۶ تا ۲۰۱۹ بررسی شده است. به طورکلی در هر ماه حداقل یک نیمرخ برداشت شده و در بعضی ماه‌ها ۴ یا ۵ نیمرخ نیز برداشت شده که زمان تمامی آن‌ها متفاوت است. لازم به ذکر است که ملاک انتخاب نیمرخ غیرطوفانی پس از اتمام طوفان لحاظ شده است. اما اگر نیمرخی در روند بازسازی پس از طوفان بوده و شرایط محیطی نشان دهنده طوفان نباشد آن نیمرخ در بررسی‌ها لحاظ شده است.

شکل ۳. نیمرخ‌های شماره ۲، ۴ و ۶ ساحل نارابین استرالیا در بازه سال‌های ۲۰۰۶ - ۲۰۱۹




Fig. 3. Bath profiles No. 2, 4, and 6 of the Narrabeen coast

این ساحل در قسمت شمالی دارای تپه‌های سنی تا ارتفاع ۹ بالاتر از سطح دریا به همراه پوشش گیاهی می‌باشد. در بخش جنوبی با توسعه شهری به سمت ساحل از ارتفاع این تپه‌ها و پوشش گیاهی آن کاسته شده و به ۳ تا ۴ متر می‌رسد. این ساحل یکی از پایگاه‌های مهم داده‌ای در مهندسی سواحل می‌باشد.


۲-۲- طبقه‌بندی داده‌ها

در سایت تحقیقاتی نارابین – کولاروی داده‌های مرتبط با مطالعات مهندسی سواحل به طور پیوسته در بازه سال‌های ۲۰۰۶ تا ۲۰۱۹ میلادی جمع آوری شده است. همچنین داده‌های امواج در محل بویه آب عمیق نشان داده شده در شکل (۲)، از مرکز پیش‌بینی آب و هوای اروپا^۱ و مجموعه داده ERA5 استخراج شده و بازه زمانی آنها یک ساعه هست [34]. در شکل (۴ الف و ب)، به ترتیب سری زمانی ارتفاع موج مشخصه و پریود موج حداکثر نمایش داده شده است. مجموعاً ۱۲۲۷۱۲ داده موج در نظر گرفته شده است. کمترین و بیشترین ارتفاع امواج به ترتیب ۰/۴۸ و ۶/۵۶

^۱ European Centre for Medium-Range Weather Forecasts


شکل ۴. داده‌های امواج در محل بویه آب عمیق، بازه سال‌های ۲۰۰۶ تا ۲۰۱۹ [34]

الف) سری زمانی ارتفاع موج مشخصه در محل بویه آب عمیق



a) Time series of significant wave height at deep water buoy location

ب) سری زمانی پریود موج حداکثر در محل بویه آب عمیق



b) Time series of peak wave period at deep water buoy location

Fig.4. The wave parameters at deep water buoy location, years 2006 to 2019 [34]

شکل ۵. سری زمانی تغییرات تراز آب دریاها در بازه سال‌های ۲۰۰۶ تا ۲۰۱۹ [35]





Fig. 5. Time series of sea level rise changes, years 2006 to 2019 [35]

هیدرودینامیک مورد نظر استخراج شده است. داده‌های هیدرودینامیک شامل؛ اطلاعات امواج و تغییرات تراز سطح دریا و داده‌های مورفودینامیک از نیمرخ‌های اندازه‌گیری شده مستخرج شده‌اند و در شکل (۶) نشان داده شده است.

در ادامه ابتدا تغییرات خط ساحل مورد بررسی قرار گرفته است؛ این محدوده ناحیه‌ای است که بطور پیوسته در مقابل با امواج قرار دارد. پس از آن، تغییرات هندسی سکوی ساحلی مورد بررسی و قرار گرفته که موقعیت آن در محدوده پیشانی ساحل قرار دارد. پس از آماده‌سازی داده‌های اولیه، پارامترهای مورفودینامیک و

شکل ۶. شماتیک نیمرخ ساحلی به همراه پارامترهای هیدرودینامیک و مورفودینامیک



Hydrodynamic Parameters					
Parameters	Definition	Parameters	Definition	Parameters	Definition
Hs	Significant wave Height	Tp	Peak Wave Period	SLR	Sea Level Rise
Hmean	Mean Wave Height	E	Wave Energy	H/L	Wave Steepness
Hmax	Maximum Wave Height	P	Wave Power	L	Wave Length
Tmean	Mean Wave Period	ζ	Iribarren		
Morphodynamic Parameters					
Parameters	Definition	Parameters	Definition	Parameters	Definition
BW	Berm Width	DT Height	Dune Toe Height	Δx_{DT}	Horizontal changes of Dune Toe
ΔBW	Berm Width Changes	Δy_{DT}	Dune Toe Height Changes	$\Delta x_{Shoreline}$	Shoreline changes
Berm Slope	Slope between Shoreline and Berm Crest	Δy_{BC}	Berm Crest Height Changes	Xloc DT	Horizontal position of Dune Toe
Beach Slope	Slope between Shoreline and Dune Toe	Xloc BC	Horizontal position of Berm Crest		
BC Height	Berm Crest Height	Δx_{BC}	Horizontal changes of Berm Crest		

Fig. 6. Schematic of beach profile along with Hydrodynamic and Morphodynamic parameters

این الگوریتم، روش لونبرگ - مارکوارت^۳ است. این روش یکی از قدرتمندترین روش‌ها برای آموزش شبکه‌های عصبی چندلایه بوده که از ترکیب الگوریتم‌های گرادیان نزولی و گاوس - نیوتون ساخته شده است [38].

۲-۳- معیارهای ارزیابی (خطاهای)

استفاده از روش‌های مقایسه‌ای بین نتایج خروجی و مقادیر واقعی توابع هدف، درک بهتر و واضح‌تری از تحلیل نتایج را ارائه می‌دهد. جذر میانگین مربعات خطأ (RMSE) حاصل از جذر MSE، یکی از پرکاربردترین معیارها است که هم در آموزش و هم در مقایسه مدل‌ها استفاده می‌شود. دلیل استفاده از آن، یکسان بودن بعد و مقیاس آن با ویژگی هدف است. همچنین معیار ضریب تعیین یا امتیاز (R^2)، برای مقایسه مدل‌ها و گزارش نتایج استفاده می‌شود. محاسبه خطاهای و معیار ضریب تعیین به ترتیب مطابق با معادلات ۱ و ۲ هست:

۳- الگوریتم‌های یادگیری ماشین

در این پژوهش برای کاهش ابعاد مساله و همچنین فیلتر نمودن اولیه پارامترهای موثر، از روش‌های انتخاب ویژگی رو به عقب^۱ استفاده شده است. همچنین برای پیش‌بینی توابع هدف از الگوریتم شبکه عصبی کمک گرفته شده است.

۳-۱- شبکه عصبی مصنوعی (پیش‌بینی)

از شبکه‌های عصبی مصنوعی عموماً برای حل مسائل مرتبط با دسته‌بندی (Classify)، خوشه‌بندی (Clustering) و رگرسیونی (Regression) استفاده می‌شود که یکی از رایج‌ترین آن‌ها، شبکه عصبی پیشخور^۲ است. این شبکه از چندین لایه متوالی (MLP) تشکیل شده است که هر لایه خروجی خود را در قالب بردار به لایه بعد منتقل می‌کند. در این مدل، جریان داده‌ها فقط به صورت یک طرفه اتفاق می‌افتد [36 و 37]. یکی از روش‌های حل مسئله در

³ Levenberg-Marquardt

¹ Wrapper Backward Feature Selection

² Feed-Forward Network

آموزش، ۱۰٪ از داده‌ها (شامل ۸۹ نیمرخ) برای ارزیابی و ۲۵٪ از داده‌ها (شامل ۲۲۲ نیمرخ) به تست اختصاص داده شد. تعداد لایه‌های پنهان (نورون) عدد ۱۰ در نظر گرفته شد و روش حل مساله در الگوریتم شبکه عصبی نیز لوبرگ – مارکوارت انتخاب شد. در جدول (۲) ترکیب پارامترهای هر سناریو نشان داده شده است. برای هر سناریو ۳۰ مرتبه آزمایش انجام گرفته و میانگین نتایج با قابلیت اعتماد بیش از ۹۰٪ ارائه شده است. بر این اساس نتایج حاصل از سناریوهای DS1 تا DS6 در شکل‌های (۷) و (۸) و خلاصه نتایج آنها در جدول (۳) و شکل (۹) آورده شده است. شکل (۷) نمودار بهینه‌ترین مدل بر اساس عدد پیچیدگی مدل (Epoch) و مقدار MSE برای هر سناریو است. به عبارتی خطای طول زمان یا تعداد دوره‌های آموزش، به ما نشان می‌دهد که مدل یادگیری ماشین به چه اندازه خوب یا بد عمل می‌کند کاهش خطای طول زمان یا تعداد دوره‌های آموزش را در شکل (۸) نیز نمودار R^2 مربوط به داده‌های آموزش و تست برای هر سناریو نشان داده شده که به عنوان یک معیار ارزیابی کمک می‌کند تا بفهمیم مدلی که آموزش داده‌ایم چقدر خوب عمل می‌کند و چه میزان داده‌ها را توانسته توضیح دهد. جمع‌بندی نتایج هر دو شکل در جدول (۳) و شکل (۹) آورده شده است.

جدول ۲. سناریوهای ساخته شده به کمک الگوریتم انتخاب ویژگی‌ها جهت

پیش‌بینی تغییرات خط ساحل

Scenarios	Effective Parameters
DS1	ΔBW
DS2	ΔBW - Berm Slope
DS3	ΔBW - Berm Slope - SLR
DS4	ΔBW - Berm Slope - SLR - ζ
DS5	ΔBW - Berm Slope - SLR - ζ - P
DS6	ΔBW - Berm Slope - SLR - ζ - P - H_{max}

Table 2. Creating scenarios with feature selection algorithms to predict shoreline changes

جدول ۳. خلاصه نتایج پیش‌بینی سناریوهای منتخب تغییرات خط ساحل DS1 تا DS6

Scenario	RMSE (Train)	R^2 (Train)	RMSE (Test)	R^2 (Test)
DS1	3.03	93.30	3.96	86.70
DS2	2.96	93.20	3.27	91.80
DS3	2.83	94.00	3.56	91.30
DS4	2.78	94.30	3.03	92.00
DS5	2.69	93.90	3.25	92.50
DS6	2.73	94.10	3.47	92.10

Table 3. Summary of the results of scenarios DS1 to DS6 for predicting shoreline changes

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2)$$

در معادلات بالا n تعداد داده‌ها، x_i مقادیر مشاهده شده، y_i مقدار پیش‌بینی شده و \bar{x} میانگین داده‌های مشاهداتی هستند.

۴- آنالیز داده‌ها و تحلیل نتایج

استفاده از پارامترهای نامناسب در الگوریتم‌های یادگیری ماشینی می‌تواند زمان محاسبات را افزایش داده و منجر به یادگیری بر پایه داده‌های کم ارتباط و یا نامناسب شود. بدین لحاظ انتخاب پارامترهای تاثیرگذار به کمک الگوریتم‌های انتخاب ویژگی به پیش‌بینی دقیق‌تر کمک می‌نماید. به کمک این روش‌ها پارامترهایی که تاثیر کمتری بر بهبود نتایج پیش‌بینی داشته و یا منجر به افزایش هزینه محاسبات می‌شوند، از مجموعه پارامترها حذف شدند. تمامی پارامترهای اولیه در شکل (۶) نشان داده شده است. مطابق با جدول (۱) پارامترهای مناسب انتخابی پس از فیلتر اولیه، به تفکیک توابع هدف نشان داده شده است.

جدول ۱. پارامترهای محیطی موثر برای پیش‌بینی توابع هدف

Group Parameters	Parameters	Targets
Morphodynamic	ΔBW - Berm Slope - Δx BC	Δx
Hydrodynamic	H_{Mean} - H/L - E - P - ζ - SLR Berm Crest Height - Δx	Shoreline
Morphodynamic	Shoreline - Δx BC - Berm Slope - BW	Δy BC
Hydrodynamic	H_{Mean} - P - ζ - SLR - L Berm Crest Height - Δx	
Morphodynamic	Shoreline - Δy BC - Berm Slope - BW	XLoc BC
Hydrodynamic	H_{Mean} - P - ζ - SLR - E	

Table 1. Effective environmental parameters to predict target functions

۴-۱- پیش‌بینی توابع هدف

تغییرات خط ساحل: در این بخش به کمک الگوریتم شبکه عصبی پیشخور، نتایج بدست آمده از الگوریتم انتخاب ویژگی، سناریوهای DS1 تا DS6 برای پیش‌بینی تغییرات خط ساحل ساخته شده است. پس از ساخت مدل اولیه و انجام آزمایش‌های متعدد، برای رسیدن به نتایج تثیت شده و قابل اتکا، پیش‌بینی تغییرات خط ساحل (شامل ۵۷۶ نیمرخ) برای

¹ Iribarren

شکل ۷. نمودارهای بهینه‌ترین مدل بر اساس Epoch و MSE در سناریو های منتخب تغییرات خط ساحل DS1 تا DS6





Fig.7. The optimal model based on the Epoch and the MSE for scenarios DS1 to DS6 in shoreline changes

شکل ۸ نمودارهای R^2 داده های آموزش و تست در سناریو های تغییرات خط ساحل DS1 تا DS6Fig. 8. Graphs of $R^2\%$ results of training and test for scenarios DS1 to DS6 on shoreline changes

شکل ۹. نمایش خلاصه نتایج آموزش و تست در سناریوهای منتخب پیش‌بینی تغییرات خط ساحل DS6 تا DS1




Fig. 9. Summary of the results of training and test in scenarios DS1 to DS6 in shoreline changes chart A shows training data and chart B test data

به همراه پارامترهای تغییرات عرض سکوی برم، شبیه برم، تراز سطح دریا و اندیس شکست موج به عنوان سناریو نهایی برای پیش‌بینی مناسب تغییرات خط ساحل با مقادیر RMSE ۰/۳۰۳ متر و R^2 ۹۲٪ نتایج قابل قبولی را ارائه نموده است.

تغییرات ارتفاعی تاج سکوی ساحلی: در این بخش پیش‌بینی روی تغییرات ارتفاعی تاج سکوی ساحلی انجام گرفته است که ساختار مدل پیش‌بینی مشابه با بخش تغییرات خط ساحل لحاظ شده است. همچنین مطابق با پارامترهای بدست آمده از الگوریتم انتخاب ویژگی، سناریوهای DY1 تا DY6 مطابق با جدول (۴) ساخته شده‌اند. بر اساس نتایج بدست آمده، در شکل (۱۰) نمودار بهینه‌ترین مدل بر اساس عدد Epoch و مقدار MSE، شکل (۱۱) نمودار R^2 مربوط به داده‌های آموزش و آزمایش برای هر سناریو و خلاصه نتایج هر دو شکل در جدول (۵) و شکل (۱۲) آورده شده است.

مطابق با شکل (۹)، در نمودار A (داده‌های آموزش)، روند تغییرات RMSE با شبیه نسبتاً کم و نزولی بوده همچنین روند تغییرات R^2 نیز با اختلاف مقادیر کم تا سناریو DS4 صعودی است. به طور کلی اختلاف معناداری در مقایسه سناریوها مشاهده نشده است. در نمودار B (داده‌های آزمایش) نیز تغییرات خطای RMSE با شبیه ملایم تا سناریو DS4 روند نزولی گرفته و تغییرات R^2 نیز روند نسبتاً صعودی دارد و پیش‌بینی بهتری نیز در سناریو DS4 بدست آمده است. کاهش میزان خطای در سناریو DS4 در مقایسه با سناریو DS3 به میزان ۱۷٪ و در مقایسه با سناریو DS5 به میزان ۷٪ کاهش در خطای مشاهده می‌شود. همچنین در مقادیر R^2 اختلاف معناداری بین سناریوهای DS5 تا DS3 مشاهده نمی‌شود. در آزمایش‌های انجام گرفته و با بررسی نتایج مشخص می‌شود که؛ هیچ‌گونه بیش‌برازش یا کم‌برازشی برای سناریوهای DS6 تا DS1 رخ نداده است. به عنوان نتیجه گیری کلی در این بخش سناریو DS4 رخ نداده است.

جدول ۴. سناریوهای ساخته شده به کمک الگوریتم انتخاب ویژگی‌ها جهت پیش‌بینی تغییرات ارتفاعی تاج سکوی ساحلی

Scenario	Effective Parameters
DY1	Berm Crest Height
DY2	Berm Crest Height - Δx Shoreline
DY3	Berm Crest Height - Δx Shoreline - Δx_{BC}
DY4	Berm Crest Height - Δx Shoreline - Δx_{BC} - P
DY5	Berm Crest Height - Δx Shoreline - Δx_{BC} - P - H_{mean}
DY6	Berm Crest Height - Δx Shoreline - Δx_{BC} - P - H_{mean} - SLR


Table 4. Creating scenarios with feature selection algorithms to predict berm crest elevation variation

جدول ۵. خلاصه نتایج پیش‌بینی سناریوهای منتخب تغییرات ارتفاعی تاج سکوی ساحلی DS6 تا DS1


Scenario	RMSE (Train)	R^2 (Train)	RMSE (Test)	R^2 (Test)
DY1	0.48	55.50	0.46	45.93
DY2	0.46	51.86	0.52	55.38
DY3	0.33	80.27	0.38	73.97
DY4	0.33	80.81	0.35	74.33
DY5	0.32	81.45	0.40	73.80
DY6	0.33	82.10	0.37	70.13

Table 5. Summary of the results of scenarios DY1 to DY6 for predicting the berm crest elevation variation

شکل ۱۰. نمودارهای بهینه‌ترین مدل بر اساس Epoch و مقدار MSE در سناریو های منتخب تغییرات ارتفاعی تاج سکوی ساحلی DY1 تا DY6

**Fig 10.** The optimal model based on the Epoch and the MSE for scenarios DY1 to DY6 in the berm crest elevation variation

شکل ۱۱. نمودارهای $R^2\%$ داده های آموزش و تست در سناریو های منتخب تغییرات ارتفاعی تاج سکوی ساحلی DY1 تا DY6

**Fig 11.** Graphs of $R^2\%$ results of train and test for scenarios DY1 to DY6 in the berm crest elevation variation




Fig. 12. Summary of the results of training and test in scenarios DY1 to DY6 for berm crest elevation variation chart A shows training data and chart B test data

مطابق با پارامترهای بدست آمده از الگوریتم انتخاب ویژگی، سناریوهای DY1 تا DX7 مطابق با جدول (۶) ساخته شده اند. نتایج حاصل در شکل های (۱۴، ۱۳) و خلاصه نتایج آنها در جدول (۷) و شکل (۱۵) آورده شده است. در شکل (۱۳) نمودار برای بهینه‌ترین مدل بر اساس معیار پیچیدگی مدل و مقدار MSE برای هر سناریو نشان داده شده است. در شکل (۱۴) نیز نمودار برآیند R² برای هر سناریو نشان داده شده است.

جدول ۶. سناریوهای ساخته شده به کمک الگوریتم انتخاب ویژگی ها جهت پیش‌بینی موقعیت افقی تاج سکوی ساحلی

Scenario	Effective Parameters
DX1	BW
DX2	BW - Berm Slope
DX3	BW - Berm Slope - ΔyBC
DX4	BW - Berm Slope - ΔyBC - Berm Crest Height
DX5	BW - Berm Slope - ΔyBC - Berm Crest Height - E
DX6	BW - Berm Slope - ΔyBC - Berm Crest Height - E - SLR
DX7	BW - Berm Slope - ΔyBC - Berm Crest Height - E - SLR - ζ

Table 6. Creating scenarios with feature selection algorithms to predict the horizontal position of the berm crest

جدول ۷. خلاصه نتایج پیش‌بینی سناریوهای منتخب موقعیت افقی تاج سکوی ساحلی DX1 تا DX7

Scenario	RMSE (Train)	R ² (Train)	RMSE (Test)	R ² (Test)
DX1	11.17	79.50	11.90	72.00
DX2	11.05	79.06	11.45	78.60
DX3	10.60	81.00	10.94	79.00
DX4	10.00	83.30	10.84	79.90
DX5	9.75	83.20	10.40	82.50
DX6	9.16	86.10	10.40	81.90
DX7	8.10	89.20	9.28	85.85

Table 7. Summary of the results of scenarios DX1 to DX7 for predicting the horizontal position of the berm crest

براساس شکل (۱۲)، در نمودار A (داده‌های آموزش)، روند تغییرات RMSE با شیب زیاد و نزولی تا سناریو شماره 3 DY3 ادامه داشته و در سناریوهای DY3 تا DY6 با شیب نسبتاً ثابت و تغییرات ناچیز پیش می‌روند. همچنین تغییرات R² تا سناریو شماره 3 DY3 با شیب زیاد صعودی بوده و از سناریو 6 DY6 تغییرات ناچیز است. داده‌های آموزش سناریوهای 3 و 4 DY4 و DY3 تغییرات ناچیز است. داده‌های آموزش سناریوهای 3 و 4 بهترین عملکرد را نشان می‌دهند. در نمودار B (داده‌های تست) نیز تغییرات خطای RMSE تا سناریو 4 DY4 دارای روند نزولی با شیب زیاد می‌باشد، که کاهش در خطای به میزان ۲۳٪ نسبت به سناریو 1 DY1 و ۸٪ نسبت به سناریو 3 DY3 را نشان می‌دهد. همچنین اختلاف خطای در سناریو 4 DY4 نسبت به سناریو 5 DY5 ۱۴٪ است. تغییرات R² نیز دارای روند صعودی با شیب نسبتاً زیاد تا سناریو 4 DY4 می‌باشد. در داده‌های آموزش سناریوهای 3 و 4 همان روند را به خوبی در نتایج تست نشان می‌دهند که در مجموع، سناریو 4 DY4 نتایج بهتری دارد.

در سناریوهای 3 DY3 تا 6 DY6 هیچ گونه پیش‌بازش یا کم‌بازشی مشاهده نشده است ولی در سناریوهای 1 DY1 و 2 DY2 شرایط کم‌بازشی مشاهده شده است. سناریو 4 DY4 به همراه پارامترهای ارتفاع تاج سکوی برم، تغییرات خط ساحل، تغییرات افقی تاج سکوی برم و توان موج به عنوان سناریو نهایی برای پیش‌بینی مناسب تغییرات ارتفاعی تاج سکوی ساحلی انتخاب شده است.

موقعیت افقی تاج سکوی ساحلی: در این بخش پیش‌بینی موقعیت افقی تاج سکوی ساحلی انجام گرفته است که ساختار مدل پیش‌بینی مشابه با بخش‌های قبل لحاظ شده است. همچنین

شکل ۱۳. نمودارهای بهینه‌ترین مدل بر اساس عدد Epoch و مقدار MSE در سناریوهای منتخب موقعیت افقی تاج سکوی ساحلی DX7 تا DX1




Fig. 13. The optimal model based on the Epoch and the MSE for scenarios DX1 to DX7 for the horizontal position of the berm crest

شکل ۱۵. نمایش خلاصه نتایج آموزش و پیش‌بینی در سناریوهای منتخب موقعیت افقی تاج سکوی ساحلی DX1 تا DX7





Fig. 15. Summary of the results of training and predicting in scenarios DX1 to DX6 in the horizontal position of the berm crest Chart A shows training data and Chart B test data

شکل ۱۴. نمودارهای R^2 داده‌های آموزش و تست در سناریوهای منتخب موقعیت افقی تاج سکوی ساحلی DX1 تا DX7Fig. 14. Graphs of $R^2\%$ results of train and test for scenarios DX1 to DX7 in the horizontal position of the berm crest

(داده‌های تست) نیز روند تغییرات RMSE با شیب زیاد و نزولی (داده‌های تست) نیز روند تغییرات RMSE با شیب زیاد و نزولی (داده‌های آموزش) روند تغییرات DX7 ادامه دارد. میزان کاهش خطأ از سناریو 1 تا سناریو 7 ادامه دارد. میزان کاهش خطأ از سناریو 1 تا سناریو 7 ۲۲٪ می‌باشد. در مقایسه سناریو DX7 با سناریو DX6 میزان کاهش خطأ ۱۰٪ می‌باشد. تغییرات R^2 نیز دارای شیب صعودی بوده و میزان تغییرات از سناریو 1 تا DX7 نزدیک به ۱۴٪ است. در تست‌های انجام گرفته روی سناریوهای DX7 تا DX3 هیچ گونه پیش‌برازشی یا کم‌برازشی مشاهده نشده است اما در سناریوهای DX1 و DX2 شرایط کم‌برازشی مشاهده می‌شود.

براساس شکل (۱۵)، نمودار A (داده‌های آموزش)، روند تغییرات RMSE شیب زیاد و نزولی تا سناریو شماره 7 می‌باشد. میزان کاهش خطأ از سناریو 1 تا DX7 ۲۷٪ بوده است. همچنین با مقایسه سناریو DX7 نسبت به سناریو ماقبل DX6 نیز میزان کاهش خطأ عدد نسبتاً بالای ۱۱٪ می‌باشد. تغییرات R^2 نیز دارای شیب صعودی بوده و میزان تغییرات از سناریو 1 تا DX7 نزدیک به ۱۰٪ می‌باشد. بر این اساس سناریو DX7 در بخش داده‌های آموزش بهترین عملکرد را داشته است. در بخش B

DS3 و DS5 می‌توان برای مقایسه و تایید نتیجه بدست آمده استفاده نمود. در شکل (۱۶) هیستوگرام خطای سناریوهای DS3 تا DS5 نشان داده شده است. اختلاف خطاهای تابع هدف و خروجی در سناریو DS4 در محدوده خطای صفر متتمرکز است و تعداد بیشتری از داده‌ها را در مقایسه با دو سناریوی دیگر پوشش می‌دهد. بر این اساس نتایج بدست آمده مورد تایید است.

تغییرات ارتفاعی تاج سکوی ساحلی: نتایج ۶ سناریو

تغییرات ارتفاعی تاج سکوی ساحلی نشان داد که؛ سناریو DY4 با RMSE برابر با 0.35 متر و $R^2 = 0.75$ % به عنوان سناریو نهایی Δx Shoreline Δx_{BC} انتخاب شد. این سناریو شامل پارامترهای Δx و P هست. برای تایید سناریو انتخابی با مقایسه هیستوگرام خطای سناریوهای قبل و بعد از سناریو DY4 در شکل (۱۷) مشخص می‌شود که اختلاف خطاهای تابع هدف و خروجی در سناریو DS4، با بیش از 500 داده با خطای زیر 0.10 متر، با اختلاف بهتر از دو سناریو دیگر می‌باشد که سناریو انتخابی را تایید می‌کند.

سناریو DX7 به عنوان سناریو نهایی به همراه پارامترهای عرض سکوی برم، شبیه سکوی برم، تغییرات ارتفاعی تاج سکوی برم، ارتفاع سکوی برم، انرژی موج، تراز سطح دریا و اندیس شکست موج به عنوان سناریو نهایی برای پیش‌بینی مناسب موقعیت افقی سکوی ساحلی انتخاب می‌شود. همچنین نتایج نشان داد که؛ پارامتر اندیس شکست موج تاثیر زیادی در بهبود عملکرد پیش‌بینی ارائه می‌نماید.

۵- بحث و گفت و گو

تغییرات خط ساحل: مطابق با نتایج بدست آمده، پیش‌بینی تغییرات خط ساحل در ۶ سناریو نشان داد که؛ سناریو DS4 با RMSE برابر با 0.30 متر و $R^2 = 0.92$ % به عنوان سناریو نهایی برای پیش‌بینی تغییرات خط ساحل انتخاب شد که شامل پارامترهای ΔBW و $Berm Slope$ هست. برای تایید نتایج سناریو انتخابی به کمک هیستوگرام خطای که شامل اختلاف مقادیر تابع هدف و خروجی الگوریتم شبکه عصبی است، با مقایسه نزدیکترین سناریوهای انتخابی یعنی سناریوهای

شکل ۱۶. هیستوگرام خطای اختلاف مقادیر تابع هدف و پیش‌بینی در تغییرات خط ساحل، سناریوهای DS5 تا DS3




Fig. 16. Histogram showing the difference between the error of the objective function and the output of scenarios from DS3 to DS5 in shoreline changes

شکل ۱۷. هیستوگرام خطای اختلاف مقادیر تابع هدف و پیش‌بینی در تغییرات ارتفاعی تاج سکوی ساحلی، سناریوهای DY5 تا DY3




Fig. 17. Histogram showing the difference between the error of the objective function and the output of scenarios from DY3 to DY5 in berm crest elevation variation

است. اختلاف خطاهای تابع هدف و خروجی کمتر از ۶ متر در سناریو 7 DX7، تقریباً تعداد ۶۰۰ داده را پوشش می‌دهد اما در سناریو 6 DX6 این عدد ۴۴۵ داده می‌باشد. در نتیجه سناریو 7 DX7 توانسته است داده‌های بیشتری را با خطای کمتر پیش‌بینی نماید که نتیجه بدست آمده را تایید می‌کند.

موقعیت افقی تاج سکوی ساحلی: پیش‌بینی موقعیت افقی تاج سکوی ساحلی در ۷ سناریو نشان داد که؛ سناریو 7 DX7 با RMSE برابر با $9/28$ متر و $R^2 = 85/80\%$ به عنوان سناریو نهایی، شامل پارامترهای ΔyBC , $Berm Slope$, BW , E , $Height$, SLR و Δ انتخاب شد. برای تایید سناریو انتخابی، هیستوگرام خطای اختلاف مقادیر تابع هدف و پیش‌بینی در شکل (۱۸) مقاسیه شده

شکل ۱۸. هیستوگرام خطای اختلاف مقادیر تابع هدف و پیش‌بینی در موقعیت افقی تاج سکوی ساحلی، سناریوهای DX6 و DX7




Fig. 18. Histogram showing the difference between the error of the objective function and the output of scenarios DX6 and DX7 in the horizontal position of the berm crest

ساحل بحرانی ترین مکان در هر ساحل می‌باشد) برای ساخت مدل اولیه با بهترین هایپر پارامترها بررسی شد. نتایج بدست آمده نشان داد که سناریو 4 DS4 با RMSE $3/03$ متر و $R^2 = 92\%$ عملکرد قابل قبولی در پیش‌بینی تغییرات خط ساحل دارد. همچنین با مقایسه هیستوگرام خطای اختلاف مقادیر پیش‌بینی و تابع هدف نیز مشخص شد که سناریو 4 DS4 تعداد بیشتری از داده‌ها را با خطای کمتر پیش‌بینی نموده است. در گام دوم پیش‌بینی تغییرات ارتفاعی تاج سکوی ساحلی با همان مدل ساخته شده در گام اول انجام گرفت. نتایج بدست آمده نشان داد که سناریو 4 DY4 با RMSE $0/35$ متر و $R^2 = 75\%$ توانایی مناسبی در پیش‌بینی تغییرات ارتفاعی تاج سکوی ساحلی دارد. همچنین با مقایسه هیستوگرام خطای اختلاف مقادیر پیش‌بینی و تابع هدف نیز مشخص شد که سناریو 4 DY4 توانسته است نزدیک به ۵۰۰ داده را با خطای کمتر از $10/0$ متر پیش‌بینی نماید که عملکرد مناسب آن را تایید می‌نماید. در گام سوم نیز پیش‌بینی موقعیت افقی تاج سکوی ساحلی مشابه با گام‌های قبلی انجام گرفته است. نتایج نشان می‌دهد که سناریو 7 DX7 با $9/28$ RMSE و $R^2 = 85/80\%$ عملکرد خوبی در پیش‌بینی موقعیت افقی تاج سکوی ساحلی ارائه نموده است. در ادامه ارزیابی هیستوگرام خطای اختلاف مقادیر پیش‌بینی و تابع هدف

۶- نتیجه‌گیری

در این پژوهش؛ به کمک الگوریتم‌های یادگیری ماشین، پیش‌بینی عارضه‌های مورفو دینامیک (تابع هدف) ناحیه ساحلی نارابین استرالیا در شرایط غیر طوفانی انجام گرفته است. در بخش اول این پژوهش به کمک الگوریتم‌های انتخاب ویژگی (Wrapper)، پارامترهای مناسب‌تر برای پیش‌بینی تابع هدف فیلتر شده تا پارامترهای کم تاثیر و یا نامناسب از محاسبات حذف شوند. سپس در ادامه سناریوهای مناسب تابع هدف ساخته شده‌اند. و در بخش نهایی نیز از الگوریتم شبکه عصبی پیشخور برای پیش‌بینی کمک گرفته شده است.

انتخاب ویژگی: با شناسایی پارامترهای هیدرودینامیک و مورفو دینامیک، در مجموع ۲۲ پارامتر شناسایی شد و پس از فیلتر نمودن آنها، سناریو های مناسب پیش‌بینی ساخته شدند. بر این اساس پیش‌بینی تغییرات خط ساحل به کمک ۶ سناریو DS1 تا DS6، پیش‌بینی تغییرات ارتفاعی تاج سکوی ساحلی به کمک ۶ سناریو DY1 تا DY6 و پیش‌بینی موقعیت افقی تاج سکوی ساحلی به کمک ۷ سناریو DX1 تا DX7 انجام گرفت.

پیش‌بینی: در گام اول پیش‌بینی تغییرات خط ساحل (خط

تقدیر و تشکر

اطلاعات مورد استفاده در این تحقیق حاصل تلاش پژوهشگران بسیاری در سراسر جهان هست؛ جمع آوری داده‌های ساحلی استرالیا در ارتباط با پژوهه‌های تحقیقاتی مرکز مطالعاتی و دانشگاهی این کشور؛ مجموعه داده‌های هواشناسی از European Center for Medium-Range Weather Forecasts؛ داده‌های تغییرات تراز آب دریا از پایگاه داده‌ای AVISO. از تلاش‌های تمامی پژوهشگرانی که کمک نمودند تا این پژوهش انجام گیرد، تقدیر و سپاس فراوان داریم.

نشان داد که این سناریو تقریباً ۶۰۰ داده را با خطای کمتر از ۶ متر پوشش می‌دهد. از آنجایی که موقعیت تاج سکوی ساحلی در بازه‌های زمانی مختلف ایجاد متholm تغییرات زیادی می‌شود، نتایج بدست آمده قابلیت اعتماد مناسبی دارند.

با بررسی نتایج بدست آمده در پیش‌بینی سه تابع هدف تغییرات خط ساحل، تغییرات ارتفاعی و موقعیت افقی تاج سکوی ساحلی می‌توان نتیجه گرفت که؛ الگوریتم شبکه عصبی توانایی بالایی در پیش‌بینی تغییرات مورفودینامیک ساحلی دارد. همچنین استفاده از الگوریتم‌های انتخاب ویژگی می‌تواند برای کاهش ابعاد مساله و کمک به انتخاب پارامترهای مناسب با ارتباط بیشتر کمک نماید.

References

- [1] Alves, B., Angnuureng, D.B., Morand, P. and Almar, R., 2020. A review on coastal erosion and flooding risks and best management practices in West Africa: what has been done and should be done. *Journal of Coastal Conservation*, 24(3), p.38.
- [2] Puplampu, D.A., Iddris, K., Alorbu, V., Asante, J.O., Takaman, J.L. and Owusu, A.B., 2023. Shoreline change analysis of the eastern coast of Ghana between 1991 and 2020. *Journal of Environmental Geography*, 16(1-4), pp.11-21. <https://doi.org/10.14232/jengeo-2023-44339>.
- [3] Ahmed, N., Howlader, N., Hoque, M.A.A. and Pradhan, B., 2021. Coastal erosion vulnerability assessment along the eastern coast of Bangladesh using geospatial techniques. *Ocean & Coastal Management*, 199, p.105408. <https://doi.org/10.1007/s11852-020-00755-7>.
- [4] Baig, M.R.I., Ahmad, I.A., Shahfahad, Tayyab, M. and Rahman, A., 2020. Analysis of shoreline changes in Vishakhapatnam coastal tract of Andhra Pradesh, India: an application of digital shoreline analysis system (DSAS). *Annals of GIS*, 26(4), pp.361-376.
- [5] Zollini, S., Dominici, D., Alicandro, M., Cuevas-González, M., Angelats, E., Ribas, F., & Simarro, G. (2023). New Methodology for Shoreline Extraction Using Optical and Radar (SAR) Satellite Imagery. *Journal of Marine Science and Engineering*, 11(3). <https://doi.org/10.3390/jmse11030627>.
- [6] Rangel-Buitrago, N., Neal, W.J. and de Jonge, V.N., 2020. Risk assessment as tool for coastal erosion management. *Ocean & Coastal Management*, 186. <https://doi.org/10.1016/j.ocecoaman.2020.105099>.
- [7] Liew, M., Xiao, M., Jones, B.M., Farquharson, L.M. and Romanovsky, V.E., 2020. Prevention and control measures for coastal erosion in northern high-latitude communities: A systematic review based on Alaskan case studies. *Environmental Research Letters*, 15(9) <https://doi.org/10.1088/1748-9326/ab9387>.
- [8] Fernández-Montblanc, T., Duo, E. and Ciavola, P., 2020. Dune reconstruction and revegetation as a potential measure to decrease coastal erosion and flooding under extreme storm conditions. *Ocean & Coastal Management*, 188. <https://doi.org/10.1016/j.ocecoaman.2019.105075>.
- [9] Flor-Blanco, G., Alcántara-Carrió, J., Jackson, D.W.T., Flor, G. and Flores-Soriano, C., 2021. Coastal erosion in NW Spain: Recent patterns under extreme storm wave events. *Geomorphology*, 387. <https://doi.org/10.1016/j.geomorph.2021.107767>.
- [10] Lemke, L. and Miller, J.K., 2021. Role of storm erosion potential and beach morphology in controlling dune erosion. *Journal of Marine Science and Engineering*, 9(12). <https://doi.org/10.3390/jmse9121428>.
- [11] Harley, M.D., Masselink, G., Ruiz de Alegría-Arzaburu, A., Valiente, N.G. and Scott, T., 2022. Single extreme storm sequence can offset decades of shoreline retreat projected to result from sea-level rise. *Communications Earth & Environment*, 3(1), p.112. <https://doi.org/10.1038/s43247-022-00437-2>.
- [12] Zheng, P., Gumbira, G., Li, M., Van der Zanden, J., van der Werf, J., Chen, X. and Tang, X., 2023. Development, calibration and validation of a phase-averaged model for cross-shore sediment transport and morphodynamics on a barred beach. *Continental Shelf Research*, 258. <https://doi.org/10.1016/j.csr.2023.104989>.
- [13] Ohnen, L.O., Shirzaei, M., Ojha, C. and Kirwan, M.L., 2023. Hidden vulnerability of US Atlantic coast to sea-level rise due to vertical land motion. *Nature Communications*, 14(1). <https://doi.org/10.1038/s41467-023-37853-7>.
- [14] Toimil, A., Camus, P., Losada, I.J., Le Cozannet, G., Nicholls, R.J., Idier, D. and Maspataud, A., 2020. Climate change-driven coastal erosion modelling in temperate sandy beaches: Methods and uncertainty treatment. *Earth-Science Reviews*, 202. <https://doi.org/10.1016/j.earscirev.2020.103110>.
- [15] den Bieman, J.P., van Gent, M.R. and van den Boogaard, H.F., 2021. Wave overtopping predictions

- using an advanced machine learning technique. *Coastal Engineering*, 166. <https://doi.org/10.1016/j.coastaleng.2020.103830>.
- [16] Yin, C., Anh, D.T., Mai, S.T., Le, A., Nguyen, V.H., Nguyen, V.C., Tinh, N.X., Tanaka, H., Viet, N.T., Nguyen, L.D. and Duong, T.Q., 2021. Advanced machine learning techniques for predicting nha trang shorelines. *IEEE access*, 9, pp.98132-98149 <https://doi.org/10.1109/ACCESS.2021.3095339>.
- [17] Bellinghausen, K., Hünicke, B. and Zorita, E., 2023. Short-term prediction of extreme sea-level at the Baltic Sea coast by Random Forests. *Natural Hazards and Earth System Sciences Discussions*, 2023, pp.1-48 <https://doi.org/10.5194/nhess-2023-21>.
- [18] Beuzen, T. and Splinter, K., 2020. Machine learning and coastal processes. In *Sandy beach morphodynamics*, pp. 689-710. <https://doi.org/10.1016/B978-0-08-102927-5.00028-X>.
- [19] Goldstein, E.B., Coco, G. and Plant, N.G., 2019. A review of machine learning applications to coastal sediment transport and morphodynamics. *Earth-science reviews*, 194, pp.97-108. <https://doi.org/10.1016/j.earscirev.2019.04.022>.
- [20] Azad, M. and Uddin, M.A., 2022. Prediction of Offshore Wave at East Coast of Malaysia—A Comparative Study. *Electronics*, 11(16). <https://doi.org/10.3390/electronics>.
- [21] Chen, H., Yunus, A.P., Nukapothula, S. and Avtar, R., 2022. Modelling Arctic coastal plain lake depths using machine learning and Google Earth Engine. *Physics and Chemistry of the Earth, Parts a/b/c*, 126. <https://doi.org/10.1016/j.pce.2022.103138>.
- [22] Luppichini, M., Bini, M., Berton, A., Casarosa, N., Merlini, S., and Paterni, M., 2022. A method based on beach profile analysis for shoreline identification. In *Ninth International Symposium "Monitoring of Mediterranean Coastal Areas: Problems and Measurement Techniques*, pp. 47–60. Firenze University Press. <https://doi.org/10.36253/979-12-215-0030-1.05>.
- [23] Pradeep, J., Shaji, E., Chandran, S., Ajas, H., Chandra, S.V., Dev, S.D. and Babu, D.S., 2022. Assessment of coastal variations due to climate change using remote sensing and machine learning techniques: A case study from west coast of India. *Estuarine, Coastal and Shelf Science*, 275 <https://doi.org/10.1016/j.ecss.2022.107968>.
- [24] Xu, G., Ji, C., Wei, H., Wang, J. and Yuan, P., 2023. A novel ensemble model using artificial neural network for predicting wave-induced forces on coastal bridge decks. *Engineering with Computers*, 39(5), pp.3269-3292. <https://doi.org/10.1007/s00366-022-01745-z>
- [25] Senechal, N., Peron, C. and Coco, G., 2023. ON the use of Artificial Neural Networks to Explore Morphological and Hydrodynamic Parameters in Shoreline Dynamics. In *Coastal Sediments 2023: The Proceedings of the Coastal Sediments 2023*, pp. 395-400.
- [26] Dalinghaus, C., Coco, G. and Higuera, P., 2023. Using genetic programming for ensemble predictions of wave setup. In *Coastal Sediments 2023: The Proceedings of the Coastal Sediments 2023*, pp. 1933-1939.
- [27] Beuzen, T., Marshall, L. and Splinter, K.D., 2018. A comparison of methods for discretizing continuous variables in Bayesian Networks. *Environmental modelling & software*, 108, pp.61-66. <https://doi.org/10.1016/j.envsoft.2018.07.007>.
- [28] Beuzen, T., Splinter, K.D., Marshall, L.A., Turner, I.L., Harley, M.D. and Palmsten, M.L., 2018. Bayesian Networks in coastal engineering: Distinguishing descriptive and predictive applications. *Coastal Engineering*, 135, pp.16-30. <https://doi.org/10.1016/j.coastaleng.2018.01.005>.
- [29] Zeinali, S., Dehghani, M. and Talebbeydokhti, N., 2021. Artificial neural network for the prediction of shoreline changes in Narrabeen, Australia. *Applied Ocean Research*, 107. <https://doi.org/10.1016/j.apor.2020.102362>.
- [30] Harley, M., Ibaceta, R., Leaman, C., Splinter, K. and Turner, I., 2023. Data-Driven modeling of coastal storm erosion: Narrabeen beach, Australia. In *Coastal Sediments 2023: The Proceedings of the Coastal Sediments 2023*, pp. 314-320. https://doi.org/10.1142/9789811275135_0028.
- [31] Turner, I.L., Harley, M.D., Short, A.D., Simmons, J.A., Bracs, M.A., Phillips, M.S. and Splinter, K.D., 2016. A multi-decade dataset of monthly beach profile surveys and inshore wave forcing at Narrabeen, Australia. *Scientific data*, 3(1), pp.1-13. <https://doi.org/10.1038/sdata.2016.24>.
- [32] Jaramillo, C., Jara, M.S., González, M. and Medina, R., 2021. A shoreline evolution model for embayed beaches based on cross-shore, planform and rotation equilibrium models. *Coastal Engineering*, 169. <https://doi.org/10.1016/j.coastaleng.2021.103983>

چگونه به این مقاله ارجاع دهیم؟

Jabari Khameneh, A., Adjami, M. and Gharachelo, S., 2025. Prediction of Coastal Berm Size and Location Changes in Non-Storm Conditions using ANN. *Modares Civil Engineering journal*, 25(2), pp.67-84.

DOI: 10.22034/25.2.67

